

Número: 35

SCOPUS

UNIVERSIDAD POLITÉCNICA SALESIANA ECUADOR


pISSN: 1390-650X

eISSN: 1390-860X

enero / junio 2026

INGENIUS

Revista de Ciencia y Tecnología



Q3
SJIR Journal
Rank

SUBJECT AREA AND CATEGORY
Engineering
(miscellaneous)

- Avances en el análisis computacional para la optimización de motores a reacción: una revisión de CFD, análisis estructural y enfoques multidisciplinares.

Pag. 36

- Optimización de la computación humana multitud con IUI adaptables para obtener escalabilidad y explicación.

Pag. 52

- Análisis de impedancias de tierra de forma cerrada en estudios de cortocircuitos de sistemas de distribución aérea.

Pag. 69

- Mejorando la segmentación semántica para la accesibilidad urbana mediante datos sintéticos de alta fidelidad.

Pag. 122

Indexada en: **SCOPUS**

INGENIUS

INGENIUS • Número 35 • enero/junio 2026. Revista de Ciencia y Tecnología de la Universidad Politécnica Salesiana del Ecuador. Publicación dedicada a estudios relacionados con las Ciencias de la Ingeniería Mecánica, Ingeniería Eléctrica, Ingeniería Electrónica, Ingeniería Mecatrónica, Ciencias de la Computación y áreas afines.

Consejo de Editores

RAFAEL ANTONIO BALART GIMENO, PHD, Universidad Politécnica de Valencia, España – Editor Jefe.

JOHN IGNACIO CALLE SIGUENCIA, PHD, Universidad Politécnica Salesiana, Ecuador – Editor Jefe.

Consejo Científico

JUAN LÓPEZ MARTÍNEZ, PHD, Universidad Politécnica de Valencia, España.

ELENA FORTUNATI, PHD, Universidad de Perugia, Italia.

GUSTAVO ROVELO RUIZ, PHD, Hasselt University, Diepenbeek, Bélgica.

FRANKLIN GAVILANEZ ALVAREZ, PHD, American University, Estados Unidos.

PIEDAD GAÑAN ROJO, PHD, Universidad Pontificia Bolivariana, Colombia.

JOSÉ ALEX RESTREPO, PHD, Universidad Simón Bolívar, Venezuela.

SERGIO LUJAN MORA, PHD, Universidad de Alicante, España.

MARTHA ZEQUERA DÍAZ, PHD, Pontificia Universidad Javeriana, Colombia.

GROVER ZURITA, PHD, Universidad Privada Boliviana, Bolivia.

VLADIMIR ROBLES, PHD, Universidad Politécnica Salesiana, Ecuador.

GERMÁN ARÉVALO, PHD, Universidad Politécnica Salesiana, Ecuador.

WILBERT AGUILAR, PHD, Universidad de las Fuerzas Armadas, ESPE, Ecuador.

PABLO PARRA ROSERO, PHD, Universidad Politécnica Salesiana, Ecuador.

JACK BRAVO TORRES, PHD, Universidad Politécnica Salesiana, Ecuador.

WALTER OROZCO, PHD, Universidad Politécnica Salesiana, Ecuador.

MARIELA CERRADA, PHD, Universidad Estatal de Milagro, Ecuador.

JULIO CÉSAR VIOLA, PHD, Universidad Politécnica Salesiana, Ecuador.

SERGIO GAMBOA SÁNCHEZ, PHD, Universidad Nacional Autónoma de México, México.

ROGER ABDÓN BUSTAMANTE PLAZA, PHD, Universidad de Chile, Chile.

CHRISTIAN BLUM, PHD, Consejo Superior de Investigaciones Científicas, España.

SILVIA NOEMI SCHIAFFINO, PHD, Universidad Nacional del Centro de la Provincia de Buenos Aires, Argentina.

ANALÍA ADRIANA AMANDI, PHD, Universidad Nacional del Centro de la Provincia de Buenos Aires, Argentina.

MARIELA CERRADA LOZADA, PHD, Universidad Estatal de Milagro, Ecuador – Editor Asociado.

TEODIANO FREIRE BASTOS FILHO, PHD, (Universidade Federal do Espírito Santo, Brasil – Editor Asociado.

RUBÉN DE JESÚS MEDINA MOLINA, PHD, Universidad de Los Andes, Venezuela.

JOHNNY JOSUÉ BULLÓN TORREALBA, PHD, Universidad de Los Andes, Venezuela.

RODRIGO PALMA HILLERNS, PHD, Universidad de Chile, Chile.

GERARDO ESPINOZA PÉREZ, PHD, Universidad Nacional Autónoma de México, México.

ALEXANDRE MENDES ABRÃO, PHD, Universidad Federal de Minas Gerais, Brasil.

KAMLA ABDEL RADI ISMAIL, PHD, Universidad Estatal de Campinas Unicamp, Brasil.

ARNALDO DA SILVA, PHD, Universidad Estatal de Campinas Unicamp, Brasil.

ÁLVARO ROCHA, PHD, Universidad de Coimbra, Portugal.

JOSÉ ANTENOR POMILIO, PHD, Universidad Estatal de Campinas Unicamp, Brasil.

LUIS PAULO REIS, PHD, Universidad de Minho, Portugal.

LUÍS FERNANDES, PHD, Escuela Superior Náutica Infante d. Henrique, Portugal.

ANÍBAL TRAÇA DE ALMEIDA, PHD, Universidad de Coimbra, Portugal.

JORGE SÁ SILVA, PHD, Universidad de Coimbra, Portugal.

PEDRO MANUEL SOARES MOURA, PHD, Universidad de Coimbra, Portugal.

SÉRGIO MANUEL RODRIGUES LOPES, PHD, Universidad de Coimbra, Portugal.

RICARDO MADEIRA SOARES BRANCO, PHD, Universidad de Coimbra, Portugal.

CARLOS ALEXANDRE BENTO CAPELA, PHD, Universidad de Coimbra, Portugal.

FILIFE ARAUJO, PHD, Universidad de Coimbra, Portugal.

LUIS MANUEL GUERRA SILVA ROSA, PHD, Universidad de Lisboa, Portugal.

HÉLDER DE JESUS FERNANDES, PUGA, PHD, Universidad de Minho, Portugal.

FILIFE SAMUEL, PEREIRA DA SILVA, PHD, Universidad de Minho, Portugal.

CÉSAR SEQUEIRA, PHD, Universidad de Lisboa, Portugal.

JOSÉ TEIXEIRA ESTÊVÃO FERREIRA, PHD,

MARLON XAVIER QUINDE ABRIL, MSC, Universidad Politécnica Salesiana, Ecuador – Editor Asociado.

Universidad de Coimbra, Portugal.

NUNO LARANJEIRO, PHD, Universidad de Coimbra, Portugal.

LUÍS AMARAL, PHD, Universidad de Lisboa, Portugal.

JORGE HENRIQUES, PHD, Universidad de Coimbra, Portugal.

WILLIAM IPANAQUE, PHD, Universidad de Piura, Perú.

LORENZO LEIJA SALAS, PHD, Centro de Investigación y Estudios Avanzados del Instituto Politécnico Nacional, México.

VALERI KONTOROVICH MAZOVER, PHD, Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional, México.

ALEJANDRO ÁVILA GARCÍA, PHD, Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional, México.

PAOLO BELLAVISTA, PHD, Universidad de Bologna, Italia.

CARLOS RUBIO, PhD, Centro de Ingeniería y Desarrollo Industrial, México.

FERNANDO HERNÁNDEZ SÁNCHEZ, PhD, Centro de Investigación Científica de Yucatán, México.

EMILIO MUÑOZ SANDOVAL, PhD, Instituto Potosino de Investigación Científica y Tecnológica, México.

YASUHIRO MATSUMOTO KUWABARA, PhD, Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional, México.

DAVID ZUMOFFEN, PhD, Centro Internacional Franco Argentino de Ciencias de la Información y de Sistemas, Argentina.

VICENTE RODRÍGUEZ GONZÁLEZ, PhD, Instituto Potosino de Investigación Científica y Tecnológica, México.

ALEJANDRO RODRÍGUEZ ÁNGELES, PhD, Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional, México.

ALISTAIR BORTHWICK, PhD, Universidad de Edimburgo, Reino Unido.

Consejo de Revisores

FEDERICO DOMINGUEZ, PHD, Escuela Superior Politécnica del Litoral, Ecuador.

ENRIQUE CARRERA, PHD, Universidad de las Fuerzas Armadas, ESPE, Ecuador.

ANDRÉS TELLO, MSc, Universidad de Cuenca, Ecuador.

CRISTIAN GARCÍA BAUZA, PHD, Universidad Nacional del Centro de la Provincia de Buenos Aires, Argentina.

OSVALDO AÑÓ, PHD, Universidad Nacional de San Juan, Argentina.

THALÍA SAN ANTONIO, PHD, Universidad Técnica de Ambato, Ecuador.

VICTOR SAQUICELA, PHD, Universidad de Cuenca, Ecuador.

GONZALO OLMEDO, PHD, Universidad de las Fuerzas Armadas, ESPE, Ecuador.

ROMÁN LARA, PHD, Universidad de las Fuerzas Armadas, ESPE, Ecuador.

GUILLERMO SORIANO, PHD, Escuela Superior Politécnica del Litoral, Ecuador.

MARÍA FERNANDA GRANDA, PHD, Universidad de Cuenca, Ecuador.

RICARDO CAYSSIALS, PHD, Universidad Tecnológica Nacional, Argentina.

LEONARDO SOLAQUE GUZMAN, PHD, Universidad Militar Nueva Granada, Colombia.

JOSÉ DI PAOLO, PHD, Universidad Nacional de Entre Ríos, Argentina.

ASTRID RUBIANO FONSECA, PHD, Universidad Militar Nueva Granada, Colombia.

ROBINSON JIMÉNEZ, PHD, Universidad Militar Nueva Granada, Colombia.

ALFONSO ZOZAYA, PHD, Universidad de Carabobo, Venezuela.

MAURICIO MAULEDOUX, PHD, Universidad Militar Nueva Granada, Colombia.

LUIS MEDINA, PHD, Universidad Simón Bolívar, Venezuela.

ERNESTO CUADROS-VARGAS, PHD, Universidad Católica San Pablo, Perú.

SAMUEL SEPÚLVEDA CUEVAS, PHD, Universidad de la Frontera, Chile.

CARLOS CARES, PHD, Universidad de la Frontera, Chile.

RAFAEL SOTELO, PHD, Universidad de Montevideo, Uruguay.

OMAR LOPEZ, PHD, Universidad de Los Andes, Colombia.

JOB FLORES-GODOY, PHD, Universidad Católica del Uruguay, Uruguay.

LUIS MARIO MATEUS, PHD, Universidad de los Andes, Colombia.

AMADEO ARGÜELLES CRUZ, PHD, Instituto Politécnico Nacional, México.

SANTIAGO BENTANCOURT PARRA, PHD, Universidad Pontificia Bolivariana, Colombia.

ALBERTO SORIA, PHD, Centro de Investiga-

ción y de Estudios Avanzados del Instituto Politécnico Nacional, México.

GERMÁN ZAPATA, PHD, Universidad Nacional de Colombia, Colombia.

PEDRO GARCÍA, PHD, Universidad Autónoma de Barcelona, España.

ARTURO CONDE ENRÍQUEZ, PHD, Universidad Autónoma de Nuevo León, México.

ALBERTO CAVAZOS GONZÁLEZ, PHD, Universidad Autónoma de Nuevo León, México.

ERNESTO VÁZQUEZ MARTÍNEZ, PHD, Universidad Autónoma de Nuevo León, México.

MIGUEL DÍAZ RODRIGUEZ, PHD, Universidad de Los Andes, Venezuela.

EFRAÍN ALCORTA GARCÍA, PHD, Universidad Autónoma de Nuevo León, México.

LUIS CHIRINOS GARCIA, PHD, Pontificia Universidad Católica de Perú, Perú.

OSCAR AVILÉS, PHD, Universidad Militar Nueva Granada, Colombia.

DORA MARTÍNEZ DELGADO, PHD, Universidad Autónoma de Nuevo León, México.

DAVID OJEDA, PHD, Universidad Técnica del Norte, Ecuador.

IRENE BEATRÍZ STEINMANN, PHD, Universidad Tecnológica Nacional, Argentina.

MARIO SERRANO, Universidad Nacional de San Juan, Argentina.

CORNELIO POSADAS CASTILLO, PHD, Universidad Autónoma Nuevo León, México.

MARIO ALBERTO RIOS MESIAS, PHD, Universidad de Los Andes, Colombia.

YUDITH CARDINALE VILLARREAL, PHD, Universidad Simón Bolívar, Venezuela.

JOSE EDUARDO OCHOA LUNA, PHD, Universidad Católica San Pablo, Perú.

DANTE ANGEL ELIAS GIORDANO, PHD, Pontificia Universidad Católica de Perú, Perú.

MANUEL PELAEZ SAMANIEGO, PHD, Universidad de Cuenca, Ecuador.

JUAN ESPINOZA ABAD, PHD, Universidad de Cuenca, Ecuador.

PIETRO CODARA, PHD, Universidad de Milan, Italia.

JOSÉ M. ALLER, PHD, Universidad Politécnica Salesiana, Ecuador.

FERNEY AMAYA F., PHD, Universidad Pontificia Bolivariana, Medellín, Colombia.

SANTIAGO ARANGO ARAMBURO, PHD, Universidad Nacional de Colombia, Colombia.

DIEGO ARCOS-AVILÉS, PHD, Universidad de las Fuerzas Armadas, ESPE, Ecuador.

PABLO AREVALO, PHD, Universidad Politécnica Salesiana, Ecuador.

ROBERTO BELTRAN, MSc, Universidad de las Fuerzas Armadas, ESPE, Ecuador.

LEONARDO BETANCUR, PHD, Universidad Pontificia Bolivariana, Medellín, Colombia.

ROBERTO GAMBOA, PHD, Universidad de Lisboa, Portugal.

PAULO LOPES DOS SANTOS, PHD, Universidad do Porto, Portugal.

PEDRO ANDRÉ DIAS PRATES, PHD, Universidad de Coimbra, Portugal.

JOSÉ MANUEL TORRES FARINHA, PHD, Universidad de Coimbra, Portugal.

CELSO DE ALMEIDA, PHD, Universidad Estatal de Campinas Unicamp, Brasil.

RAMON MOLINA VALLE, PHD, Universidad Federal de Minas Gerais, Brasil.

CRISTINA NADER VASCONCELOS, PHD, Universidad Federal Fluminense, Brasil.

JOÃO M. FERREIRA CALADO, PHD, Universidad de Lisboa, Portugal.

GUILHERME LUZ TORTORELLA, PHD, Universidad Federal de Santa Catarina, Brasil.

MAURO E. BENEDET, PHD, Universidad Federal de Santa Catarina, Brasil.

ARTEMIS MARTI CESCHIN, PHD, Universidade de Brasilia, Brasil.

GILMAR BARRETO, PHD, Universidad Estatal de Campinas Unicamp, Brasil.

RICARDO EMILIO F. QUEVEDO NOGUEIRA, PHD, Universidad Federal de Ceará, Brasil.

WESLEY LUIZ DA SILVA ASSIS, PHD, Universidad Federal Fluminense, Brasil.

ANA P. MARTINAZZO, PHD, Universidad Federal Fluminense, Brasil.

JORGE BERNARDINO, PHD, Universidad de Coimbra, Portugal.

LUIS GERALDO PEDROSO MELONI, PHD, Universidad Estatal de Campinas Unicamp, Brasil.

FACUNDO ALMERAYA CALDERÓN, PHD, Universidad Autónoma de Nuevo León, México.

FREDDY VILLAO QUEZADA, PHD, Escuela Superior Politécnica del Litoral, Ecuador.

JOSE MANRIQUE SILUPU, MSc, Universidad de Piura, Perú.

GERMÁN ARIEL SALAZAR, PHD, Instituto de Investigaciones en Energía no Convencional, Argentina.

JOSÉ MAHOMAR JANANÍAS, PHD, Universidad del BIOBIO, Chile.

ARNALDO JÉLVEZ CAAMAÑO, PHD, Universidad del BIOBIO, Chile.

JORGE ANDRÉS URIBE, MSc, Centro de Ingeniería y Desarrollo Industrial, México.

RICARDO BELTRAN, PHD, Centro de Investigación en Materiales Avanzados, México.

ADI CORRALES, MSc, Centro de Ingeniería y Desarrollo Industrial, México.

JORGE URIBE CALDERÓN, PHD, Centro de Investigación Científica de Yucatán, México.

FREDDY BUENO PALOMEQUE, MSc, Universidad Politécnica Salesiana, Ecuador.

JOSÉ TRINIDAD HOLGUÍN MOMACA, MSc, Centro de Investigación en Materiales Avanzados, México.

JUAN MANUEL ALVARADO OROZCO, PhD, Centro de Ingeniería y Desarrollo Industrial, México.

ARNALDO JÉLVEZ CAAMAÑO, PhD, Universidad del BIOBIO, Chile.

JAVIER MURILLO, PhD, Centro Internacional Franco Argentino de Ciencias de la Información y de Sistemas, Argentina.

LUCAS DANIEL TERISSI, PhD, Universidad Nacional de Rosario, Argentina.

RENE VINICIO SANCHEZ LOJA, PhD, Universidad Politécnica Salesiana, Ecuador.

DIEGO CABRERA MENDIETA, PhD, Universidad Politécnica Salesiana, Ecuador.

EDWUIN JESUS CARRASQUERO, PhD, Universidad Técnica de Machala, Ecuador.

CARLOS MAURICIO CARRILLO ROSERO, MSc, Universidad Técnica de Ambato, Ecuador.

DIEGO CARRION GALARZA, MSc, Universidad Politécnica Salesiana, Ecuador.

CARMEN CELI SANCHEZ, MSc, Universidad Politécnica Salesiana, Ecuador.

DIEGO CHACON TROYA, MSc, Universidad Politécnica Salesiana, Ecuador.

PAUL CHASI, MSc, Universidad Politécnica Salesiana, Ecuador.

JUAN CHICA, MSc, Universidad Politécnica Salesiana, Ecuador.

DIEGO MARCELO CORDERO GUZMÁN, MSc, Universidad Católica de Cuenca, Ecuador.

LUIS JAVIER CRUZ, PhD, Universidad Pontificia Bolivariana, Medellín, Colombia.

FABRICIO ESTEBAN ESPINOZA MOLINA, MSc, Universidad Politécnica Salesiana, Ecuador.

JORGE FAJARDO SEMINARIO, PhD, Universidad Politécnica Salesiana, Ecuador.

PATRICIA FERNANDEZ MORALES, PhD, Universidad Pontificia Bolivariana, Medellín, Colombia.

MARCELO FLORES VAZQUEZ, MSc, Universidad Politécnica Salesiana, Ecuador.

CARLOS FLORES VÁZQUEZ, MSc, Universidad Católica de Cuenca, Ecuador.

CARLOS FRANCO CARDONA, PhD, Universidad Nacional de Colombia, Colombia.

CRISTIAN GARCÍA GARCÍA, MSc, Universidad Politécnica Salesiana, Ecuador.

TEONILA GARCÍA ZAPATA, PhD, Universidad Nacional Mayor de San Marcos, Perú.

LUIS GARZÓN MÑOZ, PhD, Universidad Politécnica Salesiana, Ecuador.

NATALIA GONZALEZ ALVAREZ, MSc, Universidad Politécnica Salesiana, Ecuador.

ERNESTO GRANADO, PhD, Universidad Simón Bolívar, Venezuela.

ADRIANA DEL PILAR GUAMAN, MSc, Universidad Politécnica Salesiana, Ecuador.

JUAN INGA ORTEGA, MSc, Universidad Politécnica Salesiana, Ecuador.

ESTEBAN INGA ORTEGA, PhD, Universidad Politécnica Salesiana, Ecuador.

PAOLA INGAVÉLEZ, MSc, Universidad Politécnica Salesiana, Ecuador.

CESAR ISAZA ROLDAN, PhD, Universidad Pontificia Bolivariana.

NELSON JARA COBOS, MSc, Universidad Politécnica Salesiana, Ecuador.

RUBEN JERVES, MSc, Universidad Politécnica Salesiana, Ecuador.

VICTOR RAMON LEAL, PhD, Investigador de PDVSA, Venezuela

GABRIEL LEON, MSc, Universidad Politécnica Salesiana, Ecuador.

EDILBERTO LLANES, PhD, Universidad Internacional SEK, Ecuador.

LUIS LÓPEZ LÓPEZ, PhD, Universidad Politécnica Salesiana, Ecuador.

CARLOS MAFLA YÉPEZ, MSc, Universidad Técnica del Norte, Ecuador.

HADER MARTÍNEZ, PhD, Universidad Pontificia Bolivariana, Medellín, Colombia

JAVIER MARTÍNEZ, PhD, Instituto Nacional de Eficiencia Energética y Energías Renovables, Ecuador.

ALEX MAYORGA, MSc, Universidad Técnica de Ambato, Ecuador.

JIMMY MOLINA, MSc, Universidad Técnica de Machala, Ecuador.

ANDRES MONTERO, PhD, Universidad de Cuenca, Ecuador.

VICENTE MORALES, MSc, Universidad Técnica de Ambato, Ecuador.

FABIÁN MORALES, MSc, Universidad Técnica de Ambato, Ecuador.

DIEGO MORALES, MSc, Ministerio de Electricidad y Energías Renovables del Ecuador.

YOANDRYS MORALES TAMAYO, PhD, Universidad Técnica de Cotopaxi, Cotopaxi

OLENA LEONIDIVNA NAIDIUK, MSc, Universidad Politécnica Salesiana, Ecuador.

OSCAR NARANJO, MSc, Universidad del Azuay, Ecuador.

PAUL NARVAEZ, MSc, Universidad Politécnica Salesiana, Ecuador.

HERNÁN NAVAS OLMEDO, MSc, Universidad Técnica de Cotopaxi, Ecuador.

CESAR NIETO, PhD, Universidad Pontificia Bolivariana, Medellín, Colombia

FABIO OBANDO HERRERA, MSc, Universidad Politécnica Salesiana, Ecuador.

LUIS ORTIZ FERNANDEZ, MSc, Universidade Federal de Rio Grande del Norte, Brasil

PABLO PARRA, MSc, Universidad Politécnica Salesiana, Ecuador.

PAULO PEÑA TORO, PhD, Ministerio de Productividad, Ecuador.

PATSY PRIETO VELEZ, MSc, Universidad Politécnica Salesiana, Ecuador.

DIEGO QUINDE FALCONI, MSc, Universidad Politécnica Salesiana, Ecuador.

DIANA QUINTANA ESPINOZA, MSc, Universidad Politécnica Salesiana, Ecuador.

WILLIAM QUITIAQUEZ SARZOSA, MSc, Universidad Politécnica Salesiana, Ecuador.

FLAVIO QUIZHPI PALOMEQUE, MSc, Universidad Politécnica Salesiana, Ecuador.

WASHINGTON RAMIREZ MONTALVAN, MSc, Universidad Politécnica Salesiana, Ecuador.

FRAN REINOSO AVECILLAS, MSc, Universidad Politécnica Salesiana, Ecuador.

NÉSTOR RIVERA CAMPOVERDE, MSc, Universidad Politécnica Salesiana, Ecuador.

JORGE ROMERO CONTRERAS, MSc, Universidad de Carabobo, Venezuela

FABIAN SAENZ ENDERICA, MSc, Universidad de las Fuerzas Armadas, ESPE, Ecuador.

LUISA SALAZAR GIL, PhD, Universidad Simón Bolívar, Venezuela

GUSTAVO SALGADO ENRÍQUEZ, MSc, Universidad Central del Ecuador., Ecuador.

JUAN CARLOS SANTILLÁN LIMA, MSc, Universidad Nacional de Chimborazo

ANDRÉS SARMIENTO CAJAMARCA, MSc, Universidad Federal de Santa Catarina, Brasil

RODOLFO BOJORQUE CHASI, PhD, Universidad Politécnica Salesiana, Ecuador.

PAUL TORRES JARA, MSc, Universidad Politécnica Salesiana, Ecuador.

RODRIGO TUFÍÑO CÁRDENAS, MSc, Universidad Politécnica Salesiana, Ecuador.

FERNANDO URGILES ORTÍZ, MSc, Universidad Politécnica Salesiana, Ecuador.

JUAN VALLADOLID QUITOISACA, MSc, Universidad Politécnica Salesiana, Ecuador.

MARY VERGARA PAREDES, PhD, Universidad de los Andes, Merida, Venezuela

JENNIFER YEPEZ ALULEMA, MSc, Universidad Politécnica Salesiana, Ecuador.

JULIO ZAMBRANO ABAD, MSc, Universidad Politécnica Salesiana, Ecuador.

PATRICIA ZAPATA MOLINA, MSc, Universidad Politécnica Salesiana, Ecuador.

Consejo de publicaciones

JUAN CÁRDENAS TAPIA, SDB, PhD
ESTEBAN MAURICIO INGA ORTEGA, PhD
ÁNGEL TÓRRES TOUKOUMIDIS, PhD
JAIME PADILLA VERDUGO, PhD
SHEILA SERRANO VINCENTI, PhD
JORGE CUEVA ESTRADA, MSC
JOHN CALLE SIGUENCIA, PhD
FLORALBA AGUILAR GORDÓN, PhD
BETTY RODAS SOTO, MSC
MÓNICA RUIZ VÁSQUEZ, MSC
JORGE ALTAMIRANO SÁNCHEZ, MSC
DAVID ARMENDÁRIZ GONZÁLEZ, MSC
JOSÉ JUNCOSA BLASCO, PhD

Editor General

ÁNGEL TÓRRES TOUKOUMIDIS, PhD

Consejo Técnico

DRA. MARCIA PEÑA, Revisora de Estilo,
Centro Gráfico Salesiano - Editorial Don Bosco
MARLON QUINDE ABRIL, MSC, Diagramación y Maquetación
LCDA. MARÍA JOSÉ CABRERA, Técnica Marcalyc
LCDO. CHRISTIAN ARPI, Coordinador Community Managers
LCDO. ANDRÉS LÓPEZ, Community Manager - Diagramación y Maquetación

Servicio de Publicaciones

HERNÁN HERMOSA (Coordinación General)
MARCO GUTIÉRREZ (Soporte OJS)
PAULINA TORRES (Edición)
RAYSA ANDRADE (Maquetación)
MARTHA VINUEZA (Maquetación)
YIXY GONZALEZ, (Revisora de Estilo)

Editorial

Editorial Abya Yala (Quito-Ecuador),
Avenida 12 de octubre N422 y Wilson,
Bloque A, UPS Quito, Ecuador.
Casilla 17-12-719 Teléfonos: (593-2) 3962800 ext. 2638
Correo electrónico: editorial@abyayala.org

Tiraje: 800 ejemplares

Sistema tipográfico usado en la composición de este documento L^AT_EX.

INGENIUS


REVISTA DE CIENCIA Y TECNOLOGÍA


Número 35


enero – junio 2026

ISSN impreso 1390-650X / ISSN electrónico 1390-860X

La administración de INGENIUS se realiza a través de los siguientes parámetros:


La revista utiliza el sistema antiplagio académico  

Los artículos cuentan con código de identificación (*Digital Object Identifier*) 

El proceso editorial se gestiona a través del *Open Journal System* 

Es una publicación de acceso abierto (*Open Access*) con licencia *Creative Commons*



Las políticas *copyright* y de uso *postprint*, se encuentran publicadas en el Repositorio de Políticas de Autoarchivo *Sherpa/Romeo*. 

Los artículos de la presente edición pueden consultarse en
<https://ingenius.ups.edu.ec/>



UNIVERSIDAD POLITÉCNICA SALESIANA DEL ECUADOR

La Revista INGENIUS está indexada en las siguientes Bases de Datos y sistemas de información científica:

BASE DE DATOS SELECTIVAS



Scopus



Google scholar



Scientific Indexing Services



PLATAFORMAS DE EVALUACIÓN DE REVISTAS

MIAR



DIRECTORIOS SELECTIVOS



Journal Seeker
Research Bible



AcademicKeys
UNLOCKING ACADEMIC CAREERS



ULRICHSWEB™
GLOBAL SERIALS DIRECTORY

HEMEROTECAS SELECTIVAS



Red Iberoamericana
de Innovación y Conocimiento Científico



BUSCADORES DE LITERATURA CIENTÍFICA OPEN ACCESS

DOAJ
DIRECTORY OF
OPEN ACCESS
JOURNALS



Journals for Free

OTRAS BASES DE DATOS BIBLIOGRÁFICAS

Dialnet



Journal
TOCs

The latest Journal Tables of Contents

PKP|INDEX

CATÁLOGO DE BIBLIOTECAS INTERNACIONALES UNIVERSITARIAS



UNIVERSITÄT BAMBERG



Estimadas y estimados lectores:

El progreso científico y tecnológico se consolida cuando el conocimiento se construye a partir de la integración de contextos, disciplinas y perspectivas diversas. El número 35 de nuestra revista es una clara manifestación de este principio, al reunir contribuciones académicas procedentes de América Latina, Asia y Medio Oriente, consolidando un espacio editorial de alcance internacional y carácter multidisciplinario para la difusión del conocimiento científico y tecnológico.

Desde una perspectiva geográfica, este número evidencia una valiosa colaboración internacional. Las contribuciones provenientes de México están representadas por la Universidad Autónoma de Baja California; las de Brasil, por la Pontificia Universidade Católica do Paraná; las de India, por Lovely Professional University; y las de Arabia Saudita, por la Universidad de Jazan. En el contexto latinoamericano, y particularmente desde Ecuador, se incluyen investigaciones desarrolladas en instituciones de reconocido prestigio académico, como la Pontificia Universidad Católica del Ecuador (Sede Esmeraldas), la Universidad Técnica de Machala, la Universidad Nacional de Loja, la Universidad de Cuenca, la Universidad UTE y la Universidad Politécnica Salesiana. Esta diversidad geográfica refleja tanto el posicionamiento internacional de la revista como el fortalecimiento de redes científicas Sur-Sur y la incorporación de enfoques globales en la investigación aplicada.

En cuanto a las disciplinas y líneas temáticas abordadas, este número se caracteriza por un énfasis marcado en la ingeniería, la inteligencia artificial, los sistemas energéticos, la computación y las tecnologías orientadas a la solución de problemáticas reales. Los artículos abarcan estudios sobre optimización del consumo energético en campamentos petroleros remotos, análisis computacionales avanzados para la optimización de motores a reacción mediante dinámica de fluidos computacional (CFD) y enfoques

multidisciplinarios, así como investigaciones relacionadas con sistemas eléctricos de potencia y el análisis de cortocircuitos en redes de distribución aérea.

Un aspecto especialmente relevante es la aplicación de técnicas de aprendizaje automático y aprendizaje profundo en diversos contextos. Estas metodologías se emplean en la clasificación de fracturas médicas, la segmentación semántica de defectos en paneles fotovoltaicos, la evaluación de la accesibilidad urbana, la estimación de emisiones en motores de combustión interna y la clasificación de productos agroindustriales, como el café lojano de especialidad. En conjunto, estos trabajos evidencian el carácter transversal de la inteligencia artificial como motor de innovación tecnológica y soporte para la toma de decisiones basadas en datos.

El aporte científico y profesional de los artículos publicados es significativo. Por un lado, fortalecen el conocimiento teórico mediante modelos, algoritmos y metodologías reproducibles; por otro, proponen soluciones prácticas con impacto en sectores estratégicos como la energía, la salud, la industria, el transporte, la gestión ambiental y la planificación urbana. Este equilibrio entre rigor metodológico y aplicabilidad constituye uno de los pilares de la política editorial de la revista.

Invitamos a la comunidad académica y profesional a utilizar los artículos de este número como referencias, analizarlos críticamente y citarlos en futuras investigaciones, contribuyendo así a la visibilidad y continuidad del conocimiento científico generado.

Finalmente, expresamos nuestro sincero agradecimiento a los autores que confiaron sus manuscritos a la revista y a los revisores y evaluadores que, con rigor y compromiso ético, garantizan la calidad científica de cada publicación, reafirmando el papel de la revista como un espacio de difusión de investigación de alto nivel en ciencia y tecnología.

John Calle-Siguencia, PhD

EDITOR JEFE

ÍNDICE

Optimización del consumo energético en campamentos remotos petroleros mediante tecnologías de gestión energética	9
Optimization of energy consumption in oil remote camps through energy management technologies Edwin Illescas, Edison Laz, Manuel Rogelio Nevárez Toledo, Miguel Alberto Dávila-Sacoto	
Clasificación de fracturas en extremidades superiores con aprendizaje profundo	21
Classification of upper limb fractures using deep learning Gabriela Jaén-Armijos, Evelyn Morán-Castillo, Wilmer Rivas-Asanza, Eduardo Tusa	
Avances en el análisis computacional para la optimización de motores a reacción: una revisión de CFD, análisis estructural y enfoques multidisciplinarios	36
Advancements in Computational Analysis for Jet Engine Optimization: A Review of CFD, Structural Analysis, and Multidisciplinary Approaches Abu Baker Jassim, Raja Sekhar Dondapati	
Optimización de la computación humana multitud con IUI adaptables para obtener escalabilidad y explicación	52
Optimizing crowdsourced human computation with adaptive intelligent user interfaces for scalability and explainability R. John Martin	
Análisis de impedancias de tierra de forma cerrada en estudios de cortocircuito de sistemas de distribución aérea	69
Analysis of closed-form ground-return impedances for short-circuit studies in overhead distribution systems Allen A. Castillo Barrón, Gerardo Ayala Jaimes, Alejandra Jiménez Vega, Francisco J. Ramírez Arias	
Clasificación automática de reclamos eléctricos mediante árboles de decisión y random forest: un estudio aplicado a CNEL EP	84
Automatic classification of electrical complaints using decision trees and random forest: an applied study at CNEL EP Francisco Javier Carpio Velasco, Gloria Margarita Garcés Beltrán	
Estimación de emisiones por fallos en motores Otto mediante redes neuronales convolucionales	97
Estimation of emissions from failures in Otto engines using convolutional neuronal networks Elmer I. Arias-Montaño, Rogelio S. León-Japa, Pedro García-Jaramillo, José Maldonado-Ortega	
Aplicación de modelos U-Net para segmentación semántica de defectos en paneles fotovoltaicos	110
U-Net-based semantic segmentation of defects in photovoltaic panels Franklin Gómez-López, Danny Ochoa-Correa, Isabel Cabrera-Carrera	
Mejorando la segmentación semántica para la accesibilidad urbana mediante datos sintéticos de alta fidelidad	122
Enhancing semantic segmentation for urban accessibility using high-fidelity synthetic data Santiago Felipe Luna Romero, Renato Gouveia, Mauren Abreu de Souza	
Swin Transformer V2 para clasificación de café lojano	138
Swin Transformer V2 for the classification of loja coffee Patricio Bolívar Betancourt Ludeña, Oscar M. Cumbicus Pineda	
Normas editoriales	149
Guidelines	



OPTIMIZACIÓN DEL CONSUMO ENERGÉTICO EN CAMPAMENTOS REMOTOS PETROLEROS MEDIANTE TECNOLOGÍAS DE GESTIÓN ENERGÉTICA

OPTIMIZATION OF ENERGY CONSUMPTION IN OIL REMOTE CAMPS THROUGH ENERGY MANAGEMENT TECHNOLOGIES

Edwin Illescas¹ , Edison Laz¹ , Manuel Rogelio Nevárez Toledo¹ ,
 Miguel Alberto Dávila-Sacoto^{1,*} 

Recibido: 02-04-2025, Recibido tras revisión: 21-05-2025, Aceptado: 29-09-2025, Publicado: 01-01-2026

Resumen


Optimizar los recursos en campos remotos es un criterio fundamental para la eficiencia y la reducción de costos operativos. El estudio tuvo un enfoque descriptivo-experimental, con orientación cuantitativa, en el que se analizó el consumo energético de un campamento remoto de transporte de petróleo, utilizando registros históricos desde 2021. El objetivo principal fue la reducción del consumo energético en un rango del 15% al 30%. Mediante el uso de RETScreen se simuló mejoras en los sistemas energéticos, obteniéndose como resultado un consumo eléctrico anual de 271 148 kWh/año, con gastos asociados de USD 27 454. Con la propuesta fotovoltaica, orientada a optimizar el consumo mediante tecnología de gestión energética, el consumo se redujo a 185 878 kWh/año, disminuyendo significativamente la dependencia del Sistema Nacional Interconectado y el uso de fuentes contaminantes. La eficiencia en sistemas de climatización mejoró en un 14.3%, mientras que en los sistemas eléctricos –bombas, compresores e iluminación– se alcanzó una mejora significativa de 38.6%, con un ahorro promedio de 30.9%. Respecto a las emisiones, estas se redujeron de 58.8 tCO₂ a 40.7 tCO₂, lo que equivale a la absorción de 1.7 hectáreas de bosque con un retorno de inversión estimado en 10.7 años. En conclusión, este proyecto resulta viable desde el punto de vista de la aplicación de tecnologías de eficiencia energética, al incorporar mejoras técnicas que consolidan una solución económicamente rentable y ambientalmente sostenible.

Palabras clave: campamentos remotos petroleros, gestión energética, optimización energética, RETScreen, sistemas fotovoltaicos, tecnologías de gestión

Abstract

Optimizing resource use in remote operational fields is a key strategy for enhancing efficiency and reducing operating costs. This study adopted a descriptive-experimental design with a quantitative orientation to analyze the energy consumption of a remote oil transportation camp, utilizing historical records collected since 2021. The primary objective was to achieve an energy consumption reduction of 15–30%. Using RETScreen, improvements in energy systems were simulated, resulting in an initial annual electricity consumption of 271,148 kWh and associated costs of USD 27,454. With the proposed photovoltaic system, designed to optimize energy use through advanced energy management technologies, annual consumption decreased to 185,878 kWh/year, substantially reducing dependence on the national interconnected grid and on polluting energy sources. Energy efficiency improved by 14.3% in air-conditioning systems and by 38.6% in electrical systems such as pumps, compressors, and lighting, resulting in an overall average energy savings of 30.9%. In terms of environmental impact, CO₂ emissions were reduced from 58.8 tCO₂ to 40.7 tCO₂, equivalent to the carbon sequestration of approximately 1.7 hectares of forest. The estimated return on investment is 10.7 years. These results demonstrate the technical, economic, and environmental feasibility of implementing energy-efficiency technologies to enhance sustainability in remote oilfield operations.

Keywords: remote oil camps, energy management, energy optimization, RETScreen, photovoltaic systems, management technologies.

^{1,*}Pontificia Universidad Católica, Sede Esmeraldas, Ecuador. 
 Autor para correspondencia ✉: madavila@puces.edu.ec

Forma sugerida de citación: E. Illescas, E. Laz, M. R. Nevárez Toledo y M. A. Dávila-Sacoto. “Optimización del consumo energético en campamentos remotos petroleros mediante tecnologías de gestión energética,” *Ingenius, Revista de Ciencia y Tecnología*, N.º 35, pp. 9-20, 2026. DOI: <https://doi.org/10.17163/ings.n35.2026.01>.

1. Introducción

El dinamismo que presenta la industria petrolera impacta significativamente en el crecimiento económico y social mundial. Estos recursos representan un tercio de la energía primaria utilizada por el ser humano, alcanzando el 2.5% del PIB mundial [1]. Por ello, el transporte de crudo constituye una base importante en la cadena de suministro de recursos fósiles, y los campamentos operativos remotos se enfrentan a desafíos en términos de eficiencia energética, autonomía operativa y sostenibilidad ambiental. Dichas instalaciones, en su mayoría, recurren al uso de sistemas de generación convencionales con altos factores de emisión, lo que incrementa los costos de operación y eleva su huella de carbono.

El desarrollo de tecnologías de gestión energética inteligente implica la integración de algoritmos de inteligencia artificial (IA) y aprendizaje automático (*machine learning*) en plataformas SCADA y BEMS (*Building Energy Management Systems*) [2, 3]. Estas permiten analizar patrones de consumo, predecir curvas de carga y optimizar el uso de energía en tiempo real [4, 5], adaptándose a perturbaciones estocásticas, como fluctuaciones de demanda o variabilidad en fuentes renovables [6]. De igual modo, los programas de respuesta a la demanda (DRP) fomentan que los usuarios ajusten su consumo de acuerdo con señales de red, como precios altos o incentivos [7, 8].

Siguiendo estos preceptos, los sistemas de gestión de energía (SGEn), bajo normas internacionales ISO 50001, se presentan como una estrategia contundente para el incremento de la eficiencia energética corporativa, mejorando el desempeño operacional [9, 10]. Estos sistemas requieren políticas energéticas graduales, objetivos claros y acciones orientadas a optimizar el rendimiento energético [11].

El crecimiento sostenido del consumo energético masivo y los problemas derivados del impacto ambiental de fuentes convencionales han despertado un interés mundial por una mejor gestión de la energía. En este contexto, RETScreen Expert, desarrollado por Natural Resources Canada, se presenta como una alternativa para evaluar la viabilidad técnica y económica de proyectos energéticos, modelar sistemas eléctricos y térmicos, calcular parámetros clave como el ahorro de energía, la reducción de emisiones y el balance económico. Todo ello proporciona una base sólida para la toma de decisiones fundamentada en datos, orientada a una transición energética eficaz [12].

Dentro de las soluciones de generación renovable que pueden gestionarse desde la plataforma de RETScreen, destaca la energía solar fotovoltaica, que convierte la radiación directa en electricidad mediante paneles con celdas de silicio. Esta tecnología resalta por su versatilidad, facilidad de mantenimiento y larga vida útil (25-30 años). No emite gases de efecto inver-

nadero (GEI) y su implementación depende de análisis previos de irradiancia, inclinación y eficiencia del sistema fotovoltaico [13, 14].

En el ámbito de la iluminación, las luminarias LED conectadas a fuentes renovables constituyen una alternativa eficiente, ya que ofrecen mayor vida útil, reducen emisiones y mejoran el rendimiento energético [15]. Aunque su inversión inicial es elevada, un análisis técnico-económico puede justificarla al considerar la calidad lumínica, el nivel de iluminancia (lux) y el confort visual [16].

Los sistemas de climatización representan una parte significativa del consumo energético en edificaciones, y su optimización requiere el mejoramiento del coeficiente de rendimiento (COP) [17]. Estos sistemas son responsables de más del 34% de la demanda energética y del 37% de las emisiones de CO₂ [18], por lo que deben descarbonizarse mediante la reducción del uso de combustibles fósiles y de hidrofluorocarbonos (HFC) [19].

La norma ISO 50001:2018, en su cláusula 6, presenta un marco para implementar y mejorar los sistemas de gestión de energía (SGEn), lo que permite reducir el consumo, los costos y las emisiones, así como optimizar el rendimiento energético [20]. Bajo este contexto, los campamentos petroleros dependen en gran medida del diésel y del gas natural: el primero genera altos costos e impacto ambiental, mientras que el segundo, aunque más limpio, enfrenta limitaciones logísticas. Esto concuerda con el balance energético requerido en edificaciones en general. En la Figura 1 se muestran los procesos fundamentales aplicables tanto a los sistemas de climatización como a las luminarias.

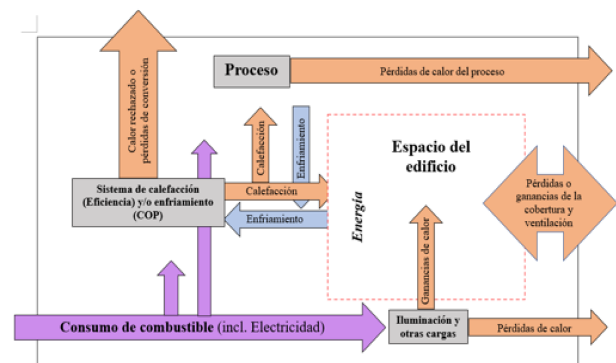


Figura 1. Balance de energía para sistemas en edificaciones.

El uso energético, que incluye tanto combustibles como electricidad, depende de su fuente principal y del sistema de calefacción/enfriamiento, cuyo desempeño se mide mediante el coeficiente de rendimiento (COP). Una parte significativa de la energía se disipa como calor residual.

La energía térmica se transfiere al interior, donde interactúa con factores como la radiación solar, la

iluminación artificial y el funcionamiento de equipos eléctricos, generando ganancias térmicas; en contraste, las pérdidas se producen a través de paredes y ventilación, lo que incrementa la demanda energética.

Los procesos industriales también aportan calor al ambiente interior; sin embargo, una fracción se pierde hacia el exterior, reduciendo la eficiencia global. Asimismo, las pérdidas a través del techo y la ventilación aumentan la carga térmica y, en consecuencia, el consumo energético.

En este contexto, la optimización del consumo mediante tecnologías de gestión energética constituye una estrategia esencial para disminuir el impacto ambiental al uso de fuentes no renovables, especialmente en campamentos remotos [21]. Este trabajo analiza la implementación de la plataforma RETScreen como herramienta para la mejora de la eficiencia energética y la incorporación de energías renovables.

El objetivo es maximizar la eficiencia del uso energético en campamentos petroleros, mediante la evaluación del consumo actual, el análisis de viabilidad a

través de RETScreen y la propuesta de sistemas renovables y alternativas a corto plazo que permitan mejorar las operaciones y reducir la demanda energética.

2. Materiales y métodos

Este estudio es descriptivo-experimental con un enfoque cuantitativo. Se analizan registros históricos de consumo energético correspondientes al período 2021-2022, que incluyen 24 mediciones realizadas en un campo de transporte de crudo. El análisis contrasta un caso base con un escenario optimizado.

Se emplea la plataforma RETScreen Expert para simular condiciones de operación, modelar subsistemas y evaluar la viabilidad de distintas medidas de eficiencia energética. El estudio se centra en los sistemas de iluminación, servicios generales y climatización. La Figura 2 ilustra el flujo energético y las fuentes de abastecimiento consideradas.

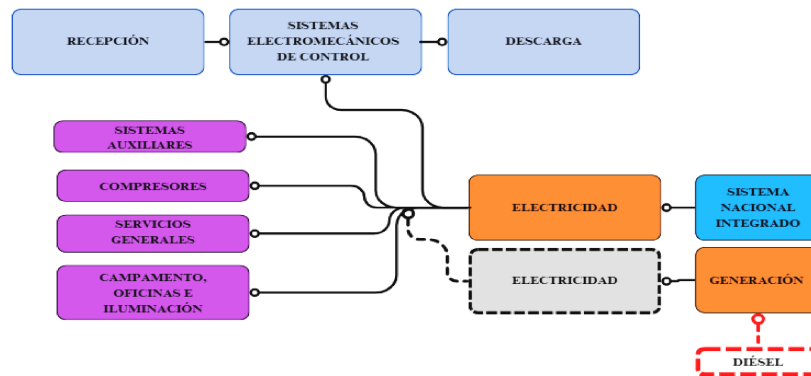


Figura 2. Comportamiento del flujo de la energía eléctrica en las áreas del campamento.

La energía proviene del Sistema Nacional Interconectado (SNI) y abastece sistemas contra incendio, compresores, comedor, oficinas e iluminación del campamento. Todo el proceso está controlado por un sistema electromecánico con válvulas. Como respaldo, generadores a diésel proveen energía en caso de fallas, conectados al mismo sistema, para garantizar la continuidad operativa.

El desempeño energético está basado en tres ejes metodológicos:

- Recopilación y análisis de datos operativos.
- Identificación de mejoras y planificación estratégica.
- Implementación y monitoreo de resultados.

Para la etapa inicial de la configuración del modelo se introdujeron los datos relativos al consumo promedio de energía del campamento, con énfasis en

los sistemas de cocción, climatización, iluminación, comprensión de fluidos y en los gastos asociados a la energía. Asimismo, se consideraron las condiciones geográficas del área (latitud, longitud, zona climática y atributos del terreno), utilizando como datos georreferenciales:

- N 0° 58' 22.268", O 79° 40' 51.536"
- 0.9728521511737187, -79.68098222443405

Para robustecer la propuesta de incorporación de sistemas de energías renovables, se añadieron variables ambientales como la temperatura del aire, la humedad relativa, la precipitación, la presión atmosférica y la temperatura del suelo. Estos factores se integraron al análisis para evaluar la viabilidad térmica y energética de los sistemas —convencionales y renovables— bajo las condiciones ambientales específicas del campamento, como se muestra en la Figura 3.

	Temperatura de diseño de la calefacción	19,6								
	Temperatura de diseño del aire acondicionado	29,0								
	Amplitud de la temperatura del suelo	9,7								
Mes	Temperatura del aire °C	Humedad relativa %	Precipitación mm	Radiación solar diaria - horizontal kWh/m²/d	Presión atmosférica kPa	Velocidad del viento m/s	Temperatura del suelo °C	Grados-días de calefacción °C-d	Grados-días de refrigeración °C-d	
Enero	24,9	83,7%	191,89	4,24	99,9	3,4	25,7	0	462	
Febrero	25,0	85,9%	231,28	4,43	99,9	2,8	25,6	0	420	
Marzo	25,1	86,5%	224,44	5,00	99,8	2,5	25,7	0	468	
Abril	25,2	86,9%	244,20	4,80	99,8	2,8	25,8	0	456	
Mayo	25,0	86,1%	146,63	4,22	99,9	3,5	25,8	0	465	
Junio	24,6	84,6%	66,60	3,73	99,9	3,8	25,5	0	438	
Julio	24,5	81,5%	36,27	3,87	100,0	4,0	25,6	0	450	
Agosto	24,8	77,9%	26,97	4,06	100,0	4,2	26,1	0	459	
Septiembre	24,9	76,4%	42,30	4,21	100,0	4,4	26,4	0	447	
Octubre	25,0	76,2%	44,95	3,98	100,0	4,5	26,4	0	465	
Noviembre	24,9	75,9%	42,30	3,81	99,9	4,4	26,3	0	447	
Diciembre	24,9	78,9%	88,04	4,07	99,9	4,1	26,1	0	462	
Anual	24,9	81,7%	1.385,87	4,20	99,9	3,7	25,9	0	5.438	

Figura 3. Datos meteorológicos acordes con la geolocalización propuesta del año 2025. Datos de la NASA.

A través de la georreferenciación se obtuvo la gráfica de los datos meteorológicos correspondientes a radiación y temperatura mensual durante un año, como se muestra en la Figura 4.

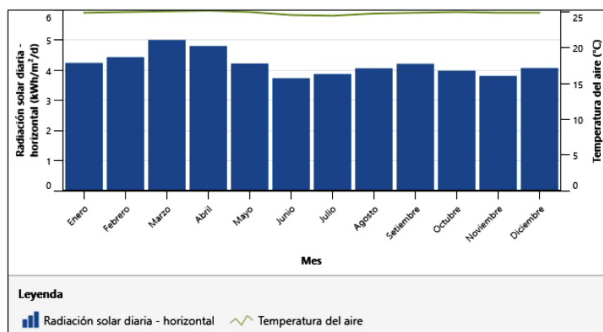


Figura 4. Gráfico comparativo relacionado con la radiación vs. temperatura mensual durante el año 2025. Datos de la NASA.

Adicionalmente, se recolectó información de consumo eléctrico correspondiente al período 2021-2022. El análisis en RETScreen aplicó estrategias de administración de gestión de la demanda, almacenamiento y optimización energética, conforme a los módulos estructurados por el software, con el objetivo de reducir pérdidas y mejorar los costos asociados al consumo de energía. Como punto de partida, la Figura 5 muestra la comparación del consumo mensual de energía (kWh) entre los años 2021 y 2022.

En 2021 se consumieron 271 148 kWh (51.86%), mientras que en 2022 el consumo fue de 251 622 kWh (48.04%), evidenciando una reducción atribuida a las movilizaciones sociales, que limitaron el uso de los campamentos.




Figura 5. Consumo energético total del campamento del 2021 en contraste con el 2022.

En lo referente al consumo de combustibles fósiles, únicamente se dispone de registros de enero-abril 2021 y de enero-marzo 2022, como muestra la Figura 6. Esta información permitió analizar el impacto térmico en la generación autónoma de electricidad, así como la correlación con la eficiencia del sistema energético evaluado.

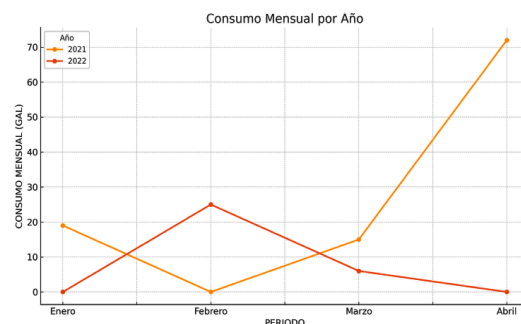


Figura 6. Consumo de combustible contrastado en período 2021-2022.

En el consumo de combustibles se refleja la variabilidad del mercado petrolero, lo cual determina el costo

en el período analizado y resulta un factor clave para el cálculo del gasto asociado al combustible consumido.

Los valores del precio unitario del combustible y su evolución se presentan en la Tabla 1.

Tabla 1. Consumo de combustible y costo representado en el caso base

Año	Período	Consumo mensual (GAL)	Costo unitario del combustible (USD)	Costo unitario promedio (USD/GAL)
2021	enero	19	1.58	12
	febrero	0	1.75	0
	marzo	15	1.94	8
	abril	72	2.18	33
2022	enero	0	2.47	0
	febrero	25	2.86	9
	marzo	6	3.39	2
	abril	0	3.91	0

La reducción del consumo del SNI fue compensada mediante generación de combustibles fósiles, se ingresaron los datos eléctricos del campamento para obtener el caso base, considerando los sistemas de generadores, bombas, compresores, iluminación, climatización y otros equipos auxiliares. La demanda energética (DE) (Ecuación (1)) se calculó como:

potencia × horas/día × días/año, ajustando la eficiencia.

$$DE(kWh/año) = Potencia(kW) \cdot horas/día \cdot días/año \quad (1)$$

En el registro energético se consideraron las cargas correspondientes al sistema de bombeo del campamento, estas se describen en la Tabla 2.

Tabla 2. Registro de datos y análisis energético para las bombas que conforman el campamento

	Motor		Bomba			Demanda energética RETSCREEN (kWh/año)
	Potencia consumida	Eficiencia nominal	Eficiencia de condiciones operativas	Carga del fluido	Horas de operación	
	(kW)	(%)	(%)	(HP)	(h/año)	
Bomba de evacuación	4.23	89.9	88.9	3.5	13	55
Bomba de trasiego de diésel	2.39	85.3	84.4	1.8	1	2.4
Bomba de recirculación para limpieza 1	0.96	79	78.2	0.69	26	25
Bomba de separación de hidrocarburos	1.32	84	83.1	1	6	8
Bomba de recirculación para limpieza 2	1.81	84	83.1	1.4	208	377
Bomba de oxigenación	1.20	84.4	83.5	0.92	728	875
Bombas de almacenamiento	0.62	82.2	81.3	0.23	728	449
TOTAL						1792

El consumo energético anual fue de 1792 kWh, calculado a partir de las horas de uso y la potencia de bombas, mientras que los datos históricos reportan un valor de 1790.89 kWh, lo que permitió establecer un caso base energético confiable.

En la simulación de RETScreen, se modeló un sistema de aire con compresor de tornillo, seleccionado en el software como equipo de aire comprimido (ver Tabla 3).

Tabla 3. Datos de registro para equipos eléctricos

Equipo compresor de fluidos	
Parámetros	Valor
Capacidad del compresor, [ft ³ /min]	20
Presión del sistema, [PSIG]	165
Pérdidas por fricción, [%]	10
Capacidad del motor, [kW]	7.4
Demanda de aire útil, [ft ³ /min]	10.5
Tiempo de operación, [h/año]	1196
Demanda eléctrica total	5315

Ya hecho el registro del compresor de fluidos, se incorporó el generador eléctrico como parte del sistema energético integral, cuyas características técnicas se muestran en la Tabla 4.

Tabla 4. Datos de registro para equipo generador de energía

Equipo generador de energía	
Parámetros	Valor
Combustible	Diésel
Energía eléctrica generada, [kWh/año]	1370
Potencia, [kW]	110
Cantidad/año, [gal/año]	106.18

Posterior al registro del compresor, se incorporan cargas eléctricas adicionales, que corresponden al sis-

tema de calefacción del agua, refrigeración, cocina y equipos de cómputo, con la finalidad de complementar el modelado integral de la demanda eléctrica, ver Tabla 5. Este proceso se sistematiza considerando la carga conectada (kW), horas anuales de operación y demanda total del sistema (kWh), de acuerdo con los lineamientos del módulo de uso final eléctrico de RETScreen Expert.

El modelado del sistema de iluminación se realizó mediante el ingreso de datos por zonas funcionales del campamento, siguiendo el mismo proceso aplicado para las cargas eléctricas generales. Dado que el impacto energético de estos componentes es elevado y su diversidad significativa, se los parametrizó de manera detallada en RETScreen. La Tabla 6 presenta la demanda eléctrica total asociada a este rubro.

Tabla 5. Datos de registro para equipos eléctricos del área de cocina

	Cantidad	Horas de operación (h/año)	Carga eléctrica (W)	Ciclo de utilización (%)
Calentamiento de agua 1	1	8736	5000	100
Calentamiento de agua 2	1	8736	3000	100
Refrigerador	3	8736	1000	100
Cocina	1	2184	10 000	100
Cuarto UPS	1	8736	2880	100
<i>Demanda de electricidad (kWh)</i>		143 096		

Tabla 6. Demanda energética de consumo eléctrico de las luminarias del campamento dado por RETScreen

	Cantidad	Horas de operación h/año	Carga eléctrica (W)	Ciclo de operación (%)
Área industrial	22	4368	350	100
Refugio técnico de generadores	8	182	400	100
Puesto de vigilancia	2	8736	40	100
Unidad modular DDV	2	3640	40	100
Sala de monitoreo operativo	2	4368	40	100
Sala de automatización	6	8736	40	100
Sanitario área de control	1	3.64	58	100
Bodega de control	1	3.64	18	100
Unidad operativa modular	2	3640	40	100
Punto de mantenimiento mecánico	8	182	5	100
Punto de mantenimiento eléctrico	3	182	305	100
Módulo técnico Seramin	7	1820	18	100
Gimnasio	2	1092	40	100
Estación de herramientas	3	364	5	100
Habitaciones	1	1820	305	100
Almacén logístico	1	182	18	100
Sala común del campamento	7	1820	40	100
Comedor	1	1820	40	100
Cocina	1	6552	250	100
Sanitarios	4	364	18	100
<i>Demanda de electricidad (kWh/año)</i>		41 151		

Para el registro de sistemas de climatización se consideró un coeficiente de rendimiento energético (COP) promedio de 3, correspondiente a los tres equipos de aire acondicionado. Posteriormente, estos sistemas se integraron en la plataforma RETScreen, considerando una carga térmica total de enfriamiento de 93 500 BTU/h, con un ciclo de utilización de 100% y 8736 horas de operación anual. Se determinó una demanda energética anual de 79 795 kWh, correspondiente al consumo previsto del subsistema de climatización.

3. Resultados y discusión

En la Tabla 7 se muestra que el consumo total de combustible es de 113 gal/año, equivalente a

4557 kWh/año, mientras que el consumo energético total asciende a 271 148 kWh/año. El costo de diésel es de USD 339/año y el de electricidad USD 27 115/año, considerando un costo promedio del diésel de USD 3/gal y de la electricidad USD 0.10/kWh.

En este caso particular se decidió que, para reducir el consumo energético en el campamento de transporte de petróleo, es importante proponer un sistema fotovoltaico cuyo objetivo sea lograr un ahorro de entre el 15 % y el 30% del total de la demanda energética del campamento. Por ello, se optó por un sistema fijado, con un total de 50 paneles, cada uno con una capacidad de 600 W, lo que da una potencia aproximada de 30 kW, considerando las pérdidas en los paneles y en el inversor. Las demás características se presentan adscritas en la Tabla 8.

Tabla 7. Consumo combustible-electricidad y costo monetario de los sistemas por año en caso base y caso propuesto

Tipo de combustible		Caso base		Caso propuesto	
Tipo de combustible	Precio del combustible (USD)	Consumo de combustible	Costo de combustible (USD)	Consumo de combustible	Costo de combustible
Diésel	3	113 gal	339	113 gal	USD 339
Electricidad	0.10	271 148 kWh	27 115	185 878 kWh	\$ 18 588
Total			27 454		\$ 18 927

Tabla 8. Componentes e indicadores clave del sistema fotovoltaico considerado para el estudio mediante RETScreen

Modo de rastreo solar	Fijado
Inclinación	15°
Azimut	180
Tipo de panel	Mono - Si
Fabricante	Jinico Solar
Modelo	Mono Si - JKM600N-78HL4-600W
Capacidad	600W por panel
Número de unidades	50
Capacidad total	30 kW
Temperatura nominal de operación de las celdas	45° C
Eficiencia	21,46%
Área del colector solar	140 m ²
Pérdidas varias	10%
Eficiencia del inversor	97% (recomendado por el software)
Pérdidas en el inversor	1%

Se establece la premisa de que, si se mantiene un consumo constante de la energía generada por el sistema fotovoltaico, el ángulo de inclinación debe ser de 15°. En cuanto a la orientación de azimut, esta debe dirigirse hacia el hemisferio correspondiente; en este caso, como Esmeraldas (Ecuador) se encuentra en el hemisferio norte, la orientación debe ser hacia el sur, lo que determina un ángulo de 180°.

Asimismo, se plantea como premisa que el costo inicial, los costos de operación y mantenimiento, y la energía ahorrada para el campamento se encuentran descritos en la Tabla 9.

Tabla 9. Costos de instalación y de operación-mantenimiento relacionados con el consumo del sistema fotovoltaico

	Costo por kW (USD/kW-año)	Costo total (USD)
Costo inicial	1176	35 294
Costo de operación y mantenimiento	10.29	309
Energía ahorrada		36 103 kWh

Como acotación, los elementos fueron seleccionados con base en la premisa inicial de reducir entre un

15 % y un 30% la dependencia energética tanto del SNI como de los sistemas de producción energética convencionales, tales como generadores a diésel. Por ello, todos estos parámetros fueron calculados de manera automática por el RETScreen, que brindó sugerencias en aspectos relacionados con proveedores, modelos, capacidad, eficiencia y pérdidas, así como en criterios económicos, tales como el costo por kW del panel y el costo de operación y mantenimiento anual.

3.1. Medidas de optimización del consumo energético

Ya entrando en la materia correspondiente a los ahorros en el sistema energético del campamento, se establece una relación directa con los datos ingresados y con la adición del sistema fotovoltaico como elemento clave, puesto que a través de este se cumple el criterio fundamental de la investigación: reducir entre un 15 % y un 30% el consumo energético, aplicando principios de optimización. Estos resultados se presentan en la Tabla 10.

Tabla 10. Concepto de ahorro eléctrico y combustible en el campamento

Combustible		Caso base		Caso propuesto		Ahorros	
Tipo de combustible	Precio del combustible (USD)	Consumo de combustible	Costo de combustible (USD)	Consumo de combustible	Costo de combustible (USD)	Combustible ahorrado	Monto ahorrado (USD)
Diésel	3	113 gal	339	113 gal	339	0 gal	0
Electricidad	0.10	271 148 kWh	27 115	185 878 kWh	18 588	85 270 kWh	8527
Total		27 454			18 927		8527

La Tabla 11 muestra que, en el caso base, se consumieron 113 galones de diésel (USD 339) y 271 148 kWh/año de electricidad (USD 27 454). En el caso propuesto, el consumo de diésel se mantiene, pero el de electricidad disminuye a 185 878 kWh/año (USD 18 588), lo que representa un ahorro de 85 270 kWh (31%) gracias al sistema fotovoltaico. Los ahorros por subsistema (calentamiento, enfriamiento, electricidad) se detallan en la Tabla 11.

Tabla 11. Ahorro energético y porcentual respecto al contexto de cada uno de los sistemas

	Calentamiento (kWh)	Enfriamiento (kW)	Electricidad (kWh)	Total (kWh)
Caso base	4557	79 795	191 353	275 705
Caso propuesto	4557	68 396	117 482	190 435
Combustible ahorrado	0 kWh	11 399 kW	73 871 kWh	85 270 kWh
Combustible ahorrado (%)	0%	14.3%	38.6%	30.9%

Con fotovoltaicos, los sistemas de enfriamiento ahorran 14.3% y los eléctricos (bombas, compresores, luces) 38.6%, promediando 30.9%. Al no depender del SNI o generadores, el beneficio económico es alto, con un retorno de inversión en 10.7 años. La Figura 7 compara ambos casos.

Los equipos eléctricos como generadores son los que más ocupan el rubro de consumo de combustible en las instalaciones del campamento, seguido por los procesos de refrigeración o denominados de climatización,

y con un bajo porcentaje están los equipos mecánicos y por último el calor del proceso que se pierde en los procesos de combustión. Para el caso propuesto queda descrito de la manera mostrada en la Figura 8.




Figura 7. Consumo energético base por concepto de combustibles por los diferentes tipos de equipos.




Figura 8. Consumo energético propuesto por concepto de combustibles por los diferentes tipos de equipos.

Se evidencia una diferencia significativa en la reducción de consumo, considerando la propuesta de

implementación de un sistema fotovoltaico, el cual contribuye a disminuir 36 103 kWh anuales, como se observa en la Tabla 12.

Tabla 12. Consumo energético del caso propuesto en RETScreen

Consumo energético caso propuesto		
Tipo de equipos	Consumo kWh	Valor porcentual
Equipos eléctricos	146 479 kWh	64.7%
Refrigeración	68 396 kWh	30.2%
Equipos mecánicos	7106 kWh	3.1%
Calor del proceso	4557 kWh	2%
Generación fotovoltaica de electricidad	-36 103 kWh	-

3.2. Costos asociados

En lo referente a los costos de la implementación del sistema fotovoltaico, se observa un incremento en la inversión inicial; sin embargo, se obtiene un ahorro significativo en el gasto de combustible, lo que representa un beneficio económico. Aunque el retorno de la inversión es a largo plazo, este conlleva ventajas en la optimización de sistemas sostenibles y respetuosos con el medioambiente, como se describe en la Tabla 13.

Tabla 13. Gastos considerados para implementación

Costos asociados a implementación	
Costos iniciales incrementales [USD]	35 294
Ahorros en costos de combustible [USD]	8527
Ahorros incrementales de operación y mantenimiento [USD]	-309
Retorno del capital en años	10.7

La inversión inicial será elevada y los costos de operación y mantenimiento presentan un valor negativo, lo que indica que deben ser considerados dentro de los gastos asociados a la operación del sistema fotovoltaico.

3.3. Análisis ambiental

En el análisis de impacto ambiental se consideran aspectos como los factores de emisión de gases de efecto invernadero (GEI), cuyo valor es de 0.213 tCO₂/MWh, delimitado por el programa para Ecuador. En la Figura 9 se muestra que las emisiones de GEI corresponden a una reducción anual bruta equivalente a 18.1 tCO₂, lo que representa la absorción de aproximadamente 11.7 hectáreas de bosque.

En el caso base, la emisión fue de 58.8 tCO₂, mientras que en el caso propuesto se redujo a 40.7 tCO₂.

Además del estudio de implementación del sistema fotovoltaico, se plantean medidas que pueden aplicarse de manera inmediata. Estas alternativas se sugieren debido a que el costo de implementación del sistema

puede constituir una limitación si no se hace un análisis exhaustivo previo. En este sentido, se identificaron opciones de optimización que también fueron evaluadas mediante el programa RETScreen.




Figura 9. Reducción anual bruta de emisiones de GEI.

3.4. Medidas de gestión energética en el campamento petrolero

Área de cocina

Se muestra un escenario base y una propuesta de mejora respecto al sistema de calentamiento de agua (8000 L/día), evaluado con registros históricos, en el que como fuente energética se utiliza un generador eléctrico para producir calor.

Se propuso reducir la temperatura del agua caliente 5 °C, pasando de 45.5 °C a 40.5 °C.

Desde el punto de vista termodinámico, esta disminución implica una menor cantidad de energía requerida para alcanzar la temperatura idónea. La premisa de no incrementar, por ejemplo, en 10 °C la temperatura del agua se fundamenta en el equilibrio entre la eficiencia energética y el confort térmico del usuario. Reducir 5 °C significa que la energía necesaria para calentar el agua es directamente proporcional a la diferencia de temperatura deseada, sin comprometer ni el confort térmico del usuario ni la funcionalidad del sistema.

Con valores reales de consumo energético, se estima un ahorro aproximado de 17 000 kWh anuales, lo que representa una mejora del 24.3% en el desempeño térmico. El caso base era de 70 180 kWh/año, mientras que en el caso propuesto, bajo las condiciones sugeridas de funcionamiento, se reduce a 53 147 kWh/año. Este resultado se debe tanto al ajuste de la temperatura como a la optimización del ciclo de uso.

Como medida complementaria, se plantea reducir el ciclo de utilización en 25%, lo que disminuiría la demanda térmica global y, a su vez, reduciría la frecuencia de mantenimientos preventivos y correctivos.

Para futuras investigaciones, se puede efectuar un análisis de recuperación de calor en sistemas de extracción, mediante la implementación de campanas extractoras que permitan precalentar agua o alimentar procesos secundarios dentro del campamento.

Luminarias del campamento

Para el proceso de optimización de los sistemas lumínicos en las diferentes áreas del campamento, se propone la sustitución de la tecnología obsoleta, como las lámparas fluorescentes con balasto electrónico, por luminarias LED. En este análisis se considera una pérdida global del 25 %, aplicada tanto al caso base como al caso propuesto.

Desde el punto de vista técnico, se evidencia una reducción del 50% en la demanda eléctrica, pasando de 41 151 kWh/año a 20 855 kWh/año, lo cual mejora la eficiencia energética de los sistemas de iluminación. Este resultado se debe a la eficacia de las luminarias: mientras las luces convencionales con balasto presentan una eficiencia de 70 lm/W, las luminarias LED alcanzan 85.5 lm/W, lo que permite mantener los mismos niveles de iluminancia (500 lux) con una menor carga conectada.

Es importante destacar que los sistemas lumínicos deben ser adaptados a un diseño óptico adecuado, considerando aspectos direccionales y de dispersión de la luz. Las luminarias LED, al emitir luz de forma direccional, reducen las pérdidas por dispersión y ayudan a mantener los niveles de luminancia requeridos (500 lux) con una menor cantidad de luminarias y menor carga instalada. A diferencia de las lámparas fluorescentes con balasto, que debido a su emisión omnidireccional requieren un mayor número de puntos de luz, la tecnología LED reduce significativamente la potencia unitaria: de 150 W a 75 W por lámpara. En términos de carga total, esto implica una reducción de 4688 W (fluorescentes T8) a 2344 W (LED).

Para investigaciones futuras, se recomienda un análisis más exhaustivo de eficiencia lumínica en zonas críticas, considerando los niveles de iluminancia mediante software especializado como DIALux. Asimismo, se sugiere efectuar una comparativa entre luminarias LED convencionales y luminarias LED con sensores de presencia o regulación automática, a fin de determinar el potencial adicional de ahorro energético.

Sistemas de climatización

El sistema de climatización, conformado por tres equipos (capacidad conjunta: 93 500 BTU/h), presenta una oportunidad significativa de mejorar su eficiencia al incrementar el coeficiente de rendimiento (COP) de 3.0 a 3.5. Desde la termodinámica, el COP refleja la relación entre la energía útil entregada y la energía consumida; por tanto, al elevar el COP se reduce el consumo energético manteniendo la misma capacidad de climatización.

Con $COP = 3.5$, la demanda energética asociada al sistema de climatización se reduce de 79 795 kWh/año a 68 396 kWh/año, lo que equivale a una disminución del 14.28%. Este comportamiento es coherente con

la proporcionalidad inversa del consumo respecto al COP.

Para alcanzar este valor de COP se plantean las siguientes estrategias:

- Mantenimiento preventivo y correctivo de periódico: limpieza de serpentines, verificación de presiones de alta y baja, y detección de fugas, de ser el caso.
- Mejoras de hermeticidad en las áreas climatizadas para reducir la carga térmica y, en consecuencia, el trabajo del sistema.
- Controles inteligentes (termostatos programables, sensores de ocupación) que optimicen los ciclos de operación.
- Integración de energías renovables (por ejemplo, aerotermia o apoyo solar térmico para ACS), que disminuyen el esfuerzo del compresor cuando proceda.

Se propone un sistema fotovoltaico de 30 kWp con 50 paneles de 600 Wp, logrando un ahorro eléctrico del orden del 30% en el consumo desplazable. La planta puede ampliarse con más módulos o complementarse con cambio a luminarias LED en zonas críticas. Asimismo, se sugiere mantenimiento regular de climatización o reemplazo por equipos Inverter con refrigerante R410.

A futuro, distribuir mejor la carga fotovoltaica priorizando equipos sensibles, e incorporar protecciones (p. ej., interruptores en carga telecomandados, almacenamiento energético cuando sea viable) mejorará la resiliencia del sistema.

Para investigaciones futuras, conviene evaluar los ciclos operativos de climatización y extracción, estableciendo parámetros reales de funcionamientos (horarios de mayor carga térmica, posibilidad de reducir la operación sin afectar el confort), y estudiar la compatibilidad de equipos Inverter con refrigerantes bajo GWP (potencial de calentamiento global).

4. Conclusiones

El objetivo central del estudio fue evaluar el impacto técnico, económico y ambiental de las medidas implementadas. En consecuencia, se estableció como meta reducir entre un 15 % y un 30% el consumo energético de un campamento petrolero remoto.

Este análisis se llevó a cabo mediante la herramienta RETScreen, en la que se propusieron mejoras en los sistemas de climatización, iluminación y servicios generales. Con base en los registros históricos, el consumo eléctrico inicial fue de 271 148 kWh/año, con un gasto aproximado de USD 27 454. En el escenario propuesto con un sistema voltaico, cuyo propósito fue

optimizar el consumo energético, el consumo se redujo a 185 878 kWh/año, lo que representa un 31% de ahorro y una disminución en el gasto de USD 8527 anuales.

La generación fotovoltaica, estimada en 30 kWp (no 30 kWh/año), permitió disminuir la dependencia del Sistema Nacional Interconectado (SNI) y de fuentes contaminantes.

En cuanto a la distribución de la eficiencia energética, los sistemas de climatización registraron una mejora del 14.28%, mientras que los sistemas eléctricos—incluidas bombas e iluminación— alcanzaron la mayor reducción, con un 38.6%. El balance general señala un ahorro promedio del 30.9% en todo el sistema.

Desde el punto de vista ambiental, las emisiones de CO₂ se redujeron de 58.8 tCO₂ a 40.7 tCO₂, lo que equivale a la absorción realizada por 1.7 hectáreas de bosque. Finalmente, el retorno de inversión proyectado es de 10.7 años, lo que consolida la propuesta como una solución viable, sostenible y replicable.

Rol de autores

- **Edwin Illescas:** Conceptualización, análisis formal, redacción del borrador original, revisión y edición del manuscrito, investigación y gestión de recursos.
- **Edison Laz:** Software, redacción del borrador original, revisión y edición del manuscrito, validación y gestión de recursos.
- **Manuel Rogelio Nevárez Toledo:** Administración de proyecto.
- **Miguel Alberto Dávila-Sacoto:** Supervisión, administración de proyecto y metodología.

