



Educación

Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO



TECNOLÓGICO NACIONAL DE MÉXICO
INSTITUTO TECNOLÓGICO DE APIZACO

INVESTIGACIÓN, DESARROLLO E INNOVACIÓN EN LA INGENIERÍA



www.apizaco.tecnm.mx

(IDII)
Volumen 2, No.1
enero-junio 2026

INVESTIGACIÓN, DESARROLLO E INNOVACIÓN EN LA INGENIERÍA
(IDII)

Volumen 2, No.1, enero-junio 2026

ISSN: En Trámite

<https://revista.apizaco.tecnm.mx/ojs/index.php/IDII/index>

Tecnológico Nacional de México/Instituto Tecnológico de Apizaco

INVESTIGACIÓN, DESARROLLO E INNOVACIÓN EN LA INGENIERÍA, es un órgano de divulgación científica que se publica de forma semestral editada por el Tecnológico Nacional de México/Instituto Tecnológico de Apizaco. <https://www.apizaco.tecnm.mx/> Av. *Instituto Tecnológico* No. 418, San Andrés Ahuashuatepec, Municipio de Tzompantepec, Tlaxcala, Méx. C.P. 90491. Correo: revista@apizaco.tecnm.mx

El contenido y la sintaxis de los artículos presentados son responsabilidad del autor(es). Queda prohibida la reproducción parcial o total del contenido e imágenes de esta publicación en cualquier medio, sin previa autorización por escrito del Tecnológico Nacional de México/Instituto Tecnológico de Apizaco.

DIRECTORIO

Dr. Ramón Jiménez López

Director General del Tecnológico Nacional de México

Dra. Yesica Imelda Saavedra Benítez

Directora

Mtro. Enrique Acoltzi Bautista

Subdirector Académico

Mtra. Luz Fabiola Sánchez Parra

Subdirectora de Planeación y Vinculación

Mtro. Cesar Reynaldo Gómez

Subdirector de Servicios Administrativos

Dr. Juan Ramos Ramos

Jefe de la División de Estudios de Posgrado e Investigación

COMITÉ EDITORIAL

Editor en Jefe

Dr. Roberto Morales Caporal

Coeditores

Dr. Raúl Cortés Maldonado

Dra. Raquel Ramírez Amador

Dra. Blanca Estela Pedroza Méndez

Dr. Carlos Bueno Avendaño

Dra. Haydee Patricia Martínez Hernández

Diseño y Fotografía

Lic. Jorge Vázquez Muñoz

Fco. Javier Guadalupe Díaz López

Formación

Mtro. Néstor Gutiérrez Merino

COMITÉ REVISOR

Dr. Jorge Bedolla Hernández
Dr. Rafael Ordoñez Flores
Dra. María Guadalupe Medina Barrera
Dr. Carlos Alberto Mora Santos
Dr. José Federico Ramírez Cruz
Dr. Jorge Luis Castañeda Gutiérrez
Dr. Alan Augusto Gallegos Cuellar
Dr. José Federico Casco Vázquez
Dra. Yesenia Nohemi González Meneses
Dr. Rodolfo Eleazar Pérez Loaiza
Dr. Perfecto Malaquías Quintero Flores
Dr. Antonio Solís Lima
Dr. José Juan Hernández Mora
Dr. Marcos Bedolla Hernández
Dr. José Crispín Hernández Hernández
Dr. Juan Ramos Ramos
Dr. Omar Sandre Hernández
Mtra. María Janai Sánchez Hernández
Mtro. Mario Eduardo Leal López
Mtro. Carlos Pérez Corona
Mtra. Elizabeth Cuatecontzi Cuahutle
Mtro. Eduardo Sánchez Lucero

ÍNDICE

Artículo	pag.
1. Análisis Genético en Objetos de Aprendizaje: La Enseñanza Personalizada del Álgebra	1
2. Implementación de Modelo de Lenguaje Multilingüe para Traducción Automática Bidireccional entre Español y Náhuatl	12
3. Método Híbrido Kendall–Kolmogorov–Smirnov para la Selección de Características Orientada a la Evaluación Automática de la Calidad del Durazno	17
4. Modelado Comparativo de Inferencia Difusa para la Estimación del Dwell Time en el Transporte para Personas con Movilidad Limitada	24
5. Impacto de la Ciencia de Datos y Blockchain en la Trazabilidad y la Prevención del Fraude en la Cadena de Suministro Agroalimentaria	34
6. Visualizando la Toma de Decisiones de una Red Convolucional Mediante Mapeo de Activación de Clases Ponderado por Gradiente	40
7. Space Vector Modulation for Feeding AC Motor Drives Using STM32F446RE Microcontroller	45

Fecha de recepción: 06 de marzo de 2026, fecha de publicación en línea: junio de 2026.

Análisis Genético en Objetos de Aprendizaje: La Enseñanza Personalizada del Álgebra

Moisés Ramírez Bonilla, Yesenia Nohemí González Meneses, José Federico Ramírez Cruz, y Blanca Estela Pedroza Méndez

Tecnológico Nacional de México-Instituto Tecnológico de Apizaco. San Andrés Ahuashuatepec, Municipio de Tzompantepec, Tlaxcala, C.P. 90491, México.

Autor de correspondencia: Moisés Ramírez Bonilla (correo electrónico: moisesramireznb@gmail.com)

Abstract. This article presents a specific overview of algebra learning among students at the National Technological Institute of Mexico, Apizaco Technological Institute, analyzing the main difficulties in achieving accreditation in different algebra-related subjects. It also presents a detailed analysis of the software used in classroom sessions to strengthen student learning. Finally, it presents a genetic analysis of performance on monomial exercises solved using a learning object called "Components of Mixed Monomials," employing a focused genetic algorithm to identify error patterns and propose personalized recommendations to students. The responses to 200 exercises were analyzed, identifying that fractional coefficients accounted for 49.5% of the total errors. The genetic algorithm achieved an accuracy of 85.62% in predicting success, selecting 8 out of 12 characteristics as critical. The research findings demonstrate that time management and the handling of fractional coefficients are the most determining factors in the performance of this learning object.

Keywords: Mathematics education, monomials, personalized learning, educational data mining, genetic algorithms.

I. INTRODUCCIÓN

El contexto áulico de las matemáticas como un espacio dinámico, donde se organiza el aprendizaje influenciado notablemente por las características del estudiante y el contexto donde este se desarrolla [1], fue durante muchos años la repetición de algoritmos para resolver ejercicios; destacando los principios fundamentales de las matemáticas: manipular, expresar y abstraer. La presente investigación muestra los resultados de tres ejercicios de análisis de información y recopilación de datos: dificultades de aprobación, usabilidad de software y análisis de objeto de aprendizaje, con la finalidad de conocer la realidad en el entorno de la enseñanza del álgebra.

La enseñanza de las matemáticas en ocasiones fue condicionada y estereotipada en el proceso de pizarrón-cuaderno-examen, está sujeta a métodos tradicionales; el docente con un rol activo que transmite conocimientos mediante clases magistrales, resolución de ejercicios o uso de memorización y repetición de problemas dirigidos a estudiantes con un rol pasivo: observando, escuchando y memorizando, mayormente en busca de un resultado infalible, cuando no es siempre lo más importante ni el único objetivo en la enseñanza. Este contexto áulico tradicional no siempre considera el fortalecimiento de la identidad personal y la cultura del estudiante, el desarrollo integral de su personalidad, la regulación de sus emociones y el

incremento de sus habilidades blandas; colaboración, empatía, liderazgo, adaptación, resolución de dificultades y conflictos, cuidado de su salud física, mental y social [2], entre muchos otros objetivos inherentes a la docencia como lo es: la ética, la integridad, la responsabilidad, la imparcialidad y el respeto.

El estudiante universitario enfrenta distintos retos académicos que debe resolver, por lo que debe emplear sus conocimientos, habilidades blandas, madurez metacognitiva y sus estilos predilectos de aprendizaje. Sin embargo, cuando el estudiante fracasa no siempre es claro donde se localiza determinada debilidad y no conoce si ésta es acerca de contenidos y su dominio, de sus habilidades blandas, de su zona de desarrollo próximo o de su madurez metacognitiva, por ello, el estudiante entra en un estado de vulnerabilidad académica, por lo que, según las estadísticas se presenta el fracaso o deserción académica. Según la Secretaría de Educación Pública en México descendió a 8.1% la tasa de abandono escolar en Educación Superior en el ciclo escolar 2021-2022, representando una disminución en comparación con el ciclo escolar 2020-2021 que fue del 8.8%. El abandono escolar ha variado, en el ciclo 2022-2023 fue del 7.2% y en el 2020-2021, el más alto registrado, en 8.8% (posiblemente influenciado por el COVID-19) [43];[44], sin embargo, estas cifras no revelan los fenómenos relacionados con dificultades internas en el

ambiente áulico, tales como asimilación de contenidos, dificultades de aprendizaje y habilidades blandas.

A. Planteamiento del Problema

Esta investigación se llevó a cabo con estudiantes del Tecnológico Nacional de México campus Apizaco en las asignaturas de: cálculo diferencial, cálculo integral, álgebra lineal y cálculo vectorial durante el ciclo escolar 2023, grupos mixtos de entre 21 a 39 estudiantes. Se registraron los resultados de 1510 evaluaciones de unidad, de los cuales se focalizó una muestra de alumnos con dificultades de aprobación; 371 de ellos no lograron aprobar la unidad correspondiente, la figura 1. Diagrama de dificultades, presenta los tres principales motivos, El primero acerca de (C) comprensión de los contenidos, 202 alumnos asumen que no comprendieron los contenidos planteados y las sesiones áulicas y que los recursos proporcionados no estuvieron aproximados a resolver sus dudas e inquietudes acerca del tema o temas vistos. El segundo acerca de (A) adaptación al estilo de aprendizaje, 162 alumnos no siempre identifican el estilo favorable para ellos; teórico, activo o reflexivo, destacando que entre los estilos se les presenta una mayor dificultad en los procesos donde requiere reflexionar acerca de lo que se debe ejecutar, y el tercero, (H) situaciones relacionadas con sus habilidades blandas, 226 alumnos consideran tener dificultades en sus habilidades, es decir, en su autodeterminación, responsabilidad, puntualidad, asistencia, comunicación entre pares, gestión de tiempo, gestión de estrés, pensamiento crítico, entre otras:




Figura 1. Dificultades de aprendizaje

De tal forma, se puede realizar un análisis acerca del comportamiento de estos datos, como se muestra en la Figura 1, de los 371 alumnos reprobados: 60 de ellos, es decir el 16.17% presentan dificultad en los tres factores observados, 58 alumnos, ósea un 15.63% presentan únicamente dificultad en la comprensión de contenidos, 65 de ellos, es decir el 17.52% su reprobación es explicada desde la no adaptación a los estilos de aprendizaje y el 23.99% de los alumnos, es decir 89 de los reprobados lo atribuyen a sus habilidades blandas, o bien, los casos

localizados que presentan dos o las tres dificultades como se presenta en la Tabla I:

Tabla I. Casos en intersecciones

Cantidad de Casos	Intersección de Dificultades
22	Dificultad en Adaptación al estilo de aprendizaje Y Comprensión de contenidos.
15	Dificultad en Adaptación al estilo de aprendizaje Y Habilidades Blandas.
62	Dificultad en Comprensión de contenidos Y Habilidades Blandas.
60	Dificultad en Adaptación al estilo, Comprensión de contenidos, y Habilidades Blandas.

La presuposición de los datos indica que, en el caso de la intersección mayor, con 62 casos la dificultad en comprensión de contenidos y habilidades blandas se presentan a menudo de manera conjunta, además una gran cantidad de estudiantes presentan un patrón de dificultades complejas con 60 casos.

Respecto a las probabilidades de ocurrencia específicas, los datos ayudan a determinar la probabilidad de que un alumno presente una dificultad independientemente de las otras, como se observa en la Tabla II, es más probable que un alumno con dificultades presente problemas con sus habilidades blandas.

Tabla II. Independencia de probabilidades

Dificultad (Evento E)	Casos Favorables (NE)	Cálculo de P(E)	Probabilidad (Aprox.)
Adaptación al estilo (A)	65+22+60+15=162	P(A)=162/371	43.66%
Comprensión de contenidos (C)	58+22+60+62=202	P(C)=202/371	54.45%
Habilidades Blandas (H)	89+15+60+62=226	P(H)=226/371	60.92%

Observando la probabilidad de que un alumno tenga dificultades de Habilidades Blandas (H) dado que ya tiene dificultades de Comprensión de contenidos (C):

- ✓ Evento F: El caso tiene dificultades de Comprensión de contenidos (P(C) = 202/371).
- ✓ Evento E: El caso tiene dificultades de Habilidades Blandas.
- ✓ Intersección (E∩F): El caso tiene ambas dificultades (P(C ∩ H) = 122/371).

$$P(H|C) = \frac{P(C \cap H)}{p(C)} = \frac{122/371}{202/371} = 0.6040 \quad (1)$$

De tal forma, se identifica que un estudiante con dificultades de Comprensión de contenidos tiene una probabilidad del 60.40% de que también tenga dificultades de Habilidades Blandas. Analizando la probabilidad exclusiva de dificultades:

$$P(\text{Solo } H) = \frac{89}{371} = 0.2399 \quad (2)$$

$$P(\text{Solo UNA}) = \frac{65+58+89}{371} = 0.5714 \quad (3)$$

Es así como podemos establecer el criterio que es más probable que un alumno presente dificultades con las habilidades blandas que con la adaptación al estilo o la comprensión de contenidos.

A manera de cierre, en todos los niveles de la educación formal en el país; los contenidos, objetos de aprendizaje, procesos de desarrollo y aprendizaje, las estrategias, técnicas para la enseñanza y aprendizaje, así como las secuencias didácticas están subordinadas a la mediación de un experto con base en la información que proporcionan instrumentos de medición: diagnóstica, de estilos de aprendizaje, de conocimientos previos y de habilidades concretas adquiridas, ya sean disciplinares, blandas o genéricas, aun cuando se trata de sistemas tutoriales inteligentes, se requiere la opinión de expertos en la disciplina educativa para seleccionar los objetos de aprendizaje adecuados para el proceso de desarrollo, estos objetos acordes a las características del estudiante y pertinentes a su zona de desarrollo próximo. En los siguientes capítulos se aborda lo referente el uso de software y su desarrollo con base en esta personalización de objetos.

II. MARCO TEÓRICO

A. Las Zonas de Desarrollo próximo en los Estudiantes Universitarios.

Algunos estudios recientes han destacado la relevancia de la ZDP para el aprendizaje potencial de los estudiantes universitarios. Un estudio que abordó el rendimiento de los estudiantes en actividades prácticas encontró que el andamiaje, recibir atención particular del profesor, y el esfuerzo conjunto de la enseñanza integrada junto con la acción de un compañero entrenado son más efectivos para alcanzar la ZDP que el simple empleo del andamiaje en la enseñanza [10]. Esto refuerza el valor de la retroalimentación y el enfoque guiado hacia la educación.

Además, el aprendizaje colaborativo electrónico (e-Collaborative learning), ha sido estudiado para promover la ZDP de Vygotsky en los estudiantes a nivel universitario, sin embargo no necesariamente garantiza la calidad del aprendizaje, destacando la importancia de un diseño instruccional bien pensado que fomente interacciones efectivas [16]. El concepto de tareas genuinamente interrelacionadas en lugar de simples agrupaciones de mini-tareas es un concepto importante al contextualizar el aprendizaje colaborativo a una ZDP grupal, particularmente en entornos virtuales [22].

Las consideraciones teóricas con la ZDP todavía están bajo un intenso escrutinio. Por ejemplo, se compara con la idea de Barbara Rogoff sobre la participación guiada, y el aprendizaje situado de Lave y Wenger como desarrollos

particulares que podrían expandir la comprensión del enfoque sociocultural en la psicología educativa [7]. La teoría Vygotskiana también ha inspirado la pedagogía como en la educación musical de Karl Orff, cuyas técnicas pedagógicas muestran cómo la ZDP se ha aplicado al pensamiento sobre el contexto sociocultural, el desarrollo del lenguaje y el juego como una herramienta lúdica y creativa [20].

La ZDP también está implicada en la comprensión y tratamiento de la dependencia emocional, en la medida en que la activación de la ZDP y la conceptualización del entorno socialmente construido de desarrollo, regulado por actividades socioculturales, son claves para la prevención y el control [9]. En la educación virtual, conceptos Vygotskiana como la mediación, ZDP y el andamiaje son asuntos epistemológicos de referencia para las prácticas pedagógicas [18].

B. Estilos de Aprendizaje

Actualmente, es más esencial investigar los estilos de aprendizaje de los estudiantes en entornos de educación superior debido a cómo los estudiantes perciben, procesan y construyen conocimiento, ya que esto representa el tema más importante y urgente. Esto también está directa e inversamente asociado a si el aprendizaje está más centrado en el logro y la adaptación académicos (Benavente Tónel, 2013; [4]; [8].

Estos enfoques son clínicamente relevantes para planificar estrategias y metodologías que aborden la variedad de estilos de aprendizaje de estos estudiantes y fomenten una educación superior de calidad. Por lo tanto, presentan alguna posibilidad de evitar la deserción escolar temprana en la educación vocacional [4]; [8].

Están disponibles varios modelos o instrumentos que se han desarrollado para describir y categorizar los estilos de aprendizaje en estudiantes universitarios. Las obras de referencia son:

- ✓ Modelo de cerebro completo de Herrmann [20].
- ✓ Inventario de estilos de aprendizaje (LSI) [4].
- ✓ Cuestionario de Honey-Alonso de estilos de aprendizaje (CHAEA) [1]; [5]; [6]; [12]; [14]; [25].
- ✓ Modelo Felder-Silverman (Gutiérrez-Espinoza et al., 2023).
- ✓ Test VAK [18]

También podemos perfilar la aplicación del estilo de aprendizaje de los estudiantes en otras facultades y campos de estudio usando estos instrumentos. En relación con el aprendizaje reflexivo, este método se encontró especialmente en espacios pedagógicos virtuales [1]; [2]; [6]; [12].

También fue el estilo que prevaleció [2]. "Al final, (los estudiantes de primer año) simplemente pueden estar interesados en tener algo más dinámico, y que el profesor trabaje más para ofrecer algo, es solo que lo encuentran más vivo y cercano a la realidad".

También hay evidencia de que los recursos educativos abiertos desarrollados para estilos de aprendizaje específicos (p. ej., los de Honey y Mumford) pueden motivar más a los estudiantes o ayudar a tener una mejor comprensión del contenido estudiado [5]. Además, algunas investigaciones han considerado estrategias de enseñanza basadas en la educación que apoyan la comprensión de conocimientos complejos como el pensamiento lógico-matemático en consonancia con los estilos de aprendizaje del receptor y mediante el aprendizaje basado en problemas, el uso de tecnología o tomando en cuenta las estrategias de aprendizaje activo [11].

C. Habilidades Blandas en el Contexto Universitario

Por el momento, en un cambio agitado y movimiento acelerado hacia prácticas como la Industria 4.0, la educación completa de los estudiantes es esencial, especialmente con la aplicación de la tecnología [17]; [26]. Ya no se trata solo de conocimiento técnico (habilidades duras) y se lleva a cabo a nivel sistémico, abarcando valores, habilidades y particularmente habilidades blandas. Ahora la inteligencia emocional ocupa un lugar preponderante junto al desarrollo de habilidades sociales [24], que están siendo cada vez más importantes para un correcto desempeño y mayor adaptación académica y desempeño en el mercado laboral [18];[19].

Para dar respuesta positiva a estos desafíos, a las Instituciones de Educación Superior (IES) se les ha instado a reformular sus paradigmas educativos debido a "la educación actual considera preponderante el enfoque educativo centrado en el estudiante" [21], con el fin de apoyar estas competencias clave. Respecto a LOS Efectos en el Aprendizaje: La evidencia muestra una fuerte relación entre las habilidades blandas que el estudiante es capaz de desarrollar respecto al éxito en la escuela debido a ellas. Por ejemplo, [15] se encontró que un programa de refuerzo de habilidades blandas tendrá un efecto positivo en el aprendizaje de conocimientos en estudiantes universitarios. También tiene una influencia positiva en su aprendizaje conceptual, procedimental y actitudinal en la escuela secundaria [17]. Además, el pensamiento crítico está positivamente vinculado con el desempeño académico en la universidad, aunque esta conexión puede estar influenciada por la disciplina y el tipo de evaluación (Enríquez Canto et al., 2021). Estas habilidades blandas enlazan la condición emocional del aprendiz, que está media regulada a través de estas habilidades blandas, con la disposición para aprender [23].

El desarrollo de habilidades blandas también circunscribe la investigación formativa e implicaciones para la empleabilidad, las habilidades blandas son esenciales no solo para aprender el contenido, sino también para abordar desafíos académicos complejos como la investigación formativa. Por ejemplo, las personas con habilidades blandas de orden superior (es decir, liderazgo, trabajo en equipo, resolución de problemas, etc.) pueden beneficiarse

de tales procesos (Valle Vargas et al., 2022). Lo mismo sucede en el lugar de trabajo, donde esta competencia es en realidad lo que las empresas realmente buscan [19]. Debido a esto, la falta de habilidades blandas (por ejemplo, habilidades de comunicación y habilidades de gestión) puede incluso disminuir la empleabilidad de los graduados técnicamente calificados [13];[18]. La capacitación en emprendimiento también tiene efectos positivos, no solo generando intención emprendedora, sino también generando las habilidades y capacidades que se requieren [3].

III. ESTADO DEL ARTE

El aprendizaje del álgebra en distintos contextos se enriquece a pasos acelerados gracias al desarrollo tecnológico de estrategias que permiten hacer de la enseñanza y el aprendizaje un ejercicio dinámico, diverso y rico en recursos digitales.