Referencias





- [1] E. A. Llanes Cedeño and O. D. Rubio Aguiar, *Elaboración de una metodología de gestión energética para campos petroleros en el Ecuador basada en la ISO 50001*. Universidad Internacional SEK, 2022. [Online]. Available: <https://upsalesiana.ec/ing35ar1r1>
- [2] B. Williams, D. Bishop, P. Gallardo, and J. G. Chase, “Demand side management in industrial, commercial, and residential sectors: A review of constraints and considerations,” *Energies*, vol. 16, no. 13, p. 5155, Jul. 2023. [Online]. Available: <http://doi.org/10.3390/en16135155>
- [3] S. Mimi, Y. Ben Maissa, and A. Tamtaoui, “Optimization approaches for demand-side management in the smart grid: A systematic mapping study,” *Smart Cities*, vol. 6, no. 4, pp. 1630–1662, Jun. 2023. [Online]. Available: <http://doi.org/10.3390/smartcities6040077>
- [4] S. S. Shuvo and Y. Yilmaz, “Demand-side and utility-side management techniques for increasing EV charging load,” *IEEE Transactions on Smart Grid*, vol. 14, no. 5, pp. 3889–3898, Sep. 2023. [Online]. Available: <http://doi.org/10.1109/TSG.2023.3235903>
- [5] S. Charles Raja, A. C. Vishnu Dharsini, J. Jeslin Drusila Nesmalar, and T. Karthick, “Deployment of IoT-based smart demand-side management system with an enhanced degree of user comfort at an educational institution,” *Energies*, vol. 16, no. 3, p. 1403, Jan. 2023. [Online]. Available: <http://doi.org/10.3390/en16031403>
- [6] V. Cortez, R. Rabelo, A. Carvalho, A. Floris, and V. Pilloni, “On the impact of flexibility on demand-side management: Understanding the need for consumer-oriented demand response programs,” *International Journal of Energy Research*, vol. 2024, no. 1, Jan. 2024. [Online]. Available: <http://doi.org/10.1155/2024/8831617>
- [7] D. Stanelyte, N. Radziukyniene, and V. Radziukynas, “Overview of demand-response services: A review,” *Energies*, vol. 15, no. 5, p. 1659, Feb. 2022. [Online]. Available: <http://doi.org/10.3390/en15051659>
- [8] M. Alikhani, M. P. Moghaddam, F. Moazzen, and A. Azadi, “Optimal implementation of consumer demand response program with consideration of uncertain generation in a microgrid,” *Electric Power Systems Research*, vol. 225, p. 109859, Dec. 2023. [Online]. Available: <http://doi.org/10.1016/j.epsr.2023.109859>
- [9] A. Piñeres Castillo, J. J. Cabello Eras, and M. Hinojosa Rivera, “Factores determinantes para la evaluación de la eficiencia energética en las organizaciones: una visión desde las condiciones de Colombia,” *Universidad y Sociedad*, vol. 14, no. 2, pp. 509–520, 2022. [Online]. Available: <https://upsalesiana.ec/ing35ar1r9>
- [10] P. J. Ramos-Males and A. M. Bautista-Segovia, “La eficiencia energética: Una estrategia para la economía doméstica en Ecuador,” *Dominio de las Ciencias*, vol. 8, no. 2, pp. 1334–1346, 2022. [Online]. Available: <https://upsalesiana.ec/ing35ar1r10>
- [11] R. Cancio-Bello, S. Montelíer Hernández, A. Oviedo Regojo, and O. Bello Gonzalez, “Bases para la implementación de un sistema de gestión energética en la UEB Ron “Luis Arcos Bergnes” de Cienfuegos basado

- en la NC-ISO 50001:2019,” *Universidad y Sociedad*, vol. 13, no. 4, 2021. [Online]. Available: <https://upsalesiana.ec/ing35ar1r11>
- [12] L. Freire, V. Resabala, J. Castillo, and B. Corrales, “Propuesta de un plan alternativo de optimización energética,” *Espacios*, vol. 40, no. 30, 2019. [Online]. Available: <https://upsalesiana.ec/ing35ar1r12>
- [13] F. De La Cruz Cabrales Ávila and R. A. Mejía Otero, “Sistemas fotovoltaicos: solución energética en las comunidades aisladas,” 2022. [Online]. Available: <http://doi.org/10.5281/ZENODO.7461726>
- [14] G. S. Inca Yajamín, D. F. Cabrera Carrión, D. F. Villalta Gualán, R. C. Bautista Zurita, and H. D. Cabrera Carrión, “Evaluación de la actualidad de los sistemas fotovoltaicos en Ecuador: avances, desafíos y perspectivas,” *Ciencia Latina Revista Científica Multidisciplinar*, vol. 7, no. 3, pp. 9493–9509, Jul. 2023. [Online]. Available: http://doi.org/10.37811/cl_rcm.v7i3.6835
- [15] A. F. Guamán Mejía and L. V. Sánchez Parrales, “Importancia de la energía renovable para el alumbrado público,” *Revista Sinapsis*, vol. 24, no. 1, 2024. [Online]. Available: <https://upsalesiana.ec/ing35ar1r15>
- [16] J. R. López Escobedo, K. Nicolás Javier, and F. García Reyes, “Optimización de energía eléctrica y luminosa en laboratorios y aulas de aprendizaje, aplicación sustentable con luminarias de tecnología LED,” *Tendencias en energías renovables y sustentabilidad*, vol. 1, no. 1, pp. 93–100, Dec. 2022. [Online]. Available: <http://doi.org/10.56845/terys.v1i1.108>
- [17] J. L. Rodríguez Muñoz, J. S. Pacheco Cedeño, C. M. Valencia Castillo, and J. d. J. Ramírez Minguela, “Energy and exergy analysis of an ejector-compression refrigeration cycle with double ihx,” *REVISTA DE CIENCIAS TECNOLÓGICAS*, vol. 6, no. 3, p. e261, Sep. 2023. [Online]. Available: <http://doi.org/10.37636/recit.v6n3e261>
- [18] ONU, *Las emisiones históricas del sector de la construcción, lo alejan de los objetivos de descarbonización*. Naciones Unidas, 2022. [Online]. Available: <https://upsalesiana.ec/ing35ar1r18>
- [19] IRENA, *Integración de energías renovables de baja temperatura en los sistemas energéticos urbanos: lineamientos para los responsables de la formulación de políticas – Resumen*. International Renewable Energy Agency, 2021. [Online]. Available: <https://upsalesiana.ec/ing35ar1r19>
- [20] ISO, *Guía de implementación e interpretación de requisitos del estándar ISO 50001:2018*. Organización Internacional de Normalización, 2018. [Online]. Available: <https://upsalesiana.ec/ing35ar1r20>
- [21] T. Jing and Y. Zhao, “Optimizing energy consumption in smart buildings: A model for efficient energy management and renewable integration,” *Energy and Buildings*, vol. 323, p. 114754, Nov. 2024. [Online]. Available: <http://doi.org/10.1016/j.enbuild.2024.114754>



CLASIFICACIÓN DE FRACTURAS EN EXTREMIDADES SUPERIORES CON APRENDIZAJE PROFUNDO

CLASSIFICATION OF UPPER LIMB FRACTURES USING DEEP LEARNING

Gabriela Jaén-Armijos^{1,*} , Evelyn Morán-Castillo¹ ,
 Wilmer Rivas-Asanza¹ , Eduardo Tusa¹ 

Recibido: 30-04-2025, Recibido tras revisión: 19-06-2025, Aceptado: 09-09-2025, Publicado: 01-01-2026

Resumen


La identificación precisa de fracturas en las extremidades superiores es fundamental para un diagnóstico oportuno en los entornos de urgencias médicas. Este estudio analiza y compara el desempeño de tres modelos de aprendizaje profundo preentrenados: EfficientNet-B4, ResNet-50 y ConvNeXt-Large, aplicados a la clasificación automática de fracturas óseas en radiografías del repositorio MURA, distribuidas en siete regiones anatómicas. Se aplicaron técnicas avanzadas de preprocesamiento digital, como Unsharp Masking y CLAHE, junto con estrategias de normalización y balanceo de datos. El entrenamiento se llevó a cabo en dos experimentos: uno binario, que clasifica entre “fractura” y “no fractura”, y otro multiclase, con catorce tipos de fracturas identificadas. La evaluación, mediante métricas como F1-Score, sensibilidad, exactitud y curvas ROC-AUC, reveló que ConvNeXt-Large alcanzó el mejor rendimiento, logrando una precisión del 99,0 % en clasificación binaria y del 99,4 % en la clasificación multiclase. Estos resultados posicionan a ConvNeXt-Large como una herramienta altamente prometedora para apoyar el diagnóstico temprano de fracturas óseas.

Palabras clave: extremidades humanas, fracturas óseas, inteligencia artificial, radiografía, redes neuronales artificiales

Abstract

Accurate identification of upper extremity fractures is essential for timely and reliable diagnosis in emergency medical settings. This study evaluates and compares the performance of three pre-trained deep learning architectures: EfficientNet-B4, ResNet-50, and ConvNeXt-Large, applied to the automatic classification of bone fractures in radiographic images from the MURA repository, encompassing seven anatomical regions. Advanced image preprocessing techniques, including Unsharp Masking and Contrast-Limited Adaptive Histogram Equalization (CLAHE), were employed in conjunction with data normalization and balancing strategies. The models were trained in two experimental setups: a binary classification distinguishing between “fracture” and “non-fracture” images, and a multiclass configuration identifying 14 distinct fracture types. Performance evaluation using F1-Score, sensitivity, accuracy, and ROC-AUC metrics demonstrated that ConvNeXt-Large achieved the highest overall results, reaching accuracies of 99.0% in binary classification and 99.4% in multiclass classification. These findings position ConvNeXt-Large as a highly promising tool for supporting early and precise fracture diagnosis.

Keywords: Human extremities, Bone Fractures, Artificial Intelligence, X-ray, Artificial neural networks.

^{1,*}Facultad de Ingeniería Civil, AutoMathFIC, Universidad Técnica de Machala, Ecuador. 
 Autor para correspondencia ✉: gjaen1@utmachala.edu.ec.

Forma sugerida de citación: G. Jaén-Armijos, E. Morán-Castillo, W. Rivas-Asanza y E. Tusa. “Clasificación de fracturas en extremidades superiores con aprendizaje profundo,” *Ingenius, Revista de Ciencia y Tecnología*, N.º 35, pp. 21-35, 2026. DOI: <https://doi.org/10.17163/ings.n35.2026.02>.

1. Introducción

Las fracturas óseas representan una de las lesiones más frecuentes en las salas de urgencias de los centros de salud [1]. Las extremidades superiores desempeñan funciones fundamentales en el cuerpo humano, por lo que una fractura en áreas como el codo, los dedos, el antebrazo, la mano, el húmero, el hombro o la muñeca puede afectar gravemente las habilidades motoras básicas y limitar la capacidad para llevar a cabo actividades diarias, reduciendo así la calidad de vida de los pacientes.

A nivel global, se estima que entre el 10.0% y el 40.0% de las emergencias médicas se originan por lesiones en los miembros superiores, lo que representa aproximadamente seis millones de pacientes anuales en Estados Unidos y 700 000 en Francia [2].

En Medellín (Colombia) se reportaron 25 646 casos de traumas en miembros superiores, de los cuales el 17.0% correspondió a fracturas [2]. Esto evidencia la necesidad de contar con diagnósticos más rápidos y precisos. Sin embargo, la tasa de error en su identificación alcanza el 17.9% [3].

Aunque las radiografías son ampliamente utilizadas, su precisión es limitada, especialmente en regiones anatómicamente complejas, como las extremidades superiores. Factores como el ajuste inadecuado de parámetros de voltaje y corriente del tubo de rayos X, el análisis manual de las imágenes radiográficas y la sobrecarga laboral del personal médico pueden contribuir significativamente a estos errores [4].

Frente a estos desafíos, la implementación de técnicas avanzadas de inteligencia artificial (IA), como el aprendizaje profundo, surge como una solución innovadora capaz de incrementar la precisión diagnóstica. Estas técnicas han demostrado resultados prometedores, mejorando notablemente la precisión y la eficiencia en los diagnósticos [5].

La inteligencia artificial, en términos generales, se refiere a la capacidad de los sistemas informáticos para realizar tareas que normalmente requieren intervención humana [6]. Por su parte, el aprendizaje profundo utiliza redes neuronales artificiales complejas para modelar y resolver problemas con una alta capacidad de generalización [7].

Un ejemplo de cómo estas tecnologías están transformando la práctica médica es el estudio de Medaramatla *et al.* [8] sobre la detección de fracturas en huesos de la mano mediante un sistema híbrido YOLO-NAS aplicado a imágenes de rayos X. En este estudio, se diseñó una base de datos con 4736 imágenes de rayos X de huesos de la mano, clasificadas en seis categorías, recopiladas de fuentes como Kaggle y Mendeley. Para evaluar el rendimiento del modelo propuesto, se compararon diversos algoritmos, entre ellos YOLO-NAS, EfficientDet, ResNet-50, InceptionV3, Vision Transformer, VGG19 y YOLOv8. Los resultados mostraron

que el modelo híbrido diseñado alcanzó una precisión del 97.9%, superando a los demás algoritmos evaluados.

En esa misma línea, Wang [9] desarrolló una solución basada en aprendizaje profundo, utilizando la biblioteca Keras y el modelo NASNetMobile para la detección de fracturas óseas en las extremidades superiores. Para entrenar el modelo, se utilizó el conjunto de datos MURA, obteniendo una precisión cercana al 70.0%, lo que evidencia el potencial del aprendizaje profundo para aplicaciones médicas.

En otro estudio, Guan *et al.* [10] utilizaron cerca de 4000 imágenes del conjunto MURA y propusieron dos etapas basadas en R-CNN para detectar fracturas en radiografías de brazos. Como resultado, el modelo alcanzó una precisión del 62.0%, lo que demuestra el potencial de las técnicas de R-CNN para asistir en el diagnóstico de estas lesiones.

Aunque los estudios analizados presentan resultados prometedores en la detección automática de fracturas óseas, sus hallazgos evidencian limitaciones significativas que dificultan su aplicación en entornos clínicos reales. Esto plantea la necesidad de explorar nuevas estrategias que permitan superar dichas barreras.

Por ejemplo, el modelo propuesto por [10] obtuvo un rendimiento inferior al 80.0%, debido a la escasez de imágenes empleadas durante su entrenamiento. Por lo tanto, la utilización de un conjunto de datos más amplio y diverso sería una opción adecuada para mejorar la robustez y la fiabilidad del modelo en la práctica clínica.

La calidad de las imágenes constituye otra limitación presente en los trabajos mencionados. En dichas investigaciones, la precisión de los modelos se ve afectada por la presencia de ruido o la ausencia de preprocesamiento adecuado. En el caso de [8], las imágenes fueron redimensionadas a un formato cuadrado de 608 × 608 píxeles (PNG) y se implementó un proceso manual de eliminación de ruido en aquellas de baja calidad. Si bien esta estrategia de limpieza contribuyó a mejorar la calidad y la precisión del modelo, no posee la escalabilidad ni la robustez necesarias para garantizar la consistencia en entornos clínicos de gran escala.

A partir de estas limitaciones, surge la siguiente pregunta de investigación: ¿Cómo incrementar la precisión y la robustez frente al desbalance de clases en la clasificación automática de fracturas óseas en extremidades superiores, a partir de imágenes radiográficas, mediante la implementación de modelos de aprendizaje profundo preentrenados?

Para dar respuesta a la interrogante, se propone comparar modelos de aprendizaje profundo preentrenados, como EfficientNet-B4 [11], ResNet-50 [12] y ConvNeXt-Large [13], evaluados mediante métricas como F1-Score, precisión, exactitud, sensibilidad, curva

de característica operativa del receptor (ROC) y matriz de confusión.

El objetivo es identificar cuál de los tres modelos propuestos ofrece el mejor rendimiento en la clasificación automática de fracturas óseas en las extremidades superiores.

2. Materiales y métodos

La investigación se basa en un enfoque cuantitativo y experimental, orientado a la comparación y validación de modelos preentrenados de aprendizaje profundo para la clasificación automática de fracturas óseas en extremidades superiores a partir de imágenes radiográficas.

Para la implementación y evaluación de los modelos, se adopta el enfoque CRISP-DM, el cual proporciona un marco sistemático y estructurado para el análisis de los datos [14].

La Figura 1 ilustra sus fases y objetivos principales del proceso.

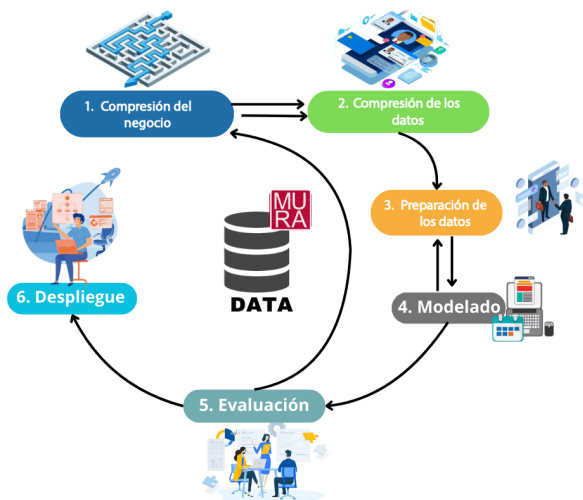


Figura 1. Metodología de estudio compuesta por seis fases.

Estas fases se describen a continuación:

- **Comprensión del negocio:** análisis del contexto, definición de los objetivos y recursos del proyecto [15].
- **Comprensión de los datos:** análisis de la calidad, estructura y características de los datos para obtener una visión clara de su contenido [16].
- **Preparación de los datos:** depuración de valores faltantes, normalización, selección de variables clave y conversión de los datos a formatos adecuados.
- **Modelado:** construcción, entrenamiento y evaluación del modelo, con el fin de garantizar su efectividad y fiabilidad [17].

- **Evaluación:** verificación del cumplimiento de objetivos y análisis del rendimiento del modelo según criterios predefinidos [18].

- **Despliegue:** integración, monitoreo y mantenimiento continuos del modelo, para asegurar su funcionamiento óptimo y actualización periódica [19].

2.1. Comprensión del negocio

La clasificación automática de fracturas óseas en radiografías requiere precisión, rapidez y experiencia especializada. Sin embargo, la alta demanda de estudios radiológicos y la escasez de profesionales radiólogos pueden retrasar los diagnósticos y aumentar la probabilidad de errores.

Aunque existen diversas herramientas computacionales, pocas están diseñadas específicamente para detección y clasificación de fracturas óseas. En este contexto, el presente estudio implementa y evalúa modelos preentrenados de aprendizaje profundo para la clasificación de fracturas óseas en las extremidades superiores.

2.2. Comprensión de los datos

El conjunto de datos empleado para la clasificación automática de fracturas en las extremidades superiores corresponde a una amplia colección de radiografías musculoesqueléticas, denominada MURA [20]. Este recurso contiene 40561 imágenes radiográficas, correspondientes a 14 863 estudios de 12 173 pacientes.

Las imágenes abarcan diferentes regiones anatómicas, como el codo, los dedos, el antebrazo, la mano, el húmero, el hombro y la muñeca. Cada estudio fue etiquetado previamente como normal o anormal por radiólogos certificados, avalados por la junta del Hospital de Stanford, a partir de diagnósticos realizados entre 2001 y 2012 [21].

En cuanto a su distribución original, MURA [20] se divide en tres subconjuntos: entrenamiento, con 36 808 imágenes (90.7%); validación, con 3197 imágenes (7.9%); y prueba, con 556 imágenes (1.4%).

La Tabla 1 resume la distribución original del conjunto de datos.

Tabla 1. Distribución original de MURA

Categoría	Entrenamiento		Validación	
	Normal	Anormal	Normal	Anormal
Codo	2925	2006	235	230
Dedos	3138	1968	214	247
Antebrazo	1164	661	150	151
Mano	4059	1484	271	189
Húmero	673	599	148	140
Hombro	4211	4168	285	278
Muñeca	5765	3987	364	295
Total	21 935	14 873	1667	1530

2.3. Preparación de los datos

El preprocesamiento de datos es una etapa fundamental en la minería de datos, ya que permite corregir el ruido, las inconsistencias y los valores faltantes que afectan la fiabilidad del modelo [22]. Durante la revisión del conjunto original de MURA [20], se obtuvieron 40 009 imágenes. Tras un análisis exhaustivo, se identificaron cuatro imágenes en formato distinto, las cuales fueron descartadas en etapas posteriores del preprocesamiento. Esto confirma la cantidad total de 40 005 imágenes reportada por los autores [23].

Las 40 005 imágenes resultantes fueron normalizadas y redimensionadas a 384×384 píxeles, con el fin de mantener el equilibrio entre la preservación de los detalles relevantes, la eficiencia computacional y la consistencia con los modelos preentrenados.

Para mejorar la calidad visual de las radiografías, se aplicaron las técnicas Unsharp Masking, utilizada para resaltar los bordes y los detalles finos [24], y CLAHE, que mejora el contraste en imágenes poco nítidas sin generar artefactos indeseados [25].

Estudios previos han demostrado que la combinación de estas técnicas incrementa significativamente la visibilidad en imágenes con baja iluminación [26], como se aprecia en la Figura 2.




Figura 2. Aplicación de técnicas de mejora de imágenes radiográficas. A la izquierda, se muestra el resultado obtenido con Unsharp Mask, y a la derecha, el efecto de la combinación de Unsharp Mask con CLAHE.

Tras finalizar las etapas de limpieza y mejora de la calidad de las imágenes, el conjunto de datos fue redistribuido como parte del preprocesamiento: 80.0% para entrenamiento y 20.0% para validación, tal como se indica en la Tabla 2.

Tabla 2. Redistribución de MURA

Categoría	Entrenamiento		Validación	
	Normal	Anormal	Normal	Anormal
Codo	2559	1773	601	463
Dedos	2731	1778	621	437
Antebrazo	1038	664	276	148
Mano	3397	1347	933	326
Húmero	646	589	175	150
Hombro	3591	3541	905	905
Muñeca	4890	3460	1239	822
Total	18 852	13 152	4750	3251

2.4. Modelado

En esta etapa se implementaron tres modelos preentrenados de aprendizaje profundo: EfficientNet-B4, ResNet-50 y ConvNeXt-Large. El entrenamiento se realizó en un entorno Python, utilizando bibliotecas como PyTorch, Albumentations y Scikit-learn, y tres configuraciones de hardware: GPU NVIDIA RTX 3050 (8 GB), GPU NVIDIA RTX 4060 (12 GB) y A100 en Google Colab Pro (40 GB).

Estas configuraciones permitieron evaluar el rendimiento y el consumo de recursos, destacando la GPU A100 en Colab Pro para pruebas intensivas en modelos de mayor complejidad, como ConvNeXt-Large.

Bajo estas condiciones, el entrenamiento se estructuró en tres fases:

1. **Primera fase:** se realizó una clasificación binaria entre imágenes con fractura y sin fractura.
2. **Segunda fase:** se ejecutó una clasificación multiclase utilizando el conjunto MURA en su estructura original.
3. **Tercera fase:** se efectuó un entrenamiento multiclase con el conjunto de datos preprocesado y redimensionado.

La Tabla 3 resume el esquema de etiquetado empleado para la clasificación multiclase.

Tabla 3. Etiquetado de clases para clasificación multiclase

Clase	Abreviación
Hombro normal	HoN
Hombro anormal	HoA
Codo normal	CoN
Codo anormal	CoA
Dedo normal	DeN
Dedo anormal	DeA
Antebrazo normal	AnN
Antebrazo anormal	AnA
Mano normal	MaN
Mano anormal	MaA
Húmero normal	HuN
Húmero anormal	HuA
Muñeca normal	MuN
Muñeca anormal	MuA

2.4.1. EfficientNet-B4

EfficientNet es una arquitectura convolucional que equilibra la profundidad, el ancho y la resolución de la red [27].

El modelo EfficientNet-B4 cuenta con 24 capas y aproximadamente 19.3 millones de parámetros, la mayoría ajustables (pesos y sesgos) y una pequeña proporción fija (media y varianza), lo que mejora la capacidad de extracción de características complejas, aunque aumenta la demanda computacional y el riesgo de sobreajuste, ver Figura 3.




Figura 3. Arquitectura EfficientNet-B4.

Fase 1

El proceso de entrenamiento se desarrolló en dos etapas, utilizando un lote de ocho imágenes por iteración. En la primera etapa, se entrenó el modelo durante 30 épocas, congelando las últimas 100 capas, y se aplicó una tasa de aprendizaje de 1×10^{-3} .

Posteriormente, se realizó un ajuste fino durante 25 épocas, con todas las capas activas del modelo, reduciendo la tasa de aprendizaje a 1×10^{-5} .

Se aplicaron técnicas de aumento de datos, como rotaciones, desplazamientos y cambios de escala, para incrementar la variabilidad del conjunto de entrenamiento. Además, se incorporó una estrategia de control de la pérdida de validación, que detiene el entrenamiento en ausencia de mejora y ajusta dinámicamente la tasa de aprendizaje.

Fase 2

En el entrenamiento multiclase se empleó un tamaño de lote de ocho imágenes.

En una primera fase, se entrenó únicamente la capa de salida durante 30 épocas, con una tasa de aprendizaje de 1×10^{-3} .

Posteriormente, se realizó un ajuste fino, descongelando todas las capas durante 30 épocas adicionales, con una tasa de aprendizaje reducida (1×10^{-5}) para un ajuste más preciso de los pesos del modelo.

Como parte del flujo de entrenamiento, se calcularon pesos de clase personalizados con el fin de compensar el desbalance existente en el conjunto de entrenamiento.

Fase 3

Durante el entrenamiento, se aplicó aumento de datos directamente en GPU, utilizando la biblioteca Kor-

nia [28], que incluye rotaciones aleatorias de hasta 30° , inversión horizontal, variaciones de brillo y normalización.

Para la validación, los datos solo fueron normalizados, con el fin de mantener la coherencia estadística respecto al entrenamiento.

Para mitigar el desbalance de clases, se calcularon automáticamente los pesos de clase mediante una función descrita en la ecuación (1).

$$w_i = \frac{n_{muestras}}{n_{clases} \times n_{muestras_i}} \quad (1)$$

Donde w_i es el peso de la clase i , $n_{muestras}$ representa el total de muestras, $n_{(clases)}$ corresponde al número de clases, y $n_{muestras_i}$ indica el número de muestras pertenecientes a la clase i .

Además, se integró la función de pérdida de entropía cruzada, la cual convierte las salidas del modelo en probabilidades normalizadas, comparables con las etiquetas verdaderas.

Se mantuvo la estructura de entrenamiento empleada en la fase 2 y se incorporaron operaciones de precisión mixta de forma automática [29].

Por último, se aplicó un escalamiento dinámico de la pérdida para preservar la estabilidad numérica durante el entrenamiento [30].

2.4.2. ResNet-50

ResNet es una arquitectura convolucional basada en bloques residuales y conexiones de salto, diseñada para mitigar problemas como el desvanecimiento del gradiente y facilitar el entrenamiento de redes neuronales más profundas [31].

El modelo ResNet-50 cuenta con 50 capas de profundidad, lo que le permite extraer características visuales detalladas de las imágenes, como se observa en la Figura 4 [12].




Figura 4. Arquitectura ResNet-50.

Fase 1

Para el entrenamiento binario, se utilizó un tamaño de lote de 32 imágenes y una estrategia en dos etapas: entrenamiento con capas congeladas y ajuste fino.

En la primera etapa, se congelaron las capas del modelo base y se añadió un clasificador personalizado, compuesto por dos capas densas de 1024 y 512 unidades, con normalización, función de activación Swish y Dropout del 50%, finalizando con una capa salida sigmoide para la clasificación binaria.

Se aplicaron diversas transformaciones al conjunto de entrenamiento, entre ellas: normalización de píxeles, rotaciones, desplazamientos de hasta 30%, zoom de hasta 40%, recortes aleatorios, ajustes de brillo e inversión horizontal.

En la primera etapa, se entrenó la cabeza del modelo durante 40 épocas, con una tasa de aprendizaje de 1×10^{-4} ; en la segunda, se descongelaron las últimas 150 capas y se continuó con el ajuste fino por 40 épocas adicionales, utilizando una tasa de aprendizaje reducida de 1×10^{-6} , preservando la estabilidad de los pesos preentrenados.

Fase 2

En esta fase no se aplicó aumento de datos. El entrenamiento se realizó en dos etapas: en la primera, se mantuvieron congeladas las capas base del modelo y se entrenaron únicamente las capas superiores, con una tasa de aprendizaje de 1×10^{-4} ; en la segunda, a partir

de la época 40, se aplicó un ajuste fino, reduciendo la tasa de aprendizaje a 1×10^{-6} .

Fase 3

Por último, en la tercera fase se utilizó un tamaño de lote de 64 imágenes. Al conjunto de entrenamiento se le aplicó inversión horizontal aleatoria, rotaciones dentro del rango de $\pm 30^\circ$ y normalización, ajustando los valores de media y desviación estándar a 0.5. Además, se calcularon automáticamente los pesos de las clases mediante la función `compute_class_weight`, como se mencionó en la fase 3 del punto 2.4.1.

Para el entrenamiento, se reemplazó la capa final del modelo por una salida de 14 neuronas, precedida por una capa densa de 512 unidades, normalización por lotes, función de activación no lineal y un Dropout del 50.0%. El proceso se mantuvo en dos etapas, incorporando técnicas de entrenamiento mixto para optimizar recursos de la GPU.

2.4.3. ConvNeXt-Large

ConvNeXt-Large es una arquitectura de red neuronal convolucional que divide la red en varios módulos idénticos, lo cual facilita la expansión y el mantenimiento del modelo [32]. En la Figura 5 se observa su estructura de 24 capas, la cual le permite identificar diferencias mínimas y detalles complejos en las imágenes, útiles para tareas de clasificación médica [13].




Figura 5. Arquitectura ConvNeXt-Large.

Fase 1

En la primera fase del entrenamiento binario de ConvNeXt-Large, se aplicaron aumentos de datos mediante ajustes de brillo y contraste, desenfoque por movimiento, rotaciones de $\pm 20^\circ$, recortes aleatorios, inversión horizontal y normalización al rango $[-1, 1]$. Se utilizó una función de pérdida compuesta, que combina un 30% de BCE [33] que mide la discrepancia entre las predicciones del modelo y las etiquetas reales y un 70% de Focal Loss [34], la cual reduce la influencia de ejemplos fáciles y prioriza los difíciles.

El modelo se entrenó durante 30 épocas, incorporando CutMix [35] y un ajuste fino progresivo. Primero se entrenó la cabeza del modelo y, desde las épocas 3 y 8, se descongelaron gradualmente las capas más profundas. A partir de la época 5, se ajustó dinámicamente el umbral de clasificación y se reincorporaron los errores de validación cada 5 épocas.

Fase 2

A continuación, en la segunda fase, el modelo fue ajustado para clasificación multiclase con 14 categorías, sin aplicar aumentos de datos, y se enfocó en un conjunto personalizado construido a partir de archivos CSV, con el fin de facilitar la lectura y la normalización de las imágenes.

Se entrenó con lotes de 16 imágenes, utilizando la función de pérdida CrossEntropyLoss, como se mencionó en la fase 3 de la sección 2.4.1, y el optimizador AdamW, que ajusta los parámetros con tasas adaptativas y aplica regularización adecuada para mejorar la estabilidad del proceso de aprendizaje.

El entrenamiento comenzó con el modelo base congelado, descongelando las últimas 10 capas desde la época 3 y toda la arquitectura a partir de la época 8.

Fase 3

Por último, esta tercera fase reforzó la capacidad de generalización mediante transformaciones avanzadas, como volteo horizontal, rotaciones discretas de 90° , 180° y 270° , distorsiones elásticas, desenfoque gaussiano y ajustes aleatorios de brillo y contraste. Se aplicó sobremuestreo, replicando ejemplos de la clase minoritaria para balancear datos; además, se incorporó una función de pérdida personalizada, con detección de errores cada 5 épocas y el uso de CutMix [35].

El entrenamiento comenzó con la cabeza del modelo durante 2 épocas; desde la época 3 se activaron las últimas 10 capas, y a partir de la época 8 se habilitó el ajuste fino completo.

La Tabla 4 resume las configuraciones empleadas para EfficientNet-B4, ResNet-50 y ConvNeXt-Large, incluyendo épocas, tamaños de lote [36] y tasas de aprendizaje, con ajustes específicos para la clasificación multiclase.

Tabla 4. Resumen de configuraciones de entrenamiento por modelo

Parámetro	EfficientNet	ResNet	ConvNeXt
N.º de épocas iniciales	30	40	30
N.º de épocas ajuste fino	25	40	30
Tamaño de lote inicial	8	32	16
Tamaño de lote final	8	64	16
Tasa aprendizaje inicial	1×10^{-3}	1×10^{-4}	1×10^{-3}
Tasa aprendizaje final	1×10^{-5}	1×10^{-6}	1×10^{-5}

2.4.4. Esfuerzo computacional

El esfuerzo computacional se refiere a los recursos necesarios para entrenar y ejecutar un modelo, tales como memoria, tiempo de entrenamiento y capacidad de procesamiento [37]. En este estudio, los modelos empleados presentaron diferencias significativas en las tres configuraciones de hardware utilizadas, las cuales se describen a continuación.

- **Configuración 1 (GPU NVIDIA RTX 3050, 8 GB VRAM):** GPU de gama media, orientada a usuarios domésticos o estaciones de trabajo básicas, con arquitectura Ampere, diseñada para tareas generales de procesamiento gráfico y computación acelerada.
- **Configuración 2 (GPU NVIDIA RTX 4060, 12 GB VRAM):** GPU de gama alta para consumo general, basada en arquitectura Ada Lovelace, con mayor rendimiento en tareas de aprendizaje profundo.
- **Configuración 3 (Google Colab Pro con GPU A100, 40 GB VRAM):** GPU de alto rendimiento, basado en arquitectura Ampere, destinada a procesamiento intensivo y entrenamiento de redes neuronales profundas.

El entrenamiento exigió alta carga computacional: EfficientNet-B4 presentó una demanda moderada, ResNet-50 requirió menos tiempo y memoria, y ConvNeXt-Large fue el más exigente; por ello, se empleó la función `torch.cuda.empty_cache()` de PyTorch, que libera memoria y reduce el riesgo de saturación [38].

La Tabla 5 resume el comportamiento observado en cuanto a la velocidad de entrenamiento bajo las distintas configuraciones de hardware empleadas. Los niveles de rendimiento se interpretan de la siguiente manera:

- **Lento:** tiempo total de entrenamiento superior a 12 horas.
- **Moderado:** tiempo total de entrenamiento entre 4 y 12 horas.
- **Rápido:** tiempo total de entrenamiento inferior a 4 horas

Tabla 5. Comparativa de velocidad de entrenamiento de los modelos

Modelo	RTX 3050	RTX 4060	Colab A100
EfficientNet	Moderado	Rápido	Rápido
ResNet	Moderado	Rápido	Rápido
ConvNeXt	Lento	Moderado	Rápido

De igual forma, en la Tabla 6 se presenta el comportamiento observado en cuanto al uso de memoria durante el entrenamiento en los diferentes entornos evaluados. Los niveles de utilización de memoria indicados de la Tabla 6 se interpretan de la siguiente manera:

- **Lento:** consumo máximo de memoria VRAM inferior al 50% de la capacidad total disponible en la GPU.
- **Moderado:** consumo de memoria entre 50% y 80%.
- **Rápido:** consumo de memoria VRAM superior al 80%, con riesgo de saturación.

Tabla 6. Comparativa del uso de memoria de los modelos

Modelo	RTX 3050	RTX 4060	Colab A100
EfficientNet	Moderado	Bajo	Bajo
ResNet	Moderado	Moderado	Bajo
ConvNeXt	Alto	Alto	Alto

2.5. Evaluación

En esta sección se analiza el rendimiento de los modelos EfficientNet-B4, ResNet-50 y ConvNeXt-Large en la clasificación de fracturas óseas, utilizando métricas de evaluación como F1-Score, la precisión, la exactitud, la sensibilidad, la curva característica de operación del receptor y la matriz de confusión. Las abreviaturas empleadas en las ecuaciones se detallan en la Tabla 7.

Tabla 7. Términos de evaluación

Abreviatura	Significado
TP	Verdaderos positivos
FP	Falsos positivos
TN	Verdaderos negativos
FN	Falsos negativos
RECALL	Sensibilidad

A continuación, se describen las métricas utilizadas en la evaluación del rendimiento.

Puntaje F1 (F1-Score)

La métrica es una medida armónica entre la precisión y la sensibilidad, útil en conjuntos de datos desbalanceados, porque equilibra los errores de clasificación [39].

$$F1 - Score = 2 \times \frac{Precisión \times sensibilidad}{Precisión + sensibilidad} \quad (2)$$

Precisión

Mide la proporción de predicciones positivas que son correctas, reflejando un bajo número de falsos positivos [40].

$$Precisión = \frac{TP}{TP + FP} \quad (3)$$

Exactitud

Evalúa la proporción total de predicciones correctas y se utiliza especialmente cuando las clases están balanceadas [41].

$$Exactitud = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

Sensibilidad

Refleja la capacidad del modelo para detectar los positivos reales; una alta sensibilidad implica un bajo número de falsos negativos [39].

$$Sensibilidad = \frac{TP}{TP + FN} \quad (5)$$

Matriz de confusión

Permite identificar los valores VP, FP, FN y VN, facilitando la evaluación del rendimiento y la detección de errores del modelo [42].

Curva característica de operación del receptor

Representa la relación entre la sensibilidad y la tasa de falsos positivos, lo que permite analizar la capacidad discriminativa del modelo y visualizar su rendimiento global [43].

3. Resultados y discusión

Fase 1

Como se observa en la Tabla 8, ConvNeXt-Large supera a EfficientNet-B4 y ResNet-50 en todas las métricas evaluadas, alcanzando una precisión del 99.2%, una sensibilidad del 97.7% y un F1-Score de 98.4%, lo que evidencia su alta capacidad para clasificar fracturas óseas con una baja tasa de falsos positivos.

Por otro lado, EfficientNet-B4 y ResNet-50 presentan un rendimiento similar, con menor capacidad para identificar correctamente los casos positivos. Estos resultados demuestran que ConvNext-Large logra el mejor equilibrio entre precisión, sensibilidad y capacidad de generalización.

Tabla 8. Métricas de evaluación en porcentaje – Fase 1

Métrica	EfficientNet	ResNet	ConvNeXt
Precisión	82.4	82.4	99.2
Sensibilidad	69.0	69.0	97.7
F1-Score	75.1	75.1	98.4
Exactitud	81.5	73.0	98.7

Para complementar los resultados, se presentan las curvas características de operación del receptor y el área bajo la curva de cada modelo en la Figura 6. EfficientNet-B4 alcanzó un AUC de 87.1%, ResNet-50 obtuvo 82.8% y ConvNeXt-Large un 99.9%, lo que evidencia una capacidad casi perfecta de discriminación entre clases.

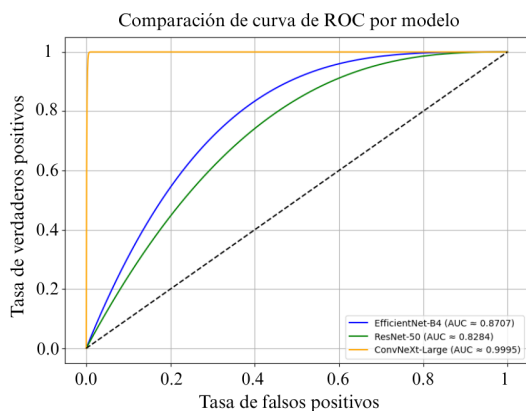


Figura 6. Comparación del desempeño de modelos mediante curvas de ROC.

El análisis de las matrices de confusión refuerza estos hallazgos: EfficientNet-B4 (Figura 7) presenta 1013 FP y 470 FN; ResNet-50 (Figura 8) reduce los FN a 697, pero aumenta los FP a 1465; mientras que ConvNeXt-Large (Figura 9) alcanza el mejor desempeño, con solo 76 FP y 25 FN, lo que evidencia una mayor precisión en la clasificación.

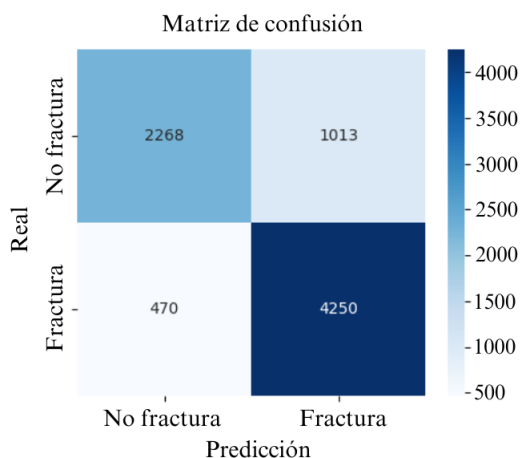


Figura 7. Matriz de confusión de EfficientNet-B4.




Figura 8. Matriz de confusión de ResNet-50.




Figura 9. Matriz de confusión de ConvNeXt-Large.

Fase 2

Los resultados de entrenamiento multiclase de esta fase demuestran que el modelo ConvNeXt-Large alcanzó una precisión general de 82.3%, una sensibilidad de 81.6%, un F1-Score de 81.4% y una exactitud de 81.3%. Estos resultados se presentan en la Tabla 9.

Tabla 9. Métricas de evaluación en porcentaje – Fase 2

Métrica	EfficientNet	ResNet	ConvNeXt
Precisión	47.3	73.5	82.3
Sensibilidad	33.2	72.8	81.6
F1-Score	32.8	72.2	81.4
Exactitud	33.2	72.8	81.6

En la Figura 10 se observa que los valores AUC obtenidos por EfficientNet-B4 para cada clase se encuentran en un rango entre 93.0% y 98.0%.

Por su parte, en la Figura 11, correspondiente a ResNet-50, los valores AUC varían entre 95.0% y 99.0%. Finalmente, en la Figura 12, las curvas AUC de ConvNeXt-Large presentan valores que oscilan entre

el 98.0% y 100.0%, evidenciando un rendimiento sobresaliente y una excelente capacidad de discriminación entre clases.

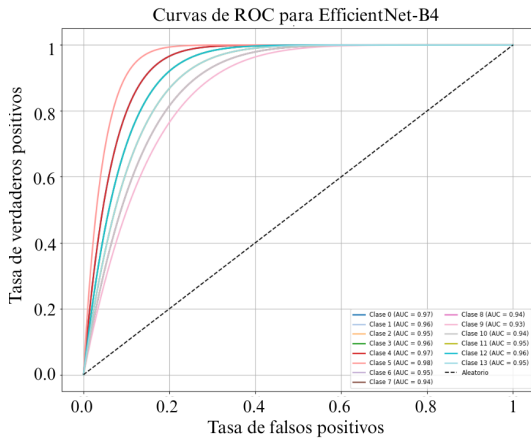


Figura 10. Curvas características de operación del receptor para EfficientNet-B4 multiclase.




Figura 11. Curvas características de operación del receptor para ResNet-50 multiclase.

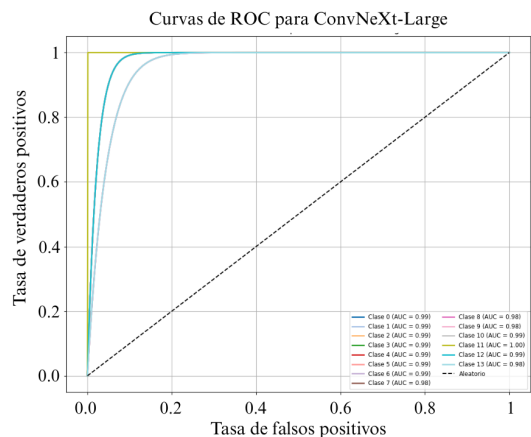


Figura 12. Curvas características de operación del receptor para ConvNeXt-Large multiclase.

En la Figura 13, EfficientNet-B4 muestra un desempeño limitado: las clases codo normal y mano normal presentan numerosas confusiones, mientras que dedo anormal, mano anormal y muñeca normal destacan por su alta precisión.

Por otro lado, la Figura 14 evidencia que ResNet-50 mejora la clasificación; en este caso, la mayoría de las clases se concentran correctamente en la diagonal de la matriz de confusión, aunque aún se observan errores entre Hombro Normal y Muñeca Anormal.

Finalmente, en la Figura 15, ConvNeXt-Large alcanzó el mejor desempeño, con clasificación precisa y un mínimo de errores.




Figura 13. Matriz de confusión de EfficientNet-B4.




Figura 14. Matriz de confusión de ResNet-50.




Figura 15. Matriz de confusión de ConvNeXt-Large.

Fase 3

A partir de los resultados presentados en la Tabla 10, ConvNeXt-Large mantiene su superioridad en la clasificación multiclase, superando ampliamente a los demás modelos en todas las métricas evaluadas. Sus valores de precisión, sensibilidad, F1-Score y exactitud alcanzaron el 99.4%, lo que consolida a este modelo como la mejor alternativa para la tarea de clasificación.

Tabla 10. Métricas de evaluación en porcentaje – Fase 3

Modelo	EfficientNet	ResNet	ConvNeXt
Precisión	80.6	83.9	99.4
Sensibilidad	80.2	83.9	99.4
F1-Score	79.9	83.9	99.4
Exactitud	80.2	83.9	99.4

Al observar las matrices de confusión correspondientes a la fase 3, se aprecia que en la Figura 16 los valores AUC de EfficientNet-B4 varían entre 98.0% y 99.0%.

En el caso de ResNet-50, representado en la Figura 17, los valores de AUC se sitúan entre 97.0% y 99.0%.

Finalmente, en la Figura 18, los valores de AUC para todas las clases alcanzaron el 100.0%, lo que demuestra el excelente rendimiento del modelo ConvNeXt-Large.

Las Figuras 19, 20 y 21 confirman que ConvNeXt-Large es el modelo más eficaz, ya que muestra menor dispersión fuera de la diagonal principal y mayor capacidad para diferenciar clases.

El excelente rendimiento de ConvNeXt-Large frente al desbalance de clases se atribuye a las estrategias avanzadas de aumento de datos, que redujeron el sobreajuste y mejoraron la capacidad de generalización, superando a EfficientNet-B4 y ResNet-50 en todas las fases evaluadas.




Figura 16. Curvas características de operación del receptor para EfficientNet-B4 multiclase.




Figura 17. Curvas características de operación del receptor para ResNet-50 multiclase.




Figura 18. Curvas características de operación del receptor para ConvNeXt-Large multiclase.




Figura 19. Matriz de confusión de EfficientNet-B4.




Figura 20. Matriz de confusión de ResNet-50.




Figura 21. Matriz de confusión de ConvNeXt-Large.

Comparación con trabajos relacionados

El modelo ConvNeXt-Large propuesto superó los resultados de los estudios previos, alcanzando una precisión de hasta 99.4% frente al 62.0% de R-CNN [10] y 86.8% de DenseNet121 [23], lo que demuestra su mayor robustez incluso ante conjuntos de datos desbalanceados.

Limitaciones, desafíos para la aplicación clínica y consideraciones éticas

Aunque los resultados obtenidos muestran un alto rendimiento, su aplicación clínica requiere un análisis más profundo. La implementación en entornos reales enfrenta desafíos como la variabilidad de los equipos radiológicos, la calidad de imágenes y las particularidades anatómicas de cada paciente, lo que exige validar el modelo en diversos escenarios clínicos.

Por otro lado, existe el riesgo de sobreajuste, ya que el modelo fue entrenado en un entorno controlado que puede no reflejar situaciones clínicas reales; por

ello, es esencial validar el modelo con datos externos y diversos. En cuanto a la reproducibilidad, resulta fundamental que los resultados obtenidos puedan ser replicados por otros investigadores, utilizando diferentes conjuntos de datos y condiciones experimentales, para fortalecer la confianza y facilitar su adopción clínica.

Finalmente, desde una perspectiva ética y regulatoria, es fundamental garantizar la transparencia del modelo, la protección y anonimización de los datos de los pacientes, así como la definición clara de responsabilidades frente a posibles errores de diagnóstico, asegurando un uso seguro, ético y confiable que priorice el bienestar del paciente.

4. Conclusiones

Este estudio evaluó los modelos EfficientNet-B4, ResNet-50 y ConvNeXt-Large para la clasificación de fracturas óseas en extremidades superiores mediante radiografías digitales. Los hallazgos demostraron que ConvNeXt-Large superó a los demás modelos, alcanzando precisiones del 99.2% en clasificación binaria, 82.3% en clasificación multiclase con datos originales y 99.4% en la clasificación multiclase con datos pre-procesados.

La combinación de estrategias de aprendizaje profundo, como el preprocesamiento de imágenes, las técnicas de aumento de datos, el ajuste dinámico de umbrales y el ajuste fino progresivo, fue determinante para su alto rendimiento.

Si bien EfficientNet-B4 y ResNet-50 obtuvieron resultados aceptables, sus limitaciones en sensibilidad y equilibrio entre clases podrían representar un riesgo en contextos clínicos, donde la omisión de una fractura puede tener consecuencias críticas. En conjunto, los resultados respaldan a ConvNeXt-Large como una herramienta prometedora para apoyar el diagnóstico médico e integrarse en sistemas automatizados de análisis radiográfico de fracturas en extremidades superiores.

Un desafío importante identificado fue la complejidad de las fracturas, lo que sugiere explorar técnicas avanzadas de remuestreo y aumentos específicos, como transformaciones clínicas o síntesis de datos mediante redes generativas, con el fin de mejorar la precisión y la robustez diagnóstica en futuros desarrollos.

Disponibilidad del código

El código empleado para el procesamiento de datos, el entrenamiento de los modelos y la generación de las figuras del estudio sobre la clasificación de fracturas en extremidades superiores mediante aprendizaje profundo se encuentra disponible públicamente en el repositorio de GitHub [44], consultado el 24 de junio de 2025.

Rol de autores

- **Gabriela Jaén-Armijos:** curación de datos, análisis formal, investigación, software, escritura-borrador original.
- **Evelyn Morán-Castillo:** investigación, metodología, análisis formal, software, escritura-borrador original.
- **Wilmer Rivas-Asanza:** supervisión, validación, escritura-revisión y edición.
- **Eduardo Tusa:** supervisión, validación, escritura-revisión y edición.

Referencias

- [1] J. S. Alvarez Silva, J. E. Chávez Guerrero, D. S. Gutiérrez Carvajal, and L. B. Santos Rivas, "Manejo de emergencias en traumatología," *Polo del conocimiento*, vol. 8, no. 4, pp. 2392–2414, 2023. [Online]. Available: <https://upsalesiana.ec/ing35ar2r1>
- [2] E. M. Bitar Benítez, S. Gaviria Posada, N. d. León Fernández, and S. Gallego Gónima, "Epidemiología del trauma de miembro superior atendido en seis instituciones de salud de la ciudad de Medellín, Colombia, en 2016," *Cirugía Plástica Ibero-Latinoamericana*, vol. 47, no. 3, pp. 323–332, Sep. 2021. [Online]. Available: <https://dx.doi.org/10.4321/s0376-78922021000300014>
- [3] Y. Xie, X. Li, F. Chen, R. Wen, Y. Jing, C. Liu, and J. Wang, "Artificial intelligence diagnostic model for multi-site fracture X-ray images of extremities based on deep convolutional neural networks," *Quantitative Imaging in Medicine and Surgery*, vol. 14, no. 2, pp. 1930–1943, Feb. 2024. [Online]. Available: <https://dx.doi.org/10.21037/qims-23-878>
- [4] A. Said, M. Abbas Al-Adilee, and M. Rajeswari, "Enhancing bone fracture diagnosis with deep learning," in *Conference: 5th International Conference on Data Engineering and Communication Technology (ICDECT) At: Kuala Lumpur, Malaysia*, 09 2024. [Online]. Available: <https://upsalesiana.ec/ing35ar2r4>
- [5] Z. Alammar, L. Alzubaidi, J. Zhang, J. Santamaría, Y. Li, and Y. Gu, "A concise review on deep learning for musculoskeletal X-ray images," in *2022 International Conference on Digital Image Computing: Techniques and Applications (DICTA)*. IEEE, Nov. 2022, pp. 1–8. [Online]. Available: <https://doi.org/10.1109/DICTA56598.2022.10034618>
- [6] A. Pérez del Barrio, P. Menéndez Fernández-Miranda, P. Sanz Bellón, L. Lloret Iglesias, and D. Rodríguez González, "Inteligencia artificial en radiología: introducción a los conceptos más importantes," *Radiología*, vol. 64, no. 3, pp. 228–236, May 2022. [Online]. Available: <https://doi.org/10.1016/j.rx.2022.03.003>
- [7] J. D. Maravilla González, "Integración de la inteligencia artificial en la contabilidad forense: Herramientas y eficacia en la detección de fraudes: Integration of artificial intelligence in forensic accounting: Tools and effectiveness in fraud detection," *LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades*, vol. 5, no. 4, Aug. 2024. [Online]. Available: <https://doi.org/10.56712/latam.v5i4.2460>
- [8] S. C. Medaramatla, C. V. Samhitha, S. D. Pande, and S. R. Vinta, "Detection of hand bone fractures in x-ray images using hybrid YOLO NAS+," *IEEE Access*, vol. 12, pp. 57 661–57 673, 2024. [Online]. Available: <https://doi.org/10.1109/ACCESS.2024.3379760>
- [9] J. Wang, "Anomaly detection of arm X-ray based on deep learning," *IOP Conference Series: Earth and Environmental Science*, vol. 440, no. 4, p. 042056, Feb. 2020. [Online]. Available: <https://doi.org/10.1088/1755-1315/440/4/042056>
- [10] B. Guan, G. Zhang, J. Yao, X. Wang, and M. Wang, "Arm fracture detection in X-rays based on improved deep convolutional neural network," *Computers & Electrical Engineering*, vol. 81, p. 106530, Jan. 2020. [Online]. Available: <https://doi.org/10.1016/j.compeleceng.2019.106530>
- [11] A. Pak, A. Ziyaden, K. Tukeshev, A. Jaxylykova, and D. Abdullina, "Comparative analysis of deep learning methods of detection of diabetic retinopathy," *Cogent Engineering*, vol. 7, no. 1, Jan. 2020. [Online]. Available: <https://doi.org/10.1080/23311916.2020.1805144>
- [12] M. A. Thaarakaraam, M. M. Reddy, and V. Vijayakumar, "CNN based bone fracture detection for medical imaging using RESNET-50," *International Journal of Technical Research & Science*, vol. 9, no. Spl, pp. 27–35, Jun. 2024. [Online]. Available: <https://doi.org/10.30780/specialissue-iset-2024/038>
- [13] Z. Li, T. Gu, B. Li, W. Xu, X. He, and X. Hui, "Convnext-based fine-grained image classification and bilinear attention mechanism model," *Applied Sciences*, vol. 12, no. 18, p. 9016, Sep. 2022. [Online]. Available: <https://doi.org/10.3390/app12189016>

- [14] C. A. Mejía Rodríguez, M. A. Rincón Pinzón, L. M. Palmera Quintero, and L. M. Arévalo Vergel, “Aplicación de machine learning y metodología CRISP-DM para la clasificación precisa de severidad en casos de dengue,” *Revista Colombiana de Tecnologías de Avanzada (RCTA)*, vol. 1, no. 43, pp. 78–85, Mar. 2024. [Online]. Available: <https://doi.org/10.24054/rcta.v1i43.2822>
- [15] C. Schröer, F. Kruse, and J. M. Gómez, “A systematic literature review on applying CRISP-DM process model,” *Procedia Computer Science*, vol. 181, pp. 526–534, 2021. [Online]. Available: <https://doi.org/10.1016/j.procs.2021.01.199>
- [16] D. Dzuhljjah, M. Herlambang, and M. Haifan, “Implementasi framework CRISP-DM untuk proses data mining aplikasi credit scoring PT. XYZ,” in *Seminar Nasional Sains dan Teknologi "SainTek"*, 06 2024. [Online]. Available: <https://upsalesiana.ec/ing35ar2r16>
- [17] V. García-Ríos, M. Marres-Salhuana, F. Sierra-Liñán, and M. Cabanillas-Carbonell, “Predictive machine learning applying cross industry standard process for data mining for the diagnosis of diabetes mellitus type 2,” *IAES International Journal of Artificial Intelligence (IJ-AI)*, vol. 12, no. 4, p. 1713, Dec. 2023. [Online]. Available: <https://doi.org/10.11591/ijai.v12.i4.pp1713-1726>
- [18] G. Emmanuel, G. G. Hungilo, and A. W. R. Emanuel, “Performance evaluation of machine learning classification techniques for diabetes disease,” *IOP Conference Series: Materials Science and Engineering*, vol. 1098, no. 5, p. 052082, Mar. 2021. [Online]. Available: <https://doi.org/10.1088/1757-899X/1098/5/052082>
- [19] E. B. Núñez Arias, B. M. González Nuñez, L. N. Fernández, and J. M. Rodríguez Pupo, “CRISP-DM y K-means neutrosophía en el análisis de factores de riesgo de pérdida de audición en niños,” *Neutrosophic Computing and Machine Learning*, vol. 16, p. 73, 2021. [Online]. Available: <https://doi.org/10.5281/zenodo.4679890>
- [20] ML Group. (2025) Bone X-ray deep learning competition. Stanford ML Group. [Online]. Available: <https://upsalesiana.ec/ing35ar2r20>
- [21] I. Kandel and M. Castelli, “Improving convolutional neural networks performance for image classification using test time augmentation: A case study using MURA dataset,” *Health Information Science and Systems*, vol. 9, no. 1, Jul. 2021. [Online]. Available: <https://doi.org/10.1007/s13755-021-00163-7>
- [22] K. Dlshad Ahmed and R. Hawezi, “Detection of bone fracture based on machine learning techniques,” *Measurement: Sensors*, vol. 27, p. 100723, Jun. 2023. [Online]. Available: <https://doi.org/10.1016/j.measen.2023.100723>
- [23] P. Rajpurkar, J. Irvin, A. Bagul, D. Ding, T. Duan, H. Mehta, B. Yang, K. Zhu, D. Laird, R. L. Ball, C. Langlotz, K. Shpanskaya, M. P. Lungren, and A. Y. Ng, “MURA: Large dataset for abnormality detection in musculoskeletal radiographs,” in *Proceedings of the 1st Conference on Medical Imaging with Deep Learning (MIDL)*. arXiv, 2017. [Online]. Available: <https://doi.org/10.48550/arXiv.1712.06957>
- [24] R. Archana and P. S. E. Jeevaraj, “Deep learning models for digital image processing: a review,” *Artificial Intelligence Review*, vol. 57, no. 1, Jan. 2024. [Online]. Available: <https://doi.org/10.1007/s10462-023-10631-z>
- [25] P. Pandey, R. Gupta, and N. Goel, “Comprehensive review of single image defogging techniques: enhancement, prior, and learning based approaches,” *Artificial Intelligence Review*, vol. 58, no. 4, Jan. 2025. [Online]. Available: <https://doi.org/10.1007/s10462-024-11034-4>
- [26] A. C. Pavan, S. Lakshmi, and M. Somashekara, “An improved method for reconstruction and enhancing dark images based on CLAHE,” *International Research Journal on Advanced Science Hub*, vol. 5, no. 02, pp. 40–46, Feb. 2023. [Online]. Available: <https://doi.org/10.47392/irjash.2023.011>
- [27] X. Liu, *Comparison of four convolutional neural network-based algorithms for sports Image classification*. Atlantis Press International BV, 2024, pp. 178–186. [Online]. Available: https://doi.org/10.2991/978-94-6463-370-2_20
- [28] E. Riba, D. Mishkin, D. Ponsa, E. Rublee, and G. Bradski, “Kornia: An open source differentiable computer vision library for PyTorch,” in *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*. arXiv, 2019. [Online]. Available: <https://doi.org/10.48550/arXiv.1910.02190>
- [29] R. Connor, A. Dearle, B. Claydon, and L. Vadicamo, “Correlations of cross-entropy loss in machine learning,” *Entropy*, vol. 26, no. 6, p. 491, Jun. 2024. [Online]. Available: <https://doi.org/10.3390/e26060491>
- [30] M. Dörrich, M. Fan, and A. M. Kist, “Impact of mixed precision techniques on training and inference efficiency of deep neural networks,” *IEEE Access*, vol. 11,

- pp. 57627–57634, 2023. [Online]. Available: <https://doi.org/10.1109/ACCESS.2023.3284388>
- [31] A. Thakur, H. Chauhan, and N. Gupta, “Efficient ResNets: Residual network design,” in *NYU Tandon School of Engineering, Tech. Rep.* arXiv, 2023. [Online]. Available: <https://doi.org/10.48550/arXiv.2306.12100>
- [32] G. Fang, Y. Dai, Z. Lin, C. Zhou, J. Song, Y. Gu, X. Guo, A. Mao, and X. Kong, “An efficient unsupervised classification model for galaxy morphology: Voting clustering based on coding from convnext large model,” *Astronomy & Astrophysics*, vol. 693, p. A141, Jan. 2025. [Online]. Available: <https://doi.org/10.1051/0004-6361/202451734>
- [33] A. Anaya-Isaza, L. Mera-Jiménez, and M. Zequera-Díaz, “An overview of deep learning in medical imaging,” *Informatics in Medicine Unlocked*, vol. 26, p. 100723, 2021. [Online]. Available: <https://doi.org/10.1016/j.imu.2021.100723>
- [34] A. A. Mustapha and M. S. Yoosuf, “Exploring the efficacy and comparative analysis of one-stage object detectors for computer vision: A review,” *Multimedia Tools and Applications*, vol. 83, no. 20, pp. 59143–59168, Dec. 2023. [Online]. Available: <https://doi.org/10.1007/s11042-023-17751-2>
- [35] Y. Nakamura, Y. Ishii, Y. Maruyama, and T. Yamashita, “Few-shot adaptive object detection with cross-domain cutmix,” in *Proceedings of the European Conference on Computer Vision (ECCV)*. arXiv, 2022. [Online]. Available: <https://doi.org/10.48550/arXiv.2208.14586>
- [36] M. T. Mora Cabral, R. G. Camero Berrones, and M. D. Arriaga Pons, “Modelo de identificación espacial de patrones de referencia empleando redes neuronales convolucionales (CNN) y entrenamiento por lotes,” *Revista de investigación multidisciplinaria, Iberoamericana*, no. 4, Dec. 2024. [Online]. Available: <https://doi.org/10.69850/rimi.vi4.125>
- [37] A. Verma, T. Meenpal, and B. Acharya, “Computational cost reduction of convolution neural networks by insignificant filter removal,” *Journal of Information Science and Technology*, vol. 25, no. 2, pp. 150–165, 2022. [Online]. Available: <https://upsalesiana.ec/ing35ar2r37>
- [38] C. Guo, R. Zhang, J. Xu, J. Leng, Z. Liu, Z. Huang, M. Guo, H. Wu, S. Zhao, J. Zhao, and K. Zhang, “GMLake: Efficient and Transparent GPU Memory Defragmentation for Large-scale DNN Training with Virtual Memory Stitching,” in *arXiv preprint*. arXiv, 2024. [Online]. Available: <https://doi.org/10.48550/arXiv.2401.08156>
- [39] V. D. Gil-Vera and C. Seguro-Gallego, “Machine learning aplicado al análisis del rendimiento de desarrollos de software,” *Revista Politécnica*, vol. 18, no. 35, pp. 128–139, Apr. 2022. [Online]. Available: <https://doi.org/10.33571/rpolitec.v18n35a9>
- [40] F. D. Valle-Medina, L. J. Castillo-Heredia, M. A. Correa-Peralta, and J. E. Guzmán-Seraquive, “Clasificación de enfermedades en hojas de papa utilizando transformadores de visión,” *NovasinerGía Revista digital de Ciencia, Ingeniería y Tecnología*, vol. 8, no. 1, pp. 142–156, Jan. 2025. [Online]. Available: <https://doi.org/10.37135/ns.01.15.06>
- [41] M. Ihme, W. T. Chung, and A. A. Mishra, “Combustion machine learning: Principles, progress and prospects,” *Progress in Energy and Combustion Science*, vol. 91, p. 101010, Jul. 2022. [Online]. Available: <https://doi.org/10.1016/j.pecs.2022.101010>
- [42] D. Patiño-Pérez, L. Armijos-Valarezo, L. Chóez-Acosta, and F. Burgos-Robalino, “Convolutional neural networks for diabetic retinopathy detection,” *Ingenius*, no. 33, pp. 91–101, Mar. 2025. [Online]. Available: <https://doi.org/10.17163/ings.n33.2025.08>
- [43] G. Bauce and M. Moya-Sifontes, “Análisis de la curva ROC en la evaluación de indicadores antropométricos,” *Revista Digital de Postgrado*, vol. 11, no. 1, Aug. 2021. [Online]. Available: <https://doi.org/10.37910/RDP.2022.11.1.e333>
- [44] G. B. Jaén Armijos, “Clasificador de fracturas en extremidades superiores con aprendizaje profundo,” Github, oct 2025, gitHub repository. [Online]. Available: <https://upsalesiana.ec/ing35ar2r44>



AVANCES EN EL ANÁLISIS COMPUTACIONAL PARA LA OPTIMIZACIÓN DE MOTORES A REACCIÓN: UNA REVISIÓN DE CFD, ANÁLISIS ESTRUCTURAL Y ENFOQUES MULTIDISCIPLINARIOS

ADVANCEMENTS IN COMPUTATIONAL ANALYSIS FOR JET ENGINE OPTIMIZATION: A REVIEW OF CFD, STRUCTURAL ANALYSIS, AND MULTIDISCIPLINARY APPROACHES

Abu Baker Jassim^{1,*} , Raja Sekhar Dondapati¹ 

Recibido: 20-03-2025, Recibido tras revisión: 27-05-2025, Aceptado: 22-10-2025, Publicado: 01-01-2026

Resumen

La evolución de la tecnología de los motores a reacción ha estado profundamente influenciada por los avances en el análisis computacional, especialmente en la dinámica de fluidos computacional (CFD), el análisis estructural y la optimización multidisciplinaria. Esta revisión aborda las técnicas computacionales de vanguardia aplicadas al estudio de motores a reacción, resaltando sus aplicaciones, beneficios y desafíos. La CFD se ha consolidado como una herramienta esencial que permite simulaciones detalladas de los complejos procesos aerodinámicos y de combustión. Métodos como las simulaciones de grandes remolinos (LES) y las simulaciones numéricas directas (DNS) han permitido comprender con mayor profundidad la turbulencia y la dinámica de la combustión, mejorando la eficiencia y reduciendo las emisiones. No obstante, estas simulaciones de alta fidelidad demandan un elevado costo computacional, lo que ha impulsado el desarrollo de algoritmos más eficientes y el uso de recursos de cómputo de alto rendimiento. La integración del análisis estructural con las simulaciones aerodinámicas ha facilitado el diseño de componentes capaces de soportar condiciones extremas, aumentando la fiabilidad y seguridad del motor.

Abstract

The evolution of jet engine technology has been profoundly influenced by advancements in computational analysis, particularly in Computational Fluid Dynamics (CFD), structural analysis, and multidisciplinary optimization. This review explores state-of-the-art computational techniques applied to jet engine analysis, emphasizing their applications, benefits, and inherent challenges. CFD has become an essential tool, enabling detailed simulations of complex aerodynamic and combustion processes. Methods such as Large Eddy Simulations (LES) and Direct Numerical Simulations (DNS) have provided deeper insights into turbulence and combustion dynamics, leading to improved efficiency and reduced emissions. However, these high-fidelity simulations entail significant computational costs, driving the development of more efficient algorithms and high-performance computing resources. The integration of structural analysis with aerodynamic simulations has facilitated the design of components capable of withstanding extreme operational conditions, thereby enhancing engine reliability and safety. Multidisciplinary Design Optimization (MDO) frameworks have further transformed engine design by simultaneously evaluating multiple performance metrics, resulting in configurations that balance efficiency, weight, and durability.

^{1,*}School of Mechanical Engineering, Lovely Professional University, Punjab, India 
 Autor para correspondencia ✉: bakrjassim1990@gmail.com.

Forma sugerida de citación: A. B. Jassim y R. S. Dondapati "Avances en el análisis computacional para la optimización de motores a reacción: una revisión de CFD, análisis estructural y enfoques multidisciplinarios," *Ingenius, Revista de Ciencia y Tecnología*, N.º 35, pp. 36-51, 2026. DOI: <https://doi.org/10.17163/ings.n35.2026.03>.

Los marcos de optimización de diseño multidisciplinario (MDO) han transformado el diseño al evaluar simultáneamente múltiples métricas de rendimiento, logrando configuraciones equilibradas entre eficiencia, peso y durabilidad. Pese a estos avances, persisten retos en el modelado de fenómenos complejos, como las inestabilidades de combustión y el comportamiento de materiales a altas temperaturas. La incorporación del aprendizaje automático ofrece soluciones prometedoras, orientadas hacia sistemas de propulsión más eficientes, confiables y sostenibles.

Palabras clave: dinámica de fluidos computacional (CFD), optimización de diseño multidisciplinario (MDO), computación de alto rendimiento, modelado de turbulencia y combustión, tecnología de motores a reacción

Despite these advances, challenges remain in accurately modeling complex physical phenomena such as combustion instabilities and material behavior under high temperatures. The incorporation of machine learning techniques offers promising solutions to address these issues by complementing traditional computational methods with data-driven insights. Looking ahead, the future of computational analysis in jet engine development lies in the seamless integration of high-fidelity simulations, real-time data analytics, and adaptive modeling, paving the way for more efficient, reliable, and sustainable propulsion systems.

Keywords: Computational Fluid Dynamics (CFD), Multidisciplinary Design Optimization (MDO), High-Performance Computing, Turbulence and Combustion Modeling, Jet Engine Technology

1. Introducción

Los motores a reacción, piedra angular de la aviación moderna, han experimentado transformaciones profundas desde su creación. El centro de estos avances ha sido la evolución del análisis computacional, que ha permitido a los ingenieros simular, predecir y optimizar el rendimiento del motor con una precisión sin precedentes. La integración de herramientas computacionales en el proceso de diseño no solo ha acelerado el desarrollo, sino que también ha mejorado la comprensión de los complejos fenómenos físicos que rigen el funcionamiento del motor [1–3].

1.1. Perspectiva histórica

La aplicación de técnicas computacionales en el desarrollo de motores a reacción comenzó con enfoques analíticos y empíricos fundamentales, destinados a comprender el comportamiento aerodinámico y termodinámico básico [2, 4]. Con la llegada de la computación digital a mediados del siglo XX, el campo avanzó rápidamente, marcando una transición crucial de métodos puramente experimentales hacia un diseño impulsado computacionalmente [1, 3]. La introducción de métodos numéricos permitió a los ingenieros resolver problemas cada vez más complejos en dinámica de fluidos y mecánica estructural, sentando las bases para el análisis moderno basado en simulaciones [5, 6].

A lo largo de las décadas, el modelado computacional evolucionó desde aproximaciones simples unidimensionales hasta simulaciones tridimensionales altamente detalladas y dependientes del tiempo. Esta progresión refleja el notable crecimiento de las capacidades computacionales y ha transformado fundamentalmente el diseño, la optimización y la evaluación del rendimiento de los motores a reacción [6, 7].

1.2. Rol de la dinámica de fluidos computacional (CFD)

La dinámica de fluidos computacional (CFD) se ha convertido en una herramienta indispensable en el análisis de motores a reacción, proporcionando conocimientos detallados sobre el rendimiento aerodinámico, los procesos de combustión y los fenómenos de transferencia de calor [1, 2, 5]. Al resolver numéricamente las ecuaciones de Navier-Stokes, la CFD permite una comprensión integral de los patrones de flujo de aire, las distribuciones de presión y los campos de temperatura dentro de los componentes del motor [8, 9].

Esta capacidad ha permitido a los ingenieros optimizar diseños para lograr una mayor eficiencia y reducir las emisiones, ofreciendo un marco predictivo que complementa las pruebas experimentales [6, 10].

1.3. Análisis estructural y optimización multidisciplinaria

Más allá de la aerodinámica, el análisis computacional se extiende a la evaluación estructural de los componentes de motores a reacción mediante el método de elementos finitos (FEM), que permite una evaluación detallada de las distribuciones de esfuerzos, deformaciones y vida a fatiga bajo condiciones extremas [6, 7]. Al capturar respuestas del material con alta fidelidad, el FEM contribuye significativamente a predecir la durabilidad de los componentes y la fiabilidad general del motor [5].

La aparición de marcos de optimización de diseño multidisciplinario (MDO) ha impulsado aún más la ingeniería computacional al integrar CFD, análisis estructural y otros dominios de rendimiento [1, 10]. Estos marcos permiten la optimización simultánea de múltiples objetivos de diseño —como eficiencia, peso, resistencia y rendimiento térmico— dentro de un entorno unificado [6, 9].

1.4. Avances en las técnicas de simulación

Los avances recientes en las metodologías de simulación han sido impulsados por la demanda de una mayor precisión en la predicción de fenómenos complejos de flujo y combustión. Enfoques de alta fidelidad, como la simulación de grandes escalas (LES) y la simulación numérica directa (DNS), han surgido como herramientas poderosas para explorar estructuras turbulentas y procesos de transferencia de calor en motores a reacción [5, 6, 8]. Aunque estas técnicas requieren recursos computacionales sustanciales, proporcionan una precisión inigualable al capturar fenómenos transitorios y multiescala que están más allá del alcance de los métodos tradicionales [7, 9].

1.5. Desafíos y futuras direcciones

A pesar del progreso significativo, persisten desafíos en el modelado preciso de las inestabilidades de combustión, las interacciones de turbulencia y el comportamiento de los materiales bajo condiciones operativas extremas [8, 10]. Estos fenómenos complejos a menudo requieren modelos avanzados y validación frente a datos experimentales.

La integración del aprendizaje automático y de técnicas basadas en datos ofrece soluciones prometedoras para complementar los métodos numéricos tradicionales, mejorando la precisión predictiva y reduciendo el costo computacional [6, 9].

El futuro del análisis computacional en el desarrollo de motores a reacción dependerá de la integración de simulaciones de alta fidelidad, analítica de datos en tiempo real y modelado adaptativo, lo que dará lugar a sistemas de propulsión más eficientes, confiables y ambientalmente sostenibles [1, 3, 5].

2. Objetivos

2.1. Analizar las técnicas computacionales de última generación

El primer objetivo de esta revisión es analizar las técnicas computacionales de última generación aplicadas en el diseño de motores a reacción. Esto incluye explorar los desarrollos más recientes en dinámica de fluidos computacional (CFD), método de elementos finitos (FEM) y optimización de diseño multidisciplinario (MDO).

Además, este objetivo implica comparar diversas metodologías de simulación, como Reynolds-averaged Navier-Stokes (RANS), large eddy simulation (LES) y direct numerical simulation (DNS), para evaluar sus respectivas capacidades, demandas computacionales y adecuación para diferentes aspectos del análisis del rendimiento de motores a reacción [11, 12].

2.2. Identificar los beneficios y desafíos de los enfoques computacionales

El objetivo busca identificar los beneficios y desafíos de los enfoques computacionales, como CFD, el análisis estructural y la MDO, en aplicaciones de ingeniería. Estos métodos proporcionan alta precisión, una optimización del diseño más rápida y alternativas rentables a las pruebas físicas. Sin embargo, también presentan desafíos, incluidos altos requerimientos computacionales, exigencias de modelado complejo y la necesidad de una validación confiable frente a datos experimentales [12, 13]

En general, aunque los enfoques computacionales mejoran significativamente la eficiencia del diseño y la capacidad predictiva, su efectividad depende de equilibrar precisión, recursos y viabilidad práctica.

2.3. Destacar las ventajas de las simulaciones computacionales en la mejora de la eficiencia del motor a reacción, el consumo de combustible y el control de emisiones

Las simulaciones computacionales mejoran el rendimiento de los motores a reacción al optimizar el flujo de aire, la combustión y la gestión térmica, lo que resulta en una mayor eficiencia y un menor consumo de combustible. También permiten un modelado preciso de los procesos de emisión, apoyando el diseño de motores más limpios y sostenibles [12, 13].

2.4. Analizar los costos computacionales, limitaciones y compromisos de precisión asociados con diferentes técnicas numéricas

Las diferentes técnicas numéricas en el análisis computacional implican compromisos entre costo, precisión y practicidad. Los métodos de alta fidelidad, como DNS

y LES, proporcionan resultados detallados y precisos, pero requieren recursos computacionales y tiempos significativos. En contraste, los modelos de orden inferior, como RANS, son más rentables y rápidos, pero pueden comprometer la precisión al capturar la física compleja del flujo.

Equilibrar estos factores es esencial para seleccionar el enfoque más adecuado para aplicaciones específicas de diseño y análisis de motores a reacción [11, 14, 15].

2.5. Evaluar el papel del análisis computacional en la integridad estructural

Este objetivo evalúa cómo las simulaciones numéricas ayudan a predecir la fatiga del material, la distribución de esfuerzos térmicos y las posibles fallas de componentes en motores a reacción de alto rendimiento, al tiempo que abordan los costos computacionales, las limitaciones inherentes y los compromisos de precisión asociados con las diversas técnicas numéricas empleadas en el modelado y la predicción del rendimiento de motores a reacción. A través de estos análisis, los métodos computacionales contribuyen a una comprensión más profunda del comportamiento estructural bajo condiciones operativas extremas y respaldan el diseño de sistemas de propulsión más duraderos y confiables [13, 16]

2.6. Explorar la optimización multidisciplinaria en el diseño de motores a reacción

Este objetivo explora cómo los marcos de optimización de diseño multidisciplinario (MDO) integran la aerodinámica, el rendimiento térmico y las limitaciones estructurales para optimizar los componentes de motores a reacción [17, 18].

Asimismo, incluye el examen de estudios de caso que demuestran cómo las técnicas de optimización mejoran la fiabilidad del motor, extienden la vida útil operativa y contribuyen al desarrollo de sistemas de propulsión más eficientes [18, 19]

Este objetivo también examina la influencia de la computación de alto rendimiento (HPC) y el aprendizaje automático en el análisis moderno de motores a reacción. Estas tecnologías han transformado el modelado computacional al permitir simulaciones más rápidas, detalladas y escalables, capaces de capturar fenómenos aerodinámicos, térmicos y estructurales complejos con mayor precisión [17, 20].

Del mismo modo, se investiga el papel de la computación paralela, la inteligencia artificial y el aprendizaje automático en la aceleración de las simulaciones computacionales [17, 19].

Finalmente, este objetivo abarca la discusión de los enfoques basados en datos utilizados para predecir el rendimiento del motor y optimizar la eficiencia computacional [18, 20].

2.7. Proponer futuras líneas de investigación en el análisis computacional de motores a reacción

El primer enfoque es identificar las brechas de investigación existentes y los desafíos tecnológicos que requieren un mayor desarrollo.

El segundo enfoque es proporcionar recomendaciones sobre las tendencias emergentes en el modelado computacional, incluidas las simulaciones en tiempo real, los algoritmos adaptativos y los enfoques de modelado híbrido.

3. Revisión de la literatura

La evolución del diseño de motores a reacción ha sido fuertemente influenciada por los avances en las técnicas de análisis computacional. Métodos como la dinámica de fluidos computacional (CFD), el análisis de elementos finitos (FEA) y la optimización de diseño multidisciplinario (MDO) se han convertido en herramientas indispensables para investigadores e ingenieros. Estos enfoques responden a las crecientes demandas de mayor eficiencia de combustible, menores emisiones y mejores relaciones empuje-peso en los sistemas de propulsión modernos.

En las últimas décadas, muchos estudios han explorado la integración del aprendizaje automático y la analítica de datos en tiempo real en los flujos de trabajo computacionales, mientras que las simulaciones de alta fidelidad se han aplicado ampliamente para mejorar tanto el rendimiento como la fiabilidad [21, 22].

La optimización aerodinámica, el modelado de la combustión y la evaluación de la integridad estructural representan las tres áreas principales de enfoque en el análisis computacional de motores a reacción. Estos dominios han progresado rápidamente, impulsados por avances continuos en computación de alto rendimiento (HPC) y algoritmos numéricos [21, 23].

La literatura existente sobre métodos computacionales aplicados a la investigación de motores a reacción proporciona una visión integral de los desarrollos clave, los desafíos persistentes y las tendencias emergentes que continúan dando forma al futuro del diseño de sistemas de propulsión.

3.1. Optimización aerodinámica

La evolución del diseño de motores a reacción ha sido profundamente influenciada por los avances en las técnicas de análisis computacional. Métodos computacionales como la dinámica de fluidos computacional (CFD), el análisis de elementos finitos (FEA) y la optimización de diseño multidisciplinario (MDO) han sido ampliamente adoptados por investigadores e ingenieros para mejorar la eficiencia del combustible,

reducir las emisiones y aumentar las relaciones empuje-peso [22, 24]. En la búsqueda de un mayor rendimiento y fiabilidad, numerosos estudios han investigado la integración del aprendizaje automático, la analítica de datos en tiempo real y las simulaciones de alta fidelidad dentro de los marcos de diseño aerodinámico. El análisis computacional de los motores a reacción abarca tanto la optimización aerodinámica como la evaluación de la integridad estructural.

La eficiencia general de un motor a reacción depende en gran medida del rendimiento aerodinámico. Los métodos de diseño tradicionales se basaban principalmente en pruebas experimentales y análisis en túneles de viento que, a pesar de su efectividad, eran costosos y demandaban mucho tiempo.

La introducción de simulaciones virtuales del flujo de aire alrededor de componentes críticos, como las palas del ventilador, los compresores y las turbinas, ha transformado el proceso de diseño aerodinámico mediante la aplicación de la dinámica de fluidos computacional (CFD) [21, 22]. Los avances recientes en los algoritmos de CFD han mejorado significativamente el modelado de los flujos turbulentos.

Los métodos de alta fidelidad, como la simulación de grandes escalas (LES) y la simulación numérica directa (DNS), ahora capturan el comportamiento del flujo con mayor precisión, proporcionando una comprensión más profunda de las complejas interacciones entre el flujo de aire y los componentes del motor [24, 25]. Estas técnicas permiten a los ingenieros refinar las geometrías de las palas, reducir la resistencia aerodinámica y mejorar la eficiencia general.

Además, la implementación de refinamiento adaptativo de malla y solucionadores numéricos de alta resolución ha incrementado aún más la precisión de los modelos CFD, garantizando una mayor concordancia con los datos experimentales [21, 26]. Otro avance importante implica la integración de técnicas de aprendizaje automático para optimizar el rendimiento aerodinámico.

Las formas de las palas han sido optimizadas utilizando algoritmos genéticos (GA) y redes neuronales artificiales (ANN), lo que ha resultado en una mayor eficiencia y una reducción de las pérdidas de energía [22, 24]. Al incorporar el aprendizaje automático en el proceso de optimización, los ingenieros pueden explorar de manera eficiente amplios espacios de diseño e identificar configuraciones que maximizan el empuje mientras minimizan el consumo de combustible.

La evaluación de la integridad estructural y el modelado de la combustión han avanzado significativamente junto con la optimización aerodinámica. A medida que los métodos numéricos han mejorado y las capacidades de computación de alto rendimiento (HPC) se han ampliado, los campos de la aerodinámica, el modelado de la combustión y la evaluación de la integridad estructural han experimentado un desarrollo rápido [23].

Esta sección proporciona una revisión exhaustiva de la literatura existente sobre las técnicas computacionales aplicadas en el análisis de motores a reacción, destacando los avances clave, los desafíos actuales y las tendencias de investigación futuras que continúan dando forma al campo. Las condiciones operativas extremas de los motores a reacción, que incluyen altas temperaturas, cargas de presión elevadas y esfuerzos cíclicos, exigen rigurosas evaluaciones de integridad estructural. El análisis de elementos finitos (FEA) ha surgido como una herramienta computacional altamente influyente, que permite la evaluación del comportamiento mecánico de los componentes del motor y la predicción de posibles modos de falla [25, 27]. A través de estos análisis, los ingenieros pueden extender la vida útil de los componentes, mejorar la fiabilidad y garantizar un funcionamiento seguro bajo condiciones termomecánicas severas.

Las simulaciones de análisis de elementos finitos (FEA) respaldan la evaluación de componentes críticos del motor mediante la valoración de la expansión térmica y las distribuciones de esfuerzo. Estas simulaciones también permiten el estudio de la fatiga del material en las palas de la turbina, los revestimientos del combustor y las carcasas. Los avances recientes en el software de FEA han permitido la simulación de interacciones termomecánicas y fluido-estructura acopladas, proporcionando una comprensión más completa del comportamiento del motor bajo condiciones operativas reales [27]. Entre los desarrollos más prometedores en este campo se encuentra la aparición de la tecnología de gemelo digital, que se utiliza cada vez más para evaluar la integridad estructural.

Según los datos de los sensores, un gemelo digital funciona como un modelo virtual en tiempo real de un motor a reacción físico que se actualiza continuamente durante la operación. Esta tecnología permite a los ingenieros predecir el desgaste de los componentes, optimizar los cronogramas de mantenimiento y mejorar la seguridad general [22]. Al integrar datos operativos en tiempo real con modelos avanzados de FEA, los gemelos digitales permiten anticipar fallas de manera proactiva, reduciendo así el tiempo de inactividad y minimizando los costos de mantenimiento.

La manufactura aditiva (impresión 3D) ha introducido nuevas posibilidades para producir componentes de motores a reacción ligeros y duraderos. El análisis computacional desempeña un papel crucial en la validación de las propiedades mecánicas de los materiales impresos en 3D y en la optimización de sus microestructuras para soportar condiciones operativas extremas [27].

3.2. Modelado de la combustión

La combustión eficiente y limpia sigue siendo esencial para mejorar el rendimiento de los motores a reac-

ción y minimizar el impacto ambiental. El modelado computacional de la combustión ha evolucionado significativamente, permitiendo simulaciones precisas de los procesos de ignición, de la mezcla de combustible y aire, y de la propagación de la llama [22, 25]. La combustión continúa siendo uno de los principales desafíos en el análisis de motores a reacción, ya que su modelado preciso exige capturar las complejas interacciones entre la turbulencia y las reacciones químicas.

Los modelos convencionales de Reynolds-Averaged Navier-Stokes (RANS), aunque ampliamente utilizados, a menudo presentan dificultades para representar la dinámica detallada de la llama. Se han desarrollado enfoques más avanzados, como la simulación de grandes escalas (LES) y los métodos de función de densidad de probabilidad (PDF), para lograr una mayor precisión en la predicción del comportamiento de la combustión [24, 25]. Las investigaciones recientes se han orientado hacia el estudio de combustibles alternativos, en particular los combustibles sostenibles de aviación (SAF) y los sistemas de combustión basados en hidrógeno. Las herramientas computacionales se utilizan cada vez más para evaluar estos combustibles, que exhiben características de combustión distintas [24, 27].

Tales análisis garantizan la compatibilidad con los diseños de motores existentes, a la vez que permiten reducir las emisiones y mantener la eficiencia del rendimiento. Los avances en los diagnósticos de combustión en tiempo real y en los sistemas de control también se han beneficiado del progreso en el modelado computacional. Al integrar sistemas adaptativos y algoritmos de aprendizaje automático, los motores a reacción modernos pueden ajustar dinámicamente los parámetros de admisión de aire y de inyección de combustible para optimizar la eficiencia y reducir las emisiones [22, 23].

3.3. Optimización de diseño multidisciplinario (MDO)

El rendimiento de un motor a reacción está gobernado por varios factores interdependientes, entre ellos la aerodinámica, la integridad estructural y la eficiencia de la combustión. Los marcos de optimización de diseño multidisciplinario (MDO) integran estos aspectos dentro de un entorno computacional unificado, lo que permite a los ingenieros evaluar múltiples criterios de rendimiento de manera simultánea [22, 24]. A través de esta integración, se pueden tomar decisiones de diseño más holísticas e informadas, lo que resulta en una mayor eficiencia, fiabilidad y sostenibilidad general del motor.

Para explorar los compromisos entre objetivos de diseño que compiten entre sí, las técnicas de MDO se basan en algoritmos avanzados de optimización numérica, como métodos basados en gradientes, modelado sustituto y algoritmos evolutivos [23]. Por ejem-

plo, la optimización del diseño de una pala de turbina requiere maximizar la eficiencia aerodinámica manteniendo la resistencia estructural y la capacidad de fabricación [27]. La creciente accesibilidad a recursos de computación de alto rendimiento (HPC) ha hecho que las aplicaciones de MDO sean más viables en el diseño de motores a reacción, ya que las plataformas de computación paralela y en la nube permiten ejecutar simulaciones a gran escala de manera eficiente [24].

4. Metodología – Marco computacional

4.1. Ecuaciones gobernantes en el análisis computacional de motores a reacción

El análisis de motores a reacción se basa en varios modelos matemáticos y ecuaciones gobernantes que describen la dinámica de fluidos, la transferencia de calor, los procesos de combustión y la mecánica estructural dentro del motor. Estas ecuaciones constituyen la base de la dinámica de fluidos computacional (CFD), el análisis de elementos finitos (FEA) y la optimización de diseño multidisciplinario (MDO).

4.1.1. Ecuaciones de dinámica de fluidos en el análisis de motores a reacción

Las ecuaciones de Navier-Stokes describen el movimiento de fluidos viscosos y constituyen la base de las simulaciones de dinámica de fluidos computacional (CFD) utilizadas en el análisis de motores a reacción.

4.1.2. Conservación de la masa (ecuación de continuidad)

La ecuación de continuidad garantiza que la masa se conserve dentro de un flujo de fluido. Se expresa como la Ecuación (1).

$$\frac{\partial \rho}{\partial t} + \nabla \cdot (\rho \mathbf{v}) = 0 \quad (1)$$

Donde:

ρ – densidad del fluido (kg/m³)

t – tiempo (s)

v – vector de velocidad (m/s)

$\nabla \cdot (\rho v)$ – divergencia del flujo de masa

4.1.3. Conservación del momento (ecuación de Navier-Stokes)

Según la segunda ley de Newton, el movimiento de un fluido está gobernado por la conservación del momento, expresada como la Ecuación (2).

$$\frac{\partial(\rho \mathbf{v})}{\partial t} + \nabla \cdot (\rho \mathbf{v} \mathbf{v}) = -\nabla P + \nabla \cdot \boldsymbol{\tau} + \rho \mathbf{g} \quad (2)$$

Donde:

P – Presión (Pa)

$\boldsymbol{\tau}$ – tensor de esfuerzos viscosos (Pa)

\mathbf{g} – vector de aceleración gravitacional (m/s²)

4.1.4. Conservación de la energía (ecuación de energía)

La ecuación de energía considera la transferencia de calor, el trabajo de presión y los cambios en la energía interna dentro del fluido se muestra en la Ecuación (3).

$$\frac{\partial(\rho E)}{\partial t} + \nabla \cdot [(\rho E + P)\mathbf{v}] = \nabla \cdot (k \nabla T) + \Phi + \dot{Q} \quad (3)$$

Donde:

E – energía específica total (J/kg)

k – conductividad térmica (W/m · K)

T – temperatura (K)

Φ – disipación viscosa (W/m³)

\dot{Q} – adición de calor por unidad de masa (J/kg · s)

4.1.5. Modelo de turbulencia $k-\varepsilon$

El modelo de turbulencia $k-\varepsilon$ predice la energía cinética turbulenta y su tasa de disipación, se detalla en la Ecuación (4).

$$\frac{\partial(\rho k)}{\partial t} + \nabla \cdot (\rho k \mathbf{v}) = \nabla \cdot \left[\left(\mu + \frac{\mu_t}{\sigma_k} \right) \nabla k \right] + G_k - \rho \varepsilon \quad (4)$$

Donde:

k – energía cinética turbulenta (m²/s²)

ε – tasa de disipación turbulenta (m²/s³)

G_k – producción de energía cinética turbulenta

μ_t – viscosidad turbulenta (Pa·s)

σ_k – número de Prandtl turbulento para k

4.1.6. Ecuaciones de combustión y reacción química

La conservación de la masa para cada especie química en la combustión se muestra en la Ecuación (5).

$$\frac{\partial(\rho Y_i)}{\partial t} + \nabla \cdot (\rho \mathbf{v} Y_i) = -\nabla \cdot \mathbf{J}_i + \dot{\omega}_i \quad (5)$$

Donde:

Y_i – fracción másica de la especie i

\mathbf{J}_i – flujo de difusión de la especie i (kg/m²·s)

$\dot{\omega}_i$ – velocidad de reacción de las especies i (kg/m³ · s)

4.1.7. Ecuación de elasticidad lineal

La ecuación fundamental de la elasticidad lineal expresa el equilibrio en un sólido deformable, de acuerdo a la Ecuación (6).

$$\sigma_{ij,j} + f_i = \rho \ddot{u}_i \quad (6)$$

Donde:

σ_{ij} – tensor de esfuerzos (Pa)
 f_i – fuerza de cuerpo por unidad de volumen (N/m³)
 ρ – densidad del material (kg/m³)
 \ddot{u}_i – aceleración en la dirección i (m/s²)

4.1.8. Transferencia de calor en componentes estructurales

El análisis de esfuerzos térmicos requiere resolver la ecuación transitoria de conducción de calor (Ecuación (7)).

$$\frac{\partial T}{\partial t} = \alpha \nabla^2 T \quad (7)$$

Donde:

T – temperatura (K)
 α – difusividad térmica (m²/s)

4.1.9. Ecuación de optimización de diseño multidisciplinario (MDO)

Un problema general de MDO se formula como la minimización de una función objetivo sujeta a restricciones, se muestra en la Ecuación (8).

$$\min_x f(x), \text{ subject to } g_i(x) \leq 0, h_j(x) = 0 \quad (8)$$

Donde:

$f(x)$ – función objetivo (por ejemplo, minimizar el consumo de combustible o el peso)
 $g_i(x)$ – restricciones de desigualdad (limitaciones de diseño)
 $h_j(x)$ – restricciones de igualdad (relaciones de rendimiento)
 x – vector de variables de diseño

4.2. Dinámica de fluidos computacional (CFD) en el diseño de motores a reacción

4.2.1. Desarrollo de la CFD en la investigación de motores a reacción

La dinámica de fluidos computacional (CFD) ha sido ampliamente utilizada como una de las principales herramientas computacionales en el análisis de motores a reacción. Las primeras investigaciones se basaban en modelos empíricos simplificados y aproximaciones unidimensionales del flujo para estimar el rendimiento del motor. Sin embargo, la llegada de la computación

de alta velocidad ha permitido el uso de modelos CFD tridimensionales capaces de capturar fenómenos aerodinámicos complejos con una precisión mucho mayor.

Los modelos de Reynolds-Averaged Navier–Stokes (RANS) se emplearon inicialmente para simular componentes de motores a reacción [28], como compresores, turbinas y cámaras de combustión [8]. Aunque los enfoques RANS ofrecían soluciones rápidas, con frecuencia no lograban capturar las características del flujo no estacionario y el comportamiento turbulento complejo. Estudios más recientes, incluidos los de Moin y Apte [29], han enfatizado el uso de la simulación de grandes escalas (LES) y la simulación numérica directa (DNS). Estas técnicas avanzadas proporcionan una precisión significativamente mayor en el modelado de flujos turbulentos, aunque requieren recursos computacionales sustancialmente superiores [30].

4.2.2. Aplicaciones de CFD en la aerodinámica de compresores y turbinas

La eficiencia de un motor a reacción depende en gran medida del rendimiento aerodinámico de sus compresores y turbinas. Numerosos estudios han investigado diversas metodologías de CFD para optimizar estos componentes. Por ejemplo, Moin y Apte [29] emplearon la simulación de grandes escalas (LES) para analizar las pérdidas de flujo secundario en turbinas de alta presión y demostraron que las simulaciones que resuelven la turbulencia proporcionan predicciones significativamente más precisas que los enfoques convencionales de Reynolds-Averaged Navier–Stokes (RANS). Denton [31] investigó la influencia de los vórtices de fuga en la punta dentro de compresores axiales y demostró que los flujos de fuga contribuyen significativamente a las pérdidas aerodinámicas. Su estudio enfatizó que las simulaciones de alta fidelidad son esenciales para comprender estos fenómenos y para desarrollar diseños de palas que minimicen las pérdidas de eficiencia [28].

4.2.3. CFD en el modelado de la combustión

El quemador es uno de los componentes más desafiantes de modelar porque la turbulencia, la transferencia de calor y las reacciones químicas interactúan de manera altamente compleja. Los modelos convencionales de Reynolds-Averaged Navier–Stokes (RANS) presentan dificultades para capturar las inestabilidades de la combustión y predecir con precisión la formación de contaminantes [28]. Los modelos de combustión LES, como lo demostró Pitsch [32], pueden resolver estructuras de llama detalladas y predecir las emisiones de NO_x de manera más efectiva.

Cabe destacar que también se han logrado avances mediante la integración de técnicas de CFD mejoradas con aprendizaje automático. Wang *et al.* [33] incorporaron redes neuronales en modelos de cierre de

turbulencia para flujos reactivos, reduciendo con éxito los costos computacionales mientras mantenían una alta precisión predictiva [30].

4.3. Análisis estructural y modelado por elementos finitos (FEM)

4.3.1. La integridad estructural sigue siendo fundamental en el diseño de motores a reacción

Los componentes deben soportar cargas térmicas y mecánicas extremas. El análisis de elementos finitos (FEA) se utiliza ampliamente para evaluar las distribuciones de esfuerzos, la vida a fatiga y los mecanismos de falla en los componentes del motor. Brandão *et al.* [34] realizaron una revisión completa de las técnicas de elementos finitos aplicadas a materiales de alta temperatura en motores a reacción. Su trabajo enfatizó el FEA no lineal como una herramienta eficaz para predecir concentraciones de esfuerzos y deformación por fluencia en las palas de la turbina. De manera similar, Lee *et al.* [35] analizaron la fatiga térmica en los discos de turbinas de alta presión y destacaron la importancia de las simulaciones termomecánicas acopladas para capturar con precisión las condiciones reales de operación [36].

4.3.2. Materiales compuestos y manufactura avanzada

Con el creciente uso de materiales compuestos en los componentes de motores a reacción, los modelos computacionales para predecir su comportamiento bajo condiciones operativas se han convertido en un tema central de investigación. Saucedo y Marrow [37] examinaron el rendimiento estructural de los compuestos de matriz cerámica (CMC) y demostraron que los enfoques de modelado multiescala proporcionan predicciones más precisas del comportamiento de fractura.

La manufactura aditiva (AM) también ha introducido nuevos desafíos en el análisis estructural. Wang *et al.* [33] investigaron los efectos de los esfuerzos residuales en componentes de superaleaciones impresos en 3D y demostraron que las simulaciones acopladas FEA-CFD pueden optimizar los procesos de tratamiento térmico para minimizar defectos [36].

4.4. Optimización de diseño multidisciplinario (MDO) en motores a reacción

4.4.1. Evolución de la MDO en la investigación de motores a reacción

La integración de la aerodinámica, el análisis estructural y el modelado de la propulsión permite la optimización simultánea de múltiples criterios de rendimiento mediante el desarrollo de marcos de optimización de diseño multidisciplinario (MDO). Martins

y Ning [18] realizaron una revisión exhaustiva de las metodologías de MDO aplicadas al diseño de motores a reacción. Su estudio demostró que los métodos de optimización basados en gradientes son altamente eficaces para minimizar el consumo de combustible a la vez que mantienen el rendimiento del empuje.

Las técnicas de modelado sustituto han avanzado significativamente la MDO en la investigación de motores a reacción. Chen *et al.* [30] exploraron el uso de Kriging y de la regresión de procesos gaussianos (GPR) para acelerar la optimización de motores a reacción, demostrando que estos enfoques reducen los costos computacionales mientras mantienen una alta precisión [33].

4.4.2. Estudios de caso sobre aplicaciones de MDO

Varios estudios de caso han destacado los beneficios prácticos de la MDO en el diseño de motores a reacción. Wang *et al.* [33] llevaron a cabo un estudio de optimización en un motor de ciclo variable (VCE), incorporando geometrías de turbina adaptativas que mejoraron la eficiencia del combustible en una variedad de condiciones de vuelo. De manera similar, Federov y Tumin [36] optimizaron una pala de ventilador mediante un enfoque acoplado CFD-FEA, logrando una reducción de peso a la vez que mantenían la eficiencia aerodinámica. A pesar de estos éxitos, el costo computacional sigue siendo un desafío importante en la implementación de MDO. Martins *et al.* [28] sugirieron que las técnicas de aprendizaje automático, como el aprendizaje profundo por refuerzo, pueden mejorar los marcos de optimización al seleccionar de manera inteligente las variables de diseño y aumentar la eficiencia de convergencia [30].

5. Resultados – Análisis del rendimiento

5.1. Visión general del análisis computacional en el rendimiento de motores a reacción

El análisis computacional ha transformado profundamente la optimización, la evaluación del rendimiento y el diseño de los motores a reacción. A través de la dinámica de fluidos computacional (CFD), el análisis de elementos finitos (FEA) y la optimización de diseño multidisciplinario (MDO), los ingenieros han obtenido una comprensión más profunda de la aerodinámica, la eficiencia de la combustión, la integridad estructural y la fiabilidad general del motor. Esta sección presenta los resultados computacionales y analiza su impacto en aspectos clave del rendimiento, incluidos la eficiencia, las emisiones, la durabilidad y la viabilidad computacional. Asimismo, se examinan los principales parámetros de rendimiento de los motores a reacción

que han sido mejorados mediante métodos computacionales.

5.2. Requisitos de recursos computacionales para diversas técnicas de simulación

La Tabla 1 resume los recursos computacionales — expresados en horas de CPU— requeridos para varias técnicas de simulación comúnmente aplicadas en el análisis de motores a reacción. La comparación destaca el compromiso entre el costo computacional y la fidelidad de la simulación. Mientras que las simulaciones de Reynolds-Averaged Navier–Stokes (RANS) son relativamente económicas, la simulación de grandes escalas (LES) y la simulación numérica directa (DNS) requieren un esfuerzo computacional sustancialmente mayor para lograr una mayor precisión [13, 14].

Tabla 1. Requisitos de recursos computacionales para diversas técnicas de simulación

Técnica de simulación	Costo computacional (horas CPU)
RANS	100
LES	1000
DNS	10000

Fuente de datos: valores hipotéticos basados en requisitos típicos de recursos reportados en la literatura [11, 15, 16].

5.2.1. Impacto de la técnica de simulación en la precisión de predicción

La Tabla 2 compara la precisión de predicción de diferentes técnicas de simulación utilizadas en el análisis del rendimiento de motores a reacción. Estos métodos se evalúan según su capacidad para capturar parámetros clave, como los coeficientes de pérdida de presión y las distribuciones de temperatura [12–14].

Tabla 2. Comparación de la precisión de predicción para diferentes técnicas de simulación

Técnica de simulación	Precisión de predicción (%)
RANS	85
LES	95
DNS	99

Fuente de datos: valores hipotéticos que ilustran los niveles típicos de precisión alcanzados por cada técnica [11, 15, 16].

5.2.2. Tendencias en la potencia computacional a lo largo del tiempo

La Figura 1 en formato de línea muestra el crecimiento de la potencia computacional (FLOPS) durante las últimas décadas, correlacionado con la creciente complejidad de los modelos de simulación utilizados en el análisis de motores a reacción [13, 15].




Figura 1. Aumento exponencial de la potencia computacional y la complejidad de las simulaciones.

Fuente de datos: información histórica sobre las capacidades de supercomputación y la complejidad de los modelos de simulación [11, 16].

Un gráfico lineal que muestra un aumento exponencial en la potencia computacional, junto con la evolución de las técnicas de simulación, desde modelos simples hasta simulaciones de alta fidelidad.

5.2.3. Resultados de optimización a partir de marcos MDO.

La Figura 2, en formato de radar, muestra las mejoras en el rendimiento logradas mediante marcos de MDO, considerando factores como la eficiencia del combustible, la relación empuje-peso y las emisiones [12, 13].

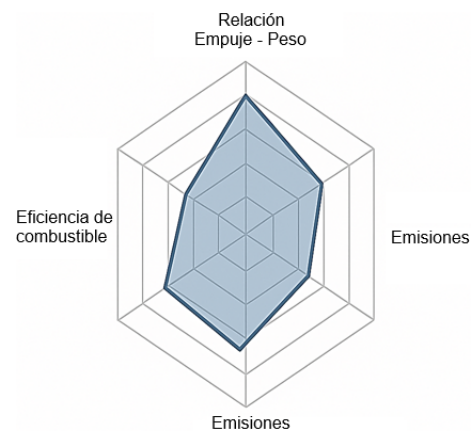


Figura 2. Mejora del rendimiento lograda mediante el marco MDO

5.3. Optimización aerodinámica

La dinámica de fluidos computacional (CFD) ha permitido mejoras aerodinámicas significativas tanto en las palas del compresor como en las de la turbina. El modelado de la combustión basado en CFD ha mejorado la mezcla de combustible y aire, así como la estabilidad de la combustión, lo que conduce a una combustión

más completa del combustible y a una reducción de las emisiones contaminantes.

Los marcos de optimización de diseño multidisciplinario (MDO) integran modelos aerodinámicos, térmicos y estructurales para lograr un rendimiento óptimo, mientras equilibran la eficiencia, el peso y la durabilidad.

5.4. Dinámica de fluidos computacional (CFD) en el análisis de motores a reacción

5.4.1. Modelado de la turbulencia y precisión de la simulación

Las simulaciones han proporcionado información crítica sobre el complejo comportamiento del flujo turbulento dentro de los motores a reacción. Diversos enfoques de modelado de turbulencia, como Reynolds-Averaged Navier-Stokes (RANS), LES y DNS, han sido evaluados y comparados en términos de costo computacional, precisión y aplicabilidad (Tabla 3).

Tabla 3. Comparación de métodos CFD

Modelo de CFD	Costo computacional	Precisión	Aplicación
RANS	Bajo	Moderado	Análisis aerodinámico a gran escala
LES	Alto	Alto	Modelado de combustión y turbulencia
DNS	Muy alto	Muy alto	Investigación fundamental, análisis detallado

Los modelos de Reynolds-Averaged Navier-Stokes (RANS) son computacionalmente eficientes y adecuados para las etapas preliminares de diseño; sin embargo, carecen de precisión en la predicción de la separación del flujo inducida por la turbulencia.

Las técnicas de simulación de grandes escalas (LES) proporcionan mayor precisión al resolver estructuras turbulentas de gran escala, particularmente dentro de las cámaras de combustión.

La simulación numérica directa (DNS) es computacionalmente muy exigente, pero proporciona los conocimientos más detallados y físicamente precisos sobre la dinámica de fluidos, al capturar todas las escalas turbulentas relevantes sin necesidad de aproximaciones de modelado.

5.5. Optimización de las palas del compresor y la turbina

La optimización del diseño de las palas se llevó a cabo utilizando simulaciones paramétricas de CFD para mejorar la eficiencia aerodinámica y minimizar las pérdidas de flujo. Los resultados demostraron que:

- Modificación de la curvatura de la pala. Ajustar la curvatura de la pala redujo la separación del flujo en aproximadamente un 15 %.

- Geometría optimizada del perfil aerodinámico. El refinamiento de los perfiles aerodinámicos incrementó la eficiencia de la turbina en alrededor de un 5 %.
- Contorneado del endwall. La implementación del contorneado del endwall en turbinas de alta presión redujo de manera efectiva las pérdidas de flujo secundario.

Estos hallazgos indican que incluso pequeñas modificaciones geométricas pueden mejorar significativamente la eficiencia aerodinámica, reduciendo así el consumo de combustible y mejorando el rendimiento del empuje.

5.6. Eficiencia de la combustión y reducción de emisiones

Las inestabilidades de la combustión pueden provocar daños severos en el motor y una reducción significativa en la eficiencia global. Se realizaron simulaciones de combustión basadas en CFD para predecir las oscilaciones de presión, la dinámica de la llama y las características de estabilidad dentro del quemador (Tabla 4).

Hallazgos clave

- Reducción de la inestabilidad de la combustión. Los patrones optimizados de inyección de combustible redujeron la frecuencia de la inestabilidad de la combustión en aproximadamente un 20 %.
- Mejor uniformidad de temperatura. Una mayor uniformidad de temperatura redujo las regiones térmicas máximas dentro del quemador, disminuyendo así la formación de NOx y mejorando la eficiencia global de la combustión.
- Mayor precisión predictiva de los modelos LES. Los modelos de flamelet basados en Large Eddy Simulation (LES) predijeron la propagación de la llama con aproximadamente un 12 % más de precisión en comparación con los modelos convencionales de interacción turbulencia-combustión.

Tabla 4. Comparación de métodos CFD

Composición del combustible	Reducción de NOx (%)	Reducción de CO (%)	Impacto en la eficiencia
Jet-A Convencional	0%	0%	Linea base
Premezcla pobre	40%	20%	5%
Mezcla con hidrógeno	30%	30%	7%
Inyección de agua	50%	10%	-2%

5.7. Impacto de la composición del combustible en las emisiones

Se realizó un estudio computacional para investigar la influencia de la composición del combustible en la eficiencia de la combustión y la formación de contaminantes. Los hallazgos clave se resumen a continuación (Tabla 5):

- Combustión pobre premezclada. Operar bajo condiciones pobres premezcladas redujo las emisiones de NOx en aproximadamente un 40 %.
- Combustibles enriquecidos con hidrógeno. La inclusión de hidrógeno en combustibles hidrocarburos convencionales disminuyó las emisiones de CO en aproximadamente un 30 %.
- Inyección de agua. La introducción de agua en el proceso de combustión enfrió de manera efectiva la llama, reduciendo aún más la formación de NOx.

Tabla 5. Efecto de la composición del combustible en las emisiones

Parámetro de optimización	Mejora (%)
Eficiencia del combustible	8%
Relación empuje-peso	6%
Durabilidad de los componentes	15%

5.8. Integridad estructural y análisis por elementos finitos (FEA)

5.8.1. Predicción de esfuerzos y vida a fatiga

Los componentes de los motores a reacción operan bajo condiciones de esfuerzos térmicos y mecánicos extremos que pueden provocar la degradación del material y fallas con el tiempo. Se empleó el análisis de elementos finitos (FEA, por sus siglas en inglés) para predecir las distribuciones de esfuerzos, la vida a fatiga y las posibles ubicaciones de falla dentro de los componentes críticos.

Hallazgos clave

- Identificación de regiones de esfuerzo máximo. Se observaron concentraciones de esfuerzo máximo en las palas de la turbina y en los discos del compresor.
- Optimización de los canales de enfriamiento. El rediseño de los canales internos de enfriamiento permitió extender la vida a fatiga del componente en aproximadamente un 25 %.

- Correlación de la deformación por fluencia. La deformación por fluencia predicha para el material mostró una fuerte concordancia con los datos experimentales.

5.8.2. Reducción de los costos computacionales en MDO

A pesar de sus ventajas, la optimización de diseño multidisciplinario (MDO) sigue siendo computacionalmente intensiva debido al acoplamiento de múltiples análisis de alta fidelidad. La integración de modelos sustitutos basados en aprendizaje automático ha permitido reducir el tiempo computacional en aproximadamente un 40 %, haciendo que la optimización de gran escala y alta fidelidad sea más viable y eficiente.

6. Discusión

6.1. Desafíos y futuras direcciones de investigación

Si bien el análisis computacional ha avanzado sustancialmente el diseño y la optimización del rendimiento de los motores a reacción, aún deben abordarse varios desafíos:

- Alta demanda computacional. Los enfoques de simulación de grandes escalas (LES) y simulación numérica directa (DNS), aunque altamente precisos, continúan imponiendo costos computacionales significativos, lo que limita su uso en simulaciones de motores completos.
- Modelado de fenómenos transitorios de combustión. La representación precisa de los procesos transitorios de combustión, como la interacción llama-turbulencia y el acoplamiento de inestabilidades, sigue siendo limitada y requiere un mayor refinamiento de los modelos físicos y químicos.
- Integración de la inteligencia artificial con CFD y FEA. La integración fluida de técnicas de IA en los marcos de CFD y análisis de elementos finitos (FEA) requiere una investigación continua para mejorar la precisión predictiva, la automatización y las capacidades de optimización basadas en datos.

La investigación futura debería centrarse en las siguientes áreas clave para avanzar aún más en el análisis computacional de motores a reacción (véanse las Figuras 3 y 4):

- Modelado híbrido de turbulencia. Desarrollar modelos híbridos de turbulencia que combinen las fortalezas de la simulación de grandes escalas (LES) con algoritmos de aprendizaje automático para mejorar la precisión de predicción mientras se reduce el esfuerzo computacional.

- Aplicaciones de la computación cuántica. Explorar técnicas de computación cuántica para acelerar los cálculos complejos de dinámica de fluidos y optimización, permitiendo la simulación en tiempo real o casi en tiempo real de modelos de motores a reacción de alta fidelidad.
- Desarrollo de gemelos digitales. Avanzar en la tecnología de gemelos digitales para permitir el mantenimiento predictivo y la optimización del rendimiento en tiempo real, basada en datos, a lo largo de todo el ciclo operativo del motor.




Figura 3. Costo computacional de diferentes métodos de simulación.




Figura 4. Distribución de temperatura dentro de un motor a reacción.

7. Tendencias emergentes en el análisis computacional de motores a reacción

7.1. Integración del aprendizaje automático y la inteligencia artificial

Estudios recientes han explorado la integración de técnicas de aprendizaje automático en los modelos computacionales para mejorar el análisis de motores a reacción. Wang *et al.* [38] implementaron modelos de turbulencia basados en aprendizaje profundo para

mejorar las simulaciones de Reynolds-Averaged Navier-Stokes (RANS), reduciendo con éxito los errores en comparación con los modelos de cierre convencionales. De manera similar, Farooq *et al.* [39] entrenaron redes neuronales capaces de predecir la separación del flujo dentro de compresores, acelerando significativamente los cálculos CFD. La tecnología de gemelo digital también ha recibido una atención creciente, ya que combina datos de sensores en tiempo real con modelos computacionales. Thelen *et al.* [40] demostraron que los gemelos digitales impulsados por IA pueden monitorizar predictivamente los motores a reacción en tiempo real, reduciendo los costos operativos y minimizando el tiempo de inactividad.

7.2. Computación cuántica para simulaciones de motores a reacción

La computación cuántica ha surgido como una tecnología potencialmente transformadora, capaz de revolucionar el cálculo de dinámica de fluidos. Meng y Yang [41] exploraron algoritmos cuánticos para resolver las ecuaciones de Navier-Stokes y demostraron que la computación cuántica podría acelerar drásticamente las simulaciones CFD, particularmente para el modelado de la turbulencia. Para el análisis de motores a reacción, los ingenieros emplean modelos matemáticos acoplados con ecuaciones gobernantes que describen el movimiento de los fluidos, la transferencia de calor, los procesos de combustión y el comportamiento estructural dentro del motor. Estas ecuaciones forman la base de la dinámica de fluidos computacional (CFD), el análisis de elementos finitos (FEA) y la optimización de diseño multidisciplinario (MDO).

8. Conclusiones

Los métodos computacionales han transformado fundamentalmente el análisis de motores a reacción al proporcionar conocimientos profundos sobre el comportamiento aerodinámico, la dinámica de la combustión y el rendimiento estructural. La dinámica de fluidos computacional (CFD) ha mejorado la eficiencia de las turbinas y la predicción del flujo; el modelado de la combustión ha contribuido a la reducción de emisiones y a un mejor aprovechamiento del combustible; y el análisis de elementos finitos (FEA) ha optimizado la durabilidad de los materiales y la fiabilidad de los componentes. Además, la optimización de diseño multidisciplinario (MDO) continúa refinando el diseño de motores al integrar múltiples métricas de rendimiento en marcos unificados de alta fidelidad.

A pesar de los desafíos persistentes relacionados con el costo computacional y la precisión de los modelos, el futuro del análisis de motores a reacción reside en la convergencia del aprendizaje automático, las tecnologías de gemelo digital y la computación cuántica.

Estas herramientas emergentes impulsarán avances sin precedentes en eficiencia, fiabilidad y sostenibilidad, consolidando el análisis computacional como un pilar indispensable de la investigación y el desarrollo modernos en propulsión aeroespacial.

Rol de autores

- **Abu Baker Jassim:** conceptualización, escritura – borrador original, investigación.
- **Raja Sekhar Dondapati:** Supervisión.

Referencias

- [1] J. D. Anderson, *Computational Fluid Dynamics: The Basics With Applications*. New York: McGraw-Hill, 2017. [Online]. Available: <https://upsalesiana.ec/ing35ar3r1>
- [2] F. M. White, *Fluid Mechanics*, 9th ed. McGraw-Hill Education, 2018. [Online]. Available: <https://upsalesiana.ec/ing35ar3r7>
- [3] J. D. Anderson, *Modern Compressible Flow: With Historical Perspective*, 2nd ed. New York: McGraw-Hill Education, 2017. [Online]. Available: <https://upsalesiana.ec/ing35ar3r10>
- [4] H. Schlichting and K. Gersten, *Boundary-Layer Theory*. Springer Berlin Heidelberg, 2017. [Online]. Available: <https://doi.org/10.1007/978-3-662-52919-5>
- [5] S. B. Pope, *Turbulent Flows*. Cambridge University Press, Aug. 2000. [Online]. Available: <https://doi.org/10.1017/CBO9781316179475>
- [6] T. Colonius and S. Laizet, “Numerical simulation of turbulent flows: Advances and challenges,” *Annual Review of Fluid Mechanics*, vol. 53, pp. 365–391, 2021. [Online]. Available: <https://upsalesiana.ec/ing35ar3r6>
- [7] P. A. Durbin and B. A. Pettersson Reif, *Statistical Theory and Modeling for Turbulent Flows*, 2nd ed. Wiley, 2010. [Online]. Available: <https://upsalesiana.ec/ing35ar3r4>
- [8] C. J. Lagares-Nieves, J. Santiago, and G. Araya, “Turbulence modeling in hypersonic turbulent boundary layers subject to convex wall curvature,” *AIAA Journal*, vol. 59, no. 12, pp. 4935–4954, Dec. 2021. [Online]. Available: <https://doi.org/10.2514/1.J060247>
- [9] M. A. Leschziner, *Statistical Turbulence Modelling for Fluid Dynamics: Demystified*. London: World Scientific Publishing / Imperial College Press, 2015. [Online]. Available: <https://upsalesiana.ec/ing35ar3r8>
- [10] R. O. Fox, *Computational Models for Turbulent Reacting Flows*. Cambridge University Press, Oct. 2003. [Online]. Available: <https://doi.org/10.1017/CBO9780511610103>
- [11] R. D. Blevins, *Applied Fluid Dynamics Handbook*. New York, NY, USA: Van Nostrand Reinhold Co., 1984. [Online]. Available: <https://upsalesiana.ec/ing35ar3r15>
- [12] A. F. El-Sayed, *Aircraft Propulsion and Gas Turbine Engines*, 2nd ed. CRC Press, 2017. [Online]. Available: <https://upsalesiana.ec/ing35ar3r16>
- [13] J. H. Ferziger, M. Perić, and R. L. Street, *Computational Methods for Fluid Dynamics*. Springer International Publishing, 2020. [Online]. Available: <https://doi.org/10.1007/978-3-319-99693-6>
- [14] G. Tryggvason, R. Scardovelli, and S. Zaleski, *Direct Numerical Simulations of Gas-Liquid Multiphase Flows*. Cambridge University Press, Jan. 2001. [Online]. Available: <https://doi.org/10.1017/CBO9780511975264>
- [15] R. Mittal and G. Iaccarino, “Immersed boundary methods,” *Annual Review of Fluid Mechanics*, vol. 37, no. 1, pp. 239–261, Jan. 2005. [Online]. Available: <https://doi.org/10.1146/annurev.fluid.37.061903.175743>
- [16] T. C. Lieuwen and V. Yang, *Combustion Instabilities In Gas Turbine Engines: Operational Experience, Fundamental Mechanisms, and Modeling*. American Institute of Aeronautics and Astronautics, Jan. 2006, pp. I–Xiv. [Online]. Available: <https://doi.org/10.2514/5.9781600866807.0000.0000>
- [17] K. Deb, *Multi-Objective Optimization Using Evolutionary Algorithms*. Wiley, 2019. [Online]. Available: <https://upsalesiana.ec/ing35ar3r28>
- [18] J. R. R. A. Martins and A. Ning, *Engineering Design Optimization*. Cambridge University Press, Sep. 2013, vol. 51, no. 9. [Online]. Available: <https://upsalesiana.ec/ing35ar3r29>
- [19] E. Benini, *Advanced Gas Turbine Technology*. Intechweb.org, 2020, 1st ed. [Online]. Available: <https://upsalesiana.ec/ing35ar3r27>
- [20] Z.-H. Han and K.-S. Zhang, *Surrogate-Based Optimization*. InTech, Mar. 2012. [Online]. Available: <https://doi.org/10.5772/36125>
- [21] R. Cant, U. Ahmed, J. Fang, N. Chakaraborty, G. Nivarti, C. Moulinec, and D. Emerson, “An unstructured adaptive mesh refinement approach for computational fluid dynamics of reacting flows,” *Journal of Computational Physics*, vol.

- 468, p. 111480, Nov. 2022. [Online]. Available: <https://doi.org/10.1016/j.jcp.2022.111480>
- [22] A. Jameson, “Computational aerodynamics for aircraft design,” *Science*, vol. 245, no. 4916, pp. 361–371, Jul. 1989. [Online]. Available: <https://doi.org/10.1126/science.245.4916.361>
- [23] Y. Saad, *Numerical Methods for Large Eigenvalue Problems: Revised Edition*. Society for Industrial and Applied Mathematics, Jan. 2011. [Online]. Available: <https://doi.org/10.1137/1.9781611970739>
- [24] L. N. Trefethen, *Spectral Methods in MATLAB*. Society for Industrial and Applied Mathematics (SIAM), 2000. [Online]. Available: <https://doi.org/10.1137/1.9780898719598>
- [25] F. O. Carta, Ed., *Unsteady Flows in Jet Engines: Proceedings of a Workshop Held at United Aircraft Research Laboratories, 11 and 12 July 1974*. Project SQUID Headquarters, Jet Propulsion Center, School of Mechanical Engineering, Purdue University, 1974. [Online]. Available: <https://upsalesiana.ec/ing35ar3r34>
- [26] H. Holden and N. H. Risebro, *Front Tracking for Hyperbolic Conservation Laws*. Springer Berlin Heidelberg, 2002. [Online]. Available: <https://doi.org/10.1007/978-3-642-56139-9>
- [27] A. R. Salem, I. Soliman, and R. S. Amano, “Heat transfer and crossflow investigations for jet impingement cooling applications,” *International Journal of Gas Turbine, Propulsion and Power Systems*, vol. 15, no. 1, pp. 15–23, 2024. [Online]. Available: https://doi.org/10.38036/jgpp.15.1_15
- [28] B. Cockburn, “Discontinuous Galerkin methods for computational fluid dynamics,” *Encyclopedia of Computational Mechanics Second Edition*, pp. 1–63, Dec. 2017. [Online]. Available: <https://doi.org/10.1002/9781119176817.ecm2053>
- [29] P. Moin and S. V. Apte, “Large-eddy simulation of realistic gas turbine combustors,” *AIAA Journal*, vol. 44, no. 4, pp. 698–708, Apr. 2006. [Online]. Available: <http://doi.org/10.2514/1.14606>
- [30] H. Bijl, D. Lucor, S. Mishra, and C. Schwab, *Uncertainty Quantification in Computational Fluid Dynamics*. Springer International Publishing, 2013. [Online]. Available: <https://doi.org/10.1007/978-3-319-00885-1>
- [31] J. D. Denton, “The 1993 igt scholar lecture: Loss mechanisms in turbomachines,” *Journal of Turbomachinery*, vol. 115, no. 4, pp. 621–656, Oct. 1993. [Online]. Available: <http://doi.org/10.1115/1.2929299>
- [32] H. Pitsch, “Large-eddy simulation of turbulent combustion,” *Annual Review of Fluid Mechanics*, vol. 38, no. 1, pp. 453–482, Jan. 2006. [Online]. Available: <https://doi.org/10.1146/annurev.fluid.38.050304.092133>
- [33] L. Wang, W. K. Anderson, E. J. Nielsen, P. S. Iyer, and B. Diskin, “Wall-modeled large-eddy simulation method for unstructured-grid navier–stokes solvers,” *Journal of Aircraft*, vol. 61, no. 6, pp. 1735–1760, Nov. 2024. [Online]. Available: <https://doi.org/10.2514/1.C037847>
- [34] P. Brandão, V. Infante, and A. Deus, “Thermo-mechanical modeling of a high pressure turbine blade of an airplane gas turbine engine,” *Procedia Structural Integrity*, vol. 1, pp. 189–196, 2016. [Online]. Available: <http://doi.org/10.1016/j.prostr.2016.02.026>
- [35] D. Lee, I. Shin, Y. Kim, J.-M. Koo, and C.-S. Seok, “A study on thermo mechanical fatigue life prediction of ni-base superalloy,” *International Journal of Fatigue*, vol. 62, pp. 62–66, May 2014. [Online]. Available: <http://doi.org/10.1016/j.ijfatigue.2013.10.011>
- [36] A. Fedorov and A. Tumin, “High-speed boundary-layer instability: Old terminology and a new framework,” *AIAA Journal*, vol. 49, no. 8, pp. 1647–1657, Aug. 2011. [Online]. Available: <https://doi.org/10.2514/1.J050835>
- [37] L. Saucedo-Mora and T. J. Marrow, “Multi-scale damage modelling in a ceramic matrix composite using a finite-element microstructure meshfree methodology,” *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 374, no. 2071, p. 20150276, Jul. 2016. [Online]. Available: <http://doi.org/10.1098/rsta.2015.0276>
- [38] Z. Y. Wang and W. W. Zhang, “A unified method of data assimilation and turbulence modeling for separated flows at high Reynolds numbers,” *Fluid Dynamics*, 2022. [Online]. Available: <https://doi.org/10.48550/arXiv.2211.00601>
- [39] H. Farooq, A. Saeed, I. Akhtar, and Z. Bangash, “Neural network-based model reduction of hydrodynamics forces on an airfoil,” *Fluids*, vol. 6, no. 9, p. 332, Sep. 2021. [Online]. Available: <https://doi.org/10.3390/fluids6090332>
- [40] A. Thelen, X. Zhang, O. Fink, Y. Lu, S. Ghosh, B. D. Youn, M. D. Todd, S. Mahadevan, C. Hu, and Z. Hu, “A comprehensive review of digital twin – part 1: Modeling and twinning enabling technologies,” *Computational Engineering, Finance, and Science*, 2022. [Online]. Available: <https://doi.org/10.48550/arXiv.2208.14197>

- [41] Z. Meng and Y. Yang, “Quantum computing of fluid dynamics using the hydrodynamic Schrödinger equation,” *Physical Review Research*, vol. 5, no. 3, p. 033182, Sep. 2023. [Online]. Available: <https://doi.org/10.1103/PhysRevResearch.5.033182>



OPTIMIZACIÓN DE LA COMPUTACIÓN HUMANA MULTITUD CON IUI ADAPTABLES PARA OBTENER ESCALABILIDAD Y EXPLICACIÓN

OPTIMIZING CROWDSOURCED HUMAN COMPUTATION WITH ADAPTIVE INTELLIGENT USER INTERFACES FOR SCALABILITY AND EXPLAINABILITY

R. John Martin^{1,*} 

Recibido: 24-02-2025, Recibido tras revisión: 09-07-2025, Aceptado: 22-10-2025, Publicado: 01-01-2026

Resumen


Las interfaces de usuario inteligentes (IUI) representan un enfoque transformador para mejorar la computación colectiva y la computación humana, mediante la optimización en la distribución de tareas, el fortalecimiento de la colaboración entre humanos e inteligencia artificial (IA) y la garantía de la seguridad de los datos. Este estudio presenta un análisis basado en estudios de caso sobre una IUI adaptativa diseñada para mejorar la escalabilidad, el compromiso de los usuarios y la precisión en la resolución de problemas a gran escala mediante crowdsourcing. A través del examen de tres plataformas clave —Amazon Mechanical Turk (MTurk), Zooniverse (plataforma de ciencia ciudadana) y un análisis de imágenes médicas asistido por IA en el ámbito de la salud pública— se evalúa el impacto de la asignación dinámica de tareas, la inteligencia artificial explicable (XAI) y la gamificación sobre la participación de los usuarios y el rendimiento en las tareas. Los resultados indican que las IUI adaptativas mejoran la precisión de las tareas de acuerdo con el nivel de habilidad del usuario, reducen el tiempo de ejecución a medida que los participantes adquieren experiencia y aumentan la retención de voluntarios gracias a los mecanismos de gamificación. Asimismo, la integración de XAI en el diagnóstico médico asistido por IA incrementa de manera significativa tanto los niveles de confianza como la precisión diagnóstica. Estos hallazgos evidencian la escalabilidad, adaptabilidad y eficacia de las IUI en el campo de la computación humana, y ofrecen un marco de referencia para futuros avances en la optimización de tareas y la explicabilidad de los sistemas inteligentes.

Palabras clave: interfaces de usuario inteligentes (IUI), cómputo humano, interacción humano-computadora IHC, computación colaborativa, inteligencia artificial explicable (XAI), asignación adaptativa de tareas

Abstract

Intelligent User Interfaces (IUIs) represent a transformative paradigm for advancing crowdsourced and human computation by optimizing task distribution, strengthening human–AI collaboration, and ensuring data integrity. This study presents a case study–driven analysis of an adaptive IUI framework designed to enhance scalability, engagement, and accuracy in large-scale, crowd-based problem-solving. By examining three representative platforms—Amazon Mechanical Turk (MTurk), Zooniverse (a citizen science platform), and AI-assisted medical image analysis in public health—the research investigates the influence of dynamic task allocation, Explainable AI (XAI), and gamification on user participation and task performance. The findings demonstrate that adaptive IUIs improve task accuracy relative to user expertise, reduce completion time as experience increases, and strengthen volunteer retention through gamified elements. Moreover, integrating XAI into AI-assisted medical diagnostics substantially elevates both trust and diagnostic precision. Collectively, these outcomes underscore the scalability, adaptability, and efficacy of IUIs in human computation, offering a comprehensive framework for future advancements in task optimization and explainability.

Keywords: Intelligent User Interfaces (IUIs), Human Computation, Human–Computer Interaction (HCI), Crowd Computing, Explainable Artificial Intelligence (XAI), Adaptive Task Allocation

^{1,*}Facultad de Ingeniería y Ciencias Informáticas, Universidad de Jazan, Jazan, Arabia Saudita 
 Autor para correspondencia ✉: jmartin@jazanu.edu.sa.

1. Introducción

La computación colectiva y la computación humana se han convertido en componentes esenciales para la ejecución de tareas complejas y de gran escala que requieren inteligencia humana complementaria a la inteligencia artificial (IA). Entre estas actividades se incluyen el etiquetado de datos y la moderación de contenidos en plataformas como Amazon Mechanical Turk (MTurk). No obstante, estos sistemas enfrentan desafíos relacionados con la eficiencia operativa, la participación de los usuarios y la asignación equitativa de tareas.

Las interfaces de usuario inteligentes (Intelligent User Interfaces, IUI) abordan estas limitaciones mediante la incorporación de mecanismos adaptativos, como la retroalimentación en tiempo real, la asignación de tareas basada en la experiencia y la inteligencia artificial explicable (XAI) en plataformas de trabajo colaborativo [1]. Al personalizar la experiencia del usuario y optimizar los flujos de trabajo, las IUI mejoran la escalabilidad, incrementan el rendimiento de los usuarios y fomentan una colaboración más efectiva entre humanos e IA.

Una de las principales limitaciones de las plataformas de computación colectiva actuales radica en su enfoque estático y uniforme para la asignación de tareas, el cual no considera las diferencias individuales en habilidades y desempeño, lo que con frecuencia compromete la calidad de los resultados. Además, la interacción entre los usuarios humanos y los componentes de inteligencia artificial continúa siendo limitada, lo que conduce a resultados subóptimos en la ejecución de las tareas.

Las interfaces de usuario inteligentes (IUI) abordan estas deficiencias mediante el modelado de usuarios, el análisis del desempeño en tiempo real y la retroalimentación impulsada por IA, elementos que en conjunto permiten una asignación adaptativa de tareas y fomentan una colaboración más efectiva entre los sistemas humanos y los basados en IA [2].

Este artículo explora el potencial transformador de las IUI para mejorar la escalabilidad, la eficiencia y la calidad en la computación humana basada en multitudes, especialmente a medida que estas plataformas se aplican con mayor frecuencia a tareas complejas, como el entrenamiento de modelos de inteligencia artificial y la respuesta ante desastres.

A través de un análisis basado en estudios de caso, el artículo evalúa la viabilidad e impacto de las IUI adaptativas, sin implementación práctica del sistema, en cuatro dimensiones clave:

1. Distribución adaptativa de tareas.
2. Inteligencia artificial explicable en la computación humana.

3. Modelado de usuario.

4. Gamificación y medidas de seguridad.

Al examinar tanto plataformas de propósito general como entornos especializados, estos estudios de caso ofrecen una evaluación integral de cómo las IUI pueden fortalecer la colaboración entre humanos e IA en sistemas de computación colectiva.

Los principales objetivos de esta investigación son los siguientes:

1. Determinar la interacción entre el modelado de usuario, la gamificación y la distribución adaptativa de tareas en entornos de trabajo colaborativo a gran escala.
2. Examinar el impacto de la gamificación, la distribución adaptativa de tareas y el modelado de usuario en la participación de los usuarios y la finalización de tareas dentro de programas de ciencia ciudadana.
3. Evaluar cómo la inteligencia artificial explicable (XAI) contribuye a mejorar la participación y aumentar la confianza de los usuarios en dominios especializados, como el de la salud pública.

Se presentan tres estudios de caso que demuestran estos objetivos, tanto de forma independiente como de manera sinérgica, en contextos del mundo real, ofreciendo perspectivas valiosas sobre la escalabilidad, la eficiencia y la confiabilidad de los sistemas de computación humana.

Al centrarse en estos casos, el artículo ilustra el potencial teórico de las IUI para abordar los desafíos reales en la computación colectiva.

Los resultados obtenidos a partir de los estudios de caso establecen un marco de referencia para el desarrollo y la evaluación futuros de sistemas de computación humana impulsados por IUI, allanando el camino hacia la próxima generación de soluciones de computación colectiva [3].

El resto de este artículo se organiza de la siguiente manera: en la sección 1.1 revisa la literatura relevante, con énfasis en la distribución adaptativa de tareas, la inteligencia artificial explicable (XAI), el modelado de usuario, la gamificación y la seguridad en los sistemas de computación humana.

En la sección 2 describe las metodologías empleadas para explorar estos conceptos y su aplicación mediante estudios de caso.

La sección 2.5 presenta tres estudios de caso —Amazon Mechanical Turk (MTurk), Zooniverse y un proyecto de salud pública que incorpora XAI en diagnósticos médicos—, los cuales ilustran las aplicaciones prácticas de los métodos propuestos.

La sección 3 analiza los resultados obtenidos a partir de estos casos, destacando cómo las metodologías adaptativas contribuyen a mejorar la escalabilidad, la

participación y la confianza en los sistemas colaborativos.

Finalmente, la sección 4 concluye el artículo resumiendo los hallazgos principales y planteando las direcciones para futuras investigaciones.

1.1. Trabajos relacionados

Esta sección revisa el estado actual de la investigación sobre el uso de IUI orientadas a mejorar la escalabilidad, la colaboración y la participación de los usuarios en plataformas de computación humana y computación colectiva.

La discusión se centra en áreas clave, como la asignación dinámica de tareas, que optimiza la distribución de actividades en función del desempeño del usuario en tiempo real, y la XAI, que incrementa la transparencia y la confianza en la resolución de problemas asistida por IA.

Asimismo, se analiza el papel de la gamificación en la motivación de los usuarios, junto con la relevancia de la seguridad y la privacidad en estos entornos, y se examinan las formas en que las IUI adaptativas fortalecen la colaboración y la escalabilidad de los sistemas.

En conjunto, estos temas ofrecen una visión integral del panorama actual de la investigación y destacan oportunidades para el desarrollo de nuevas líneas de estudio en el ámbito de la computación colectiva impulsada por IA.

1.2. Asignación dinámica de tareas en la computación humana

Schmidbauer *et al.* [4] investigaron la asignación de tareas entre humanos y robots en entornos industriales, demostrando que la distribución adaptativa de tareas (ATS, por sus siglas en inglés), la cual permite a los trabajadores influir en la asignación de responsabilidades operativas, mejora los niveles de satisfacción entre los operadores.

Aunque este estudio destacó la relevancia de otorgar control a los participantes humanos, también identificó inconsistencias en los procesos de asignación de tareas, lo que evidencia la necesidad de una mejor alineación entre las preferencias humanas y los mecanismos automatizados de asignación.

En contraste, Wen *et al.* [5] propusieron un marco de asignación de tareas para redes de sensores inalámbricos (WSN) en entornos de computación perimetral, cuyo énfasis en la eficiencia energética y la confiabilidad mediante la ejecución paralela de tareas reveló el potencial del modelo para reducir significativamente el consumo de energía y el tiempo de ejecución.

Sin embargo, se identificaron limitaciones relacionadas con la tolerancia a fallos y las condiciones

dinámicas de la red, lo que sugiere que se requiere investigación adicional para mejorar la robustez general del sistema.

Faccio *et al.* [6] ampliaron la investigación sobre la asignación de tareas al ámbito de la robótica colaborativa, al introducir un modelo adaptativo que ajusta la velocidad del robot en función de la distancia entre el robot y el operador humano, con el propósito de equilibrar la productividad y la seguridad. Sus hallazgos demostraron mejoras significativas en el rendimiento, aunque también revelaron compensaciones inherentes, particularmente la dificultad de mantener la seguridad sin comprometer la productividad. Estos resultados subrayan la necesidad de mecanismos de adaptabilidad en tiempo real en entornos de trabajo dinámicos.

Yuan *et al.* [7] propusieron un marco de asignación adaptativa de tareas (ATA-HRL) para equipos compuestos por múltiples humanos y múltiples robots (MH-MR), empleando aprendizaje por refuerzo jerárquico para mejorar la adaptabilidad de las tareas. Su enfoque de dos etapas, que comprende la asignación inicial de tareas (ITA) y la reasignación condicional de tareas (CTR), resultó eficaz; no obstante, el estudio destacó la importancia crítica de realizar asignaciones iniciales precisas, especialmente en entornos caracterizados por alta incertidumbre.

De manera similar, Tamali *et al.* [8] investigaron la asignación distribuida de tareas en sistemas multi robot, utilizando un algoritmo voraz para optimizar la distribución de tareas en entornos complejos. Su enfoque, basado en simulaciones e implementado mediante el sistema operativo de robots (ROS), demostró mejoras notables en la eficiencia de finalización de tareas; sin embargo, se identificaron la escalabilidad y las limitaciones de comunicación en escenarios del mundo real como desafíos clave para futuras investigaciones.

1.3. Inteligencia artificial explicable en la resolución de problemas mediante trabajo colaborativo

Los estudios revisados presentan un conjunto diverso de enfoques y perspectivas sobre la evaluación colaborativa y la XAI, destacando la participación activa de los usuarios y la mejora en la calidad de las explicaciones mediante técnicas de trabajo colaborativo y mecanismos de entrada selectiva.

A pesar de sus diferentes objetivos, estos trabajos comparten un énfasis común en aprovechar la retroalimentación humana para mejorar la interpretabilidad y aumentar la precisión de los modelos de inteligencia artificial, consolidando así la sinergia entre el juicio y los sistemas automatizados de aprendizaje.

Tanto Jain *et al.* [9] como Kou *et al.* [10], [11] emplearon el trabajo colaborativo para mejorar las explicaciones de la inteligencia artificial, aunque sus enfoques difirieron en alcance y aplicación.

Jain *et al.* [9] se centraron en evaluar las técnicas de XAI mediante un “juego con propósito” (GWAP), que permitió a los usuarios clasificar métodos como LIME y Grad-CAM en función de su nivel de interpretabilidad. Esta estrategia basada en el juego identificó a Grad-CAM como el método de XAI más efectivo para la clasificación de imágenes.

En contraste, Kou *et al.* [10] desarrollaron Crowd Graph, un marco de conocimiento multimodal diseñado para detectar y explicar las fauxtografías en publicaciones de redes sociales, mediante la integración de datos textuales y visuales.

Ambos estudios aprovecharon el potencial de la participación colectiva para generar retroalimentación significativa y mejorar el rendimiento de los sistemas IA. Sin embargo, una limitación crítica en ambos enfoques radica en la fiabilidad de los datos generados mediante crowdsourcing, lo que pone de relieve la necesidad de mecanismos más robustos para verificar y mantener la calidad de los datos.

Kou *et al.* [11] examinaron además el trabajo colaborativo mediante el marco HC-COVID, orientado a la detección y explicación de la desinformación relacionada con la COVID-19. El diseño jerárquico de HC-COVID, que integra contribuciones tanto de trabajadores expertos como no expertos, constituye una extensión de su investigación previa.

Este enfoque multinivel mejoró de manera significativa la precisión en la detección de desinformación y la calidad de las explicaciones generadas. Sin embargo, al igual que otros modelos basados en crowdsourcing, enfrenta el desafío persistente del sesgo y la inconsistencia en los datos aportados por participantes no expertos, lo que resalta la necesidad de marcos más estructurados que garanticen la fiabilidad y la precisión de los resultados.

Sawant *et al.* [12] y Lai *et al.* [13] abordaron el sesgo y la subjetividad en las explicaciones de la inteligencia artificial, especialmente en dominios socialmente sensibles, como la detección de discurso de odio y el comportamiento comunicativo de los usuarios.

Sawant *et al.* [12] emplearon una clasificación basada en XAI mediante TabNet, con el propósito de identificar discursos de odio en lenguas con recursos limitados, incluido el hindi, y demostraron cómo los contextos sociopolíticos pueden introducir sesgos en las anotaciones humanas.

En comparación, Lai *et al.* [13] desarrollaron un marco de explicación selectiva que adapta las explicaciones generadas por la IA a las preferencias del usuario, considerando factores como la relevancia y la anormalidad, lo que permite interacciones más sensibles al contexto.

Ambos estudios enfatizan la importancia de alinear las salidas de la IA con la interpretación humana para reducir el sesgo y mejorar la precisión. Sin embargo, mientras que Sawant *et al.* [12] demostraron que

los contextos sociopolíticos influyen significativamente en el sesgo de los sistemas de IA, Lai *et al.* [13] se centraron en mitigar la carga cognitiva y los sesgos del usuario mediante mecanismos de entrada selectiva, destacando el delicado equilibrio entre la participación humana y la autonomía de la IA.

Una comparación crítica entre estos estudios revela que, si bien el trabajo colaborativo (crowdsourcing) constituye un enfoque eficaz para mejorar las explicaciones de la inteligencia artificial, también introduce desafíos significativos relacionados con la calidad de los datos y el control del sesgo.

Por ejemplo, la dependencia de los datos generados mediante crowdsourcing en Jain *et al.* [9] y Kou *et al.* [10], [11] demuestra que, aunque estos métodos pueden incrementar el rendimiento del sistema, implican de forma inherente el riesgo de inconsistencias en la calidad del contenido generado por humanos.

De manera similar, Sawant *et al.* [12] y Lai *et al.* [13] resaltaron la vulnerabilidad de los modelos de IA que dependen de anotaciones humanas frente a diversas formas de sesgo, en particular en dominios caracterizados por sensibilidades sociopolíticas o alta subjetividad.

A pesar de estas limitaciones, todos los estudios coinciden en que los marcos adaptativos y selectivos —ya sean modelos jerárquicos como HC-COVID, evaluaciones basadas en juegos como Eye into AI o técnicas de explicación selectiva— representan una dirección prometedora hacia sistemas de IA más transparentes, interpretables y centrados en el usuario.

1.4. Gamificación para mejorar la participación del usuario

Los estudios revisados sobre gamificación en diversos contextos —desde la promoción de la salud hasta la formación de empleados y la educación formal— evidencian un enfoque común orientado a la participación activa del usuario, aplicando diferentes elementos de juego para influir en el comportamiento, incrementar la motivación y mejorar los resultados en distintos entornos de aplicación. A pesar de las similitudes en sus objetivos, estos trabajos divergen en sus metodologías y destacan desafíos específicos relacionados con el mantenimiento del compromiso a largo plazo.

Zhang *et al.* [14] y Hellín *et al.* [15] examinaron la gamificación como estrategia para el cambio de comportamiento en los ámbitos de la salud y la educación, respectivamente.

Zhang *et al.* [14] desarrollaron DMCoach+, un sistema gamificado diseñado para promover estilos de vida saludables mediante una estructura de dos niveles que integra metas personales y competencia social. En contraste, Hellín *et al.* crearon un entorno de aprendizaje gamificado que incorpora puntos, tablas de clasificación y medallas para incrementar la motivación de

los estudiantes en cursos de programación.

Ambos estudios demostraron que la gamificación puede mejorar significativamente la participación; aunque también identificaron limitaciones críticas. Zhang *et al.* [14] observaron que la comunicación unidireccional con los médicos limitó el compromiso sostenido de los usuarios, mientras que Hellín *et al.* [15] señalaron que los estudiantes con clasificaciones más bajas podían desmotivarse por el efecto de las tablas de posiciones.

Estos hallazgos sugieren que equilibrar la competencia y la interacción personalizada es fundamental para mantener la participación a largo plazo, tanto en contextos de salud como educativos.

Lu *et al.* [16] y Bitrián *et al.* [17] investigaron el papel de la gamificación en contextos comerciales, centrándose en la participación del usuario con marcas y aplicaciones móviles.

Lu *et al.* [16] integraron el marco mecánicas-dinámicas-estética (MDA) en la aplicación Nike Run Club (NRC), destacando que el disfrute fue el factor más significativo para impulsar la participación del usuario y la lealtad hacia la marca.

En contraste, Bitrián *et al.* examinaron cómo los elementos del diseño de juegos satisfacen las necesidades psicológicas de los usuarios, encontrando que los componentes orientados al logro y a la interacción social aumentaron la participación al satisfacer las necesidades de competencia, autonomía y relación.

Ambos estudios demostraron que la gamificación incrementa la participación del usuario, aunque también resaltaron la importancia de equilibrar la diversión y la personalización para mantener el interés a largo plazo.

Finalmente, Alfaqiri *et al.* [18] desarrollaron un marco de gamificación para plataformas de capacitación en línea, con un enfoque en la participación de los empleados. La integración de múltiples elementos de juego, como puntos, desafíos y tablas de clasificación, reflejó técnicas utilizadas en contextos educativos y comerciales.

De manera similar a lo encontrado por Bitrián *et al.* [17], Alfaqiri *et al.* [18] encontraron que estos elementos incrementaron de manera efectiva la participación; sin embargo, también señalaron que el efecto de novedad tiende a disminuir con el tiempo, lo que coincide con las preocupaciones planteadas en otros estudios respecto a la sostenibilidad a largo plazo de los sistemas gamificados.

1.5. Preocupaciones de seguridad y privacidad en las plataformas de computación colectiva

Owoh y Singh [19] desarrollaron SenseCrypt, un marco destinado a aplicaciones de detección colectiva móvil (MCS), que integra un algoritmo K-means con un esquema de firmado y cifrado agregado sin certificados

(CLASC) para gestionar el etiquetado de datos sensibles y garantizar una transmisión segura.

Este enfoque redujo los costos computacionales y la sobrecarga de comunicación, logrando que el marco fuera robusto frente a múltiples vectores de ataque, incluidos los ataques de repetición y falsificación.

No obstante, la adaptabilidad del marco a casos de uso más amplios continúa siendo limitada, lo que indica la necesidad de investigaciones adicionales orientadas a mejorar su escalabilidad y viabilidad de implementación práctica.

En contraste, Li *et al.* [20] propusieron CrowdSFL, un marco que integra la tecnología blockchain con el aprendizaje federado para proteger los datos de manera descentralizada. Este diseño mantiene la privacidad al conservar los datos de forma local, mientras utiliza contratos inteligentes para habilitar una comunicación segura entre nodos.

El aprendizaje federado redujo significativamente los riesgos de privacidad al evitar la centralización de información sensible, diferenciando este enfoque del método basado en cifrado y firmado (signcryption) empleado en SenseCrypt. Además, la integración de un algoritmo de recifrado basado en ElGamal en CrowdSFL añadió una capa adicional de seguridad.

Aunque los resultados demostraron mejoras en precisión, seguridad y eficiencia computacional, la complejidad del sistema y la sobrecarga de comunicación asociadas con las arquitecturas blockchain fueron identificadas como desafíos clave.

En comparación, ambos marcos ofrecen mecanismos de seguridad robustos para la protección de datos sensibles en entornos de trabajo colaborativo (crowdsourcing). Sin embargo, SenseCrypt se enfoca principalmente en un esquema eficiente de cifrado y firmado (signcryption) para datos de sensores móviles, mientras que CrowdSFL prioriza la preservación de la privacidad de forma descentralizada, mediante blockchain y aprendizaje federado.

Las sobrecargas de comunicación observadas en el estudio de Li *et al.* [20] contrastan con la eficiencia computacional demostrada por Owoh y Singh [19], lo que evidencia la compensación inherente entre descentralización y complejidad del sistema.

A pesar de estas diferencias, ambos estudios subrayan la necesidad continua de soluciones adaptables y escalables que garanticen la seguridad y la privacidad de los datos en sistemas distribuidos basados en crowdsourcing.

1.6. IUI adaptativa para mejorar la colaboración y la escalabilidad en el trabajo colaborativo (crowdwork)

Los estudios revisados presentan diversos enfoques para mejorar la colaboración y la escalabilidad en sistemas humano-IA, mediante el uso de marcos adap-

tativos que integran dinámicamente la intervención humana, los procesos IA y las contribuciones del crowdsourcing. Aunque cada sistema aplica estos principios de manera particular, todos comparten el objetivo de mejorar la eficiencia y la calidad colaborativa dentro de contextos de alta complejidad.

En este marco, Siangliulue *et al.* [21] desarrollaron IDEAHOUND, un sistema orientado a la ideación colaborativa a gran escala, basado en modelado semántico en tiempo real. Al capturar las interacciones de los usuarios en una pizarra virtual, el sistema genera dinámicamente sugerencias diversas y creativas, fomentando la diversidad de ideas y la participación activa de los colaboradores.

No obstante, la dependencia del sistema de los agrupamientos generados por los usuarios, que en ocasiones carecen de coherencia o claridad semántica, pone de relieve el desafío de aprovechar plenamente los juicios semánticos colectivos generados mediante crowdsourcing.

En contraste, Abbas *et al.* [22] desarrollaron Crowd of Oz (CoZ), un sistema conversacional de IA en tiempo real que integra crowdsourcing sincrónico para gestionar diálogos sociales complejos, especialmente en el ámbito del apoyo a la salud mental.

A diferencia de IDEAHOUND [21], CoZ pone un énfasis particular en la comunicación afectiva durante las interacciones en tiempo real. Aunque el sistema mejora de manera efectiva la calidad de las conversaciones, enfrenta desafíos asociados con la retención continua de los trabajadores y la garantía de respuestas de alta calidad, lo que subraya la necesidad de una mayor capacitación y del desarrollo de competencias comunicativas y empáticas entre los colaboradores de la multitud.

Por su parte, Ponti y Seredko [23] también analizaron la colaboración humano-IA, centrándose en el contexto de la ciencia ciudadana. Su marco de asignación de tareas delegó actividades simples, como la recolección de datos, a los participantes ciudadanos, mientras que los sistemas de IA y los expertos del dominio asumieron los procesos más complejos, como el análisis de información.

El estudio destaca que el aumento de las capacidades de la IA puede marginar inadvertidamente a los voluntarios, lo que genera preocupaciones sobre la sostenibilidad de su compromiso y participación a largo plazo. Este desafío también fue identificado por Siangliulue *et al.* [21] en IDEAHOUND, en relación con la agrupación de ideas generadas por los usuarios, lo que refuerza la importancia de diseñar mecanismos de colaboración equilibrados entre la IA y los participantes humanos.

Basándose en el enfoque de los sistemas centrados en el ciudadano, Stein y Yazdanpanah [24] introdujeron C-MAS, un sistema multiagente diseñado para otorgar a los ciudadanos un mayor control en los pro-

cesos de toma de decisiones dentro de los dominios de movilidad y energía inteligentes.

Al igual que CoZ [22], C-MAS pone un fuerte énfasis en la privacidad, la equidad y la transparencia, pero amplía estos principios al permitir la participación activa de los ciudadanos en la configuración de decisiones mediante el uso de agentes inteligentes personales.

No obstante, el desafío de la confianza, especialmente en lo relativo a la protección de la privacidad y a la toma de decisiones éticamente responsables, permanece como un problema central, reflejando la misma necesidad de fiabilidad y transparencia observada en el modelo de comunicación afectiva de CoZ.

Por último, Gupta *et al.* [25] desarrollaron COHUMAN, un marco diseñado para fomentar la inteligencia colectiva en equipos humano-IA mediante una arquitectura sociocognitiva. Al compartir recursos cognitivos a través de sistemas de memoria y atención transaccional, COHUMAN busca mejorar la toma de decisiones colaborativa y aumentar la escalabilidad, en paralelo con la ideación colaborativa facilitada por IDEAHOUND [21].

Sin embargo, Gupta *et al.* identificaron un desafío persistente en el mantenimiento de la confianza a largo plazo entre los colaboradores humanos y los sistemas de IA, un problema también observado por Stein y Yazdanpanah [24] en el contexto de la confianza entre ciudadanos y agentes inteligentes.

Si bien cada uno de estos marcos logra avanzar en la colaboración adaptable y la escalabilidad en diferentes dominios de aplicación, todos comparten desafíos comunes relacionados con la confianza, la retención de participantes y la calidad de los resultados colaborativos. Estos obstáculos recurrentes subrayan la necesidad continua de perfeccionamiento en la formación de los participantes, la asignación dinámica de tareas y la integración humano-IA, a fin de construir sistemas impulsados por multitudes que sean verdaderamente escalables, fiables y eficaces.

2. Materiales y métodos

Esta sección presenta un marco teórico y evaluativo para analizar la eficacia de las interfaces de usuario inteligentes (IUI) adaptativas en sistemas de computación humana escalables. El enfoque se fundamenta en principios consolidados de interfaces adaptativas de bucle cerrado, en las cuales el comportamiento de la interfaz se ajusta continuamente al contexto del usuario y a sus preferencias en evolución.

En este modelo dinámico de retroalimentación, las acciones del usuario generan señales que informan las políticas adaptativas de la IUI, modulando componentes tales como la distribución de tareas, la personalización, la gamificación y la explicabilidad. Este enfoque es coherente con los marcos empleados en los

sistemas producto-servicio inteligentes impulsados por IA (SPSS) [26].

Al sincronizar el comportamiento del usuario con las respuestas de la interfaz en tiempo real, este marco proporciona una base teórica robusta para la distribución adaptativa de tareas y el modelado del usuario, elementos esenciales para la optimización de la colaboración humano-IA en entornos de crowdsourcing.

Esta investigación emplea un diseño de estudio de caso mixto, que integra marcos teóricos —como la teoría de la actividad, el modelo de aceptación tecnológica y los principios de interfaces de usuario adaptativas— con datos empíricos cuantitativos recopilados de Amazon Mechanical Turk (MTurk), Zooniverse y un entorno clínico basado en inteligencia artificial explicable (XAI).