Se presentan los hallazgos relevantes en el uso de estos recursos digitales en estudiantes del Tecnológico Nacional de México campus Apizaco en las asignaturas de: cálculo diferencial, cálculo integral, análisis numérico, álgebra lineal, cálculo vectorial, durante el ciclo escolar 2024. Los temas de la unidad se desarrollaron apoyados en el software para entender; métodos, procedimientos y resultados, las opiniones de los 186 estudiantes encuestados. Este capítulo presenta los datos referentes a la usabilidad del software predilecto de los estudiantes, por ejemplo, GeoGebra, PhotoMath, Symbolab entre otras. Los resultados recopilan información de la experiencia de estudiantes de ingeniería acerca de la usabilidad del software, evaluando la eficacia en su propósito, eficiencia, la facilidad de memorización y de aprendizaje, la percepción subjetiva de las interfaces gráficas y la tasa de errores que se cometen.

Estos hallazgos confirman que el software como una estrategia de enseñanza apoyando en el aprendizaje reflexivo consiguen resultados favorables en el desempeño académico de los estudiantes mitigando la dificultad de aprendizaje por adaptación al estilo (A) y Comprensión de contenidos (C). De tal forma que se pretende indagar en la realidad del contexto universitario con el fin de entender como el uso del software puede influir en el desarrollo de habilidades blandas (H).

A. Software en la enseñanza del aprendizaje en álgebra

Este corpus de investigación se ha centrado en la tecnología digital. Como primero, se integra esta tecnología en la enseñanza del álgebra universitaria [38], y luego se elabora la formación de esta integración dado el tipo de usos y costumbres tecnológicas de hoy en relación con las diferentes etapas del sistema educativo [29], incluyendo destacar la importancia de las herramientas tecnológicas para la enseñanza de las matemáticas, en particular, el álgebra, así como GeoGebra [28], Photomath[33], Symbolab [27], entre otras aplicaciones y software en el

proceso de aprendizaje. Se presentan múltiples experiencias respecto al software usado durante las sesiones los cursos: cálculo diferencial, cálculo integral, análisis numérico, álgebra lineal, cálculo vectorial, los problemas en el campo de implementación, el conjunto de beneficios potenciales y problemas, los factores para el nivel de operación, así como el impacto en el rendimiento y capacidad de alcanzar resultados exitosos al resolver problemas.

Los autores [30] en su estudio indicaron que GeoGebra es una herramienta poderosa en manos de estudiantes a nivel de escuela secundaria y que los estudiantes enseñados con la ayuda de GeoGebra obtuvieron calificaciones más altas que sus contrapartes que fueron enseñados utilizando métodos tradicionales. También se ha estudiado el efecto cognitivo del uso de GeoGebra ejemplo, la introducción de una secuencia didáctica sobre polinomios en la que obtuvieron avances en el aprendizaje sobresaliente fue debido al uso de GeoGebra [31]. También investigaron el impacto de las tareas de visualización de secciones cónicas en la articulación del desempeño algebraico y geométrico en el aprendizaje del alumno [36]. En general, los estudiantes valoran a GeoGebra como un mediador de aprendizaje eficaz [28].

Otros estudios confirmaron que Photomath aumenta los logros en ecuaciones algebraicas [35], enfatizando su uso bajo orientación para no depender de respuestas automáticas. También se apoyan estudios reportando que el uso de Photomath mejoró el rendimiento de los estudiantes y fomentó el interés en el álgebra [37], otras investigaciones [32] encontraron que la Calculadora Symbolab era más efectiva en comparación con un método tradicional en la enseñanza de ecuaciones simultáneas a nivel elemental. A continuación, en la Tabla III, se presenta un listado del software utilizado en las sesiones áulicas y su descripción detallada, mostrando características, fortalezas e inconvenientes.

Tabla III. Análisis de software usado con mayor frecuencia por estudiantes universitarios.

Software y plataforma	Característica	Fortaleza	Inconveniente
GeoGebra	Software de matemáticas dinámicas para geometría, álgebra, cálculo y estadística.	Herramienta versátil para visualizar conceptos matemáticos. Gratuito y de código abierto.	Curva de aprendizaje para usuarios nuevos. Enfocado principalmente en matemáticas.
Web, iOS, Android, Windows, macOS.			
Photomath	Aplicación que resuelve problemas matemáticos escaneando ecuaciones con la cámara del teléfono.	Soluciones paso a paso. Fácil de usar y rápida. Cubre aritmética, álgebra, cálculo y más.	Dependencia excesiva de la app puede limitar el aprendizaje. No siempre explica el razonamiento detrás de los pasos.
iOS, Android			
Symbolab	Calculadora avanzada que resuelve problemas matemáticos y	Amplio rango de temas (álgebra, cálculo, ecuaciones diferenciales,	Versión gratuita con limitaciones. Puede ser abrumador para

Web, iOS, Android	muestra pasos detallados.	etc.). Explicaciones detalladas.	usuarios principiantes.
Mathway	Herramienta para resolver problemas matemáticos en áreas como álgebra, trigonometría, cálculo y más.	Interfaz sencilla y fácil de usar.	Explicaciones limitadas en la versión gratuita.
Web, iOS, Android		Soluciones rápidas y precisas.	Requiere suscripción para ver pasos detallados.
Cymath	Aplicación que resuelve problemas matemáticos y muestra pasos intermedios.	Enfoque en explicaciones paso a paso.	Menos funciones que otras herramientas como Symbolab o Mathway.
Web, iOS, Android		Gratuita y fácil de usar.	

B. Características de usabilidad

Se presentan los hallazgos relevantes en el uso de estos programas. Los temas de la unidad se desarrollaron apoyados en el software para entender; métodos, procedimientos y resultados, las opiniones de los 186 estudiantes encuestados con la prueba estandarizada SUS (System Usability Scale), Test de usabilidad, entrevistas y cuestionarios se concentraron en el siguiente análisis:

Tabla IV. Foco de usabilidad.

Software	Eficacia (¿Logra su objetivo?)	Eficiencia (Tiempo/Esfuerzo)	Percepción de Satisfacción (SUS estimado)	Curva de Aprendizaje	Tasa de errores aproximada
GeoGebra	100%. Herramientas enfocadas	91%, Interfaz compleja	72%	Alta, requiere explicación de expertos	25%, Herramientas ocultas
Photomath	73%, Escaneo preciso	100%, Resultados instantáneos	85%	Muy baja, intuitiva y fácil de comprender	5%, Interpretación errónea de símbolos, resultados incongruentes
Symbolab	100%, Resoluciones paso a paso	91%, Buena velocidad	80%	Media, requiere explicación de expertos	20%, Pasos de solución poco entendibles
Mathway	67%, Amplio rango de temas	100%, Interfaz rápida	82%	Baja, ideal para principiantes	15%, Funciones de pago bloqueadas
Cymath	45%, Funcionalidad limitada	91%, Rápido y básico	75%	Muy baja, intuitiva y fácil de comprender	30%, Explicaciones generales poco entendibles

Esta solución es comparada con los métodos y procedimientos analizados en el aula, de tal forma que, esta tendencia a buscar los procedimientos mecanizados se diluye al realizar ejercicios de análisis comparativo desde el pensamiento reflexivo. La Tabla V presenta las preferencias de los estudiantes desde un análisis estadístico comparativo según la norma ISO/IEC 25010 [39] respecto a la calidad del software, enfocado a 6 sub características respectivas a la usabilidad. Cada una de ellas se ponderó preguntando la satisfacción de los usuarios en una escala de 1 (deficiente), 2 (Inaceptable), 3 (Aceptable), 4 (Muy bueno), 5(Excelente). Se registra el promedio de las seis preferencias analizadas: Adecuación reconocible ¿El propósito del software es claro?, Aprendizaje ¿Cuán fácil es usar el software?, Operatividad ¿La interfaz permite una operación fluida y sin esfuerzo?, Protección frente a errores ¿El sistema previene, detecta y ayuda a recuperarse de errores?, Estética de la UI ¿El diseño es limpio, moderno y agradable?, y Accesibilidad ¿Es usable por personas con discapacidades?.

Tabla V. Foco de usabilidad.

Métricas	GeoGebra	Photomat	Symbolab	Mathway	Cymath	Media	Desviación estándar
Adecuación reconocible	4.2	5	4.9	4.6	3.8	4.30	0.49
Aprendizaje	2.3	5	4	4.6	3.7	3.92	1.01
Operatividad	3	4.9	3.9	4.8	3.7	3.88	0.77
Protección frente a errores	3.5	5	3.8	4	2.6	3.78	0.96
Estética de la UI	2.7	4.8	4	4.9	2.6	3.60	1.05
Accesibilidad	3	3.2	2.9	3.8	2.7	3.12	0.45
Media	3.1	4.7	3.9	4.5	3.2		

La metrica mejor percibida es la adecuación reconocible, las más consistentes son accesibilidad y adecuación reconocible, y las que los alumnos identifican como más distintas entre si son la estetica UI y el aprendizaje. Los datos estadísticos brindan un panorama acerca de las predilecciones del usuario. A lo largo de la investigación surgieron dos principales inquietudes; ¿El uso de software mejora la efectividad en la comprensión de contenidos? y ¿el uso de software puede mitigar las dificultades de aprobación antes descritas? Por lo que se comenzó a bitacorar los resultados en la solución de distintos ejercicios.

Tabla VI. Resultados de ejercicios correctos

	Inicio de clase	Desarrollo del ejercicio	Cierre de clase	En examen
Sin Software	62	72	69	81
Con Software	107	179	179	142
Después del uso	123	153	112	128

Se registró la efectividad de los alumnos al usar la metodología propuesta en clase para la solución de problemas. La Tabla VI, presenta los hallazgos en resultados de evaluar ejercicios exitosos con y sin el uso de herramientas tecnológicas, mostrando un comparativo de los alcances en el

desarrollo y asimilación de aprendizajes antes, durante y después de la adopción de estas herramientas.

Como se señaló en el corpus de la investigación, la relevancia teórica afirma los resultados obtenidos en el desempeño de los alumnos, por ejemplo; mientras que 81 alumnos lograban resultados exitosos sin el apoyo de software en el examen, una vez conocido y practicado durante el desarrollo de los distintos temas con apoyo del software ahora 128 alumnos alcanzaron ejercicios exitosos.

La última evidencia en la enseñanza del álgebra y las matemáticas usando software parece favorecer el aprendizaje y el rendimiento de los estudiantes. La efectividad de las plataformas, el software y los recursos tecnológicos depende de variables como la mediación y formación del docente, la definición de estrategias pedagógicas y la integración equilibrada con las tradicionales [34]. La personalización de estas herramientas puede significar que el estudiante derrumbe barreras de aprendizaje persistentes históricamente. De tal forma, el corpus de investigación anterior dio origen al desarrollo de software mediante distintos objetos de aprendizaje, el cual se analiza en el siguiente capítulo.

IV. DESARROLLO

Partiendo del argumento de las tres principales dificultades de aprobación en el aprendizaje del álgebra, los estudiantes universitarios disponen de una variedad de software para incrementar sus habilidades en el aprendizaje, como se desarrolló en capítulos anteriores. Estas consideraciones dieron inspiraron el “desarrollo de software para el aprendizaje del algebra” para que permita conocer la asimilación del alumno con base en respuestas a problemas sugeridos en distintos objetos de aprendizaje.

Se desarrolla un software (programado en Python 3.14.1) de “aprendizaje inteligente en la enseñanza del algebra” para estudiantes preuniversitarios y universitarios. El Software presenta al usuario distintos objetos de aprendizaje con problemas algebraicos de dificultad progresiva, en distintos temas. Para fines de esta investigación se analizará un objeto de aprendizaje; el tema inicial “monomios” como se muestra en la Figura 2. El objeto de aprendizaje es el último de una serie de 4 entrenamientos referidos a monomios, donde el alumno aprende a identificar los tipos de monomios: simples, de coeficiente fraccionario y de tipo fraccionarios.




Figura 2. Objeto de aprendizaje “Componentes de monomios mixtos”

Como se mencionó en los primeros capítulos, el desempeño académico de estudiantes universitarios se ha transformado significativamente con el desarrollo de software aplicado [40]. Este estudio fundamenta la incorporación de algoritmos genéticos para evaluar el objeto de aprendizaje propuesto y reconocer dificultades de aprendizaje en dicho objeto, para generar posibles recomendaciones personalizadas de mejora. Los algoritmos genéticos, como así lo indica la teoría; inspirados en los procesos de selección natural, son fundamentalmente efectivos para identificar patrones complejos en datos, en el caso de estudio, datos educativos [41]. A continuación, se desarrolla la metodología en la implementación del algoritmo “informado” con los resultados obtenidos en la respuesta de estudiantes de ingeniería.

A. Metodología

Se registraron 200 respuestas en el objeto de aprendizaje. Los datos registran las características: Calificaciones por componente (signo, numerador, denominador, coeficiente, variable, exponente, tipo), Tiempo de respuesta, Calificación total, Dificultad del ejercicio, Tipo de monomio. Los ejercicios (10) se distribuyen en: 40% simples, 30% fraccionarios, 30% coeficientes fraccionarios. La siguiente figura presenta el procesamiento del algoritmo.




Figura 3. Algoritmo genético informado

Como se muestra en la Tabla VII y VIII, se implementó un algoritmo genético informado con las siguientes características:

Tabla VII. Parámetros ajustables

Parámetro	Valor	Efecto
Tamaño de la población	50	Más individuos = mayor diversidad, más lento
Generaciones	100	Más generaciones = mejor optimización, más lento
Probabilidad de cruce	0.8	Alta = mayor exploración, baja = más conservador
Tasa de mutación	0.1	Alta = mayor diversidad, baja = converge más rápido

Tabla VIII. Ejemplo de procesamiento

Paso 1. Preparación de datos “objeto de aprendizaje”	
ejercicio número: “2”, tiempo en segundos: “54.93” calificación total: “7.14” tipo: “coeficiente fraccionario”, dificultad: “alta”, es simplificable: “true”, monomio: “2\ n — z\ n 8”, signo: “-”, numerador: “2”, denominador: “8”, coeficiente: “1/4”, variable: “z”, exponente: “1”, numerador simplificado: “1”, denominador simplificado: “4”, coef no simplificado: “2/8”	respuestas usuario: signo: “+”, numerador: “1”, denominador: “8”, coeficiente: “1/4”, variable: “z”, exponente: “2”, tipo: “simple” calificaciones por componente: signo: 0, numerador: 50, denominador: 100, coeficiente: 100, variable: 100, exponente: 50, tipo: 0 tiempo: 42.5, calificación total: 75.0, dificultad: 2, tipo monomio: 1 es simplificable: 1

Convierten los datos de los ejercicios de monomios en un vector numérico, se otorgan al usuario tres calificaciones según sus respuestas: correcto=100, Aproximado=50 e incorrecto=0

Se convierte a vector numérico:

Individuo de 11 índices: [0,50,100,100,100,50] [0, 42.5, 75, 2, 1]

Paso 2. Inicialización de población “Codificación”

Se normalizan los datos y se crean individuos binarios aplicando un umbral >0.5, ya que es el punto medio entre 0 y 1, así convierte valores altos en 1 y bajos en 0. (0 o 1), 1 = característica seleccionada, 0 = característica no seleccionada.

Ejemplo:

Población (200 individuos, 11 características):

Individuo 1: [1,0,0,1,0,1,0,0,1,0,0] → Selecciona 0, 3, 5, 8

Individuo 2: [0,1,1,0,0,1,0,0,0,1,0] → Selecciona 1, 2, 5, 9

Individuo 180: [1,1,0,0,1,0,1,1,0,0,0] → Selecciona 0,1, 4,6,7

Individuo 200: [0,0,1,1,1,0,0,0,0,0,0] → Selecciona 2, 3 y 4

Paso 3. Función de evaluación “Fitness”

Para Individuo 1: [1, 0, 0, 1, 0, 1, 0, 0, 1, 0, 0]

1. Verificar que selecciona al menos una característica

2. Seleccionar características según el individuo

Individuo 1 selecciona índices: 0, 3, 5, 8. signo (0), coeficiente (3), exponente (5), calificación total (8)

X original (3×11):

[[0.0, 1.2, 0.0, 0.8, 0.0, 0.0, 0.0, -1.3, 1.5, -0.8, -0.8],

[0.0, -1.6, 0.0, -1.2, 0.0, 0.0, 0.0, 1.4, -1.5, 1.3, 1.2],

[0.0, 1.2, 0.0, -0.2, 0.0, 0.0, 0.0, 0.5, 0.0, 2.4, 2.0]]

X seleccionado (3×4):

[[0.0, 0.8, 0.0, 1.5], Ej1: signo=0.0, coeficiente=0.8, exponente=0.0, calificación total=1.5

[0.0, -1.2, 0.0, -1.5], Ej2: signo=0.0, coeficiente=-1.2, exponente=0.0, calificación total=-1.5

[0.0, -0.2, 0.0, 0.0], Ej3: signo=0.0, coeficiente=-0.2, exponente=0.0, calificación total=0.0

3. Entrenar KNN con validación cruzada (2 folds)

Como hay 3 muestras, usamos 2 folds (ej1, ej2) vs (ej3)

Fold 1: Entrenar con [Ej1, Ej2], probar con [Ej3]

Vecinos más cercanos a Ej3: Ej1 ($\text{dist}=\sqrt{[(0.0-0.0)^2+(0.8+0.2)^2+(0.0-0.0)^2+(1.5-0.0)^2]}=1.58$).

Ej2 ($\text{dist}=\sqrt{[(0.0-0.0)^2+(-1.2+0.2)^2+(0.0-0.0)^2+(-1.5-0.0)^2]}=1.80$)

Predicción para Ej3: Ej1=éxito (1), Ej2=fracaso (0) → Predice 1 (correcto)

Fold 2: Entrenar con [Ej1, Ej3], probar con [Ej2]

Vecinos más cercanos a Ej2: Ej3 ($\text{dist}=1.80$), Ej1 ($\text{dist}=2.53$)

Predicción para Ej2: Ej3=éxito (1), Ej1=éxito (1) → Predice 1 (incorrecto, debería ser 0)

4. Calcular accuracy

Fold 1: 1 correcto de 1 = 100%

Fold 2: 0 correctos de 1 = 0%

Accuracy promedio = $(1.0 + 0.0) / 2 = 0.5$

5. Aplicar penalización por muchas características (4 características)

Feature penalty = $0.1 * (\text{n_selected} / \text{n_features})$
 $= 0.1 * (4/11) = 0.0364$

6. Fitness final

accuracy = 0.5

fitness = accuracy - feature_penalty
 $= 0.5 - 0.0364 = 0.4636$

Paso 4. "Mecanismos de Selección" método de Ruleta

Ind	Fitness	Probabilidad	Sector en Ruleta
1	0.4636	0.2081 (20.81%)	[0.000 - 0.208]
2	0.7200	0.3258 (32.58%)	[0.208 - 0.534]
3	0.3800	0.1719 (17.19%)	[0.534 - 0.706]
4	0.6500	0.2941 (29.41%)	[0.706 - 1.000]

Giro de ruleta:

Giro 1: 0.878 → Selecciona Individuo #4

Giro 2: 0.431 → Selecciona Individuo #2

Padres seleccionados: Ind4 e Ind2

Paso 5. Cruce (Crossover) "Operadores genéticos"

Cruce entre padres:

Padre 1 (Ind4): 10001101010

Padre 2 (Ind2): 01001011010

✓ CRUCE ACTIVADO en punto 5

Hijo 1: 10001011010 (10001|011010)

↑↑↑↑ ↓↓↓↓

Padre1|Padre2 (del punto 5 en adelante)

Hijo 2: 01001101010 (01001|101010)

↑↑↑↑ ↓↓↓↓

Padre2|Padre1 (del punto 5 en adelante)

Análisis de los hijos:

Hijo 1: [signo, denominador, tiempo, tipo, dificultad]

10001|011010 = 10001011010. Características: signo (1), exponente (0), tipo (0), tiempo (1), tipo (1), dificultad (0)

Hijo 2: [numerador, coeficiente, exponente, calif_total, tipo monomio]

01001|101010 = 01001101010. Características: numerador (0), variable (1), exponente (0), tipo (1), calificación total (1), dificultad (0), tipo monomio (1)

Paso 6. Mutación "Traslape"

Individuo antes: 10001011010

MUTACIÓN en bits: [3, 9]

Características afectadas: ['coeficiente', 'dificultad']

Individuo después: 10011011110

Cambió Bit 3 (índice 3): 0→1 → Ahora INCLUYE "coeficiente"

Cambió Bit 9 (índice 9): 0→1 → Ahora INCLUYE "dificultad"

Nuevo individuo: [signo, coeficiente, tiempo, tipo, dificultad, tipo_monomio]

1 0 0 1 1 0 1 1 1 0

Paso 7. Elitismo

Conservando el mejor individuo

Mejor individuo: #2 (de la generación anterior)

Vector: 01001011010

Fitness: 0.7200

Características: ['numerador', 'variable', 'tipo', 'tiempo', 'tipo monomio']

ESTE INDIVIDUO PASA DIRECTAMENTE A LA NUEVA GENERACIÓN

El algoritmo genético encuentra las características más importantes para predecir el aprendizaje del estudiante, cómo: Calificación en exponentes, Tiempo de respuesta, Tipo de monomio (fraccionario vs simple), además de hacer una recomendación, por ejemplo: "Enfócate en practicar ejercicios con exponentes y monomios fraccionarios". Se realizó la ejecución del algoritmo genético mostrando los resultados posteriormente descritos.

V. RESULTADOS

A. Resultados del análisis genético

Se realizaron 10 ejecuciones, el comportamiento de la evolución del Fitness, en la siguiente figura se muestra su comportamiento:




Figura 4. 10 ejecuciones de prueba

La siguiente tabla muestra las estadísticas básicas del conjunto de datos registrados:

Tabla X. Métricas de componentes

Métrica	Valor
Total, de ejercicios	200
Ejercicios exitosos ($\geq 70\%$)	154 (77.0%)
Ejercicios fallidos ($< 70\%$)	46 (23.0%)
Tiempo promedio	35.5 segundos
Distribución por tipo	
Simple	80 (40%)
Fraccionario	60 (30%)
Coeficiente fraccionario	30 (30%)

El algoritmo genético logró un fitness máximo del 85.62%, seleccionando 8 de las 11 características

disponibles. La precisión final con validación cruzada fue de 0.8200 (± 0.0428). Las características más importantes identificadas fueron: **Calificación de signo, Calificación de numerador, Calificación de denominador, Calificación de coeficiente, Calificación de variable, Tiempo de respuesta, Calificación total y Dificultad del ejercicio.**

B. Análisis de componentes problemáticos

La siguiente tabla muestra la distribución de errores por componentes:

Tabla XI. Componentes problemáticos

Componente	Errores	Porcentaje
Coeficiente	99	49.5%
Variable	39	19.5%
Signo	30	15.0%
Tipo	24	12.0%
Numerador	23	11.5%
Denominador	18	9.0%
Exponente	15	7.5%

B. Análisis de dificultad por tipo

Los coeficientes fraccionarios presentaron la mayor dificultad (31.2%), seguidos por los fraccionarios (21.8%) y los simples (18.1%). Como se observa en la Tabla XII, el tiempo promedio de los ejercicios errados fue mayor.

Tabla XII. Componentes problemáticos

Métrica	Éxitos	Fallos
Tiempo promedio	30.9s	48.2s
Rango mínimo	14.8s	29.4s
Rango máximo	58.1s	117.9s
Desviación estándar	10.2s	15.8s

Los ejercicios fallidos tomaron en promedio 56% más tiempo que los exitosos. La combinación coeficiente + variable incorrecta (35% de fallos), Signo incorrecto + tipo mal identificado (25% de fallos), Tiempo excesivo + múltiples errores (20% de fallos).

VI. DISCUSIÓN

Los resultados indican que los coeficientes fraccionarios representan el mayor desafío para los estudiantes, estadísticamente se constatan los desafíos acerca del dominio de fracciones [42] que, en la práctica docente, se identifica como problemática. La alta tasa de error (49.5%) sugiere la necesidad de intervenciones específicas, dichas intervenciones relacionadas con el uso de distintas estrategias de enseñanza, generación de hábitos que desarrollen habilidades blandas y diferentes mecanismos de aseguramiento en la comprensión de una variedad de ejercicios.

La correlación entre tiempo y desempeño (56% más tiempo en fallos) sugiere que los estudiantes se pueden estar enfocando en estrategias ineficientes o careciendo de automatización en procedimientos básicos. Las características identificadas como importantes por el algoritmo genético proporcionan información valiosa.

Como se demostró en el estudio, según los datos proporcionados por las 200 pruebas en el objeto de aprendizaje, hay un énfasis en coeficientes; Debe priorizarse la enseñanza de operaciones con fracciones, además de incorporar estrategias de gestión de tiempo en la enseñanza y la resolución de problemas. Como se muestra en la Figura 5 se presentan el resumen del desempeño individual al usuario. El algoritmo genético permite identificar los errores en cada componente del objeto de aprendizaje para focalizar la solución. De forma personalizada, al usuario se le presenta un resumen de su desempeño y sugerencias para mejorar




Figura 5. Resultados de los ejercicios

En la Figura 6, al alumno se le presenta el análisis genético destacando su desempeño; resultados, características más importantes y recomendaciones personalizadas.




Figura 4. Resultados y recomendaciones del análisis genético.

VII. CONCLUSIONES

La investigación demostró la efectividad de los algoritmos genéticos para analizar el desempeño estudiantil mediante un objeto de aprendizaje “Componentes de monomios mixtos” donde se presentan distintos tipos de monomios. Los resultados principales son: los coeficientes fraccionarios representan el 49.5% de los errores totales. El algoritmo genético logró una precisión de 85.62% identificando características críticas. Los ejercicios fallidos toman 56% más tiempo que los exitosos.

El sistema propuesto ofrece un enfoque personalizado para la identificación de dificultades específicas y la generación de recomendaciones focalizadas.

REFERENCIAS

- [1] A. M. C. Alanes-Fernandez, "Estilos de aprendizaje de estudiantes universitarios en ciencias de la salud y su proceso de desempeño," *MEMORIA DEL POSGRADO*, vol. 3, no. 2, 2022. doi: 10.53287/bapf8840rr92r.
- [2] C. Albornoz, L. Silarayan, y M. Hidalgo, "Estilos de aprendizaje 2022 en la enseñanza virtual en estudiantes universitarios," *Mendive*, vol. 20, no. 1, 2022.
- [3] M. D. Aledo Ruiz, "Development of soft skills and entrepreneurial intention in university students | Desarrollo de habilidades blandas e intención emprendedora en los estudiantes universitarios," *TECHNO REVIEW. International Technology, Science and Society Review /Revista Internacional De Tecnología, Ciencia Y Sociedad*, vol. 12, no. 4, 2022. doi: 10.37467/revtechno.v11.4468.
- [4] J. Caizapanta Suárez, "Estilos de aprendizaje en estudiantes universitarios: una descripción integral al iniciar la formación profesional," *LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades*, vol. 4, no. 1, 2023. doi: 10.56712/latam.v4i1.534.
- [5] R. Campos Ortuño, M.-J. Hernández-Serrano, P. Renes-Arellano, y F. J. Lena-Acebo, "Recursos Educativos Abiertos adaptados a estilos de aprendizaje para la enseñanza de competencias digitales en Educación Superior," *Revista de Estilos de Aprendizaje*, vol. 16, no. 31, 2023. doi: 10.55777/rea.v16i31.4602.
- [6] T. H. Cruz Sánchez, J. M. Gomero Mancesidor, N. C. Jamanca Gonzales, y L. H. Tosso Pineda, "Relación de preferencias en estilos de aprendizaje con el rendimiento académico de los estudiantes universitarios de ingeniería," *Alpha Centauri*, vol. 3, no. 1, 2022. doi: 10.47422/ac.v3i1.70.
- [7] B. A. Delabra Ríos y E. P. Romero Mancilla, "Una Aproximación Histórica a Las Aportaciones Del Paradigma Sociocultural a La Psicología Educativa," *Revista Electrónica de Psicología Iztacala*, vol. 24, no. 1, 2021.
- [8] A. Freiberg Hoffmann, M. Fernández Liporace, y F. Uriel, "¿Cómo aprenden los estudiantes de educación secundaria y universitaria? Un análisis integral desde los estilos de aprendizaje," *Avances en Psicología Latinoamericana*, vol. 40, no. 3, 2023. doi: 10.12804/revistas.urosario.edu.co/apl/a.10980.
- [9] H. Gil Alba, L. del C. Alba Pérez, y A. E. Gutiérrez Díaz, "La dependencia emocional: un problema de la psicología y otras ciencias humanísticas," *Edumecentro*, vol. 13, no. 2, 2021.
- [10] D. González-Lomeli et al., "Zona de Desarrollo Próximo y Desempeño de Universitarios en una Prueba de Ejecución," *Revista Iberoamericana de Diagnóstico y Evaluación – e Avaliação Psicológica*, vol. 58, no. 1, pp. 95-109, 2021. doi: 10.21865/ridep58.1.08.
- [11] C. A. Hernández Dávila, R. S. Velastegui Hernández, L. A. Mayorga Ases, y S. V. Hernández Del Salto, "Métodos de enseñanza del razonamiento lógico matemático para estudiantes universitarios," *AlfaPublicaciones*, vol. 5, no. 4, 2023. doi: 10.33262/ap.v5i4.409.
- [12] A. Jiménez, C. F. S. Ruiz, y L. A. H. Tupia, "Estilos de aprendizaje 2022 en la enseñanza virtual en estudiantes universitarios," *MENDIVE*, vol. 20, no. 1, 2022.
- [13] E. F. Loayza Maturrano, "Competencias digitales y habilidades blandas de los estudiantes universitarios en el aprendizaje electrónico en tiempos de COVID-19," *Tierra Nuestra*, vol. 17, no. 1, 2023. doi: 10.21704/rtn.v17i1.2010.
- [14] J. M. Mendoza Puertas, "Renuencia a hablar en clase y estilos de aprendizaje entre los estudiantes de ELE en Taiwán," *Revista Internacional de Lenguas Extranjeras / International Journal of Foreign Languages*, no. 16, 2022. doi: 10.17345/rile16.3265.
- [15] W. E. Mucha-Huamán, "Habilidades blandas para el logro de aprendizaje de los estudiantes de nivel superior," *Investigación Valdizana*, vol. 17, no. 2, 2023. doi: 10.33554/riv.17.2.1837.
- [16] F. P. Naupari Rafael, "Google drive y aprendizaje colaborativo en estudiantes universitarios," *Revista Internacional de Tecnología, Conocimiento y Sociedad*, vol. 9, no. 1, pp. 1-12, 2021. doi: 10.18848/2474-588x/cgp/v08i01/1-12.
- [17] A. V. Palacios Zenteno, "Coaching docente y habilidades blandas en el aprendizaje de estudiantes de nivel secundario, Lima, Perú," *Horizontes. Revista de Investigación en Ciencias de la Educación*, vol. 6, no. 25, 2022. doi: 10.33996/revistahorizontes.v6i25.433.
- [18] G. Salgado-Oviedo, "Desarrollo de habilidades blandas a los estudiantes de medicina," *Polo del Conocimiento*, vol. 8, no. 9, 2023.
- [19] G. Sánchez Ambriz, A. Yáñez Hernández, y M. L. Sánchez Ambriz, "Talento humano en las organizaciones: Competencias blandas para la empleabilidad de estudiantes universitarios," *Revista Universitaria Digital de Ciencias Sociales (RUDICS)*, vol. 13, no. 24, 2022. doi: 10.22201/fesc.20072236e.2022.13.24.2.
- [20] M. Segarra, M. Estrada, y D. Monferrer, "Estilos de aprendizaje en estudiantes universitarios: lateralización vs. interconexión de los hemisferios cerebrales," *Revista Española de Pedagogía*, vol. 73, no. 262, 2023. doi: 10.22550/2174-0909.2633.
- [21] J. Tapia, "Habilidades blandas y la ética en la formación del docente universitario," Universidad Abierta Para Adultos, 2022.
- [22] L. M. Tarco Sánchez, "Aprendizaje colaborativo en entornos virtuales," *UCV-SCIENTIA*, vol. 14, no. 1, 2022. doi: 10.18050/revucv-scientia.v14n1a7.
- [23] M. R. Torres Cueva et al., "Neuroeducación en los ambientes escolares. Un despertar desde el binomio: Emoción-aprendizaje," *Ciencia Latina Revista Científica Multidisciplinar*, vol. 7, no. 2, 2023. doi: 10.37811/cl_rcm.v7i2.5298.
- [24] L. Vázquez-González et al., "Estudio sobre habilidades blandas en estudiantes universitarios: El caso del TECNM Coatzacoalcos," *IPSA Scientia, revista científica multidisciplinaria*, vol. 7, no. 1, 2022. doi: 10.25214/27114406.1311.
- [25] J. E. Villarreal Fernández, "Cuestionario Honey-Alonso de estilos de aprendizaje (CHAEA). Propiedades psicométricas en estudiantes universitarios colombianos," *Psicogente*, vol. 26, no. 50, 2023. doi: 10.17081/psico.26.50.6231.
- [26] M. E. Zepeda Hurtado, J. A. Cortés Ruiz, y E. O. Cardoso Espinosa, "Estrategias para el desarrollo de habilidades blandas a partir del aprendizaje basado en proyectos y gamificación," *RIDE Revista Iberoamericana para la Investigación y el Desarrollo Educativo*, vol. 13, no. 25, 2022. doi: 10.23913/ride.v13i25.1348.
- [27] 2 Akpan, E. T., Charles-Ogan, G. I., Eze, F. B., Okafor-Agbala, U. C., & Onyeka, E. C. (2023). Technology Enhanced Learning: Utilization of SymboLab Manipulative Instruction and Performance of Students in Quadratic Graphs. *Asian Journal of Advanced Research and Reports*, 17(11), 32-42. doi:10.9734/ajarr/2023/v17i11551
- [28] 8 Córdoba Gómez, F. J., Mariño, L. F., & Pabón Galán, C. A. (2023). Percepciones estudiantiles y uso de GeoGebra en la enseñanza de matemáticas: un análisis comparativo entre grados. *Revista Perspectivas*, 8(S1), 386-395. doi:10.22463/25909215.4155
- [29] 11 Flores Cuevas, F., Vásquez Martínez, C. R., & González González, F. A. (2021). El uso de las TIC en la enseñanza de conceptos geométricos en la educación básica. *RIDE Revista Iberoamericana Para La Investigación y El Desarrollo Educativo*, 12(23). doi:10.23913/ride.v12i23.1024
- [30] 13 Lucas Espinoza, D. M., & Zambrano Zambrano, E. J. (2023). Las tecnologías de la información y comunicación como herramienta y su uso por docentes de matemática. *Unianides Episteme. Revista de Ciencia, Tecnología e Innovación*, 10(3), 352-364. doi:10.61154/rue.v10i3.3027
- [31] 14 Mera Miele, C. C., & Fosado Tellez, O. (2022). Propuesta metodológica para el uso de Geogebra en la enseñanza de funciones Polinómicas. *Serie Científica de La Universidad de Las Ciencias Informáticas*, 15(5), 110-125.
- [32] 18 Naz Makhdum, F., Sandhu, R. H., Batool, T., Khan, S., Faisal, F., & Younas, A. (2023). Effect Of Using Symbolab Calculator In Teaching Simultaneous Equations On Students' Conceptual Understanding At The Elementary Level In Pakistan: Mathematics Attitude In Technological Corners. *Journal of Positive School Psychology*, 2023(1), 117-124.
- [33] 22 Pikri, A. Z., Yulia, P., & Putri, R. (2023). Photomath Applications for Learning Mathematics Analysis. *Mathline : Jurnal Matematika Dan Pendidikan Matematika*, 8(2), 120-129. doi:10.31943/mathline.v8i2.322
- [34] 26 Rueda-Gómez, K. L., Rodríguez-Muñoz, L. J., & Muñoz-Rodríguez, L. (2023). Performance and mathematical self-concept in university students using Khan Academy. *Heliyon*, 9(4), e15441. https://doi.org/10.1016/j.heliyon.2023.e15441
- [35] 27 Saundarajan, K., Osman, S., Kumar, J. A., Daud, M. F., Abu, M. S., & Pairan, M. R. (2020b). Learning Algebra using Augmented Reality: A Preliminary Investigation on the Application of Photomath for Lower

- Secondary Education. International Journal of Emerging Technologies in Learning (IJET), 15(16), 122-131. doi:10.3991/ijet.v15i16.10540
- [36] 29 Vera, E. M., & Sabino, C. M. (2018). Uso de geogebra en la enseñanza y aprendizaje de las cónicas. IX Congreso Internacional Sobre Enseñanza de Las Matemáticas, 345-355.
- [37] 30 Zain, I. N. M., Setambah, M. A. B., Othman, M. S., & Hanapi, M. H. M. (2023). Use of Photomath Applications in Helping Improving Students' Mathematical (Algebra) Achievement. European Journal of Education and Pedagogy, 4(2), 93-96. doi:10.24018/ejedu.2023.4.2.601
- [38] 33 Zenteno Ruiz, F. A., Malpartida Lovatón, R., Alborno Dávila, V. L., & Rojas, W. (2023). Plataforma Khan Academy para enseñanza - aprendizaje de matemática básica en estudiantes universitarios. Llimpi, 3(1), 129-144. doi:10.54943/lree.v3i1.243.
- [39] 34 Zhang, C., Li, B., Wang, L., Xu, H., Shao, T. (2023). A Hierarchical Model for Quality Evaluation of Mixed Source Software Based on ISO/IEC 25010. International Journal of Software Engineering and Knowledge Engineering, Vol 33. doi: 10.1142/S021819402250070X.
- [40] R. S. J. d. Baker, "Educational data mining: An advance for intelligent systems in education," *IEEE Intell. Syst.*, vol. 30, no. 3, pp. 20-28, May-Jun. 2015, doi: 10.1109/MIS.2015.42.
- [41] C. Romero and S. Ventura, "Educational data mining: A review of the state of the art," *IEEE Trans. Syst., Man, Cybern. C, Appl. Rev.*, vol. 40, no. 6, pp. 601-618, Nov. 2010, doi: 10.1109/TSMCC.2010.2053532.
- [42] Z. Niu, D. C. Wilkins, and M. C. Desmarais, "A genetic algorithm approach to optimizing the distribution of instructional resources," *IEEE Trans. Learn. Technol.*, vol. 9, no. 4, pp. 320-332, Oct.-Dec. 2016, doi: 10.1109/TLT.2016.2518160.
- [43] Secretaría de Educación Pública (SEP), "Boletín 100 Desciende a 8.1% tasa de abandono escolar en Educación Superior," *Gob.mx*, 23 de mayo de 2023. [En línea]. Disponible en: <https://www.gob.mx/sep/articulos/boletin-100-desciende-8-1-tasa-de-abandono-escolar-en-educacion-superior-sep?idiom=es>
- [44] [2] Instituto Nacional de Estadística y Geografía (INEGI), "Tasa de abandono escolar por entidad federativa según nivel educativo, ciclos escolares seleccionados de 2000/2001 a 2023/2024," [En línea]. Disponible en: <https://www.inegi.org.mx/app/tabulados/interactivos/?pxq=9171df60-8e9e-4417-932e-9b80593216ce>



MOISÉS RAMÍREZ BONILLA. Recibió los grados de Técnico Superior Universitario en Procesos de Producción por la Universidad Tecnológica de Tlaxcala en 2004. Licenciatura en Ingeniería Industrial por el Tecnológico Nacional de México, campus Apizaco en 2008. Licenciatura en Educación por la Universidad Pedagógica Nacional U291 en 2024. Maestría en Educación por el Instituto Cristóbal Colón de Veracruz en 2024. Actualmente cursa el Doctorado en Ciencia de la Ingeniería en el Tecnológico Nacional de México, campus Apizaco. Sus áreas de interés incluyen: desarrollo infantil en el aprendizaje numérico, la enseñanza de las matemáticas, investigación educativa, aprendizaje reflexivo en el aprendizaje del álgebra y tutores inteligentes en la educación.



interacción humano computadora.

YESENIA NOHEMÍ GONZÁLEZ MENESES

Obtuvo en el año 2021 el grado de Doctor en Ingeniería del Lenguaje y del Conocimiento por parte de la Universidad Autónoma de Puebla. Actualmente trabaja en la División de Estudios de Posgrado del Tecnológico Nacional de México Campus Apizaco. Sus áreas de interés incluyen: reconocimiento automático de emociones, aplicaciones de IA, ingeniería de software e



investigación incluyen modelos de lógica difusa, tutoriales inteligentes y aplicaciones de internet de las cosas.

BLANCA ESTELA PEDROZA MÉNDEZ

Obtuvo el grado de Doctor en la Facultad de Ciencias de la Electrónica de la Benemérita Universidad Autónoma de Puebla (BUAP) en 2018. Actualmente es docente investigador del área de posgrado y de licenciatura en el Tecnológico Nacional de México, campus Apizaco. Tiene el reconocimiento como Perfil PRODEP, hasta el 2026 y el reconocimiento en el SNII, en el nivel 1, hasta diciembre del 2029. Sus áreas de



Aprendizaje Automático, Computación Evolutiva, Visión por Computadora y Robótica Inteligente.

JOSÉ FEDERICO RAMÍREZ CRUZ

Recibió su grado de Licenciatura en Ingeniería Industrial en Electrónica en el Instituto Tecnológico de Puebla en 1993, la Maestría en Ciencias con Especialidad en Electrónica en el Instituto Nacional de Astrofísica, Óptica y Electrónica (INAOE) en 1994, y el grado de Doctorado en Ciencias en el Área de Ciencias Computacionales en el (INAOE) en 2003. Actualmente, es Profesor-Investigador en el Tecnológico Nacional de México, campus Apizaco. Sus intereses de investigación en el área de aplicaciones del

Fecha de recepción: 06 de marzo de 2026, fecha de publicación en línea: junio de 2026.

Implementación de Modelo de Lenguaje Multilingüe para Traducción Automática Bidireccional entre Español y Náhuatl

Samuel Pérez Zistecatl, José Crispín Hernández Hernández, Eduardo Sánchez Lucero, Yesenia Nohemí González Meneses, y Edmundo Bonilla Huerta

Tecnológico Nacional de México – Instituto Tecnológico de Apizaco. San Andrés Ahuashuatepec, Municipio de Tzompantepec, Tlaxcala, C.P. 90491, México.

Autor de correspondencia: Samuel Pérez Zistecatl (correo electrónico: m24370014@apizaco.tecnm.mx).

Abstract- In this work, we present the design, construction, and evaluation of a large-scale language model (LLM) conceived for bidirectional translation between Spanish and Nahuatl, developed with technical rigor and with careful respect for the cultural weight inherent to the Indigenous language. A bilingual corpus comprising 15,000 sentence pairs were compiled; SentencePiece tokenization was adopted, and fine-tuning was carried out on Transformer-based architectures (refinement using mBART50-Sequential Encoder and LoRA adaptation). A functional web prototype was deployed as proof of concept. Automated metrics (BLEU, chrF++/ROUGE), along with expert evaluation conducted by native speakers and linguists, demonstrate the feasibility of the system and its capacity to preserve linguistic features of Nahuatl that are often lost in generic translation systems. This endeavor therefore constitutes both a technical and sociocultural contribution aimed at fostering digital inclusion and supporting the preservation of Indigenous languages.

Keywords: cultural preservation, digital inclusion, large language model (LLM), linguistic revitalization, natural language processing (NLP), Spanish–Nahuatl machine translation, Transformers.

I. INTRODUCCIÓN

La pluralidad lingüística de la república mexicana es un patrimonio vasto y venerable, hoy más amenazada por la merma de hablantes jóvenes y por la escasa incorporación de las lenguas indígenas en los ámbitos tecnológicos contemporáneos [1]. El náhuatl en México, padece un retroceso en su transmisión intergeneracional. En territorios como Tlaxcala, la hegemonía del español en la escuela, la administración y los medios ha coadyuvado al desplazamiento del uso cotidiano del náhuatl, restringiendo los recursos digitales disponibles y agrandando la brecha tecnológico-cultural frente a las mayorías [2]. Un LLM (Large Language Model) es un modelo de inteligencia artificial basado en redes neuronales profundas, generalmente del tipo *transformer*, entrenado con grandes volúmenes de texto para aprender patrones del lenguaje natural. El desarrollo de herramientas de procesamiento del lenguaje natural (PLN) se erige como estrategia pertinente para la preservación, normalización y revitalización del náhuatl en ámbitos digitales [3]. Este artículo presenta la metodología, implementación y validación de un modelo de lenguaje de gran tamaño para la traducción bidireccional

español-náhuatl como contribución para el aprendizaje y conservación de las lenguas indígenas. El modelo fue desarrollado con precisión técnica y sensibilidad cultural como muestra de respeto a la lengua.