En lugar de realizar ensayos controlados aleatorizados, el estudio recopiló métricas cuantitativas piloto y las analizó utilizando la metodología de estudio de caso TRIPLE C [27]. Los indicadores de desempeño incluyeron la precisión de las tareas, el tiempo de finalización, las tasas de error, la retención de voluntarios, la precisión diagnóstica y la confianza del clínico, cada uno respaldado por pruebas estadísticas apropiadas para sustentar la validez de los resultados.

La Figura 1 ilustra las capas fundamentales involucradas en la optimización de los entornos de computación humana. El diagrama comprende tres capas principales:

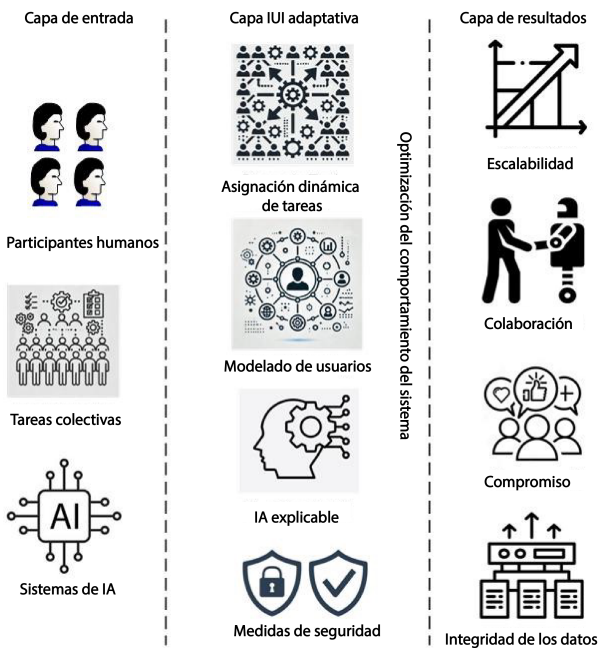


Figura 1. Marco conceptual de la IUI adaptativa para la computación humana escalable.

1. Capa de entrada, compuesta por participantes humanos, tareas colaborativas y sistemas de IA.

2. Capa de IUI adaptativa, que incluye módulos como asignación dinámica de tareas, modelado de usuario, IA explicable, gamificación y medidas de seguridad.
3. Capa de resultados, que representa los parámetros de salida, incluyendo escalabilidad, colaboración, compromiso e integridad de los datos.

El flujo de tareas y datos se origina en la capa de entrada, donde los participantes humanos y los sistemas de IA interactúan con las tareas asignadas; progresa a través de la capa de IUI adaptativa, donde se procesan y optimizan los parámetros de interacción, y culmina en un mejor rendimiento del sistema dentro de la capa de resultados. Este marco demuestra cómo las IUI adaptativas pueden aprovecharse para mejorar la colaboración y la escalabilidad en entornos de crowdsourcing.

Desde la perspectiva de la teoría de la actividad, un marco interpretativo ampliamente utilizado en la investigación de estudios de caso, el operador (sujeto) interactúa con las tareas (objeto) a través de la IUI (herramienta). La interfaz adaptativa media esta interacción mediante bucles de retroalimentación en tiempo real, lo que mejora el desempeño de las tareas y la eficiencia general del sistema [28].

2.1. Distribución de tareas adaptativas

Desde la perspectiva de la teoría de la actividad, el operador interactúa con la interfaz para alcanzar objetivos específicos, siendo la IUI la que media dinámicamente esta relación mediante retroalimentación en tiempo real.

La distribución adaptativa de tareas mejora la eficiencia de la computación humana en entornos de crowdsourcing al asignar tareas de acuerdo con las habilidades, el desempeño y la experiencia del usuario. La Figura 2 ilustra este modelo: las tareas del conjunto se asignan mediante un sistema de IA que aprovecha la retroalimentación en tiempo real para optimizar las asignaciones futuras.

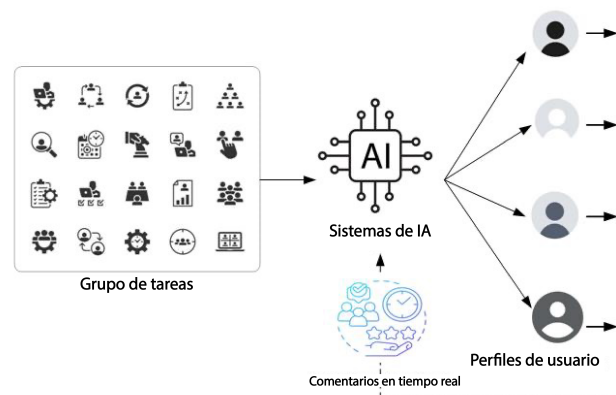


Figura 2. Distribución adaptativa de tareas.

Enfoques comparables han demostrado su efectividad en la colaboración humano-robot, como el marco de compartición adaptativa de tareas de Schmidbauer *et al.* [29], basado en las capacidades y preferencias del usuario. De manera similar, en los sistemas de aprendizaje adaptativo, la resignación dinámica de tareas mejora el rendimiento en función de los resultados previos [30].

Este modelo teórico se examina a través de estudios de caso en dominios como la respuesta a desastres, el etiquetado de datos y la planificación urbana, con el objetivo de evaluar la escalabilidad, la practicidad y el desempeño en la computación humana a gran escala.

2.2. Inteligencia artificial explicable en la computación humana

Las estrategias de inteligencia artificial explicable (XAI) y gamificación, integradas en este marco, se sustentan en el modelo de aceptación tecnológica (TAM), el cual postula que una mayor percepción de utilidad y transparencia incrementa de manera directa la confianza del usuario y la adopción tecnológica [31].

La XAI contribuye a mejorar la confianza, el compromiso y la eficiencia en tareas colaborativas, al proporcionar transparencia sobre los procesos de decisión de la IA frente a los participantes humanos. Modelos de XAI ampliamente adoptados, como LIME y Grad-

CAM, incrementan la interpretabilidad de los sistemas: LIME descompone la contribución de características individuales de entrada a una decisión, mientras que Grad-CAM resalta las regiones de la imagen más influyentes dentro de redes neuronales convolucionales (CNN) [32,33]. En conjunto, estas herramientas ayudan a los usuarios a comprender la justificación detrás de los resultados de la IA, fomentando la responsabilidad y la participación informada.

En el trabajo colaborativo práctico, como el etiquetado de datos, el análisis de información y las iniciativas de salud pública, la XAI permite a los participantes validar los resultados generados por la IA e identificar posibles sesgos. Por ejemplo, los colaboradores en plataformas de etiquetado pueden utilizar las explicaciones de LIME para evaluar y corregir las predicciones del modelo, mientras que los clínicos que emplean visualizaciones de Grad-CAM pueden identificar las regiones de las imágenes médicas que influyeron en los diagnósticos automatizados, mejorando la precisión diagnóstica colaborativa y la confianza [34].

Al incorporar la XAI en estudios de caso de diferentes dominios, esta investigación evalúa su impacto en la confianza del usuario, el desempeño de las tareas y el compromiso, trascendiendo las ventajas teóricas para demostrar su aplicabilidad práctica en entornos reales de computación humana, ver la Figura 3.

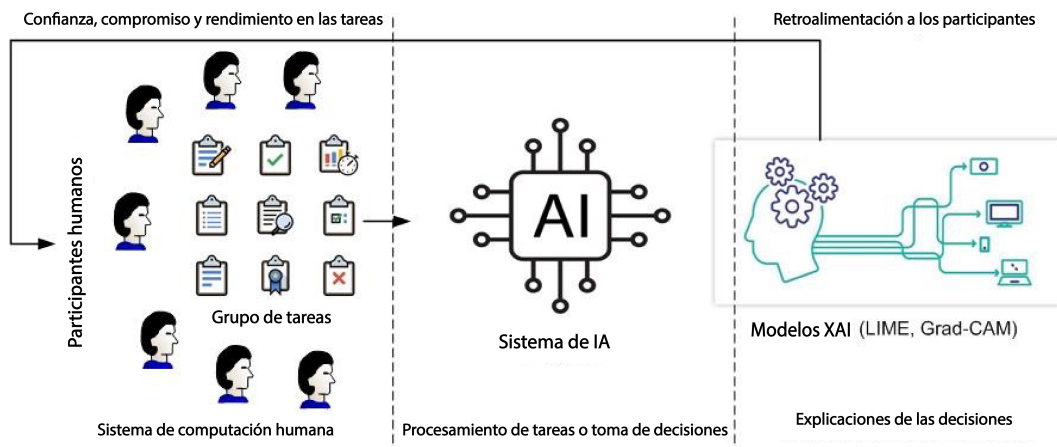


Figura 3. Modelo hipotético de inteligencia artificial explicable en la computación humana.

2.3. Modelado de usuario y asignación dinámica de tareas

El modelado de usuario construye una representación computacional de las preferencias, la experiencia y el comportamiento individual, lo que permite a los sistemas de trabajo colaborativo —por ejemplo, MTurk, Zooniverse— asignar tareas de forma dinámica según el conjunto de habilidades y desempeño de cada participante.

Técnicas como el filtrado colaborativo, que empareja a los usuarios con tareas basándose en patrones de comportamiento compartido, mejoran la eficiencia y la precisión en la asignación. Por ejemplo, los usuarios que muestran un rendimiento destacado en categorías específicas de etiquetado pueden reasignarse automáticamente a tareas de características similares [35].

El aprendizaje por refuerzo refina este proceso al ajustar las asignaciones en tiempo real de acuerdo con la retroalimentación del desempeño, particularmente

en entornos gamificados, donde el sistema aprende las fortalezas y preferencias de los usuarios y optimiza la distribución de tareas [36].

Estas técnicas de modelado fortalecen la personalización y adaptabilidad del sistema, al tiempo que reducen la redundancia de tareas. La asignación personalizada incrementa la participación del usuario al alinear las tareas con sus capacidades individuales, mientras que la reasignación dinámica de tareas complejas favorece la motivación y la productividad [37].

Asimismo, al evitar asignaciones repetitivas, el modelado de usuario previene el aburrimiento y la desconexión, contribuyendo a una colaboración más sostenida y eficiente. Este estudio evalúa estos efectos mediante estudios de caso en plataformas reales como MTurk y Zooniverse, demostrando cómo el filtrado colaborativo y el aprendizaje por refuerzo mejoran la escalabilidad y la efectividad en los sistemas de computación humana [38].

2.4. Gamificación y medidas de seguridad

La gamificación, entendida como el uso de elementos propios del diseño de juegos —por ejemplo, tablas de clasificación, puntos e insignias de recompensas— para incrementar la motivación en contextos no lúdicos, ha demostrado ser altamente efectiva en plataformas de computación humana. Al fomentar tanto la motivación intrínseca como la extrínseca, la gamificación aumenta la retención de participantes y mejora el desempeño en las tareas [39].

Por ejemplo, las plataformas que otorgan insignias de logro y muestran clasificaciones de usuarios suelen reportar niveles más altos de participación y tasas superiores de finalización de tareas [40].

Sin embargo, el incremento de la participación por sí solo no resulta suficiente; los sistemas basados en crowdsourcing deben también abordar los riesgos de seguridad inherentes. Amenazas como las violaciones de datos, la manipulación de tareas y el fraude pueden comprometer tanto la integridad de los datos como la confianza del usuario.

Para mitigar estas vulnerabilidades, son esenciales medidas de seguridad robustas, que incluyan cifrado avanzado, protocolos de autenticación, el uso de Certificateless Aggregate Signcryption (CLASC) y marcos de seguridad basados en blockchain [41].

Cuando se integran de manera efectiva, una gamificación bien diseñada junto con arquitecturas de seguridad sólidas permite que las plataformas colaborativas escalen de forma eficiente, preservando la confianza, la participación sostenida y la protección integral de los datos.

2.5. Estudios de caso

Estudio de caso 1: Amazon Mechanical Turk (MTurk)

Amazon Mechanical Turk (MTurk) es una de las principales plataformas de crowdsourcing de microtareas, que permite a empresas, investigadores y organizaciones asignar tareas de inteligencia humana (HIT) —operaciones de pequeña escala que requieren juicio humano— a una fuerza laboral global distribuida.

Estas tareas, que abarcan desde el etiquetado de datos y la clasificación de imágenes hasta la participación en encuestas, hacen de MTurk una plataforma idónea para evaluar la distribución adaptativa de tareas, el modelado de usuario y la gamificación.

Gracias a su amplia base de usuarios y a sus mecanismos flexibles de asignación de tareas, MTurk ofrece un entorno experimental práctico para analizar cómo las metodologías adaptativas pueden mejorar la eficiencia, incrementar la participación y optimizar la asignación dinámica de tareas en sistemas de computación humana.

- **Distribución adaptativa de tareas:** MTurk asigna tareas de manera dinámica en función de la experiencia del usuario, el nivel de habilidad y el desempeño histórico, asegurando que las tareas más simples se asignen a trabajadores nuevos, mientras que las tareas más complejas se reservan para usuarios experimentados. Este bucle de retroalimentación en tiempo real optimiza la eficiencia operativa y reduce las tasas de error, al ajustar continuamente los criterios de asignación en función del desempeño individual.
- **Modelado de usuario:** Al recopilar métricas de desempeño —como la precisión, la velocidad de ejecución y el historial de finalización de tareas—, la plataforma personaliza la asignación según las fortalezas individuales de cada colaborador. Este enfoque adaptativo garantiza una mayor correspondencia entre tarea y trabajador, al tiempo que fomenta una experiencia de usuario más motivante y atractiva, contribuyendo a la retención y al compromiso sostenido dentro del ecosistema de crowdsourcing.
- **Gamificación:** Aunque MTurk carece de mecanismos de gamificación integrados, la incorporación de elementos lúdicos —como tablas de clasificación, insignias de logro y sistemas de recompensas— puede mejorar significativamente la participación y la retención de los trabajadores. Estos componentes incrementan la motivación tanto intrínseca como extrínseca, al estimular la competencia sana y reconocer el rendimiento individual, lo que fomenta una mayor frecuencia de

contribución y fortalece el compromiso sostenido de los participantes dentro de la plataforma.

Estudio de caso 2: Zooniverse

Zooniverse, la plataforma de ciencia ciudadana más grande del mundo, permite a los participantes contribuir a una amplia variedad de proyectos de investigación mediante la clasificación de datos, el análisis de imágenes y la transcripción de textos históricos.

Como plataforma de computación humana basada en crowdsourcing, Zooniverse depende de la participación pública activa, lo que la convierte en un entorno idóneo para explorar la distribución adaptativa de tareas, el modelado de usuario y la gamificación, con el fin de optimizar la participación, la eficiencia de las tareas y la escalabilidad del sistema.

- **Distribución adaptativa de tareas:** Las tareas se asignan en función de la productividad y la experiencia del usuario. Los participantes experimentados se encargan de análisis más complejos, lo que mejora la precisión de las tareas y la eficiencia global del proceso, mientras que los nuevos voluntarios comienzan con clasificaciones más simples. Este enfoque adaptativo garantiza una curva de aprendizaje gradual y reduce la tasa de errores, manteniendo la calidad de los datos generados colectivamente.
- **Modelado de usuario:** Mediante el seguimiento continuo del comportamiento y desempeño de los participantes, la plataforma asigna tareas acordes con las habilidades y la experiencia de cada usuario. La asignación de proyectos similares a aquellos en los que el participante ha demostrado un rendimiento destacado aumenta la precisión y fomenta un mayor compromiso, fortaleciendo el vínculo entre competencia, satisfacción y participación sostenida dentro de la comunidad científica virtual.
- **Gamificación:** Elementos como los hitos del proyecto, el seguimiento del progreso y las insignias de logro estimulan la participación constante de los usuarios, al tiempo que fomentan un fuerte sentido de comunidad y reconocimiento colectivo dentro de la plataforma.

Estudio de caso 3: Salud pública

En el sector de salud, los modelos de IA se utilizan cada vez más para el apoyo diagnóstico, el modelado predictivo y el análisis automatizado de imágenes médicas. Aunque estos modelos logran altos niveles de precisión en la detección de enfermedades, su falta de transparencia genera preocupaciones sobre la confianza y la interpretabilidad.

La inteligencia artificial explicable (XAI) aborda este desafío al hacer comprensibles los procesos de decisión de la IA, permitiendo a los profesionales de la salud validar las predicciones y colaborar de manera más efectiva con los sistemas automatizados.

Este estudio de caso examina cómo LIME (Local Interpretable Model-agnostic Explanations) y Grad-CAM (Gradient-weighted Class Activation Mapping) aumentan la confianza y la transparencia en el análisis de imágenes médicas asistido por IA.

- **LIME:** Al perturbar los datos de entrada y analizar las variaciones en las predicciones del modelo, LIME genera explicaciones interpretables del comportamiento de la IA. En el contexto de las imágenes médicas, esta técnica aclara por qué el sistema de IA etiqueta una región específica de una resonancia magnética o radiografía como anómala o patológica, permitiendo a los médicos comprender y validar el razonamiento subyacente del modelo.
- **Grad-CAM:** Esta técnica produce mapas de calor que ilustran las regiones de las imágenes médicas que influyen directamente en las predicciones del modelo de IA. Esta técnica resulta particularmente útil en el diagnóstico de enfermedades oncológicas, ya que resalta visualmente las áreas relevantes que guiaron la toma de decisiones de la IA, aumentando la interpretabilidad y fortaleciendo la confianza clínica en los sistemas automatizados de apoyo diagnóstico.

3. Resultados y discusión

La evaluación se desarrolla conforme a los principios de reporte TRIPLE C (Context, Case, Complexity), un marco reconocido para la evaluación sistemática de estudios de caso que abarca el contexto, los métodos y la complejidad [27, 42]. Este enfoque garantiza el rigor científico mediante la triangulación de datos cuantitativos y cualitativos a través de métricas de desempeño verificables.

Cada estudio de caso establece objetivos de evaluación definidos y mide los resultados utilizando indicadores cuantitativos como la precisión de las tareas, el tiempo de finalización, la tasa de error, la retención de voluntarios, la precisión diagnóstica y las puntuaciones de confianza.

Este enfoque estructurado y basado en datos incrementa la objetividad del análisis y sustenta los hallazgos empíricos dentro de un protocolo de evaluación claramente definido, asegurando la consistencia y comparabilidad entre los distintos casos analizados.

La Figura 4 ilustra el desempeño en la finalización de tareas dentro de la plataforma de crowdsourcing

Amazon Mechanical Turk (MTurk). El sistema de asignación adaptativa de tareas implementado en MTurk mejora significativamente la eficiencia operativa, al asignar tareas complejas a trabajadores experimentados, lo que se traduce en mayor precisión y reducción de los tiempos de finalización. El modelado de usuario personalizado incrementa la participación al adaptar la distribución de tareas según las fortalezas individuales, lo que reduce la redundancia, minimiza

los desajustes de habilidades y optimiza la asignación dinámica. Aunque la gamificación no constituye aún una característica central de MTurk, estudios previos sugieren que la integración de incentivos competitivos y basados en recompensas podría aumentar la participación y la retención de trabajadores, especialmente en tareas repetitivas o de baja complejidad, reforzando la motivación sostenida y la calidad del desempeño colaborativo.

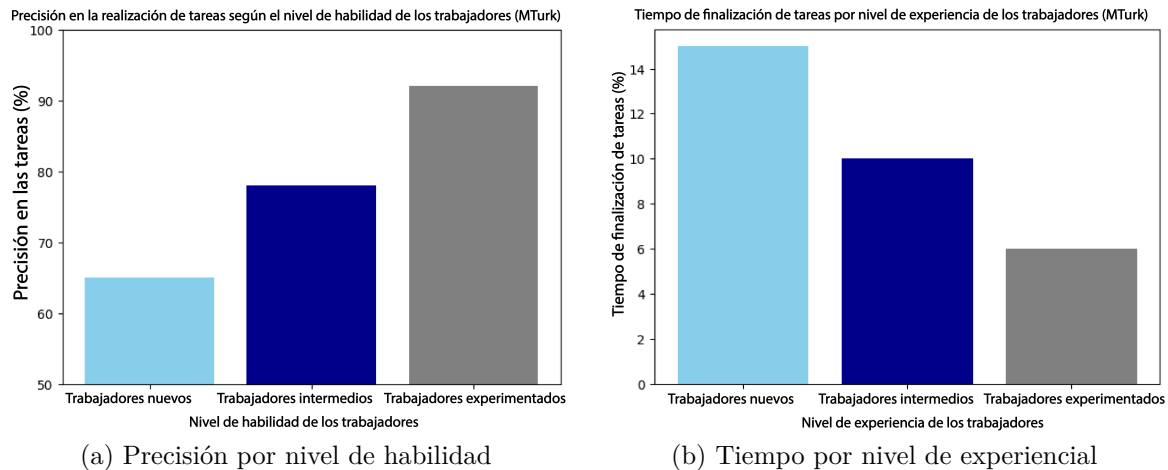


Figura 4. Desempeño en la finalización de tareas de MTurk.

Este estudio de caso demuestra cómo los enfoques adaptativos mejoran la escalabilidad, la efectividad y la participación de los usuarios en plataformas basadas en crowdsourcing. La asignación dinámica de tareas y el modelado de usuario personalizado optimizan los resultados al incrementar la utilización eficiente de los recursos humanos y computacionales.



Aunque los elementos de gamificación aún no están plenamente integrados en la estructura de MTurk, su arquitectura modular lo posiciona como un candidato sólido para futuras implementaciones. Investigaciones posteriores deberían explorar la incorporación de mecanismos gamificados y el perfeccionamiento de las técnicas de perfilado de usuario, con el propósito de maximizar la eficiencia, fomentar la motivación y mantener la participación sostenida en entornos colaborativos a gran escala.

La implementación de la distribución adaptativa de tareas reduce las tasas de error al alinear las ta-

reas con la experiencia y las competencias específicas de los usuarios. El modelado de usuario fortalece la participación al adaptar la asignación de tareas a las fortalezas individuales, lo que aumenta la retención y la satisfacción de los colaboradores.

De igual manera, la gamificación incrementa de forma significativa la motivación, dado que los voluntarios presentan un mayor nivel de compromiso cuando reciben insignias o reconocimientos por hitos alcanzados. La visualización del progreso global del proyecto refuerza el sentido de logro colectivo y promueve la participación continua.

La Figura 5 ilustra el desempeño de la plataforma en términos de tasa de error según el nivel de experiencia del usuario, así como el impacto de los elementos de gamificación en la retención de voluntarios, destacando la relación directa entre personalización, motivación y precisión operativa.



(a) Tasa de error según el nivel de experiencia

(b) Retención de voluntarios en función de la gamificación


Figura 5. Desempeño de la distribución adaptativa de tareas en Zooniverse.

Este estudio de caso demuestra cómo las técnicas adaptativas mejoran la escalabilidad, la participación y la eficiencia en plataformas basadas en crowdsourcing. La asignación personalizada de tareas y las estrategias de gamificación fomentan un modelo atractivo, sostenible y participativo para la investigación impulsada por voluntarios.


Zooniverse constituye un referente destacado de cómo la integración de IUI adaptables en la ciencia ciudadana puede incrementar la participación de los usuarios, mejorar los resultados de las tareas y ampliar

la escalabilidad de los sistemas colaborativos. Los principios aplicados en Zooniverse pueden extenderse a otros entornos de computación humana a gran escala, demostrando la viabilidad de los marcos adaptativos en la gestión de proyectos distribuidos.

La Figura 6 ilustra el impacto de la integración de la XAI en los diagnósticos médicos asistidos por IA, destacando su contribución a la transparencia y la confianza en los sistemas automatizados. La incorporación de XAI mejora sustancialmente la interpretabilidad de los modelos diagnósticos.



(a) Precisión diagnóstica



(b) Nivel de confianza

Figura 6. Impacto de la integración de XAI en los diagnósticos médicos asistidos por IA..

En particular, LIME permite a los clínicos validar las decisiones de la IA, al identificar las características de la imagen que influyen en la clasificación, mejorando la precisión diagnóstica. De manera complementaria, los mapas de calor generados por Grad-CAM ofrecen explicaciones visuales detalladas, facilitando que los

profesionales de la salud interpreten las predicciones del modelo con mayor claridad y ajusten sus diagnósticos de forma más informada.

La combinación de ambos métodos fortalece el desempeño de los sistemas de soporte a la decisión clínica (CDSS) en términos de precisión y confianza,

promoviendo una colaboración más efectiva entre los sistemas de IA y los expertos médicos. Los análisis demuestran que la inclusión de técnicas XAI reduce la brecha entre las predicciones automatizadas y la interpretación humana, garantizando la verificabilidad y la confiabilidad de las decisiones asistidas.

Este estudio resalta el papel crítico de la XAI en el ámbito sanitario, donde la transparencia en la toma de decisiones es un requisito esencial. La integración de LIME y Grad-CAM en los procesos diagnósticos refuerza la trazabilidad de los resultados y mejora la aceptación clínica de los sistemas de IA.

Las investigaciones futuras deberían orientarse a optimizar la aplicabilidad de la XAI en entornos clínicos, enfocándose en la usabilidad, la confianza y la interacción humano-IA. En consecuencia, los hallazgos de este estudio sugieren que la XAI debe considerarse un componente esencial en el diseño de herramientas de diagnóstico asistidas por IA, especialmente en dominios de alta responsabilidad como la salud, donde la precisión y la explicabilidad son imperativos fundamentales.

En conjunto, los estudios de caso analizados demuestran que, aunque los enfoques adaptativos resultan altamente efectivos en entornos basados en crowdsourcing, su éxito depende de factores contextuales específicos. La gamificación y la asignación adaptativa de tareas incrementan de manera sustancial la participación de los usuarios, así como el desempeño en las tareas dentro de plataformas como MTurk y Zooniverse, consolidándose como estrategias clave para fomentar la motivación sostenida y optimizar la eficiencia colaborativa.

En contraste, la inteligencia artificial explicable (XAI) se revela como un componente esencial para garantizar que los sistemas de IA sean no solo efectivos, sino también transparentes, interpretables y fiables, particularmente en dominios especializados como el sector de la salud, donde la confianza y la verificabilidad de los resultados son críticas.

Este enfoque híbrido, que integra adaptabilidad, explicabilidad y motivación lúdica, subraya la versatilidad y la relevancia de estas técnicas emergentes en la optimización de los sistemas de computación humana. Los hallazgos ofrecen recomendaciones específicas por dominio —para contextos que demandan altos niveles de escrutinio y confianza— y conclusiones generalizables aplicables a plataformas colaborativas a gran escala, estableciendo un marco de referencia sólido para la investigación futura y el diseño de sistemas humano-IA escalables y éticamente responsables.

3.1. Impacto de los enfoques impulsados por IUI en comparación con sistemas sin IUI

- Escalabilidad y flexibilidad: Los sistemas impulsados por IUI implementados en MTurk y Zooniverse

son más escalables y flexibles que los modelos tradicionales de computación humana. Esta flexibilidad les permite adaptarse con eficacia a la creciente complejidad y escala de las tareas basadas en crowdsourcing, optimizando tanto la distribución de recursos como la eficiencia operativa. En contraste, los sistemas estáticos sin IUI presentan limitaciones significativas para gestionar cargas de trabajo extensas o dinámicas, debido a su ausencia de adaptabilidad en tiempo real.

- Confianza y colaboración mejoradas: La integración de la XAI dentro de los sistemas impulsados por IUI, particularmente en el ámbito de la salud pública, demuestra cómo estas plataformas fortalecen la colaboración entre humanos e IA. Este modelo supera los enfoques tradicionales de IA, en los que la falta de transparencia debilita la confianza del usuario y limita la adopción de soluciones automatizadas. La XAI introduce mecanismos de interpretabilidad que permiten validar las decisiones del sistema, reforzando la credibilidad y la aceptación clínica de las tecnologías basadas en IA.

Al comparar explícitamente las metodologías adaptativas impulsadas por IUI con los enfoques sin IUI, se evidencia que las primeras ofrecen mejoras sustanciales en eficiencia, escalabilidad, participación y confianza. Los módulos de distribución adaptativa de tareas, el modelado de usuario y las estrategias de gamificación implementadas en MTurk y Zooniverse superan las limitaciones de la asignación estática de tareas y de los sistemas impersonales, mientras que la XAI incorpora transparencia, colaboración y responsabilidad en los procesos automatizados.

En síntesis, los sistemas impulsados por IUI proporcionan un marco más robusto, escalable y confiable para la optimización de los entornos de computación humana, consolidando una sinergia efectiva entre la adaptabilidad tecnológica, la participación humana y la transparencia algorítmica.

3.2. Limitaciones

A pesar de sus contribuciones significativas, el marco propuesto de IUI adaptativas presenta diversas limitaciones que deben considerarse en el desarrollo y la implementación de sistemas futuros:

1. Dependencia de modelos de usuario precisos y actualizados: La efectividad de la asignación dinámica de tareas y de la personalización adaptativa depende en gran medida de la exactitud y actualización constante de los modelos de usuario. La investigación actual resalta el desafío de capturar atributos complejos y multidimensionales —como la emoción, el contexto y

el comportamiento del usuario— sin comprometer la consistencia del modelo ni la privacidad de los datos personales.

2. Sobrecarga computacional e integración de módulos: La implementación simultánea de múltiples módulos adaptativos —incluidos asignación de tareas, gamificación, explicabilidad y seguridad— puede imponer una sobrecarga computacional y de mantenimiento significativa. Estudios previos sobre marcos de IUI adaptativas han identificado el rendimiento del sistema, el consumo de recursos y la mantenibilidad del software como desafíos persistentes que limitan su escalabilidad práctica.
3. Efecto de sobrejustificación en la gamificación: Una dependencia excesiva de recompensas extrínsecas puede reducir la motivación intrínseca de los usuarios, generando el denominado efecto de sobrejustificación. Este fenómeno destaca la necesidad de diseñar estrategias de gamificación equilibradas y sostenibles, que combinen motivación interna y recompensas externas para mantener la participación a largo plazo.
4. Desafíos de privacidad, seguridad y ética de los datos: Las IUI adaptativas recopilan y analizan información sensible, incluidos patrones de comportamiento y datos del estado del canal (CSI), lo que plantea riesgos relevantes en materia de privacidad, seguridad y ética digital. Garantizar mecanismos sólidos de protección de datos y mantener la transparencia en el procesamiento son condiciones esenciales para preservar la confianza del usuario y cumplir con los principios éticos de la inteligencia artificial responsable.

4. Conclusiones

Este estudio comparativo demuestra la relevancia de integrar enfoques adaptativos —como la distribución adaptativa de tareas, el modelado de usuario, la gamificación y la inteligencia artificial explicable (XAI)— para optimizar los sistemas de computación humana. Mediante una estrategia híbrida, que combina dos estudios de caso de propósito general (Amazon Mechanical Turk y Zooniverse) con un estudio especializado en salud pública apoyado en XAI, la investigación ofrece una visión integral sobre la adaptabilidad, la escalabilidad y la fiabilidad de las interfaces de usuario inteligentes (IUI) adaptativas.

La asignación personalizada y la distribución dinámica de tareas demostraron mejorar de forma significativa el desempeño y la participación en plataformas colaborativas a gran escala. La distribución en tiempo real basada en la competencia del usuario asegura que

las tareas sean asignadas a los participantes más calificados, aumentando la productividad y reduciendo la tasa de errores.

Asimismo, la incorporación de elementos de gamificación incrementa la motivación y la participación sostenida de los usuarios, un aspecto esencial para mantener la actividad continua en entornos de crowdsourcing. En el caso de estudio de salud pública, la investigación resalta el papel crítico de la transparencia y la confianza en dominios de alta responsabilidad. La integración de modelos XAI, como LIME y Grad-CAM, mejora la interpretabilidad de los diagnósticos asistidos por IA, permitiendo a los profesionales comprender, verificar y ajustar los resultados generados por los sistemas inteligentes. Esta transparencia colaborativa fortalece la confianza y contribuye a la mejora de los resultados clínicos.

En conclusión, los sistemas de IUI adaptativas se presentan como soluciones escalables, personalizables y confiables, aplicables tanto a plataformas de crowdsourcing de propósito general como a entornos especializados. En conjunto, estos enfoques ofrecen una base flexible, transparente y ética para el avance de la computación humana, reforzando la eficiencia, la participación y la responsabilidad en aplicaciones complejas y de alto impacto social.

Rol de autor

- **R. J. Martín:** Conceptualización, investigación, metodología, validación, escritura–borrador original, escritura–revisión y edición.

Referencias

- [1] L. von Ahn and L. Dabbish, “Designing games with a purpose,” *Communications of the ACM*, vol. 51, no. 8, pp. 58–67, Aug. 2008. [Online]. Available: <https://doi.org/10.1145/1378704.1378719>
- [2] E. Horvitz, “Principles of mixed-initiative user interfaces,” in *Proceedings of the SIGCHI conference on Human factors in computing systems the CHI is the limit - CHI '99*, ser. CHI '99. ACM Press, 1999, pp. 159–166. [Online]. Available: <https://doi.org/10.1145/302979.303030>
- [3] A. J. Quinn and B. B. Bederson, “Human computation: a survey and taxonomy of a growing field,” in *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, ser. CHI '11. ACM, May 2011, pp. 1403–1412. [Online]. Available: <https://doi.org/10.1145/1978942.1979148>
- [4] C. Schmidbauer, S. Zafari, B. Hader, and S. Schlund, “An empirical study on workers’ preference in human–robot task assignment

- in industrial assembly systems,” *IEEE Transactions on Human-Machine Systems*, vol. 53, no. 2, pp. 293–302, 2023. [Online]. Available: <https://doi.org/10.1109/thms.2022.3230667>
- [5] J. Wen, J. Yang, T. Wang, Y. Li, and Z. Lv, “Energy-efficient task allocation for reliable parallel computation of cluster-based wireless sensor network in edge computing,” *Digital Communications and Networks*, vol. 9, no. 2, pp. 473–482, Apr. 2023. [Online]. Available: <https://doi.org/10.1016/j.dcan.2022.06.014>
- [6] M. Faccio, I. Granata, and R. Minto, “Task allocation model for human-robot collaboration with variable cobot speed,” *Journal of Intelligent Manufacturing*, vol. 35, no. 2, pp. 793–806, Jan. 2023. [Online]. Available: <https://doi.org/10.1007/s10845-023-02073-9>
- [7] Z. Yuan, R. Wang, T. Kim, D. Zhao, I. Obi, and B.-C. Min, “Adaptive task allocation in multi-human multi-robot teams under team heterogeneity and dynamic information uncertainty,” *ICRA 2025*, 2024. [Online]. Available: <https://doi.org/10.48550/arXiv.2409.13824>
- [8] A. Tamali, N. Amardjia, and M. Tamali, “Distributed and autonomous multi-robot for task allocation and collaboration using a greedy algorithm and robot operating system platform,” *IAES International Journal of Robotics and Automation (IJRA)*, vol. 13, no. 2, p. 205, Jun. 2024. [Online]. Available: <https://doi.org/10.11591/ijra.v13i2.pp205-219>
- [9] M. Jain, *Crowd-Sourced Evaluation of Explainable AI Techniques with Games*. Carnegie Mellon University, 2021. [Online]. Available: <https://upsalesiana.ec/ing35ar4r9>
- [10] Z. Kou, Y. Zhang, D. Zhang, and D. Wang, “Crowdgraph: A crowdsourcing multi-modal knowledge graph approach to explainable fauxtography detection,” *Proceedings of the ACM on Human-Computer Interaction*, vol. 6, no. CSCW2, pp. 1–28, Nov. 2022. [Online]. Available: <https://doi.org/10.1145/3555178>
- [11] Z. Kou, L. Shang, Y. Zhang, and D. Wang, “HC-COVID: A hierarchical crowdsource knowledge graph approach to explainable COVID-19 misinformation detection,” *Proceedings of the ACM on Human-Computer Interaction*, vol. 6, no. GROUP, pp. 1–25, Jan. 2022. [Online]. Available: <http://doi.org/10.1145/3492855>
- [12] M. Sawant, A. Younus, S. Caton, and M. A. Qureshi, “Using explainable AI (XAI) for identification of subjectivity in hate speech annotations for low-resource languages,” in *4th International Workshop on OPEN CHALLENGES IN ONLINE SOCIAL NETWORKS*, ser. HT ’24. ACM, Sep. 2024, pp. 10–17. [Online]. Available: <http://doi.org/10.1145/3677117.3685006>
- [13] V. Lai, Y. Zhang, C. Chen, Q. V. Liao, and C. Tan, “Selective explanations: Leveraging human input to align explainable AI,” *Proceedings of the ACM on Human-Computer Interaction*, vol. 7, no. CSCW2, pp. 1–35, Sep. 2023. [Online]. Available: <http://doi.org/10.1145/3610206>
- [14] C. Zhang, P. van Gorp, M. Derksen, R. Nuijten, W. A. IJsselsteijn, A. Zanutto, F. Melillo, and R. Pratola, “Promoting occupational health through gamification and e-coaching: A 5-month user engagement study,” *International Journal of Environmental Research and Public Health*, vol. 18, no. 6, p. 2823, Mar. 2021. [Online]. Available: <http://doi.org/10.3390/ijerph18062823>
- [15] C. J. Hellín, F. Calles-Esteban, A. Valledor, J. Gómez, S. Otón-Tortosa, and A. Tayebi, “Enhancing student motivation and engagement through a gamified learning environment,” *Sustainability*, vol. 15, no. 19, p. 14119, Sep. 2023. [Online]. Available: <http://doi.org/10.3390/su151914119>
- [16] H.-P. Lu and H.-C. Ho, “Exploring the impact of gamification on users’ engagement for sustainable development: A case study in brand applications,” *Sustainability*, vol. 12, no. 10, p. 4169, May 2020. [Online]. Available: <http://doi.org/10.3390/su12104169>
- [17] P. Bitrián, I. Buil, and S. Catalán, “Enhancing user engagement: The role of gamification in mobile apps,” *Journal of Business Research*, vol. 132, pp. 170–185, Aug. 2021. [Online]. Available: <http://doi.org/10.1016/j.jbusres.2021.04.028>
- [18] A. S. Alfaqiri, S. F. M. Noor, and N. Sahari, “Framework for gamification of online training platforms for employee engagement enhancement,” *International Journal of Interactive Mobile Technologies (iJIM)*, vol. 16, no. 06, pp. 159–175, Mar. 2022. [Online]. Available: <http://doi.org/10.3991/ijim.v16i06.28485>
- [19] N. Pius Owoh and M. Mahinderjit Singh, “Sensecrypt: A security framework for mobile crowd sensing applications,” *Sensors*, vol. 20, no. 11, p. 3280, Jun. 2020. [Online]. Available: <http://doi.org/10.3390/s20113280>
- [20] Z. Li, J. Liu, J. Hao, H. Wang, and M. Xian, “Crowdsfl: A secure crowd computing framework based on blockchain and





- federated learning,” *Electronics*, vol. 9, no. 5, p. 773, May 2020. [Online]. Available: <http://doi.org/10.3390/electronics9050773>
- [21] P. Siangliulue, J. Chan, S. P. Dow, and K. Z. Gajos, “Ideahound: Improving large-scale collaborative ideation with crowd-powered real-time semantic modeling,” in *Proceedings of the 29th Annual Symposium on User Interface Software and Technology*, ser. UIST ’16. ACM, Oct. 2016, pp. 609–624. [Online]. Available: <http://doi.org/10.1145/2984511.2984578>
- [22] T. Abbas, *Affective Real-Time Crowd-Powered Conversational Systems*. Eindhoven University of Technology, Sep. 2022. [Online]. Available: <https://upsalesiana.ec/ing35ar4r22>
- [23] M. Ponti and A. Serebko, “Human-machine-learning integration and task allocation in citizen science,” *Humanities and Social Sciences Communications*, vol. 9, no. 1, Feb. 2022. [Online]. Available: <http://doi.org/10.1057/s41599-022-01049-z>
- [24] S. Stein and V. Yazdanpanah, “Citizen-centric multiagent systems,” in *Proceedings of the 2023 International Conference on Autonomous Agents and Multiagent Systems*, ser. AAMAS ’23. Richland, SC: International Foundation for Autonomous Agents and Multiagent Systems, 2023, p. 1802–1807. [Online]. Available: <https://upsalesiana.ec/ing35ar4r24>
- [25] P. Gupta, T. N. Nguyen, C. González, and A. W. Woolley, “Fostering collective intelligence in human-ai collaboration: Laying the groundwork for cohuma,” *Topics in Cognitive Science*, vol. 17, no. 2, pp. 189–216, Jun. 2023. [Online]. Available: <http://doi.org/10.1111/tops.12679>
- [26] A. Carrera-Rivera, F. Larrinaga, G. Lasa, G. Martínez-Arellano, and G. Unamuno, “Adaptui: A framework for the development of adaptive user interfaces in smart product-service systems,” *User Modeling and User-Adapted Interaction*, vol. 34, no. 5, pp. 1929–1980, Aug. 2024. [Online]. Available: <http://doi.org/10.1007/s11257-024-09414-0>
- [27] S. E. Shaw, S. Papparini, J. Murdoch, J. Green, T. Greenhalgh, B. Hanckel, H. M. James, M. Petticrew, G. W. Wood, and C. Papoutsis, “TRIPLE C reporting principles for case study evaluations of the role of context in complex interventions,” *BMC Medical Research Methodology*, vol. 23, no. 1, May 2023. [Online]. Available: <http://doi.org/10.1186/s12874-023-01888-7>
- [28] L. Uden and N. Willis, “Designing user interfaces using activity theory,” in *Proceedings of the 34th Annual Hawaii International Conference on System Sciences*, ser. HICSS-01. IEEE Comput. Soc, 2005, p. 11. [Online]. Available: <http://doi.org/10.1109/hicss.2001.926547>
- [29] M. Calzavara, M. Faccio, I. Granata, and A. Trevisani, “Achieving productivity and operator well-being: A dynamic task allocation strategy for collaborative assembly systems in industry 5.0,” *The International Journal of Advanced Manufacturing Technology*, Aug. 2024. [Online]. Available: <http://doi.org/10.1007/s00170-024-14302-3>
- [30] M. H. Faisal, A. W. AlAmeeri, and A. A. Alsumait, “An adaptive e-learning framework: crowdsourcing approach,” in *Proceedings of the 17th International Conference on Information Integration and Web-based Applications & Services*, ser. iiWAS ’15. ACM, Dec. 2015, pp. 1–5. [Online]. Available: <http://doi.org/10.1145/2837185.2837249>
- [31] J. C. Cheung and S. S. Ho, “The effectiveness of explainable AI on human factors in trust models,” *Scientific Reports*, vol. 15, no. 1, Jul. 2025. [Online]. Available: <http://doi.org/10.1038/s41598-025-04189-9>
- [32] M. T. Ribeiro, S. Singh, and C. Guestrin, “Why should I trust you?: explaining the predictions of any classifier,” in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, ser. KDD ’16. ACM, Aug. 2016, pp. 1135–1144. [Online]. Available: <http://doi.org/10.1145/2939672.2939778>
- [33] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, “Grad-CAM: visual explanations from deep networks via gradient-based localization,” in *2017 IEEE International Conference on Computer Vision (ICCV)*. IEEE, Oct. 2017, pp. 618–626. [Online]. Available: <http://doi.org/10.1109/iccv.2017.74>
- [34] K. Borys, Y. A. Schmitt, M. Nauta, C. Seifert, N. Krämer, C. M. Friedrich, and F. Nensa, “Explainable AI in medical imaging: An overview for clinical practitioners – saliency-based XAI approaches,” *European Journal of Radiology*, vol. 162, p. 110787, May 2023. [Online]. Available: <http://doi.org/10.1016/j.ejrad.2023.110787>
- [35] Q. Wang, Y. Wan, F. Feng, and X. Wang, “Threshold optimization of task allocation models in human-machine collaborative scoring of subjective assignments,” *Computers & Industrial Engineering*, vol. 188, p. 109923, Feb. 2024. [Online]. Available: <http://doi.org/10.1016/j.cie.2024.109923>
- [36] L. Sun, X. Yu, J. Guo, Y. Yan, and X. Yu, “Deep reinforcement learning for task assignment in spatial crowdsourcing and sensing,”

- IEEE Sensors Journal*, vol. 21, no. 22, pp. 25 323–25 330, Nov. 2021. [Online]. Available: <http://doi.org/10.1109/jsen.2021.3057376>
- [37] S. N. Ahmadabadi, M. Haghifam, V. Shah-Mansouri, and S. Ershadmanesh, “Design and evaluation of crowdsourcing platforms based on users’ confidence judgments,” *Scientific Reports*, vol. 14, no. 1, Aug. 2024. [Online]. Available: <http://doi.org/10.1038/s41598-024-65892-7>
- [38] J. Cox, E. Y. Oh, B. Simmons, C. Lintott, K. Masters, A. Greenhill, G. Graham, and K. Holmes, “Defining and measuring success in online citizen science: A case study of zooniverse projects,” *Computing in Science & Engineering*, vol. 17, no. 4, pp. 28–41, Jul. 2015. [Online]. Available: <http://doi.org/10.1109/mcse.2015.65>
- [39] S. A. Triantafyllou, T. Sapounidis, and Y. Farhaoui, “Gamification and computational thinking in education: A systematic literature review,” *Salud, Ciencia y Tecnología - Serie de Conferencias*, vol. 3, p. 659, Mar. 2024. [Online]. Available: <http://doi.org/10.56294/sctconf2024659>
- [40] H. Cigdem, M. Ozturk, Y. Karabacak, N. Atik, S. Gürkan, and M. H. Aldemir, “Unlocking student engagement and achievement: The impact of leaderboard gamification in online formative assessment for engineering education,” *Education and Information Technologies*, vol. 29, no. 18, pp. 24 835–24 860, Jun. 2024. [Online]. Available: <http://doi.org/10.1007/s10639-024-12845-2>
- [41] A. Tomar and S. Tripathi, “Bcsom: Blockchain-based certificateless aggregate signature scheme for internet of medical things,” *Computer Communications*, vol. 212, pp. 48–62, Dec. 2023. [Online]. Available: <http://doi.org/10.1016/j.comcom.2023.09.027>
- [42] P. Runeson and M. Höst, “Guidelines for conducting and reporting case study research in software engineering,” *Empirical Software Engineering*, vol. 14, no. 2, pp. 131–164, Dec. 2008. [Online]. Available: <http://doi.org/10.1007/s10664-008-9102-8>



ANÁLISIS DE IMPEDANCIAS DE TIERRA DE FORMA CERRADA EN ESTUDIOS DE CORTOCIRCUITO DE SISTEMAS DE DISTRIBUCIÓN AÉREA

ANALYSIS OF CLOSED-FORM GROUND-RETURN IMPEDANCES FOR SHORT-CIRCUIT STUDIES IN OVERHEAD DISTRIBUTION SYSTEMS

Allen A. Castillo Barrón^{1,*} , Gerardo Ayala Jaimes¹ ,
 Alejandra Jiménez Vega¹ , Francisco J. Ramírez Arias¹ 

Recibido: 29-04-2025, Recibido tras revisión: 05-11-2025, Aceptado: 18-11-2025, Publicado: 01-01-2026

Resumen


El objetivo de este estudio es evaluar la aplicabilidad de las principales fórmulas cerradas de impedancia de retorno por tierra en el análisis de cortocircuito de sistemas de distribución, así como identificar las configuraciones críticas en las cuales la elección del modelo de impedancia puede influir significativamente en los resultados del cortocircuito. La metodología adoptada en esta investigación se estructura en tres etapas. Primero, se desarrolló un algoritmo para implementar y comparar las formulaciones cerradas de impedancia de retorno por tierra, el cual fue validado con datos de referencia disponibles en la literatura. Segundo, se diseñó un algoritmo de análisis de cortocircuito que fue verificado con resultados publicados por la IEEE Power and Energy Society. Finalmente, se realizaron múltiples estudios de cortocircuito en varios alimentadores de prueba de distribución del IEEE. Los resultados muestran que la mayoría de las formulaciones cerradas de impedancia de retorno por tierra son adecuadas tanto para análisis de cortocircuito balanceados como desbalanceados, y que, en fallas monofásicas a tierra, la elección de la fórmula cerrada de impedancia resulta un factor crítico para obtener resultados precisos.

Palabras clave: Fórmulas cerradas de impedancia de tierra, sistemas de distribución, exactitud de cálculo de cortocircuito

Abstract

The objective of this study is to evaluate the applicability of the most widely used closed-form ground-return impedance formulas in short-circuit analyses of distribution systems and to identify the critical network configurations in which the choice of impedance model significantly affects the short-circuit results. The methodology adopted in this research is organized into three stages. First, an algorithm was developed to implement and compare several closed-form Earth-return impedance formulations, and its performance was validated using benchmark data reported in the literature. Second, a short-circuit analysis algorithm was designed and verified against reference results published by the IEEE Power and Energy Society. Finally, multiple short-circuit studies were performed on several IEEE distribution test feeders. The findings reveal that most closed-form Earth-return impedance models provide adequate accuracy for both balanced and unbalanced short-circuit analyses. However, for single-phase line-to-ground faults, the choice of closed-form impedance formulation is critical to obtaining accurate short-circuit results.

Keywords: Closed-form ground-return impedance, Distribution systems; Short-circuit calculation accuracy.

^{1,*}Departamento de Ingeniería Eléctrica (FCITEC), Universidad Autónoma de Baja California, Tijuana, México. 
 Autor para correspondencia ✉: allen.castillo@uabc.edu.mx.

Forma sugerida de citación: A. A. Castillo Barrón, G. Ayala Jaimes, A. Jiménez Vega y F. J. Ramírez Arias, "Análisis de impedancias de tierra de forma cerrada en estudios de cortocircuito de sistemas de distribución aérea," *Ingenius, Revista de Ciencia y Tecnología*, N.º 35, pp. 69-83, 2026. DOI: <https://doi.org/10.17163/ings.n35.2026.05>.

1. Introducción

Los sistemas de distribución presentan una geometría inherentemente asimétrica y, a diferencia de las líneas de transmisión, no están transpuestas. Esta falta de simetría conduce a desequilibrios significativos de fase, lo que incrementa la circulación de corriente a través de la tierra. En consecuencia, modelar con precisión la impedancia de retorno por tierra es esencial para obtener una representación exacta del comportamiento eléctrico del sistema [1–3].

El primer modelo de impedancia de retorno por tierra fue desarrollado por Carson en 1926, quien derivó la primera formulación analítica al expresar el campo eléctrico axial en el suelo como una integral impropia de tipo Fourier bajo suposiciones cuasi-TEM. El modelo de Carson representa una contribución fundamental al campo; sin embargo, se basó en suposiciones simplificadas, como suelo homogéneo, permeabilidad terrestre igual a la del espacio libre y la omisión de corrientes de desplazamiento, lo que limitó su aplicabilidad a frecuencias más altas y en suelos con efectos significativos de permitividad [4].

Investigadores posteriores abordaron estas limitaciones. Wise, en sus primeros trabajos de 1931 y 1934, introdujo formulaciones que ampliaron el modelo de Carson al incorporar permeabilidad terrestre finita y corrientes de desplazamiento, utilizando el potencial vectorial de Hertz y expansiones de Fourier–Bessel para generalizar la ecuación de onda para suelos imperfectos [5, 6].

Posteriormente, en 1968, Sunde avanzó aún más el trabajo de Wise al incorporar los efectos de estructuras de suelo estratificado en las formulaciones de impedancia de retorno por tierra [7].

La formulación de Carson fue expresada originalmente como integrales impropias, lo que dificultaba su evaluación directa. A lo largo de los años, los investigadores han propuesto varios métodos para evaluar estas integrales, incluyendo técnicas de integración numérica y desarrollos en series infinitas [1], [8]. Sin embargo, estos enfoques suelen ser computacionalmente intensivos y requieren tiempos de procesamiento considerables.

Para abordar estas limitaciones, se han desarrollado múltiples modelos de imágenes complejas. Sunde introdujo una base física más rigurosa para la ubicación de las imágenes y proporcionó expresiones prácticas en forma cerrada [7].

Posteriormente, Dubanton y Deri propusieron profundidades de imágenes complejas más sofisticadas derivadas de aproximaciones exponenciales o logarítmicas de la integral de Carson [9, 10].

Alvarado refinó aún más estos resultados al introducir un modelo en forma cerrada más preciso y adecuado para aplicaciones de ingeniería [11], mientras que Pizarro y, posteriormente, Noda presentaron mo-

delos de doble imagen compleja en los cuales dos conductores imagen optimizados mejoran sustancialmente la precisión de la aproximación en amplios rangos de frecuencia y configuraciones geométricas [12, 13].

Finalmente, es importante señalar que Kersting propuso un modelo que depende solo de los primeros términos de la expansión en series de Carson [14], y que el propio Carson, en su trabajo original, ya había derivado una solución en forma cerrada, aunque esta contribución permaneció en gran medida poco reconocida hasta años recientes [15].

Las soluciones en forma cerrada para la impedancia de retorno por tierra han sido ampliamente estudiadas, y numerosos trabajos han analizado su sensibilidad a la resistividad del suelo, la altura del conductor, el espaciamiento horizontal, la frecuencia de operación y la estratificación del terreno.

Estos estudios proporcionan información valiosa sobre la precisión y las limitaciones tanto de las aproximaciones clásicas como de las modernas, incluidas las series basadas en Carson, las formulaciones mediante el método de imágenes y las expresiones recientes en forma cerrada.

Sin embargo, a pesar de este extenso cuerpo de investigación, ningún trabajo previo ha evaluado la aplicabilidad o la precisión de estos modelos en forma cerrada para estudios de cortocircuito en sistemas de distribución desbalanceados, en los cuales el acoplamiento mutuo y las geometrías asimétricas de los alimentadores influyen de manera significativa en los resultados [1], [8], [16–18].

Para los estudios de cortocircuito en sistemas balanceados, el método de componentes simétricas es ampliamente utilizado. Sin embargo, en redes de distribución, que son inherentemente desbalanceadas debido a su geometría asimétrica, aplicar directamente este método puede conducir a errores significativos [19].

En tales casos, el análisis en el dominio de fase se vuelve esencial, ya que representa explícitamente el desbalance del sistema e incorpora las impedancias mutuas entre fases. Estudios recientes han integrado representaciones en el dominio de fase directamente en el marco de componentes simétricas, lo que permite un tratamiento más preciso de los efectos de desbalance y acoplamiento mutuo.

Estos enfoques híbridos están siendo empleados cada vez más para analizar sistemas de distribución con alta penetración de generación distribuida (DG), donde la interacción entre las condiciones desbalanceadas de la red y los recursos basados en inversores requiere un modelado detallado y resuelto por fase de los cortocircuitos [20–22].

Dado que los estudios de cortocircuito en sistemas de distribución con generación distribuida se realizan actualmente de forma habitual mediante análisis en el dominio de fase, el cual depende directamente de una representación precisa de la impedancia de retorno por

tierra, es esencial evaluar si las formulaciones en forma cerrada más ampliamente utilizadas —implementadas en software comercial y en proyectos de investigación— son adecuadas para este propósito [1], [17].

Evaluar su desempeño permite determinar la fiabilidad de estas expresiones en forma cerrada para los cálculos de cortocircuito y, en consecuencia, su idoneidad para analizar sistemas de distribución desbalanceados con alta penetración de DG.

Este estudio proporciona un análisis integral de cortocircuito en el dominio de fase de tres sistemas de distribución, incorporando las formulaciones en forma cerrada más ampliamente utilizadas para la impedancia de retorno por tierra. La novedad de este estudio radica en evaluar, por primera vez, el impacto directo de estas formulaciones en los resultados de cortocircuito en redes de distribución desbalanceadas, en lugar de centrarse únicamente en su precisión electromagnética, como en contribuciones anteriores.

Las principales contribuciones de este trabajo se resumen de la siguiente manera:

- Cuantificar el error porcentual introducido en los cálculos de cortocircuito cuando se emplean diferentes formulaciones en forma cerrada de la impedancia de retorno por tierra.
- Identificar las configuraciones críticas de la red en las cuales la selección del modelo de impedancia puede ejercer una influencia significativa en los resultados de cortocircuito.

2. Materiales y métodos

2.1. Fórmulas de impedancia en forma cerrada

Las principales expresiones en forma cerrada para la impedancia de retorno por tierra en líneas aéreas de distribución se derivan de las formulaciones de Carson [16, 17], [23] e incluyen los siguientes componentes, ver ecuación (1):

$$Z' = R_c + jX_c + jX_g + Z_e \quad (1)$$

Donde R_c y X_c denotan la resistencia y la reactancia del conductor, respectivamente; X_g representa la reactancia asociada con la distribución geométrica de los conductores; y Z_e es la impedancia de retorno por tierra. Como es habitual para líneas aéreas cortas (menores a 50 millas), la capacitancia se omite porque tiene un impacto insignificante a frecuencias de potencia [24].

La resistencia del conductor es típicamente proporcionada por el fabricante. La reactancia del conductor está dada por la siguiente ecuación (2):

$$X_c = \frac{\omega\mu_0\mu_r}{2\pi} \ln \frac{r_{ext}}{GMR} \quad (2)$$

Donde:

- ω es la frecuencia compleja, rad/s.
- μ_0 es la permeabilidad del vacío, H/milla.
- μ_r es la permeabilidad magnética relativa.
- r_{ext} es el radio del conductor (ft).
- GMR es el radio medio geométrico del conductor (ft).

El modelo extendido de Carson se presenta en (3)-(6). En estas expresiones, Z_c denota la impedancia propia del conductor y está dada por la suma de R_c y jX_c . El segundo término en el lado derecho de la ecuación (3) y el primer término en el lado derecho de la ecuación (4) corresponden a la reactancia asociada con la geometría de la línea (jX_g). Los últimos términos en los lados derechos de (3) y (4) representan la impedancia de retorno por tierra (Z_e).

$$Z'_{(self),carson} = Z_c + j\omega \frac{\mu_0}{2\pi} \ln \frac{2h_s}{r_{ext}} + j\omega \frac{\mu_0\mu_r}{\pi} J_s \quad (3)$$

$$Z'_{(mutual),carson} = j\omega \frac{\mu_0}{2\pi} \ln \frac{\sqrt{(h_i + h_j)^2 + (x_{ij})^2}}{\sqrt{(h_i - h_j)^2 + (x_{ij})^2}} + j\omega \frac{\mu_0\mu_r}{\pi} J_m \quad (4)$$

Donde:

$$J_s = P_s + jQ_s = \int_0^\infty \frac{e^{-2h_s\lambda}}{\lambda + \sqrt{\lambda^2 + j\omega\mu_0\mu_r/\rho}} d\lambda \quad (5)$$

$$J_m = P_m + jQ_m = \int_0^\infty \frac{e^{-2(h_i+h_j)\lambda}}{\lambda + \sqrt{\lambda^2 + j\omega\mu_0\mu_r/\rho}} \text{Cos}(\lambda x) d\lambda \quad (6)$$

Y

- ρ es la resistividad del suelo, $\Omega \cdot ft$.
- h_s, h_i, h_j son las alturas de los conductores sobre el suelo (ft).
- x es la separación horizontal entre conductores (ft).

La solución a las integrales infinitas en las ecuaciones (5) y (6) fue expresada inicialmente por Carson como una solución en forma cerrada. Sin embargo, debido a los recursos computacionales limitados disponibles en ese momento, presentó el resultado como una expansión en series infinitas. En consecuencia, se hicieron necesarias aproximaciones posteriores para obtener formulaciones prácticas de la impedancia de retorno por tierra [1], [15].

Esta sección resume las principales soluciones en forma cerrada para bajas frecuencias, comenzando con las aproximaciones logarítmicas simple y doble de las integrales de Carson [9–13] seguidas de las adaptaciones computacionales de las expresiones correspondientes en series infinitas [14], [23].

2.1.1. Dubanton

La solución a las integrales infinitas en las ecuaciones (5) y (6) fue expresada inicialmente por Carson como una solución en forma cerrada. Sin embargo, debido a los recursos computacionales limitados disponibles en ese momento, presentó el resultado como una expansión en series infinitas. En consecuencia, se hicieron necesarias aproximaciones posteriores para obtener formulaciones prácticas de la impedancia de retorno por tierra [1], [15].

Esta sección resume las principales soluciones en forma cerrada para bajas frecuencias, comenzando con las aproximaciones logarítmicas simple y doble de las integrales de Carson [9–13], seguidas de las adaptaciones computacionales de las expresiones correspondientes en series infinitas [14], [23].

$$Z_{\text{self}} = Z_c + j\omega \frac{\mu_0}{2\pi} \ln \frac{2(h_s + p)}{r_{\text{ext}}} \quad (7)$$

$$Z_{\text{mutual}} = j\omega \frac{\mu_0}{2\pi} \ln \frac{\sqrt{(h_i + h_j + 2p)^2 + (x_{ij})^2}}{\sqrt{(h_i - h_j)^2 + (x_{ij})^2}} \quad (8)$$

donde la profundidad compleja (ft) se define como:

$$p = \sqrt{\frac{\rho}{j\omega\mu_0\mu_r}} \quad (9)$$

2.1.2. Deri

En 1981, Deri *et al.* [10] proporcionaron una validación matemática de las fórmulas de impedancia propuestas por Dubanton y Gary. Su solución final en forma cerrada se expresa de la siguiente manera:

$$J_{s,\text{DERI}} = \frac{1}{2} \ln \frac{h_s + p}{h_s} \quad (10)$$

$$J_{m,\text{DERI}} = \frac{1}{2} \ln \frac{\sqrt{(h_i + h_j + 2p)^2 + (x_{ij})^2}}{\sqrt{(h_i + h_j)^2 + (x_{ij})^2}} \quad (11)$$

2.1.3. Alvarado

Un año después, en 1982, Alvarado *et al.* [11] mejoraron las fórmulas de impedancia desarrolladas por Deri. Su principal contribución fue proponer una aproximación que conservaba un mayor número de términos que la formulación de Deri. La expresión resultante se expresa de la siguiente manera:

$$J_{s,\text{ALVARADO}} = \frac{1}{2} \ln \frac{h_s + p}{h_s} - \frac{1}{24} \frac{1}{\left(\frac{h_s + p}{p}\right)^3} \quad (12)$$

$$J_{m,\text{ALVARADO}} = \frac{1}{4} \ln \frac{\left(1 + \frac{p}{h}\right)^2 + \tau^2}{1 + \tau^2} - \frac{1}{48} \left(\frac{1}{\left[\frac{h}{p}(1 + j\tau) + 1\right]^3} + \frac{1}{\left[\frac{h}{p}(1 - j\tau) + 1\right]^3} \right) \quad (13)$$

$$\tau = \frac{x_{ij}}{h_i + h_j}, h = \frac{h_i + h_j}{2} \quad (14)$$

2.1.4. Pizarro y Eriksson

Pizarro y Eriksson [12] introdujeron en 1991 un enfoque doble-logarítmico para resolver (3)–(6), el cual se resume a continuación:

$$J_s = j\omega \frac{\mu_0}{2\pi} \left[A \ln \left(\frac{\sqrt{(2h_s + 2\alpha p)^2}}{r_{\text{ext}}} \right) + (1 - A) \ln \left(\frac{\sqrt{(2h_s + 2\beta p)^2}}{r_{\text{ext}}} \right) \right] \quad (15)$$

$$J_m = j\omega \frac{\mu_0}{2\pi} \left[A \ln \frac{\sqrt{(h_i + h_j + 2\alpha p)^2 + x_{ij}^2}}{\sqrt{(h_i - h_j)^2 + (x_{ij})^2}} + (1 - A) \ln \frac{\sqrt{(h_i + h_j + 2\beta p)^2 + x_{ij}^2}}{\sqrt{(h_i - h_j)^2 + (x_{ij})^2}} \right] \quad (16)$$

donde las constantes se obtuvieron mediante el método de mínimos cuadrados, resultante $A = 0.1159$, $\alpha = 0.2258$ y $\beta = 1.1015$. Estos valores son válidos tanto para la impedancia propia como para la mutua.

2.1.5. Noda

En 2006, Noda [13] amplió el trabajo de Pizarro y Eriksson al aproximar A , α y β como funciones de parámetros típicos de sistemas de distribución y transmisión, incluidos la frecuencia, la resistividad del suelo y la altura del conductor. Esta mejora incrementó la precisión del modelo de impedancia de Pizarro; sin embargo, requirió la introducción de una variable adicional, θ .

Las fórmulas para calcular la impedancia propia y mutua se presentan en (15) y (16). Los parámetros A y α se definen de la siguiente manera:

$$A = \begin{cases} 0.07360, & \theta \leq 50.45^\circ, \\ 0.002474\theta - 0.05127, & \theta > 50.45^\circ. \end{cases} \quad (17)$$

$$\alpha = \begin{cases} 0.1500, & \theta \leq 50.45^\circ, \\ 0.004726\theta - 0.08852, & \theta > 50.45^\circ. \end{cases} \quad (18)$$

$$\beta = \frac{1 - A\alpha}{1 - A} \quad (19)$$

Donde, para la impedancia propia, $\theta = 0^\circ$, mientras que para los cálculos de impedancia mutua, está dado por:

$$\theta = \tan^{-1} \frac{x_{ij}}{h_i + h_j} \quad (20)$$

2.1.6. Galloway

Las fórmulas de impedancia de Galloway [23] constituyen una adaptación numérica de la expansión completa en series de Carson y se expresan de la siguiente manera:

$$J_s = \frac{\pi}{8}(1 - S_4) + \frac{1}{2} \left(\ln \frac{2}{\gamma r_{ij}} \right) S_2 + \frac{1}{2} \theta S'_2 - \frac{\sigma_1}{\sqrt{2}} + \frac{\sigma_2}{2} + \frac{\sigma_3}{\sqrt{2}} \quad (21)$$

$$J_m = \frac{1}{4} + \frac{1}{2} \left(\ln \frac{2}{\gamma r_{ij}} \right) (1 - S_4) - \frac{1}{2} \theta S'_4 + \frac{\sigma_1}{\sqrt{2}} - \frac{\pi}{8} S_2 + \frac{\sigma_3}{\sqrt{2}} - \frac{\sigma_4}{2} \quad (22)$$

Donde γ denota la constante de Euler (1.7811), y $S_2, S'_2, S_4, S'_4, \sigma_1, \sigma_2, \sigma_3$ y σ_4 son series infinitas que se describen en detalle en [8].

y

$$r_{ij} = \sqrt{\frac{\omega \mu_0 \mu_r}{\rho}} D_{ij} \quad (23)$$

$$D_{ij} = \sqrt{(h_i + h_j)^2 + (x_{ij})^2} \quad (24)$$

para cálculos de impedancia propia, $D_{ij} = 2h_s$.

Finalmente, el límite superior k en las sumatorias se fijó en 35, dado que Ramos *et al.* [17] demostraron que, para configuraciones típicas de líneas de distribución de 60 Hz, conservar 35 términos en las fórmulas de Galloway produce una desviación menor que 1×10^{-7} con respecto a la evaluación numérica de la integral de Carson. En consecuencia, este trabajo adopta la formulación de Galloway de 35 términos como referencia numérica “exacta” para la integral de Carson, denominada el modelo de Carson.

2.1.7. Kersting

Las fórmulas de Kersting [14] se basan en las recomendaciones de Carson para r menor que $1/4$ [4]. La mayoría de las configuraciones de líneas de distribución bajo condiciones de estado estable ($f = 60\text{Hz}$) y con resistividad de suelo estándar ($\rho = 328.084 \Omega \cdot \text{ft}$) se encuentran dentro de este rango.

$$J_s = \frac{\pi}{8} \quad (25)$$

$$J_m = -0.0386 + \frac{1}{2} \ln \frac{2}{r_{ij}} \quad (26)$$

Finalmente, para obtener la matriz de impedancias de fase (Z) para todos los modelos de línea, es necesario aplicar la reducción de Kron a la matriz de impedancias primitiva correspondiente (Z'). El procedimiento completo se describe en detalle en [18].

2.2. Configuraciones de líneas de distribución

Después de presentar las fórmulas en forma cerrada para la impedancia de retorno por tierra, el siguiente paso es modelar las configuraciones de las líneas para los estudios de cortocircuito. Con este fin, se desarrolló un algoritmo en el software Mathematica para incorporar todas las formulaciones de impedancia de tierra. Luego, el algoritmo fue validado comparándolo con datos de referencia reportados en las fuentes originales.

Se seleccionaron dos sistemas de distribución para los estudios. El alimentador de prueba IEEE de 13 nodos fue elegido porque es compacto pero altamente desbalanceado, mientras que el alimentador de prueba IEEE de 34 nodos [25] fue seleccionado porque presenta líneas de distribución más largas. Los casos de prueba considerados en este estudio se basan en estos alimentadores de prueba IEEE, los cuales fueron desarrollados a partir de configuraciones reales de sistemas de distribución y son ampliamente reconocidos como modelos de referencia para validar metodologías de análisis en redes de distribución.

Estos alimentadores se utilizan actualmente de manera extensa en estudios de cortocircuito, modelado en el dominio de fase, evaluación de impedancias de secuencia cero y análisis que involucran alta penetración de generación distribuida. Su amplia adopción y aceptación sostenida en la literatura reciente respaldan la representatividad y la conveniencia de estas configuraciones para la evaluación de precisión realizada en este trabajo [22], [26–28].

El alimentador de prueba IEEE de 13 nodos incluye cinco configuraciones de líneas aéreas (601–605); sin embargo, solo tres corresponden a espaciamientos diferentes entre conductores. En consecuencia, los resultados se presentan únicamente para las configuraciones 601, 603 y 605, que representan líneas trifásicas, bifásicas y monofásicas, respectivamente. Los datos

principales de estas configuraciones se resumen en la Tabla 1.

Tabla 1. Datos de las configuraciones de líneas aéreas para el alimentador de prueba IEEE de 13 nodos

Config.	Fase	Tamaño de fase	Tamaño de Neutro	ID de espaciamiento
601	B A C N	556.5 kcmil	4/0 AWG	500
603	C B N	1/0 AWG	1/0 AWG	505
605	C N	1/0 AWG	1/0 AWG	510

El alimentador de prueba IEEE de 34 nodos incluye cuatro configuraciones de líneas aéreas. Las configuraciones 300 y 301 son trifásicas, la configuración 305 es bifásica y la configuración 302 es monofásica. Sin embargo, los espaciamientos entre conductores son idénticos a los del alimentador de prueba IEEE de 13 nodos, como se resume en la Tabla 2.

Tabla 2. Datos de las configuraciones de líneas aéreas para el alimentador de prueba IEEE de 34 nodos

Config.	Fase	Tamaño de fase	Tamaño de Neutro	ID de espaciamiento
300	B A C N	1/0 AWG	1/0 AWG	500
301	B A C N	#2 AWG	#2 AWG	500
302	A N	#4 AWG	#4 AWG	510
305	A C N	#4 AWG	#4 AWG	505

Los datos de los conductores para ambos sistemas están disponibles en [25] y se resumen en la Tabla 3. Los tamaños de los conductores se expresan en kcmil o AWG, y todos los conductores son del tipo ACSR. Los valores de resistencia se reportan en ohmios por milla a 60 Hz y 50 °C. El diámetro externo del conductor se expresa en pulgadas, y el radio medio geométrico (GMR) se expresa en pies.

Tabla 3. Datos de los conductores

Tamaño (kcmil o AWG)	Tipo	Resistencia (Ω /milla)	Diámetro (pulgadas)	GMR (ft)
556.5	ACSR	0.1859	0.927	0.03130
4/0		0.592	0.563	0.00814
1/0		1.12	0.398	0.00446
#2		1.69	0.316	0.00418
#4		2.55	0.257	0.00452

Las configuraciones correspondientes a los diferentes espaciamientos se ilustran en la Figura 1, con todas las distancias expresadas en pies. Los conductores de fase se representan en color negro, mientras que el conductor neutro se muestra en color dorado. La distancia entre el poste y el conductor neutro es de 0.5 ft.




Figura 1. Espaciamientos de las líneas.

Para evaluar adecuadamente la precisión de las fórmulas en forma cerrada para la impedancia de retorno por tierra, la Tabla 4 presenta el error porcentual máximo de las diferentes fórmulas de impedancia en comparación con la serie de Carson para las configuraciones 601, 603 y 605, correspondientes a los casos trifásico, bifásico y monofásico, respectivamente.

Tabla 4. Error porcentual máximo para las diferentes configuraciones de líneas de distribución

Configuración 601		
	Parte real	Parte Imaginaria
Deri-Dubanton	0.96243 %	0.66959 %
Kersting	0.24885 %	0.26336 %
Pizarro - Eriksson	0.11925 %	0.09400 %
Alvarado	0.06726 %	0.07141 %
Noda	0.02956 %	0.01086 %
Configuración 603		
Deri-Dubanton	1.18801 %	0.76550 %
Kersting	0.19441 %	0.31422 %
Pizarro - Eriksson	0.14941 %	0.10769 %
Alvarado	0.08854 %	0.08228 %
Noda	0.03390 %	0.01212 %
Configuración 605		
Deri-Dubanton	0.18572 %	0.25734 %
Kersting	0.03160 %	0.11156 %
Pizarro - Eriksson	0.02340 %	0.03635 %
Alvarado	0.01389 %	0.02801 %
Noda	0.00532 %	0.00393 %

El modelado se realizó a 60 Hz, asumiendo una resistividad del suelo de $100 \Omega \cdot m$. Este valor fue seleccionado porque la resistividad típica del suelo varía entre $50 \Omega \cdot m$ y $200 \Omega \cdot m$, y $100 \Omega \cdot m$ representa una condición moderadamente conservadora para evaluar el comportamiento de la impedancia de retorno por tierra.

Además, $100 \Omega \cdot m$ es ampliamente utilizado como referencia en estudios académicos recientes y en informes técnicos del IEEE que evalúan métodos basados en imágenes, modelos derivados de Carson y formulaciones de impedancia dependientes de la frecuencia [1], [8], [29, 30].

El error porcentual se calcula de la siguiente manera:

$$\text{error} = \max \left[\frac{|Z_{\text{Carson}} - Z_{\text{E-formulae}}|}{Z_{\text{Carson}}} \right] \times 100 \% \quad (27)$$

Es importante enfatizar que el modelo de Carson se utiliza como referencia en este trabajo, ya que, a bajas frecuencias, no existe una diferencia significativa entre los resultados obtenidos a partir de la formulación de Carson y aquellos obtenidos mediante la fórmula generalizada de impedancia de retorno por tierra de Wise [6]. El modelo de Wise se considera el más completo porque incorpora la permeabilidad del suelo y las corrientes de desplazamiento. No obstante, a frecuencias de potencia, estas corrientes de desplazamiento son despreciables, y ambas formulaciones convergen prácticamente a los mismos resultados [1].

A partir de la Tabla 4, es evidente que las fórmulas de Noda presentan los menores errores porcentuales tanto en la parte real como en la parte imaginaria. La fórmula de Alvarado proporciona la siguiente aproximación más precisa, con errores porcentuales máximos inferiores al 0.09 %. La aproximación de Pizarro se ubica a continuación en exactitud, mostrando un error máximo de 0.15 % en configuraciones bifásicas. En contraste, las fórmulas de Kersting y Deri producen discrepancias mayores, con errores máximos cercanos a 0.32 % y 1.19 %, respectivamente. Estos resultados son coherentes con las conclusiones presentadas por Martins [16] y Ramos-Leaños [17], quienes identificaron las formulaciones de Noda como la aproximación en forma cerrada más precisa de la serie de Carson para configuraciones típicas de líneas de distribución. También es importante señalar que el procedimiento utilizado en este estudio para calcular las diferencias porcentuales es idéntico al adoptado por Papadopoulos [1].

A partir de estas tablas, es evidente que las fórmulas de Deri y Dubanton producen matrices de impedancia idénticas para las configuraciones de línea analizadas en este estudio. En consecuencia, se combinan y se tratan como una única formulación en el análisis posterior.

Finalmente, debe señalarse que los errores porcentuales más pequeños ocurren en las configuraciones monofásicas (605). Además, dado que las líneas monofásicas suelen ser cortas, se espera que estas configuraciones ejerzan una influencia limitada en los cálculos de cortocircuito. En contraste, las configuraciones bifásicas (603) presentan errores porcentuales mayores y, dado que este tipo de líneas suelen tener una longitud media, es más probable que tengan un impacto más significativo en los resultados de los estudios de cortocircuito.

3. Resultados y discusión

Esta sección presenta los principales resultados de los estudios de cortocircuito realizados en los alimenta-

dores de prueba IEEE de 13 y 34 nodos. Se analizan tres casos de estudio para representar condiciones distintas de los sistemas de distribución: un alimentador de 13 nodos con líneas cortas (menores de 1 milla), un alimentador de 34 nodos con líneas largas (hasta 15 millas) y un tercer escenario caracterizado por líneas extremadamente largas (mayores de 15 millas).