II. MARCO TEÓRICO Y TRABAJOS RELACIONADOS

2.1. Arquitecturas Basadas en Transformers y Mecanismos de Atención

La base de la traducción automática moderna es la arquitectura Transformer [13]. A diferencia de sus predecesores recurrentes (RNN- Recurrent Neural Network y LSTM-Long Short Term Memory), el Transformer elimina la secuencialidad obligatoria, permitiendo el procesamiento paralelo mediante el Mecanismo de Auto-atención de Múltiples Cabezaes (Multi-Head Self-Attention).

Este mecanismo permite que, para cada unidad lingüística o token (unidad de texto), el modelo calcule un puntaje de relevancia respecto a todos los demás elementos de la secuencia, independientemente de su distancia lineal. En el caso del náhuatl, esta propiedad es fundamental: permite conectar prefijos de sujeto situados al inicio de una palabra

aglutinada con raíces verbales o sufijos de tiempo que aparecen al final, resolviendo dependencias morfológicas complejas que en modelos analíticos se perderían.

2.2. Modelos de Lenguaje Multilingües

Los modelos como NLLB (No Language Left Behind) y mBART50 (Sequential Encoder) representan una evolución del Transformer estándar hacia la traducción multilingüe masiva. Estos modelos son pre-entrenados mediante objetivos de eliminación de ruido (denoising) [9], donde el modelo debe reconstruir fragmentos de texto alterados.

El modelo proyecta las palabras a vectores de alta dimensión (embeddings). Al ser multilingüe, el modelo aprende que el concepto "agua" en español y "atl" en náhuatl deben ocupar regiones cercanas en el espacio vectorial, facilitando la transferencia de conocimiento entre idiomas con abundantes recursos y aquellos de bajo recurso [6], [8].

Otro aspecto importante en los modelos de lenguaje multilingüe es el sesgo lingüístico digital (SLD). Es imperativo considerar que los LLM masivos suelen heredar sesgos de los datos de entrenamiento. Muñoz-Basols et al. (2024) [12] advierten que, sin un ajuste fino adecuado, el modelo puede "españolizar" la sintaxis de lenguas indígenas, perdiendo la esencia polisintética del náhuatl.

2.3. Lingüística Computacional del Náhuatl y Desafíos Técnicos

El náhuatl presenta una complejidad morfológica superior a las lenguas indoeuropeas debido a su naturaleza aglutinante. Una palabra puede contener información de sujeto, objeto, dirección y tiempo.

Teniendo presente lo anterior, es recomendable utilizar la tokenización por sub-palabras. Para manejar esta complejidad, se emplea SentencePiece (Sequence to Sequence Tokenizer) que divide el texto en unidades sub-léxicas. Esto previene el problema del "vocabulario fuera de diccionario" (OOV), permitiendo que el modelo entienda palabras que nunca vio en el entrenamiento, siempre que reconozca sus componentes morfológicos.

Otro de los retos es la asimetría de datos, la cual consiste en establecer una categorización en los datos obtenidos del tokenizador. La categorización del náhuatl como lengua de bajo recurso (low resource) no es cultural, sino estadística. La disparidad entre el volumen de datos digitales para el español y el náhuatl exige técnicas de optimización específicas, como el ajuste de hiperparámetros sugerido por Araabi y Monz (2020) [10].

2.4. Fundamentación de las Métricas de Evaluación

Para validar la efectividad del modelo, se emplean métricas que cuantifican la fidelidad de la traducción [7]:

BLEU (Bilingual Evaluation Understudy): Evalúa la precisión basada en la coincidencia de n-gramas. Un puntaje BLEU alto valida la coherencia sintáctica global.

chrF++(Character n-gram F-score): Esta métrica es especialmente relevante para esta investigación, ya que mide n-gramas a nivel de caracteres. Al ser el náhuatl una lengua que construye palabras "pegando" piezas, chrF++ captura si el modelo está ensamblando correctamente los morfemas, incluso si hay pequeñas variaciones ortográficas.

ROUGE (Recall-Oriented Understudy for Gisting Evaluation): Se utiliza para medir la recuperación (recall), asegurando que el modelo no omita conceptos clave presentes en la oración fuente.

III. IMPLEMENTACION DE UN LLM

La materialización de un LLM no es tarea fácil, si bien varias arquitecturas contemporáneas admiten entradas de larga duración, sobreviene con frecuencia el fenómeno denominado "loss-in-the-middle" —la pérdida de información situada en la parte mediana del contexto—. En su percepción [4] menciona que tal déficit proviene de una supervisión explícita insuficiente durante el entrenamiento de contextos extensos, ausencia que impide reconocer cualquier posición de los mismos.

Para este trabajo, se construyó un corpus bilingüe de 7 500 pares de oraciones, se entrenó un tokenizador SentencePiece y se ajustaron con precisión modelos basados en Transformer — particularmente mBART50 con adaptación LoRA—; además, se liberó un prototipo web operativo como prueba de concepto, demostrando así la factibilidad del modelo. Se realizaron evaluaciones automáticas (BLEU, chrF++ y ROUGE) y retroalimentación humana de hablantes nativos junto con especialistas, ambos validaron la viabilidad del sistema y su capacidad para conservar matices del náhuatl que suelen perderse en traductores genéricos; por tanto, el modelo representa una mejora significativa respecto a los sistemas de traducción existentes. En esencia, el modelo constituye una innovación técnica con una misión sociocultural centrada en la accesibilidad digital y la conservación de lenguas indígenas, y por ende posee el potencial de incidir positivamente en la preservación y promoción del náhuatl

IV. METODOLOGIA

El desarrollo del sistema de traducción automática bidireccional se fundamenta en un pipeline de ingeniería de lenguaje [6], [10]. La arquitectura seleccionada es el modelo NLLB-1.3B (No Language Left Behind), cuya capacidad de representación multilingüe masiva ofrece una base sólida para el aprendizaje por transferencia (transfer learning) en lenguas indígenas americanas [11]. Se desarrollaron las siguientes actividades:

4.1 Ingeniería de Datos y Curación del Corpus

La calidad del entrenamiento supervisado depende críticamente de la integridad del corpus paralelo, por ello se consolidó un conjunto de datos mixto de 15,000 pares de sentencias

bilingües, siguiendo un proceso de tres etapas para asegurar la documentación adecuada de la lengua [2]:

- **Recolección Multifuente:** Se integraron datos provenientes de repositorios educativos del INALI [14], contenidos pedagógicos de la SEP [15] e información de recursos bilingües de JW.org [16]. Esta diversidad de fuentes busca reducir el sesgo lingüístico digital (SLD) que suelen presentar los modelos de gran escala [12].
- **Normalización Ortográfica:** Dada la ausencia de una norma única para el náhuatl, se unificaron las variantes gráficas hacia la convención del náhuatl del centro. Se aplicaron técnicas de limpieza para eliminar ruidos ortográficos y caracteres especiales que incrementan la entropía del vocabulario y dificultan la convergencia del modelo [1].
- **Tokenización Basada en Sub-palabras:** Se implementó el algoritmo SentencePiece para descomponer las estructuras polisintéticas del náhuatl en unidades sub-léxicas recurrentes [13]. Este enfoque previene el problema de palabras fuera de vocabulario (out-of-vocabulary) y permite que el modelo capture la compleja morfología aglutinante de la lengua [9], [10].

4.2 Arquitectura del Sistema y Mecanismos de Atención

Como motor de traducción se empleó la arquitectura Transformer [13], la cual utiliza un codificador para procesar la secuencia fuente y un decodificador para generar la secuencia destino mediante mecanismos de auto-atención (self-attention), los cuales se mencionan a continuación:

- **Atención Cruzada (Cross-Attention):** Se aplicó este mecanismo ya permite que el decodificador consulte las representaciones contextuales del codificador para mantener la concordancia entre los prefijos de sujeto en náhuatl y los pronombres en español, factor determinante en lenguas con alta densidad morfológica [4], [8].
- **Eficiencia en Bajos Recursos:** Se aplicaron técnicas de optimización y ajuste de hiperparámetros para adaptar el modelo a las restricciones de memoria de una infraestructura académica, asegurando la estabilidad del gradiente durante el proceso de retropropagación (backpropagation) [10].

4.3 Protocolo de Entrenamiento: Se aplicó aprendizaje por currículo (Curriculum Learning)

Para maximizar la convergencia ante la escasez de datos, el entrenamiento se estructuró en tres fases progresivas [4]:

- **Fase 1 (Fine-Tuning Unidireccional):** Se realizó un entrenamiento inicial enfocado en la dirección Náhuatl↔Español con una tasa de aprendizaje de 3×10^{-5} para estabilizar la comprensión semántica del modelo sobre la morfología indígena.
- **Fase 2 (Generación Sintética y Back-translation):** Se utilizó el modelo intermedio para traducir frases monolingües de español hacia un náhuatl sintético, ya que estos pares adicionales actúan como un mecanismo de regularización

que mejora la fluidez del decodificador y la capacidad de traducción del modelo [6], [9].

- **Fase 3 (Optimización Bidireccional):** Se ejecutó un entrenamiento simultáneo en ambas direcciones (ESP↔NAH) utilizando el optimizador AdamW y un esquema de incremento progresivo (warmup) para refinar los pesos finales del modelo [13].

4.4 Marco de Evaluación Híbrido

La validación de los resultados se realizó bajo un esquema dual que garantiza la precisión técnica y la fidelidad lingüística [7]:

- **Evaluación Automática:** Se emplearon las métricas BLEU y chrF++ para cuantificar la similitud léxica, y ROUGE para la recuperación de información frente a referencias humanas [5], [7].
- **Evaluación Cualitativa:** Se contempló un análisis de interacción directa para examinar la adecuación contextual y la naturalidad de la traducción, considerando que el rendimiento de los modelos actuales aún presenta discrepancias entre las métricas automáticas y los juicios expertos [5], [11].

V. RESULTADOS

5.1 Evaluación Cuantitativa y Convergencia del Modelo

El desempeño se evaluó tras completar las 10 épocas totales de entrenamiento definidas en el esquema de currículo. Los resultados, segmentados por métricas de precisión, recuperación y estructura de caracteres, demuestran la eficacia de la arquitectura NLLB-1.3B adaptada.

TABLA I. Resultados de Evaluación Automática del Modelo Final.

Dirección de Traducción	BLEU	chrF++	ROUGE-L
Náhuatl ↔ Español	31.25	58.40	0.54
Español ↔ Náhuatl	26.15	49.12	0.42
Promedio General	28.70	53.76	0.48

Se observa que la métrica chrF++ es significativamente más alta que el BLEU. Esto indica que, aunque el modelo a veces no acierta la palabra exacta (especialmente en náhuatl), sí es capaz de generar los componentes morfológicos correctos, lo cual es un indicador de éxito para una lengua aglutinante [7].

5.2 Discusión sobre la Polisíntesis y el Error de Atención

Tras un análisis cualitativo de las muestras, se identificaron patrones de error específicos:

Incorporación Sustantiva: El modelo identifica correctamente la raíz verbal, pero en ocasiones falla al integrar el objeto directo dentro del verbo, optando por una estructura más analítica similar al español. Esto confirma el sesgo lingüístico digital (SLD) advertido por Muñoz-Basols et al. (2024) [12].

- **Ambigüedad Dialectal:** En frases con alta varianza regional, el modelo tiende a la normalización, eligiendo la forma gramatical más frecuente en el corpus del INALI o la SEP [14], [15].
- **Mecanismo de Atención Cruzada:** Se verificó que los cabezales de atención logran alinear correctamente los prefijos de sujeto (ej. ni-, ti-) con los pronombres correspondientes en español, lo que valida la robustez de la arquitectura Transformer en este dominio [13].

5.3 Discusión sobre la Polisíntesis y el Error de Atención

Tras un análisis cualitativo de las muestras, se identificaron patrones de error específicos:

Incorporación Sustantiva: El modelo identifica correctamente la raíz verbal, pero en ocasiones falla al integrar el objeto directo dentro del verbo, optando por una estructura más analítica similar al español. Esto confirma el sesgo lingüístico digital (SLD) advertido por Muñoz-Basols et al. (2024) [12].

- **Ambigüedad Dialectal:** En frases con alta varianza regional, el modelo tiende a la normalización, eligiendo la forma gramatical más frecuente en el corpus del INALI o la SEP [14], [15].

5.4 Comparativa con el Estado del Arte

Comparado con modelos base como mBART50 (sin ajuste fino específico para náhuatl central) o GPT-4 (en tareas zero-shot), la propuesta actual muestra una ventaja competitiva en la preservación de la estructura gramatical indígena [5], [11]. Mientras que los modelos comerciales suelen alucinar términos o usar estructuras simplificadas, el modelo ajustado respeta la densidad morfológica requerida para una interpretación lingüística confiable.

VI. CONCLUSIONES

A partir de los resultados experimentales, se infiere que los modelos de lenguaje de gran tamaño (LLM), cuando se ajustan finamente con corpus bilingües seleccionados y metodologías de *fine-tuning* —particularmente sobre la arquitectura NLLB generan traducciones para el náhuatl más precisas y culturalmente sensibles.

- **Estrategia Viable:** La sinergia de un procesamiento de datos riguroso (limpieza y aumento) junto con la validación humana constituye una estrategia efectiva para la accesibilidad digital.
- **Escalabilidad:** Esta metodología es escalable y puede emularse para otras lenguas indígenas de México, posicionando a la inteligencia artificial como una herramienta para el renacimiento cultural.

Refinamiento: Se concluye que la cantidad de datos sin refinamiento genera ruido, mientras que el refinamiento metodológico amplifica el valor del sistema.

REFERENCIAS

- [1] G. A. Gomashie y R. Terborg, "Nahuatl, selected vitality indicators and scales of vitality in an Indigenous language community in Mexico," *Open Linguistics*, vol. 7, n.º 1, pp. 166–180, 2021.
- [2] J. Shi, J. D. Amith, X. Chang, S. Dalmia, B. Yan, S. Watanabe, "Highland Puebla Nahuatl-Spanish Speech Translation Corpus for Endangered Language Documentation", capítulo de conferencia/libro, 2021–2022.
- [3] C. A. Aguilar Santiago, H. A. García Zúñiga, "Language technologies applied to processing indigenous languages in Mexico: an overview", *Lingüística y Literatura*, n.º 84, 2022.
- [4] S. An, Z. Ma, Z. Lin, N. Zheng, J. G. Lou, W. Chen, "Let your LLM make the most of the context," *Advances in Neural Information Processing Systems*, vol. 37, pp. 62160–62188, 2024.
- [5] A. Hendy et al., "What is the performance of GPT models on machine translation? An exhaustive assessment," *arXiv:2302.09210*, 2023.
- [6] B. Zhang, P. Williams, I. Titov, R. Sennrich, "Improving massively multilingual neural machine translation and zero-shot translation," *arXiv:2004.11867*, 2020.
- [7] M. Freitag et al., "Experts, errors, and context: A large-scale study of human evaluation for machine translation," *Trans. Assoc. Comput. Linguist.*, vol. 9, pp. 1460–1474, 2021.
- [8] A. Chowdhery et al., "Scaling language modeling with pathways (PaLM)," *J. Mach. Learn. Res.*, vol. 24, no. 240.
- [9] Y. Tang et al., "Multilingual translation from denoising pre-training", *Proceedings of Findings ACL-IJCNLP*, August 2021, pp. 3450–3466.
- [10] A. Araabi, C. Monz, "Optimizing Transformer for low-resource neural machine translation", *arXiv:2011.02266*, 2020.
- [11] M. Lucas et al., "The Performance of Artificial Intelligence in the Use of Indigenous American Languages", *Inter-American Development Bank*, May 2025.
- [12] J. Muñoz-Basols, M. del M. Palomares, F. Moreno Fernández, "Digital linguistic bias (SLD) in artificial intelligence: consequences for large-scale language models in Spanish," *Language and Society*, vol. 23, n.º 2, pp. 623–648, 2024.
- [13] A. Vaswani et al., "Attention Is All You Need," *NeurIPS*.
- [14] INALI, Recursos lingüísticos y educativos en lenguas nacionales indígenas.
- [15] SEP, Secretaría de Educación Pública, Contenidos educativos oficiales en lenguas nacionales indígenas.
- [16] JW.org, Contenidos lingüísticos y educativos en español y náhuatl.



Samuel Pérez Zistecatli recibió el título de Ingeniería en Sistemas Computacionales por el Instituto Politécnico de Tlaxcala, región Poniente, Campus Hueyotlipan, actualmente cursa la Maestría en Sistemas Computacionales en el Tecnológico Nacional de México, Campus Apizaco. Su trabajo de investigación se centra en el desarrollo de modelos de lenguaje de gran tamaño (LLM) para la traducción automático-computacional entre español y náhuatl, integrando técnicas de minería de datos, procesamiento de lenguaje natural y arquitecturas neuronales avanzadas.



José Crispín Hernández-Hernández Obtuvo el título de Licenciado en Informática por el Instituto Tecnológico de Apizaco, Apizaco, Tlaxcala, México, en 1993. El grado de Maestro en Ciencias, en Ciencias Computacionales por el Instituto Tecnológico de Apizaco, Apizaco, Tlaxcala, México, en 1998. Y el grado de Doctorado en Ciencias de la Computación por la Université d'Angers. Campus Belle Beille, Francia en 2008. Sus principales áreas de investigación incluyen: metaheurísticas, optimización, bioinformática, biomedicina, lógica difusa, visión por computadora. aprendizaje máquina, minería de datos



Eduardo Sánchez Lucero recibió la licenciatura en Informática por el Instituto Tecnológico de Puebla, México, en 2002 y la maestría en ciencias en ciencias computacionales por el Instituto Tecnológico de Apizaco, México, en 2004. Actualmente está cursando el doctorado en ciencias de la ingeniería en el TecNM-Apizaco. Sus intereses de investigación incluyen el procesamiento digital de señales, reconocimiento de patrones, redes neuronales artificiales, modelos de lenguaje de gran tamaño, procesamiento del lenguaje natural y estudio de la lengua náhuatl.



computadora.

Yesenia Nohemí González Meneses Obtuvo en el año 2021 el grado de Doctor en Ingeniería del Lenguaje y del Conocimiento por parte de la Universidad Autónoma de Puebla. Actualmente trabaja en la División de Estudios de Posgrado del Tecnológico Nacional de México Campus Apizaco. Sus áreas de interés incluyen reconocimiento automático de emociones, aplicaciones de IA, ingeniería de software e interacción humano



Edmundo Bonilla-Huerta recibió los grados de Licenciatura en Ciencias (B.Sc.) y Maestría en Ciencias (M.Sc.) en ciencias de la computación por parte del Instituto Tecnológico de Apizaco (ITA), Apizaco, Tlaxcala, México, en 1994 y 1996, respectivamente, y el grado de Doctorado (Ph.D.) en ciencias de la computación por la Universidad de Angers, Angers, Francia, en 2008.

Actualmente es Profesor en la División de Estudios de Posgrado e Investigación del ITA. Sus intereses de investigación incluyen la optimización, lógica difusa, aprendizaje automático (machine learning), técnicas para el análisis de datos de microarreglos y bioinformática.

Fecha de recepción: 06 de marzo de 2026, fecha de publicación en línea: junio de 2026.

Método Híbrido Kendall–Kolmogorov–Smirnov para la Selección de Características Orientada a la Evaluación Automática de la Calidad del Durazno

Humberto Huerta Flores, Yesenia Nohemí González Meneses, Blanca Estela Pedroza Méndez, y María Guadalupe Medina Barrera

Tecnológico Nacional de México – Instituto Tecnológico de Apizaco. San Andrés Ahuashuatepec, Municipio de Tzompantepec, Tlaxcala, C.P. 90491, México.
Autor de correspondencia: Humberto Huerta Flores (m24370005@apizaco.tecnm.mx)

Abstract- The present work presents a hybrid methodology for the selection of traits in peach samples from the municipality of Atltzayanca, (Tlaxcala). The methodology consists of the application of Kendall's Tau coefficient, which measures the correlation by ranges between a variable and the class. This allows you to detect if, when the value of a feature increases, the class also changes in an orderly fashion (high values belong to one class and low values to another). This method is useful for identifying monotonic relationships that are not necessarily linear. In a complementary way, the Kolmogorov–Smirnov test is used, which compares the distributions of the values of the same variable between two classes; If these distributions are different with a significance level $p = 0.05$, the attribute is considered to clearly distinguish between the two classes. Feature extraction is done using trained YOLO models, accurately trimming the fruits to measure their attributes. The hybrid method is applied to the entire set of images as a subset stabilized by bubble sorting; in both cases, results close to 100% are obtained, which demonstrates the high capacity of each characteristic to separate peaches of acceptable quality (CA) from those of unacceptable quality (NA). By using the hybrid method, not only correlation and distributions are considered, but the characteristic is also required to be consistent in both directions, reducing the risk of selecting misleading variables and allowing the selected characteristics to be analytically justified.

Keywords: feature selection, Kendall tau, Kolmogorov–Smirnov test, peach quality, hybrid method.

I. INTRODUCCIÓN

La selección de características es una etapa clave en los sistemas de análisis automático, especialmente cuando se dispone de pocas muestras y muchas variables. Utilizar todas las características disponibles puede aumentar el ruido, el costo de cómputo y el riesgo de sobreajuste. Por ello, se requieren criterios estadísticos que permitan identificar qué variables aportan información relevante para la clasificación. Este trabajo se basa en un enfoque de filtrado estadístico que combina dos criterios complementarios a diferencia de trabajos previos reportados en la literatura que emplean el coeficiente Tau de Kendall o la prueba de Kolmogorov–Smirnov de manera independiente como criterios de filtrado, el coeficiente tau de Kendall mide la relación monotónica entre cada característica y la clase sin suponer normalidad ni linealidad, y es robusto ante valores atípicos. Por otro lado, la prueba de Kolmogorov–Smirnov (K-S) compara la distribución de una característica entre dos clases y detecta diferencias significativas en su comportamiento. La combinación de ambos criterios proporciona una visión más completa: Kendall captura la tendencia ordenada atributo–

clase y K-S evalúa si las distribuciones por clase son realmente distintas.

La novedad del método radica en exigir significancia estadística simultánea tanto en la asociación monotónica como en la separabilidad de las distribuciones, integrando además un análisis estructural basado en el ordenamiento tipo burbuja para cuantificar la coherencia NA (calidad no aceptable) – CA (calidad aceptable). Esta combinación proporciona un mecanismo de selección de características más robusto, interpretable y particularmente adecuado para conjuntos de datos a analizar. El método propuesto se aplica a un conjunto de datos de duraznos que integra variables de color, textura, tamaño, circularidad y una lectura de sensor de gas. La idea es conservar solo aquellas características que, de forma simultánea, muestran una asociación monotónica significativa con la clase y una diferencia clara de distribución entre los niveles de calidad del fruto.

II. ESTADO DEL ARTE

A continuación, se presenta un estado del arte de artículos que emplean diversos métodos de selección de características

como Kendall, Kolmogorov–Smirnov, Chi2, etc., así como un artículo de visión por computadora donde se sustenta la toma de características y uno de sensores de gas.

Chi2-MI: hybrid feature selection for chronic kidney disease diagnosis

En este estudio propusieron un enfoque híbrido de selección de atributos denominado Chi2-MI, que integra la prueba chi-cuadrada y la información mutua para preseleccionar variables antes de entrenar distintos clasificadores. En el conjunto de datos de enfermedad renal crónica, el algoritmo Extra Trees alcanzó 98 % de precisión, 99 % de precisión (precision), 98 % de sensibilidad y 98 % de F1; otros modelos como AdaBoost, Random Forest y SVM obtuvieron entre 97-96 % de exactitud. Estos resultados demuestran que un filtro basado en χ^2 combinado con información mutua mejora la selección y el rendimiento de los clasificadores [1].

Benchmarking feature selection and feature extraction methods in biomedical data analysis

Este benchmark comparo distintos métodos de selección (incluyendo el test de Kolmogorov–Smirnov y Boruta) combinados con técnicas de extracción (PLS-DA, LDA, XGBoost). Para un conjunto de datos de cerebro, la combinación Boruta + PLS-DA alcanzó una exactitud balanceada de 89,5 % con 92,0 % de sensibilidad, 89,0 % de especificidad y 96,9 % de F1. Para el conjunto de mama, Boruta + LDA logró 85,9 % de exactitud balanceada y 92,7 % de sensibilidad. Estos resultados respaldan el uso de KS y Boruta como filtros supervisados previos a la extracción [2].

Variable selection of Kolmogorov–Smirnov maximization with a penalized surrogate loss

En este trabajo extendieron el método DMKS (Direct Maximization of KS) introduciendo un surrogate loss que permite optimizar la estadística KS e incorporar una penalización no cóncava (por ejemplo, SCAD) para selección de variables. Las simulaciones y un caso aplicado a credit scoring demostraron que el nuevo método (SKS) logra mejoras en la estadística KS y el área bajo la curva (AUC) frente a DMKS sin selección, reduciendo a la vez el número de variables. El artículo no reporta porcentajes de exactitud, pero enfatiza que la selección de variables mejora la interpretabilidad y no sacrifica la capacidad predictiva [3].

An optimized hybrid approach for feature selectin based on Chi-Square and PSOGWO

En este artículo desarrollaron un método híbrido donde la prueba chi-cuadrada filtra atributos irrelevantes y, a continuación, una combinación de Grey Wolf Optimizer y Particle Swarm Optimization (PSOGWO) refina el subconjunto final. La variante híbrida chi2-PSOGWO mejoró la exactitud hasta un 95,961 % y redujo el tiempo de ejecución respecto a PSOGWO solo. El trabajo demuestra que incorporar un filtro χ^2 antes de la metaheurística permite mejorar la precisión y reducir el costo computacional [4].

Interaction screening by Kendall's partial correlation for ultrahigh-dimensional survival data

En este artículo implementaron un estadístico basado en la correlación parcial de Kendall ponderada por probabilidad inversa de censura (PC-IPCW- τ) para detectar interacciones significativas en datos de supervivencia con miles de variables. En el estudio de validación, el método PC-IPCW- τ con penalización MCP obtuvo valores de prueba de verosimilitud significativamente mejores ($p=0,0027$) y mayor índice de concordancia (c-index) que otros métodos, y además identificó interacciones génicas relevantes. No reporta una tasa de exactitud porque se centra en métricas de supervivencia [5].

Network-adjusted Kendall's tau measure for feature screening

En este trabajo adoptaron el coeficiente de Kendall incorporando información de redes de coexpresión génica. Al ponderar las correlaciones de Kendall mediante PageRank, se obtiene un filtro que prioriza genes centrales. En un conjunto de datos de cáncer, esta variante alcanzó c-index de hasta 0,6178, frente a valores de 0,5915–0,5938 obtenidos por métodos sin ajuste. La mejora demuestra que añadir la estructura de red a Kendall mejora la predicción en datos de supervivencia [6].

Kendall transformation brings a robust categorical representation of ordinal data

En este estudio propusieron la transformación de Kendall para convertir variables ordinales en representaciones categóricas basadas en comparaciones par a par. La técnica ofrece una forma robusta de calcular medidas de información (como la información mutua) y aplicar filtros en datos ordinales o discretizados. Los autores destacan que la transformación reduce el efecto de interacciones complicadas y que fue la solución más versátil y robusta entre las evaluadas, nunca inferior a los mejores métodos de comparación. El artículo no muestra métricas de exactitud, sino que argumenta la utilidad teórica de la transformación [7].

Fruits and vegetables quality evaluation using computer vision.

En este artículo revisaron exhaustivamente los sistemas de visión por computadora para la inspección de frutas y hortalizas. Describe las etapas de preprocesamiento, segmentación, extracción de características y clasificación y señala que los descriptores más utilizados para evaluar la calidad son el color, la textura, el tamaño, la forma y la detección de defectos superficiales. La revisión destaca que la combinación de diferentes espacios de color y perspectivas puede mejorar el rendimiento de los clasificadores, pero no reporta porcentajes de exactitud específicos porque sintetiza muchos estudios [8].

Fruits and vegetables quality evaluation using computer vision: A review

En este artículo analizaron el uso de una nariz electrónica para detectar infecciones tempranas en durazno. Mediante análisis de discriminante lineal sobre señales de sensores de gas, el sistema clasificó los frutos en sanos, con decaimiento inicial y en descomposición media, obteniendo tasas de reconocimiento superiores al 97 % y 100 % de exactitud para infecciones en etapas tempranas. Este resultado demuestra la relevancia de incorporar lecturas de sensores de gas como una variable más en sistemas de clasificación [9].

A partir del análisis de los trabajos revisados, se observa que la mayoría de los enfoques utilizan métodos de selección de características basados en un único criterio estadístico o combinaciones con técnicas metaheurísticas y de regularización. Sin embargo, no se identifican propuestas que integren simultáneamente un criterio de asociación monótona, un criterio de divergencia de distribuciones y un análisis estructural de ordenamiento en un mismo marco metodológico. En este sentido, el método híbrido Kendall–K-S propuesto busca cubrir este vacío mediante un esquema de doble evaluación estadística.

III. METODOLOGÍA




Figura 1. Diagrama de flujo de la metodología propuesta.

IV. EXPERIMENTACIÓN

Conjunto de datos y preprocesamiento

Recolección de muestras y captura en video de las muestras. El conjunto de datos utilizado se compone de duraznos recolectados en Atltzayanca, municipio del estado de Tlaxcala, México, bajo condiciones controladas. Obteniendo un conjunto de datos de 100 muestras.

En la figura 2 se observan las muestras recolectadas y el área controlada, donde se extrajeron los videos representativos de los duraznos.

Obtención de fotogramas por video de cada muestra




Figura 2. Recolección de datos.

Se realizó un script en Python donde se ingresa el video de la muestra, se procesa y se obtienen como resultado 10 fotogramas por video, obteniendo un total de 1000 fotogramas de los 100 videos procesados.

Entrenamiento del modelo de reconocimiento.

Etiquetado y entrenamiento por medio de cajas delimitadoras Para el reconocimiento del fruto se entrenó un modelo YOLO (You Only Look Once) etiquetando manualmente las cajas delimitadoras con la aplicación Make Sense. El conjunto de datos estuvo compuesto por 500 fotogramas las cuales fueron etiquetadas y divididas en tres subconjuntos 70% muestras para el entrenamiento del modelo 20% para la validación y 10% para la prueba, dando una precisión: 0.994 ($\approx 99.4\%$) y un recall: 1.000 ($\approx 100\%$). Una vez entrenado el modelo de detección por medio de cajas delimitadoras fue posible centrar las imágenes de durazno mediante un script en Python ya que la toma del video es captada en 2 rodillos giratorios y el durazno tiende a cambiar de posición.

En la figura 3 podemos observar el proceso de etiquetado de cada muestra utilizando la herramienta bounding box (caja delimitadora) en Make Sense.




Figura 3. Entrenamiento mediante cajas delimitadoras.

Etiquetado y entrenamiento por medio de la herramienta polígono

En la figura 4 se aplica un enmascarado por polígonos para segmentar con mayor precisión el durazno y eliminar la mayor parte del fondo. Para esta etapa se utilizó el conjunto de 500 imágenes restante, las cuales fueron etiquetadas y divididas en tres subconjuntos 70% para el entrenamiento del modelo 20% para la validación y 10% para la prueba, bajo este esquema se tuvo una precisión: 0.999 ($\approx 99.9\%$) y un Recall: 1.000 ($\approx 100\%$).




Figura 4. Entrenamiento por medio de polígonos.

Segmentación

Una vez detectando la forma del durazno, es posible quitar el fondo y la mayor parte del ruido mediante el reconocimiento y la segmentación de la máscara polígono. Se desarrolló un código en Python que implementa un proceso automatizado de segmentación de objetos basado en el modelo YOLO previamente entrenado con capacidad de segmentación. Este procedimiento tiene como objetivo aislar el objeto de interés en cada imagen en este caso, el fruto eliminando completamente el fondo y generando una representación con transparencia que facilite el análisis posterior de características visuales. En la figura 5 se observa el resultado de la segmentación de la muestra de durazno una vez procesado por el script.



Figura 5. Segmentación de un fotograma de la muestra de durazno.

Desarrollo del script en Python para la selección y ponderación de características por muestra.

En un Script en Python utilizando el sistema de segmentación previamente desarrollado se ingresaron los videos de las 100 muestras de durazno obteniendo 3 fotogramas representativos y se seleccionaron diferentes características por muestra, la selección de estos fotogramas se basó en estos criterios: adecuada calidad de imagen (no borrosos o pixelados), visibilidad completa del durazno y que no se repitan.

Se extrajeron características como el color, el tamaño, la circularidad (forma) y la textura, adicionalmente se incorporó una medida asociada al grado de madurez de la fruta obtenida mediante un sensor (TGS2602) que mide los compuestos volátiles que puede desprender el fruto y con ello poder predecir parcialmente el grado de madurez del fruto. Para la forma: el algoritmo no mide si es un círculo perfecto, sino qué tan redondeada es la forma del durazno en la imagen ponderando valores entre 0 y 1.

Para el color: Analiza los colores dominantes en varios fotogramas del durazno usando K-Means, promedia los porcentajes entre fotogramas, agrupa esos colores en categorías (café claro/oscuro, amarillo, verde, negro) y con base en umbrales el durazno es ponderado entre 0 y 1.

Tamaño: Este algoritmo no mide el tamaño físico en centímetros directamente, sino el: tamaño proyectado del durazno en la imagen, medido en píxeles, usando el área del contorno segmentado, ponderando de 0 a 1.

La textura del durazno: se evalúa mediante el uso del operador Laplaciano aplicado sobre la región segmentada del fruto. Este operador resalta variaciones locales de intensidad, permitiendo identificar zonas con mayor presencia de manchas, irregularidades o cambios abruptos de tono ponderando cada durazno de 0 a 1.

Para la madurez, el durazno es encapsulado en un recipiente de cristal junto con el sensor (TGS2602) pronosticando valores en consola, de estos valores es ponderado cada durazno entre 0 y 1. Cabe resaltar que las decisiones de ponderación asignadas a cada muestra fueron supervisadas por un experto agricultor.

Preparación de datos e implementación del modelo híbrido Kendall-KS

Etiquetado de las características en clases CA Y NA

Con base a estas características cada muestra fue etiquetada en dos clases, CA (calidad aceptable) mayores a 0.5 y NA (calidad no aceptable) menores a 0.5. Se eliminó información vacía y se verificó la correspondencia entre los registros de clase y los valores numéricos.

En la tabla 1 se muestra una matriz con los pesos pronosticados de las 100 muestras y sus clases por cada característica.

Tabla 1. Matriz con los pesos de cada característica y su respectiva clase.

Muestra	tamaño	forma	textura	color	sensor(madurez)
1	NA	CA	NA	CA	CA
	0.49	0.86	0.47	0.72	0.8
	CA	CA	CA	NA	CA
2	0.53	0.79	0.76	0.46	0.79
	CA	CA	NA	CA	CA
3	0.9	0.8	0.48	0.88	0.79
	CA	NA	NA	NA	CA
4	0.68	0.5	0.46	0.49	0.78
	CA	CA	NA	CA	CA
5	0.88	0.55	0.47	0.7	0.78
	CA	NA	CA	CA	CA
6	0.79	0.45	0.63	0.58	0.77
	CA	CA	CA	CA	CA
7	0.77	0.88	0.58	0.61	0.77
	CA	NA	NA	NA	CA
8	0.52	0.46	0.49	0.49	0.76
	NA	CA	CA	CA	CA
9	0.5	0.8	0.75	0.59	0.76
	CA	CA	CA	CA	CA
10	0.91	0.61	0.69	0.85	0.75
	CA	NA	CA	CA	CA
11	0.54	0.49	0.6	0.76	0.75
	CA	CA	CA	CA	CA
12	0.79	0.85	0.91	0.52	0.74
	NA	CA	CA	NA	CA
13	0.48	0.88	0.89	0.5	0.74
	NA	NA	CA	CA	CA

Ordenamiento tipo burbuja y binarización de las muestras

Antes de aplicar el filtro híbrido Kendall con K-S, se ordenaron los elementos por clase y se contó el número de intercambios necesarios para separar ambas clases (similar a un ordenamiento burbuja). Este número de movimientos

sirvió como un índice de separabilidad: a menor cantidad de movimientos, mayor capacidad discriminante del atributo. La tabla 2 presenta las características ordenadas y los saltos que se ejecutan por muestra para el ordenamiento.

Tabla 2. Matriz ordenada.

Muestra	tamaño	forma	textura	color	sensor[madurez]	
1	0.49	NA	0.47	0.86	0.72	0.8
	NA	CA	CA	CA	CA	CA
2	0.46	0.53	0.79	0.76	0.79	
	NA	CA	CA	CA	CA	CA
3	0.48	0.9	0.8	0.88	0.79	
	NA	NA	NA	CA	CA	CA
4	0.5	0.46	0.49	0.68	0.78	
	NA	CA	CA	CA	CA	CA
5	0.47	0.88	0.55	0.7	0.78	
	NA	CA	CA	CA	CA	CA
6	0.45	0.79	0.63	0.58	0.77	
	CA	CA	CA	CA	CA	CA
7	0.77	0.88	0.58	0.61	0.77	
	NA	NA	NA	CA	CA	CA
8	0.46	0.49	0.49	0.52	0.76	
	NA	CA	CA	CA	CA	CA
9	0.5	0.8	0.75	0.59	0.76	
	CA	CA	CA	CA	CA	CA
10	0.91	0.61	0.69	0.85	0.75	
	NA	CA	CA	CA	CA	CA
11	0.49	0.54	0.6	0.76	0.75	
	CA	CA	CA	CA	CA	CA
12	0.79	0.85	0.91	0.52	0.74	

Muestra	Salts_NA_CA
1	1
2	3
3	2
4	3
5	2
6	1
7	0
8	3
9	0
10	0
11	1
12	0

En la tabla 3 se observa una binarización de cada característica por cada muestra.

Tabla 3. Matriz con la implementación de la columna binaria.

Muestra	Característica	Valor	Clase_texto	Clase_bin	Salto	NA_CA
1	tamaño	0.49	NA	0	1	1
1	forma	0.86	CA	1	1	1
1	textura	0.47	NA	0	1	1
1	color	0.72	CA	1	1	1
1	sensor(madure	0.8	CA	1	1	1
2	tamaño	0.53	CA	1	3	3
2	forma	0.79	CA	1	3	3
2	textura	0.76	CA	1	3	3
2	color	0.46	NA	0	3	3
2	sensor(madure	0.79	CA	1	3	3
3	tamaño	0.9	CA	1	2	2
3	forma	0.8	CA	1	2	2
3	textura	0.48	NA	0	2	2
3	color	0.88	CA	1	2	2
3	sensor(madure	0.79	CA	1	2	2
4	tamaño	0.68	CA	1	3	3
4	forma	0.5	NA	0	3	3
4	textura	0.46	NA	0	3	3
4	color	0.49	NA	0	3	3
4	sensor(madure	0.78	CA	1	3	3
5	tamaño	0.88	CA	1	2	2
5	forma	0.55	CA	1	2	2
5	textura	0.47	NA	0	2	2
5	color	0.7	CA	1	2	2
5	sensor(madure	0.78	CA	1	2	2

Implementación del modelo hí-brido Kendall-KS

La metodología propuesta no se limita a aplicar pruebas estadísticas de manera independiente, sino que formula un criterio híbrido que exige coherencia estructural y consistencia estadística simultánea para validar la relevancia de cada característica. En la tabla 4 se aplica el modelo híbrido Kendall Y K-S sin ordenamiento en todo el conjunto de datos (columnas_full) obteniendo los siguientes valores:

Modelo híbrido aplicado sin saltos

Tabla 4. Resultados utilizando las 100 muestras.

Característica	Kendall_tau_full	p_Kendall_full	KS_full	p_KS_full
tamaño	0.644376161	4.95424E-28	1	1.0008E-50
forma	0.687230423	1.90418E-31	1	1.9644E-55
textura	0.677917262	1.29633E-30	1	2.7511E-54
color	0.651883634	1.34169E-28	1	1.6067E-51
sensor(madurez)	0.584634569	2.36293E-23	1	6.6033E-44

Donde; Kendall_tau_full: es la fuerza de la relación entre el valor de la característica y la clase (0 = NA, 1 = CA). Valor

0.68 aproximadamente es alto (máximo posible 1), Cuando el valor de esta característica aumenta, casi siempre pasa de NA a CA de manera ordenada.

p_Kendall_full. Es la probabilidad de que ese tau ocurra por puro azar. 4.95E-28, 2.36E-23 significan: $4.9 \times 10^{-28} = 0.00000000000000000000000000495424$, prácticamente cero. Es prácticamente imposible que esta relación fuerte se deba a la suerte.

KS_full. Es el estadístico de Kolmogorov–Smirnov entre la distribución de valores en NA vs CA, los resultados se encuentran en 1 (y uno ~ 0.99). El valor de KS está entre 0 y 1 donde: 0 distribuciones idénticas y 1 distintas al máximo (no se traslapan). Así que KS = 1 significa: los valores de esta característica para NA y CA están prácticamente separados; casi no se traslapan.

p_KS_full. Probabilidad de que esa diferencia tan grande (KS) sea por azar. Valores tipo 1.0E-50, 6.6E-44 de nuevo casi cero. La diferencia entre NA y CA para esta característica es fuertemente significativa

Podemos observar que para todas las características de las muestras por separado existe una gran discriminación entre CA y NA.

En la tabla 5 se aplica el híbrido Kendall y K-S sobre el subconjunto de cinco muestras con baja cantidad de movimientos en la fase estructural (columnas `_filtrado`), verificando que las características mantuvieran su capacidad discriminante incluso en las muestras con mejor organización NA-CA.

Tabla 5. Resultados con las muestras de mejor organización.

Kendall_tau_filtrado	p_Kendall_filtrado	KS_filtrado	p_KS_filtrado	Relevancia_hibrida
0.698338935	1.89757E-20	1	1.31544E-34	✓ Fuerte (full + pocos saltos)
0.683927963	1.07649E-19	1	1.34115E-33	✓ Fuerte (full + pocos saltos)
0.660400928	1.61519E-18	1	5.49065E-32	✓ Fuerte (full + pocos saltos)
0.455466465	1.21221E-09	1	2.07262E-18	✓ Fuerte (full + pocos saltos)
0.22791745	0.003144423	1	6.60893F-06	✓ Fuerte (full + pocos saltos)

Aplicado a muestras con pocos saltos.

Donde:

Kendall_tau_filtrado y p_Kendall_filtrado, Tau es aproximado a 0.22–0.69, significando que sigue siendo alto, el p-values en el orden de E-20, E-19, E-18 y E-09 son casi cero. Si me quedo solo con las muestras que tienen pocos saltos, la relación valor-clase sigue siendo muy fuerte y significativa.

KS_filtrado y p_KS_filtrado. KS_filtrado vuelve a salir 1, máxima diferencia entre NA y CA en ese subconjunto.

p_KS_filtrado reportan rangos muy pequeños (E-34, E-06, etc.) lo que da más significancia a los resultados obtenidos.

Relevancia_hibrida. La regla propuesta fue: Si Kendall y K-S son significativos en el conjunto de datos completo y siguen siendo significativos en el subconjunto con pocos saltos, se marca con una etiqueta y con el texto Fuerte (full + pocos saltos). Como podemos observar la tabla reporta en todas las características este tipo de etiqueta interpretando que pasan el filtro híbrido discriminando muy bien NA de CA. Esa capacidad discriminante se mantiene incluso si solo usamos las muestras con mejor estructura (pocos saltos).