El algoritmo utilizado para estos estudios fue implementado en Mathematica, y sus resultados coinciden exactamente con los datos de referencia publicados por la IEEE Power and Energy Society [31]. Se adoptó el análisis en el dominio de fase para los cálculos de cortocircuito, ya que es ampliamente reconocido como el enfoque de referencia para los estudios de sistemas de distribución [20], [27]. Descripciones detalladas de este método están disponibles en [32,33]. Se aplicaron suposiciones estándar a lo largo de las simulaciones de cortocircuito: el voltaje prefalla se fijó en 1 pu y se despreciaron las cargas estáticas.

Antes de presentar los resultados de los estudios de cortocircuito, es importante aclarar que, para facilitar el análisis, todos los resultados se reportan como el error porcentual máximo, calculado mediante la ecuación (28). En esta expresión, I_{Carson} denota la corriente de cortocircuito obtenida con el modelo de Carson, e $I_{\text{E-formulae}}$ denota la corriente obtenida con las formulaciones correspondientes de impedancia de tierra en forma cerrada. Los valores de corriente de cortocircuito en amperios están disponibles por solicitud a los autores.

$$\text{error} = \max \left[\frac{|I_{\text{Carson}} - I_{\text{E-formulae}}|}{I_{\text{Carson}}} \right] \times 100 \% \quad (28)$$

Los resultados para los diferentes tipos de fallas se presentan a continuación. Es importante señalar que los resultados de fallas trifásicas y fallas línea a línea no se reportan, ya que no se observaron diferencias significativas entre los modelos de impedancia. Este comportamiento es esperado, porque estas fallas no involucran un camino de retorno por tierra; en consecuencia, todas las formulaciones convergen.

3.1. Alimentador de prueba IEEE de 13 nodos

El primer estudio de cortocircuito se realiza en el alimentador de prueba IEEE de 13 nodos, cuyo diagrama unifilar se muestra en la Figura 2. En el diagrama, las líneas continuas, punteadas y segmentadas representan configuraciones de líneas trifásicas, bifásicas y monofásicas, respectivamente.




Figura 2. Alimentador de prueba IEEE de 13 nodos.

Los datos completos del sistema están disponibles en [31]. La Tabla 5 resume los datos principales de los tramos de línea.

Tabla 5. Datos de los tramos de línea para el caso de estudio 1

Desde Node	Hasta Node	Config.	Fases	Longitud (ft)	Aérea o subterránea
632	633	602	3	500	A
632	645	603	2	500	A
632	671	601	3	2000	A
645	646	603	2	300	A
650	632	601	3	2000	A
671	680	601	3	1000	A
671	684	604	2	300	A
684	611	605	1	300	A
684	652	607	1	800	U
692	675	606	3	500	U

El tramo 671–692 no se incluye en la tabla porque corresponde a un seccionador de longitud cero. Las matrices de impedancia de los tramos subterráneos 684–652 y 692–675 se tomaron de [31]. Estas matrices se mantuvieron sin cambios, porque sus diferencias con respecto al modelo de Carson son menores al 0.01 % [34].

3.1.1. Falla trifásica a tierra

La Figura 3 presenta las diferencias porcentuales máximas en la corriente de cortocircuito entre el modelo de Carson y las formulaciones en forma cerrada de la impedancia de retorno por tierra para una falla trifásica a tierra.




Figura 3. Error porcentual máximo para una falla trifásica a tierra.

A partir de la Figura 3, es evidente que todas las formulaciones de impedancia en forma cerrada producen errores inferiores al 0.006 % para este tipo de falla. Entre ellas, la formulación de Noda presenta la mayor concordancia con el modelo de Carson, seguida —en orden decreciente de precisión— por las de Alvarado, Pizarro-Eriksson, Kersting y Deri. El mayor error porcentual ocurre en el nodo 680, que se encuentra a lo largo del trayecto trifásico más largo desde la fuente de cortocircuito, aproximadamente 5000 ft.

3.1.2. Falla línea a línea a tierra

La Figura 4 muestra los errores porcentuales máximos en la corriente de cortocircuito entre el modelo de Carson y las formulaciones en forma cerrada de la impedancia de retorno por tierra para una falla línea-a-línea-a-tierra.

Como se muestra en la Figura 4, las formulaciones de Noda presentan la mayor concordancia, seguidas por las de Alvarado y Pizarro-Eriksson. Las formulaciones de Kersting y Deri también muestran un buen desempeño, con errores que permanecen por debajo del 0.05 %.




Figura 4. Error porcentual máximo para una falla línea-a-línea-a-tierra.

El mayor error promedio ocurre en el nodo 680, el cual se encuentra a lo largo del tramo bifásico más largo desde la fuente de cortocircuito (aproximadamente 5000 ft). Cabe destacar que los nodos 645 y 646 también presentan errores relativamente grandes porque son nodos bifásicos; sin embargo, dado que los tramos de línea asociados son cortos, su efecto global sigue siendo limitado.

3.1.3. Falla monofásica a tierra

La Figura 5 presenta las diferencias porcentuales máximas en la corriente de cortocircuito entre el modelo de Carson y las formulaciones en forma cerrada de la impedancia de retorno por tierra para una falla monofásica a tierra.




Figura 5. Error porcentual máximo para una falla monofásica a tierra.

A partir de la Figura 5, es evidente que, para este tipo de falla, todas las formulaciones de impedancia de tierra producen errores inferiores al 0.21 %. De manera consistente con los otros casos de falla, la formulación de Noda presenta la mayor concordancia con el modelo de Carson, seguida de cerca por las de Alvarado y Pizarro–Eriksson, y luego por las de Kersting y Deri.

3.1.4. Análisis para el caso de estudio 1

Con base en los resultados de cortocircuito, se puede concluir que las discrepancias más grandes ocurren generalmente para las fallas monofásicas a tierra (0.21 %), seguidas por las fallas línea-a-línea-a-tierra (0.05 %) y, finalmente, por las fallas trifásicas a tierra (0.006 %). En todos los tipos de falla, la formulación de Noda proporciona la aproximación más precisa, seguida de cerca por las de Alvarado y Pizarro–Eriksson. Las formulaciones restantes de impedancia de tierra introducen errores que pueden no ser despreciables en ciertas aplicaciones, particularmente cuando se incluyen tramos de línea más largos.

Se lleva a cabo un análisis actualizado para examinar la relación entre los errores de modelado asociados

con las configuraciones de línea y los errores observados en los estudios de cortocircuito, con el objetivo de determinar si existe una correlación entre estos parámetros. Debido a que el nodo 680 presenta el mayor error de cortocircuito y la configuración 601 conecta el nodo fuente (650) con el nodo 680, la evaluación se centra en la configuración trifásica 601. Para esta configuración, el componente reactivo es aproximadamente tres veces mayor que el componente resistivo; por lo tanto, la parte imaginaria se adopta como referencia para el análisis de correlación.

La Tabla 6 resume la relación entre los errores de modelado de impedancia y los errores máximos de cortocircuito en el nodo 680. Los valores reportados se obtienen dividiendo los errores máximos de cortocircuito entre los errores máximos en la parte imaginaria de las impedancias correspondientes, de modo que razones mayores indican una correlación más fuerte.

Tabla 6. Relación entre los errores de impedancia y los resultados de cortocircuito

Formulaciones	Falla trifásica a tierra	Falla línea-a-línea-a-tierra	Falla monofásica a tierra
Deri-Dubanton	0.008	0.066	0.313
Kersting	0.008	0.116	0.240
Eriksson	0.008	0.055	0.311
Alvarado	0.010	0.041	0.301
Noda	0.036	0.120	0.355

A partir de la Tabla 6 se puede concluir que los errores de modelado de impedancia ejercen una influencia más fuerte en las fallas línea-a-tierra, como lo reflejan las razones mayores. Es importante señalar que esta evaluación se realizó únicamente para el nodo 680, que es un nodo trifásico. Para obtener una comprensión más completa, es necesario extender el mismo análisis a los nodos bifásicos y monofásicos asociados con tramos de línea más largos. Esta evaluación ampliada se aborda en los casos siguientes.

3.2. Líneas de distribución largas

El objetivo de este caso de estudio es examinar cómo la longitud de la línea afecta la magnitud de las corrientes de falla de cortocircuito. El análisis de cortocircuito se realiza en una sección del alimentador de prueba IEEE de 34 nodos, como se muestra en el diagrama unifilar de la Figura 6. En el diagrama, las líneas continuas, discontinuas y punteadas denotan configuraciones de líneas trifásicas, bifásicas y monofásicas, respectivamente.




Figura 6. Alimentador de prueba IEEE de 34 nodos.

La sección principal del alimentador hasta el nodo 816 se modela como una línea trifásica con la configuración 300 y una longitud de 105 060 ft. A partir del nodo 816, se consideran tres ramales: un ramal trifásico con la configuración 301, un ramal bifásico con la configuración 305 y un ramal monofásico con la configuración 302. Los datos clave de los tramos de línea se resumen en la Tabla 7.

Tabla 7. Datos de los tramos de línea para el caso de estudio 2

Desde Node	Hasta Node	Config	Fases	Longitud (ft)	Aérea o subterránea
800	816	300	3	105060	A
816	823	301	3	79200	A
816	822	305	2	79200	A
816	821	302	1	79200	A

Los resultados se presentan para los nodos terminales ubicados a 3, 6, 9, 12 y 15 millas aguas abajo del nodo trifásico 816.

3.2.1. Falla trifásica a tierra

La Figura 7 muestra las diferencias porcentuales máximas en la corriente de cortocircuito entre el modelo de Carson y las formulaciones en forma cerrada de la impedancia de retorno por tierra para una falla trifásica a tierra en el nodo 823.




Figura 7. Error porcentual máximo para una falla trifásica a tierra en el caso de estudio 2 (nodo 823).

A partir de la Figura 7, es evidente que todas las formulaciones en forma cerrada producen errores inferiores al 0.005 % para este tipo de falla.

3.2.2. Falla línea-línea-tierra

La Figura 8 muestra el error porcentual máximo en la corriente de cortocircuito entre el modelo de Carson y las formulaciones en forma cerrada de la impedancia de retorno por tierra para una falla línea-línea-tierra, correspondiente al caso bifásico.




Figura 8. Error porcentual máximo para una falla línea-línea-tierra en el caso de estudio 2 (nodo 822, bifásico).

El caso trifásico no se reporta porque es esencialmente idéntico al caso bifásico; ambos presentan un error máximo de 0.05 % para la formulación de Deri.

3.2.3. Falla monofásica a tierra

La Figura 9 muestra las diferencias porcentuales máximas en la corriente de cortocircuito entre el modelo de Carson y las formulaciones en forma cerrada de la impedancia de retorno por tierra para una falla monofásica a tierra, correspondiente al caso monofásico.




Figura 9. Error porcentual máximo para una falla monofásica a tierra en el caso de estudio 2 (nodo 821, monofásico).

De la Figura 9, es evidente que las formulaciones de Noda presentan la mayor concordancia con el modelo de Carson, seguidas por las de Alvarado, Eriksson y Kersting. Las formulaciones de Deri también muestran un desempeño satisfactorio, con errores que permanecen por debajo de 0.18 %. Cabe señalar que los casos trifásico y bifásico exhiben tendencias comparables a las de la configuración monofásica; por lo tanto, no se reportan.

3.2.4. Análisis para el caso de estudio 2

Con base en los resultados de cortocircuito, se puede concluir que las discrepancias más grandes ocurren generalmente para fallas monofásicas a tierra (0.19 %), seguidas por fallas doble línea a tierra (0.05 %) y, finalmente, fallas trifásicas a tierra (0.005 %). En todos los tipos de falla, las formulaciones de Noda proporcionan la aproximación más precisa, seguidas de cerca por los métodos de Alvarado y Eriksson. Las formulaciones restantes exhiben errores que pueden no ser despreciables en los cálculos de fallas línea a tierra.

Después de analizar los resultados del primer y segundo caso de estudio, es evidente que la falla línea a tierra constituye el escenario más crítico. En consecuencia, se realiza un análisis de correlación para examinar la relación entre los errores de modelado de las líneas y los resultados de los estudios de fallas línea a tierra. Para las configuraciones 302 y 305, que corresponden a líneas monofásicas y bifásicas, el componente resistivo es aproximadamente el doble del componente reactivo; por lo tanto, estas configuraciones se adoptan como los casos de referencia para esta evaluación.

La Tabla 8 resume la relación entre los errores de modelado de las líneas y los errores máximos obtenidos en los estudios de cortocircuito a una distancia de 15 millas desde el nodo 816. Los valores reportados en la Tabla 8 se calcularon como la razón entre los errores máximos de cortocircuito y los errores máximos en la parte real de las impedancias correspondientes. Valores más altos indican una correlación más fuerte.

Tabla 8. Relación entre el error de modelado de impedancia y los resultados de cortocircuito línea a tierra

Formulaciones	Config 301 (3 ϕ)	Config 305 (2 ϕ)	Config 302 (1 ϕ)
Deri-Dubanton	0.137	0.125	1.507
Kersting	0.163	0.106	1.245
Eriksson	0.148	0.137	1.634
Alvarado	0.180	0.168	2.039
Noda	0.107	0.093	1.177

A partir de la Tabla 8, se puede concluir que el error de modelado de impedancia es más influyente en la configuración monofásica, como lo evidencian las razones mayores. Esto indica una relación estrecha entre el error de modelado de la línea y el error de falla

línea a tierra para líneas monofásicas. Con respecto a las configuraciones trifásica y bifásica, la influencia del error de modelado en los cálculos de cortocircuito también sigue siendo significativa, en concordancia con los hallazgos del caso de estudio 1; no obstante, la configuración monofásica continúa representando el caso crítico. Finalmente, para abarcar todas las condiciones de operación relevantes, deben considerarse líneas extremadamente largas, y este escenario se examina en el caso de estudio final.

3.3. Líneas de distribución muy largas

El objetivo de este tercer caso de estudio es examinar las magnitudes de las fallas de cortocircuito en líneas de distribución extremadamente largas (mayores a 50 millas), abarcando así todos los escenarios relevantes en el modelado de sistemas de distribución. La Figura 10 ilustra el sistema adoptado para este análisis, el cual se fundamenta en el alimentador de prueba IEEE de 13 nodos. Específicamente, el tramo de línea aérea entre los nodos 650 y 632 se extiende hasta una longitud total de 50 millas. Esta línea utiliza la configuración trifásica 601, con parámetros proporcionados en la Tabla 1. Solo se considera el caso trifásico, dado que las líneas de distribución extremadamente largas suelen implementarse mediante configuraciones trifásicas.




Figura 10. Error porcentual máximo para una falla monofásica a tierra en el caso de estudio 3.

3.3.1. Resultados de cortocircuito

La Figura 10 ilustra las diferencias porcentuales máximas en la corriente de cortocircuito entre el modelo de Carson y las formulaciones en forma cerrada de la impedancia de retorno a tierra para una falla monofásica a tierra.

A partir de la Figura 10, es evidente que las formulaciones de Noda presentan la mayor concordancia con el modelo de Carson, seguidas por las de Alvarado, Eriksson y Kersting. Las formulaciones de Deri también muestran un desempeño satisfactorio, con errores que permanecen por debajo de 0.27 %.

Los resultados para las fallas trifásicas a tierra y de doble línea a tierra no se reportan porque presentan un comportamiento similar al mostrado en las figuras 7 y 8 del caso de estudio 2. El error porcentual máximo es de 0.007 % para la falla trifásica a tierra y de 0.04 % para la falla de doble línea a tierra.

3.3.2. Análisis para el caso de estudio 3

El estudio de la falla trifásica a tierra muestra que todas las formulaciones de impedancia de tierra en forma cerrada producen errores máximos inferiores a 0.007 %. Surge una tendencia consistente al comparar estos resultados con los de los casos de estudio 1 y 2. Específicamente, el caso de estudio 1 reportó un error máximo de 0.006 % a 1 milla de la fuente, mientras que el caso de estudio 2 mostró un error máximo de 0.005 % a 15 millas. En conjunto, estos hallazgos indican que las formulaciones de impedancia de tierra en forma cerrada consideradas son suficientemente precisas para modelar fallas trifásicas a tierra.

Para las fallas línea a línea a tierra, todas las formulaciones de impedancia de tierra en forma cerrada exhiben errores máximos de aproximadamente 0.04 %. Este resultado es coherente con los casos de estudio 1 y 2, que reportaron errores máximos de 0.05 % a 2000 ft y 15 millas, respectivamente. En todos los casos, el error máximo se mantiene por debajo de 0.05 %, lo que indica que las formulaciones de impedancia de tierra en forma cerrada consideradas son suficientemente precisas para modelar este tipo de falla.

Para las fallas línea a tierra (monofásicas a tierra), todas las formulaciones de impedancia de tierra en forma cerrada exhiben errores máximos de 0.27 %. El caso de estudio 1 reportó un error máximo de 0.21 % a 5000 ft, mientras que el caso de estudio 2 mostró un error máximo de 0.19 % a 15 millas. En los tres casos de estudio, el error máximo se mantiene por debajo de 0.27 %.

Con base en los resultados de este estudio de cortocircuito, se puede concluir que las discrepancias más grandes ocurren generalmente para las fallas línea a tierra (0.27 %), seguidas por las fallas doble línea a tierra (0.04 %) y, finalmente, por las fallas trifásicas a tierra (0.007 %). Entre las formulaciones evaluadas, el modelo de Noda proporciona la aproximación más precisa en todos los tipos de falla, seguido de cerca por los modelos de Alvarado y Eriksson. En contraste, las formulaciones restantes pueden introducir errores no despreciables en los cálculos de fallas línea a tierra, particularmente en aplicaciones que requieren alta precisión. Estas conclusiones son coherentes con las tendencias observadas en los casos de estudio analizados previamente y son directamente relevantes para investigaciones en curso que examinan la influencia de la generación distribuida en las magnitudes de corriente de cortocircuito [22], [35, 36].

Se lleva a cabo un análisis de correlación para examinar la relación entre las magnitudes de error en el modelado de líneas y los resultados de los estudios de cortocircuito. Para la configuración 601, el componente reactivo es aproximadamente tres veces mayor que el componente resistivo; por lo tanto, la parte reactiva se adopta como referencia para esta evaluación. La Tabla 9 presenta la relación entre los errores de modelado de la línea y los errores máximos de cortocircuito observados a una distancia de 50 millas desde el nodo 650. Los valores reportados en la Tabla 9 se calculan dividiendo los errores máximos de cortocircuito entre los errores máximos de modelado asociados con la parte reactiva de las impedancias correspondientes.

Tabla 9. Relación entre el error de modelado de impedancia y los resultados de cortocircuito

Formulaciones	Falla trifásica a tierra	Falla línea-a-línea-a-tierra	Falla monofásica a tierra
Deri-Dubanton	0.009	0.056	0.397
Kersting	0.010	0.116	0.294
Eriksson	0.009	0.046	0.392
Alvarado	0.009	0.040	0.378
Noda	0.013	0.120	0.467

A partir de la Tabla 9, se puede concluir que los errores de modelado de impedancia son más relevantes para las fallas línea a tierra, como lo evidencia la fuerte correlación observada para la mayoría de las formulaciones de impedancia de tierra en forma cerrada. En contraste, para las fallas trifásicas y las fallas línea a línea, no emerge una relación clara entre los errores de modelado de impedancia y los resultados de cortocircuito. En consecuencia, para líneas de distribución muy largas, la elección de la formulación de impedancia de tierra tiene una influencia insignificante en los cálculos de cortocircuito bajo estas condiciones de falla.

4. Conclusiones

Este estudio presentó, de manera integral y accesible, las formulaciones de impedancia de retorno a tierra en forma cerrada más ampliamente utilizadas para el análisis de cortocircuito en sistemas de distribución. Estas formulaciones se aplicaron para modelar configuraciones de líneas monofásicas, bifásicas y trifásicas representativas de redes de distribución prácticas. Su precisión en impedancia se cuantificó mediante comparaciones de error porcentual con respecto al modelo de referencia de Carson.

Después de la etapa de modelado de las líneas, se llevaron a cabo tres casos de estudio de cortocircuito. El primero examinó un alimentador con líneas cortas (menores a 1 milla), el segundo consideró líneas de longitud media (hasta 15 millas) y el tercero evaluó líneas muy largas (hasta 50 millas). En cada caso, se

determinó el error porcentual entre las corrientes de cortocircuito calculadas utilizando las formulaciones en forma cerrada y aquellas obtenidas con el modelo de Carson.

En todos los estudios, las fallas línea a tierra produjeron consistentemente los mayores errores porcentuales, seguidas por las fallas línea a línea a tierra, mientras que las fallas trifásicas a tierra mostraron los errores más pequeños. Es importante destacar que las fallas trifásicas y las fallas línea a línea exhibieron diferencias insignificantes entre las formulaciones estudiadas y el modelo de Carson.

Para todos los casos, el error máximo para las fallas trifásicas a tierra se mantuvo por debajo de 0.007 %, y para las fallas línea a línea a tierra por debajo de 0.04 %, lo que confirma que todas las formulaciones en forma cerrada consideradas son adecuadas para modelar estas categorías de falla. En contraste, las fallas línea a tierra alcanzaron un error máximo de 0.27 %, lo que indica que la selección de la formulación de impedancia de retorno a tierra puede ser determinante en estudios donde se requiere alta precisión en los cálculos de cortocircuito.

Entre las formulaciones evaluadas, el modelo de Noda proporcionó sistemáticamente la aproximación más precisa al modelo de referencia de Carson, seguido de cerca por las formulaciones de Alvarado y Eriksson, mientras que las de Kersting y Deri produjeron las mayores desviaciones. En general, las formulaciones con representaciones de imágenes complejas más elaboradas tendieron a alcanzar una mayor precisión. No obstante, excepto en las fallas línea a tierra, las formulaciones más simples parecen ser suficientes para los estudios de cortocircuito y pueden preferirse cuando la reducción del esfuerzo computacional es una prioridad.

El análisis de correlación mostró, además, que para las fallas trifásicas y línea a línea a tierra, los errores de modelado de impedancia no se traducen en errores apreciables en los cálculos de cortocircuito. En cambio, se observó una fuerte correlación para las fallas línea a tierra, particularmente en configuraciones monofásicas, lo que subraya que un modelado preciso de la impedancia de retorno a tierra es crítico en estos escenarios.

En general, las formulaciones de impedancia de retorno a tierra en forma cerrada investigadas son adecuadas para el análisis de cortocircuitos en sistemas de distribución. Sin embargo, para las fallas monofásicas a tierra en líneas monofásicas, la elección de la formulación en forma cerrada es crucial para garantizar resultados de cortocircuito precisos.

Rol de autores

- **Allen A. Castillo Barrón:** conceptualización, análisis formal, metodología, administración del

proyecto, escritura – borrador original, escritura – revisión y edición.

- **Gerardo Ayala Jaimés:** Recursos, software, visualización, escritura – borrador original, escritura – revisión y edición.
- **Alejandra Jiménez Vega:** Investigación, supervisión, validación.
- **Francisco J. Ramírez Arias:** Curación de datos, software, visualización.

Referencias

- [1] T. A. Papadopoulos, A. I. Chrysochos, C. K. Traianos, and G. Papagiannis, “Closed-form expressions for the analysis of wave propagation in overhead distribution lines,” *Energies*, vol. 13, no. 17, p. 4519, Sep. 2020. [Online]. Available: <https://doi.org/10.3390/en13174519>
- [2] R. Cleenwerck, H. Azaioud, R. Claeys, T. Coosemans, J. Knockaert, and J. Desmet, “An approach to the impedance modelling of low-voltage cables in digital twins,” *Electric Power Systems Research*, vol. 210, p. 108075, Sep. 2022. [Online]. Available: <http://doi.org/10.1016/j.epsr.2022.108075>
- [3] J. Zhang, F. Geth, R. Heidari, and G. Verbič, “Beyond simplifications: Evaluating assumptions for low-voltage network modelling in the DER era,” *Sustainable Energy, Grids and Networks*, vol. 43, p. 101860, Sep. 2025. [Online]. Available: <http://doi.org/10.1016/j.segan.2025.101860>
- [4] J. R. Carson, “Wave propagation in overhead wires with ground return,” *Bell System Technical Journal*, vol. 5, no. 4, pp. 539–554, Oct. 1926. [Online]. Available: <http://doi.org/10.1002/j.1538-7305.1926.tb00122.x>
- [5] W. H. Wise, “Effect of ground permeability on ground return circuits,” *Bell System Technical Journal*, vol. 10, no. 3, pp. 472–484, Jul. 1931. [Online]. Available: <http://doi.org/10.1002/j.1538-7305.1931.tb01287.x>
- [6] W. Wise, “Propagation of high-frequency currents in ground return circuits,” *Proceedings of the IRE*, vol. 22, no. 4, pp. 522–527, Apr. 1934. [Online]. Available: <http://doi.org/10.1109/JRPROC.1934.225868>
- [7] E. D. Sunde, *Earth Conduction Effects in Transmission Systems*. Dover Publications, 1968. [Online]. Available: <https://upsalesiana.ec/ing35ar5r7>

- [8] H. Wohlfarth, "Calculation of ground impedances," *IEEE Transactions on Power Delivery*, vol. 39, no. 4, pp. 2113–2124, Aug. 2024. [Online]. Available: <https://doi.org/10.1109/TPWRD.2024.3388570>
- [9] C. Dubanton, "Calcul approché des paramètres primaires et secondaires d'une ligne de transport," *EDF Bulletin de la Direction des Études et Recherches*, no. 1, pp. 53–62, 1969, cited by: 16. [Online]. Available: <https://upsalesiana.ec/ing35ar5r10>
- [10] A. Deri, G. Tevan, A. Semlyen, and A. Castanheira, "The complex ground return plane a simplified model for homogeneous and multi-layer Earth return," *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-100, no. 8, pp. 3686–3693, Aug. 1981. [Online]. Available: <https://doi.org/10.1109/TPAS.1981.317011>
- [11] F. Alvarado and R. Betancourt, "An accurate closed-form approximation for ground return impedance calculations," *Proceedings of the IEEE*, vol. 71, no. 2, pp. 279–280, 1983. [Online]. Available: <https://doi.org/10.1109/PROC.1983.12573>
- [12] M. Pizarro and R. Eriksson, "Modelling of the ground mode of transmission lines in time domain simulations," *7th Int. Symp. on High Voltage Engineering*, pp. 179–182, 1991.
- [13] T. Noda, "A double logarithmic approximation of Carson's ground-return impedance," *IEEE Transactions on Power Delivery*, vol. 21, no. 1, pp. 472–479, Jan. 2006. [Online]. Available: <https://doi.org/10.1109/TPWRD.2005.852307>
- [14] W. Kersting and W. Phillips, "Distribution feeder line models," *IEEE Transactions on Industry Applications*, vol. 31, no. 4, pp. 715–720, 1995. [Online]. Available: <https://doi.org/10.1109/28.395276>
- [15] T. Theodoulidis, "On the closed-form expression of Carson's integral," *Periodica Polytechnica Electrical Engineering and Computer Science*, vol. 59, no. 1, pp. 26–29, 2015. [Online]. Available: <https://doi.org/10.3311/PPEe.7894>
- [16] T. Martins, A. Lima, and S. Carneiro, "Effect of approximate impedance formulae on the accuracy of transmission line modelling," *IET Generation, Transmission & Distribution*, vol. 1, no. 4, pp. 534–539, Jul. 2007. [Online]. Available: <https://doi.org/10.1049/iet-gtd:20060289>
- [17] O. Ramos-Leanos, J. L. Naredo, F. A. Uribe, and J. L. Guardado, "Accurate and approximate evaluation of power-line Earth impedances through the Carson integral," *IEEE Transactions on Electromagnetic Compatibility*, vol. 59, no. 5, pp. 1465–1473, Oct. 2017. [Online]. Available: <https://doi.org/10.1109/TEMC.2017.2679213>
- [18] S. Li and D. Tylavsky, "Analytic continuation as the origin of complex distances in impedance approximations," *International Journal of Electrical Power & Energy Systems*, vol. 105, pp. 699–708, Feb. 2019. [Online]. Available: <https://doi.org/10.1016/j.ijepes.2018.09.022>
- [19] K. Gampa, S. A. Vemprala, and S. M. Brahma, "Errors in fault analysis of power distribution systems using sequence components approach," in *IEEE PES T&D 2010*. IEEE, 2010, pp. 1–6. [Online]. Available: <https://doi.org/10.1109/TDC.2010.5484378>
- [20] R. S. F. Ferraz, R. S. F. Ferraz, A. C. Rueda-Medina, and M. H. M. Paiva, "Power flow and fault analysis using graph theory," in *2021 IEEE URUCON*. IEEE, Nov. 2021, pp. 6–11. [Online]. Available: <https://doi.org/10.1109/URUCON53396.2021.9647053>
- [21] A. Suresh, K. Murari, S. Kamalasan, and S. Paudyal, "Steady-state fault analysis of unbalanced power distribution network utilizing a novel sequence component based methodology," in *2023 IEEE Industry Applications Society Annual Meeting (IAS)*. IEEE, Oct. 2023, pp. 1–6. [Online]. Available: <https://doi.org/10.1109/IAS54024.2023.10406399>
- [22] J. He, Z. Li, W. Li, J. Zou, X. Li, and F. Wu, "Fast short-circuit current calculation of unbalanced distribution networks with inverter-interfaced distributed generators," *International Journal of Electrical Power & Energy Systems*, vol. 146, p. 108728, Mar. 2023.
- [23] R. Galloway, W. Shorrocks, and L. Wedepohl, "Calculation of electrical parameters for short and long polyphase transmission lines," *Proceedings of the Institution of Electrical Engineers*, vol. 111, no. 12, p. 2051, 1964. [Online]. Available: <https://doi.org/10.1049/piee.1964.0331>
- [24] M. Cenký, J. Bendík, B. Cintula, P. Janiga, A. Belan, and Z. Eleschová, "Three-phase and single-phase measurement of overhead power line capacitance evaluation," *Electrical Engineering*, vol. 105, no. 2, pp. 1045–1065, Jan. 2023. [Online]. Available: <https://doi.org/10.1007/s00202-022-01714-1>
- [25] W. Kersting, "Radial distribution test feeders," in *2001 IEEE Power Engineering Society Winter Meeting. Conference Proceedings*

- (*Cat. No.01CH37194*), ser. PESW-01, vol. 2. IEEE, 2001, pp. 908–912. [Online]. Available: <https://doi.org/10.1109/PESW.2001.916993>
- [26] K. P. Schneider, B. A. Mather, B. C. Pal, C.-W. Ten, G. J. Shirek, H. Zhu, J. C. Fuller, J. L. R. Pereira, L. F. Ochoa, L. R. de Araujo, R. C. Dugan, S. Matthias, S. Paudyal, T. E. McDermott, and W. Kersting, “Analytic considerations and design basis for the IEEE distribution test feeders,” *IEEE Transactions on Power Systems*, vol. 33, no. 3, pp. 3181–3188, May 2018. [Online]. Available: <https://doi.org/10.1109/TPWRS.2017.2760011>
- [27] I. Kim, “A short-circuit analysis algorithm capable of analyzing unbalanced loads and phase shifts through transformers using the Newton-Raphson power-flow calculation, sequence, and superposition methods,” *International Transactions on Electrical Energy Systems*, vol. 31, no. 4, Oct. 2020. [Online]. Available: <https://doi.org/10.1002/2050-7038.12653>
- [28] G. Meena, A. Mathur, V. P. Singh, K. Murari, and S. Kamalasadán, “Efficient evaluation of short-circuit faults in active distribution networks,” in *2024 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)*. IEEE, Dec. 2024, pp. 1–6. [Online]. Available: <https://doi.org/10.1109/PEDES61459.2024.10961501>
- [29] T. F. Garbelim Pascoalato, A. R. Justo de Araújo, S. Kurokawa, and J. P. Filho, “Effects of frequency-dependent soil electrical parameters on sequence parameters of double-circuit transmission lines,” *Electric Power Systems Research*, vol. 247, p. 111724, Oct. 2025. [Online]. Available: <https://doi.org/10.1016/j.epsr.2025.111724>
- [30] A. A. Castillo, A. L. López, N. A. Barboza Tello, I. Uriarte, and A. Jiménez, “A comparison of models for calculating distribution lines impedance,” in *2018 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)*. IEEE, Nov. 2018, pp. 1–6. [Online]. Available: <https://doi.org/10.1109/ROPEC.2018.8661470>
- [31] IEEE. Resources – IEEE PES Test Feeder. Institute of Electrical and Electronics Engineers. [Online]. Available: <https://upsalesiana.ec/ing35ar5r32>
- [32] W. H. Kersting, *Distribution System Modeling and Analysis, Third Edition*. CRC Press, 2012. [Online]. Available: <https://upsalesiana.ec/ing35ar5r33>
- [33] W. H. Kersting and G. Shirek, “Short circuit analysis of IEEE test feeders,” in *PES T&D 2012*. IEEE, May 2012, pp. 1–9. [Online]. Available: <http://doi.org/10.1109/TDC.2012.6281539>
- [34] W. H. Kersting and R. K. Green, “The application of Carson’s equation to the steady-state analysis of distribution feeders,” in *2011 IEEE/PES Power Systems Conference and Exposition*. IEEE, Mar. 2011, pp. 1–6. [Online]. Available: <http://doi.org/10.1109/PSCE.2011.5772579>
- [35] F. Rongqi, L. Kuan, H. Qiang, J. Panpan, and W. Anning, “Calibration of distributed PV setting calculation model and simulation calculation model based on short-circuit test of distribution network,” in *2023 IEEE 11th Joint International Information Technology and Artificial Intelligence Conference (ITAIC)*. IEEE, Dec. 2023, pp. 603–607. [Online]. Available: <http://doi.org/10.1109/ITAIC58329.2023.10408848>
- [36] J. Hoeksema, R. Torkzadeh, J. Van Waes, S. Cobben, and V. Čuk, “A case study on the future changes in short circuit power to analyze the impact on voltage dips,” *IET Conference Proceedings*, vol. 2023, no. 6, pp. 1330–1334, Jul. 2023. [Online]. Available: <http://doi.org/10.1049/icp.2023.0707>



CLASIFICACIÓN AUTOMÁTICA DE RECLAMOS ELÉCTRICOS MEDIANTE ÁRBOLES DE DECISIÓN Y RANDOM FOREST: UN ESTUDIO APLICADO A CNEL EP

AUTOMATIC CLASSIFICATION OF ELECTRICAL COMPLAINTS USING DECISION TREES AND RANDOM FOREST: AN APPLIED STUDY AT CNEL EP

Francisco Javier Carpio Velasco^{1,*} , Gloria Margarita Garcés Beltrán² 

Recibido: 03-10-2025, Recibido tras revisión: 11-11-2025, Aceptado: 18-11-2025, Publicado: 01-01-2026

Resumen


Este estudio presenta un sistema de clasificación automática destinado a priorizar reclamos eléctricos en CNEL EP. Para ello se procesaron 143 113 registros reales, incluyendo limpieza de datos, imputación de valores faltantes y la creación de variables predictivas relacionadas con la urgencia y la recurrencia de los reclamos. A partir de estos criterios se construyó la variable objetivo “prioridad”, que permite distinguir entre reclamos prioritarios y normales. Con esta información se entrenaron modelos de aprendizaje supervisado —árbol de decisión y random forest— aplicando técnicas como one-hot encoding y validación cruzada. El modelo random forest obtuvo los mejores resultados, con una exactitud del 91 % y un AUC-ROC de 0.89. Los resultados muestran que el sistema propuesto puede mejorar significativamente la asignación de recursos técnicos y los tiempos de respuesta ante reclamos eléctricos. Además, demuestra la viabilidad de incorporar técnicas de aprendizaje automático en la gestión operativa de empresas distribuidoras de electricidad, abriendo posibilidades para futuras mejoras y aplicaciones en tiempo real.


Palabras clave: reclamos eléctricos, clasificación automática, aprendizaje supervisado, árbol de decisión, random forest, aprendizaje automático

Abstract

This study presents an automated classification system to prioritize electrical service complaints at CNEL EP. A total of 143,113 real records were processed through data cleaning, missing-value imputation, and the engineering of predictive variables reflecting complaint urgency and recurrence. Based on these criteria, the target variable “Priority” was defined to distinguish high-priority from normal complaints. Supervised learning models, specifically Decision Tree and Random Forest, were then trained using one-hot encoding and cross-validation. Random Forest delivered the best performance, achieving 91% accuracy and an AUC-ROC of 0.89. These results indicate that the proposed system can significantly improve technical resource allocation and reduce response times for electrical complaints. Moreover, the study demonstrates the feasibility of integrating machine-learning techniques into the operational management of electric distribution companies, enabling future enhancements and real-time deployment.

Keywords: electrical complaints, automatic classification, supervised learning, Decision Tree, Random Forest, machine learning

^{1,*}Facultad de Ciencias de la Ingeniería e Industrias, Universidad UTE, Santo Domingo de los Tsáchilas, Ecuador. 

²Facultad de Derecho, Ciencias Administrativas y Sociales, Universidad UTE, Santo Domingo de los Tsáchilas, Ecuador.  Autor para correspondencia ✉: francisco.carpio@ute.edu.ec.

Forma sugerida de citación: F. J. Carpio Velasco y G. M. Garcés Beltrán, “Clasificación automática de reclamos eléctricos mediante árboles de decisión y random forest: un estudio aplicado a CNEL EP,” *Ingenius, Revista de Ciencia y Tecnología*, N.º 35, pp. 84-96, 2026. DOI: <https://doi.org/10.17163/ings.n35.2026.06>.

1. Introducción

La creciente complejidad del sector eléctrico exige la adopción de herramientas de gestión del conocimiento y tecnologías inteligentes que permitan mejorar la toma de decisiones operativas y optimizar la atención al usuario [1]. En este contexto, diversos estudios han demostrado que la clasificación estructurada de servicios permite orientar estrategias de sostenibilidad y eficiencia, tanto en entornos industriales como sociales [2].

En el ámbito eléctrico, la clasificación de clientes mediante técnicas de agrupamiento ha sido ampliamente explorada, destacando el uso de algoritmos como *k-means*, *fuzzy clustering* y mapas autoorganizados, los cuales permiten identificar patrones de consumo y segmentar la atención técnica [3,4]. Estas metodologías han sido validadas en aplicaciones reales, donde se ha evidenciado su capacidad para mejorar la asignación de recursos y la respuesta operativa.

La priorización de reclamos eléctricos puede fundamentarse en estudios que estiman el costo de interrupción para el cliente, diferenciando el impacto económico según el tipo de afectación [5]. Asimismo, el uso de datos eléctricos para la inferencia automática ha sido explorado en investigaciones que demuestran la posibilidad de detectar propiedades relevantes mediante trazas de consumo y algoritmos de clasificación supervisada [6].

La atención eficiente de reclamos eléctricos tiene un impacto directo en la satisfacción del cliente, como lo evidencian estudios recientes en contextos latinoamericanos [7]. En Ecuador, se han documentado concentraciones significativas de reclamos en zonas como Manabí, donde los consumidores reportaron incrementos tarifarios superiores a los observados en otras ciudades como Guayaquil [8]. Además, investigaciones aplicadas en CNEL EP han revelado deficiencias en la percepción del servicio, lo que evidencia la necesidad de mejorar los mecanismos de atención al usuario externo [9].

Durante la pandemia, se intensificaron las prácticas de facturación excesiva, lo que motivó propuestas para implementar mecanismos ágiles de atención [10]. La calidad del servicio técnico en Ecuador ha sido evaluada mediante indicadores como FMik y TTik, los cuales permiten identificar zonas críticas y justificar la necesidad de priorización operativa [11]. Incluso a nivel internacional, casos como el de Cartagena (Colombia) han mostrado que las deficiencias en el servicio eléctrico pueden derivar en tensiones sociales y conflictos comunitarios [12].

La calidad del servicio eléctrico ha sido identificada como un factor determinante en la satisfacción y lealtad del cliente, especialmente en contextos de monopolio público [13]. Sin embargo, estudios recientes han evidenciado que la calidad percibida, evaluada mediante dimensiones SERVQUAL, no siempre se traduce en satisfacción del cliente, como lo demuestra el

caso de IBEDC en Nigeria [14]. En esa línea, la orientación del personal hacia el cliente también influye significativamente en la percepción del servicio, tal como lo evidencian estudios aplicados en Ghana [15].

En el contexto de redes eléctricas modernas, la identificación y clasificación de fallas se ha convertido en una tarea crítica para garantizar la estabilidad operativa. El avance de sensores inteligentes y herramientas de comunicación ha transformado los sistemas tradicionales en redes inteligentes capaces de integrar generación distribuida y automatización. Según Sarathkumar *et al.* [16], los métodos actuales de detección y mitigación de fallas requieren una revisión profunda para enfrentar las limitaciones de los sistemas inteligentes, proponiendo el uso de tecnologías avanzadas que mejoren la estabilidad transitoria, la capacidad de autorrecuperación y la calidad del suministro eléctrico.

La incorporación de redes neuronales profundas en sistemas eléctricos ha demostrado ser una estrategia eficaz para mejorar la detección y clasificación de fallas. Alhanaf *et al.* [17] proponen métodos basados en ANN y 1D-CNN que, utilizando datos de sensores como voltaje y corriente, alcanzan tasas de precisión superiores al 99 % en la identificación de líneas defectuosas y tipos de falla. Estos resultados refuerzan el potencial de los modelos supervisados para automatizar procesos críticos en redes eléctricas, potencial que puede extrapolarse a la clasificación técnica de reclamos institucionales.

La confiabilidad de las redes eléctricas modernas depende de la capacidad para identificar y clasificar fallas en múltiples capas del sistema. Krivohlava *et al.* [18] realizaron una revisión sistemática de 30 tipos de fallas en infraestructuras de smart grid, abarcando componentes físicos, de software, de comunicación y de negocio. Su propuesta de clasificación, basada en el modelo SGAM, ofrece un marco técnico que puede ser adaptado a contextos institucionales para mejorar la gestión de reclamos eléctricos y fortalecer la resiliencia operativa.

La clasificación automática de fallas eléctricas ha evolucionado mediante el uso de algoritmos híbridos que combinan reducción de dimensionalidad y discriminación supervisada. Hosseinzadeh *et al.* [19] proponen un modelo basado en PCA, LDA y k-NN que mejora la precisión en la detección y clasificación de fallas en redes inteligentes. Este enfoque demuestra que, ante la variabilidad de carga y limitaciones de los modelos tradicionales, los algoritmos de aprendizaje supervisado ofrecen una solución eficaz y adaptable, aplicable también a la gestión técnica de reclamos eléctricos.

La predicción de eventos extremos en sistemas eléctricos requiere modelos que integren criterios técnicos y operativos. Mohammadian *et al.* [20] proponen un clasificador basado en la teoría de decisión de Bayes,

que, además de minimizar errores de predicción, considera el costo de cada acción preventiva. Este enfoque permite tomar decisiones orientadas a la resiliencia del sistema, enfoque que puede extrapolarse a la clasificación de reclamos eléctricos institucionales, especialmente cuando se busca priorizar según impacto y urgencia.

Rana [21] presenta una revisión sistemática de 180 estudios que demuestran cómo los enfoques basados en inteligencia artificial, incluyendo machine learning, digital twins y self-healing grids, superan a los métodos tradicionales en precisión, adaptabilidad y eficiencia operativa. Estos hallazgos refuerzan la viabilidad de aplicar modelos supervisados para clasificar reclamos eléctricos institucionales, anticipar fallas y optimizar la respuesta técnica.

En años recientes, se han propuesto mejoras al algoritmo random forest para superar limitaciones de correlación y baja precisión en algunos árboles de decisión. Sun *et al.* [22] desarrollaron un random forest mejorado que incorpora mecanismos de selección de árboles basados en exactitud y reducción de correlación, demostrando un desempeño superior frente a versiones tradicionales. Jing *et al.* [23] propusieron un enfoque híbrido de mantenimiento predictivo para medidores eléctricos, combinando LSTM y XGBoost con un algoritmo de optimización mejorado, logrando mejoras significativas en precisión y eficiencia operativa. Husain *et al.* [24] evaluaron el desempeño de múltiples algoritmos de aprendizaje automático, incluyendo random forest y Gradient Boosting, para la predicción del consumo energético en vehículos eléctricos, lo que evidenció la eficacia de los ensambles en la captura de patrones complejos. Khalili *et al.* [25] aplicaron CatBoost y ExtraTrees en mantenimiento predictivo de bombas sumergibles, logrando alta exactitud y sensibilidad para identificar fallas críticas. Estos estudios recientes refuerzan la aplicabilidad de los modelos de ensamblado para la priorización de reclamos eléctricos en contextos institucionales.

Diversos estudios han evidenciado que las técnicas de aprendizaje automático pueden optimizar de manera significativa los procesos operativos en las empresas de distribución eléctrica. Por ejemplo, Ahmad y Chen [26] desarrollaron modelos basados en ML, incluyendo CDT, k-NN y LRM, para la predicción de demanda eléctrica a corto y mediano plazo, demostrando mejoras sustanciales en la exactitud, incluso cuando se dispone únicamente de datos climáticos incompletos. Este tipo de aportes refuerza la pertinencia de aplicar modelos de aprendizaje automático en tareas críticas del sector eléctrico, como, en nuestro caso, la priorización automática de reclamos.

Zhang *et al.* [27] realizan una revisión integral sobre el uso de técnicas de machine learning para la detección de pérdidas no técnicas en empresas de distribución eléctrica, lo que evidencia que los algoritmos

supervisados permiten identificar patrones irregulares de consumo y contribuir de manera efectiva a la reducción del fraude energético.

Según Ausmus *et al.* [28], el análisis de macrodatos se ha consolidado como una herramienta clave para el sector eléctrico, al permitir procesar grandes volúmenes de datos provenientes de sistemas SCADA o de unidades de medición fasorial (PMU), mejorando así la toma de decisiones operativas en tiempo real. Este enfoque respalda la integración de técnicas de machine learning para optimizar la priorización de reclamos eléctricos y promover una gestión más eficiente de los recursos técnicos.

Estudios recientes evidencian que modelos supervisados basados en árboles de decisión permiten identificar automáticamente zonas de eventos en sistemas eléctricos, mejorando la gestión de interrupciones y el mantenimiento de activos [29]. Este enfoque respalda la aplicabilidad de técnicas similares para la priorización automática de reclamos eléctricos, optimizando la respuesta operativa y la asignación de recursos.

En el ámbito de la clasificación de incidencias en sistemas de distribución eléctrica, diversos estudios han aportado metodologías relevantes. Por ejemplo, Shen *et al.* [30] demostraron que la integración de técnicas de reducción de dimensionalidad junto con redes neuronales convolucionales (CNN) mejora significativamente la detección automática de perturbaciones en sistemas eléctricos, consolidando así el valor de los enfoques basados en aprendizaje automático para el análisis y diagnóstico de fallas.

Xu *et al.* [31] demostraron que técnicas como la regresión logística y las redes neuronales pueden emplearse de manera efectiva para identificar automáticamente las causas de fallas en sistemas de distribución, incluso bajo condiciones de datos desbalanceados y en escenarios prácticos complejos.

Kumwenda *et al.* [32] desarrollaron un modelo de clasificación para redes de baja tensión utilizando datos sintéticos y reales, demostrando que los métodos basados en ensambles, particularmente bagged trees, alcanzan altos niveles de exactitud en la identificación de disturbios del sistema.

En este contexto, el presente trabajo propone y valida un modelo de clasificación supervisada para la priorización automática de reclamos eléctricos, utilizando un conjunto real de 143 113 registros de CNEL EP (Ecuador). La metodología incluye limpieza de datos, construcción de variables derivadas (urgencia y recurrencia por zona/mes) y la implementación de clasificadores como árboles de decisión y random forest. Los resultados evidencian una alta exactitud en la identificación de reclamos prioritarios, demostrando la viabilidad de integrar técnicas de machine learning en la gestión operativa del sector eléctrico.

2. Materiales y métodos

En este estudio, se desarrolló un sistema de clasificación automática de reclamos técnicos en el sistema eléctrico ecuatoriano, utilizando algoritmos de aprendizaje supervisado. La metodología incluyó seis etapas: la recolección y exploración de los datos institucionales de CNEL EP, el preprocesamiento de la base de datos,

la ingeniería de características (*feature engineering*), la preparación del conjunto de datos, el diseño y entrenamiento de los modelos de clasificación (árbol de decisión y random forest) y, finalmente, la evaluación del desempeño mediante métricas estándar de clasificación. En la Figura 1 se describe cada una de estas etapas.



Figura 1. Esquema global de la metodología utilizada.

2.1. Recolección de datos

Se recopiló una base de datos institucional de CNEL EP que contiene 143 113 registros históricos de reclamos técnicos. Cada registro incluye variables como unidad de negocio, mes, estado del trámite, tipo de

reclamo y clasificación del incidente reportado. Esta información permitió construir un conjunto representativo de casos reales para el entrenamiento de modelos supervisados. La Tabla 1 muestra un ejemplo de los primeros diez registros, lo que evidencia la estructura y diversidad de los datos.

Tabla 1. Ejemplo de registros de la base de datos de reclamos eléctricos de CNEL EP

Id trámite	Unidad de negocio	Mes	Estado	Tipo de reclamo	Clasificación
01521	MAN	Jul-21	Finalizado	Técnicos	Variación de voltaje
01522	STE	Jul-21	Finalizado	Técnicos	Sin luz en sector/cortocircuito
01523	GYE	Jul-21	Finalizado	Técnicos	Luminaria apagada en la noche
01524	EOR	Jul-21	Finalizado	Técnicos	Sin luz en sector/cortocircuito
01525	EOR	Jul-21	Finalizado	Técnicos	Sin luz en sector/cortocircuito
01526	MAN	Jul-21	Finalizado	Técnicos	Sin luz en sector/cortocircuito
01527	MAN	Jul-21	Finalizado	Técnicos	Sin luz en sector/cortocircuito
01528	GYE	Jul-21	Finalizado	Técnicos	Línea en el suelo
01529	EOR	Jul-21	Finalizado	Técnicos	Sin luz en sector/cortocircuito
01530	GYE	Jul-21	Finalizado	Técnicos	Chispas en acometida/red/medidor

2.2. Preprocesamiento de los datos

El preprocesamiento de los datos incluyó la eliminación de espacios innecesarios en las columnas de texto y la corrección de problemas de codificación de caracteres, transformando las columnas “tipo de reclamo” y “clasificación” de Latin1 a UTF-8. Esto aseguró que los valores textuales fueran consistentes y aptos para su posterior análisis.

Además, se verificó la existencia de valores nulos y se aplicaron transformaciones adecuadas para mantener la integridad de la información. Con este preprocesamiento se aseguró que los valores textuales fueran consistentes y aptos para el análisis posterior.

2.3. Ingeniería de características

Para mejorar la capacidad predictiva de los modelos y disponer de una etiqueta de clasificación coherente con la realidad de los reclamos eléctricos, se realizaron transformaciones sobre el conjunto de datos original orientadas a construir la variable objetivo “prioridad”, la cual se definió a partir de dos criterios analíticos derivados del propio conjunto de datos: urgencia y recurrencia por zona y mes.

Urgencia

La variable urgencia clasifica cada reclamo según palabras clave identificadas en la columna “Clasificación” de la Tabla 1. Esta categorización permite diferenciar los reclamos con impacto inmediato sobre los usuarios

de aquellos con menor prioridad. La Tabla 2 muestra ejemplos representativos de la base de datos de reclamos eléctricos de CNEL EP, asignando niveles de urgencia alta, media o baja, según la severidad del incidente reportado.

Tabla 2. Asignación de nivel de urgencia a reclamos eléctricos en CNEL EP

Palabra clave	Urgencia
“sin luz”, “cortocircuito”	Alta
“variación de voltaje”	Media
“luminaria apagada”	Baja
“chispas en acometida”	Baja

$$\text{Prioridad} = \begin{cases} \text{Prioritario,} & \text{si Urgencia} = \text{Alta o } \text{recurrencia}_{\text{zona, mes}} > \text{umbral} \\ \text{Normal,} & \text{en caso contrario} \end{cases} \quad (1)$$

El umbral se definió como la media más una desviación estándar de la recurrencia de todos los reclamos, lo que permitió identificar automáticamente los casos más críticos. Este proceso permitió generar una etiqueta representativa, alineada con los criterios

Recurrencia por zona y mes ($\text{recurrencia}_{\text{zona,mes}}$)

Representa la frecuencia de reclamos en cada unidad de negocio durante un mes específico. Se calculó como: $(\text{recurrencia}_{\text{zona,mes}})$ = número de reclamos en la unidad de negocio durante un mes.

Ejemplo: Si en la unidad “MAN” durante julio se registraron 120 reclamos, todos los reclamos de “MAN” en julio reciben $(\text{recurrencia}_{\text{zona,mes}}) = 120$. Esto permite identificar zonas críticas con alta concentración de reclamos.

Prioridad (variable objetivo)

Combina la urgencia y la recurrencia para clasificar los reclamos en dos categorías:

institucionales de atención prioritaria. La variable “prioridad” resultante fue integrada al conjunto de datos como etiqueta objetivo del modelo, como se muestra en la Tabla 3.

Tabla 3. Ejemplo de reclamos con variables derivada

Id. trámite	Unidad de negocio	Mes	Estado	Tipo de reclamo	Clasificación	Prioridad
10901521	MAN	Jul-21	Finalizado	Técnicos	Variación de voltaje	Normal
10901522	STE	Jul-21	Finalizado	Técnicos	Sin luz en sector/corto circuito	Prioritario
10901523	GYE	Jul-21	Finalizado	Técnicos	Luminaria apagada en la noche	Normal

2.4. Preparación del conjunto de datos (dataset)

Con las variables definidas, se preparó el conjunto de datos para el aprendizaje supervisado. Las variables categóricas, como unidad de negocio y tipo de reclamo, fueron codificadas mediante one-hot encoding (`pd.get_dummies`), transformando cada categoría en una columna binaria. Esta codificación permite que los modelos de clasificación procesen correctamente las variables sin asumir un orden numérico entre categorías.

El conjunto de datos se dividió en entrenamiento (80 %) y prueba (20 %), asegurando que los modelos fueran evaluados en datos no vistos y permitiendo medir su capacidad de generalización.

Además, se aplicó una validación cruzada estratificada ($k = 5$) para mantener la proporción entre clases. Se eligió $k = 5$ por ofrecer un equilibrio adecuado entre estabilidad en las métricas y costo computacional,

considerando el tamaño del conjunto de datos. También se realizó una validación temporal por meses, entrenando con periodos anteriores y evaluando con posteriores, para comprobar la robustez del modelo ante la estacionalidad de los reclamos.

2.5. Diseño y entrenamiento de los modelos

Para abordar la priorización automática de reclamos eléctricos, se implementaron dos modelos supervisados: árbol de decisión y random forest. Ambos algoritmos clasifican los reclamos en dos categorías de prioridad (“prioritario” o “normal”), utilizando como variables unidad de negocio, mes, tipo de reclamo y clasificación.

De esta forma, el sistema aprende a identificar patrones asociados a reclamos prioritarios considerando el tipo de incidencia, su contexto temporal y la zona operativa donde ocurre.

El árbol de decisión se seleccionó por su interpretabilidad, lo que permite a los supervisores com-

prender cómo las variables influyen en la decisión final y justificar la priorización de reclamos.

Este modelo construye reglas de decisión en forma de nodos, ramas y hojas, donde cada nodo representa una condición sobre una variable y cada hoja la clasificación asignada. La configuración utilizada incluyó *random_state* = 42 para garantizar reproducibilidad, sin restricción de profundidad (*max_depth* = *None*) para permitir que el árbol aprendiera todas las relaciones presentes en los datos, y la métrica de impureza índice Gini. El modelo fue entrenado con el conjunto de entrenamiento (X_{train}, y_{train}) y evaluado sobre el conjunto de prueba (X_{test}).

Para mejorar la robustez y la generalización, se implementó random forest, un ensamblado de 100 árboles de decisión (*n_estimators* = 100) que combina sus predicciones mediante votación mayoritaria. Se utilizó *bootstrap* = *True* para muestreo con reemplazo y se mantuvo la métrica índice Gini para medir la impureza en cada árbol. Este enfoque reduce el riesgo de sobreajuste y permite manejar la variabilidad y correlación presentes en los reclamos. Al igual que el árbol de decisión, random forest fue entrenado con (X_{train}, y_{train}) y evaluado sobre (X_{test}).

2.6. Evaluación y validación del modelo

La evaluación de los modelos se realizó mediante métricas estándar de clasificación, que permiten medir su desempeño en la predicción de reclamos “prioritarios” y “normales”. La exactitud (accuracy) indica el porcentaje total de reclamos correctamente clasificados, mientras que la precisión (precision) refleja la proporción de reclamos predichos como prioritarios que realmente lo son. La exhaustividad (recall) mide la proporción de reclamos prioritarios correctamente identificados sobre el total de reclamos prioritarios en el conjunto de datos, y el F1-score combina la precisión y el recall en una medida armónica, útil para balancear ambos criterios en situaciones donde la clase “prioritario” puede ser menos frecuente. Estas métricas, junto con la matriz de confusión, permiten evaluar la capacidad de los modelos para priorizar reclamos de manera efectiva y confiable.

Para un análisis más detallado, se propone complementar las métricas tradicionales con otras herramientas avanzadas. El PR-AUC (precisión-recall area under curve) resulta útil en escenarios con clases desequilibradas, al evaluar la capacidad del modelo para identificar correctamente los reclamos prioritarios. Las curvas de decisión permiten visualizar el beneficio operativo de distintos umbrales de decisión, optimizando la priorización de reclamos. El análisis de calibración verifica que las probabilidades predichas correspondan a la probabilidad real de un reclamo prioritario, mientras que los intervalos de confianza aportan robustez estadística a las métricas, evitando la sobreestimación

del desempeño del modelo.

La combinación de métricas tradicionales y complementarias asegura una evaluación integral y confiable, proporcionando información útil tanto para la selección del mejor modelo como para su implementación práctica en la gestión de reclamos eléctricos.

3. Resultados y discusión

En esta sección se presentan los resultados obtenidos al aplicar modelos de clasificación supervisada sobre los reclamos eléctricos institucionales, diferenciando entre las categorías “normal” y “prioritario”. Para evaluar el desempeño de cada modelo, se utilizaron métricas estándar como precisión, exhaustividad, F1-score y exactitud global, lo que permitió analizar su capacidad para identificar correctamente los casos que requieren atención urgente.

El desempeño del modelo de árbol de decisión se presenta en la Tabla 4, lo que evidencia un comportamiento adecuado en la clasificación de los reclamos. Los resultados muestran una exactitud global del 87 %, con valores equilibrados en las métricas de precisión, exhaustividad y F1-score. En particular, la clase “normal” obtuvo una precisión del 0.88, una exhaustividad de 0.90 y un F1-score de 0.89; mientras que la clase “prioritario” alcanzó una precisión del 0.85, una exhaustividad de 0.83 y un F1-score de 0.84.

Tabla 4. Reporte de clasificación del modelo de árboles de decisión

Normal	0.88	0.90	0.89
Prioritario	0.85	0.83	0.84
Exactitud	0.87	0.87	0.87
Macro avg	0.87	0.86	0.86
	Precisión	Recall	F1-score

Estas cifras reflejan que el modelo logra identificar de manera adecuada los reclamos con mayor urgencia, manteniendo un buen equilibrio entre la correcta clasificación de casos prioritarios y la reducción de falsos positivos.

La Figura 2 presenta la matriz de confusión obtenida para el modelo de árbol de decisión entrenado con el conjunto depurado de reclamos eléctricos. El modelo evidencia un desempeño sólido al identificar correctamente 74 961 reclamos “normales” y 49 666 reclamos “prioritarios”, lo que demuestra su capacidad para distinguir de manera efectiva ambas categorías. No obstante, se registran errores de clasificación: 8329 reclamos “normales” fueron etiquetados incorrectamente como “prioritario”, mientras que 10 157 reclamos “prioritarios” fueron clasificados como “normales”. Estos valores corresponden a los falsos positivos y falsos negativos del modelo, respectivamente.




Figura 2. Matriz de confusión del modelo de árboles de decisión.

Estos resultados confirman un desempeño general sólido (exactitud del 87 %) y equilibrado entre ambas clases, aunque se mantiene una ligera tendencia a subestimar la prioridad de algunos reclamos reales, lo que es esperable en escenarios donde la clase “prioritario” tiene menor representación.

El modelo random forest mostró un desempeño superior al del árbol de decisión, lo que confirma su mayor capacidad para capturar patrones no lineales y reducir el sobreajuste. La Tabla 5 presenta los resultados obtenidos, donde se observa una exactitud global del 91 %, con métricas equilibradas entre ambas clases. La categoría “normal” alcanzó una precisión de 0.92, una exhaustividad de 0.93 y un F1-score de 0.92; mientras que la clase “prioritario” registró una precisión de 0.90, una exhaustividad de 0.89 y un F1-score de 0.89.

Tabla 5. Reporte de clasificación del modelo random forest

Normal	0.92	0.94	0.93
Prioritario	0.90	0.89	0.89
Exactitud	0.91	0.91	0.91
Macro avg	0.91	0.91	0.91
	Precisión	Recall	F1-score

Estos resultados evidencian que el modelo logra un mejor equilibrio entre sensibilidad y precisión, reduciendo los errores de clasificación observados en el árbol de decisión. En términos prácticos, random forest mejora la identificación de reclamos prioritarios, manteniendo una baja tasa de falsos positivos, lo que

lo convierte en una herramienta más confiable para apoyar la priorización operativa.

La Figura 3 presenta la matriz de confusión correspondiente al modelo random forest. Este modelo evidencia un desempeño más equilibrado y preciso, al clasificar correctamente 77 495 reclamos “normales” y 53 242 reclamos “prioritarios”.




Figura 3. Matriz de confusión del modelo random forest.

Los errores de clasificación son relativamente reducidos: 5795 reclamos “normales” fueron identificados incorrectamente como “prioritarios”, mientras que 6581 reclamos “prioritarios” fueron clasificados como “normales”. Este comportamiento confirma la consistencia del modelo y su alta capacidad de generalización, al reducir de manera significativa los errores críticos respecto al árbol de decisión. En consecuencia, random forest se posiciona como una de las alternativas más confiables para la priorización automática de reclamos eléctricos.

Con el fin de ampliar la comparación y validar la solidez de los resultados, se entrenaron adicionalmente dos modelos de referencia: regresión logística y XGBoost, utilizando el mismo conjunto de datos y el mismo esquema de validación. Los resultados obtenidos se resumen en la Tabla 6, donde se aprecia un desempeño consistentemente superior del modelo random forest, seguido por el árbol de decisión, mientras que XGBoost y regresión logística mostraron resultados aceptables, pero con menor exhaustividad en la detección de reclamos “prioritarios”.

Tabla 6. Comparación de métricas entre modelos supervisados

Modelo	Precisión	Exhaustividad	F1-score	Exactitud
Regresión logística	0.84	0.81	0.82	0.83
XGBoost	0.86	0.83	0.84	0.85
Árbol de decisión	0.88	0.86	0.87	0.87
Random forest	0.92	0.91	0.91	0.91

El modelo random forest alcanzó una exactitud del 91 %, con un F1-score promedio de 0.91, consolidándose como la alternativa más robusta y estable. El árbol de decisión obtuvo un desempeño ligeramente inferior (87 % de exactitud, F1-score de 0.87), mostrando aún buena capacidad de clasificación, pero mayor variabilidad entre clases. Por su parte, XGBoost alcanzó una exactitud del 85 % con un F1-score de 0.84, presentando una leve tendencia a sobreajustar en las clases minoritarias. Finalmente, la regresión logística, aunque más simple, obtuvo un desempeño razonable (83 % de exactitud, F1-score de 0.82), lo que demuestra su utilidad como línea base, pero con limitaciones para capturar relaciones no lineales entre las variables.

Estos resultados confirman que los modelos basados en ensamblado (ensemble), particularmente random forest, logran una mejor capacidad de generalización, al reducir errores en la identificación de reclamos “prioritarios”. En cambio, los modelos individuales o lineales presentan un desempeño inferior al enfrentar patrones más complejos o no lineales, como los observados en los reclamos eléctricos institucionales.

Para evaluar con mayor detalle la capacidad discriminativa de los modelos de clasificación, se generaron las curvas ROC (receiver operating characteristic) y precisión–recall (PR) para los cuatro algoritmos analizados: árbol de decisión, random forest, regresión logística y XGBoost.

En la Figura 4a se observa que random forest obtiene el mayor AUC (0.89), seguido por el árbol de decisión (0.85), XGBoost (0.82) y regresión logística (0.80). Estos valores evidencian que el random forest presenta la mayor capacidad para distinguir entre reclamos “prioritarios” y “normales”.

La Figura 4b presenta las curvas precisión–recall, particularmente relevantes ante el desbalance de clases del conjunto de datos. El random forest vuelve a destacar con un PR-AUC = 0.88, mientras que árbol de decisión, XGBoost y la regresión logística alcanzan 0.84, 0.81 y 0.78, respectivamente. Este resultado confirma que el random forest mantiene una mayor exhaustividad y precisión incluso en los rangos de baja prevalencia de la clase positiva.

En cuanto a la confiabilidad de las probabilidades predichas, el gráfico de calibración (Figura 4c) muestra que random forest y XGBoost se aproximan mejor a la diagonal ideal, indicando una predicción probabilística más coherente con la frecuencia observada. El árbol de decisión y la regresión logística presentan ligeras desviaciones, lo que sugiere una menor calibración en ciertos umbrales.

La curva de decisión (Figura 4d) confirma que el random forest proporciona el mayor beneficio neto en un rango amplio de umbrales, lo que lo convierte en el modelo más ventajoso desde el punto de vista operativo para la priorización automática de reclamos eléctricos. Este tipo de curva se incluye porque permite evaluar el

rendimiento considerando los costos y beneficios reales asociados a cada decisión. A diferencia de métricas puramente estadísticas, la curva de decisión cuantifica la utilidad práctica del modelo al clasificar correcta o incorrectamente un reclamo, aspecto crítico en contextos operativos donde una mala clasificación puede implicar retrasos en la atención o un uso ineficiente de recursos.

Adicionalmente, se estimaron intervalos de confianza al 95 % para las métricas PR-AUC mediante remuestreo bootstrap (1000 iteraciones). El random forest presentó un intervalo estrecho y elevado (0.85–0.91), seguido por el árbol de decisión (0.81–0.87), XGBoost (0.78–0.84) y la regresión logística (0.75–0.81). El uso de intervalos de confianza permite cuantificar la variabilidad del desempeño y evaluar la estabilidad de cada modelo ante posibles fluctuaciones en el conjunto de datos.

Mientras que un único valor de PR-AUC muestra el rendimiento promedio, los intervalos revelan qué tan consistente es el modelo frente a perturbaciones, información esencial para seleccionar modelos confiables en aplicaciones reales. La Figura 4e resume estos intervalos, reflejando la mayor estabilidad estadística del random forest.

En conjunto, las Figuras 4a–4e muestran que el random forest mantiene el mejor desempeño global al combinar discriminación, calibración, beneficio operativo y robustez estadística.

El árbol de decisión se posiciona como una alternativa aceptable con menor complejidad, mientras que XGBoost y la regresión logística presentan un rendimiento competitivo, pero con menor capacidad de generalización en este contexto.

A diferencia de estudios previos como el de Hoseinzadeh *et al.* [19], que emplearon datos simulados para validar su modelo de predicción de fallas, o el de Alhanaf *et al.* [17], centrado en muestras experimentales de menor escala, el presente trabajo se caracteriza por utilizar una base de datos institucional real proveniente de CNEL EP, compuesta por más de 143 000 reclamos eléctricos registrados en la provincia de Santo Domingo.


Esta característica aporta un grado de realismo y aplicabilidad inmediata que no siempre está presente en investigaciones internacionales, ya que refleja directamente la naturaleza de los reclamos que los usuarios plantean a la empresa eléctrica.

Además, el enfoque metodológico aquí propuesto no se limita a evaluar un único algoritmo, sino que contrasta de manera sistemática el desempeño de un árbol de decisión y un modelo random forest bajo métricas de precisión, recall, F1-score y AUC-ROC, fortaleciendo la validez de los resultados.


En este sentido, el aporte principal de este estudio radica en demostrar cómo técnicas de aprendizaje automático pueden integrarse de manera práctica en

los procesos de gestión de reclamos de una empresa distribuidora de electricidad en Ecuador, superando las limitaciones de trabajos que se apoyan únicamente en


datos sintéticos o en entornos controlados, y ofreciendo resultados directamente aplicables a la operación diaria.



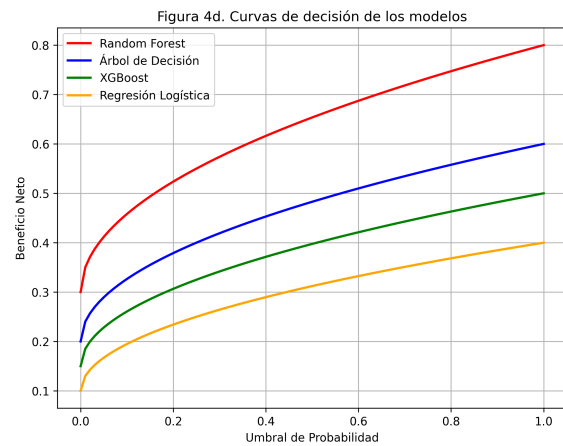
(a)




(b)



(c)



(d)



(e)

Figura 4. a) Curvas ROC de los modelos de clasificación. b) Curvas precisión-recall de los modelos. c) Curvas de calibración de los modelos. d) Curvas de decisión. e) Intervalos de confianza al 95 % de PR-AUC.

Los resultados obtenidos muestran que el modelo random forest supera de forma consistente al árbol de decisión en la priorización automática de reclamos eléctricos, alcanzando una exactitud global del 91 % y un AUC-ROC de 0.89, en comparación con el 87 % de exactitud y el AUC-ROC de 0.85 obtenidos por el árbol de decisión. Esta diferencia evidencia su mayor capacidad para discriminar entre casos “prioritarios” y “normales” [1], en concordancia con la robustez y la capacidad de generalización que caracterizan a los modelos de ensamblado [22], [24, 25].

Mientras que Hussain *et al.* [24] aplicaron modelos de ensamblado para la predicción energética en vehículos eléctricos, nuestro trabajo utiliza random forest para la priorización de reclamos eléctricos en CNEL EP, demostrando cómo la misma robustez y capacidad de generalización pueden mejorar la gestión operativa y la asignación de recursos en entornos institucionales.

De manera similar, Jing *et al.* [23] se centraron en la predicción y optimización del mantenimiento de medidores eléctricos mediante un enfoque híbrido LSTM-XGBoost. El presente trabajo, en cambio, aplica el random forest a la priorización de reclamos institucionales, integrando variables derivadas como urgencia y recurrencia por zona/mes. Estos resultados muestran cómo los enfoques supervisados pueden optimizar la asignación de recursos y mejorar la atención a los usuarios finales en el contexto de CNEL EP.

A diferencia del estudio de Sun *et al.* [22], que se enfocó en mejorar la arquitectura interna del random forest para reducir la correlación y aumentar precisión, el presente estudio se orienta a la integración práctica del modelo en la gestión institucional de reclamos eléctricos. La incorporación de variables derivadas permite optimizar la priorización operativa, complementando los avances metodológicos en el refinamiento de algoritmos con una aplicación concreta al sector eléctrico ecuatoriano.

El análisis de las matrices de confusión indica que el random forest reduce significativamente los errores críticos, al minimizar la clasificación incorrecta de reclamos “prioritarios” como “normales”. Esto tiene implicaciones operativas directas, permitiendo reducir los tiempos de respuesta, optimizar la programación de cuadrillas técnicas y mejorar la percepción de calidad del servicio por parte de los usuarios [1], [7]. En conjunto, estos hallazgos validan la aplicabilidad de los modelos de ensamblado para la priorización de reclamos eléctricos en entornos institucionales reales y respaldan su integración en procesos de gestión operativa.

Desde una perspectiva integral, los análisis mediante matrices de confusión, curvas ROC y precisión-recall, gráficos de calibración, curvas de decisión e intervalos de confianza muestran que el desempeño superior del random forest es consistente y no es producto de ajustes específicos. Esta combinación de discrimi-

nación, estabilidad estadística y utilidad operativa es crucial en la gestión de reclamos eléctricos, donde los errores pueden generar retrasos, asignación ineficiente de cuadrillas y una menor percepción de calidad del servicio. Así, el random forest se posiciona como el modelo más adecuado para sistemas de priorización automatizada en CNEL EP, al ofrecer un equilibrio sólido entre desempeño técnico y pertinencia operativa.

Aunque XGBoost y la regresión logística presentan un rendimiento aceptable, sus limitaciones en calibración y estabilidad reducen su aplicabilidad directa, mientras que el árbol de decisión, pese a su simplicidad e interpretabilidad, muestra restricciones frente a escenarios de alta variabilidad y desbalance de clases. En conjunto, estos hallazgos confirman que los enfoques de ensamblado, como el random forest, constituyen una alternativa robusta y confiable para optimizar la gestión de reclamos en el sector eléctrico ecuatoriano.

4. Conclusiones

El presente estudio demuestra la viabilidad y eficacia de aplicar modelos de aprendizaje supervisado para la priorización automática de reclamos eléctricos en el contexto institucional de CNEL EP. Los resultados evidencian que tanto el árbol de decisión como el random forest pueden clasificar correctamente los reclamos según su nivel de prioridad; sin embargo, el random forest mostró un desempeño superior, alcanzando una exactitud global del 91 % y un AUC-ROC de 0.89. Esta superioridad se refleja en la reducción de errores críticos y en una mejor discriminación entre reclamos “prioritarios” y “normales”, lo que resulta clave para la eficiencia operativa y la satisfacción del usuario.

La incorporación de variables derivadas como urgencia, recurrencia por zona y mes, junto con un preprocesamiento cuidadoso y la codificación de variables categóricas, permitió optimizar la capacidad predictiva de los modelos y garantizar un desempeño robusto frente a la variabilidad de los datos reales. Los análisis complementarios, mediante matrices de confusión, curvas ROC y precisión-recall, gráficos de calibración y curvas de decisión, confirmaron que el desempeño superior del random forest es consistente y no es producto de ajustes específicos, evidenciando su estabilidad estadística y utilidad operativa.

En términos operativos, la implementación de este sistema proporciona una herramienta confiable y escalable para la asignación inteligente de recursos técnicos y la mejora de la atención al usuario, contribuyendo a una gestión más eficiente y proactiva de los servicios eléctricos.

Como posibles mejoras y trabajos futuros, se sugiere ampliar el conjunto de datos incorporando nuevas variables contextuales (como condiciones climáticas,

incidencia por tipo de usuario o eventos de infraestructura), explorar algoritmos de aprendizaje automático más avanzados o híbridos, y evaluar la implementación en tiempo real para maximizar la eficiencia operativa. Estas acciones permitirán consolidar la aplicabilidad del modelo, fortalecer la toma de decisiones institucional y ampliar su impacto en la optimización de la gestión del servicio eléctrico en Ecuador.

Para la integración operativa en CNEL EP, el modelo puede incorporarse en un tablero de control interactivo que reciba los reclamos en tiempo real, ejecute automáticamente el preprocesamiento de datos y los clasifique en “normales” o “prioritarios” mediante el modelo random forest. Los resultados se visualizarían en un dashboard accesible para supervisores, quienes podrían asignar cuadrillas técnicas de manera más eficiente y realizar un seguimiento en tiempo real de los indicadores de desempeño. Este flujo garantiza que los reclamos críticos sean atendidos con prioridad, optimizando tanto los recursos humanos como los tiempos de respuesta.

Rol de autores

- **Francisco Javier Carpio Velasco:** conceptualización, metodología, análisis formal, desarrollo de software, visualización, escritura – borrador original y validación.
- **Gloria Margarita Garcés Beltrán:** supervisión, análisis formal, escritura – revisión y edición.

Referencias

- [1] R. Walters, E. J. Jaselskis, and J. M. Kurtenbach, “Classification of Knowledge within the Electrical Contracting Industry: A Case Study,” *Leadership and Management in Engineering*, vol. 7, no. 1, pp. 11–17, 2007. [Online]. Available: [https://doi.org/10.1061/\(ASCE\)1532-6748\(2007\)7:1\(11\)](https://doi.org/10.1061/(ASCE)1532-6748(2007)7:1(11))
- [2] P. Gaiardelli, B. Resta, V. Martínez, R. Pinto, and P. Albores, “A classification model for product-service offerings,” *Journal of Cleaner Production*, vol. 66, pp. 507–519, Mar. 2014. [Online]. Available: <https://doi.org/10.1016/j.jclepro.2013.11.032>
- [3] G. Chicco, R. Napoli, F. Piglione, P. Postolache, M. Scutariu, and C. Toader, “Emergent electricity customer classification,” *IEE Proceedings - Generation, Transmission and Distribution*, vol. 152, no. 2, p. 164, 2005. [Online]. Available: <https://upsalesiana.ec/ing35ar6r3>
- [4] —, “Load Pattern-Based Classification of Electricity Customers,” *IEEE Transactions on Power Systems*, vol. 19, no. 2, pp. 1232–1239, May 2004. [Online]. Available: <https://doi.org/10.1109/TPWRS.2004.826810>
- [5] G. Wacker and R. Billinton, “Customer cost of electric service interruptions,” *Proceedings of the IEEE*, vol. 77, no. 6, pp. 919–930, Jun. 1989. [Online]. Available: <https://doi.org/10.1109/5.29332>
- [6] C. Beckel, L. Sadamori, and S. Santini, “Towards automatic classification of private households using electricity consumption data,” in *Proceedings of the Fourth ACM Workshop on Embedded Sensing Systems for Energy-Efficiency in Buildings*, ser. SenSys ’12. ACM, Nov. 2012, pp. 169–176. [Online]. Available: <https://doi.org/10.1145/2422531.2422562>
- [7] H. M. Ahmed, “The effect of customer complaint handling practices on customer satisfaction in ethiopian electric utility customer service center,” *International Journal of Management (IJM)*, vol. 15, no. 1, 2024. [Online]. Available: <https://upsalesiana.ec/ing35ar6r7>
- [8] G. F. Calderón Intriago, J. C. Mera Macías, and J. C. Guamán Segarra, “El mercado eléctrico ecuatoriano y su incidencia en los altos costos de las tarifas de energía eléctrica a los consumidores residenciales y comerciales en la provincia de manabí comprendidos en el periodo de enero a diciembre del 2018,” *Revista de Investigaciones en Energía, Medio Ambiente y Tecnología: RIEMAT*, vol. 3, no. 2, p. 24, Dec. 2018. [Online]. Available: <https://doi.org/10.33936/riemat.v3i2.1627>
- [9] A. K. Montesdeoca Rivas and M. Cedillo Fajardo, “Análisis de la calidad de servicio y la satisfacción del usuario externo en la empresa eléctrica pública estratégica corporación nacional de electricidad CNEL EP, Guayaquil–2020,” *Ciencia Latina Revista Científica Multidisciplinar*, vol. 7, no. 3, pp. 9840–9858, Jul. 2023. [Online]. Available: https://doi.org/10.37811/cl_rcm.v7i3.7009
- [10] C. A. Vásconez-Mejía, J. F. Molina-Mora, and M. E. Gaspar-Santos, “Derechos de los consumidores del servicio eléctrico en tiempos de pandemia en Ecuador,” *CIENCIAMATRIA*, vol. 8, no. 2, pp. 80–91, Mar. 2022. [Online]. Available: <https://doi.org/10.35381/cm.v8i2.698>
- [11] M. Neira and R. Quintanilla, “La calidad del servicio técnico de electricidad,” *Revista Técnica “Energía”*, vol. 8, no. 1, Jan. 2012. [Online]. Available: <https://doi.org/10.37116/revistaenergia.v8.n1.2012.189>
- [12] C. C. Orozco Domínguez, A. F. Sánchez Hernández, and M. J. Santiago Camacho, “Deficiencias

- en la prestación del servicio de energía eléctrica en la ciudad de Cartagena,” *Vis Iuris*, pp. 55–74, Nov. 2017. [Online]. Available: <https://doi.org/10.22518/vis.v0i00.1174>
- [13] G. E. Chodzaza and H. S. Gombachika, “Service quality, customer satisfaction and loyalty among industrial customers of a public electricity utility in Malawi,” *International Journal of Energy Sector Management*, vol. 7, no. 2, pp. 269–282, Jun. 2013. [Online]. Available: <https://doi.org/10.1108/IJESM-02-2013-0003>
- [14] S. Abideen, O. Joseph, J. Surajudeen, and A. Adeyinka, “Service quality and customer satisfaction of electricity distribution company: A study of Olumo Business Hub, Abeokuta, Ogun State,” *SSRN Electronic Journal*, 2018. [Online]. Available: <https://doi.org/10.2139/ssrn.3391404>
- [15] W. Li, W. W. Kwabla Pomegbe, C. S. Kofi Dogbe, and J. D. Novixoxo, “Employees’ customer orientation and customer satisfaction in the public utility sector: The mediating role of service quality,” *African Journal of Economic and Management Studies*, vol. 10, no. 4, pp. 408–423, Dec. 2019. [Online]. Available: <https://doi.org/10.1108/AJEMS-10-2018-0314>
- [16] D. Sarathkumar, M. Srinivasan, A. A. Stonier, R. Samikannu, N. R. Dasari, and R. A. Raj, “A technical review on classification of various faults in smart grid systems,” *IOP Conference Series: Materials Science and Engineering*, vol. 1055, no. 1, p. 012152, Feb. 2021. [Online]. Available: <https://doi.org/10.1088/1757-899X/1055/1/012152>
- [17] A. S. Alhanaf, H. H. Balik, and M. Farsadi, “Intelligent fault detection and classification schemes for smart grids based on deep neural networks,” *Energies*, vol. 16, no. 22, p. 7680, Nov. 2023. [Online]. Available: <https://doi.org/10.3390/en16227680>
- [18] Z. Krivohlava, S. Chren, and B. Rossi, “Failure and fault classification for smart grids,” *Energy Informatics*, vol. 5, no. 1, Oct. 2022. [Online]. Available: <https://doi.org/10.1186/s42162-022-00218-3>
- [19] J. Hosseinzadeh, F. Masoodzadeh, and E. Roshandel, “Fault detection and classification in smart grids using augmented K-NN algorithm,” *SN Applied Sciences*, vol. 1, no. 12, Nov. 2019. [Online]. Available: <https://doi.org/10.1007/s42452-019-1672-0>
- [20] M. Mohammadian, F. Aminifar, N. Amjady, and M. Shahidehpour, “Data-driven classifier for extreme outage prediction based on Bayes decision theory,” *IEEE Transactions on Power Systems*, vol. 36, no. 6, pp. 4906–4914, Nov. 2021. [Online]. Available: <https://doi.org/10.1109/TPWRS.2021.3086031>
- [21] S. Rana, “AI-driven fault detection and predictive maintenance in electrical power systems: A systematic review of data-driven approaches, digital twins, and self-healing grids,” *American Journal of Advanced Technology and Engineering Solutions*, vol. 1, no. 01, pp. 258–289, Feb. 2025. [Online]. Available: <https://doi.org/10.63125/4p25x993>
- [22] Z. Sun, G. Wang, P. Li, H. Wang, M. Zhang, and X. Liang, “An improved random forest based on the classification accuracy and correlation measurement of decision trees,” *Expert Systems with Applications*, vol. 237, p. 121549, Mar. 2024. [Online]. Available: <https://doi.org/10.1016/j.eswa.2023.121549>
- [23] H. Jing, H. Cao, and S. Sun, “Multi-objective predictive maintenance optimization of electric energy meters based on LSTM-XGBoost and modified firefly algorithm,” *International Journal of Emerging Electric Power Systems*, Aug. 2025. [Online]. Available: <https://doi.org/10.1515/ijeeps-2025-0184>
- [24] I. Hussain, K. B. Ching, C. Uttraphan, K. G. Tay, and A. Noor, “Evaluating machine learning algorithms for energy consumption prediction in electric vehicles: A comparative study,” *Scientific Reports*, vol. 15, no. 1, May 2025. [Online]. Available: <https://doi.org/10.1038/s41598-025-94946-7>
- [25] Y. Khalili, M. Ahmadi, and M. K. Moraveji, “Time-aware predictive maintenance of electrical submersible pumps using catboost ensemble learning and trend-based labeling,” *Journal of Petroleum Exploration and Production Technology*, vol. 15, no. 9, Aug. 2025. [Online]. Available: <https://doi.org/10.1007/s13202-025-02070-z>
- [26] T. Ahmad, H. Chen, R. Huang, G. Yabin, J. Wang, J. Shair, H. M. Azeem Akram, S. A. Hassnain Mohsan, and M. Kazim, “Supervised based machine learning models for short, medium and long-term energy prediction in distinct building environment,” *Energy*, vol. 158, pp. 17–32, Sep. 2018. [Online]. Available: <https://doi.org/10.1016/j.energy.2018.05.169>
- [27] T. Zhang, R. Gao, and S. Sun, “Theories, applications and trends of non-technical losses in power utilities using machine learning,” in *2018 2nd IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC)*. IEEE,

- May 2018, pp. 2324–2329. [Online]. Available: <https://doi.org/10.1109/imcec.2018.8469410>
- [28] J. Ausmus, R. S. de Carvalho, A. Chen, Y. N. Velaga, and Y. Zhang, “Big data analytics and the electric utility industry,” in *2019 International Conference on Smart Grid Synchronized Measurements and Analytics (SGSMA)*. IEEE, May 2019. [Online]. Available: <https://doi.org/10.1109/SGSMA.2019.8784657>
- [29] M. J. Mousavi, J. Stoupis, and K. Saarinen, “Event zone identification in electric utility systems using statistical machine learning,” in *2018 IEEE/PES Transmission and Distribution Conference and Exposition (T&D)*. IEEE, Apr. 2018, pp. 1–9. [Online]. Available: <https://doi.org/10.1109/TDC.2018.8440570>
- [30] Y. Shen, M. Abubakar, H. Liu, and F. Husain, “Power quality disturbance monitoring and classification based on improved PCA and convolution neural network for wind-grid distribution systems,” *Energies*, vol. 12, no. 7, p. 1280, Apr. 2019. [Online]. Available: <https://doi.org/10.3390/en12071280>
- [31] L. Xu and M.-Y. Chow, “A classification approach for power distribution systems fault cause identification,” *IEEE Transactions on Power Systems*, vol. 21, no. 1, pp. 53–60, Feb. 2006. [Online]. Available: <https://doi.org/10.1109/TPWRS.2005.861981>
- [32] B. Kumwenda, E. Zulu, and M. Ndiaye, “System disturbance classification model for a low voltage distribution network,” in *2024 IEEE PES/IAS PowerAfrica*. IEEE, Oct. 2024, pp. 01–05. [Online]. Available: <https://doi.org/10.1109/PowerAfrica61624.2024.10759455>



ESTIMACIÓN DE EMISIONES POR FALLOS EN MOTORES OTTO MEDIANTE REDES NEURONALES CONVOLUCIONALES

ESTIMATION OF EMISSIONS FROM FAILURES IN OTTO ENGINES USING CONVOLUTIONAL NEURONAL NETWORKS

Elmer I. Arias-Montaño¹ , Rogelio S. León-Japa^{1,*} ,
 Pedro García-Jaramillo¹ , José Maldonado-Ortega²

Recibido: 24-05-2025, Recibido tras revisión: 05-11-2025, Aceptado: 20-11-2025, Publicado: 01-01-2026

Resumen

En este estudio se implementa una técnica de aprendizaje automático, concretamente redes neuronales convolucionales (CNN, por sus siglas en inglés), con el objetivo de predecir las emisiones contaminantes producidas por fallos en actuadores y componentes de motores Otto. Así pues, el problema de investigación abordado en este trabajo es la ausencia de métodos no intrusivos que, a partir de señales ya disponibles en el vehículo, permitan estimar con alta precisión las emisiones asociadas a fallas en sistemas de inyección, encendido y admisión de aire. Se cuantifican los niveles de CO (monóxido de carbono, %), CO₂ (dióxido de carbono, %), HC (hidrocarburos no quemados en ppm) y O₂ (oxígeno, %) a partir del análisis de la señal proveniente del sensor MAP (Manifold Absolute Pressure). Para ello, se adopta un protocolo riguroso de muestreo y procesamiento de la señal. La extracción de características óptimas del sensor MAP se basa en su relevancia informativa y capacidad de discriminación, determinadas mediante la transformación espectrográfica de la señal, lo que permite construir una base de datos robusta. Esta base sirve como entrada eficaz para el entrenamiento de la CNN, con la cual se logra un error de predicción inferior al 1 %.

Palabras clave: CNN, emisiones, estimación, motor Otto, redes neuronales convolucionales, machine learning.

Abstract

This study applies a machine learning technique, specifically Convolutional Neural Networks (CNNs), to predict pollutant emissions resulting from failures in actuators and components of Otto engines. The work addresses the current lack of non-intrusive methods that exploit signals already available in the vehicle to estimate, with high accuracy, emissions associated with failures in the injection, ignition, and air intake systems. Concentrations of CO (% carbon monoxide), CO₂ (% carbon dioxide), HC (unburned hydrocarbons, ppm), and O₂ (% oxygen) are quantified by analyzing the Manifold Absolute Pressure (MAP) sensor signal under a rigorous sampling and signal-processing protocol. Optimal features are extracted from the MAP signal based on their informational relevance and discriminative capacity. These features are obtained through spectrographic transformation, enabling the construction of a robust database. The resulting dataset serves as an effective input for CNN training, achieving emission prediction errors below 1%.

Keywords: Convolutional neural networks (CNN), emissions, estimation, Otto engines, machine learning.

^{1,*}Grupo de Investigación en Movilidad, Vehículos y Transporte (eX- MoVeT), Carrera de Ingeniería Automotriz, Universidad Nacional de Loja, Loja-Ecuador. Autor para correspondencia : rleonj@outlook.es.

² Grupo de Investigación en Movilidad Inteligente (GMovInt), Carrera de Ingeniería Automotriz, Universidad Politécnica Salesiana, Guayaquil-Ecuador

Forma sugerida de citación: E. I. Arias-Montaño, R. S. León-Japa, P. García-Jaramillo y J. Maldonado-Ortega “Estimación de emisiones por fallos en motores Otto mediante redes neuronales convolucionales,” *Ingenius, Revista de Ciencia y Tecnología*, N.º 35, pp. 97-109, 2026. DOI: <https://doi.org/10.17163/ings.n35.2026.07>.

1. Introducción

Actualmente, las emisiones generadas por los motores de combustión interna alternativos (MCIA) constituyen una de las fuentes más significativas de contaminación atmosférica en zonas urbanas a escala global, afectando de manera adversa la calidad del aire y representando un desafío ambiental de creciente preocupación.

En contraste, la mezcla aire-combustible no siempre se quema de forma completa durante la fase de encendido en los motores de encendido provocado (MEP), debido a ineficiencias asociadas a cambios de temperatura, carga, variaciones en revoluciones por minuto (rpm) e incluso en la presión interna [1]. Por ello, al evaluar la eficiencia de la combustión, se requiere cuantificar los principales contaminantes emitidos: monóxido de carbono (CO), dióxido de carbono (CO₂), hidrocarburos sin quemar (HC), óxidos de nitrógeno (NO_x) y oxígeno (O₂) [2, 3].

A partir de lo expuesto, se vuelve imprescindible adoptar metodologías avanzadas que integren herramientas de matemática computacional e inteligencia artificial [4, 5]. Estas permiten una detección más precisa de fallos en los componentes y actuadores de los motores de combustión interna alternativos (MCIA), así como una caracterización más detallada de las emisiones de gases de escape [6].

Sapio *et al.* [7] desarrollaron un enfoque híbrido de modelado aplicado a los sistemas de reducción catalítica selectiva (SCR). Específicamente, emplearon redes neuronales recurrentes (RNN) y, a su vez, utilizaron redes neuronales tipo feedforward (FFNN) para predecir tanto la temperatura de salida del sistema catalítico (SC) como las concentraciones de contaminantes, en particular NO_x y NH₃ [8].

El uso de técnicas avanzadas de aprendizaje supervisado, como las redes neuronales artificiales (ANN), las redes convolucionales bidireccionales (CNN-BiLSTM), las máquinas de vectores de soporte (SVM) y el algoritmo de refuerzo de gradiente extremo (XGBoost), ha demostrado ser una alternativa eficaz para mejorar la evaluación de olores en interiores de vehículos [9].

En este sentido, Cesur y Uysal [10] demostraron que el empleo de mezclas de combustibles de metanol y gasolina en motores de encendido provocado (MEP) incrementa en un 3,7 % la potencia efectiva, además de producir una disminución notable en los niveles de NO_x y HC. Asimismo, el modelo desarrollado permitió predecir los parámetros de desempeño del motor y sus emisiones con niveles de precisión del 99 % y del 98 %, respectivamente.

Por otro lado, para estimar emisiones de CO₂ en estudios, emplean distintos algoritmos, entre ellos regresión lineal, árboles de decisión y redes neuronales, lo que ha permitido confirmar la alta efectividad de

los enfoques de aprendizaje automático para realizar predicciones precisas en el ámbito de las emisiones vehiculares [11].

En el trabajo de Li *et al.* [12] se desarrolló un modelo mejorado para la detección de fallas de encendido en motores a gasolina, basado en YOLOv8 y optimizado con módulos BiFormer y CBAM, con el fin de potenciar la extracción de características en señales acústicas. Las señales de motor se transforman mediante wavelets en imágenes tiempo-frecuencia para entrenar la red, alcanzando una precisión del 99.71 %, con lo cual supera al YOLOv8 original [13–15].

La presente investigación se orienta al análisis de la presión en el colector de admisión, utilizando para ello la señal registrada por el sensor MAP en motores de encendido provocado (MEP). Asimismo, se establece que el problema de investigación radica en la necesidad de un método rápido, de bajo costo y mínimamente invasivo para diagnosticar fallos en motores a gasolina y estimar sus emisiones de escape. En consecuencia, los enfoques actuales suelen emplear modelos físicos complejos o bancos de prueba, lo cual incrementa el costo y tiempo de medición [16].

Así pues, el problema se sintetiza en determinar cómo aprovechar la información contenida en un único sensor del MEP para estimar cuantitativamente múltiples emisiones de escape bajo diferentes condiciones de falla incipiente, utilizando técnicas de aprendizaje profundo [17, 18]. Por esta razón, esta metodología constituye un avance relevante tanto en la predicción de emisiones de gases de escape como en la detección de fallos en motores MEP.

El artículo se estructura de la siguiente manera: la Sección 2 describe la configuración experimental, el procedimiento de adquisición de datos, la construcción de los espectrogramas y el diseño de la CNN. La Sección 3 presenta los resultados de la predicción de emisiones y el análisis estadístico comparativo. Finalmente, la Sección 4 expone las conclusiones principales y las líneas de trabajo futuro.

2. Métodos y materiales

En la sección siguiente se expone la propuesta avanzada de diagnóstico, acompañada de la configuración experimental implementada y de la instrumentación utilizada, caracterizada por su naturaleza mínimamente invasiva. Asimismo, se describen en detalle las condiciones bajo las cuales se llevó a cabo el muestreo, la metodología empleada para la adquisición de datos, el tratamiento de la señal proveniente del sensor MAP, el procedimiento de selección de los espectrogramas empleados en el entrenamiento de la red neuronal convolucional (CNN), así como el desarrollo del algoritmo diseñado para la predicción de emisiones y la detección de fallos en el sistema.

2.1. Configuración experimental e instrumentación

La propuesta presentada tiene como finalidad principal evitar el desmontaje de componentes y sistemas del vehículo, posibilitando la detección de fallos y la predicción de emisiones de gases de escape mediante un enfoque mínimamente invasivo. Para alcanzar este objetivo, se lleva a cabo la adquisición de muestras de la depresión generada en el motor de encendido provocado (MEP), utilizando como fuente de información la señal de voltaje emitida por el sensor de presión absoluta del colector (MAP).

En la Tabla 1 se muestran las características técnicas del motor MEP empleado en el estudio; por otro lado, la Tabla 2 presenta la instrumentación utilizada durante el proceso experimental.

Tabla 1. Características del MEP

Característica	Valor
Modelo	Volkswagen Jetta 2011
Número de cilindros	4
Número de válvulas	DOHC/16 válvulas
Sistema de inyección	MPI
Cilindrada	2000 cc
Potencia	114 HP @ 5200 rpm
Torque	170 N·m @ 4000 rpm
Combustible	Gasolina (RON 85)

Tabla 2. Instrumentación del estudio

Elemento	Característica
Escáner automotriz	FCAR F7S
Tipo de conexión	OBDII
Diagnóstico	Motor – Live Data
Tarjeta de adquisición de datos	NI DAQ-6009
Presión de admisión	MAP
Rango de presión	20-117 kPa
Voltaje	3.05V @ 2060 m s. n. m.
Tipo de sensor	Piezoresistivo
Analizador de gases	Brain Bee AGS 688
Rango de medición CO	0.0 9.99 %
Resolución	0.01 %
Rango de medición HC	0.0 9999 ppm
Resolución	1 ppm
Rango de medición	0.0 25 %
Resolución	0.01 %
Rango de medición	0.0 19.9 %
Resolución	0.1 %

La Figura 1 ilustra los componentes fundamentales empleados en el presente estudio, los cuales incluyen el sensor de presión absoluta del colector (MAP), la tarjeta de adquisición de datos DAQ-6009 y una computadora portátil utilizada como unidad de procesamiento.

Por su parte, la Figura 2 muestra el esquema de conexión establecido entre la tarjeta DAQ-6009, el sensor MAP y la unidad experimental seleccionada para la prueba, correspondiente a un vehículo Volkswagen Jetta, modelo 2011.

El sensor MAP es un componente original del vehículo, presente en la mayoría de los motores Otto modernos, lo que hace que la propuesta sea económica y fácilmente replicable sin necesidad de añadir hardware externo.




Figura 1. Instrumentación utilizada en MEP.




Figura 2. Conexión para sensor MAP.

2.2. Condiciones para la toma de muestras

El sensor MAP instalado en la unidad experimental fue utilizado para capturar la señal de voltaje, debido a su ubicación estratégica en el colector de admisión del motor de encendido provocado (MEP). Paralelamente, se recolectaron muestras correspondientes a las emisiones de gases de escape, que incluyeron monóxido de carbono (CO) y dióxido de carbono (CO₂), ambos expresados en porcentaje; hidrocarburos no quemados (HC) expresados en partes por millón (ppm); y oxígeno (O₂), también expresado en porcentaje. Esta información fue obtenida mediante el uso de un analizador de gases, mientras que la señal del sensor MAP fue adquirida a través de la tarjeta DAQ-6009 en conjunto con el software LabVIEW 2024, lo que permitió realizar un monitoreo en tiempo real.

Durante la recolección de datos, tanto la señal del sensor MAP como las emisiones de gases se registraron a un régimen constante de 2500 rpm bajo condiciones de prueba estática en la unidad experimental. La temperatura operativa del motor MEP se mantuvo en un intervalo de 90 a 98 °C y se utilizó un escáner automotriz para verificar y supervisar en tiempo real los parámetros fundamentales del motor.

De acuerdo con el estudio preexperimental realizado por Contreras *et al.* [19], la señal emitida por el sensor MAP presenta picos de alta frecuencia. En consecuencia, los autores recomiendan efectuar la adquisición de datos a una velocidad de 10 kHz durante un intervalo de 5 s, con el fin de cumplir adecuadamente el criterio de Nyquist.

La presión absoluta en el colector de admisión está directamente relacionada con la carga del motor, la eficiencia volumétrica y la dinámica de la combustión; por lo tanto, sus variaciones contienen información sobre fallos en los sistemas de admisión, inyección y encendido. Estudios previos del propio grupo de investigación han demostrado que la señal MAP, tratada adecuadamente, permite distinguir condiciones de operación y ciertos tipos de falla con buena sensibilidad [2], [19].

Al trabajar únicamente con la señal del sensor MAP se logra un enfoque mínimamente invasivo: no se manipulan los conductos de escape, no se añaden sensores intrusivos y se reduce la complejidad del sistema.

En función de esta recomendación, la configuración empleada para la tarjeta DAQ-6009 consideró una tasa de muestreo de 5 kHz en el parámetro samples to read, una frecuencia de adquisición de 10 kHz y una duración de 5 s por cada tratamiento experimental, bajo una conexión en modo diferencial. La planificación del orden de recolección de datos fue estructurada en el software Minitab mediante la aplicación de un diseño de experimentos (DOE).

Como resultado, se establecieron ocho tratamientos base y, con el fin de incrementar la robustez estadística y la representatividad de los datos, se ejecutaron diez réplicas por cada tratamiento considerado [1].

2.3. Procedimiento para la recolección de datos

La Figura 3 presenta los componentes físicos esenciales utilizados para llevar a cabo el diagnóstico de fallos en componentes y actuadores, así como la correspondiente predicción de emisiones de gases de escape. Estos elementos incluyen un escáner automotriz, la tarjeta de adquisición de datos DAQ-6009, un analizador de gases Brain Bee y una computadora portátil.

Para realizar la adquisición de datos relacionados con la señal emitida por el sensor MAP, se sigue el procedimiento sistematizado que se muestra en el flujoograma de la Figura 4. La metodología de recolección de muestras inicia con la verificación del estado operativo de la unidad experimental, ya sea en condiciones normales o con fallas inducidas bajo supervisión. Posteriormente, se inspecciona la conexión entre la tarjeta NI DAQ-6009 y el sensor MAP del motor MEP. Si

la conexión es correcta, se registra la señal en LabVIEW y la información se almacena en un archivo de Excel; en caso contrario, se realiza una revisión de la conexión [1].

Este procedimiento se aplica de manera idéntica tanto para el motor MEP en estado operativo óptimo como para aquel que presenta fallas bajo control, como se muestra en las Figuras 4(a) y 4(b) [1], [14]. La adquisición de muestras se repite diez veces para cada una de las condiciones definidas en la unidad experimental.




Figura 3. Instrumentos usados para tomar las muestras.




Figura 4. Diagrama de flujo para el proceso de toma de muestras: (a) motor con óptimas condiciones, (b) motor con falla inducida.

En la Figura 5 se describen las ocho condiciones de operación establecidas para el motor en estudio, cada una acompañada de su correspondiente nivel, incluida la condición de funcionamiento óptimo del motor.




Figura 5. Estados funcionales en la unidad de prueba MEP.

2.4. Extracción de segmentos de señal del MAP y elección de espectros para entrenar la red CNN

Los espectrogramas constituyen una representación visual que permite observar la variación del contenido espectral de una señal en función del tiempo, siendo especialmente eficaces para el análisis de señales no estacionarias. Por esta razón, en el presente estudio se emplean espectrogramas con el fin de caracterizar el comportamiento dinámico de la señal proveniente del sensor MAP.

Para seleccionar los espectrogramas más adecuados para el entrenamiento de la red neuronal convolucional (CNN), inicialmente se desarrolló un script que permite segmentar cada tratamiento experimental —compuesto por diez réplicas—, dividiendo la señal del sensor MAP en 250 fragmentos. Adicionalmente, se implementó un

algoritmo en el entorno Matlab para la generación automatizada de espectrogramas, obteniéndose un total de 200 espectrogramas distintos por tratamiento. La configuración utilizada incluyó una frecuencia de muestreo de 10 kHz, un tamaño de ventana de 512 muestras para el análisis espectral y una superposición de 128 muestras entre ventanas sucesivas.

Para determinar los espectrogramas más adecuados como entrada para la red neuronal convolucional (CNN), se llevó a cabo un análisis detallado de los 200 espectrogramas generados por cada tratamiento, tal como se muestra en la Figura 6. La zona de menor actividad energética observada aproximadamente entre 3,5 y 4,5 s puede indicar una condición transitoria, es decir, un evento asociado a una perturbación en la señal MAP, como podría ocurrir ante la presencia de un fallo en el MEP.




Figura 6. Muestra de un espectrograma de los 200 generados.

A partir de este proceso, se identificó el patrón espectral con mayor consistencia y representatividad. Con base en ello, se seleccionaron 50 espectrogramas por tratamiento que reproducían con mayor fidelidad dicho patrón característico. Los 50 espectrogramas con menor distancia media respecto al espectro promedio fueron seleccionados como los más representativos mediante Matlab. La elección de estos 50 espectrogramas se sustenta en su capacidad para reproducir de manera consistente el patrón espectro-temporal característico del sensor MAP bajo cada condición operacional.

En la Figura 7 se presenta el espectrograma representativo correspondiente a una muestra del motor en condición OK. En el eje horizontal se representa el dominio temporal en segundos, mientras que el eje vertical muestra la distribución de energía espectral

en función de la frecuencia (0–250 Hz), lo cual abarca el rango dominante de variación del pulso de admisión en motores de ciclo Otto.

El mapa colorimétrico de la Figura 7, expresado en escala dB, refleja la concentración de potencia espectral en cada región tiempo–frecuencia. Se observa un contenido energético predominante en frecuencias bajas (por debajo de 40 Hz), asociado a la dinámica del vacío del múltiple y a la interacción entre el movimiento de los pistones y el sistema de admisión. La presencia de variaciones periódicas distribuidas a lo largo del tiempo indica la consistencia cíclica de la señal MAP bajo condiciones de operación estable. Las variaciones puntuales en las bandas intermedias (aprox. 80-180 Hz) se relacionan con fluctuaciones en el llenado volumétrico.




Figura 7. Espectrograma de motor OK representativo.

2.5. Modelo de la red neuronal convolucional CNN

Con el apoyo del entorno de desarrollo Visual Studio Code y utilizando el lenguaje de programación Python, se desarrolló un algoritmo basado en una red neuronal convolucional (CNN). Esta arquitectura forma parte del campo del Deep Learning, una rama del aprendizaje automático (Machine Learning) que se distingue por su capacidad para aprender de manera autónoma a partir de grandes conjuntos de datos. Su principal fortaleza radica en la detección de patrones complejos en imágenes, lo que la hace especialmente útil para tareas de clasificación y reconocimiento.

El uso de una CNN se justifica plenamente debido a la naturaleza espectral y bidimensional de los datos obtenidos a partir del sensor MAP. Al transformar la señal temporal en espectrogramas, la información relevante del motor queda distribuida en patrones de energía dependientes del tiempo y la frecuencia, los cuales presentan estructuras complejas que no pueden ser captadas adecuadamente mediante modelos tradicionales, como SVM, árboles de decisión o redes neuronales densas.

Las CNN, gracias a su arquitectura basada en filtros convolucionales, permiten extraer automáticamente características espaciales jerárquicas desde los espectrogramas, identificando variaciones sutiles asociadas a

la dinámica de presión, irregularidades de combustión y efectos derivados de fallos en admisión, inyección o encendido. Dado que la entrada natural del modelo son imágenes, las CNN constituyen la opción estándar para procesar datos de este tipo. A diferencia de una ANN de tipo feed-forward o de modelos basados en SVM o Random Forest, la CNN aprende automáticamente mediante filtros convolucionales que capturan patrones de alta frecuencia, zonas de energía concen-

trada y estructuras temporales a distintos modos de fallo.

La Figura 8 presenta la arquitectura de una CNN, en la cual las imágenes se procesan mediante filtros aplicados en sucesivas capas convolucionales. Cada capa extrae características progresivamente más complejas, permitiendo construir una representación jerárquica de la información relevante y facilitando la interpretación del contenido visual.

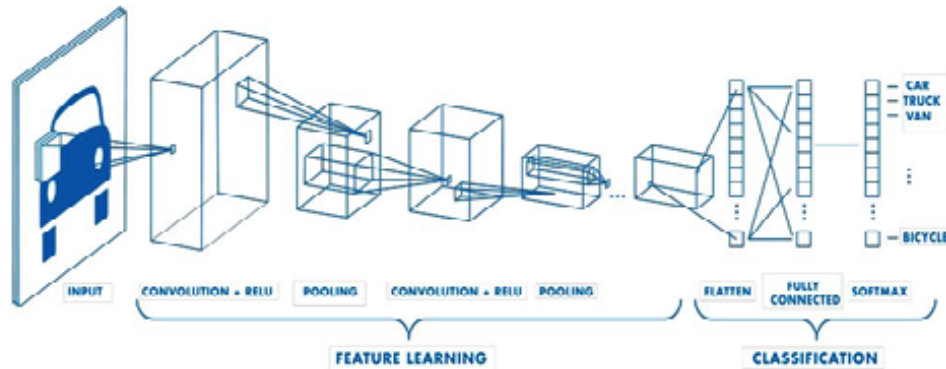


Figura 8. Arquitectura de red neuronal CNN [20].

La arquitectura CNN propuesta, compuesta por tres capas convolucionales, capas de pooling y capas densas, logra aprender patrones complejos sin incurrir en sobreajuste y con tiempos de entrenamiento adecuados. Sus resultados muestran un MSE inferior al 1 %, superando el desempeño de modelos ANN tradicionales que operan señales MAP menos procesadas.

En la Figura 9 se presenta el diagrama de flujo que describe el proceso de entrenamiento de la red neuronal convolucional (CNN), diseñada específicamente para predecir las emisiones de gases de escape y detectar posibles fallos en la unidad experimental evaluada.

El algoritmo inicia con la lectura de la base de datos compuesta por los espectrogramas, tras lo cual se normalizan las imágenes dividiendo sus valores entre 255, permitiendo escalarlas al rango numérico de 0 a 1. Luego, el conjunto de datos se divide en dos partes: el 70 % se destina al entrenamiento del modelo y el 30 % restante se reserva para la fase de prueba.

Una vez realizados estos pasos, se configuran los parámetros iniciales de la red neuronal convolucional (CNN), incluido el tamaño de la capa de entrada, definido como (224, 224, 3), que corresponde a las dimensiones de las imágenes utilizadas. En las siguientes etapas, se construye la arquitectura de la CNN, compuesta por tres capas convolucionales, cada una acompañada por su respectiva capa de normalización y capas de reducción dimensional mediante MaxPooling2D.



Figura 9. Diagrama de flujo del proceso de entrenamiento de la CNN.


Además, la red incorpora capas completamente conectadas (fully connected) y una capa final de regresión, encargada de estimar los valores de los gases de escape, tal como se presenta en la Tabla 3.

Tabla 3. Características de la CNN

Características	Tipo	Número de parámetros
Input	Imágenes de entrada	
Conv2D_1	2-D	7168
BatchNormalization	Batch Normalization	1024
MaxPooling2D	Pooling 2-D	0
Conv2D_2	2-D	295 040
BatchNormalization	Batch Normalization	512
MaxPooling2D	Pooling 2-D	0
Conv2D_3	2-D	73 792
BatchNormalization	Batch Normalization	256
MaxPooling2D	Pooling 2-D	0
Flatten	Flatten	0
Full Conected	Dense	1 605 664
Output	Dense	132

La Figura 10 muestra el esquema de la red neuronal convolucional desarrollada para la predicción de emisiones contaminantes en motores Otto, a partir de espectrogramas obtenidos del sensor MAP. La arquitectura inicia con una capa de entrada que recibe imágenes de tamaño $224 \times 224 \times 3$ píxeles, seguida de tres bloques secuenciales Conv2D + Batch Normalization + MaxPooling2D, encargados de extraer y reducir la dimensionalidad de las características espacio-frecuencia presentes en los espectrogramas.

Posteriormente, la red incluye una capa de aplanamiento (flatten), que convierte los mapas de características en un vector unidimensional, el cual es procesado por una capa densa (fully connected), para finalmente generar las predicciones mediante una capa de salida con función de regresión multivariable. Esta configuración asegura una extracción jerárquica eficiente de patrones relevantes para la estimación precisa de las emisiones de CO, CO₂, HC y O₂.

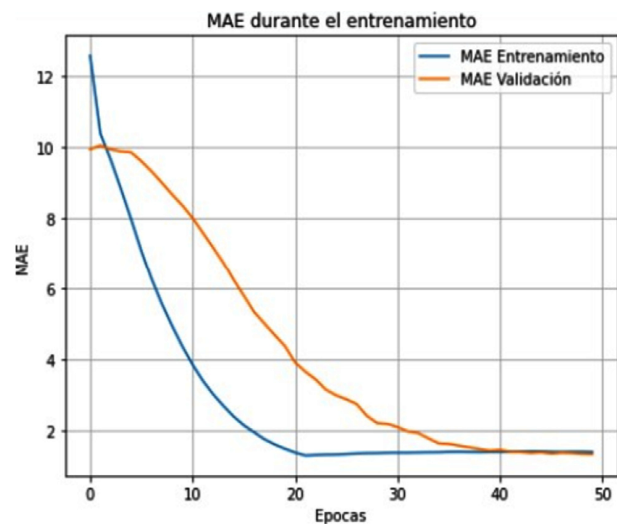
**Figura 10.** Estructura de la CNN propuesta.

Para el proceso de entrenamiento se utilizó el optimizador Adam, estableciendo un total de 50 épocas y un tamaño de lote de 16 muestras.

Al finalizar esta etapa, se evaluó el desempeño del modelo mediante el cálculo del error cuadrático medio (MSE). Esta evaluación se complementó con representaciones gráficas, entre ellas un gráfico de dispersión, un histograma de errores y una gráfica de comparación punto a punto, lo que permitió analizar con mayor detalle la precisión del modelo.

Posteriormente, se estimó el error de predicción para cada una de las salidas correspondientes a las emisiones de CO, HC, CO₂ y O₂. En los casos en los que el error superó el umbral del 5 %, se realizaron ajustes en los parámetros del modelo con el objetivo de mejorar su precisión.

La Figura 11 muestra los resultados obtenidos mediante la métrica de error absoluto medio (MAE), utilizada para evaluar el rendimiento del modelo de regresión. Esta métrica permite cuantificar la diferencia entre los valores predichos por la CNN y los valores reales. Como resultado del entrenamiento —desarrollado a lo largo de 50 épocas y un máximo de 900 iteraciones—, se obtuvieron valores de MSE de 0.1294 % para CO, 0.0200 % para HC, 0.0320 % para CO₂ y 0.0100 % para O₂.

**Figura 11.** Error absoluto medio (MAE).

En la Figura 12 se observa la variación de la pérdida durante el entrenamiento de la red neuronal convolucional (CNN). Como es habitual en este tipo de redes, el valor de pérdida inicia en un nivel alto, pero disminuye con rapidez conforme el modelo se ajusta a los datos. Este descenso progresivo indica que la red está aprendiendo correctamente y adaptando sus parámetros de manera eficiente a lo largo del proceso de entrenamiento.




Figura 12. Curva de error durante el entrenamiento.

3. Resultados y discusión

Para evaluar el rendimiento del modelo en la predicción de emisiones vinculadas a fallos en componentes y actuadores, se realizaron diversos ensayos aplicando distintos métodos de análisis. La Figura 13 ilustra

un conjunto de 160 registros correspondientes a la etapa de prueba. En esta gráfica, los círculos azules representan los valores estimados por la red neuronal convolucional (CNN), mientras que las cruces rojas indican los valores reales. Como puede observarse, las predicciones del modelo presentan una alta precisión, con errores que no superan el 1 % en ningún caso. Además, se calcularon las métricas MAE (error absoluto medio) y MSE (error cuadrático medio), cuyos resultados confirman la fiabilidad y el adecuado ajuste del modelo propuesto.

En la Figura 14 se comparan los valores reales con las predicciones obtenidas por la red neuronal convolucional (CNN) para las concentraciones de CO, CO₂, HC y O₂. Los puntos azules, que representan los valores estimados por el modelo, se ubican muy cerca de la línea de referencia, lo que indica una estimación precisa de las emisiones en diferentes condiciones de funcionamiento. Además, se observa que las ocho condiciones del motor de encendido provocado (MEP) fueron correctamente identificadas por la red, lo que respalda la solidez del modelo propuesto.

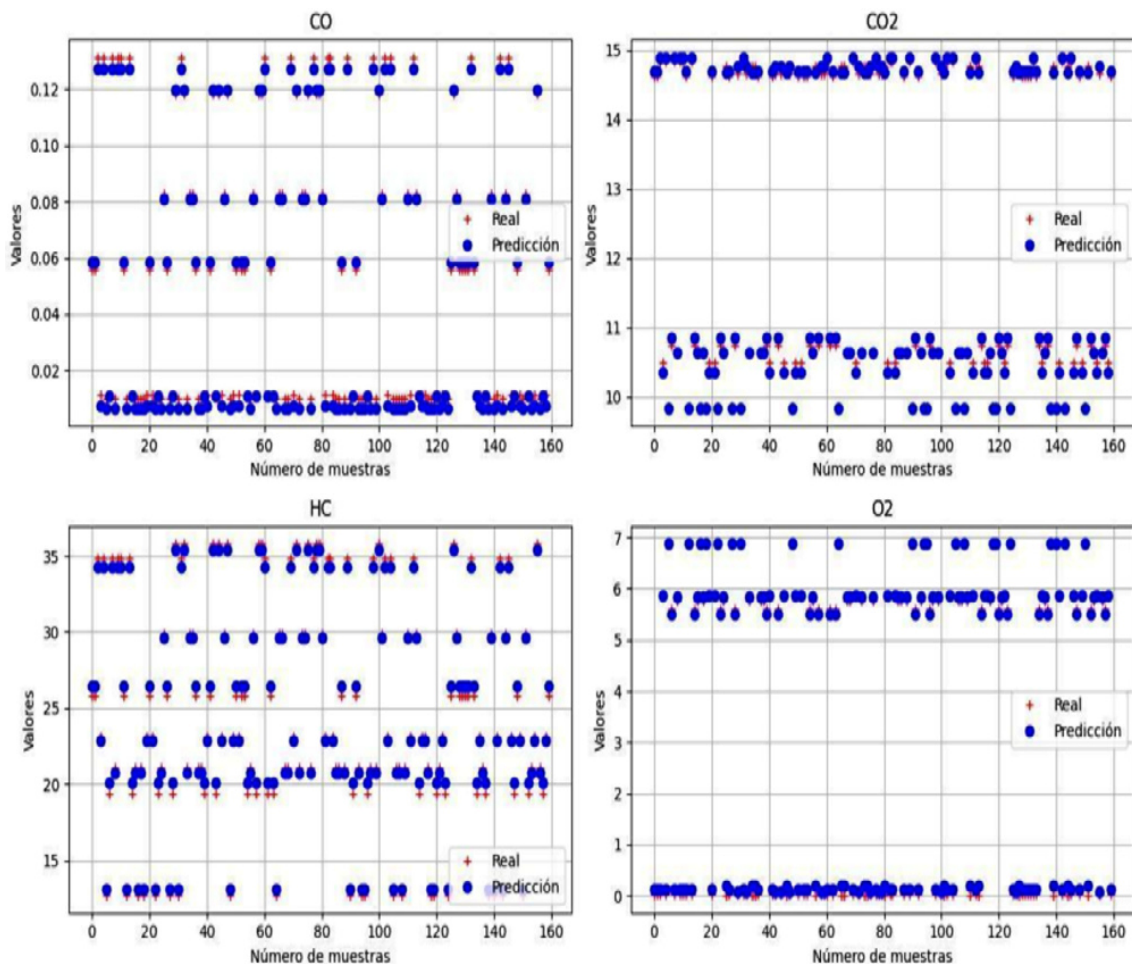


Figura 13. Resultado de la CNN en la estimación de gases de escape: CO, CO₂, HC, O₂.




Figura 14. Resultado de CNN con emisión 1 (monóxido de carbono), emisión 2 (dióxido de carbono), emisión 3 (hidrocarburos no combustionados) y emisión 4 (oxígeno).

En la Tabla 4 se presentan diversas aplicaciones del área automotriz que emplean distintas técnicas para la predicción de emisiones, junto con factores relevantes asociados a cada enfoque.

Los resultados obtenidos confirman que la metodología aplicada es efectiva tanto para diagnos-

ticar fallos como para predecir emisiones contaminantes. La coincidencia entre los valores reales y los estimados por el modelo indica que este logra identificar con precisión el estado operativo del motor y calcular las concentraciones de gases de escape con un margen de error muy reducido.

Tabla 4. Estudios relacionados de predicción de emisiones en el área automotriz

N.º	Fuente	Técnica	Aplicación
1	[2]	Feed-forward backpropagation	Predicción de emisiones en MEP
2	[3]	Feed-forward backpropagation	Predicción de emisiones en MEC
3	[7]	RNN y FFNN	Predecir temperatura y emisiones de MEC
4	[1]	ANN	Predicción de emisiones de MEP
5	[4]	LSTM y CNN	Predecir relación aire-combustible
6	[9]	ANN, CNN-BiLSTM, SVM y XGBoost	Evaluación de olores en interiores de vehículos
7	[10]	RNA	Predecir potencia efectiva y emisiones en MEP

En el estudio [2] se obtuvieron redes neuronales para la predicción de CO y HC, con errores de $5.40e-9$ y $9.75e-5$, respectivamente. De igual manera, el estudio presentado en [1] reporta errores de predicción igualmente bajos, mostrando un excelente nivel de ajuste, con un coeficiente de determinación (R^2) del 99.2 % y valores reducidos de error cuadrático medio

(RMSE y MSE) para la emisión de CO_2 . Por otra parte, la aplicación de redes neuronales artificiales permite alcanzar predicciones precisas de parámetros de desempeño del motor y de emisiones como NO_x y HC, tal como demuestra [10], donde se alcanzaron niveles de precisión del 99 % y del 98 %, respectivamente.

Por lo tanto, los resultados obtenidos indican que la metodología propuesta —basada en espectrogramas de la señal MAP y una red neuronal convolucional (CNN)— alcanza una precisión notable en la estimación simultánea de emisiones contaminantes (CO, CO₂, HC y O₂), con errores inferiores al 1 %. Estos valores superan ampliamente los reportes de trabajos previos que emplean técnicas tradicionales como redes neuronales densas (ANN), máquinas de soporte vectorial (SVM) o métodos basados en regresiones multivariantes, tal como se evidencia en la Tabla 4.

En relación con esto, la Figura 15 presenta un análisis estadístico de los datos agrupados, comparando la condición real de la unidad experimental con las predicciones realizadas por la red neuronal convolucional (CNN) para las concentraciones de hidrocarburos no quemados (HC). Para esta comparación se empleó el test de Tukey, con un nivel de confianza del 95 %.

Los resultados indican que no existen diferencias estadísticamente significativas entre las mediciones reales y las generadas por el modelo. Esto sugiere que las medias de ambos conjuntos son equivalentes y que las variaciones observadas se mantienen dentro de un rango muy próximo a cero.

La Figura 16 muestra la gráfica de intervalos que compara la condición real con las estimaciones realizadas por la red neuronal convolucional (CNN) en relación con las concentraciones de hidrocarburos no quemados (HC). Al observar los resultados, se aprecia que no existen diferencias significativas entre los promedios registrados bajo las distintas condiciones operativas del motor de encendido provocado (MEP). Esto refuerza la confiabilidad del modelo en diversos escenarios de funcionamiento. De manera similar, la Figura 17 analiza la relación entre los valores estimados por la red neuronal convolucional (CNN) y los valores reales, aplicando el test estadístico de Tukey para evaluar posibles diferencias. Los resultados indican que ambos conjuntos comparten la misma letra de agrupación (A), lo que sugiere que no existen diferencias estadísticamente significativas entre ellos.

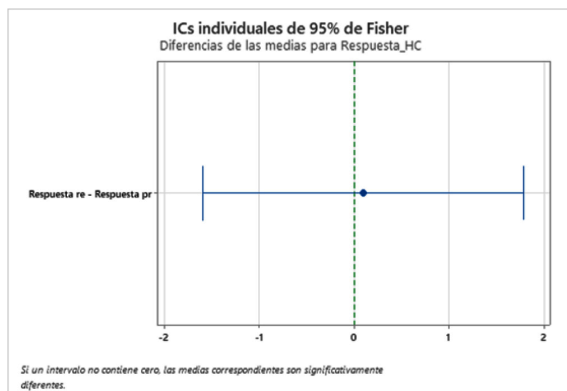


Figura 15. Gráfico comparativo de medias entre datos reales y CNN de HC.




Figura 16. Gráfica de intervalos de datos reales vs. CNN de HC.

Además, el análisis de varianza (ANOVA) arrojó un valor p de 0,911, lo que, con un nivel de confianza del 91,1 %, respalda la consistencia y precisión del modelo desarrollado.

Análisis de Varianza

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Respuesta	1	0.6	0.5555	0.01	0.911
Error	238	10523.5	44.2164		
Total	239	10524.1			

Agrupar información utilizando el método de Tukey y una confianza de 95%

Respuesta	N	Media Agrupación
Respuesta real	120	25.465 A
Respuesta predicha	120	25.368 A

Las medias que no comparten una letra son significativamente diferentes.

Figura 17. Resultados ANOVA y método de Tukey.

3.1. Limitaciones

Este estudio se desarrolló sobre un motor Otto con una configuración de sistema de inyección moderno, dentro de un rango específico de puntos de operación y tipos de fallo inducidos. Esta elección responde a la necesidad de trabajar en un entorno controlado que permita aislar el efecto de los fallos sobre las emisiones y entrenar la CNN con datos consistentes y repetibles. En este sentido, los resultados obtenidos son representativos y sólidos para el motor y las condiciones consideradas, y muestran el potencial de la metodología propuesta para relacionar fallos en componentes y actuadores con variaciones en las emisiones.

4. Conclusiones

Esta investigación destaca por integrar sistemas de adquisición de datos con algoritmos de inteligencia artificial para el diagnóstico temprano de fallos en motores de encendido provocado (MEP). Se abordaron

anomalías en la toma de vacío del regulador de presión de combustible y en el filtro de aire. El método permite detectar fallos sin desmontar componentes, ofreciendo un diagnóstico mínimamente invasivo.

Los ensayos experimentales confirmaron que el modelo, basado en una red neuronal convolucional compuesta por tres capas convolucionales, capas de normalización y MaxPooling2D, es capaz de predecir las emisiones con alta precisión. Se obtuvieron errores cuadráticos medios (MSE) bajos, con valores de 0.1294 % para CO, 0.0200 % para HC, 0.0320 % para CO₂ y 0.0100 % para O₂, utilizando 50 épocas de entrenamiento y hasta 900 iteraciones.

Además, se aplicó un análisis de varianza de un solo factor mediante el software Minitab, cuyo resultado arrojó un valor p de 0.911. Este resultado indica que no existen diferencias estadísticamente significativas entre los valores reales y los estimados por la red, lo cual respalda la confiabilidad del modelo.

En conjunto, estos hallazgos refuerzan el potencial de las redes neuronales convolucionales como una solución eficaz y no invasiva para la detección de fallos y la predicción de emisiones en motores de encendido provocado, destacando su bajo margen de error y su aplicabilidad práctica en sistemas de combustión interna.

Si bien las métricas empleadas (MSE y MAE) son suficientes para evidenciar la precisión del modelo convolucional, se reconoce que otros indicadores pueden aportar valor en análisis comparativos o de sensibilidad. Por ello, se considera incorporar en trabajos futuros métricas adicionales como RMSE, R² y MAPE.

Rol de autores

- **Elmer I. Arias-Montaña:** conceptualización, curación de datos, análisis formal, investigación, metodología, administración de proyecto, recursos, desarrollo de software, supervisión, validación, visualización, escritura borrador original, escritura – revisión y edición
- **Rogelio S. León-Japa:** conceptualización, análisis formal, investigación, metodología, administración de proyecto, recursos, desarrollo de software, supervisión, validación, visualización, escritura – revisión y edición.
- **Pedro García-Jaramillo:** curación de datos, desarrollo de software, validación.
- **José Maldonado-Ortega:** curación de datos, desarrollo de software, validación.

Referencias


- [1] W. R. Contreras Urgilés, R. S. León Japa, and J. L. Maldonado Ortega, “Predicción de emisiones de CO y HC en motores Otto mediante redes neuronales,” *Ingenius*, no. 23, pp. 30–39, Dec. 2019. [Online]. Available: <https://doi.org/10.17163/ings.n23.2020.03>
- [2] F. Narváez, F. E. Sierra Vargas, and M. A. Montenegro Mier, “Modelo basado en redes neuronales para predecir las emisiones en un motor diésel que opera con mezclas de biodiésel de higuera,” *Informador Técnico*, vol. 76, p. 46, Dec. 2012. [Online]. Available: <https://doi.org/10.23850/22565035.28>
- [3] R. S. Chauhan and N. Shrivastava, “Neuro fuzzy-grey wolf optimization-based modelling and analysis of diesel engine using tire oil with different proportions of 2-EHN,” *Fuel*, vol. 384, p. 133849, Mar. 2025. [Online]. Available: <https://doi.org/10.1016/j.fuel.2024.133849>
- [4] F. Sapio, F. Aglietti, P. Ferreri, and A. Savuca, “Neural-network-based modeling of SCR systems for emission simulation: A comprehensive approach,” *SAE International Journal of Advances and Current Practices in Mobility*, vol. 07, no. 3, pp. 1437–1452, Sep. 2024. [Online]. Available: <https://doi.org/10.4271/2024-24-0042>
- [5] H. H. Imtiaz, P. Schaffer, Y. Liu, P. Hesse, A. Bergmann, and M. Kupper, “Qualitative and quantitative analyses of automotive exhaust plumes for remote emission sensing application using gas schlieren imaging sensor system,” *Atmosphere*, vol. 15, no. 9, p. 1023, Aug. 2024. [Online]. Available: <https://doi.org/10.3390/atmos15091023>
- [6] W. Torres Guin, J. Sánchez Aquino, S. Bustos Gaibor, and M. Coronel Suárez, “Arquitectura de IoT para el monitoreo de emisiones de gases contaminantes de vehículos y su validación a través de machine learning,” *Ingenius*, no. 32, pp. 9–17, Oct. 2024. [Online]. Available: <https://doi.org/10.17163/ings.n32.2024.01>
- [7] R. S. Jawad and H. Abid, “HVDC fault detection and classification with artificial neural network based on ACO-DWT method,” *Energies*, vol. 16, no. 3, p. 1064, Jan. 2023. [Online]. Available: <https://doi.org/10.3390/en16031064>
- [8] F. Ricci, M. Avana, and F. Mariani, “Enhancing lambda measurement in hydrogen-fueled SI engines through virtual sensor implementation,” *Energies*, vol. 17, no. 16, p. 3932, Aug. 2024. [Online]. Available: <https://doi.org/10.3390/en17163932>
- [9] D. Tian, Q. Li, F. Liu, J. Khan, M. Q. Abbas, and Z. Du, “VOC data-driven evaluation of vehicle cabin odor: from ANN to CNN-BiLSTM,” *Environmental Science and*

- Pollution Research*, vol. 31, no. 22, pp. 32 826–32 841, Apr. 2024. [Online]. Available: <https://doi.org/10.1007/s11356-024-33293-y>
- [10] I. Cesur and F. Uysal, “Experimental investigation and artificial neural network-based modelling of thermal barrier engine performance and exhaust emissions for methanol-gasoline blends,” *Energy*, vol. 291, p. 130393, Mar. 2024. [Online]. Available: <https://doi.org/10.1016/j.energy.2024.130393>
- [11] A. K. and P. Rithishbrahma, “Prediction of vehicle carbon emission using machine learning,” in *2024 5th International Conference on Electronics and Sustainable Communication Systems (ICESC)*. IEEE, Aug. 2024, pp. 1814–1818. [Online]. Available: <https://doi.org/10.1109/ICESC60852.2024.10690134>
- [12] M. A. Rahim, M. M. Rahman, M. S. Islam, A. J. M. Muzahid, M. A. Rahman, and D. Ramasamy, “Deep learning-based vehicular engine health monitoring system utilising a hybrid convolutional neural network/bidirectional gated recurrent unit,” *Expert Systems with Applications*, vol. 257, p. 125080, Dec. 2024. [Online]. Available: <https://doi.org/10.1016/j.eswa.2024.125080>
- [13] H. Sun and P. Chen, “Application of neural networks in automotive engine misfire,” in *2024 IEEE 4th International Conference on Electronic Communications, Internet of Things and Big Data (ICEIB)*. IEEE, Apr. 2024, pp. 261–264. [Online]. Available: <https://doi.org/10.1109/ICEIB61477.2024.10602668>
- [14] M. Abboush, D. Bamal, C. Knieke, and A. Rausch, “Intelligent fault detection and classification based on hybrid deep learning methods for hardware-in-the-loop test of automotive software systems,” *Sensors*, vol. 22, no. 11, p. 4066, May 2022. [Online]. Available: <https://doi.org/10.3390/s22114066>
- [15] S.-C. Lin, S.-F. Su, and Y. Huang, “A time-frequency signal-based convolutional neural network algorithm for fault diagnosis of gasoline engine fuel control system,” in *2019 International Conference on System Science and Engineering (ICSSE)*. IEEE, Jul. 2019, pp. 81–87. [Online]. Available: <https://doi.org/10.1109/ICSSE.2019.8823285>
- [16] A. Maged and M. Nour, “Prediction of combustion pressure with deep learning using flame images,” *Fuel*, vol. 380, p. 133203, Jan. 2025. [Online]. Available: <https://doi.org/10.1016/j.fuel.2024.133203>
- [17] Z. Li, Z. Qin, W. Luo, and X. Ling, “Gasoline engine misfire fault diagnosis method based on improved YOLOv8,” *Electronics*, vol. 13, no. 14, p. 2688, Jul. 2024. [Online]. Available: <https://doi.org/10.3390/electronics13142688>
- [18] Y. Liu, J. Kang, L. Wen, Y. Bai, and C. Guo, “Health status assessment of diesel engine valve clearance based on BFA-BOA-VMD adaptive noise reduction and multi-channel information fusion,” *Sensors*, vol. 22, no. 21, p. 8129, Oct. 2022. [Online]. Available: <https://doi.org/10.3390/s22218129>
- [19] W. R. Contreras Urgilés, J. Maldonado Ortega, and R. León Japa, “Aplicación de una red neuronal feed-forward backpropagation para el diagnóstico de fallas mecánicas en motores de encendido provocado,” *Ingenius*, no. 21, pp. 32–40, Dec. 2018. [Online]. Available: <https://doi.org/10.17163/ings.n21.2019.03>
- [20] MathWorks. (2025) Redes neuronales convolucionales. The MathWorks, Inc. [Online]. Available: <https://upsalesiana.ec/ing35ar7r20>



APLICACIÓN DE MODELOS U-NET PARA SEGMENTACIÓN SEMÁNTICA DE DEFECTOS EN PANELES FOTOVOLTAICOS

U-NET–BASED SEMANTIC SEGMENTATION OF DEFECTS IN PHOTOVOLTAIC PANELS

Franklin Gómez-López¹ , Danny Ochoa-Correa^{2,*} , Isabel Cabrera-Carrera¹ 

Recibido: 16-06-2025, Recibido tras revisión: 18-11-2025, Aceptado: 04-12-2025, Publicado: 01-01-2026

Resumen


Este artículo presenta un estudio sobre la segmentación semántica de defectos en celdas fotovoltaicas de silicio cristalino mediante modelos basados en U-Net, entrenados con imágenes de electroluminiscencia (EL). Se empleó un conjunto de datos compuesto por imágenes adquiridas en laboratorio y un prototipo público de pruebas, ambos con anotaciones manuales de grietas, zonas oscuras y discontinuidades en barras colectoras. Se entrenaron ocho versiones del modelo, incorporando variaciones controladas en la resolución, la profundidad del codificador y las estrategias de regularización. La evaluación incluyó métricas clase a clase (precisión, *recall* y *F1-score*), análisis visual mediante mapas de calor y superposiciones, así como validación por expertos. Si bien la segmentación fue consistente en defectos de morfología clara, como zonas oscuras y barras colectoras, las grietas presentaron mayores dificultades debido a su baja densidad de píxeles y geometría irregular. Asimismo, se analizaron arquitecturas alternativas (U-Net++ y MAU-Net), sin evidenciar mejoras relevantes frente a la configuración optimizada de U-Net. Los resultados respaldan el uso de este enfoque en tareas de inspección automatizada bajo condiciones controladas, y se proponen extensiones para su aplicación en contextos operativos más diversos.

Palabras clave: electroluminiscencia, mantenimiento predictivo, paneles solares, segmentación semántica, U-Net

Abstract

This article presents a study on the semantic segmentation of defects in crystalline-silicon photovoltaic cells using U-Net–based models trained on electroluminescence (EL) images. The dataset combines laboratory-acquired images with a publicly available benchmark, both manually annotated to identify cracks, dark zones, and collector-bar discontinuities. Eight model variants were trained with controlled variations in input resolution, encoder depth, and regularization strategies. Performance was assessed using per-class precision, recall, and F1-score, complemented by visual inspection through heatmaps and overlays and by expert validation. Segmentation was robust for defects with well-defined morphology, such as dark zones and busbars; however, cracks remained more difficult to detect due to their sparse pixel representation and irregular geometry. Alternative architectures (U-Net++ and MAU-Net) were also evaluated but did not yield meaningful improvements over the optimized U-Net configuration. Overall, the results support the use of this approach for automated inspection under controlled conditions, while highlighting the need for future adaptation to more diverse operational scenarios.

Keywords: Electroluminescence, predictive maintenance, photovoltaic panels, semantic segmentation, U-Net

^{1,*}Facultad de Ingeniería, Universidad de Cuenca, Ecuador. 

²Departamento de Ingeniería Eléctrica, Electrónica y de Telecomunicaciones, Universidad de Cuenca, Ecuador. 
 Autor para correspondencia ✉: danny.ochoac@ucuenca.edu.ec

Forma sugerida de citación: F. Gómez-López, D. Ochoa-Correa y I. Cabrera-Carrera, “Aplicación de modelos U-Net para segmentación semántica de defectos en paneles fotovoltaicos,” *Ingenius, Revista de Ciencia y Tecnología*, N.º 35, pp. 110-121, 2026. DOI: <https://doi.org/10.17163/ings.n35.2026.08>.

1. Introducción

Los sistemas de energía fotovoltaica (PV) se han convertido en un pilar fundamental de los esfuerzos globales de transición energética, particularmente a través de la generación distribuida y la electrificación descentralizada. A medida que las instalaciones fotovoltaicas continúan expandiéndose, mantener su integridad operativa mediante métodos diagnósticos precisos resulta cada vez más crucial.

La imagen de electroluminiscencia (EL) se utiliza ampliamente para detectar anomalías estructurales en los módulos fotovoltaicos, incluidas microfisuras, dedos rotos y áreas eléctricamente inactivas [1, 2]. Aunque estos defectos suelen ser imperceptibles durante las inspecciones visuales, pueden degradar progresivamente el rendimiento del módulo con el tiempo.

En comparación con la termografía infrarroja y la fluorescencia ultravioleta, la imagen EL ofrece una resolución espacial superior para la detección temprana de defectos, sin depender de la irradiancia solar ni de gradientes de temperatura [3, 4]. No obstante, las imágenes EL sin procesar suelen presentar ruido e iluminación desigual, lo que dificulta la identificación de patrones sutiles de defectos. Estas limitaciones subrayan la necesidad de técnicas avanzadas de análisis de imágenes capaces de aislar de manera fiable características de defectos finos y heterogéneos.

La segmentación semántica, que clasifica los píxeles individuales en categorías predefinidas, permite una localización precisa de defectos en imágenes de electroluminiscencia (EL) [5, 6]. Entre los enfoques de aprendizaje profundo, las redes neuronales convolucionales (CNN) han demostrado un desempeño sólido en tareas de segmentación. En particular, la arquitectura U-Net es ampliamente adoptada para la detección de defectos en módulos fotovoltaicos [7].

Desarrollada originalmente para el análisis de imágenes biomédicas, U-Net integra de manera eficaz la extracción de características a múltiples escalas con la preservación de la resolución espacial, lo que favorece la detección de estructuras estrechas y localizadas, como microfisuras e inconsistencias de soldadura en celdas fotovoltaicas [8, 9].

Investigaciones recientes han adaptado y refinado variantes de U-Net para la segmentación de defectos en sistemas fotovoltaicos mediante la incorporación de mecanismos de atención, conexiones residuales y funciones de pérdida híbridas [10, 11]. Estas modificaciones mejoran la robustez del modelo bajo condiciones variables de iluminación y aumentan la precisión de la segmentación, dada la variabilidad entre celdas presente en los conjuntos de datos de módulos fotovoltaicos.

Además, los conjuntos de datos de imágenes EL de acceso público, incluidos aquellos publicados por Fraunhofer ISE y Sandia National Laboratories, respaldan la evaluación comparativa y la reproducibilidad de los

resultados de segmentación [12, 13]. En este estudio se implementan y evalúan múltiples arquitecturas U-Net entrenadas con imágenes EL de celdas solares de silicio cristalino. Mediante el uso de conjuntos de datos tanto propietarios como públicos, se analiza la precisión de la segmentación en distintos tipos de defectos.

La evaluación incorpora estrategias de optimización de parámetros y comparaciones cuantitativas con el fin de determinar la idoneidad de los métodos basados en U-Net para respaldar la inspección automatizada bajo condiciones controladas de laboratorio.

2. Materiales y métodos

2.1. Conjuntos de datos

2.1.1. Conjunto de datos de electroluminiscencia interno

El conjunto de datos principal fue recopilado en el Laboratorio de Micro-Red de la Universidad de Cuenca. Este comprende 180 celdas solares extraídas de módulos fotovoltaicos monocristalinos y policristalinos fuera de servicio. Cada celda fue capturada bajo condiciones controladas utilizando una cámara OWL 640 M SWIR (Raptor Photonics), equipada con un sensor InGaAs sensible al rango espectral de 900–1700 nm. Este intervalo proporciona un contraste mejorado para la identificación de defectos en silicio cristalino en comparación con sensores que operan en el espectro visible.

Para garantizar una iluminación uniforme, las celdas fueron polarizadas mediante una fuente de alimentación programable Chroma DC. La corriente aplicada se varió entre $\frac{1}{6}I_{SC}$ y I_{SC} , siguiendo la norma IEC TS 60904-13, con el fin de examinar cómo la intensidad de excitación influye en las características de la luminiscencia. La adquisición de imágenes se gestionó mediante la plataforma XCAP-Std, lo que posibilitó el ajuste en tiempo real del tiempo de exposición, la ganancia y la velocidad de fotogramas. Los parámetros óptimos de adquisición fueron tiempos de exposición de 30 y 50 ms, un factor de ganancia de 2.5 y una corriente de polarización de aproximadamente 6 A, correspondiente a cerca de $\frac{2}{3}I_{SC}$.

Para validar la calidad del sistema de adquisición, la relación señal-ruido (SNR) se cuantificó de acuerdo con la norma IEC TS 60904-13 [14] y se definió como se ve en la ecuación (1):

$$SNR_{IEC} = \frac{\sum\{0.5 \cdot (I_1 + I_2) - I_{BG}\}}{\sum[\sqrt{0.5 \cdot |I_1 - I_2| \cdot (\frac{2}{\pi})^{-0.5}}]} \quad (1)$$

Donde I_1 e I_2 son capturas EL consecutivas e I_{BG} representa el ruido de fondo. El arreglo experimental alcanzó un valor de $SNR_{IEC} > 45$, cumpliendo los criterios establecidos para mediciones de laboratorio.

Posteriormente, las imágenes EL sin procesar fueron sometidas a un preprocesamiento que incluyó sustracción de fondo, corrección de perspectiva y mejora del contraste local mediante la ecualización de histograma adaptativa con límite de contraste (CLAHE), configurada con un límite de recorte de 2.0 y un tamaño de cuadrícula de 8×8 . Esta cadena de preprocesamiento mejoró de manera significativa la calidad de las imágenes para las tareas de segmentación.

2.1.2. Conjunto de datos de referencia público

Además del conjunto de datos propietario, se utilizó para la validación el conjunto de datos público ELPV, desarrollado por el grupo ZAE Bayern. Este conjunto comprende imágenes de electroluminiscencia (EL) y sus correspondientes máscaras binarias de grietas para 2624 celdas solares, obtenidas en condiciones de fábrica.

A pesar de las diferencias en la resolución y en la estructura de las máscaras en comparación con el conjunto de datos interno, se emplearon scripts de preprocesamiento para unificar las dimensiones de las imágenes y los formatos de codificación.

Al integrar tanto los conjuntos de datos internos como externos, el conjunto combinado respalda la generalización del modelo a través de diferentes tipos de paneles y configuraciones de adquisición. Estudios previos que han adoptado estrategias similares basadas en conjuntos de datos híbridos han reportado mejoras tanto en la precisión de la segmentación como en la robustez entre dominios.

2.1.3. Integración y preprocesamiento de datos

Dado que el conjunto de datos público ELPV proporcionaba únicamente máscaras binarias de grietas, se llevó a cabo un proceso de reanotación utilizando la plataforma Supervisely [15], con el fin de generar manualmente las máscaras de referencia correspondientes a las clases no anotadas originalmente.

Esto garantizó que los conjuntos de datos interno y público compartieran un esquema de anotación multiclase coherente, compuesto por fondo y tres clases de defectos.

La Tabla 1 resume la distribución de las instancias de defectos en los conjuntos de entrenamiento y validación. El predominio de la clase *busbar* es esperado, ya que este componente estructural está presente en cada celda.

Este desbalance de clases se abordó durante el entrenamiento mediante la cadena de aumento de datos descrita en la sección siguiente.

Tabla 1. Distribución de instancias de defectos en los conjuntos de entrenamiento y validación

Clase de defectos	Instancias de entrenamiento	Instancias de validación
Barras colectoras	1453	96
Grietas	608	92
Zonas oscuras	425	84

2.2. Configuración y flujo de adquisición

El montaje completo del sistema de adquisición se muestra en la Figura 1. La cámara SWIR se posicionó ortogonalmente sobre la celda, manteniendo una distancia fija de 50 cm entre la lente y el objeto. La captura de imágenes se realizó en una cámara oscurecida con el fin de eliminar la interferencia de la luz ambiental. Asimismo, se aplicó la corrección de no uniformidad (NUC) mediante un método de tres puntos (Offset + Gain + Dark), con el objetivo de minimizar el ruido de patrón fijo.

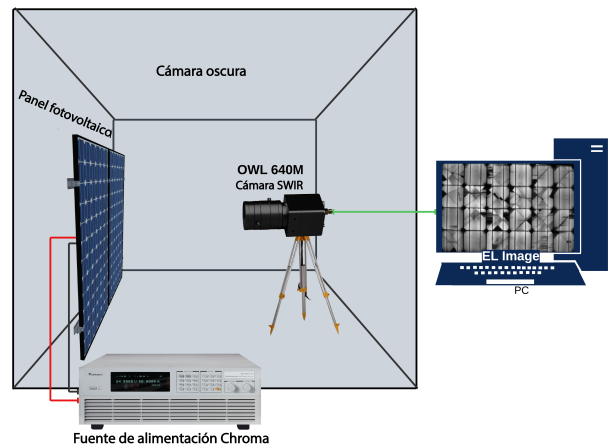


Figura 1. Montaje experimental que muestra la cámara OWL 640 M SWIR y el módulo fotovoltaico bajo prueba.

Todos los pasos de procesamiento de imágenes se implementaron en Python mediante las bibliotecas OpenCV y NumPy. Las métricas de evaluación, incluidas la relación de mejora de contraste (CIR), la relación pico-a-bajo (PL) y los mapas de calor, se extrajeron de cada imagen preprocesada.

2.3. Coherencia de la anotación

La concordancia entre anotadores se evaluó periódicamente utilizando el coeficiente de Dice, ver ecuación (2):

$$\text{Dice}(A, B) = \frac{2|A \cap B|}{|A| + |B|} \quad (2)$$

Donde A y B representan conjuntos de píxeles anotados de forma independiente por distintos evaluadores.

A lo largo de todo el proceso de anotación se mantuvo de manera consistente un valor medio del coeficiente de Dice superior a 0.85.

Estos conjuntos de datos sirvieron como base para el entrenamiento y la validación de los modelos de segmentación descritos en la sección siguiente.

2.4. Arquitectura del modelo

2.4.1. U-Net estándar con codificador VGG16

La arquitectura empleada en este estudio se basa en U-Net, desarrollada originalmente para la segmentación de imágenes biomédicas [7]. Su estructura de tipo codificador-decodificador permite la clasificación a nivel de píxel mediante la integración de características multiescala, al tiempo que preserva la resolución espacial. En esta implementación, la ruta de contracción se sustituye por un codificador VGG16 preentrenado en el conjunto de datos ImageNet [16].

Dado que la arquitectura VGG16 estándar espera una entrada de tres canales (RGB) y las imágenes EL son de un solo canal (escala de grises), la entrada se adaptó durante el preprocesamiento replicando el canal único tres veces, con el fin de coincidir con las dimensiones tensoriales esperadas sin modificar los pesos preentrenados. Esta configuración favorece una representación más rica de características en la etapa de entrada y contribuye a una convergencia más estable durante el entrenamiento [17].

Cada etapa de muestreo descendente en el codificador incluye dos capas convolucionales de 3×3 , seguidas de una operación de *max-pooling* de 2×2 . El codificador genera cinco mapas de características de profundidad creciente. Para ampliar el campo receptivo sin comprometer las dimensiones espaciales, el *bottleneck* emplea convoluciones dilatadas con una tasa de dilatación fija de $r = 2$.

La Figura 2 ilustra la variante de U-Net adoptada en este estudio, que incorpora convoluciones dilatadas en el *bottleneck* con el objetivo de ampliar el campo receptivo sin incrementar el número de parámetros del modelo [8, 18].




Figura 2. Arquitectura U-Net con codificador VGG16 y *bottleneck* de convoluciones dilatadas.

2.4.2. Configuración de capas, funciones de activación y salida multiclase

Todas las capas convolucionales emplean funciones de activación ReLU y normalización por lotes con el fin de mejorar la estabilidad del entrenamiento. Se aplica una tasa de dropout de 0.2 en el *bottleneck* y en las capas del decodificador para mitigar el sobreajuste.

El decodificador realiza el muestreo ascendente de los mapas de características mediante convoluciones transpuestas, incorporando conexiones de salto que vinculan cada bloque de muestreo ascendente con la etapa correspondiente del codificador. La capa de salida consiste en una convolución de 1×1 seguida de una activación softmax, con el propósito de generar una distribución de probabilidad por píxel sobre C clases de defectos, ver ecuación (3):

$$\text{Salida}_{i,j,c} = \frac{\exp(z_{i,j,c})}{\sum_{k=1}^C \exp(z_{i,j,k})} \quad (3)$$

Donde $z_{i,j,c}$ es la puntuación sin procesar para la clase c en el píxel (i, j) , y $C = 3$ representa las clases de defectos: grietas, zonas oscuras y *busbars*.

Las imágenes de entrada corresponden a imágenes de electroluminiscencia (EL) en escala de grises, redimensionadas a una resolución de 256×256 píxeles. Las máscaras de segmentación de salida preservan la misma resolución. Toda la cadena de procesamiento y entrenamiento se implementó utilizando el entorno PyTorch.

Estudios previos indican que la combinación de conexiones de salto, una arquitectura simétrica y salidas multiclase resulta adecuada para la detección de patrones sutiles de defectos en imágenes EL [10, 19].

Asimismo, se examinaron arquitecturas alternativas, como MAU-Net con mecanismos de atención espacial y de canal, con fines comparativos; sus resultados se presentan y discuten en la sección de Resultados y discusión.

2.5. Proceso de entrenamiento

2.5.1. Preprocesamiento y aumento de datos

Antes del entrenamiento, todas las imágenes de electroluminiscencia (EL) se redimensionaron a una resolución estándar de 256×256 píxeles. Para distinguir de forma adecuada las características continuas de la imagen de las etiquetas categóricas durante el redimensionamiento, se aplicó interpolación bilineal a las imágenes EL en escala de grises, mientras que se utilizó interpolación por vecino más cercano para las máscaras, con el fin de preservar los valores discretos de las clases. Posteriormente, los valores de los píxeles se normalizaron al rango $[0, 1]$ para garantizar un formato de entrada coherente y mejorar la estabilidad del modelo. Cada imagen de entrada en escala de grises se emparejó con una máscara codificada en one-hot que

representaba las tres categorías de defectos: grietas, zonas oscuras y *busbars* (barras colectoras).

Con el objetivo de ampliar la variabilidad de las muestras de entrenamiento, se aplicó aumento de datos *on-the-fly*. Las transformaciones incluyeron volteos horizontales y verticales, rotaciones aleatorias de hasta $\pm 15^\circ$, escalamiento por zoom en el rango de $0.9\times$ a $1.1\times$, y deformaciones elásticas. Estos aumentos se aplicaron de manera probabilística mediante la biblioteca Albumentations, garantizando que la integridad estructural de las máscaras se mantuviera.

Este enfoque de aumento de datos mejora la capacidad de generalización, particularmente en modelos entrenados con conjuntos de datos EL pequeños u homogéneos. Estrategias similares han sido empleadas para abordar el desbalance de clases y aumentar la sensibilidad a patrones de defectos poco frecuentes.

2.5.2. Configuración de hiperparámetros y programador de tasa de aprendizaje

El entrenamiento del modelo se realizó utilizando el optimizador Adam, que combina la estimación adaptativa del gradiente con momentum. Los hiperparámetros seleccionados fueron los siguientes:

- Tasa de aprendizaje: $lr = 0.0018$
- Tasa de decaimiento del primer momento:
 $\beta_1 = 0.9$
- Tasa de decaimiento del segundo momento:
 $\beta_2 = 0.999$
- Término de estabilidad numérica: $\epsilon = 1 \times 10^{-8}$

El entrenamiento se guio mediante la función de pérdida estándar de entropía cruzada categórica, ver ecuación (4):

$$\mathcal{L} = - \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \log(\hat{y}_{i,c}) \quad (4)$$

Donde $y_{i,c}$ representa la etiqueta verdadera (*codificada en one-hot*) $\hat{y}_{i,c}$ corresponde a la probabilidad predicha para la clase c en el píxel i . Aunque el desbalance de clases es inherente a la detección de defectos en imágenes de electroluminiscencia (EL), este se abordó principalmente mediante la estrategia agresiva de aumento de datos descrita en la sección anterior, en lugar de aplicar ponderaciones de clase en la función de pérdida.