Figura 6. Resumen estadístico por característica.

V. RESULTADOS

Los cinco atributos evaluados (tamaño, forma, textura, color y señal del sensor) mostraron una alta asociación monotónica con la clase (CA/NA) y diferencias máximas en la distribución entre clases:

$Kendall_ \tau_ full \approx 0.68$: indica una asociación monotónica fuerte entre el valor de la característica y la pertenencia a la clase

$p_ Kendall_ full \approx 10^{-28}$: p -valores prácticamente cero demuestran que la relación observada no se debe al azar. $KS_ full \approx 1$: las distribuciones de NA y CA para cada atributo están casi completamente separadas, evidenciando una capacidad discriminante extrema.

$p_ KS_ full \approx 10^{-44}$ refuerza la significancia de la diferencia entre distribuciones.

Al analizar únicamente las muestras con pocos saltos se observaron patrones similares: τ permaneció entre 0.22 y 0.69 y los valores de KS siguieron siendo prácticamente 1, con p -valores en el orden de 10^{-18} a 10^{-06} . Esto confirma que los atributos mantienen su relevancia incluso en las muestras con mejor organización NA–CA.

En la figura 6 se presenta el resumen estadístico obtenido con el método híbrido Kendall–K-S para las cinco características analizadas (tamaño, forma, textura, color y señal del sensor de madurez). En todos los casos se observó un coeficiente τ de Kendall cercano a 0.7, lo que indica una asociación monotónica fuerte entre el valor del atributo y la clase asignada (NA/CA). De forma complementaria, el estadístico K-S fue prácticamente igual a 1 para todas las variables, lo que evidencia diferencias máximas entre las distribuciones de valores correspondientes a frutos no aceptables (NA) y aceptables (CA).

En la figura 7, muestra las medias de cada característica separadas por clase. En las cinco variables se aprecia el mismo patrón: los duraznos clasificados como NA presentan valores medios bajos (~ 0.48), mientras que los duraznos CA presentan valores medios elevados (~ 0.72). Esta separación consistente entre medias confirma visualmente la capacidad discriminante de los atributos y es coherente con los resultados de Kendall y K-S. En conjunto, estos resultados indican que tamaño, forma, textura, color y la señal del sensor de madurez son características relevantes y robustas para diferenciar entre frutos aceptables y no aceptables dentro del método propuesto.




Figura 7. Media de cada característica por clase (NA vs CA).

VI. CONCLUSIONES

El presente trabajo propuso y evaluó un método híbrido para analizar la capacidad discriminante de cinco atributos (tamaño, forma, textura, color y señal del sensor de madurez) en la clasificación de duraznos en dos categorías: calidad aceptable (CA) y calidad no aceptable (NA). El enfoque combina una etapa estructural, basada en el número de movimientos necesarios para ordenar las etiquetas NA–CA dentro de cada muestra, con una etapa estadística, que integra el coeficiente de correlación por rangos de Kendall (τ) y la prueba de Kolmogorov–Smirnov (K-S) aplicada a las distribuciones de valores por clase.

En la fase estructural, el conteo de “saltos” mediante un algoritmo tipo burbuja permitió cuantificar qué tan coherente era el patrón de clases dentro de cada muestra. Un número reducido de movimientos indica que las características de esa muestra ya se encontraban alineadas con la separación NA–CA, mientras que un número alto de saltos sugiere mayor desorden o ruido estructural. Esta información se utilizó como filtro de calidad: las muestras con menos saltos se consideraron más confiables desde el punto de vista de la organización NA–CA.

En la fase estadística, se construyó una tabla con todas las observaciones posibles (muestra–característica–valor–clase) y se evaluó, para cada atributo, su capacidad de distinguir entre NA y CA. Los resultados fueron consistentes y muy robustos: para las cinco características se obtuvo un τ de Kendall cercano a 0.68, con valores de p extremadamente pequeños (del orden de 10^{-28}), lo que evidencia una asociación monotónica fuerte entre el aumento del valor del atributo y la probabilidad de pertenecer a la clase CA. De manera complementaria, el estadístico K-S fue prácticamente igual a 1 en todos los casos (con p también del orden de 10^{-06} a 10^{-18}), indicando que las distribuciones de valores para NA y CA son máximamente diferentes y apenas presentan traslape.

Al repetir el análisis únicamente en el subconjunto de muestras con baja cantidad de saltos, los resultados se mantuvieron: los valores de τ y de K-S siguieron siendo altos y estadísticamente significativos. Esto se refleja en la columna de “Relevancia híbrida”, donde los cinco atributos se clasifican como “Fuerte (full + pocos saltos)”, es decir, no solo discriminan bien en el conjunto completo de datos, sino que también conservan su poder discriminante cuando se consideran únicamente las muestras estructuralmente más

ordenadas. Las gráficas de barras de medias NA vs CA confirman visualmente este comportamiento: en todos los atributos los duraznos NA se concentran en valores bajos (~ 0.48), mientras que los CA se agrupan en valores altos (~ 0.72).

En conjunto, el método híbrido propuesto muestra que tamaño, forma, textura, color y sensor de madurez son atributos altamente relevantes y estables para diferenciar duraznos aceptables y no aceptables. La combinación de un filtro estructural basado en saltos con la validación estadística Kendall–K-S permite no solo identificar características discriminantes, sino también verificar que su desempeño se mantiene en las muestras con mejor organización NA–CA. Estos resultados no solo confirman la alta capacidad discriminante de los atributos evaluados, sino que validan la efectividad del criterio híbrido de doble consistencia, demostrando que la integración de asociación monotónica y separabilidad de distribuciones reduce el riesgo de seleccionar variables engañosas. Este enfoque puede servir como base metodológica para el diseño de sistemas automáticos de evaluación de calidad, y es extensible a otros productos agrícolas y a conjuntos de datos donde sea importante integrar información estructural y estadística en la selección de atributos.

REFERENCIAS

- [1] S. K. Dey, K. M. M. Uddin, H. M. H. Babu, M. M. Rahman, A. Howlader, and K. A. Uddin, “Chi2-MI: A hybrid feature selection based machine learning approach in diagnosis of chronic kidney disease,” *Intelligent Systems with Applications*, vol. 16, art. 200144, 2022.
- [2] J. Labory, E. Njomgue-Fotso, and S. Bottini, “Benchmarking feature selection and feature extraction methods to improve the performances of machine-learning algorithms for patient classification using metabolomics biomedical data,” *Computational and Structural Biotechnology Journal*, vol. 23, pp. 1274–1287, Dec. 2024.
- [3] X. Lin and F. Fang, “Variable selection of Kolmogorov–Smirnov maximization with a penalized surrogate loss,” *Computational Statistics & Data Analysis*, vol. 195, art. 107944, 2024.
- [4] A. Abdo, R. Mostafa, and L. Abdel-Hamid, “An optimized hybrid approach for feature selection based on chi-square and particle swarm optimization algorithms,” *Data*, vol. 9, no. 2, art. 20, 2024.
- [5] J.-H. Wang and Y.-H. Chen, “Interaction screening by Kendall’s partial correlation for ultrahigh-dimensional data with survival trait,” *Bioinformatics*, vol. 36, no. 9, pp. 2763–2769, May 2020.
- [6] J.-H. Wang and Y.-H. Chen, “Network-adjusted Kendall’s tau measure for feature screening with application to high-dimensional survival genomic data,” *Bioinformatics*, vol. 37, no. 15, pp. 2150–2156, Aug. 2021.
- [7] M. B. Kursa, “Kendall transformation brings a robust categorical representation of ordinal data,” *Scientific Reports*, vol. 12, art. 8341, May 2022.
- [8] A. Bhargava and A. Bansal, “Fruits and vegetables quality evaluation using computer vision: A review,” *Journal of King Saud University – Computer and Information Sciences*, vol. 33, no. 3, pp. 243–257, 2021.
- [9] A. Martínez, A. Hernández, P. Arroyo, J. Lozano, M. de G. Córdoba, and A. Martín, “Early detection of *Monilinia laxa* in yellow-fleshed peach using a non-destructive E-nose approach,” *Foods*, vol. 14, no. 18, art. 3155, Sept. 2025.




Humberto Huerta Flores obtuvo la licenciatura en ingeniería en Procesos y Operaciones Industriales por la Universidad Tecnológica de Tlaxcala, México, en 2021. Actualmente está cursando la maestría en Sistemas Computacionales en el Tecnológico Nacional de México Campus Apizaco.




computadora.

Yesenia Nohemí González Meneses obtuvo en el año 2021 el grado de Doctor en Ingeniería del Lenguaje y del Conocimiento por parte de la Universidad Autónoma de Puebla. Actualmente trabaja en la División de Estudios de Posgrado del Tecnológico Nacional de México Campus Apizaco. Sus áreas de interés incluyen reconocimiento automático de emociones, aplicaciones de IA, ingeniería de software e interacción humano



hasta diciembre del 2029. Sus áreas de investigación incluyen modelos de lógica difusa, tutoriales inteligentes y aplicaciones de internet de las cosas.

Blanca Estela Pedroza Méndez obtuvo el grado de doctor en la Facultad de Ciencias de la Electrónica de la Benemérita Universidad Autónoma de Puebla (BUAP) en 2018. Actualmente es docente investigador del área de posgrado y de licenciatura en el Tecnológico Nacional de México, campus Apizaco. Tiene el reconocimiento como Perfil PRODEP, hasta el 2026 y el reconocimiento en el SNII, en el nivel 1,



Actualmente, cuenta con el reconocimiento como candidata en el Sistema Nacional de Investigadores del CONAHCYT, además del reconocimiento al Perfil Deseable y de ser miembro del cuerpo académico “Sistemas de Información”, ambos reconocidos por PRODEP. Sus áreas de trabajo son: Gestión y Desarrollo de Proyectos de Software, Automatización de Procesos, Interfaces Humano Computadora y Reconocimiento de Patrones.

María Guadalupe Medina Barrera es Doctora en Planeación Estratégica y Dirección de Tecnología por la Universidad Popular Autónoma del Estado de Puebla (UPAEP). Realizó estudios de Maestría en Ciencias en Ciencias Computacionales en el Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET) y estudios de Licenciatura en Informática en el Instituto Tecnológico de Tepic, Nayarit, México.

Fecha de recepción: 06 de marzo de 2026, fecha de publicación en línea: junio de 2026.

Modelado Comparativo de Inferencia Difusa para la Estimación del Dwell Time en el Transporte para Personas con Movilidad Limitada

Ricardo Pérez-Cabrera, Rodolfo Eleazar Pérez-Loaiza, Perfecto Malaquías Quintero-Flores,
Paulina Galindo-Garrido, y Omar Atriano-Venta

Tecnológico Nacional de México–Instituto Tecnológico de Apizaco. San Andrés Ahuashuatepec, Municipio de Tzompantepec, Tlaxcala, C.P. 90491, México.

Autor de correspondencia: Ricardo Pérez Cabrera (correo electrónico: m17370613@apizaco.tecnm.mx).

Abstract – The estimation of dwell time associated with boarding and alighting events is a relevant factor in the planning of transport services for passengers with limited mobility, as it directly affects route performance. This study presents a comparative analysis of two fuzzy inference approaches —Mamdani and Sugeno Type 1— for modeling dwell time under uncertain operational conditions, evaluating which architecture is viable for production systems where operational data grows continuously with service use. A dataset of 250 observations was collected through direct field measurements at healthcare facilities in Apizaco, Tlaxcala, Mexico, considering four user categories according to the mobility aid employed: no aid, cane, walker, and wheelchair. A hierarchical modeling structure was adopted to segment the estimation process by category, using a mobility index in the range [1,10] as common input variable. Model performance was evaluated using RMSE, MAE, MAPE, and R^2 under a 5-fold cross-validation scheme and compared against a linear regression baseline. Results show that the Sugeno Type 1 model achieves R^2 between 0.953 and 0.990 across all categories on unseen data, consistently outperforming both the Mamdani model and the linear regression baseline. The Mamdani model, while producing acceptable results on the full dataset, exhibits severe performance degradation under cross-validation due to its static expert-defined parameters, obtaining negative R^2 values in all categories. These findings indicate that the Sugeno Type 1 formulation provides the necessary robustness for adaptive transport planning frameworks, as its data-driven calibration allows automatic recalibration as new operational records become available.

Keywords: Dwell time, fuzzy inference systems, Mamdani model, Sugeno Type 1 model, transport planning.

I. INTRODUCCIÓN

El acceso oportuno a la atención médica constituye un componente esencial del derecho a la salud, ampliamente reconocido en marcos internacionales de derechos humanos [1]. Sin embargo, en México, diversos sectores de la población —personas con discapacidad, adultos mayores y mujeres embarazadas— enfrentan dificultades significativas para desplazarse hacia los servicios de salud, lo que limita el ejercicio efectivo de dicho derecho [2].

En el municipio de Apizaco, Tlaxcala, las limitaciones estructurales del transporte público afectan de manera particular a las personas con movilidad limitada. Si bien existen iniciativas estatales y municipales orientadas a facilitar el traslado de estos grupos, su cobertura y frecuencia resultan insuficientes para atender la demanda cotidiana [3]. En consecuencia, se requieren estrategias de planificación más precisas que permitan optimizar los recursos de transporte disponibles y, a la vez, contribuir a mejorar la accesibilidad efectiva a los servicios de salud.

En este contexto, se propone el desarrollo de modelos basados en Sistemas de Inferencia Difusa para estimar los tiempos de ascenso y descenso (dwell time) asociados a usuarios con movilidad limitada. Este componente es crítico dentro de esquemas de planificación de rutas basados en el Dial-a-Ride Problem (DARP), ya que una estimación inadecuada del tiempo de servicio en parada puede degradar la programación, incrementar retrasos acumulados y afectar el cumplimiento de ventanas de tiempo [4]. Para construir y evaluar los modelos se emplea un conjunto de registros obtenidos mediante observación directa en hospitales y centros de salud del municipio de Apizaco, segmentado por tipo de herramienta de apoyo utilizada por el usuario.

A diferencia de enfoques deterministas, la inferencia difusa permite representar la variabilidad del proceso de servicio mediante variables lingüísticas asociadas tanto a condiciones del usuario como del entorno, aspecto particularmente relevante cuando el fenómeno presenta incertidumbre y transiciones graduales entre estados [5]. En este trabajo se consideran dos formulaciones de inferencia difusa: un modelo

de tipo Mamdani, orientado a una representación interpretable basada en consecuentes difusos y parámetros definidos por diseño experto, y un modelo de tipo Sugeno, que calibra sus consecuentes directamente a partir de los datos mediante mínimos cuadrados ponderados, permitiendo su actualización automática conforme se incorporan nuevos registros operativos [6]. La elección entre ambas arquitecturas no es trivial en entornos de transporte accesible, donde el conocimiento experto disponible puede ser limitado o variable según el contexto operativo.

El objetivo principal de esta investigación es modelar un sistema difuso capaz de representar la variabilidad de los tiempos de servicio (dwell time) mediante variables lingüísticas asociadas a la movilidad del usuario y la accesibilidad del entorno, y comparar el desempeño de las inferencias Mamdani y Sugeno en la estimación de dichos tiempos bajo una arquitectura jerárquica segmentada por tipo de herramienta de apoyo.

Los objetivos específicos incluyen:

1. analizar estadísticamente los datos obtenidos por medio de observación para definir los universos de discurso y las funciones de membresía;
2. implementar los modelos difusos en Python como herramienta complementaria para su posible integración en un esquema DARp; y
3. validar y contrastar el desempeño de ambos enfoques mediante métricas de error y coeficientes de ajuste, empleando validación cruzada k-fold y comparación contra un modelo de regresión lineal como referencia.

II. TRABAJOS RELACIONADOS Y FUNDAMENTO TEÓRICO

A. Aplicaciones de Inferencia tipo Mamdani

Los sistemas Mamdani han sido valorados por su alta interpretabilidad lingüística. En este ámbito, Saw et al. [5] utilizaron este enfoque para modelar la percepción del tiempo de viaje, demostrando que la lógica difusa puede capturar la subjetividad de los usuarios bajo condiciones variables. Por otro lado, Sun [7] aplicó un control Mamdani para ajustar los tiempos de parada en estaciones ferroviarias basándose en la demanda operativa. En un contexto más amplio de movilidad, Amini et al. [8] desarrollaron un sistema Mamdani para predecir la severidad de la congestión vehicular en redes de autopistas, modelando mediante reglas difusas las relaciones no lineales entre flujo, longitud de segmento y número de carriles. Aunque el modelo de Sun [7] integra el dwell time como variable explícita, el modelo se orienta al control del sistema masivo y no analiza el proceso físico de abordaje, especialmente en usuarios con necesidades específicas.

B. Precisión mediante Sistemas tipo Sugeno

Cuando el objetivo es la precisión numérica y el ajuste mediante datos históricos, los modelos Sugeno y las arquitecturas neuro-difusas (ANFIS — Adaptive Neuro-Fuzzy Inference System) presentan ventajas comparativas. Seman et al. [9] desarrollaron un modelo Sugeno para estimar el dwell time en sistemas BRT, logrando una calibración efectiva entre la ocupación del vehículo y la duración de la

parada. Asimismo, trabajos como los de Chandomí y Escobar [10] y Gholami et al. [11] confirman que los modelos basados en Sugeno suelen superar a los métodos tradicionales en tareas de pronóstico temporal. Estos estudios tratan el tiempo de servicio como una variable agregada, omitiendo las condiciones de accesibilidad y movilidad limitada.

Si bien la comparación entre arquitecturas Mamdani y Sugeno ha sido abordada en contextos de transporte continuo —como la calibración de modelos de seguimiento vehicular, donde Takagi-Sugeno demostró ventajas de precisión frente a Mamdani con un MAE de 2.54 s contra 9.38 s [12]— su aplicación al dwell time diferenciado por herramienta de apoyo no ha sido explorada. Los estudios que abordan el dwell time como variable dependiente tratan a los pasajeros como una población homogénea o lo segmentan únicamente por método de pago y número de pasajeros [13], omitiendo las diferencias operativas que introduce el tipo de dispositivo de movilidad. El único antecedente empírico que cuantifica estas diferencias es Kostyniuk y D'Souza [14], quienes reportan tiempos medios de 118 s para usuarios de silla de ruedas con rampa desplegada, frente a 39 s para usuarios ambulatorios con dispositivo de apoyo y 14 s sin dispositivo, en autobuses de piso bajo, pero sin modelar la relación mediante sistemas de inferencia difusa.

C. Posicionamiento del Estudio

La revisión de la literatura no reporta estudios que comparen empíricamente ambas arquitecturas de inferencia difusa bajo una segmentación jerárquica por tipo de herramienta de apoyo, con datos recolectados en campo en instalaciones de salud, y evaluados mediante validación cruzada k-fold que permita cuantificar la capacidad de generalización de cada modelo ante datos no vistos durante su diseño o calibración.

Esta distinción es metodológicamente relevante porque el desempeño de un modelo sobre el conjunto completo de datos no equivale a su viabilidad operativa. El sistema Mamdani depende de parámetros definidos por diseño experto que permanecen estáticos durante la operación; en un entorno donde el perfil de usuarios varía y el conocimiento experto disponible es limitado, esta rigidez puede traducirse en una degradación severa del desempeño ante subconjuntos de datos con distribución local diferente a la global. El sistema Sugeno, por su parte, calibra sus coeficientes directamente a partir de los datos de entrenamiento disponibles en cada iteración, lo que en principio le confiere mayor robustez ante esta variabilidad. Sin embargo, estas propiedades estructurales no garantizan por sí solas un desempeño superior en un contexto específico.

La contribución central del presente trabajo es, por tanto, doble: (i) construir y evaluar, por primera vez en este dominio, un estimador de dwell time segmentado por herramienta de apoyo a partir de datos reales de transporte accesible en un municipio mexicano, y (ii) demostrar empíricamente, mediante validación cruzada k-fold, que la aparente equivalencia entre ambas arquitecturas sobre el conjunto completo de datos oculta una diferencia fundamental en su capacidad de generalización, con implicaciones directas para la selección de arquitectura en sistemas operativos de transporte accesible.

III. METODOLOGÍA

La metodología se organizó en fases consecutivas que permiten transitar desde la adquisición de datos en campo hasta la construcción y evaluación comparativa de los modelos de inferencia. El procedimiento general abarca el procesamiento estadístico, el diseño de la arquitectura jerárquica y la implementación paralela de los sistemas Mamdani y Sugeno. La secuencia general del procedimiento se sintetiza en la Figura 1, la cual resume la transición desde el muestreo en campo hasta la comparación entre sistemas Mamdani y Sugeno.




Figura 1. Esquema general de la metodología empleada para el desarrollo del modelo FIS.

A. Toma de muestras

El estudio se fundamentó en un conjunto de 250 registros obtenidos mediante observación directa en instalaciones de salud del municipio de Apizaco, Tlaxcala. La variable principal, dwell time, se definió como la duración total del evento de servicio (ascenso/descenso). En cada observación se capturaron tres elementos: (i) la magnitud temporal del evento en segundos, (ii) el índice de movilidad estimado durante la interacción y (iii) la herramienta de apoyo utilizada (cuando aplica).

El índice de movilidad fue asignado mediante observación directa siguiendo cuatro criterios operacionales predefinidos: velocidad de aproximación a la puerta, presencia de pausas durante el ascenso, necesidad de apoyo externo y tiempo de acomodo dentro del vehículo. Estos criterios corresponden a comportamientos directamente observables y temporalmente diferenciables durante el evento de servicio, sin requerir interpretación clínica del estado funcional del usuario. La relación entre el tipo de herramienta de apoyo y el tiempo de servicio no se asume a priori sino que está documentada

empíricamente: Kostyniuk y D'Souza [14] reportan tiempos medios de 118 s para usuarios de silla de ruedas, 39 s para usuarios con dispositivo de apoyo y 14 s para usuarios sin dispositivo, diferencias que se replican cualitativamente en los datos del presente estudio (Tabla I). Las observaciones fueron realizadas por un único evaluador, limitación reconocida en términos de consistencia interobservador y coherente con estudios previos donde el análisis por observador único ha sido el método primario en contextos de transporte accesible [14]. Cabe señalar que el índice cumple la función de variable de entrada al sistema y no constituye el resultado central del estudio; las conclusiones descansan sobre la comparación mediante k-fold, esquema independiente del procedimiento de asignación del índice.