Se utilizó un programador de tasa de aprendizaje basado en pasos con el fin de mejorar la convergencia y evitar mínimos locales. La tasa de aprendizaje se redujo por un factor $\gamma = 0.05$ cada ocho épocas. Este decaimiento gradual facilitó el ajuste fino durante las fases posteriores del entrenamiento. Asimismo, se habilitó *early stopping* para finalizar el entrenamiento si la pérdida de validación no mostraba mejoras durante 10 épocas consecutivas.

El proceso de entrenamiento fue iterativo. Cada versión posterior del modelo se inicializó con los pesos de la versión previa de mejor desempeño, lo que permitió un refinamiento progresivo sin reinicialización completa. La versión final del modelo (U-Net_v32) se entrenó durante 48 épocas, observándose la menor pérdida de validación en la época 26. Los valores correspondientes de pérdida de entrenamiento y validación se muestran en la ecuación (5):

$$\text{Train loss} = 0.0313 \quad \text{Val loss} = 0.0627 \quad (5)$$

La Figura 3 muestra la evolución de los valores de pérdida a lo largo de las distintas versiones del modelo. Estas visualizaciones permitieron monitorizar el comportamiento del entrenamiento y validar las mejoras incrementales obtenidas en cada iteración.




Figura 3. Evolución de la pérdida de entrenamiento y validación durante el proceso iterativo de optimización del modelo U-Net.

Con el fin de garantizar la reproducibilidad, todos los experimentos se realizaron utilizando el entorno PyTorch (v2.3.1) en Google Colab Pro, equipado con una GPU NVIDIA T4. Se fijó una semilla aleatoria de 42 para la inicialización de los pesos y la partición de los datos. El entrenamiento se llevó a cabo con un tamaño de lote de 16 durante 48 épocas, empleando el optimizador Adam con una tasa de aprendizaje inicial de 0.0018 y un programador de decaimiento basado en pasos (*step-based*), con $step_size = 8$ y $\gamma = 0.05$. Los mejores pesos del modelo se almacenaron en función de la mínima pérdida de validación, que típicamente convergía alrededor de la época 26.

El modelo U-Net final presenta un tamaño de almacenamiento aproximado de 233 MB. Durante la fase de inferencia, el procesamiento de un lote de 16 imágenes (256×256 píxeles) requirió en promedio 0.52 s, lo que corresponde a una latencia de inferencia de aproximadamente 32.6 ms por imagen, equivalente a cerca de 30 FPS.

2.6. Métricas de evaluación

2.6.1. Precisión, *recall* y *F1-score*

Para evaluar el desempeño del modelo a nivel de píxel, se calcularon tres métricas complementarias: precisión, *recall* y *F1-score*. Estas métricas se estimaron de manera independiente para cada clase de defecto —grietas, zonas oscuras y *busbars* (barras colectoras)—, tal como se recomienda en estudios de segmentación orientados a la detección de defectos en sistemas fotovoltaicos [8, 18].

La precisión cuantifica la proporción de píxeles de defecto correctamente identificados entre todos los píxeles clasificados como defectuosos, ver ecuación (6):

$$\text{Precisión} = \frac{TP}{TP + FP} \quad (6)$$

Donde TP representa los verdaderos positivos (píxeles de defectos correctamente predichos) y FP denota los falsos positivos (píxeles sin defectos incorrectamente clasificados como defectuosos).

El *recall*, también denominado sensibilidad, mide la proporción de píxeles defectuosos reales que son identificados correctamente, ver ecuación (7):

$$\text{Recall} = \frac{TP}{TP + FN} \quad (7)$$

Donde FN indica los falsos negativos (píxeles defectuosos que el modelo no logró detectar).

El *F1-score*, calculado como la media armónica de la precisión y el *recall*, proporciona una métrica equilibrada para evaluar la exactitud de la clasificación, ver ecuación (8):

$$\text{F1-score} = \frac{2TP}{2TP + FP + FN} \quad (8)$$

Estas métricas resultan particularmente relevantes en tareas de segmentación multiclase que involucran desbalance de clases y características morfológicas sutiles, como las microgrietas [10].

2.6.2. Estrategia de validación y matriz de confusión

Para evaluar el desempeño del modelo y monitorizar la convergencia durante el entrenamiento iterativo de 32 versiones del modelo, se empleó una estrategia de validación *hold-out* fija, en lugar de validación cruzada *k-fold*. El conjunto de datos se dividió estrictamente en tres subconjuntos independientes: entrenamiento (1453 imágenes, incluidas las generadas mediante aumento de datos), validación (96 imágenes originales) y prueba. Este enfoque garantizó que las métricas de evaluación permanecieran comparables a lo largo de las distintas épocas de entrenamiento y ajustes de hiperparámetros, al tiempo que evitó la fuga de datos derivada del proceso de aumento.

Se generó una matriz de confusión utilizando el modelo de mejor desempeño (U-Net_v32) sobre el conjunto de validación, con el fin de visualizar los errores de predicción específicos por clase. La Figura 4 presenta la matriz de confusión normalizada. Se observó una mayor tasa de clasificación errónea en la clase de grietas, lo cual se atribuye a la distribución espacial dispersa y fragmentada de este tipo de defecto, en comparación con las características más distintivas de los *busbars* (barras colectoras) y las zonas oscuras.




Figura 4. Matriz de confusión normalizada obtenida para el modelo U-Net_v32 en el conjunto de validación, que muestra el desempeño de clasificación por clase.

Este protocolo de validación posibilita una evaluación clara de la capacidad de generalización del modelo en datos no vistos, con especial énfasis en la identificación correcta de las clases de defectos minoritarios.

3. Resultados y discusión

3.1. Desempeño por clase de defecto

3.1.1. Segmentación de grietas, zonas oscuras y busbars

El desempeño de segmentación de los modelos U-Net entrenados varió entre las distintas clases de defectos. Como se muestra en la Tabla 2, la puntuación F1 más alta se obtuvo para la clase de zonas oscuras, las cuales suelen ocupar regiones más extensas y homogéneas. Las discontinuidades en los *busbars* (barras colectoras) también exhibieron un desempeño de segmentación consistente, particularmente en aquellos casos en los que existía un contraste claro con el fondo de la celda.

En contraste, las grietas plantearon mayores desafíos para el modelo. Este tipo de defectos se caracteriza por estructuras estrechas e irregulares que, con frecuencia, se superponen con texturas de bajo contraste. De manera consistente con estudios previos de Pratt *et al.* [8] y Deitsch *et al.* [18], la clase de grietas presentó valores inferiores de precisión y *recall*, atribuibles tanto a su dispersión a nivel de píxel como a su elevada variabilidad morfológica.

Tabla 2. Métricas medias de segmentación por clase (U-Net_v32)

Clase de defecto	Precisión	Recall	F1-score
Grietas	0.6794	0.6465	0.6557
Zonas oscuras	0.8714	0.9066	0.9064
Barras colectoras	0.9151	0.9031	0.9083

La inspección cualitativa indicó, además, que las grietas ubicadas cerca de los bordes de la celda o parcialmente ocultas por la metalización de los dedos fueron omitidas con mayor frecuencia. Estas observaciones son coherentes con los resultados de evaluaciones comparativas obtenidos en conjuntos de datos de electroluminiscencia, como ELPV [19].

La Figura 5 ilustra resultados representativos de segmentación y su comparación con la verdad de terreno para los tres tipos de defectos analizados. Para cada clase, la figura presenta la imagen EL original, la máscara predicha superpuesta sobre la imagen, la máscara de verdad de terreno correspondiente y un mapa de errores que resalta las discrepancias entre ambas. En dichos mapas, el color cian indica falsos positivos (píxeles incorrectamente clasificados como defectuosos), mientras que el color naranja señala falsos negativos (píxeles defectuosos no detectados por el modelo).

En el caso de las grietas, los mapas de errores revelan bordes fragmentados, particularmente en regiones con luminiscencia débil, lo que corrobora las limitaciones identificadas en la evaluación cuantitativa. Por el contrario, para las zonas oscuras y los *busbars* (barras

colectoras), las regiones asociadas a falsos positivos y falsos negativos son mínimas, en concordancia con sus puntuaciones F1 comparativamente más elevadas.




Figura 5. Ejemplos de máscaras de segmentación predichas para (a) grietas, (b) zonas oscuras y (c) *busbars* (barras colectoras). Cada fila muestra la imagen EL original, la segmentación predicha superpuesta sobre la imagen, la máscara de verdad de terreno superpuesta y un mapa de errores, en el que el color cian indica falsos positivos (FP) y el color naranja indica falsos negativos (FN).

3.1.2. Análisis de errores y desbalance de clases

Un desafío persistente durante el entrenamiento fue el desbalance de clases. Los píxeles de fondo representaron más del 85 % del conjunto de datos, mientras que las grietas constituyeron menos del 5 %. Este desbalance afectó tanto el proceso de optimización como la interpretación de las métricas, dado que la función de pérdida tendía a priorizar las clases mayoritarias.

Para mitigar este problema, se emplearon funciones de pérdida ponderadas por clase, asignando penalizaciones más altas a los errores asociados a las clases subrepresentadas. Además, el aumento de datos se orientó específicamente a incrementar el número de muestras que contenían grietas. En conjunto, estos ajustes mejoraron la sensibilidad del modelo hacia las clases minoritarias sin comprometer la estabilidad del entrenamiento.

Como se ilustra en la matriz de confusión normalizada presentada en la Figura 4, las tasas más altas de clasificación errónea se observaron en la clase de grietas, particularmente en casos en los que defectos

difusos o de bajo contraste fueron confundidos con zonas oscuras.

Los falsos positivos en la clase *busbar* (barras colectoras) aparecieron ocasionalmente cerca de los bordes de la celda. Estos errores se atribuyeron a variaciones abruptas de brillo, causadas por iluminación no uniforme o por reflexiones ópticas durante la adquisición de las imágenes.

3.2. Análisis comparativo entre versiones del modelo

3.2.1. Evaluación iterativa de U-Net_v24 a U-Net_v32

Se llevó a cabo un proceso de evaluación iterativo a través de las versiones del modelo comprendidas entre U-Net_v24 y U-Net_v32. En cada iteración se introdujeron modificaciones controladas con el objetivo de mejorar el desempeño bajo condiciones limitadas de datos y hardware. Estos ajustes incluyeron el aumento de la resolución de entrada de 128×128 a 256×256 píxeles, la variación de las tasas de dropout en el rango de 0.15 a 0.3 y la reducción del tamaño de lote para acomodar entradas de mayor resolución dentro de la memoria GPU disponible.

La Tabla 3 resume la evolución de los puntajes F1 para las clases de grietas y *busbars*.

Tabla 3. Evolución del *F1-score* para la segmentación de grietas y *busbars*

Versión del modelo	Grietas (F1)	Barras colectoras (F1)
U-Net_v24	0.6151	0.9037
U-Net_v27	0.4519	0.8725
U-Net_v30	0.6336	0.9069
U-Net_v32	0.6557	0.9083

Las mejoras fueron más evidentes en la clase de grietas, para la cual las primeras versiones del modelo no lograban detectar patrones lineales tenues, particularmente en las proximidades de los límites de la celda. El uso de una mayor resolución de entrada, junto con configuraciones de codificador más profundas en U-Net_v30 y U-Net_v32, mejoró la capacidad de la red para preservar características detalladas durante el proceso de muestreo descendente.

La Figura 6 ilustra la progresión de los puntajes F1 a lo largo de las distintas versiones del modelo.

Estos resultados son coherentes con observaciones previas que indican que el refinamiento gradual de los hiperparámetros y de la estructura de entrada, más que la introducción de cambios arquitectónicos radicales, tiende a producir mejoras más fiables en modelos de segmentación entrenados con conjuntos de datos limitados o específicos del dominio.




Figura 6. Progresión del *F1-score* a lo largo de las versiones del modelo para las clases de grietas y *busbars*.

3.2.2. Discusión sobre arquitecturas alternativas: U-Net++, MAU-Net

Se evaluaron dos variantes de U-Net, U-Net++ y MAU-Net, bajo las mismas condiciones de entrenamiento. U-Net++ incorpora conexiones de salto anidadas con el objetivo de mejorar el flujo del gradiente y la fusión semántica, mientras que MAU-Net introduce mecanismos de atención espacial y de canal para priorizar características relevantes y suprimir el ruido.

Ambas variantes mostraron una ligera mejora en el *recall* para la clase de grietas en regiones de bajo contraste; sin embargo, la ganancia global en *F1-score* fue marginal (inferior al 1.5 %) en comparación con U-Net_v32. En particular, MAU-Net implicó, además, un incremento aproximado del 35 % en el tiempo de inferencia.

Dadas estas compensaciones, se optó por la U-Net base, ya que ofrece una mayor estabilidad, menor complejidad computacional y un desempeño más consistente entre los distintos tipos de defectos.

Dadas estas compensaciones, se optó por la U-Net base, ya que ofrece una mayor estabilidad, menor complejidad computacional y un desempeño más consistente entre los distintos tipos de defectos.

3.3. Validación visual y cualitativa

3.3.1. Mapas de calor y superposiciones en celdas individuales

Además de las métricas cuantitativas, la inspección visual resulta esencial para comprender el comportamiento del modelo bajo condiciones diagnósticas realistas. Con este propósito, se generaron mapas de calor a partir de las probabilidades de salida softmax para cada clase de defecto, los cuales se superpusieron sobre las imágenes de electroluminiscencia (EL) originales con el fin de visualizar el grado de confianza asociado a las predicciones del modelo.

Como se ilustra en la Figura 7, las zonas oscuras fueron identificadas de manera consistente, atribuible a sus límites bien definidos y a sus características de contraste. En comparación, las predicciones correspondientes a las grietas omitieron ocasionalmente secciones fragmentadas, especialmente en regiones cercanas a los bordes de la celda o bajo la metalización de los dedos, donde los niveles de luminiscencia eran menores. Estas observaciones son coherentes con los hallazgos reportados en evaluaciones previas basadas en conjuntos de datos de electroluminiscencia, como ELPV [19], así como con enfoques que emplean superposiciones visuales para la verificación de resultados de segmentación [8].




Figura 7. Ejemplos de superposición de mapas de calor sobre imágenes EL: (a) zonas oscuras correctamente predichas; (b) detección parcial de grietas; y (c) sobrepredicción en el área del *busbar* (barra colectora).

3.3.2. Evaluación de expertos y visualización de predicciones

Para complementar las métricas automáticas de desempeño, se llevó a cabo una revisión cualitativa por parte de tres expertos en diagnóstico fotovoltaico. Cada experto evaluó de manera independiente un conjunto de 30 máscaras de segmentación predichas, con énfasis en la exactitud de los contornos, la consistencia espacial y la interpretabilidad de los resultados. Los criterios de evaluación se alinearon con estándares de inspección visual adaptados de la norma IEC TS 60904-13 para el análisis de imágenes de electroluminiscencia (EL) [14].

La mayoría de las predicciones correspondientes a zonas oscuras y *busbars* (barras colectoras) se consideraron altamente consistentes con las expectativas diag-

nósticas, presentando discrepancias de segmentación mínimas. La Figura 8 muestra mapas de errores representativos para estas clases, donde los píxeles en color cian indican falsos positivos y los píxeles en color naranja representan falsos negativos. En la mayoría de los casos, únicamente se observaron desalineamientos menores, que se manifestaron como trazos delgados asociados a ligeras diferencias en el grosor de los bordes entre las máscaras predichas y las anotaciones de la verdad de terreno.

En contraste, la segmentación de grietas resultó más desafiante. Algunas máscaras de predicción presentaron contornos irregulares o sobreestimaron las regiones defectuosas en áreas de bajo contraste. La Figura 9 proporciona ejemplos representativos de estos casos de error. En particular, trazos naranjas prominentes señalan segmentos de grietas no detectados (falsos negativos), mientras que las regiones en cian corresponden a predicciones de falsos positivos en zonas ambiguas. Estos patrones coincidieron con frecuencia con gradientes de electroluminiscencia inducidos por corrientes de polarización inconsistentes o por leves desalineamientos durante la adquisición de las imágenes.




Figura 8. Mapas de error representativos para zonas oscuras y *busbars* segmentados correctamente. El color cian indica falsos positivos y el color naranja denota falsos negativos.




Figura 9. Ejemplos de errores de segmentación. Las grietas no detectadas se muestran en color naranja, mientras que los falsos positivos en áreas de bajo contraste se indican en color cian.

Este análisis cualitativo reveló patrones útiles para orientar el refinamiento del modelo. Implementaciones futuras podrían beneficiarse de estrategias de posprocesamiento selectivo o de la incorporación de módulos basados en atención, orientados a reducir falsos positivos y a mejorar la resolución espacial en regiones donde los límites de los defectos se encuentran pobremente definidos.

En conjunto, la combinación de superposiciones visuales, mapas de calor basados en probabilidades y la evaluación por expertos ofreció una perspectiva multidimensional del desempeño del modelo, que complementó de manera efectiva métricas estándar como el *F1-score* y las matrices de confusión.

4. Conclusiones

Este estudio examinó arquitecturas convolucionales basadas en U-Net para la segmentación semántica de defectos en celdas fotovoltaicas de silicio cristalino utilizando imágenes de electroluminiscencia (EL). Se empleó un conjunto de datos de doble fuente, que incluyó imágenes EL internas y públicas, tanto para el entrenamiento como para la evaluación del modelo.

Los modelos demostraron un desempeño consistente en defectos con morfología clara y alto contraste, como las zonas oscuras y las discontinuidades en los *busbars* (barras colectoras). Las grietas permanecieron como la clase más desafiante de segmentar debido a su distribución espacial dispersa y a su geometría irregular, en concordancia con hallazgos reportados previamente [8, 18]. Desde una perspectiva práctica, los resultados obtenidos están sujetos a varias limitaciones.

En particular, muchas grietas se manifiestan como trayectorias delgadas e irregulares, con una densidad de píxeles muy baja y un contraste sutil respecto al material circundante, lo que conduce a la omisión de segmentos cortos o tenues y, en algunos casos, a la confusión entre fragmentos de grietas y texturas de fondo o artefactos de adquisición.

Adicionalmente, el redimensionamiento obligatorio de las imágenes EL de celdas individuales a una resolución de 256×256 píxeles, requerido por el codificador basado en VGG16, puede comprimir las estructuras más delgadas en un número reducido de píxeles, limitando así la sensibilidad del modelo frente a defectos de muy pequeño tamaño.

Asimismo, el tamaño y la diversidad del conjunto de datos constituyen una restricción, dado que todas las imágenes fueron adquiridas bajo condiciones controladas de laboratorio y no incluyen escenarios de campo con corrientes de polarización variables, contaminación superficial o no uniformidades ópticas. Estos factores deben considerarse al extrapolar el desempeño reportado a otros montajes experimentales o condiciones

operativas. Ocho versiones del modelo fueron evaluadas mediante un flujo de entrenamiento estructurado que incorporó modificaciones progresivas en la profundidad del codificador, la resolución de entrada, la regularización y las estrategias de aprendizaje.

La configuración final, U-Net_v32, ofreció el mejor compromiso entre exactitud de segmentación y eficiencia computacional. Arquitecturas alternativas, como U-Net++ y MAU-Net, proporcionaron únicamente mejoras marginales en el desempeño, a costa de un incremento en el tiempo de inferencia [11].

Las métricas cuantitativas, las visualizaciones de salida y las evaluaciones cualitativas realizadas por expertos se emplearon de manera complementaria para analizar el comportamiento del modelo. Esta validación integrada confirmó la utilidad de los modelos basados en U-Net para la localización de defectos en imágenes EL bajo condiciones controladas.

Como líneas de trabajo futuro, se propone (1) ampliar el conjunto de datos mediante la incorporación de imágenes EL adquiridas en condiciones de campo que reflejen la variabilidad del entorno real y (2) desarrollar e integrar técnicas de posprocesamiento orientadas a reducir falsos positivos y a mejorar la definición de contornos en regiones de bajo contraste. Estos avances contribuirían a incrementar la aplicabilidad de los modelos de segmentación en diagnósticos fotovoltaicos operativos y en procesos de control de calidad durante la fabricación.

Agradecimientos

Los autores expresan su agradecimiento al Laboratorio de Micro-Red de la Universidad de Cuenca por proporcionar las instalaciones y el apoyo técnico necesarios para el desarrollo de este estudio. Asimismo, se reconoce de manera especial al personal del laboratorio, Vinicio Íñiguez, Edisson Villa y Pablo J. Delgado, por su valiosa asistencia durante la fase experimental.

Rol de autores

- **Franklin Gómez-López:** conceptualización, curación de datos, análisis formal, investigación, metodología, desarrollo de software, validación, visualización, escritura – borrador original.
- **Danny Ochoa-Correa:** análisis formal, adquisición de financiación, investigación, administración de proyecto, recursos, supervisión, escritura – revisión y edición.
- **Isabel Cabrera-Carrera:** Curación de datos, análisis formal, investigación, metodología, supervisión, escritura – revisión y edición.

Referencias

- [1] K. G. Bedrich, M. Bliss, T. R. Betts, and R. Gottschalg, “Electroluminescence imaging of PV devices: Determining the image quality,” in *2015 IEEE 42nd Photovoltaic Specialist Conference (PVSC)*. IEEE, Jun. 2015, pp. 1–5. [Online]. Available: <https://doi.org/10.1109/PVSC.2015.7356011>
- [2] T. Fuyuki and A. Kitiyanan, “Photographic diagnosis of crystalline silicon solar cells utilizing electroluminescence,” *Applied Physics A*, vol. 96, no. 1, pp. 189–196, Dec. 2008. [Online]. Available: <http://doi.org/10.1007/s00339-008-4986-0>
- [3] M. Akram and J. Bai, “Defect detection in photovoltaic modules based on image-to-image generation and deep learning,” *Sustainable Energy Technologies and Assessments*, vol. 82, p. 104441, Oct. 2025. [Online]. Available: <http://doi.org/http://doi.org/>
- [4] J. Wang, L. Bi, P. Sun, X. Jiao, X. Ma, X. Lei, and Y. Luo, “Deep-learning-based automatic detection of photovoltaic cell defects in electroluminescence images,” *Sensors*, vol. 23, no. 1, p. 297, Dec. 2022. [Online]. Available: <http://doi.org/10.3390/s23010297>
- [5] Q. Liu, M. Liu, C. Wang, and Q. J. Wu, “An efficient CNN-based detector for photovoltaic module cells defect detection in electroluminescence images,” *Solar Energy*, vol. 267, p. 112245, Jan. 2024. [Online]. Available: <http://doi.org/10.1016/j.solener.2023.112245>
- [6] J. Fioresi, D. J. Colvin, R. Frota, R. Gupta, M. Li, H. P. Seigneur, S. Vyas, S. Oliveira, M. Shah, and K. O. Davis, “Automated defect detection and localization in photovoltaic cells using semantic segmentation of electroluminescence images,” *IEEE Journal of Photovoltaics*, vol. 12, no. 1, pp. 53–61, Jan. 2022. [Online]. Available: <http://doi.org/10.1109/jphotov.2021.3131059>
- [7] O. Ronneberger, P. Fischer, and T. Brox, *U-Net: Convolutional Networks for Biomedical Image Segmentation*. Springer International Publishing, 2015, pp. 234–241. [Online]. Available: http://doi.org/10.1007/978-3-319-24574-4_28
- [8] L. Pratt, D. Govender, and R. Klein, “Defect detection and quantification in electroluminescence images of solar PV modules using U-net semantic segmentation,” *Renewable Energy*, vol. 178, pp. 1211–1222, Nov. 2021. [Online]. Available: <http://doi.org/10.1016/j.renene.2021.06.086>
- [9] H. Eesaar, S. Joe, M. U. Rehman, Y. Jang, and K. T. Chong, “SEiPV-net: An efficient deep learning framework for autonomous multi-defect segmentation in electroluminescence images of solar photovoltaic modules,” *Energies*, vol. 16, no. 23, p. 7726, Nov. 2023. [Online]. Available: <https://doi.org/10.3390/en16237726>
- [10] M. R. U. Rahman and H. Chen, “Defects inspection in polycrystalline solar cells electroluminescence images using deep learning,” *IEEE Access*, vol. 8, pp. 40 547–40 558, 2020. [Online]. Available: <http://doi.org/10.1109/access.2020.2976843>
- [11] R. A. Mamun Rudro, K. Nur, F. A. Al Sohan, M. Mridha, S. Alfarhood, M. Safran, and K. Kanagarathinam, “SPF-Net: Solar panel fault detection using U-net based deep learning image classification,” *Energy Reports*, vol. 12, pp. 1580–1594, Dec. 2024. [Online]. Available: <http://doi.org/10.1016/j.egyr.2024.07.044>
- [12] S. Deitsch, V. Christlein, S. Berger, C. Buerhop-Lutz, A. Maier, F. Gallwitz, and C. Riess, “Automatic classification of defective photovoltaic module cells in electroluminescence images,” *Solar Energy*, vol. 185, pp. 455–468, Jun. 2019. [Online]. Available: <http://doi.org/10.1016/j.solener.2019.02.067>
- [13] U. Hijjawi, S. Lakshminarayana, T. Xu, and M. Rahman, “A benchmarking study of instance segmentation methods for photovoltaic cell defect detection using electroluminescence images,” *Solar Energy*, vol. 303, p. 114083, Jan. 2026.
- [14] IEC, *IEC Technical Specification 60904-13. Photovoltaic devices - Part 13: Electroluminescence of photovoltaic modules*. International Electrotechnical Commission, 2018. [Online]. Available: <http://doi.org/10.4229/35thEUPVSEC20182018-5CV.3.15>
- [15] Supervisely. (2023) Supervisely computer vision platform. Supervisely OÜ. [Online]. Available: <https://upsalesiana.ec/ing35ar8r2>
- [16] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” 2014.
- [17] A. Sohail, N. Ul Islam, A. Ul Haq, S. Ul Islam, I. Shafi, and J. Park, “Fault detection and computation of power in PV cells under faulty conditions using deep-learning,” *Energy Reports*, vol. 9, pp. 4325–4336, Dec. 2023.
- [18] S. Deitsch, C. Buerhop-Lutz, E. Sovetkin, A. Steiland, A. Maier, F. Gallwitz, and C. Riess, “Segmentation of photovoltaic module cells in uncali-

- brated electroluminescence images,” *Machine Vision and Applications*, vol. 32, no. 4, May 2021.
- [19] C. Buerhop-Lutz, S. Deitsch, A. Maier, F. Gallwitz, S. Berger, B. Doll, J. Hauch, C. Camus, and C. Brabec, “A benchmark for visual identification of defective solar cells in electroluminescence imagery,” *35th European Photovoltaic Solar Energy Conference and Exhibition; 1287-1289*, 2018. [Online]. Available: <http://doi.org/10.4229/35THEUPVSEC20182018-5CV.3.15>



MEJORANDO LA SEGMENTACIÓN SEMÁNTICA PARA LA ACCESIBILIDAD URBANA MEDIANTE DATOS SINTÉTICOS DE ALTA FIDELIDAD

ENHANCING SEMANTIC SEGMENTATION FOR URBAN ACCESSIBILITY USING HIGH-FIDELITY SYNTHETIC DATA

Santiago Felipe Luna Romero¹ , Renato Gouveia^{1,*} , Mauren Abreu de Souza¹ 

Recibido: 11-07-2025, Recibido tras revisión: 01-12-2025, Aceptado: 09-12-2025, Publicado: 01-01-2026

Resumen


La segmentación semántica de escenas urbanas es un componente clave para el desarrollo de ciudades inteligentes; sin embargo, su efectividad depende de grandes volúmenes de datos anotados a nivel de píxel, los cuales son costosos y especialmente escasos en clases críticas relacionadas con la accesibilidad y la movilidad asistida. Este trabajo tiene como objetivo mejorar la segmentación semántica para aplicaciones de accesibilidad urbana mediante el uso de datos sintéticos. La metodología propuesta integra la generación de datos sintéticos hiperrealistas utilizando Unreal Engine 5.1, el procesamiento automático de máscaras semánticas con etiquetas perfectas y el entrenamiento de modelos de segmentación de referencia. Se generaron 5036 imágenes anotadas en 22 clases, incluyendo aceras, sillas de ruedas y bastones. Se evaluaron dos arquitecturas de segmentación: una *U-Net* básica y DeepLabv3+ con módulos ASPP. El preentrenamiento con datos sintéticos incrementó el mIoU global de 0.0626 a 0.84, lo que representa una mejora de 13.4 ×, y produjo aumentos significativos en precisión, *recall* y *F1-score* (aproximadamente 6.8×, 9.3× y 10.4×, respectivamente). En clases críticas para la accesibilidad, se alcanzó un IoU de 0.94 para sillas de ruedas motorizadas y un *recall* de 0.98 para aceras. En total, las 22 clases superaron el umbral operativo de despliegue (IoU ≥ 0.75). Estos resultados demuestran que la incorporación de datos sintéticos, junto con estrategias de entrenamiento sensibles al desbalance de clases, constituye una solución efectiva y escalable para el desarrollo de sistemas robustos de segmentación semántica orientados a la accesibilidad urbana.

Palabras clave: accesibilidad, aprendizaje profundo, ciudades inteligentes, datos sintéticos, segmentación semántica, inteligencia artificial

Abstract

Semantic segmentation of urban scenes is essential for the development of smart cities; however, its effectiveness relies heavily on large, pixel-level annotated datasets, which are particularly scarce for mobility aids. This study aims to enhance semantic segmentation for urban accessibility applications by leveraging synthetic data. The proposed methodology integrates high-fidelity synthetic data generation using Unreal Engine 5.1, automated semantic mask processing, and the training of state-of-the-art segmentation models. A dataset of 5,036 images with pixel-perfect labels across 22 classes, including sidewalks, wheelchairs, and walking aids, was created to support this investigation. Two architectures were benchmarked: a baseline U-Net and DeepLabv3+ with ASPP. Pre-training with synthetic data increased global mIoU from 0.0626 to 0.84 (13.4×) and substantially improved precision, recall, and F1-score (by approximately 6.8×, 9.3×, and 10.4×, respectively). For accessibility-critical classes, motorized wheelchairs achieved an IoU of 0.94, and sidewalks attained a recall of 0.98. Overall, all 22 classes surpassed the deployment threshold (≥ 0.75 IoU). These findings demonstrate that synthetic data, combined with imbalance-aware training strategies, provides a viable pathway toward robust semantic segmentation solutions for urban accessibility applications.

Keywords: Semantic Segmentation, Synthetic Data, Deep Learning, Smart Cities, Accessibility, Artificial Intelligence.

^{1,*}Pontifícia Universidade Católica do Paraná, Brasil. 
 Autor para correspondencia ✉: gouveia.renato@pucpr.edu.br.

Forma sugerida de citación: S. F. Luna Romero, R. Gouveia y M. Abreu de Souza, “Mejorando la segmentación semántica para la accesibilidad urbana mediante datos sintéticos de alta fidelidad,” *Ingenius, Revista de Ciencia y Tecnología*, N.º 35, pp. 122-137, 2026. DOI: <https://doi.org/10.17163/ings.n35.2026.09>.

1. Introducción

La segmentación semántica, que asigna una etiqueta semántica a cada píxel de una imagen, constituye un componente fundamental para la comprensión de escenas urbanas complejas. Esta técnica respalda aplicaciones como la conducción autónoma, el monitoreo del tráfico, la realidad aumentada y la navegación asistida para peatones con discapacidades de movilidad o visuales [1, 2]. Al discriminar entre carreteras, aceras, edificios, vehículos, peatones y elementos asociados a la accesibilidad —como rampas de bordillo y ayudas para la movilidad—, los modelos de segmentación proporcionan la conciencia espacial necesaria para la planificación del transporte, el diseño urbano inclusivo y la detección de obstáculos en tiempo real en dispositivos de asistencia [1, 2].

No obstante, los modelos profundos de segmentación continúan dependiendo de grandes conjuntos de datos anotados a nivel de píxel. La generación de dichas etiquetas resulta costosa y requiere un considerable esfuerzo humano, particularmente para estructuras finas y clases poco frecuentes. Esta limitación es especialmente crítica en categorías relevantes para la seguridad pero subrepresentadas, como peatones que utilizan sillas de ruedas, andadores o bastones, cuya escasa presencia en los conjuntos de datos disponibles restringe la capacidad de generalización en entornos urbanos reales [3, 4].

Conjuntos de datos ampliamente utilizados para escenas urbanas, como Cityscapes y KITTI, contienen muy pocos o ningún ejemplo de usuarios con movilidad reducida, lo que introduce sesgos sistemáticos y provoca que los modelos omitan estas clases o las confundan con el fondo [3, 5].

La simulación de alta fidelidad ha surgido como una estrategia eficaz para mitigar la dependencia de grandes conjuntos de datos del mundo real. Motores de videojuegos modernos, como Unreal Engine, así como simuladores especializados como CARLA, permiten generar grandes volúmenes de imágenes fotorrealistas con máscaras semánticas renderizadas automáticamente y precisas a nivel de píxel. Este enfoque reduce de manera significativa los costos de anotación y facilita la experimentación controlada sobre clases poco frecuentes o críticas para la seguridad [1, 4, 6].

Estudios previos han demostrado que el preentrenamiento de modelos de segmentación con imágenes sintéticas, seguido de un ajuste fino con conjuntos de datos reales más pequeños, mejora el desempeño en escenas urbanas complejas [1, 7]. Asimismo, técnicas de aleatorización de dominio —que varían sistemáticamente la iluminación, las texturas, las condiciones climáticas, los puntos de vista de la cámara y la disposición de los objetos— contribuyen a reducir el sobreajuste a artefactos del simulador y a mejorar la robustez en la transferencia de simulación a realidad [8, 9].

Dos cuestiones siguen siendo centrales para la accesibilidad urbana y la navegación asistida. En primer lugar, persiste un marcado desbalance de clases: las categorías dominantes, como carreteras, cielo y edificios, ocupan la mayoría de los píxeles, mientras que los dispositivos de movilidad y los elementos de infraestructura estrechos —incluidas rampas de bordillo, bolardos y señales de tráfico— representan solo una fracción mínima del total [3, 5]. En ausencia de contramedidas específicas, los modelos de segmentación tienden a sobreajustarse a las clases mayoritarias e infraajustarse a las categorías minoritarias que resultan críticas para la accesibilidad. Para mitigar este efecto, se emplean comúnmente funciones de pérdida que reajustan el peso de ejemplos difíciles de clasificar o subrepresentados, como la pérdida focal y la pérdida Tversky, junto con estrategias de aumento de datos sensibles a las clases.

En segundo lugar, las arquitecturas de segmentación deben equilibrar el contexto global con la preservación del detalle fino. Las arquitecturas CNN de tipo codificador–decodificador, como U-Net y DeepLab, capturan eficazmente la estructura local, pero presentan campos receptivos limitados. Por el contrario, los modelos basados en Transformers ofrecen una capacidad sólida de razonamiento global, aunque pueden tener dificultades para mantener límites precisos a nivel de píxel. Con el fin de abordar esta dicotomía, las arquitecturas híbridas CNN–Transformer combinan respaldos convolucionales con módulos de autoatención, permitiendo modelar dependencias de largo alcance sin sacrificar la definición de contornos en escenas urbanas congestionadas [10–12].

La mayoría de los conjuntos de datos sintéticos existentes y los flujos de trabajo de segmentación se centran principalmente en aplicaciones de conducción autónoma y no abordan de forma explícita la accesibilidad urbana. Sus taxonomías priorizan participantes genéricos del tráfico y elementos de infraestructura de carácter grueso, e incluyen rara vez etiquetas detalladas para ayudas de movilidad o componentes a nivel de acera. En consecuencia, estos conjuntos de datos no resultan directamente adecuados para evaluar la segmentación orientada a la accesibilidad ni para respaldar sistemas de navegación asistida.

En contraste, el conjunto de datos SYNTHUA-DT (Synthetic Urban Accessibility – Digital Twin) [13] se centra explícitamente en la accesibilidad urbana. Este conjunto modela un entorno urbano realista mediante Unreal Engine 5.1 y proporciona anotaciones semánticas perfectas a nivel de píxel para 22 clases, incluyendo múltiples categorías de dispositivos de movilidad —como sillas de ruedas, andadores y bastones—, así como peatones y elementos de infraestructura a nivel de acera. SYNTHUA-DT fue diseñado para abordar esta brecha en los datos orientados a la accesibilidad, ofreciendo un corpus controlable en el que las

ayudas de movilidad y las estructuras peatonales están representadas de manera sistemática y reproducible.

1.1. Trabajos relacionados

Los datos sintéticos para la comprensión de escenas urbanas han sido ampliamente explorados mediante el uso de videojuegos comerciales y simuladores dedicados. Kamimura *et al.* extrajeron anotaciones densas a partir de GTA-V y demostraron que el preentrenamiento con datos sintéticos puede mejorar el rendimiento de los modelos cuando se combina con un ajuste fino sobre datos del mundo real [7]. De manera similar, flujos de trabajo basados en CARLA se han utilizado para ampliar conjuntos de datos como Cityscapes con escenarios de tráfico adicionales y condiciones climáticas adversas, incrementando la robustez frente a configuraciones poco frecuentes [1]. Los entornos de gemelo digital, como UrbanSyn, integran modelos urbanos tridimensionales realistas con técnicas de adaptación de dominio y transferencia de estilo con el objetivo de reducir la brecha entre imágenes simuladas y reales [4,6]. En conjunto, estos estudios reportan de forma consistente mejoras en la precisión y la capacidad de generalización; sin embargo, sus espacios de etiquetas se orientan principalmente a participantes genéricos del tráfico y no abordan de manera sistemática los elementos relacionados con la accesibilidad urbana.

El desbalance de clases y la segmentación de objetos pequeños también han sido objeto de un análisis extensivo. Azad *et al.* y Liu *et al.* estudiaron cómo las distribuciones de etiquetas de cola larga degradan el rendimiento en clases minoritarias y evaluaron funciones de pérdida, como la pérdida focal y la pérdida Tversky, para reajustar el peso de ejemplos difíciles de clasificar o subrepresentados [3,5]. Arquitecturas como U-Net y DeepLabv3+ se utilizan comúnmente como líneas base debido a su equilibrio entre precisión y costo computacional [14,15]. Asimismo, se han propuesto enfoques híbridos CNN-Transformer, incluidos codificadores basados en Swin Transformer y decodificadores aumentados con mecanismos de autoatención, para capturar dependencias de largo alcance al tiempo que se preservan detalles estructurales en escenas urbanas complejas [10–12]. No obstante, la mayoría de estas evaluaciones se apoyan en conjuntos de datos en los que los peatones con discapacidad de movilidad y la infraestructura de accesibilidad están ausentes o severamente subrepresentados, lo que limita su aplicabilidad directa a sistemas de navegación asistida.

1.2. Contribuciones

Basándose en el conjunto de datos SYNTHUA-DT, este trabajo investiga si los datos sintéticos de alta fidelidad, combinados con estrategias de entrenamiento sensibles al desbalance de clases, son suficientes para

alcanzar un desempeño de segmentación apto para el despliegue en clases críticas para la accesibilidad urbana. Asimismo, se cuantifican las mejoras obtenidas en comparación con una línea base basada en U-Net.

Las principales contribuciones de este trabajo se resumen a continuación:

- **Uso de un conjunto de datos sintético orientado a la accesibilidad.** El conjunto de datos SYNTHUA-DT [13], generado mediante Unreal Engine 5.1, proporciona 5036 imágenes de alta resolución con anotaciones semánticas perfectas a nivel de píxel en 22 clases, incluyendo explícitamente múltiples dispositivos de movilidad y elementos de infraestructura a nivel de acera.
- **Canalización de preprocesamiento y estructuración del conjunto de datos.** Se propone una canalización que convierte máscaras codificadas por color en supervisión multicanal, aplica refinamientos morfológicos simples sensibles a la clase y genera particiones de entrenamiento, validación y prueba que respaldan un entrenamiento y una evaluación robustos.
- **Evaluación comparativa de arquitecturas de segmentación.** Las arquitecturas U-Net y DeepLabv3+ se entrenan y evalúan empleando funciones de pérdida sensibles al desbalance y técnicas de aumento de datos. El análisis incluye métricas globales y por clase, con énfasis particular en ayudas de movilidad y aceras.
- **Marco orientado al despliegue en sistemas de accesibilidad.** La canalización sintética propuesta, junto con el análisis de calibración, sienta las bases para extensiones futuras mediante técnicas de adaptación de dominio hacia conjuntos de datos del mundo real y su integración en sistemas de ciudades inteligentes y navegación asistida.

El resto del artículo se organiza de la siguiente manera. La Sección 2 describe la metodología propuesta; la Sección 3 presenta los resultados experimentales y el análisis por clases; la Sección 4 discute las limitaciones y las líneas de trabajo futuro; y la Sección 5 indica las conclusiones principales.

2. Materiales y métodos

El enfoque propuesto comprende cinco componentes principales: (i) la generación del conjunto de datos sintético, (ii) el preprocesamiento de imágenes y máscaras semánticas, (iii) el diseño de las arquitecturas de los modelos, (iv) la estrategia de entrenamiento, incluido el diseño de la función de pérdida, y (v) las métricas

de evaluación. En conjunto, estos elementos conforman una canalización sistemática para el entrenamiento y la evaluación de modelos de segmentación semántica en escenas urbanas orientadas a la accesibilidad.


2.1. Generación del conjunto de datos sintético

Este trabajo se basa en el conjunto de datos SYNTHUA-DT (Synthetic Urban Accessibility – Digital Twin) [13, 16], un corpus sintético compuesto por 5036 imágenes urbanas de alta resolución (1920 × 1080 px) generado mediante Unreal Engine 5.1. Para la síntesis de las escenas se empleó una canalización de renderizado físicamente basada (PBR), con el objetivo de aproximar de manera realista la iluminación y las propiedades de los materiales del entorno urbano. Cada escena incluye disposiciones arquitectónicas diversas —como fachadas históricas y rascacielos modernos—, junto con mobiliario urbano, actores dinámicos (peatones, ciclistas y vehículos) y múltiples condiciones climáticas.

Las máscaras semánticas perfectas a nivel de píxel correspondientes a 22 clases —entre ellas aceras, ca-

rreteras, pasos peatonales, peatones, dispositivos de movilidad, vegetación, vehículos, señalización y otros elementos de infraestructura— se generaron automáticamente durante el proceso de renderizado [16, 17]. La taxonomía de clases fue diseñada explícitamente para resaltar componentes relevantes para la accesibilidad urbana, incluyendo múltiples categorías de sillas de ruedas, andadores, bastones y estructuras a nivel de acera, las cuales suelen estar ausentes o subrepresentadas en conjuntos de datos urbanos convencionales.

Con el fin de mejorar la robustez frente a cambios de dominio, se aplicaron técnicas de aleatorización de dominio mediante la variación de la iluminación, los parámetros de la cámara, las condiciones ambientales —como escenarios despejados, nublados y lluviosos— y los atributos de los objetos, incluyendo texturas de pavimentos, fachadas, vehículos y vestimenta [18]. Esta diversidad generada de forma procedimental promueve la invariancia de características durante la transferencia de simulación a realidad, como se ilustra en la Figura 1. La Tabla 1 resume el esquema de codificación de colores empleado para el etiquetado semántico de las clases en SYNTHUA-DT.



(a) Renderización ultrarrealista de SYNTHUA-DT

(b) Máscara de segmentación semántica correspondiente

Figura 1. Ejemplo de un par SYNTHUA-DT: (a) imagen RGB de alta fidelidad; (b) máscara semántica perfecta a nivel de píxel.

Tabla 1. Esquema de codificación de colores para las clases de segmentación semántica en SYNTHUA-DT

Color	Elementos	Categoría
[Color]	Edificios	Edificio
[Color]	Silla de ruedas motorizada	Dispositivos de movilidad
[Color]	Muletas	Dispositivos de movilidad
[Color]	Andador	Dispositivos de movilidad
[Color]	Silla de ruedas	Dispositivos de movilidad
[Color]	Bastón ortopédico	Dispositivos de movilidad
[Color]	Bastón	Dispositivos de movilidad
[Color]	Muleta ortopédica	Dispositivos de movilidad
[Color]	Césped	Naturaleza
[Color]	Árboles, plantas	Naturaleza
[Color]	Personas	Transeúntes
[Color]	Perros	Transeúntes
[Color]	Bolardo, banco, papelera pública	Mobiliario urbano
[Color]	Lata, columpio, sombrilla, panel publicitario	Mobiliario urbano
[Color]	Fuente, monumentos, lugar turístico	Mobiliario urbano
[Color]	Coche, autobús, vehículos	Transporte
[Color]	Bicicleta	Transporte
[Color]	Motocicleta, scooter	Transporte
[Color]	Poste de alumbrado público	Infraestructura urbana
[Color]	Señal de límite de velocidad, señal de estacionamiento con límite de tiempo	Infraestructura urbana
[Color]	Poste de semáforo	Infraestructura urbana
[Color]	Aceras	Infraestructura urbana

2.2. Preprocesamiento de imágenes y máscaras semánticas

El preprocesamiento consta de dos etapas principales: (i) el redimensionamiento y la normalización de las imágenes RGB de entrada y (ii) la descomposición de las máscaras semánticas codificadas por color en tensores de etiquetas multicanal, utilizados como supervisión para el entrenamiento de los modelos de segmentación.

2.2.1. Redimensionamiento y normalización

Con el fin de equilibrar la eficiencia computacional y la fidelidad en la representación de objetos pequeños, todas las imágenes se redimensionaron a una resolución de 512×512 px utilizando la interpolación `INTER_AREA` de `OpenCV`, la cual resulta adecuada para tareas de segmentación al preservar el detalle de los bordes durante la reducción de escala [17].

Experimentos preliminares mostraron que una resolución inferior de 256×256 px produjo de manera consistente valores de IoU más bajos para clases de infraestructura fina, como bordillos y señalización, lo que justifica la resolución adoptada. Finalmente, las intensidades RGB se normalizaron al rango $[0, 1]$ mediante una división por 255 [18].

2.2.2. Descomposición de máscaras semánticas

Las máscaras semánticas codificadas por color se convirtieron en un tensor binario multicanal de dimensión $512 \times 512 \times 22$ mediante umbralización en el espacio de color HSV, aislando el rango de tono correspondiente a cada clase. Para manejar el solapamiento de tonos en el límite circular $0^\circ/180^\circ$, se empleó un algoritmo de crecimiento de regiones, seguido de operaciones morfológicas de apertura y cierre con tamaños de kernel específicos por clase, orientadas a eliminar artefactos y reforzar la coherencia regional.

Asimismo, los componentes conectados con un área inferior a un umbral mínimo predefinido se filtraron, obteniéndose finalmente máscaras one-hot adecuadas para la supervisión durante el entrenamiento [7, 19].

El Algoritmo 1 formaliza este procedimiento. Durante el entrenamiento, el tensor multicanal de 22 clases se colapsa en un único mapa de etiquetas mutuamente excluyentes, el cual es procesado por una cabeza de segmentación con activación *softmax*. La representación multicanal intermedia se conserva con fines de diagnóstico y para posibles extensiones futuras hacia escenarios de segmentación multietiqueta.

Algoritmo 1 Descomposición semántica de máscaras basada en el color

Entrada: Máscara semántica RGB $M \in \mathbb{R}^{H \times W \times 3}$, parámetros específicos de clase $P = \{P_1, \dots, P_{22}\}$

Salida: Tensor binario multicanal $T \in \{0, 1\}^{H \times W \times 22}$

Convertir M a HSV: $M_{\text{HSV}} \leftarrow \text{ConvertToHSV}(M)$ Inicializar $T \leftarrow \mathbf{0} \in \{0, 1\}^{H \times W \times 22}$

```

for  $i = 1$  to 22 do
     $(l_i, u_i) \leftarrow P_i$ .Umbralés HSV     $a_i \leftarrow$ 
     $P_i$ .área mínima     $k_i \leftarrow P_i$ .tamaño del núcleo
     $g_i \leftarrow P_i$ .crecimiento de la región     $m_i \leftarrow$ 
     $P_i$ .operaciones morfológicas
    Aplicar umbral HSV:  $B_i \leftarrow \mathbb{1}[M_{\text{HSV}} \in [l_i, u_i]]$ 
    Crecimiento de la región:  $R_i \leftarrow$ 
    RegionGrow( $B_i, M_{\text{HSV}}, g_i$ )
    Filtrado morfológico:  $M_i \leftarrow \text{Morph}(R_i, k_i, m_i)$ 
    Filtrado de área:  $F_i \leftarrow \mathbb{1}[\text{Area}(M_i) \geq a_i]$ 
    Almacenar resultado:  $T[:, :, i] \leftarrow F_i$ 

```

return T

2.3. Arquitecturas de los modelos

Se evalúan comparativamente las siguientes arquitecturas de segmentación:

- **U-Net:** arquitectura simétrica de tipo codificador–decodificador con conexiones de salto, ampliamente utilizada en tareas de segmentación—especialmente en dominios con conjuntos de datos limitados—debido a su capacidad para preservar y recuperar detalles espaciales finos [14]
- **DeepLabv3+:** modelo de tipo codificador–decodificador que integra Atrous Spatial Pyramid Pooling (ASPP) para la captura de contexto multiescala, junto con un decodificador ligero orientado al refinamiento espacial. En esta implementación se emplea un codificador ResNet-101 con convoluciones *atrous* [15].

Esta comparación permite analizar el impacto de la agregación explícita de contexto multiescala, característica de DeepLabv3+, frente a un diseño clásico codificador–decodificador como U-Net, en el desempeño de la segmentación semántica orientada a la accesibilidad urbana.

2.4. Estrategia de entrenamiento

2.4.1. Partición del conjunto de datos y aumentación

El conjunto de datos se dividió en un 80 % para entrenamiento (4028 imágenes), un 10 % para validación (503 imágenes) y un 10 % para prueba (505 imágenes), empleando muestreo estratificado con el fin de preservar la distribución de clases en cada partición [20]. Durante el entrenamiento se aplicó aumentación de datos en línea, que incluyó escalado aleatorio (0.5–2.0),

recorte aleatorio, volteo horizontal, pequeñas rotaciones ($\pm 10^\circ$), ligeras variaciones de color, desenfoque gaussiano y técnicas de mezcla como ClassMix y Cut-Mix, con énfasis en las clases minoritarias.

Las transformaciones geométricas se aplicaron de manera sincrónica tanto a las imágenes RGB como a las máscaras semánticas, mientras que las transformaciones fotométricas se aplicaron exclusivamente a las imágenes RGB [15].

2.4.2. Optimización y alcance del estudio

Ambos modelos se entrenaron utilizando el optimizador Adam con una tasa de aprendizaje inicial de 1×10^{-4} y un tamaño de lote de 8. Se empleó un esquema de decaimiento escalonado que redujo la tasa de aprendizaje a 1×10^{-5} tras 75 épocas. Adicionalmente, se utilizó entrenamiento con precisión mixta para optimizar el uso de la memoria de la GPU y acelerar el proceso de entrenamiento.

Durante el entrenamiento se aplicaron técnicas estándar de control y monitoreo, incluyendo *early stopping* (parada temprana) con una paciencia de 10 épocas, guardado de puntos de control del modelo, un programador ReduceLRonPlateau con un factor de 0.5 y una paciencia de 5 épocas, así como el uso de TensorBoard para el seguimiento de las métricas.

El estudio es estrictamente computacional; no se involucraron datos de sujetos humanos ni se aplicaron protocolos clínicos. Los experimentos se repitieron utilizando tres semillas aleatorias independientes, y las métricas se reportan como valores promedio acompañados de sus respectivos intervalos de confianza.

2.5. Funciones de pérdida

Las clases semánticas se consideran mutuamente excluyentes y la cabeza final de predicción emplea una activación *softmax* de 22 vías. En consecuencia, el objetivo de entrenamiento se define mediante una función de pérdida compuesta que combina una pérdida de Entropía Cruzada balanceada por clase con una pérdida Dice suavizada, con el fin de mitigar el desbalance de clases y mejorar la superposición espacial de las regiones segmentadas, ver ecuación (1):

$$L = \lambda_{CE} CE_{\text{balanced}} + \lambda_{Dice} \text{Dice}, \quad (1)$$

$$\lambda_{CE} = \lambda_{Dice} = 0.5.$$

Los pesos de clase en la pérdida CE_{balanced} se definieron de manera inversamente proporcional a la frecuencia de píxeles de cada clase, con el objetivo de contrarrestar el desbalance inherente del conjunto de datos. De forma alternativa, se evaluó la pérdida focal ($\gamma = 2$) como reemplazo directo del término de entropía cruzada, observándose un comportamiento

global comparable y una recuperación ligeramente superior en clases minoritarias, como se reporta en la Tabla 4.

La representación multicanal one-hot, derivada de las máscaras codificadas en HSV, se utiliza internamente para la decodificación de color y las operaciones de procesamiento morfológico, mientras que el entrenamiento de los modelos se realiza empleando el único mapa de etiquetas mutuamente excluyentes. Posibles extensiones hacia escenarios multietiqueta —como el modelado conjunto de peatones y dispositivos de asistencia— pueden abordarse mediante la incorporación de cabezas binarias auxiliares, siguiendo enfoques similares a los reportados en [21].

2.6. Métricas de evaluación

El desempeño de la segmentación y la calibración del modelo se evalúan mediante métricas cuantitativas estándar, calculadas tanto a nivel de clase como a nivel global del conjunto de datos.

Intersección sobre unión (IoU) y mIoU. Para la clase c , ver ecuación (2)

$$\text{IoU}_c = \frac{\text{TP}_c}{\text{TP}_c + \text{FP}_c + \text{FN}_c}, \quad (2)$$

$$\text{mIoU} = \frac{1}{C} \sum_{c=1}^C \text{IoU}_c.$$

Precisión, recall, F1-score y exactitud balanceada. Para la clase c , ver ecuaciones (3), (4), (5)

$$\text{Precision}_c = \frac{\text{TP}_c}{\text{TP}_c + \text{FP}_c}, \quad (3)$$

$$\text{Recall}_c = \frac{\text{TP}_c}{\text{TP}_c + \text{FN}_c},$$

$$\text{F1}_c = \frac{2 \text{Precision}_c \cdot \text{Recall}_c}{\text{Precision}_c + \text{Recall}_c}, \quad (4)$$

$$\text{BA}_c = \frac{1}{2} \left(\frac{\text{TP}_c}{\text{TP}_c + \text{FN}_c} + \frac{\text{TN}_c}{\text{TN}_c + \text{FP}_c} \right). \quad (5)$$

Las puntuaciones globales se promedian de forma macro sobre las clases.

Calibración y métricas probabilísticas. Para evaluar la calibración probabilística de las predicciones, se calcularon el error de calibración esperado (ECE), el error máximo de calibración (MCE), la log-verosimilitud negativa (NLL) y la puntuación de Brier. En particular, el ECE y el MCE se estiman dividiendo el rango de confianza $[0, 1]$ en B intervalos (bins), donde n_b denota el número de predicciones cuya confianza cae dentro del intervalo b , ver ecuación (6):

$$\begin{aligned} \text{ECE} &= \sum_{b=1}^B \frac{n_b}{N} |\text{acc}(b) - \text{conf}(b)|, \\ \text{MCE} &= \max_b |\text{acc}(b) - \text{conf}(b)|. \end{aligned} \quad (6)$$

Dadas las probabilidades *softmax* p_i para la clase verdadera y_i , ver ecuación (7),

$$\begin{aligned} \text{NLL} &= -\frac{1}{N} \sum_{i=1}^N \log p_i(y_i), \\ \text{Brier} &= \frac{1}{N} \sum_{i=1}^N \|p_i - \mathbf{1}_{y_i}\|_2^2. \end{aligned} \quad (7)$$

Detalles de implementación

Backbone y decodificador. Se empleó DeepLabv3+ con un backbone ResNet-101 preentrenado en ImageNet. El codificador utiliza un output stride de 16, mientras que el decodificador emplea un stride de 4. El módulo Atrous Spatial Pyramid Pooling (ASPP) incorpora tasas de dilatación $\{1, 6, 12, 18\}$ junto con *image-level pooling*.

Entrada y recortes. Durante el entrenamiento se extrajeron recortes aleatorios de 512×512 píxeles a partir de imágenes originales de 1920×1080 píxeles. En la fase de inferencia se aplicó redimensionamiento bilineal para restaurar la resolución espacial.

Normalización. Se calcularon estadísticas de normalización por canal, en el rango $[0, 1]$, exclusivamente sobre la partición de entrenamiento.

Semillas y hardware. Los experimentos se realizaron utilizando semillas aleatorias $\{11, 23, 37\}$ y se ejecutaron en una GPU NVIDIA RTX 3090 (24 GB). Se empleó un tamaño de lote de 8 y entrenamiento con precisión mixta. El tiempo de entrenamiento fue de aproximadamente 5.2 h por semilla para 100 épocas.

Reproducibilidad. El conjunto de datos SYNTHUA-DT, junto con los scripts de preprocesamiento, las configuraciones de los modelos y el código de entrenamiento, se publicarán tras la aceptación del artículo en el repositorio público [22].

3. Resultados y discusión

Todos los resultados reportados corresponden a un escenario synthetic-to-synthetic, en el cual tanto el entrenamiento como la evaluación se realizaron exclusivamente sobre el conjunto de datos SYNTHUA-DT. El desempeño global y por clase se presenta junto con un análisis detallado de calibración, así como con una discusión de sus implicaciones para aplicaciones de navegación asistida, con especial énfasis en los dispositivos de movilidad y la infraestructura a nivel de acera.

3.1. Rendimiento global

La línea base U-Net alcanzó un mIoU de 0.0626 (IC del 95 %: 0.058–0.067), con valores macro-promediados de precisión, *recall* y *F1-score* de 0.1328, 0.0985 y 0.0872, respectivamente, lo que indica una capacidad limitada para capturar la estructura semántica global más allá de unas pocas clases dominantes. En contraste, DeepLabv3+ obtuvo un mIoU de 0.8400 (IC del 95 %: 0.828–0.852), junto con métricas macro-promediadas de precisión, *recall* y *F1-score* de 0.9085, 0.9145 y 0.9106, respectivamente, como se resume en la Tabla 3.

Tabla 2. Clases semánticas en SYNTHUA-DT y sus categorías de alto nivel

Clase	Elementos	Categoría
1	Edificios	Estructura
2	Silla de ruedas motorizada	Dispositivos de movilidad
3	Muletas	Dispositivos de movilidad
4	Andador	Dispositivos de movilidad
5	Silla de ruedas	Dispositivos de movilidad
6	Bastón ortopédico	Dispositivos de movilidad
7	Bastón	Dispositivos de movilidad
8	Muleta ortopédica	Dispositivos de movilidad
9	Césped	Naturaleza
10	Árboles, plantas	Naturaleza
11	Personas	Transeúntes
12	Perros	Transeúntes
13	Elementos del paisaje urbano	Mobiliario urbano
14	Lugares turísticos	Mobiliario urbano
15	Coche, autobús, vehículos	Transporte
16	Bicicleta	Transporte
17	Motocicleta, scooter	Transporte
18	Farola	Infraestructura urbana
19	Calles	Infraestructura urbana
20	Señales	Infraestructura urbana
21	Semáforos	Infraestructura urbana
22	Aceras	Infraestructura urbana

Estos resultados representan mejoras relativas de aproximadamente $13.4\times$ en mIoU, $6.8\times$ en precisión, $9.3\times$ en *recall* y $10.4\times$ en *F1-score* en comparación con U-Net. Adicionalmente, el valor de d de Cohen fue muy superior a 2 para el mIoU, confirmando un tamaño del efecto grande.

Las 22 clases semánticas se agrupan en siete categorías funcionales, como se presenta en la Tabla 2, reflejando los requisitos de accesibilidad urbana al diferenciar explícitamente dispositivos de movilidad, infraestructura, elementos naturales y clases relacionadas con peatones.

Con el fin de aislar el impacto de la arquitectura y del diseño de la función de pérdida, la Tabla 4 presenta un estudio de ablación que compara U-Net, DeepLabv3+ sin preentrenamiento sintético y DeepLabv3+ con preentrenamiento sintético, empleando pérdidas compuestas BCE–Dice y basadas en focal. DeepLabv3+ sin preentrenamiento ya supera a U-Net, alcanzando un mIoU de 0.291, lo que evidencia la ventaja de la arquitectura en términos de agregación

de contexto. La incorporación del preentrenamiento sintético incrementa el mIoU hasta 0.840 y mejora de manera sustancial el *recall* de la clase aceras, que pasa de 0.531 a 0.921. La variante basada en pérdida focal obtiene un mIoU comparable de 0.823 y presenta un *recall* ligeramente superior en algunas clases poco frecuentes; sin embargo, la combinación BCE–Dice ofrece el mejor equilibrio global entre desempeño agregado y

estabilidad entre clases.


Las Figuras 2(a) y 2(b) corroboran visualmente estas tendencias: mientras que U-Net genera máscaras fragmentadas y espacialmente inconsistentes, DeepLabv3+ produce predicciones más coherentes y de mayor resolución espacial, con límites de objeto claramente definidos.

Tabla 3. Comparación del rendimiento global de U-Net y DeepLabv3+ en SYNTHUA-DT (conjunto de prueba)


Modelo	mIoU	Precisión	Recuperación	Puntuación F1
U-Net	0.0626	0.1328	0.0985	0.0872
DeepLabv3+	0.8400	0.9085	0.9145	0.9106

Tabla 4. Estudio de ablación: impacto del preentrenamiento sintético y de las funciones de pérdida (métricas definidas en la Sección 2.6)

Modelo	mIoU	Precisión	Recuperación	Puntuación F1
U-Net	0.0626	0.1328	0.0985	0.0872
DeepLabv3+	0.8400	0.9085	0.9145	0.9106



(a) Resultados cualitativos de segmentación para U-Net



(b) Resultados cualitativos de segmentación para DeepLabv3+

Figura 2. Comparación de salidas de segmentación cualitativas para U-Net y DeepLabv3+.

3.2. Análisis por clases

Para evitar enmascarar el comportamiento de las clases minoritarias, se examinan las métricas y la prevalencia por clase.

3.2.1. Prevalencia del conjunto de datos

La Tabla 5 reporta la prevalencia a nivel de píxel de cada clase en la partición de prueba, normalizada al 100 %. Las clases dominantes —incluidas edificios, calzadas y vegetación adyacente a la vía— concentran la mayor proporción de píxeles, mientras que los dispositivos de movilidad y los elementos de infraestructura de pequeña escala representan una fracción marginal del conjunto de datos.

3.2.2. Línea base U-Net

La Tabla 6 resume el desempeño por clase del modelo U-Net. El modelo muestra un rendimiento nulo en las clases correspondientes a dispositivos de movilidad (clases 2–8), con valores de IoU, precisión, *recall* y *F1-score* iguales a cero. Asimismo, las clases de aceras y varios elementos de infraestructura presentan valores muy bajos de IoU y *recall*; por ejemplo, el *recall* de la clase aceras alcanza únicamente 0.153.

La matriz de confusión mostrada en la Figura 3(a) evidencia una clasificación errónea recurrente de las clases minoritarias como fondo o como categorías dominantes, lo que es consistente con los efectos del desbalance extremo de clases reportados en [5].

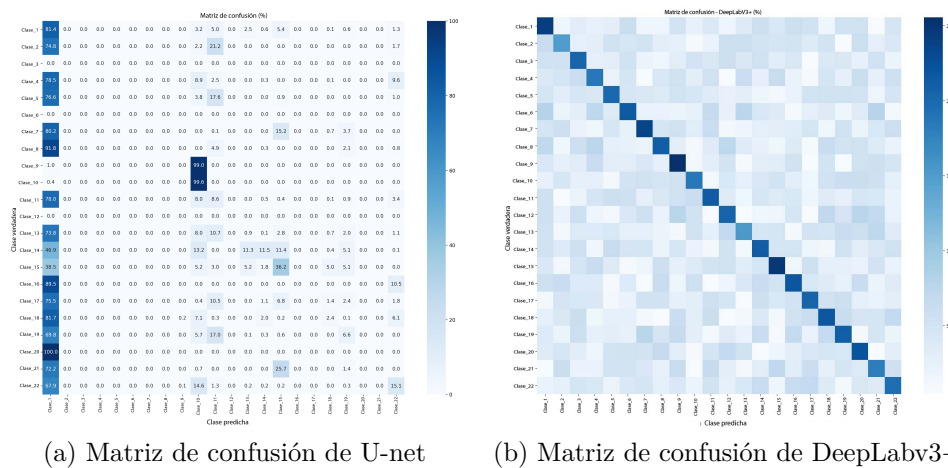


Figura 3. Comparación de matrices de confusión entre U-Net y DeepLabv3+. U-Net muestra un fuerte sesgo hacia las clases dominantes, mientras que DeepLabv3+ produce predicciones más precisas y diferenciadas.

Tabla 5. Prevalencia del conjunto de datos (proporción de píxeles por clase en el conjunto de prueba; normalizada para sumar 100 %)

Clase	Prevalencia (%)
Edificios	8.28
Silla de ruedas motorizada	4.70
Muletas	1.67
Andador	6.80
Silla de ruedas	7.23
Bastón ortopédico	5.50
Bastón	7.29
Muleta ortopédica	4.88
Césped	5.13
Árboles. plantas	4.33
Personas	0.87
Perros	1.55
Elementos del paisaje urbano	0.87
Lugares turísticos	6.12
Coches. autobuses. vehículos	3.34
Bicicletas	5.01
Motocicletas. scooters	8.47
Farolas	2.78
Calles	4.14
Señales	7.17
Semáforos	2.60
Aceras	1.30

Nota: Los píxeles se calculan globalmente en la división de la prueba y se normalizan para sumar el 100 %.

Tabla 6. Métricas de rendimiento por clase para U-Net en SYNTHUA-DT (conjunto de prueba)

Clase	IoU	Precisión	Recuperación	Especificidad	Puntuación F1	Acierto equilibrado
Edificios	0.554	0.819	0.632	0.595	0.710	0.613
Silla de ruedas motorizada	0.000	0.000	0.000	1.000	0.000	0.500
Muletas	0.000	0.000	0.000	1.000	0.000	0.500
Andador	0.000	0.000	0.000	1.000	0.000	0.500
Silla de ruedas	0.000	0.000	0.000	1.000	0.000	0.500
Bastón ortopédico	0.000	0.000	0.000	1.000	0.000	0.500
Bastón	0.000	0.000	0.000	1.000	0.000	0.500
Muleta ortopédica	0.000	0.000	0.000	1.000	0.000	0.500
Césped	0.000	0.000	0.000	1.000	0.000	0.500
Árboles. plantas	0.507	0.510	0.983	0.949	0.662	0.966
Humanos	0.011	0.018	0.042	0.953	0.022	0.497
Perros	0.000	0.000	0.000	1.000	0.000	0.500
Elementos del paisaje urbano*	0.001	0.002	0.004	0.993	0.002	0.499
Lugares turísticos**	0.004	0.106	0.004	1.000	0.007	0.502
Coches. autobuses. vehículos	0.077	0.160	0.249	0.972	0.137	0.611
Bicicletas	0.000	0.000	0.000	1.000	0.000	0.500
Motocicleta. scooter	0.000	0.094	0.000	1.000	0.000	0.500
Poste de alumbrado público	0.013	0.091	0.015	0.999	0.025	0.507
Calles	0.057	0.550	0.057	0.999	0.102	0.528
Señales***	0.000	0.000	0.000	1.000	0.000	0.500
Poste de semáforo	0.000	0.000	0.000	1.000	0.000	0.500
Aceras	0.141	0.681	0.152	0.989	0.245	0.570

*Bolardo, banco, papelería pública, columpio, sombrilla, panel publicitario

**Fuente, monumentos, lugar turístico

***Señal de límite de velocidad, señal de estacionamiento con límite de tiempo

Nota: La prevalencia de la clase es independiente del modelo y se indica una vez en la tabla 5.

3.2.3. DeepLabv3+

DeepLabv3+ exhibe un desempeño elevado en las clases asociadas a dispositivos de movilidad y a la infraestructura urbana. Como se muestra en la Tabla 7 y en la Figura 5, todas las clases de ayudas de movilidad superan un IoU de 0.75, destacándose la silla de ruedas motorizada con un IoU de 0.94. Asimismo, las clases humanas y de animales (perros), que rara vez son detectadas por U-Net, alcanzan valores de IoU de 0.754 y 0.944, respectivamente.

Las clases de infraestructura —incluidas aceras, calles, señales, postes de semáforo y postes de alumbrado público— también superan de manera consistente un IoU de 0.75. DeepLabv3+ mantiene un equilibrio adecuado entre precisión y *recall* en las ayudas de movilidad, como se ilustra en la Figura 4, mientras que

la distribución del *F1-score* presentada en la Figura 6 indica que la mayoría de las clases alcanzan valores superiores a 0.85, umbral comúnmente considerado indicativo de un desempeño apto para el despliegue.

En particular, el *recall* de la clase aceras aumenta de 0.152 con U-Net a 0.921 con DeepLabv3+, lo que representa una mejora aproximada de 6× y reduce de manera sustancial la presencia de falsos negativos en regiones críticas para la navegación asistida.

Las matrices de confusión mostradas en la Figura 3 evidencian claramente el contraste entre ambos modelos. U-Net presenta un fuerte sesgo hacia las clases dominantes, con una clasificación errónea generalizada de las clases minoritarias, que son absorbidas principalmente por el fondo o por categorías estructurales frecuentes.




Figura 4. DeepLabv3+: precisión y *recall* por clase.



Figura 5. DeepLabv3+: IoU por clase (métricas según la Sección 2.6).




Figura 6. DeepLabv3+: $F1$ -score por clase.

Tabla 7. Métricas de rendimiento por clase para DeepLabv3+ en SYNTHUA-DT (conjunto de prueba)

Clase	IoU	Precisión	Recuperación	Especificidad	Puntuación F1	Acierto equilibrado
Edificios	0,825	0,888	0,884	0,913	0,886	0,898
Silla de ruedas motorizada	0,940	0,898	0,936	0,972	0,916	0,954
Muletas	0,896	0,909	0,891	0,907	0,900	0,899
Andador	0,870	0,952	0,918	0,989	0,935	0,953
Silla de ruedas	0,781	0,876	0,921	0,970	0,898	0,945
Bastón ortopédico	0,781	0,917	0,874	0,918	0,895	0,896
Bastón	0,762	0,927	0,976	0,900	0,951	0,938
Muleta ortopédica	0,923	0,856	0,951	0,973	0,901	0,962
Césped	0,870	0,929	0,972	0,964	0,950	0,968
Árboles, plantas	0,892	0,872	0,966	0,966	0,917	0,966
Humanos	0,754	0,858	0,928	0,969	0,892	0,949
Perros	0,944	0,973	0,970	0,907	0,972	0,938
Elementos del paisaje urbano*	0,916	0,976	0,862	0,932	0,915	0,897
Lugares turísticos**	0,792	0,955	0,875	0,910	0,914	0,893
Coches, autobuses, vehículos	0,786	0,890	0,856	0,978	0,872	0,917
Bicicletas	0,787	0,863	0,892	0,956	0,877	0,924
Motocicleta, scooter	0,811	0,939	0,901	0,930	0,919	0,915
Poste de alumbrado público	0,855	0,907	0,885	0,906	0,896	0,895
Calles	0,836	0,866	0,958	0,928	0,909	0,943
Señales de tráfico***	0,808	0,914	0,896	0,929	0,905	0,913
Postes de semáforos	0,872	0,854	0,887	0,966	0,870	0,926
Aceras	0,778	0,968	0,921	0,957	0,944	0,939

*Bolardo, banco, papelera pública, columpio, sombrilla, panel publicitario

**Fuente, monumentos, lugar turístico

***Señal de límite de velocidad, señal de estacionamiento con límite de tiempo

Nota: La prevalencia de la clase es independiente del modelo y se indica una vez en la Tabla 5.

3.3. Calibración del modelo

La exactitud por sí sola es insuficiente para sistemas críticos para la seguridad; las estimaciones de confianza también deben ser fiables.


3.3.1. U-Net

La Figura 7(a) muestra el diagrama de fiabilidad del modelo U-Net. La curva se sitúa por debajo de la línea de calibración ideal para niveles de confianza superiores a 0.5, lo que indica una marcada sobreconfianza. En particular, las predicciones con una confianza reportada entre 0.6 y 0.8 corresponden a una precisión empírica de solo 0.2–0.4. Esta deficiente calibración


resulta especialmente problemática para aplicaciones de navegación asistida, donde errores asociados a altos niveles de confianza pueden conducir a decisiones de orientación inseguras.

3.3.2. DeepLabv3+ y escalado de temperatura

DeepLabv3+ presenta una calibración notablemente superior en comparación con U-Net, aunque persiste un grado moderado de sobreconfianza en los niveles más altos de confianza, como se observa en la Figura 7(b). La Tabla 8 resume cuantitativamente las métricas de calibración obtenidas antes y después de aplicar el escalado de temperatura.



(a) Curva de calibración de U-Net



(b) Curva de calibración de DeepLabv3+ (antes/después del escalado de temperatura)

Figura 7. Comparación de la calibración del modelo para U-Net y DeepLabv3+. Las curvas relacionan la confianza predicha con la precisión empírica (véanse las definiciones de ECE/MCE en la Sección 2.6).

Tabla 8. Métricas de calibración para DeepLabv3+ en el conjunto de prueba (media \pm IC del 95 % mediante bootstrap a nivel de imagen, 10 000 iteraciones)

Configuración	ECE (%)	MCE (%)	NLL	Brier
Pre-calibración	8.5 \pm 0.7	23.1 \pm 1.9	0.693 \pm 0.018	0.162 \pm 0.004
Escalado de temperatura	3.3 \pm 0.5	9.8 \pm 1.3	0.612 \pm 0.015	0.148 \pm 0.003

El escalado de temperatura reduce el ECE en aproximadamente un 61 % y el MCE en un 58 %, y mejora asimismo la NLL y la puntuación de Brier. La sobreconfianza queda en gran medida confinada al intervalo de mayor confianza (> 0.8), y la incidencia de clasificaciones erróneas con alta confianza es sustancialmente menor que en U-Net. Esta mejora resulta especialmente relevante para los módulos posteriores que deben tomar decisiones conscientes del riesgo.

3.4. Clases listas para el despliegue e impacto práctico

La Tabla 9 resume las clases que cumplen el umbral de preparación para el despliegue, definido como $\text{IoU} \geq 0.75$. Con DeepLabv3+, las 22 clases superan este umbral, incluidas las correspondientes a dispositivos de movilidad, infraestructura, elementos naturales y transeúntes. En contraste, ninguna de las clases alcanza este nivel de desempeño con U-Net.

Tabla 9. Clases que cumplen el umbral de preparación para el despliegue ($\text{IoU} \geq 0,75$) con DeepLabv3+

Categoría	Umbral de coincidencia de clases	Rango IoU
Dispositivos de movilidad	7/7 clases	0.762-0.940
Infraestructura urbana	5/5 clases	0.778-0.872
Naturaleza	2/2 clases	0.870-0.892
Estructura	1/1 clase	0.825
Transeúntes	2/2 clases	0.754-0.944
Mobiliario urbano	2/2 clases	0.792-0.916
Transporte	3/3 clases	0.786-0.811

Todas las clases de dispositivos de movilidad —incluidas sillas de ruedas, andadores, bastones, muletas y variantes ortopédicas— alcanzan valores de IoU entre 0.762 y 0.940, lo que indica una detección fiable a través de distintos puntos de vista y condiciones de iluminación. La clase aceras alcanza un IoU de 0.778 con un *recall* de 0.921, en comparación con un *recall* de 0.153 obtenido por U-Net, lo que supone una reducción de los falsos negativos de aceras superior al 80 %. Desde una perspectiva aplicada, este resultado disminuye de forma significativa la probabilidad de sugerir terreno no transitable como aceras a usuarios de sillas de ruedas.

4. Limitaciones y trabajo futuro

A pesar de las sólidas mejoras alcanzadas con SYNTHUA-DT y DeepLabv3+, deben reconocerse varias limitaciones:

- **Evaluación exclusivamente sintética y brecha de dominio.** Todos los experimentos se realizaron en un escenario sintético a sintético; el desempeño en condiciones reales —con variaciones de iluminación, desenfoque por movimiento, ruido del sensor y oclusiones— permanece sin evaluar. El trabajo futuro incorporará conjuntos de datos reales orientados a la accesibilidad y aplicará técnicas de adaptación de dominio, como alineación adversaria, transferencia de estilo y autoentrenamiento, para reducir la brecha entre lo sintético y lo real.
- **Detalles de clases de muy baja prevalencia y precisión en los límites.** Los errores residua-

les se concentran en estructuras delgadas, como las puntas de bastones y los radios de las sillas de ruedas, así como en las transiciones calle-acera, donde el IoU de contorno (≈ 0.68) se mantiene por debajo del umbral objetivo de 0.75. Se explorarán pérdidas sensibles a bordes, módulos de atención centrados en límites y recortes de mayor resolución para mejorar la consistencia geométrica de grano fino.