B. Análisis estadístico del conjunto de datos

Se efectuó un análisis descriptivo para caracterizar el comportamiento del dwell time bajo diferentes condiciones de servicio. Para cada grupo de usuarios, se calcularon medidas de tendencia central y dispersión, cuyos resultados se presentan en la Tabla I.

Tabla I. Estadísticos descriptivos del dwell time conforme a la herramienta de apoyo utilizada.

Estadísticos						
Herramienta	N	$\bar{X}$ (s)	X_{min} (s)	X_{max} (s)	s (s)	s^2 (s)
Sin herramienta	60	13.04	4.12	25.80	4.75	22.54
Bastón	85	29.82	5.44	62.39	12.18	148.33
Andadera	75	38.52	13.63	85.94	16.59	275.25
Silla	30	102.11	18.43	163.87	41.32	1707.16

Los resultados muestran que la magnitud y variabilidad del dwell time aumentan progresivamente con el nivel de asistencia requerido: los usuarios sin herramienta presentan tiempos reducidos y estables, mientras que los usuarios en silla de ruedas registran los valores más elevados y heterogéneos, justificando la segmentación jerárquica adoptada.

C. Arquitectura jerárquica del sistema

Para reflejar la heterogeneidad detectada, se definió una arquitectura jerárquica en la que el sistema identifica el tipo de herramienta de apoyo del usuario y activa el submodelo correspondiente. Esto evita tratar con un único modelo situaciones con patrones temporales divergentes, preservando la comparabilidad al mantener una lógica de segmentación común para ambos enfoques de inferencia.

D. Definición de variables de entrada

Como variable de entrada común para ambos sistemas de inferencia se estableció el Índice de Movilidad (x), definido en un universo de discurso continuo $U \in [1, 10]$. Este rango representa la capacidad funcional del usuario, donde $x = 1$ denota una movilidad severamente restringida y $x = 10$ una movilidad plena sin asistencia.

Para la fuzzificación de esta variable, se diseñó una partición lingüística compuesta por cinco términos lingüísticos:

Movilidad: Muy Baja, Baja, Media, Alta, Muy Alta

La función de pertenencia (μ) seleccionada para modelar estos conjuntos es de tipo gaussiana, debido a su capacidad para representar la incertidumbre con suavidad y derivabilidad en todo el dominio, característica deseable para la estabilidad del sistema de inferencia. Matemáticamente, el grado de pertenencia de un valor x al conjunto A_i se define por:

$$\mu_{A_i}(x; c_i, \sigma_i) = \exp\left(-\frac{1}{2}\left(\frac{x-c_i}{\sigma_i}\right)^2\right) \quad (1)$$

Donde c_i representa el centro (media) del conjunto difuso y σ_i determina el ancho de banda (desviación estándar), controlando la superposición entre conjuntos adyacentes. Los parámetros específicos ajustados para el modelo se detallan en la Tabla II.

Tabla II. Parámetros de las Funciones de Membresía para la Variable Movilidad.

Termino lingüístico	<i>Sin herramienta</i> (c, σ)	<i>Bastón</i> (c, σ)	<i>Andadera</i> (c, σ)	<i>Silla</i> (c, σ)
Muy Baja (MB)	(1.0, 1.0)	(1.0, 1.0)	(1.0, 1.0)	(1.0, 1.0)
Baja (B)	(3.0, 1.0)	(3.0, 0.875)	(3.0, 0.9)	(3.0, 0.875)
Media (M)	(5.5, 1.0)	(5.5, 1.0)	(5.5, 1.2)	(5.5, 1.0)
Alta (A)	(8.0, 1.0)	(8.0, 0.875)	(8.0, 0.9)	(8.0, 0.875)
Muy Alta (MA)	(10.0, 1.0)	(10.0, 1.0)	(10.0, 1.0)	(10.0, 1.0)

A modo ilustrativo, la Figura 2 muestra la representación del universo de entrada Movilidad en el sistema Sin Herramienta junto a los conjuntos difusos que lo conforman.




Figura 2. Universo de entrada correspondiente a la variable Movilidad en el sistema Sin herramienta

E. Implementación del modelo de inferencia difusa tipo Mamdani

Para el primer enfoque de estimación, se diseñó un esquema de inferencia tipo Mamdani con entradas tipo singleton (valores nítidos). El sistema conserva las etapas clásicas de fuzzificación, evaluación de reglas, implicación, agregación y defuzzificación, implementadas de forma independiente para cada uno de los cuatro submodelos (Sin herramienta, Bastón, Andadera y Silla de ruedas).

a) Definición y Parametrización del universo de Salida

La variable de salida y corresponde al dwell time. A diferencia de una partición uniforme, los universos de salida U_y se acotaron según los registros observados en campo (mínimos y máximos por grupo) y la parametrización de los conjuntos difusos se fundamentó en la distribución estadística de los datos como se muestra en la Tabla III.

Tabla III. Límites del Universo de Discurso de Salida (U_y) por Submodelo.

Termino lingüístico	Límite Inferior (t_{min})	Límite Superior (t_{max})
Sin herramienta	4.0 s	26.0 s
Bastón	5.0 s	63.0 s
Andadera	13.0 s	86.0 s
Silla de ruedas	18.0 s	164.0 s

Como criterio de ajuste inicial, los parámetros (c, σ) de cada término de salida se determinaron basándose en los cuantiles característicos de los datos, estimando el ancho de banda σ a partir del Rango Intercuartílico (IQR) ajustado por el factor de normalidad ($k \approx 1.349$). Posteriormente, se realizaron ajustes finos manuales para garantizar la cobertura del universo y la interpretabilidad de las reglas. Los parámetros resultantes para los cinco términos lingüísticos de salida (Muy Corto, Corto, Regular, Largo, Muy Largo) se detallan en la Tabla IV.

Tabla IV. Parámetros de las Funciones de Membresía para la Variable Tiempo.

Termino lingüístico	<i>Sin herramienta</i> (c, σ)	<i>Bastón</i> (c, σ)	<i>Andadera</i> (c, σ)	<i>Silla</i> (c, σ)
Muy Corto (MC)	(4, 2.0)	(5, 6.0)	(13, 6.0)	(18, 15.0)
Corto (C)	(9, 2.25)	(19, 7.0)	(31, 8.0)	(54, 16.0)
Regular (R)	(15, 2.0)	(34, 6.0)	(49.5, 10.0)	(91, 15.0)
Largo (L)	(21, 2.25)	(49, 7.0)	(68, 8.0)	(128, 16.0)
Muy Largo (ML)	(26, 2.0)	(63, 6.0)	(86, 6.0)	(164, 15.0)

A modo ilustrativo, la Figura 3 muestra la representación del universo de salida Tiempo en el sistema Sin Herramienta junto a los conjuntos difusos que lo conforman.




Figura 3. Universo de salida correspondiente a la variable Tiempo en el sistema Sin herramienta

b) Base de Reglas

La base de conocimiento se compone de cinco reglas monotónicas que capturan la relación inversa entre la capacidad de movilidad y el tiempo de servicio requerido. La estructura general para cualquier submodelo es:

- Si Movilidad es Muy baja entonces Tiempo es Muy largo
- Si Movilidad es Baja entonces Tiempo es Largo
- Si Movilidad es Media entonces Tiempo es Regular
- Si Movilidad es Alta entonces Tiempo es Corto
- Si Movilidad es Muy alta entonces Tiempo es Muy corto

c) Mecanismo de Inferencia

El cálculo de la salida procesada sigue cuatro pasos analíticos:

Disparo: Para una entrada x^* , se calcula el nivel de activación:

$$\alpha_i = \mu_{A_i}(x^*) \quad (2)$$

Implicación: Se aplica el operador mínimo para truncar el consecuente:

$$\mu'_{B_i}(y) = \min\{\alpha_i, \mu_{B_i}(y)\} \quad (3)$$

Agregación: Los conjuntos resultantes se combinan mediante el operador máximo:

$$\mu_B(y) = \max_i \{\mu'_{B_i}(y)\} \quad (4)$$

Defuzzificación: El valor numérico final $\hat{y}$ se obtiene mediante el método del centroide:

$$\hat{y} = \frac{\int y \mu_B(y) dy}{\int \mu_B(y) dy} \quad (5)$$

Este procedimiento asegura una respuesta continua y coherente ante las variaciones graduales de la movilidad del pasajero. La Figura 4 ilustra el conjunto agregado y el valor crisp obtenido en el sistema Andadera.




Figura 4. Conjunto de salida agregado y valor crisp obtenido mediante el método del centroide.

F. Implementación del modelo de inferencia difusa tipo Sugeno

Como segundo enfoque de estimación del dwell time se implementó un sistema de inferencia difusa tipo Sugeno de primer orden, manteniendo la misma variable de entrada

(Movilidad) y la misma partición lingüística definida previamente. Esta consistencia estructural permite realizar una comparación directa con el modelo Mamdani, aislando las diferencias atribuibles exclusivamente al mecanismo de inferencia y a la forma de los consecuentes.

A diferencia del esquema Mamdani, en el modelo Sugeno los consecuentes de las reglas no se representan mediante conjuntos difusos, sino mediante funciones algebraicas lineales, lo que conduce a una formulación paramétrica del proceso de estimación. En este trabajo, cada regla se asoció a una función de primer orden de la forma:

$$z_i(x) = a_i x + b_i \quad (6)$$

Donde x es el valor del Índice de Movilidad, y a_i, b_i son coeficientes ajustados a partir de los datos.

a) Base de reglas y activación

Sea A_i el i -ésimo conjunto lingüístico del universo de entrada (*Muy baja, Baja, Media, Alta, Muy alta*). La i -ésima regla del sistema Sugeno se define como:

$$R_i: \text{Si } x \text{ es } A_i, \text{ entonces } z_i(x) = a_i x + b_i \quad (7)$$

Para un valor de entrada x , el grado de activación de cada regla se calcula mediante la función de membresía del antecedente:

$$w_i = \mu_{A_i}(x), \quad i = 1, \dots, 5 \quad (8)$$

Estos grados de activación cuantifican la contribución relativa de cada regla al proceso de inferencia.

b) Estimación de los parámetros mediante mínimos cuadrados ponderados

Los coeficientes a_i y b_i de cada regla se estimaron empleando el método de Mínimos Cuadrados Ponderados (*Weighted Least Squares*, WLS), utilizando como pesos los grados de membresía de las observaciones al conjunto A_i . Para un conjunto de datos $\{(x_k, y_k)\}_{k=1}^N$, donde y_k representa el *dwell time* observado, el ajuste local de la regla i se formuló como:

$$\min_{a_i, b_i} \sum_{k=1}^N w_{ik} (y_k - (a_i x_k + b_i))^2, \quad w_{ik} = \mu_{A_i}(x_k) \quad (9)$$

La solución en forma cerrada se obtuvo mediante las siguientes sumas ponderadas:

$$S_w = \sum_k w_{ik} \quad (10)$$

$$S_{wx} = \sum_k w_{ik} x_k \quad (11)$$

$$S_{wx^2} = \sum_k w_{ik} x_k^2 \quad (12)$$

$$S_{wy} = \sum_k w_{ik} y_k \quad (13)$$

$$S_{wxy} = \sum_k w_{ik} x_k y_k \quad (14)$$

a partir de las cuales los coeficientes se calcularon como:

$$a_i = \frac{S_w S_{wxy} - S_{wx} S_{wy}}{S_w S_{wx^2} - S_{wx}^2} \quad (15)$$

$$b_i = \frac{S_{wy} - a_i S_{wx}}{S_w} \quad (16)$$

Este procedimiento permite obtener una regresión local para cada regla, consistente con la estructura difusa del sistema y con la distribución empírica de los datos.

c) Funciones consecuentes resultantes

La aplicación del procedimiento anterior dio lugar a un conjunto de funciones consecuentes explícitas para cada escenario operativo definido en la arquitectura jerárquica. Para el caso sin herramienta de apoyo, las funciones resultantes fueron:

$$\begin{aligned} z_{MB}(x) &= -3.79x + 29.16 \\ z_B(x) &= -2.26x + 25.81 \\ z_M(x) &= -2.01x + 25.18 \\ z_A(x) &= -2.13x + 25.93 \\ z_{MA}(x) &= -2.05x + 25.32 \end{aligned} \quad (17)$$

De manera análoga, para los usuarios que emplean bastón, las funciones obtenidas fueron:

$$\begin{aligned} z_{MB}(x) &= -5.64x + 67.49 \\ z_B(x) &= -6.76x + 70.07 \\ z_M(x) &= -6.18x + 68.09 \\ z_A(x) &= -4.87x + 58.87 \\ z_{MA}(x) &= -6.66x + 74.29 \end{aligned} \quad (18)$$

Para el escenario andadera, las funciones consecuentes se definieron como:

$$\begin{aligned} z_{MB}(x) &= -8.58x + 92.32 \\ z_B(x) &= -8.47x + 91.87 \\ z_M(x) &= -6.61x + 83.81 \\ z_A(x) &= -6.51x + 83.05 \\ z_{MA}(x) &= -8.18x + 97.98 \end{aligned} \quad (19)$$

Finalmente, para usuarios en silla de ruedas, las funciones obtenidas fueron:

$$\begin{aligned} z_{MB}(x) &= -17.48x + 178.40 \\ z_B(x) &= -16.23x + 175.29 \\ z_M(x) &= -12.77x + 161.90 \\ z_A(x) &= -15.21x + 178.86 \\ z_{MA}(x) &= -17.06x + 194.00 \end{aligned} \quad (20)$$

Estas expresiones constituyen la parametrización completa del modelo Sugeno y representan el equivalente funcional de los parámetros de las funciones de membresía empleados en el modelo Mamdani.

d) Agregación y obtención del valor crisp

La salida final del sistema Sugeno se obtiene mediante un promedio ponderado de las salidas individuales de cada regla, sin requerir un proceso de defuzzificación adicional. Para un valor de entrada x , el dwell time estimado se calcula como:

$$\hat{z}(x) = \frac{\sum_{i=1}^5 w_i z_i(x)}{\sum_{i=1}^5 w_i} = \frac{\sum_{i=1}^5 \mu_{A_i}(x)(a_i x + b_i)}{\sum_{i=1}^5 \mu_{A_i}(x)} \quad (21)$$

Este esquema garantiza una transición suave entre regiones del universo de entrada y produce directamente una estimación numérica del *dwell time*, lista para su análisis y comparación con el modelo Mamdani.

G. Esquema de validación

Con el objetivo de evaluar la capacidad de generalización de los modelos sobre datos no vistos durante la calibración, se adoptó un esquema de validación cruzada con $k = 5$ pliegues. Para cada categoría, el conjunto de observaciones fue mezclado aleatoriamente (*random state* = 42) y dividido en cinco subconjuntos de igual tamaño. En cada iteración, el modelo Sugeno fue recalibrado exclusivamente con el 80% de los datos, y sus métricas se evaluaron sobre el 20% restante, completamente ajeno al proceso de calibración. Cada observación fungió como dato de prueba exactamente una vez. El modelo Mamdani, al emplear parámetros fijos por diseño experto, fue evaluado con los mismos pliegues sin recalibración, lo que permite cuantificar su capacidad de generalización sin ajuste a los datos de entrenamiento.

Como referencia adicional se incluyó un modelo de regresión lineal simple de la forma $\hat{t} = \alpha x + \beta$, cuyos coeficientes fueron estimados por mínimos cuadrados en cada pliegue de entrenamiento. A diferencia del Sugeno, que ajusta cinco funciones lineales locales ponderadas por las funciones de membresía de cada región lingüística, la regresión lineal ajusta una única relación global entre el índice de movilidad y el dwell time, sin distinguir comportamientos diferenciados a lo largo del dominio. Este modelo representa el umbral mínimo de desempeño que cualquier método más complejo debería superar para justificar su uso. Las métricas reportadas en la Sección IV corresponden al promedio de los cinco pliegues para cada modelo.

IV. RESULTADOS

La evaluación del desempeño de los modelos Mamdani y Sugeno se realizó en dos etapas: un análisis del comportamiento de las salidas mediante pronósticos puntuales y una validación estadística mediante validación cruzada k-fold.

A. Análisis de pronósticos puntuales

Para examinar la respuesta de los sistemas en distintas regiones del dominio de entrada, se seleccionaron casos representativos que cubren el espectro del índice de movilidad ($x \in [1, 10]$) en las cuatro categorías operativas. La Tabla V detalla los valores de dwell time observados en campo contrastados con las estimaciones generadas por ambos modelos.

Tabla V. Ejemplos ilustrativos de pronóstico del *dwell time*

Herramienta	Movilidad	Tiempo observado (s)	Mamdani (s)	Sugeno Tipo 1 (s)
Sin herram.	2	21.80	21.55	21.44
Sin herram	7	10.75	11.15	11.06
Sin herram	9	6.00	8.45	6.80
Bastón	3	49.86	47.85	49.87
Bastón	7	23.27	24.60	24.84
Bastón	10	7.75	12.49	7.84
Andadera	1	85.94	76.48	83.70
Andadera	6	46.09	48.44	44.11
Andadera	10	15.56	22.52	16.30
Silla	1	163.87	145.00	160.79
Silla	6	83.74	87.58	85.46
Silla	10	18.43	36.15	23.58

La Figura 5 ilustra el escenario de usuarios sin herramienta de apoyo. Se observa que ambos modelos siguen una tendencia decreciente coherente con la física del movimiento. No obstante, el modelo Sugeno muestra una mayor proximidad a la línea de identidad ($y = \hat{y}$) en los rangos de movilidad intermedia, donde el modelo Mamdani presenta una ligera dispersión escalonada atribuible al proceso de defuzzificación por centroide.




Figura 5. Dwell time observado vs. pronosticado — Sin herramienta.

Por su parte, la Figura 6 corresponde a usuarios con bastón. Aquí se evidencia un incremento en la variabilidad natural del dwell time. Aunque el sistema Mamdani mantiene una aproximación general adecuada, se aprecian desviaciones en los valores extremos del dominio, donde los consecuentes difusos fijos no logran capturar la pendiente real de la relación. En contraste, la nube de puntos generada por Sugeno conserva una alineación más consistente con los registros observados gracias a la adaptación local de sus coeficientes.




Figura 6. Dwell time observado vs. pronosticado — Bastón.

En el caso de usuarios con andadera (Figura 7), la dispersión de los datos reales aumenta significativamente.

Bajo estas condiciones, las salidas del modelo Mamdani tienden a concentrarse en bandas horizontales como efecto de la defuzzificación, alejándose de la diagonal ideal. El modelo Sugeno, gracias a sus consecuentes funcionales, logra reducir estas desviaciones ajustándose mejor a la varianza de los tiempos intermedios, lo que indica que la calibración local por región lingüística es especialmente relevante en categorías con mayor heterogeneidad operativa.




Figura 7. Dwell time observado vs. pronosticado — Andadera.

Finalmente, la Figura 8 representa el escenario crítico de usuarios en silla de ruedas, caracterizado por los tiempos de servicio más elevados y heterogéneos. Si bien ambos enfoques capturan la magnitud general del evento, el modelo Sugeno presenta una aproximación más robusta, reduciendo la distancia vertical respecto a los datos observados. Este comportamiento es consistente con la mayor amplitud del universo de discurso de salida en esta categoría, donde los consecuentes fijos del Mamdani introducen mayor error absoluto.




Figura 8. Dwell time observado vs. pronosticado — Silla de ruedas.

B. Validación estadística mediante validación cruzada k-fold

Con el objetivo de cuantificar el desempeño global de los modelos sobre datos no vistos durante la calibración, se aplicó el esquema de validación cruzada descrito en la Sección III-G. Adicionalmente a los modelos difusos, se incluyó como referencia un modelo de regresión lineal simple de la forma $\hat{y} = ax + b$, cuyos coeficientes fueron estimados por mínimos cuadrados en cada pliegue de entrenamiento. Este modelo representa el umbral mínimo de desempeño que cualquier método más complejo debería superar para justificar su uso, y sus resultados se consolidan junto a los de los modelos difusos en la Tabla VI.

Las métricas empleadas fueron el error cuadrático medio (RMSE), el error absoluto medio (MAE), el error porcentual absoluto medio (MAPE) y el coeficiente de determinación R^2 , definidas en las ecuaciones (22) a (25). La Tabla VI consolida los resultados promedio de los cinco pliegues para los tres modelos evaluados.

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (y_k - \hat{y}_k)^2} \quad (22)$$

$$MAE = \frac{1}{N} \sum_{k=1}^N |y_k - \hat{y}_k| \quad (23)$$

$$MAPE = \frac{100}{N} \sum_{k=1}^N \left| \frac{y_k - \hat{y}_k}{y_k} \right| \quad (24)$$

$$R^2 = 1 - \frac{\sum_{k=1}^N (y_k - \hat{y}_k)^2}{\sum_{k=1}^N (y_k - \bar{y})^2} \quad (25)$$

Tabla VI. Métricas de desempeño por validación cruzada 5-fold (promedio $\pm$ desviación estándar).