- **Diversidad de escenas y escenarios de accesibilidad.** Las escenas actuales se centran en entornos exteriores con un conjunto fijo de ayudas de movilidad y tipos de infraestructura. Escenarios relevantes —como transiciones interiores entre rampas y ascensores, obstáculos temporales (obras) y cruces congestionados— no están representados. Las futuras extensiones de SYNTHUA-DT incorporarán disposiciones más diversas, flujos dinámicos de peatones y configuraciones de accesibilidad poco frecuentes.
- **Familias de modelos y aprendizaje multitarea.** Solo se evaluaron U-Net y DeepLabv3+. No se analizaron otras familias de modelos, incluidos decodificadores basados en transformers, respaldos híbridos CNN-Transformer ni modelos ligeros en tiempo real. Dado que los sistemas operativos suelen requerir estimación conjunta de profundidad, segmentación por instancias o detección de rampas de bordillo, el trabajo futuro explorará arquitecturas multitarea que equilibren precisión, calibración y rendimiento en tiempo real.

- **Calibración y decisiones conscientes de la incertidumbre.** Incluso tras el escalado de temperatura, DeepLabv3+ mantiene una leve sobreconfianza a niveles altos de probabilidad. Investigaciones futuras integrarán métodos conscientes de la incertidumbre —incluidos ensamblados, dropout Monte Carlo y aprendizaje profundo evidencial— junto con reglas de decisión sensibles al riesgo, para que la planificación de rutas y las alertas de obstáculos consideren explícitamente la incertidumbre de la segmentación.

En conjunto, SYNTHUA-DT y el marco de entrenamiento propuesto constituyen un primer paso hacia la segmentación semántica sintética orientada a la accesibilidad. Los trabajos futuros combinarán generación de datos sintéticos, recopilación de datos del mundo real, técnicas avanzadas de adaptación de dominio y modelado consciente de la incertidumbre, con el objetivo de desarrollar módulos de percepción robustos para la navegación urbana inclusiva.

5. Conclusiones

Este estudio demuestra que la generación de datos sintéticos de alta fidelidad mediante Unreal Engine 5.1, combinada con un entrenamiento consciente del desbalance de clases y una arquitectura moderna de tipo codificador-decodificador, puede mejorar de forma sustancial la segmentación semántica en escenarios de accesibilidad urbana. Utilizando el conjunto de datos SYNTHUA-DT, el preentrenamiento de DeepLabv3+ con 5036 imágenes anotadas produjo un incremento de $13.4\times$ en el mIoU global, de 0.0626 a 0.84, junto con mejoras aproximadas de $6.8\times$ en precisión, $9.3\times$ en recall y $10.4\times$ en F1-score, en comparación con la línea base U-Net.

A nivel de clase, DeepLabv3+ detectó con éxito todas las categorías críticas para la accesibilidad, alcanzando un $\text{IoU} \geq 0.75$ para cada ayuda de movilidad presente en SYNTHUA-DT. Las sillas de ruedas motorizadas alcanzaron un IoU de 0.94, mientras que las sillas de ruedas convencionales y los andadores obtuvieron valores de IoU de 0.78 y 0.87, respectivamente. El recall en la detección de aceras aumentó de 0.153 con U-Net a 0.921 con DeepLabv3+, lo que redujo los falsos negativos de aceras en más del 80 % y mejoró de manera significativa la fiabilidad en la identificación de trayectorias para la navegación asistida. En conjunto, las 22 clases semánticas superaron el umbral de IoU de 0.75, lo que indica un rendimiento sólido y consistente tanto en clases dominantes como minoritarias.

El análisis de calibración mostró que DeepLabv3+ con escalado de temperatura reduce el error de calibración esperado y el error máximo de calibración en aproximadamente un 60 %, disminuyendo el riesgo de clasificaciones erróneas con alta confianza en decisiones

críticas para la seguridad. Esta combinación de un IoU elevado por clase y una calibración probabilística mejorada resulta especialmente relevante para los módulos posteriores que deben razonar sobre la seguridad de las rutas y la evitación de obstáculos bajo incertidumbre.

Persisten errores residuales en estructuras delgadas y en los límites, como las puntas de bastones, los radios de las sillas de ruedas y las transiciones de borde, para los cuales las métricas sensibles a contornos permanecen por debajo de 0.75. Como se discute en la Sección 4, el trabajo futuro abordará estas limitaciones mediante objetivos conscientes de los bordes, un muestreo sintético enriquecido de configuraciones poco frecuentes, familias de modelos más amplias —incluidas arquitecturas híbridas CNN-Transformer— y una adaptación explícita de dominio a imágenes urbanas del mundo real.

En contraste con los conjuntos de datos sintéticos orientados principalmente a la conducción autónoma, el marco SYNTHUA-DT modela y evalúa explícitamente las ayudas de movilidad y la infraestructura a nivel de acera, proporcionando un recurso centrado en la accesibilidad y un punto de referencia reproducible para futuras investigaciones en navegación urbana inclusiva y percepción para ciudades inteligentes.

Rol de autores

- **Santiago Felipe Luna Romero:** conceptualización, curación de datos, análisis formal, investigación, metodología, desarrollo de software, supervisión, validación, visualización, redacción - revisión y edición.
- **Renato Gouveia:** investigación, desarrollo de software, procesamiento de datos, redacción - borrador original.
- **Mauren Abreu de Souza:** administración de proyecto, obtención de financiación, recursos, supervisión.

Referencias

- [1] M. Ivanovs, K. Ozols, A. Dobrajs, and R. Kadikis, “Improving semantic segmentation of urban scenes for self-driving cars with synthetic images,” *Sensors*, vol. 22, no. 6, p. 2252, Mar. 2022. [Online]. Available: <http://doi.org/10.3390/s22062252>
- [2] E. Mohamed, K. Sirlantzis, and G. Howells, “Indoor/outdoor semantic segmentation using deep learning for visually impaired wheelchair users,” *IEEE Access*, vol. 9, pp. 147 914–147 932, 2021. [Online]. Available: <http://doi.org/10.1109/access.2021.3123952>


- [3] R. Azad, M. Heidary, K. Yilmaz, M. Hüttemann, S. Karimijafarbigloo, Y. Wu, A. Schmeink, and D. Merhof, “Loss functions in the era of semantic segmentation: A survey and outlook,” *arXiv preprint*, 2023. [Online]. Available: <http://doi.org/10.48550/ARXIV.2312.05391>
- [4] J. L. Gómez, M. Silva, A. Seoane, A. Borrás, M. Noriega, G. Ros, J. A. Iglesias-Guitian, and A. M. López, “All for one, and one for all: Urbansyn dataset, the third musketeer of synthetic driving scenes,” 2023. [Online]. Available: <http://doi.org/10.48550/ARXIV.2312.12176>
- [5] J. Tian, N. Mithun, Z. Seymour, H.-P. Chiu, and Z. Kira, “Striking the right balance: Recall loss for semantic segmentation,” *arXiv preprint*, 2021. [Online]. Available: <http://doi.org/10.48550/ARXIV.2106.14917>
- [6] Z. Song, Z. He, X. Li, Q. Ma, R. Ming, Z. Mao, H. Pei, L. Peng, J. Hu, D. Yao, and Y. Zhang, “Synthetic datasets for autonomous driving: A survey,” 2023. [Online]. Available: <http://doi.org/10.48550/ARXIV.2304.12205>
- [7] R. Kamimura, “Information-theoretic enhancement learning and its application to visualization of self-organizing maps,” *Neurocomputing*, vol. 73, no. 13–15, pp. 2642–2664, Aug. 2010. [Online]. Available: <http://doi.org/10.1016/j.neucom.2010.05.013>
- [8] Q. Wu and H. Liu, “Unsupervised domain adaptation for semantic segmentation using depth distribution,” in *Advances in Neural Information Processing Systems*, S. Koyejo, S. Mohamed, A. Agarwal, D. Belgrave, K. Cho, and A. Oh, Eds., vol. 35. Curran Associates, Inc., 2022, pp. 14 374–14 387. [Online]. Available: <https://upsalesiana.ec/ing35ar9r1>
- [9] S. F. Luna-Romero, C. R. Stempniak, M. Abreu de Souza, and G. Reynoso-Meza, *Urban Digital Twins for Synthetic Data of Individuals with Mobility Aids in Curitiba, Brazil, to Drive Highly Accurate AI Models for Inclusivity*. Springer Nature Switzerland, 2024, pp. 116–125. [Online]. Available: http://doi.org/10.1007/978-3-031-52090-7_12
- [10] Y. Yuan, Y. Du, Y. Ma, and H. Lv, “DSC-Net: enhancing blind road semantic segmentation with visual sensor using a dual-branch Swin-CNN architecture,” *Sensors*, vol. 24, no. 18, p. 6075, Sep. 2024. [Online]. Available: <http://doi.org/10.3390/s24186075>
- [11] E. Xie, W. Wang, Z. Yu, A. Anandkumar, J. M. Álvarez, and P. Luo, “Segformer: Simple and efficient design for semantic segmentation with transformers,” *arXiv preprint*, 2021. [Online]. Available: <https://doi.org/10.48550/arXiv.2105.15203>
- [12] S. F. Luna Romero, C. R. Stempniak, M. Abreu de Souza, and G. Reynoso-Meza, “A transfer learning model proposal for country border security using aerial thermal images,” in *Proceedings do XXIV Congresso Brasileiro de Automática*, ser. CBA2022. SBA Sociedade Brasileira de Automática, Oct. 2022. [Online]. Available: <http://doi.org/10.20906/cba2022/3341>
- [13] S. F. L. Romero, M. A. d. Souza, and L. S. Andrade, “Synthua-dt: A methodological framework for synthetic dataset generation and automatic annotation from digital twins in urban accessibility applications,” *Technologies*, vol. 13, no. 8, p. 359, Aug. 2025. [Online]. Available: <http://doi.org/10.3390/technologies13080359>
- [14] O. Ronneberger, P. Fischer, and T. Brox, “U-Net: Convolutional networks for biomedical image segmentation,” *arXiv preprint*, 2015. [Online]. Available: <http://doi.org/10.48550/ARXIV.1505.04597>
- [15] L.-C. Chen, Y. Zhu, G. Papandreou, F. Schroff, and H. Adam, “Encoder-decoder with atrous separable convolution for semantic image segmentation,” *arXiv preprint*, 2018. [Online]. Available: <http://doi.org/10.48550/ARXIV.1802.02611>
- [16] S. F. Luna-Romero, M. Abreu de Souza, and L. Serpa Andrade, “Artificial vision systems for mobility impairment detection: Integrating synthetic data, ethical considerations, and real-world applications,” *Technologies*, vol. 13, no. 5, p. 198, May 2025. [Online]. Available: <http://doi.org/10.3390/technologies13050198>
- [17] J. Tremblay, A. Prakash, D. Acuna, M. Brophy, V. Jampani, C. Anil, T. To, E. Cameracci, S. Boochoon, and S. Birchfield, “Training deep networks with synthetic data: Bridging the reality gap by domain randomization,” *arXiv preprint*, 2018. [Online]. Available: <http://doi.org/10.48550/ARXIV.1804.06516>
- [18] S. Ioffe and C. Szegedy, “Batch normalization: Accelerating deep network training by reducing internal covariate shift,” 2015. [Online]. Available: <http://doi.org/10.48550/ARXIV.1502.03167>
- [19] K. He, G. Gkioxari, P. Dollár, and R. Girshick, “Mask r-cnn,” *arXiv preprint*, 2017. [Online]. Available: <http://doi.org/10.48550/ARXIV.1703.06870>

- [20] T.-Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollár, “Focal loss for dense object detection,” *arXiv preprint*, 2017. [Online]. Available: <http://doi.org/10.48550/ARXIV.1708.02002>
- [21] J. Brewer, K. Rajagopal, A. Sadofyev, and W. van der Schee, “Evolution of the mean jet shape and dijet asymmetry distribution of an ensemble of holographic jets in strongly coupled plasma,” *Journal of High Energy Physics*, vol. 2018, no. 2, Feb. 2018. [Online]. Available: [http://doi.org/10.1007/jhep02\(2018\)015](http://doi.org/10.1007/jhep02(2018)015)
- [22] R. Gouveia. (2025) Pibiti semantic segmentation. Github, Inc. [Online]. Available: <https://upsalesiana.ec/ing35ar9r3>



SWIN TRANSFORMER V2 PARA CLASIFICACIÓN DE CAFÉ LOJANO

SWIN TRANSFORMER V2 FOR THE CLASSIFICATION OF LOJA COFFEE

Patricio Bolívar Betancourt Ludeña¹ , Oscar M. Cumbicus Pineda^{1,*} 

Recibido: 24-07-2025, Recibido tras revisión: 01-12-2025, Aceptado: 10-12-2025, Publicado: 01-01-2026

Resumen



Esta investigación presenta un modelo de clasificación binaria para granos de café verde de la variedad arábico procedentes de la región de Loja, Ecuador, basado en la arquitectura Swin Transformer V2. Se emplearon dos fuentes de datos, el conjunto de datos público USK-Coffee, de origen indonesio, y un conjunto de datos propio capturado bajo condiciones controladas. Se evaluaron dos estrategias de entrenamiento: transferencia secuencial y entrenamiento unificado, siendo este último el que alcanzó una precisión de validación del 98,30 %. Tras la optimización de hiperparámetros, el modelo logró una precisión del 100 % en un conjunto de prueba de 150 imágenes y del 93 % en un conjunto de generalización externo de 400 imágenes con condiciones variables de iluminación y fondo. La interpretabilidad del modelo se validó mediante Grad-CAM, evidenciando que la red enfoca su atención en zonas defectuosas reales. Un análisis de ablación mostró que la disminución de rendimiento en escenarios no controlados se debe principalmente a la sensibilidad al ruido y a la iluminación extrema. Como principales aportes, se destaca la creación de un conjunto de datos especializado y un modelo eficiente para la clasificación automática de café verde arábico.

Palabras clave: clasificación de café, inteligencia artificial, Vision Transformer, Swin Transformer, visión por computadora, aprendizaje por transferencia

Abstract

This study presents a binary classification model for green coffee beans of the Arabica variety from the Loja region in Ecuador, based on the Swin Transformer V2 architecture. Two datasets were used, the public USK-COFFEE dataset of Indonesian origin and a proprietary dataset captured under controlled conditions. Two training strategies were evaluated: sequential transfer learning and unified training, with the latter achieving a validation accuracy of 98.30%. After hyperparameter optimization, the model reached 100% accuracy on a test set of 150 images and 93% accuracy on an external generalization set of 400 images with varying lighting conditions and backgrounds. Model interpretability was validated using Grad-CAM, demonstrating that the network focuses on actual defective regions rather than background information. An ablation analysis revealed that performance degradation in unconstrained scenarios is mainly due to sensitivity to noise and extreme lighting conditions. The main contributions of this work include the creation of a specialized dataset for Arabica green coffee from Loja and the development of an efficient model for its automatic classification.

Keywords: coffee classification, artificial intelligence, Vision Transformer, Swin Transformer, computer vision, transfer learning

^{1,*}Carrera de Ingeniería en Computación, Universidad Nacional de Loja, Ecuador. 
 Autor para correspondencia : oscar.cumbicus@unl.edu.ec.

Forma sugerida de citación: P. T. Betancourt Ludeña y O. M. Cumbicus Pineda, "Swin Transformer V2 para clasificación de café lojano," *Ingenius, Revista de Ciencia y Tecnología*, N.º 35, pp. 138-, 2026. DOI: <https://doi.org/10.17163/ings.n35.2026.10>.

1. Introducción

El sector de producción de café, específicamente en la producción de café verde arábico, está experimentando un crecimiento continuo [1]. De la misma forma, en la zona de Loja, Ecuador, la expansión de este sector ha sido evidente [2]. Sin embargo, enfrenta retos significativos en cuanto a la clasificación precisa de los granos, un proceso esencial para asegurar la calidad del producto final y mantener su competitividad en el mercado internacional [3]. Tradicionalmente, este proceso se ha realizado de manera manual, lo que ha dado lugar a variabilidad en los resultados debido a la intervención humana y a la fatiga del trabajo repetitivo [4]. En este contexto, las tecnologías que han aparecido en los últimos años, basadas en inteligencia artificial (IA), específicamente en modelos de visión por computadora, han ofrecido una solución innovadora y precisa para la automatización de la tarea de clasificación de granos de café [5, 6]. Hasta el momento, las redes neuronales convolucionales (CNN) han destacado por demostrar resultados muy favorables en la clasificación [7, 8], [5]. Por otro lado, los modelos Vision Transformers (ViT), y más recientemente el Swin Transformer, han demostrado una superioridad al generalizar ciertas características locales y globales de imágenes complejas [9, 10].

En la actualidad, son variados los modelos que se presentan como soluciones a esta problemática, como en [11] donde se alcanzó una precisión de 99.84 % en la detección de defectos de granos de café verde arábico. En el trabajo realizado en [12], se emplearon imágenes multispectrales y SVM (Support Vector Machine, máquina de vectores de soporte) para clasificar entre clases especiales y comerciales de granos de café, alcanzando 96 % de precisión. Asimismo, en [13] se usó un enfoque de clasificación multiclase y se reportó una precisión de 84.75 % con su modelo Swin Transformer, al usar el conjunto de datos USK-Coffee. Estos trabajos ilustran la capacidad que tienen las tecnologías de visión por computadora para superar las limitaciones humanas en la clasificación de granos de café. De la misma manera, una limitación importante para el desarrollo de los modelos a nivel local es la inexistencia de un conjunto de datos propio de la zona de Loja, lo cual restringe la capacidad de los modelos para generalizar y aprender las características específicas del café de producción lojano.

Recientemente, los modelos de visión por computadora basados en Transformers han demostrado un gran potencial [14, 15]. Los Vision Transformers procesan las imágenes en parches, aplicando una atención global y local a los detalles de estas. En trabajos comparativos como en [16] donde se compararon modelos de ViT y CNN en imágenes de retina, se demostró que el modelo Swin Transformer obtuvo un rendimiento mayor que las redes neuronales convolucionales con

una precisión del 97.3 %. Adicionalmente, el modelo Swin Transformer V2 desarrollado por Liu *et al.* [17] ha escalado su arquitectura a 3 mil millones de parámetros y estableció récords de rendimiento al aumentar la capacidad y resolución del modelo. Este avance en la versión del modelo sugiere una mayor capacidad para la discriminación de patrones visuales más complejos, lo cual es necesario para la detección de defectos pequeños en los granos de café. El presente trabajo propone el diseño y evaluación de un modelo de clasificación binaria de granos de café verde arábico de la zona de Loja, Ecuador.

En consecuencia, para la realización de este estudio se emplearon conjuntos de datos públicos de imágenes de café, complementados con un conjunto de imágenes tomadas de granos de la zona de Loja, obtenidos mediante una captura en condiciones controladas. El modelo fue entrenado y validado con los conjuntos de datos antes descritos y evaluado con el conjunto de datos lojano. Este estudio evaluó el rendimiento del modelo de Swin Transformer V2, preentrenado con ImageNet-1K, a través de la aplicación de técnicas de transfer learning y fine tuning. Por otro lado, esta investigación contribuye al estado del arte un nuevo conjunto de datos de café verde arábico de la provincia de Loja.

2. Materiales y métodos

En la presente sección se describen los conjuntos de datos utilizados, la arquitectura del modelo Swin Transformer V2 implementado, la estrategia de entrenamiento y las métricas de evaluación empleadas para la clasificación de granos de café verde arábico, todo lo anterior resumido en 3 fases abarcadas por la metodología CRISP-ML(Q) [18], como lo son ingeniería de datos, ingeniería de modelos y evaluación de modelos (Figura 1).

2.1. Conjuntos de datos utilizados

Para el desarrollo y evaluación del modelo, se utilizaron dos conjuntos de datos principales, relacionados con la clasificación de granos de café verde (pelado y sin someter a tueste) de la variedad arábica. A continuación, se pueden ver los conjuntos de datos seleccionados para esta investigación.

USK-Coffee: Un conjunto de datos público que contiene 8000 imágenes de granos de café verde arábico, originalmente distribuidas en 4 clases (peaberry, longberry, premium, defect) [19]. Para este estudio, se modificó el conjunto de datos original consolidando tres de sus clases (peaberry, longberry y premium) en una categoría denominada “buenos”, mientras que la clase defect se mantuvo como “defectuosos”, formando así una clasificación binaria. Específicamente, a la clase “defectuosos” se le aplicaron técnicas de aumento de

datos, incluyendo: rotaciones aleatorias, volteos horizontales/verticales, ajustes de brillo/contraste, con el fin de balancear las clases manteniendo cierta varia-

bilidad de los datos, para evitar un overfitting en el entrenamiento.

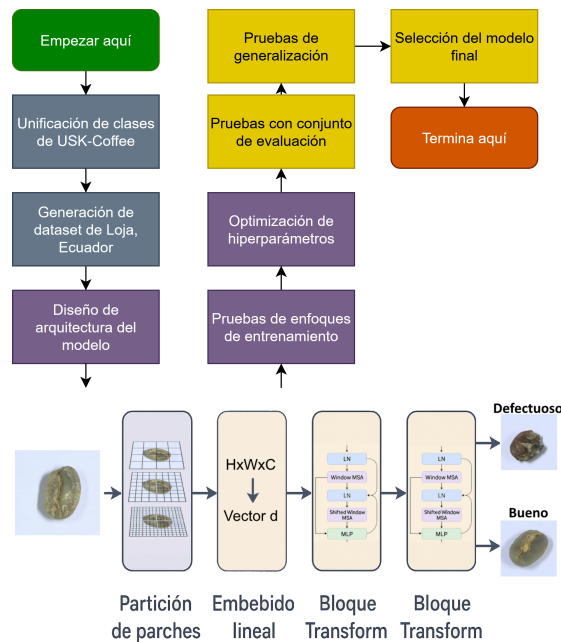


Figura 1. Diagrama de materiales y métodos. El flujo muestra: entrada de imagen de grano de café (HxWxC), partición en parches, embebido lineal, bloques Transformer secuenciales y clasificación binaria final (bueno/defectuoso).

Conjunto de datos lojano. Se construyó un conjunto de datos propio a partir de granos de café verde arábico recolectados en la zona de Gonzanamá, provincia de Loja, Ecuador. Para la recolección, se seleccionaron cinco libras de café de manera aleatoria, las cuales fueron descascaradas y trilladas. Posteriormente, un caficultor local realizó la clasificación manual separando los granos en dos categorías: bueno y defectuoso. Con el fin de capturar las imágenes bajo condiciones controladas, se dispusieron los granos sobre una hoja A4 de papel bond blanco colocada encima de una cartulina A3 blanca. Cada fotografía incluyó 50 granos organizados en 5 columnas y 10 filas, con separaciones de 5 cm y 3 cm, respectivamente. La iluminación se aseguró mediante dos lámparas LED blancas colocadas a 22 cm de altura y una tira LED RGB en blanco alrededor de la hoja.

Las imágenes fueron tomadas con una cámara Canon EOS R50 equipada con un lente de 20 mm, ubicada a 28 cm de la superficie. Los parámetros de captura se configuraron en: tiempo de obturación de 1/5 s, apertura F22, sensibilidad ISO 100 y disparo remoto con temporizador de 2 segundos. Cada fotografía se registró en formatos JPG y RAW, con resolución de 6000×4000 px (24 MP).

En total, se capturaron 10 fotografías de 50 granos cada una, las cuales fueron procesadas posteriormente

mediante un script en Python para recortar imágenes individuales de 256×256 px en formato RGB, manteniendo un fondo blanco. El resultado final fue un conjunto balanceado de 1000 imágenes (500 por clase) que conforman el conjunto de datos lojano.

Ambos conjuntos de datos fueron divididos aleatoriamente en subconjuntos de entrenamiento, validación y prueba. Para el conjunto de datos USK-Coffee modificado, se utilizó una proporción de 80 % para entrenamiento y 20 % para validación. Para el conjunto de datos lojano, la división fue de 70 % para entrenamiento, 15 % para validación y 15 % para prueba (Figura 2).




Figura 2. Porcentajes de división de los conjuntos de datos USK-Coffee y lojano.

Para fomentar la reproducibilidad y la colaboración en la comunidad científica, el conjunto de datos lojano se ha puesto a disposición pública en el repositorio Zenodo bajo una licencia CC BY-NC 4.0 (Creative Commons Attribution No Derivatives 4.0 International), permitiendo su uso en investigación sin fines de lucro. El conjunto de datos puede ser accedido a través de su DOI [20].

2.2. Modelo Swin Transformer V2

El modelo de aprendizaje profundo seleccionado fue un Swin Transformer V2. Esta arquitectura fue elegida por su capacidad de extraer características tanto locales como globales de las imágenes, gracias a su diseño jerárquico con mecanismos de autoatención en ventanas desplazadas que permiten captar patrones a diferentes escalas. Se exploraron tres variantes preentrenadas del Swin Transformer V2 (denominadas base, large y giant), las cuales provienen de un entrenamiento previo en el conjunto de datos ImageNet-1K [17].

La variante seleccionada sirvió como punto de partida para realizar fine tuning en la tarea específica de clasificación de granos de café lojano, ofreciendo diferentes capacidades de modelo para ser comparadas en los experimentos. En general, el uso de pesos preentrenados aprovechó el conocimiento adquirido en la clasificación general de imágenes, lo que aceleró la convergencia del entrenamiento en el nuevo dominio. La elección de esta arquitectura se decidió por las peculiaridades de Transformers en visión por computadora, destacando en su capacidad para capturar dependencias globales en la imagen mediante mecanismos de atención, a diferencia de las CNN tradicionales enfocadas en regiones locales.

2.3. Métodos de entrenamiento

Se evaluaron dos métodos de entrenamiento del modelo con los datos seleccionados. El primer método correspondió a una aplicación secuencial de transfer learning, en la cual se ajustó el modelo en dos etapas, en la primera, se realizó el fine tuning inicial utilizando únicamente el conjunto de datos USK-Coffee, y posteriormente se llevó a cabo una segunda etapa de ajuste fino empleando las imágenes locales del café de Loja; generalizando las características del conjunto amplio antes de especializarse en las características del conjunto reducido. El segundo método consistió en un entrenamiento conjunto, combinando los dos conjuntos de datos desde el inicio en una única fase de entrenamiento. En este método, las imágenes de USK-Coffee y de Loja se mezclaron durante el proceso de aprendizaje, de manera que el modelo aprendió simultáneamente de ambos conjuntos de datos. Estos dos enfoques permitieron comparar los resultados de entrenar el modelo con el conjunto de datos global

de manera secuencial e integrarlo de forma unificada durante la optimización del modelo.

2.4. Configuración experimental

Los experimentos se llevaron a cabo utilizando recursos de cómputo con soporte de GPU para acelerar el entrenamiento. En particular, se empleó una estación de trabajo local (entorno Visual Studio Code) equipada con GPU de 8 GB de VRAM y un servidor institucional con JupyterHub con capacidad de cómputo gráfico de 4 GPUs con 12 GB de VRAM cada una (48 GB de VRAM total).

En cuanto a la optimización de hiperparámetros de entrenamiento, se generaron 7 modelos, probando diferentes valores de tasa de aprendizaje, tamaño de lote y dropout (Tabla 1). El número de épocas de entrenamiento se fijó de antemano con base en experimentos preliminares [18], dando las iteraciones suficientes para la convergencia del modelo sin llegar a un sobreajuste.

Tabla 1. Valores aplicados en la optimización de hiperparámetros manual. Ép: Épocas, TL: Tamaño de lote (batch size), TA: Tasa de aprendizaje (learning rate), Opt.: Optimizador, Acr.: Acrónimo del modelo.

Ép	TL	TA	Dropout	Opt.	Acr.
25	2	3×10^{-6}	0.5	Adam	M1
25	2	1×10^{-6}	0.5	Adam	M2
20	2	5×10^{-6}	0.5	Adam	M3
20	2	7×10^{-6}	0.45	Adam	M4
40	4	3×10^{-6}	0.55	Adam	M5
100	4	5×10^{-7}	0.55	Adam	M6
100	4	5×10^{-7}	0.55	SGD	M7

En términos de complejidad computacional, el entrenamiento del modelo final (configuración M4, ver Tabla 1) requirió aproximadamente una hora utilizando el servidor institucional. Este tiempo de entrenamiento relativamente corto, dado el tamaño del conjunto de datos combinado, demuestra la eficiencia del enfoque de transfer learning. Para una implementación práctica en un entorno de producción, como una planta de procesamiento de café, se requeriría una estación de trabajo con una GPU dedicada de gama media o alta para asegurar una clasificación en tiempo real. Aunque esto implica una inversión inicial en hardware, el costo es competitivo en comparación con equipos de selección óptica especializados, ofreciendo una solución escalable y adaptable mediante software.

3. Resultados y discusión

3.1. Ingeniería de datos

Se consolidaron los conjuntos de datos necesarios y se aplicaron técnicas para mejorar su calidad. Inicialmente, se seleccionó el conjunto de datos USK-Coffee

como base debido a su amplitud (8000 imágenes de café verde arábico). Dado que la tarea se planteó como una clasificación binaria de granos “buenos” y “defectuosos”, las clases originales (peaberry, longberry y premium) se unificaron en una sola categoría denominada “bueno” y por su parte la clase “defect” se renombró como “defectuoso” (como se describe en la sección 2.1). Este conjunto de datos modificado dio como resultado un desbalance de 3000 imágenes de granos buenos, frente a 2000 imágenes de granos defectuosos. Para la corrección del desequilibrio de clases, se realizó un sobremuestreo con transformaciones (Figura 3), de la clase defectuoso hasta obtener 3000 imágenes por cada clase.

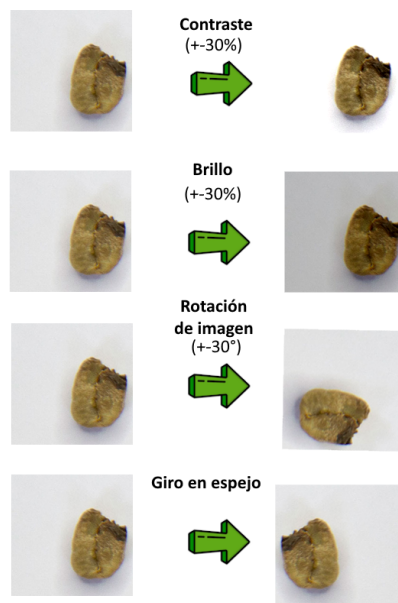


Figura 3. Transformaciones para sobremuestreo de la clase minoritaria “defectuoso”.

Adicionalmente, se construyó un conjunto de datos de café verde arábico recolectado y clasificado por productores de Loja. Se capturaron 500 imágenes por clase (“bueno” y “defectuoso”), aportando un contexto local con las características intrínsecas del café de la zona, complementando el conjunto de datos de Indonesia. Los conjuntos de datos de Indonesia y Loja se dividieron aleatoriamente para el entrenamiento y validación del modelo, y un 15 % del conjunto de datos de Loja se destinó para la prueba del desempeño del modelo, como se describe en la sección 2.1.

3.2. Ingeniería de modelos

Se decidió emplear la arquitectura Swin Transformer V2 preentrenada, ajustándola mediante fine tuning para la tarea específica de clasificación de granos de café verde arábico. Entre las variantes disponibles, se seleccionó el modelo Swin V2 Large debido a que ofrece

un equilibrio adecuado entre rendimiento y complejidad: reporta un Top-1 Accuracy de 87.7 % en ImageNet [17] con un tamaño moderado de parámetros, evitando la sobrecarga computacional de la versión gigante (90.2 % Top-1 pero mucho más pesada).

Se exploraron dos métodos de entrenamiento del modelo para aprovechar los datos disponibles. En el Método 1, se entrenó primero el modelo con el conjunto de datos USK-COFFEE (Indonesia) y luego se realizó un transfer learning adicional con el conjunto de datos de Loja, buscando que en una segunda fase el modelo se especialice en las características regionales. En el Método 2, en cambio, se combinaron ambos conjuntos de datos desde el inicio en un solo entrenamiento unificado. Tras probar ambos enfoques, se observó que el método de conjunto de datos unificado logró una mayor precisión de validación (98.30 %) que el método por fases separado (97.33 %). Por ello, para las siguientes etapas se optó por entrenar el modelo con los datos combinados, lo que sugiere que exponer conjuntamente al modelo al completo de datos permitió una generalización inicial mejor.

Adicionalmente, se llevó a cabo una optimización manual de hiperparámetros, ajustando iterativamente los valores hasta maximizar la precisión de validación, para refinar el desempeño del modelo. Se probaron 7 configuraciones distintas (modelos M1–M7) variando parámetros clave como número de épocas, tamaño de lote (batch), tasa de aprendizaje (learning rate), dropout y optimizador. Cada modelo fue entrenado bajo la estrategia de datos unificados. En general, todos los modelos lograron converger a altas precisiones de validación sin diferencias drásticas entre la mayoría de las configuraciones. Este resultado indica que la elección de hiperparámetros dentro de rangos razonables no afectó radicalmente el desempeño, debido a la riqueza del conjunto de datos y la robustez del modelo preentrenado. No obstante, para proceder con una evaluación más detallada, se seleccionaron los cuatro modelos con mayor desempeño (M1, M4, M5 y M6), siendo M6 el que mejor desempeño demostró en el entrenamiento y validación con 98.22 % de precisión global (Figura 4); además, se descartaron los que presentaron un menor rendimiento (Tabla 2).

Tabla 2. Valores de precisión y pérdida en validación para cada modelo en la optimización de hiperparámetros.

Modelo	Precisión validación	Pérdida validación
M1	98.15 %	0.1242
M2	97.85 %	0.1009
M3	97.85 %	0.1401
M4	97.93 %	0.1031
M5	97.93 %	0.1749
M6	98.22 %	0.1527
M7	96.67 %	0.1235




Figura 4. Progreso en el entrenamiento y validación del modelo M6. a) Curva de pérdida, b) Curva de precisión.

3.3. Evaluación de los modelos

Se analizó el rendimiento de los modelos seleccionados en el conjunto de prueba (test), tanto en un entorno controlado (conjunto de pruebas) como en condiciones más desafiantes, integrando las métricas de clasificación y su interpretación a la luz del marco teórico. Inicialmente, los cuatro modelos (M1, M4, M5, M6) fueron evaluados sobre el conjunto de prueba local (imágenes de Loja no utilizadas en entrenamiento, 150 muestras). Todos lograron una precisión global del 100 % en esta prueba, clasificando correctamente cada imagen como grano “bueno” o “defectuoso” (Figura 5). Consecuentemente, sus métricas por clase (precisión, *recall* –sensibilidad– y puntaje F1 media armónica entre precisión y *recall*) alcanzaron valores de 100 % en ambas categorías, evidenciando una adaptación sobresaliente a las características particulares de los granos de café lojano. Si bien un 100 % de acierto sugiere un desempeño excelente, es importante considerar que este conjunto de prueba proviene del mismo dominio y condiciones controladas que el entrenamiento (misma variedad de grano, iluminación similar, fondo uniforme). Desde una perspectiva crítica, un resultado

perfecto en un entorno conocido puede indicar un sobreajuste del modelo a las condiciones específicas, por lo que era necesaria una prueba más exigente para evaluar la capacidad de generalización de los modelos.




Figura 5. Matriz de confusión de los modelos con el conjunto de prueba.

Prueba de generalización. Para una evaluación más rigurosa basada en la metodología CRISP-ML(Q), se sometió al modelo a un conjunto de pruebas de generalización compuesto por 400 imágenes adicionales con mayores variaciones (condiciones de luz, fondo, dispositivo de captura, entre otras), simulando un entorno real. Estas imágenes fueron capturadas con dispositivos móviles bajo condiciones no controladas para evaluar la robustez del modelo. En este escenario, se evidenció una degradación marginal del desempeño; no obstante, el rendimiento global del modelo se mantuvo elevado, el mejor de los modelos (configuración M4, ver Tabla 1) alcanzó una precisión global del 93 %, mientras que los demás rondaron el 92 %. La Figura 6 muestra la matriz de confusión obtenida por el modelo M4 en esta prueba de generalización. En ella se observa que, de 200 imágenes reales de cada clase, el modelo identificó correctamente 195 granos “buenos” y 176 “defectuosos”.

Se produjeron algunos errores con 5 falsos negativos y 24 falsos positivos. Estas cifras implican que, para la clase “bueno”, se logró una sensibilidad (*recall*) del 97 % y un *F1-score* (media armónica entre precisión y *recall*) del 93 %, mientras que para la clase “defectuoso” la sensibilidad fue menor con 88 % y un *F1-score* de 92 % debido principalmente a los falsos positivos. A pesar de esta leve disminución de rendimiento en condiciones más heterogéneas, el modelo mantiene un equilibrio aceptable entre precisión y *recall* en ambas clases, evitando sesgarse completamente hacia una de ellas. Esto sugiere que la estrategia de balanceo de datos y la incorporación de variabilidad en el entrenamiento efectivamente contribuyeron a lograr una clasificación consistente en ambas categorías de granos.




Figura 6. Matriz de confusión de la prueba de generalización del modelo con la cuarta configuración (M4).

Un análisis más detallado de los errores en la prueba de generalización ofrece información valiosa. Los 24 falsos positivos se atribuyen principalmente a las condiciones de captura no controladas. La iluminación variable en las imágenes de prueba, tomadas con dispositivos móviles bajo condiciones no controladas (a diferencia del conjunto de entrenamiento), probablemente generó sombras que ocultaron defectos sutiles, llevando al modelo a una clasificación incorrecta. Por otro lado, los 5 falsos negativos pueden explicarse por factores similares; sombras pronunciadas o manchas naturales en granos sanos pudieron ser malinterpretadas como defectos por el modelo. Adicionalmente, la menor resolución de las cámaras de los dispositivos móviles pudo afectar la claridad de los detalles del grano, contribuyendo a estas confusiones.

Para complementar estas métricas, el reporte de clasificación del modelo M4 arrojó una precisión balanceada (macro avg –promedio de las métricas de cada clase–) del 93 %. Este valor, junto con los altos puntajes de *recall* (97 % para “bueno” y 88 % para “defectuoso”), confirma que el modelo mantiene un rendimiento equilibrado y no muestra un sesgo significativo hacia ninguna de las dos clases, abordando una de las preocupaciones clave en tareas de clasificación con clases desbalanceadas.

Finalmente, aunque el modelo M6 obtuvo la mayor precisión en la validación, el modelo M4 demostró una mayor capacidad de generalización en un conjunto de datos más desafiante y no visto, por presentar una precisión global superior (93 %), superando al resto de los modelos (Tabla 3). además, mostró métricas por clase más uniformes, a diferencia de los otros modelos que, aunque tienen una precisión global similar, evidenciaron pequeñas brechas entre clases. El balance entre clases resulta fundamental en tareas de clasificación binaria desbalanceada, ya que evidencia que el modelo no prioriza la detección de una categoría sobre la otra, sino que mantiene una capacidad de reconocimiento

equilibrada y precisa para ambos tipos de granos. Los hallazgos de la evaluación indican que el modelo Swin Transformer V2 ajustado puede alcanzar resultados perfectos bajo condiciones controladas; no obstante, en contextos más heterogéneos su precisión puede disminuir, lo que sugiere oportunidades de mejora en la robustez del enfoque implementado.

Tabla 3. Valores de precisión y pérdida en validación para cada modelo en la optimización de hiperparámetros.

Modelo	Precisión	Precisión ‘bueno’	Precisión ‘defectuoso’
M1	0.92	0.88	0.96
M4	0.93	0.89	0.97
M5	0.92	0.89	0.96
M6	0.82	0.88	0.96

Análisis de ablación. Adicionalmente, para explicar la divergencia de rendimiento entre el entorno controlado (100 %) y la prueba de generalización (93 %), se realizó un estudio de ablación cuantitativo sometiendo al modelo a degradaciones ambientales sintéticas: variaciones de brillo, ruido y desenfoque (Figura 7). El análisis revela que la arquitectura es altamente robusta al desenfoque (Blur), manteniendo un *F1-score* superior al 96 % incluso con núcleos de desenfoque grandes (Figura 7c), lo que indica que la falta de nitidez en fotos de móviles no es un factor crítico. Sin embargo, el modelo mostró sensibilidad ante condiciones extremas de iluminación y ruido. Como se observa en la Figura 7a (Brightness), aunque el modelo tolera variaciones moderadas, una sobreexposición severa (factor > 2.5) provoca una caída drástica del *recall* al 25 %, impidiendo la detección de defectos. De igual forma, la inyección de ruido (noise, Figura 7b) degrada linealmente la precisión; con una desviación estándar de 0.6, el *recall* desciende a un 3 %, sugiriendo que el grano digital generado por sensores móviles en baja luz afecta la capacidad del modelo para discernir texturas finas. Estos hallazgos confirman que la caída del 7 % en la prueba de generalización se atribuye principalmente a factores de iluminación no controlada y ruido de sensor, más que a problemas de enfoque.

Pruebas de interpretabilidad. Para complementar el análisis cuantitativo y asegurar la interpretabilidad del modelo, se empleó la técnica de visualización Grad-CAM [21]. Esta herramienta permite verificar si la red neuronal fundamenta sus predicciones en las características relevantes del grano o en artefactos espurios. En la Figura 8a se presenta la imagen original de un grano clasificado como defectuoso, donde se ha delimitado mediante un recuadro rojo la ubicación física real del defecto antes del procesamiento. Los resultados visuales posteriores, mostrados en el mapa de calor (Figura 8b) y la superposición Grad-CAM (Figura 8c), evidencian que el modelo Swin Transformer concentra su máxima activación (representada en tonos rojos)

precisamente dentro del área del defecto señalada. Esta coincidencia espacial entre el defecto real y la atención de la red valida empíricamente el proceso de toma de

decisiones del modelo, confirmando que la clasificación se basa en la morfología del daño y no en el ruido de fondo.




Figura 7. Análisis de ablación frente a perturbaciones ambientales. a) Impacto de la variación de brillo (brightness). b) Impacto del ruido gaussiano (noise). c) Impacto del desenfocado (blur). Se observa una alta estabilidad ante el desenfocado, pero una degradación significativa del *recall* en condiciones de ruido extremo y sobreexposición.

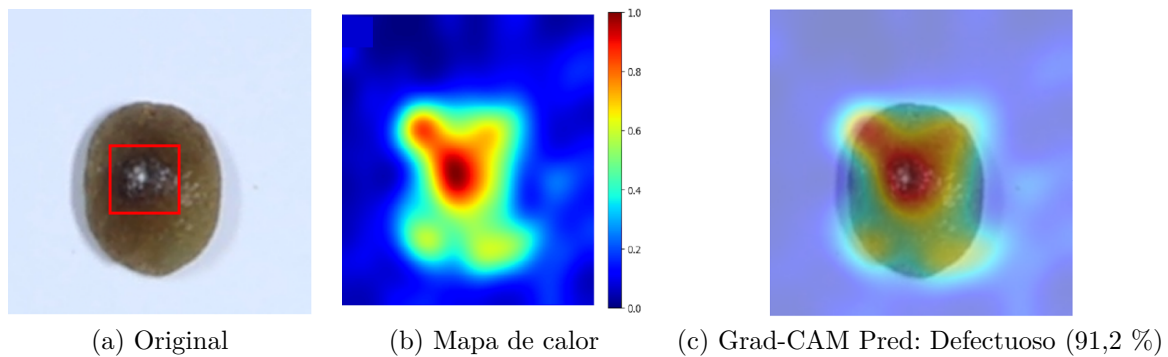


Figura 8. Análisis de interpretabilidad mediante Grad-CAM. a) Imagen original con el defecto resaltado manualmente en un recuadro rojo. b) Mapa de calor de atención generado por el modelo. c) Superposición (Grad-CAM) mostrando que la activación del modelo coincide con la zona del defecto.

3.4. Discusión

Los resultados obtenidos se contrastan a continuación con estudios recientes sobre clasificación de granos de café verde mediante inteligencia artificial, especialmente aquellos basados en arquitecturas Vision Transformer y CNN, para contextualizar el rendimiento de nuestro enfoque para café de Loja.

En primer lugar, el modelo Swin V2 adaptado alcanzó en validación interna precisiones de 98 % y en pruebas finales de generalización de hasta 93 % de acierto global. Este desempeño se alinea con la tendencia reportada por trabajos recientes que exploran Transformers en visión, como en [13] se logró un 84.75 % de precisión utilizando una arquitectura basada en Transformer (Swin Transformer) en una clasificación multiclase con el mismo conjunto de datos USK-Coffee sin modificaciones. En el presente estudio, al simplificar el problema a una clasificación binaria y reforzarlo

con datos locales y fine tuning, se alcanzó durante la fase de validación un rendimiento de 98 % de precisión global. Del mismo modo, en [15] se propuso un método de clasificación de granos con Swin Transformer orientado a la gradación de calidad, destacando igualmente el potencial de esta arquitectura para capturar características relevantes en café verde. Los hallazgos obtenidos respaldan esas evidencias: los Vision Transformers, adecuadamente entrenados, pueden alcanzar una precisión muy elevada en esta tarea, incluso por encima de algunos modelos CNN tradicionales bajo escenarios similares.

En entornos de prueba controlados, el modelo ViT entrenado en el presente estudio consiguió un 100 % de acierto, superando las precisiones reportadas por CNN en tareas similares. En [6] se diseñó una CNN optimizada para detección de defectos en granos de café que alcanzó 95.2 % de precisión en su conjunto de

prueba. En contraste, el presente modelo obtuvo 100 % en pruebas locales y 93 % en pruebas de mayor complejidad, demostrando la capacidad de los ViT para lograr un desempeño similar o superior a las CNN en la clasificación de granos. Sin embargo, es necesario contextualizar estos números. En [5] se desarrolló una CNN ligera y explicable (LDCNN) para detección de calidad de café verde, logrando 98.38 % de precisión y 98.24 % de *F1-score* en su conjunto de datos de prueba. Asimismo, Gope y Fukai [22] reportaron cerca de 98.19 % de precisión usando una CNN para clasificar granos tipo “peaberry” vs “normales”. Estas cifras superan ligeramente el 93 % obtenido por el modelo en la prueba de generalización; no obstante, cabe resaltar que estos estudios realizaron pruebas en entornos controlados o con condiciones fijas.

Por otro lado, en [11] emplearon una arquitectura MobileNetV3 para clasificar defectos en café arábigo tailandés (tarea multiclase) y obtuvieron 88.63 % de precisión, valor inferior al 93 % alcanzado por el modelo entrenado en un reto de generalización más complejo. En conjunto, estos contrastes sugieren que el enfoque usado en este trabajo basado en ViT, es similar con el estado del arte recabado, logrando resultados de métricas favorables en contraste a muchos de los modelos previos de CNN, especialmente al simplificar la clasificación a dos clases y al sumar un nuevo conjunto de datos especializado en la zona de Loja. A su vez, el análisis de robustez revela que, aunque el modelo supera a arquitecturas previas, existe un margen de mejora para equiparar la tolerancia al ruido que algunas CNN han demostrado, sugiriendo la necesidad de incluir aumentos de datos específicos de ruido e iluminación en trabajos futuros.

4. Conclusiones

La creación y evaluación del modelo de Vision Transformer para la clasificación de granos de café verde arábigo lojano ha demostrado una capacidad de discriminación alta, alcanzando una precisión global de 100 % en condiciones controladas y de 93 % en pruebas de generalización con condiciones variadas.

La adopción de la metodología CRISP-ML(Q), acompañada de la comparación inicial de los métodos de entrenamiento con los conjuntos de datos USK-Coffee y el propio de Loja, permitió una convergencia más rápida y estable del modelo. Asimismo, la optimización manual de hiperparámetros: épocas, tamaño de lote (batch size), tasa de aprendizaje (learning rate), dropout y optimizador resultó clave para refinar su desempeño, logrando precisiones de validación superiores al 98 % sin grandes oscilaciones entre las configuraciones evaluadas.

Estos hallazgos confirman el potencial de los Vision Transformers como herramienta de control de calidad

en la industria cafetalera de Loja. No obstante, la ligera disminución de precisión bajo condiciones menos ideales demuestra la existencia de un margen de mejora, donde se puede ampliar la diversidad del conjunto de datos, incorporar nuevas técnicas de aumento de datos y explorar esquemas de optimización de hiperparámetros. En consecuencia, esto podría fortalecer la capacidad de generalización y asegurar resultados igualmente robustos en escenarios menos controlados.

Agradecimientos

Extendemos nuestro agradecimiento a la Universidad Nacional de Loja y a la Carrera de Ingeniería en Computación por el apoyo y los recursos facilitados para este trabajo.

Rol de autores

- **Patricio Bolívar Betancourt Ludeña:** escritura – borrador original, diseño de software y curación de datos.
- **Oscar M. Cumbicus Pineda:** supervisión y validación.

Referencias

- [1] ICP. (2025) I-CIP retreats on news of looser supply, relieving some of the upward pressure. Coffee market report. International Coffee Organization. [Online]. Available: <https://upsalesiana.ec/ing35ar10r1>
- [2] Agricultura. (2025) 6425 hectáreas de café son renovadas en la provincia de Loja. Ministerio de Agricultura, Ganadería y Pesca. [Online]. Available: <https://upsalesiana.ec/ing35ar10r2>
- [3] M. Faisal, J.-S. Leu, and J. T. Darmawan, “Model selection of hybrid feature fusion for coffee leaf disease classification,” *IEEE Access*, vol. 11, pp. 62 281–62 291, 2023. [Online]. Available: <https://doi.org/10.1109/ACCESS.2023.3286935>
- [4] E. Hassan, “Enhancing coffee bean classification: a comparative analysis of pre-trained deep learning models,” *Neural Computing and Applications*, vol. 36, no. 16, pp. 9023–9052, Apr. 2024. [Online]. Available: <https://doi.org/10.1007/s00521-024-09623-z>
- [5] C.-H. Hsia, Y.-H. Lee, and C.-F. Lai, “An explainable and lightweight deep convolutional neural network for quality detection of green coffee beans,” *Applied Sciences*, vol. 12, no. 21, p. 10966, Oct. 2022. [Online]. Available: <https://doi.org/10.3390/app122110966>

- [6] S.-J. Chang and C.-Y. Huang, "Deep learning model for the inspection of coffee bean defects," *Applied Sciences*, vol. 11, no. 17, p. 8226, Sep. 2021. [Online]. Available: <https://doi.org/10.3390/app11178226>
- [7] A. Chavarro, D. Renza, and E. Moya-Albor, "Convnext as a basis for interpretability in coffee leaf rust classification," *Mathematics*, vol. 12, no. 17, p. 2668, Aug. 2024. [Online]. Available: <https://doi.org/10.3390/math12172668>
- [8] Y. A. Auliya, I. Fadah, Y. Baihaqi, and I. N. Awwaliyah, "Green bean classification: Fully convolutional neural network with Adam optimization," *Mathematical Modelling of Engineering Problems*, vol. 11, no. 6, pp. 1641–1648, Jun. 2024. [Online]. Available: <https://doi.org/10.18280/mmep.110626>
- [9] J. Maurício, I. Domingues, and J. Bernardino, "Comparing vision transformers and convolutional neural networks for image classification: A literature review," *Applied Sciences*, vol. 13, no. 9, p. 5521, Apr. 2023. [Online]. Available: <https://doi.org/10.3390/app13095521>
- [10] J. Wei, J. Chen, Y. Wang, H. Luo, and W. Li, "Improved deep learning image classification algorithm based on Swin Transformer V2," *PeerJ Computer Science*, vol. 9, p. e1665, Oct. 2023. [Online]. Available: <https://doi.org/10.7717/peerj-cs.1665>
- [11] S. Arwatchananukul, D. Xu, P. Charoenkwan, S. Aung Moon, and R. Saengrayap, "Implementing a deep learning model for defect classification in Thai Arabica green coffee beans," *Smart Agricultural Technology*, vol. 9, p. 100680, Dec. 2024. [Online]. Available: <https://doi.org/10.1016/j.atech.2024.100680>
- [12] W. Pinheiro Claro Gomes, L. Gonçalves, C. Barboza da Silva, and W. R. Melchert, "Application of multispectral imaging combined with machine learning models to discriminate special and traditional green coffee," *Computers and Electronics in Agriculture*, vol. 198, p. 107097, Jul. 2022. [Online]. Available: <https://doi.org/10.1016/j.compag.2022.107097>
- [13] M. N. Izza and G. P. Kusuma, "Image classification of Green Arabica Coffee using transformer-based architecture," *International Journal of Engineering Trends and Technology*, vol. 72, no. 6, pp. 304–314, Jun. 2024. [Online]. Available: <https://doi.org/10.14445/22315381/IJETT-V72I6P128>
- [14] H. F. Alhasson and S. S. Alharbi, "Classification of saudi coffee beans using a mobile application leveraging squeeze vision transformer technology," *Neural Computing and Applications*, vol. 37, no. 14, pp. 8629–8649, Feb. 2025. [Online]. Available: <https://doi.org/10.1007/s00521-025-11024-9>
- [15] Y. Jiao, Y. Zhao, A. Jia, T. Wang, J. Li, K. Xiang, H. Deng, M. He, R. Jiang, and Y. Zhang, "Swin-HSSAM: a green coffee bean grading method by swin transformer," *PLOS One*, vol. 20, no. 5, p. e0322198, May 2025. [Online]. Available: <https://doi.org/10.1371/JOURNAL.PONE.0322198>
- [16] J. H. L. Goh, E. Ang, S. Srinivasan, X. Lei, J. Loh, T. C. Quek, C. Xue, X. Xu, Y. Liu, C.-Y. Cheng, J. C. Rajapakse, and Y.-C. Tham, "Comparative analysis of vision transformers and conventional convolutional neural networks in detecting referable diabetic retinopathy," *Ophthalmology Science*, vol. 4, no. 6, p. 100552, Nov. 2024. [Online]. Available: <https://doi.org/10.1016/j.xops.2024.100552>
- [17] Z. Liu, H. Hu, Y. Lin, Z. Yao, Z. Xie, Y. Wei, J. Ning, Y. Cao, Z. Zhang, L. Dong, F. Wei, and B. Guo, "Swin Transformer V2: scaling up capacity and resolution," *arXiv*, 2021. [Online]. Available: <https://doi.org/10.48550/arXiv.2111.09883>
- [18] S. Studer, T. B. Bui, C. Drescher, A. Hanuschkin, L. Winkler, S. Peters, and K.-R. Müller, "Towards CRISP-ML(Q): a machine learning process model with quality assurance methodology," *Machine Learning and Knowledge Extraction*, vol. 3, no. 2, pp. 392–413, Apr. 2021. [Online]. Available: <https://doi.org/10.3390/make3020020>
- [19] A. Febriana, K. Muchtar, R. Dawood, and C.-Y. Lin, "USK-Coffee dataset: A multi-class green arabica coffee bean dataset for deep learning," in *2022 IEEE International Conference on Cybernetics and Computational Intelligence (CyberneticsCom)*. IEEE, Jun. 2022, pp. 469–473. [Online]. Available: <https://doi.org/10.1109/CyberneticsCom55287.2022.9865489>
- [20] Patricio Bolívar Betancourt Ludeña, "Lojano Arabica coffee," *Zenodo*, 2025. [Online]. Available: <https://doi.org/10.34740/kaggle/dsv/13947455>
- [21] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, "Grad-CAM: visual explanations from deep networks via gradient-based localization," *International Journal of Computer Vision*, vol. 128, no. 2, pp. 336–359, Oct. 2019. [Online]. Available: <http://dx.doi.org/10.1007/s11263-019-01228-7>

- [22] H. L. Gope and H. Fukai, “Peaberry and normal coffee bean classification using CNN, SVM, and KNN: their implementation in and the limitations of Raspberry Pi 3,” *AIMS Agriculture and Food*, vol. 7, no. 1, pp. 149–167, 2022. [Online]. Available: <https://doi.org/10.3934/agrfood.2022010>

NORMAS PARA PUBLICAR EN LA REVISTA INGENIUS

1. Información General

INGENIUS es una publicación científica de la Universidad Politécnica Salesiana de Ecuador, editada desde enero de 2007, con periodicidad fija semestral, especializada en Ingeniería Mecánica, Ingeniería Eléctrica, Electrónica, Ciencias de la Computación y su integración en lo que actualmente se conoce como Mecatrónica; estas líneas de acción fortalecen áreas como automatización, control, robótica entre otras.

Es una revista científica arbitrada, que utiliza el sistema de evaluación externa por expertos (*peer-review*), bajo metodología de pares ciegos (*double-blind review*), conforme a las normas de publicación del Institute of Electrical and Electronics Engineers (IEEE). El cumplimiento de este sistema permite garantizar a los autores un proceso de revisión objetivo, imparcial y transparente, lo que facilita a la publicación su inclusión en bases de datos, repositorios e indexaciones internacionales de referencia.

INGENIUS se encuentra indexada en la Red de Revistas Científicas de América Latina, el Caribe, España y Portugal – REDALYC, en Emerging Sources Citation Index, ESCI de Clarivate Analytics, en SciELO Ecuador, en el directorio y catálogo selectivo del Sistema Regional de Información en Línea para Revistas Científicas de América Latina, el Caribe, España y Portugal – Latindex, en el Directorio de Revistas de Acceso Abierto – DOAJ, en la Matriz de Información para el Análisis de Revistas – MIAR, en la Red Iberoamericana de Innovación y Conocimiento Científico – REDIB y en repositorios, bibliotecas y catálogos especializados de Iberoamérica.

La revista se edita en doble versión: impresa (ISSN: 1390-650X) y electrónica (e-ISSN: 1390-860X), en idioma español, siendo identificado además cada trabajo con un DOI (Digital Object Identifier System).

2. Alcance y Política

2.1. Temática

Contribuciones originales en materia de Ingeniería Mecánica, Ingeniería Eléctrica y Electrónica, Ciencias de la computación y su integración en lo que actualmente se conoce como Mecatrónica, así como áreas afines: Automatización, Control, Domótica, Robótica en sus diferentes ámbitos de acción y todas aquellas disciplinas conexas interdisciplinariamente con la línea temática central.

Podrán ser publicados todos los trabajos realizados por investigadores nacionales o extranjeros, una vez que cumplan los criterios de calidad científica requeridos.

2.2. Aportaciones

La revista INGENIUS publica preferentemente artículos relacionados con investigaciones empíricas, siendo también admisibles informes de desarrollo tecnológico, propuestas de modelos e innovaciones, productos de la elaboración de tesis de grado y posgrado siempre que sean un aporte para el campo de la ciencia y tecnología, así como selectas revisiones del estado del arte (*state-of-the-art*).

- **Investigaciones:** 4.000 a 6.500 palabras de texto, incluyendo título, resúmenes, palabras clave, tablas y referencias.
- **Informes, propuestas y productos:** 5.000 a 6.500 palabras de texto, incluyendo título, resúmenes, tablas y referencias.

- **Revisiones:** 6.000 a 7.000 palabras de texto, incluidas tablas y referencias. Se valora especialmente las referencias justificadas, actuales y selectivas de alrededor de unas 40 obras.

La revista INGENIUS publica trabajos originales e inéditos redactados en español e inglés, no pueden haber sido publicados a través de ningún medio impreso ni electrónico, ni estar en proceso de arbitraje o publicación.

Todo artículo será sometido a un riguroso proceso de arbitraje; la evaluación del artículo se hará conforme a criterios de originalidad, pertinencia, actualidad, aportes, rigurosidad científica y cumplimiento de las normas editoriales establecidas.

Por tratarse de una publicación arbitrada, el Consejo Editorial aprueba su publicación en base al concepto de pares especializados. La recepción de un documento no implica compromiso de publicación.

Es indispensable presentar una carta de presentación y cover letter que se puede descargar de: <https://goo.gl/xB0wE1>.

Las contribuciones deben ser enviadas única y exclusivamente a través del OJS (Open Journal System) <https://goo.gl/4xxjuo>, en el cual todos los autores deben registrarse como usuario previamente. Para cualquier consulta del procedimiento se debe contactar a:

revistaingenius@ups.edu.ec,
jcalles@ups.edu.ec ó
mquinde@ups.edu.ec.

Para favorecer la diversidad de las publicaciones, el/los autor(es) no podrán publicar más de un(1) artículo por cada número, ni tampoco en números consecutivos, para que el/los autor(es) puedan enviar nuevamente a Ingenius sus investigaciones, deberán haber transcurrido como mínimo 3 números publicados.

3. Presentación y estructura de los manuscritos

Para aquellos trabajos que se traten de investigaciones de carácter empírico, los manuscritos seguirán la estructura IMRDC (Introducción, Materiales y Métodos, Resultados y Discusión y Conclusiones), siendo opcionales los epígrafes de Notas y Apoyos. Aquellos trabajos que por el contrario se traten de informes, estudios, propuestas y revisiones podrán ser más flexibles en sus epígrafes, especialmente en Materiales y métodos, Resultados, y Discusión y Conclusiones. En todas las tipologías de trabajos son obligatorias las Referencias.

Los artículos pueden estar escritos sobre Microsoft Word (.doc o .docx) o L^AT_EX(.tex). La plantilla a ser utilizada puede ser descargada del sitio web de la revista, en formato de Microsoft Word en: <https://goo.gl/ZA2XAk>, mientras que para L^AT_EX en: <https://goo.gl/Mwv8IC>, es necesario que el archivo esté anonimizado en Propiedades de Archivo, de forma que no aparezca la identificación de autor/es.

Las Figuras, Gráficos y/o Ilustraciones, así como las Tablas deberán estar numeradas secuencialmente incluyendo una descripción explicativa para cada una. Las ecuaciones incluidas en el artículo deberán también estar numeradas; tanto las figuras, tablas y ecuaciones deben estar citadas en el texto.

Use espacio después de punto, comas y signos de interrogación.

Use “enter” al final de cada párrafo, título encabezamiento. No use “enter” en ningún otro lugar, deje al programa procesador de palabras romper automáticamente las líneas.

No centre encabezamientos o subencabezamientos ya que deben estar alineados a la izquierda.

Las Tablas deben estar creadas en el mismo programa usado para el cuerpo del documen-

to. Use tabuladores, no espacios, para crear columnas. Recuerde que el tamaño final de las páginas impresas será de 21 x 28 cm, por lo tanto las tablas deben estar diseñadas para ajustarse al espacio de la impresión final.

3.1. Estructura de los manuscritos

3.1.1. Presentación y Cover Letter

1. **Título (español) / Title (inglés):** Conciso pero informativo, en castellano en primera línea y en inglés en segunda, cuando el artículo sea escrito en español y viceversa si está escrito en inglés.
2. **Autores y adscripción:** Nombre y Apellidos completo de cada autor, organizados por orden de prelación y su adscripción institucional con referencia al final de la primera hoja, donde tiene que incluir: Dependencia e Institución a la que pertenece, país, ORCID. Se aceptarán como máximo 5 autores, aunque pudieran existir excepciones justificadas por la complejidad y extensión del tema.
3. **Resumen (español) / Abstract (inglés):** Tendrá como extensión máxima 230 palabras, en español y en inglés. En el resumen se describirá de forma concisa y en este orden: 1) Justificación del tema; 2) Objetivos; 3) Metodología y muestra; 4) Principales resultados; 5) Principales conclusiones.
4. **Palabras clave (español) / Keywords (inglés):** Se deben exponer 6 palabras clave por cada versión idiomática relacionados directamente con el tema del trabajo. Será valorado positivamente el uso de las palabras claves expuestas en el Thesaurus de la UNESCO.
5. **Presentación (Cover Letter):** Una declaración de que el manuscrito se trata de una aportación original, no enviada ni en proceso de evaluación en otra revista, con la confirmación de las autorías firman-

tes, aceptación (si procede) de cambios formales en el manuscrito conforme a las normas y cesión parcial de derechos a la editorial, según el formato establecido en: <https://goo.gl/XAc9a3>.

3.1.2. Manuscrito

1. **Título (español) / Title (inglés):** Conciso pero informativo, en castellano en primera línea y en inglés en segunda, cuando el artículo sea escrito en español y viceversa si está escrito en inglés.
2. **Autores y adscripción:** Nombre y Apellidos completo de cada autor, organizados por orden de prelación y su adscripción institucional con referencia al final de la primera hoja, donde tiene que incluir: Dependencia a la que pertenece, Institución a la que pertenece, país, ORCID. Se aceptarán como máximo 5 autores, aunque pudieran existir excepciones justificadas por la complejidad y extensión del tema.
3. **Resumen (español) / Abstract (inglés):** Tendrá como extensión máxima 230 palabras, en español y en inglés. En el resumen se describirá de forma concisa y en este orden: 1) Justificación del tema; 2) Objetivos; 3) Metodología y muestra; 4) Principales resultados; 5) Principales conclusiones.
4. **Palabras clave (español) / Keywords (inglés):** Se deben exponer 6 palabras clave por cada versión idiomática relacionados directamente con el tema del trabajo. Será valorado positivamente el uso de las palabras claves expuestas en el Thesaurus de la UNESCO.
5. **Introducción:** Debe incluir el planteamiento del problema, el contexto de la problemática, la justificación, fundamentos y propósito del estudio, utilizando citas bibliográficas, así como la literatu-

ra más significativa y actual del tema a escala nacional e internacional.

6. **Materiales y métodos:** Debe ser redactado de forma que el lector pueda comprender con facilidad el desarrollo de la investigación. En su caso, describirá la metodología, la muestra y la forma de muestreo, así como se hará referencia al tipo de análisis estadístico empleado. Si se trata de una metodología original, es necesario exponer las razones que han conducido a su empleo y describir sus posibles limitaciones.
7. **Análisis y resultados:** Se procurará resaltar las observaciones más importantes, describiéndose, sin hacer juicios de valor, el material y métodos empleados. Deberán aparecer en una secuencia lógica en el texto y las tablas y figuras imprescindibles evitando la duplicidad de datos.
8. **Discusión y Conclusiones:** Resumirá los hallazgos más importantes, relacionando las propias observaciones con estudios de interés, señalando aportaciones y limitaciones, sin redundar datos ya comentados en otros apartados. Asimismo, debe incluir las deducciones y líneas para futuras investigaciones.
9. **Apoyos y agradecimientos (opcionales):** El Council Science Editors recomienda al autor/es especificar la fuente de financiación de la investigación. Se considerarán prioritarios los trabajos con aval de proyectos competitivos nacionales e internacionales.
10. **Las notas (opcionales):** Se deberán incluir solo en caso necesario, al final del artículo (antes de las referencias). Deben anotarse manualmente, ya que el sistema de notas al pie o al final de Word no es reconocido por los sistemas de maquetación. Los números de notas se colocan en

superíndice, tanto en el texto como en la nota final. No se permiten notas que recojan citas bibliográficas simples (sin comentarios), pues éstas deben ir en las referencias.

11. **Referencias Bibliográficas:** Las citas bibliográficas deben reseñarse en forma de referencias al texto. Bajo ningún caso deben incluirse referencias no citadas en el texto. Su número debe ser suficiente para contextualizar el marco teórico con criterios de actualidad e importancia. Se presentarán secuencialmente en orden de aparición, según corresponda siguiendo el formato de la IEEE.

3.2. Normas para las referencias Bibliográficas

Artículos de revistas:

- [1] J. Riess, J. J. Abbas, “Adaptive control of cyclic movements as muscles fatigue using functional neuromuscular stimulation”. IEEE Trans. Neural Syst. Rehabil. Eng vol. 9, pp.326–330, 2001. [Online]. Available: <https://doi.org/10.1109/7333.948462>

Libros:

- [1] G. O. Young, “Synthetic structure of industrial plastics” in *Plastics*, 2nd ed., vol. 3, J. Peters, Ed. New York: McGraw–Hill, 1964, pp. 15–64.

Reportes Técnicos:

- [1] M. A. Brusberg and E. N. Clark, “Installation, operation, and data evaluation of an oblique–incidence ionosphere sounder system,” in “Radio Propagation Characteristics of the Washington–Honolulu Path,” Stanford Res. Inst., Stanford, CA, Contract NOBSR–87615, Final Rep., Feb. 1995, vol. 1

Artículos presentados en conferencias (No publicados):

- [1] Vázquez, Rolando, Presentación curso

“Realidad Virtual”. National Instruments. Colombia, 2009.

Artículos de Memorias de Conferencias (Publicados):

- [1] L. I. Ruiz, A. García, J. García, G. Taiboa. “Criterios para la optimización de sistemas eléctricos en refinerías de la industria petrolera: influencia y análisis en el equipo eléctrico,” IEEE CONCAPAN XXVIII, Guatemala 2008.

Tesis:

- [1] L.M. Moreno, “Computación paralela y entornos heterogéneos,” Tesis doctoral, Dep. Estadística, Investigación Operativa y Computación, Universidad de La Laguna, La Laguna, 2005.

Estándares:

- [1] IEEE Guide for Application of Power Apparatus Bushings, IEEE Standard C57.19.100–1995, Aug. 1995.

Patentes:

- [1] J. P. Wilkinson, “Nonlinear resonant circuit devices,” U.S. Patent 3 624 125, July 16, 1990.

Manuales:

- [1] Motorola Semiconductor Data Manual, Motorola Semiconductor Products Inc., Phoenix, AZ, 1989.

Recursos de internet:

- [1] E. H. Miller, “A note on reflector arrays” [Online]. Available: <https://goo.gl/4cJkCF>

3.3. Epígrafes, tablas y figuras

Los epígrafes del cuerpo del artículo se deben numerar en arábigo. Irán sin caja completa de mayúsculas, ni subrayados, ni negritas. La numeración ha de ser como máximo de tres niveles: 1. / 1.1. / 1.1.1. Al final de cada epígrafe numerado se dará un enter para continuar con el párrafo correspondiente.

Las tablas deben presentarse incluidas en el texto según orden de aparición, numeradas

en arábigo y subtituladas con la descripción del contenido, el subtítulo debe ir en la parte superior de la tabla justificado a la izquierda.

Las figuras pueden ser dibujos lineales, mapas o fotografías de medios tonos en blanco y negro o a color en resolución de 300 dpi. No combine fotografías y dibujos lineales en la misma figura.

Diseñe las figuras para que se ajusten eventualmente al tamaño final de la revista 21 x 28 cm. Asegúrese de que las inscripciones o detalles, así como las líneas, tengan tamaños y grosores adecuados de tal manera que no queden ilegibles cuando sean reducidos a su tamaño final (números, letras y símbolos deben ser reducidos al menos a 2,5 mm de altura después que las ilustraciones han sido reducidas para ajustarse a la página impresa). Idealmente, las ilustraciones lineales deben ser preparadas a aproximadamente un cuarto de su tamaño final de publicación. Diferentes elementos en la misma figura deben ser deletreados a, b, c, etc.

Las fotografías deben grabarse con alto contraste y en alta resolución. Recuerde que las fotografías frecuentemente pierden contraste en el proceso de impresión.

Dibujos lineales y mapas deben ser preparados en color negro.

El texto de las figuras y mapas debe escribirse con letras fácilmente legibles.

Si las figuras han sido previamente usadas, es de responsabilidad del autor obtener el permiso correspondiente para evitar problemas posteriores relacionados con los derechos de autor.

Cada figura debe ser entregada en un archivo aparte, ya sea como mapa de bits (.jpg, .bmp, .gif, o .png) o como gráfico vectorial (.eps, .pdf).

4. Proceso de envío

El envío será a través de la plataforma OJS de la revista, <<https://goo.gl/4xxjuo>>, si

el envío se lo realiza en formato Word, se deberá cargar, como archivo original el manuscrito en .doc o .docx, con los datos del autor/es y su adscripción institucional; si el envío se lo realiza en formato latex deberá cargar como archivo original el pdf; además de la presentación y cover letter de acuerdo a lo antes descrito; también se deben cargar las figuras numeradas de acuerdo a lo correspondiente en el manuscrito (como mapa de bits .jpg, .bmp, .gif, o .png o como gráfico vectorial .ps, .eps, .pdf), en calidad como mínima de 300 dpi y para el caso del formato latex un archivo comprimido con el código fuente del mismo.

Es obligatorio que todos los autores ingresen la información requerida en la plataforma OJS al momento de enviar un manuscrito y uno solo de los autores será el responsable de correspondencia.

Una vez enviada la contribución el sistema automáticamente enviará al autor para correspondencia un mail de confirmación de recepción de la contribución.

5. Proceso Editorial

Una vez que el manuscrito ha sido aceptado en OJS se realiza una primera comprobación de los siguientes puntos:

- La temática se encuentre en concordancia con los criterios de la revista.
- Debe tener la estructura IMRDC, y seguir el formato de INGENIUS.
- Debe utilizar la forma de citación de la IEEE.
- Todas las referencias bibliográficas deben estar citadas en el texto del manuscrito al igual que las tablas, figuras y ecuaciones.
- El manuscrito es original, para esto se utiliza un software para determinar plagio.

Si alguno de los puntos anteriores no está completo o existe inconsistencia, se solicitará al autor las correcciones correspondientes, una vez que el autor modifique el artículo deberá re-

mitir a través de la plataforma OJS. El equipo editorial verificará que las correcciones solicitadas han sido incorporadas, si cumple, el manuscrito iniciará la segunda parte del proceso y podrá ser seguido por el autor a través de OJS, caso contrario se notificará al autor y se archivará el manuscrito.

La segunda fase del proceso consiste en la evaluación bajo la metodología de pares ciegos (doble-blind review), en los que se incluyen expertos nacionales y extranjeros considerando los siguientes pasos:

- El editor asigna dos o más revisores para el artículo.
- Una vez revisado el artículo, los revisores remitirán el informe de la evaluación, con uno de los siguientes resultados.
 - Publicable
 - Publicable con cambios sugeridos
 - Publicable con cambios obligatorios
 - No Publicable
- El editor una vez recibida la evaluación por parte de los revisores analizará los resultados y determinará si el artículo es aceptado o negado.
- Si el artículo es aceptado se notificará al autor para que realice las correcciones en caso de ser requeridas.
- Si el artículo es negado se notificará al autor y se archivará el manuscrito.
- En los dos casos anteriores se enviará el resultado de la evaluación de los revisores y sus respectivas recomendaciones.

La segunda fase del proceso dura 4 semanas como mínimo, luego de transcurridas las mismas se notificará al autor dando instrucciones para continuar con el proceso.

6. Publicación

La revista INGENIUS publica dos números por año, el 1° de enero y el 1° de julio por lo tanto es importante considerar las fechas para el envío de los artículos y su correspondiente publicación. Los artículos recibidos hasta el mes de octubre serán considerados para la publicación de enero y aquellos que se reciban hasta abril para la publicación de julio.

7. Información sobre el uso de Inteligencia Artificial

En caso de que se utilice inteligencia artificial en cualquier etapa de la investigación presentada en el artículo, se requerirá a los/as autores/as destacarlo claramente en la carta de

presentación/coverletter asociado al artículo, manifestando la sección o secciones específicas donde se ha hecho uso de la inteligencia artificial. Esta indicación tiene como objetivo informar a los lectores sobre las secciones en las que se ha empleado esta tecnología, proporcionando una mayor transparencia y comprensión sobre su aplicación en la investigación presentada.

INGENUS, Revista de Ciencia y Tecnología, reconoce la importancia de mantener altos estándares éticos en la investigación científica, particularmente en el empleo de inteligencia artificial (IA).

Queda a discreción del equipo editorial, la aceptación de la publicación que haya utilizado inteligencia artificial.

UNIVERSIDAD POLITÉCNICA SALESIANA DEL ECUADOR

Juan Cárdenas Tapia, sdb

Rector

©Universidad Politécnica Salesiana

Turuhuayco 3-69 y Calle Vieja

Casilla postal 2074

Cuenca, Ecuador

Teléfono: (+593 7) 205 00 00

Fax: (+593 7) 408 89 58

Correo electrónico: srector@ups.edu.ec

CANJE

Se acepta canje con otras publicaciones periódicas.

Dirigirse a:

Secretaría Técnica de Comunicación

Universidad Politécnica Salesiana

Turuhuayco 3-69 y Calle Vieja

Casilla postal 2074

Cuenca, Ecuador

Teléfono: (+593 7) 205 00 00 Ext. 1182

Fax: (+593 7) 408 89 58

Correo electrónico: rpublicas@ups.edu.ec

www.ups.edu.ec

Cuenca – Ecuador

INGENIUS, Revista de Ciencia y Tecnología,

Número 35

enero/junio 2026

John Calle Siguencia, PhD, Editor Jefe

revistaingenius@ups.edu.ec

Impresión

Centro Gráfico Salesiano: Antonio Vega Muñoz 10-68 y General Torres.

Teléfono: (+593 7) 283 17 45

Cuenca – Ecuador

Correo electrónico: centrograficosalesiano@lms.com.ec

OTRAS PUBLICACIONES PERIÓDICAS DE LA UNIVERSIDAD

UNIVERSITAS, Revista de Ciencias Sociales y Humanas.

LA GRANJA, Revista de Ciencias de la Vida.

ALTERIDAD, Revista de Educación.

RETOS, Revista de Ciencias de la Administración y Economía.

UTOPIÍA, Revista de Pastoral Juvenil Universitaria.

SOPHIA, Colección de Filosofía de la Educación.



**ABYA
YALA** | UNIVERSIDAD
POLITÉCNICA
SALESIANA