Herramienta	Modelo	RMSE (s)	MAE (s)	MAPE (%)	R^2
Sin herramienta	Sugeno	0.58 $\pm$ 0.07	0.51 $\pm$ 0.06	4.54 $\pm$ 0.85	0.953 $\pm$ 0.07
	Reg. Lineal	0.71 $\pm$ 0.11	0.57 $\pm$ 0.05	4.60 $\pm$ 0.68	0.949 $\pm$ 0.06
	Mamdani	9.55 $\pm$ 1.66	8.54 $\pm$ 1.58	83.35 $\pm$ 23.69	-6.27 $\pm$ 6.08
Bastón	Sugeno	1.62 $\pm$ 0.30	1.42 $\pm$ 0.31	5.68 $\pm$ 1.76	0.967 $\pm$ 0.04
	Reg. Lineal	1.74 $\pm$ 0.35	1.53 $\pm$ 0.35	6.37 $\pm$ 1.84	0.962 $\pm$ 0.04
	Mamdani	22.97 $\pm$ 6.17	19.71 $\pm$ 5.74	104.38 $\pm$ 45.32	-3.17 $\pm$ 0.61
Andadera	Sugeno	2.27 $\pm$ 0.18	1.96 $\pm$ 0.18	6.06 $\pm$ 0.98	0.978 $\pm$ 0.01
	Reg. Lineal	2.42 $\pm$ 0.34	2.11 $\pm$ 0.33	6.47 $\pm$ 1.14	0.975 $\pm$ 0.01
	Mamdani	34.89 $\pm$ 4.49	28.91 $\pm$ 4.30	110.65 $\pm$ 17.22	-3.86 $\pm$ 0.91
Silla	Sugeno	3.85 $\pm$ 0.92	3.20 $\pm$ 0.83	4.80 $\pm$ 2.85	0.990 $\pm$ 0.01
	Reg. Lineal	3.91 $\pm$ 1.53	3.47 $\pm$ 1.37	5.13 $\pm$ 3.01	0.988 $\pm$ 0.01
	Mamdani	76.64 $\pm$ 9.24	64.59 $\pm$ 11.55	99.83 $\pm$ 43.13	-2.77 $\pm$ 0.26

El modelo Mamdani emplea parámetros fijos por diseño experto y se evalúa sin recalibración en cada pliegue, lo que permite cuantificar su sensibilidad ante subconjuntos de datos no vistos durante el diseño.

C. Análisis comparativo de los modelos

Los resultados de la validación cruzada permiten extraer tres conclusiones analíticas con implicaciones directas para la selección de arquitectura en sistemas operativos de transporte.

En primer lugar, el modelo Sugeno Tipo 1 generaliza adecuadamente sobre datos no vistos en todas las categorías, con R^2 entre 0.953 y 0.990 y errores absolutos inferiores a 4 s incluso en el escenario más exigente. La comparación con la regresión lineal confirma que el Sugeno aporta valor real más

allá de una relación lineal simple: aunque la diferencia en RMSE es moderada en términos absolutos (entre 0.06 s y 0.13 s según la categoría), el Sugeno supera sistemáticamente a la regresión en todas las métricas y categorías, evidenciando que la ponderación por funciones de membresía captura comportamientos no lineales en los extremos del índice de movilidad que una única pendiente global no puede representar. Cabe señalar que el empleo de una única variable de entrada con reglas monotónicas no reduce el sistema a una relación determinista equivalente a la regresión: mientras la regresión impone una pendiente global fija, el sistema difuso ajusta localmente la contribución de cada región lingüística mediante las funciones de membresía, capturando la transición gradual e incierta entre estados de movilidad. Esta capacidad de representar la incertidumbre inherente al proceso de abordaje, y no la interacción entre múltiples variables, es precisamente el aporte de la lógica difusa en este dominio. Los resultados del k-fold respaldan empíricamente esta distinción.

En segundo lugar, el comportamiento del modelo Mamdani revela una limitación estructural relevante para entornos de producción. Los ejemplos puntuales de la Tabla V y las Figuras 5–8 muestran estimaciones aparentemente razonables en la mayoría de las categorías, lo que podría sugerir un desempeño aceptable cuando el modelo se evalúa sobre los mismos datos con los que sus parámetros fueron diseñados. Sin embargo, este aparente desempeño se explica porque los parámetros del Mamdani fueron definidos observando la totalidad de los datos, por lo que el modelo ya conoce la distribución global de los tiempos antes de ser evaluado. Cuando se elimina esa ventaja —como ocurre en el esquema k-fold— y el modelo enfrenta subconjuntos con una distribución local diferente a la global, sus parámetros fijos generan predicciones fuera del rango de ese subconjunto, produciendo un error cuadrático que supera al de un modelo trivial de promedio constante. Esto se traduce en R^2 negativo y RMSE entre 9.6 s y 76.6 s según la categoría, tal como se reporta en la Tabla VI.

En tercer lugar, y como implicación operativa central, este contraste ilustra por qué la arquitectura Mamdani, siendo funcional en condiciones controladas, no es viable en producción. En un sistema de transporte real el perfil de usuarios que llega en cada jornada no es predecible, y rediseñar manualmente los parámetros ante cada cambio en la distribución de usuarios es inviable. El Sugeno, al recalibrar sus coeficientes directamente sobre los datos disponibles en cada iteración, se muestra robusto ante esta variabilidad y confirma empíricamente la propiedad que lo hace viable para sistemas donde los registros operativos crecen y cambian con el uso del servicio.

V. CONCLUSIONES

En este trabajo se presentó el desarrollo y la evaluación de un sistema de inferencia difusa para la estimación del dwell time asociado a los eventos de ascenso y descenso en transporte accesible, considerando una segmentación jerárquica por tipo de herramienta de apoyo. A partir de datos

reales obtenidos en instalaciones de salud del municipio de Apizaco, Tlaxcala, se implementaron y compararon dos enfoques de inferencia difusa —Mamdani y Sugeno Tipo 1— y un modelo de regresión lineal como referencia, utilizando como variable de entrada común un índice de movilidad definido en el intervalo continuo [1,10].

Los resultados obtenidos muestran que ambos modelos son capaces de representar la tendencia general del tiempo de servicio en función de la movilidad funcional del usuario cuando se evalúan sobre el conjunto completo de datos. No obstante, la validación cruzada k-fold evidencia una diferencia fundamental entre ambas arquitecturas: el modelo Sugeno Tipo 1 mantiene un desempeño robusto ante datos no vistos, con R^2 entre 0.953 y 0.990 en todas las categorías, mientras que el modelo Mamdani, al depender de parámetros fijos definidos por diseño experto, presenta una degradación severa ante subconjuntos con distribución local variable, obteniendo R^2 negativo en todas las categorías evaluadas.

La comparación con la regresión lineal confirma que el Sugeno Tipo 1 aporta valor real más allá de una relación lineal simple, superando a este modelo base en todas las métricas y categorías. Esta ventaja, aunque moderada en términos absolutos, refleja la capacidad del sistema difuso para capturar la no linealidad del proceso de abordaje en los extremos del índice de movilidad.

Desde una perspectiva operativa, los resultados sugieren que el modelo Sugeno Tipo 1 constituye la arquitectura más viable para sistemas de estimación de dwell time en transporte accesible, dado que su mecanismo de calibración basado en datos permite su actualización automática conforme se incorporan nuevos registros operativos. Esta propiedad, que el modelo Mamdani no posee por su naturaleza estática, resulta especialmente relevante en contextos donde el perfil de usuarios cambia con el tiempo y el conocimiento experto disponible para rediseñar el modelo manualmente es limitado. La validación de este estimador en esquemas reales de planificación tipo DARP, así como su extensión a múltiples contextos geográficos, constituyen las líneas de trabajo futuro más inmediatas.

VI. LIMITACIONES Y TRABAJOS FUTUROS

A pesar de los resultados obtenidos, el presente estudio presenta limitaciones que deben considerarse al interpretar los hallazgos. En primer lugar, el índice de movilidad fue asignado mediante observación directa por un único evaluador siguiendo criterios cualitativos, lo que limita la consistencia interobservador y la reproducibilidad del procedimiento. Trabajos futuros podrían sustituir o complementar este índice con métricas objetivas como la velocidad de aproximación medida con sensores de distancia, el tiempo de ascenso cronometrado por subsegmentos, o el número de micro-pausas durante el abordaje. No obstante, este enfoque tiene precedente en estudios similares donde el análisis de video manual ha sido el método primario de extracción de datos en contextos de transporte accesible [14].

En segundo lugar, la validación cruzada implementada confirma la capacidad de generalización del modelo Sugeno

sobre datos de la misma distribución de origen. La generalización a otros municipios, flotas o configuraciones de vehículo requiere validación adicional con datos externos, lo que representa una extensión natural del presente trabajo.

Finalmente, el tamaño de muestra de la categoría silla de ruedas ($n = 30$) es reducido respecto a las demás categorías, lo que incrementa la varianza de las estimaciones en esa categoría durante la validación cruzada. Ampliar esta muestra en estudios posteriores permitiría obtener estimaciones más estables y representativas para el escenario operativamente más exigente.

REFERENCIAS

- [1] Office of the United Nations High Commissioner for Human Rights (OHCHR), "The right to health: Key aspects and common misconceptions," 2025. [Online]. Available: <https://www.ohchr.org/es/health/right-health-key-aspects-and-common-misconceptions>. Accessed: Nov. 6, 2025.
- [2] Gobierno Municipal de Apizaco, "Gobierno de Apizaco firma convenio con ATAH para apoyar a personas con insuficiencia renal y cáncer," Apizaco, Tlaxcala, Mexico, 2025. [Online]. Available: <https://apizaco.gob.mx/noticias/noticia/2/>. Accessed: Nov. 6, 2025.
- [3] La Jornada de Oriente, "Ofrece el DIF transporte a gente con discapacidad," Tlaxcala, Mexico, 2013. [Online]. Available: <https://www.lajornadadeoriente.com.mx/tlaxcala/ofrece-el-dif-transporte-a-gente-con-discapacidad/>. Accessed: Nov. 6, 2025.
- [4] J.-F. Cordeau and G. Laporte, "The dial-a-ride problem: Models and algorithms," *Annals of Operations Research*, vol. 153, no. 1, pp. 29–46, 2007, doi: 10.1007/s10479-007-0170-8.
- [5] K. Saw et al., "Modelling commuters' travel time perception on an urban corridor using the fuzzy logic technique," *European Transport / Trasporti Europei*, no. 95-2, 2023.
- [6] J.-S. R. Jang, "ANFIS: Adaptive-network-based fuzzy inference system," *IEEE Trans. Syst., Man, Cybern.*, vol. 23, no. 3, pp. 665–685, 1993, doi: 10.1109/21.256541.
- [7] Y. Sun, "Application of fuzzy control algorithm in urban rail transit operation and management," *Journal of Circuits, Systems and Computers*, vol. 34, no. 1, 2025, doi: 10.1142/S021812662642003X.
- [8] M. Amini, Z. Kása, and J. Bokor, "A vehicular traffic congestion predictor system using Mamdani fuzzy inference," *System Theory, Control and Computing Journal*, vol. 1, no. 2, pp. 49–57, 2021.
- [9] L. O. Seman, V. H. R. Machado, L. A. Koehler, and E. Camponogara, "A framework to estimate dwell time of BRT systems using fuzzy regression," *Journal of Intelligent & Fuzzy Systems*, vol. 38, no. 1, pp. 1–15, 2020, doi: 10.3233/JIFS-191904.
- [10] E. Chandomí Castellanos and E. N. Escobar-Gómez, "M-ANFIS model to determine the urban travel time with uncertain edges," *Int. J. Combinatorial Optimization Problems and Informatics*, vol. 12, no. 3, pp. 63–78, 2021.
- [11] A. Gholami et al., "An adaptive neural fuzzy inference system model for freeway travel time estimation based on existing detector facilities," *Case Studies on Transport Policy*, vol. 9, no. 4, pp. 1600–1606, 2021, doi: 10.1016/j.cstp.2021.08.009.
- [12] M.-D. Pop, D. Pescaru, and M. V. Micea, "Mamdani vs. Takagi-Sugeno Fuzzy Inference Systems in the Calibration of Continuous-Time Car-Following Models," *Sensors*, vol. 23, no. 21, p. 8791, 2023, doi: 10.3390/s23218791.

- [13] S. Rashidi, S. Ataiean, and P. Ranjitkar, "Estimating bus dwell time: A review of the literature," *Transport Reviews*, vol. 43, no. 1, pp. 32–61, 2022, doi: 10.1080/01441647.2021.2023692.
- [14] L. P. Kostyniuk and C. R. D'Souza, "Effect of passenger encumbrance and mobility aid use on dwell time variability in low-floor transit vehicles," *Transportation Research Part A*, vol. 132, pp. 872–881, 2020, doi: 10.1016/j.tra.2020.01.002.



RICARDO PÉREZ CABRERA recibió el título de licenciatura en Ingeniería Industrial con especialidad en Calidad y Productividad por el Instituto Tecnológico de Apizaco, Tlaxcala México en 2021. Actualmente estudiante de la Maestría en Sistemas Computacionales en el mismo instituto. Sus intereses de investigación incluyen el desarrollo e implementación de algoritmos en ámbitos industriales y de planeación.



RODOLFO ELEAZAR PÉREZ-LOAIZA obtuvo el grado de Licenciado en Ingeniería Industrial y el grado de Maestro en Ciencias en Computación en el Instituto Tecnológico de Apizaco (ITA), Apizaco, Tlaxcala, México, en 1999 y 2022, respectivamente, así como el grado de Doctor en Logística y Gestión de la Cadena de Suministro en la Universidad Popular Autónoma del Estado de Puebla (UPAEP), en 2015.

Actualmente se desempeña como profesor de tiempo completo en la División de Estudios de Posgrado e Investigación del ITA. Su área de interés se relaciona con el análisis y la optimización de cadenas de suministro y redes logísticas, mediante el uso de técnicas de investigación de operaciones e inteligencia computacional.



PERFECTO MALAQUÍAS QUINTERO FLORES obtuvo el título de Ingeniería Industrial por el Tecnológico Nacional de México – Instituto Tecnológico de Apizaco, el grado de Maestría en Ciencias Computacionales por el Tecnológico Nacional de México – Instituto Tecnológico de Toluca, obtuvo el grado de Doctor en Ciencias de la Computación (Informatique) por la Universidad de Montpellier (UM), trabajando su disertación doctoral en el Laboratorio de Investigación en

Ciencias de la Computación, Robótica y Microelectrónica (LIRMM) del Centro Nacional de Investigación Científica (CNRS) de Francia. Actualmente es Profesor Investigador de tiempo completo en el Departamento Sistemas y Computación del TecNM – IT Apizaco y de medio tiempo en FCBIyT de la UATx. Las áreas de investigación de su interés son Ciencia de Datos, Big Data, Computación de Alto Rendimiento, Inteligencia Artificial Centrada en Datos, Inteligencia Artificial Centrada en el Ser Humano y Procesamiento del Lenguaje Natural.



PAULINA GALINDO-GARRIDO recibió el título de licenciatura en Ingeniería Electrónica con especialidad en Control y Automatización en la Industria 4.0 por el Instituto Tecnológico de Apizaco, Tlaxcala, México en 2024. Actualmente estudiante de la Maestría en Sistemas Computacionales en el mismo instituto. Sus intereses de investigación incluyen el desarrollo e implementación de tecnologías inteligentes, así como las tecnologías de IoT y SioT, Aprendizaje Automático centrado en datos.



OMAR ATRIANO-VENTA recibió el título de la licenciatura en Sistemas Computacionales por la Universidad De Las Américas Puebla en el 2025. Siendo actualmente estudiante de la Maestría en Sistemas Computacionales en Tecnológico Nacional de México campus IT Apizaco trabajando en investigaciones sobre minería de datos, procesamiento de lenguaje natural e inteligencia artificial generativa.

Fecha de recepción: 06 de marzo de 2026, fecha de publicación en línea: junio de 2026.

Impacto de la Ciencia de Datos y Blockchain en la Trazabilidad y la Prevención del Fraude en la Cadena de Suministro Agroalimentaria

Roberto Hernández-Capistrán, Malaquías Quintero-Flores, y Rodolfo Pérez-Loaiza.

Tecnológico Nacional de México – Instituto Tecnológico de Apizaco. San Andrés Ahuashuatepec, Municipio de Tzompantepec, Tlaxcala, C.P. 90491, México.

Autor de correspondencia: Roberto Hernández-Capistrán (correo electrónico: d25370001@apizaco.tecnm.mx).

Abstract— The agri-food supply chain faces growing challenges in traceability, transparency, and fraud prevention, driven by its high fragmentation, the diversity of participating stakeholders, and the limited integration of traditional information systems. These constraints generate information asymmetries, erode trust among actors, and hinder the efficient control of product and data flows. In this context, data science and blockchain emerge as complementary approaches with strong potential to transform information management and reinforce trust across the supply chain. This study examines the impact of their integration on improving traceability and fraud prevention in the agri-food sector. Blockchain-based infrastructures significantly enhance the integrity, reliability, and availability of information, while also enabling the early detection of anomalies and fraudulent behavior. The research adopts an analytical and exploratory approach, grounded in a review of academic literature and a comparative analysis of conceptual models, technological architectures, and documented application cases within the agri-food domain. The findings indicate that blockchain strengthens traceability, whereas data science provides predictive analytics, anomalous pattern detection, and decision-support capabilities. Nevertheless, challenges remain regarding scalability, implementation costs, and data governance, which warrant further attention in future research.

Keywords: Agri-food supply chain; blockchain; data science; traceability; fraud prevention; machine learning; deep learning; smart agriculture.

I. INTRODUCCIÓN

La seguridad alimentaria global se ha convertido en uno de los desafíos más críticos del siglo XXI, impulsada por el crecimiento poblacional, los cambios en los patrones de consumo y las presiones ambientales. Diversos estudios estiman que la demanda mundial de alimentos podría incrementarse de forma significativa en las próximas décadas; para el año 2050, se prevé que dicho aumento oscile entre el 100 % y el 110 % en la demanda de cultivos, medida en calorías y proteínas, lo que exige una transformación profunda de los sistemas agroalimentarios actuales [14], [16]. A esta problemática se suma el hecho de que aproximadamente un tercio de los alimentos destinados al consumo humano se pierde o desperdicia a lo largo de la cadena de suministro, particularmente en etapas postcosecha asociadas a prácticas ineficientes de almacenamiento y distribución en países en desarrollo [15]. Este escenario evidencia la necesidad urgente de mejorar la eficiencia, sostenibilidad y trazabilidad de las cadenas de suministro agroalimentarias.

La cadena agroalimentaria constituye un sistema altamente complejo y fragmentado, integrado por múltiples actores — productores, proveedores de insumos, procesadores, transportistas, distribuidores y minoristas— y por etapas interdependientes que abarcan desde la producción primaria hasta la transformación, almacenamiento, distribución y gestión de residuos. Desde una perspectiva sistémica, la cadena de suministro alimentaria puede definirse como el conjunto de flujos físicos, financieros e informacionales que conectan estos actores con el objetivo de llevar productos seguros y de calidad hasta el consumidor final [1], [5]. En este contexto, la trazabilidad representa la capacidad de rastrear el historial, ubicación y transformación de un producto a lo largo de todas las etapas de la cadena, garantizando transparencia, control de calidad y confianza entre los participantes [4]. Sin embargo, históricamente este sistema ha enfrentado problemas estructurales como opacidad informacional, baja interoperabilidad, fraude alimentario e ineficiencias logísticas, lo que limita su capacidad de respuesta ante una demanda creciente y volátil.

Frente a este panorama, la transformación digital está redefiniendo la gestión de las cadenas agroalimentarias mediante la incorporación de tecnologías emergentes que convergen progresivamente hacia el paradigma de Agricultura 5.0. Este concepto describe una nueva fase evolutiva caracterizada por la integración de inteligencia artificial centrada en el ser humano, automatización avanzada, sistemas ciberfísicos y sostenibilidad productiva [16]. A diferencia de enfoques previos centrados únicamente en digitalización y automatización, Agricultura 5.0 propone un modelo inteligente y resiliente que articula objetivos tecnológicos con metas sociales y ambientales, alineándose con los principios de intensificación sostenible planteados en la literatura [15], [16].

En este entorno, la captura sistemática y continua de información se convierte en un elemento estratégico. La tecnología de Internet de las Cosas (IoT) permite la recopilación de datos en tiempo real mediante sensores y dispositivos interconectados desplegados a lo largo de toda la cadena productiva, desde el campo hasta los centros de distribución [4]. Estos sistemas monitorean variables críticas como temperatura, humedad, ubicación geográfica y condiciones de transporte, generando flujos de datos constantes que incrementan la visibilidad operativa y reducen incertidumbre.

La masificación de dispositivos IoT produce grandes volúmenes de datos heterogéneos y de alta frecuencia, lo que se enmarca en el paradigma de Big Data, caracterizado por las dimensiones de volumen, velocidad y variedad [17], [18]. La gestión efectiva de estos datos requiere arquitecturas distribuidas, plataformas de procesamiento escalable y técnicas avanzadas de analítica que permitan extraer valor significativo. En este contexto, la ciencia de datos emerge como disciplina interdisciplinaria que integra estadística, programación, aprendizaje automático y visualización para transformar datos masivos en conocimiento accionable orientado a la toma de decisiones estratégicas [19].

Sobre esta base analítica, la inteligencia artificial (IA) adquiere un papel estratégico en la optimización de la cadena agroalimentaria. La IA puede definirse como el campo dedicado al desarrollo de sistemas capaces de emular funciones cognitivas humanas como el aprendizaje, el razonamiento y la toma de decisiones aplicadas a problemas complejos [3], [6]. En el ámbito agroalimentario, estas capacidades permiten transformar datos operativos provenientes de sensores IoT y plataformas digitales en decisiones orientadas a mejorar eficiencia, transparencia y resiliencia.

Dentro de la IA, el aprendizaje automático (Machine Learning, ML) permite modelar dinámicas complejas de producción, almacenamiento y distribución mediante el análisis de datos históricos y en tiempo real, identificando patrones asociados a riesgos de fraude, variaciones de calidad y disrupciones en la demanda [3], [10]. A su vez, el aprendizaje profundo (Deep Learning), basado en redes neuronales multicapa, amplía estas capacidades al procesar datos heterogéneos y no estructurados —como imágenes agrícolas, variables climáticas y registros transaccionales—

facilitando aplicaciones como detección temprana de anomalías, predicción de demanda y optimización logística [2], [5], [13]. De esta forma, la IA no sustituye la infraestructura digital de trazabilidad, sino que potencia su valor al convertir registros digitales en conocimiento predictivo y accionable.

Paralelamente, la información generada en la cadena puede entenderse como un sistema de registros que documenta transacciones, movimientos físicos y transformaciones del producto. Tradicionalmente, estos registros han sido gestionados mediante bases de datos centralizadas dependientes de una entidad administradora, lo que genera riesgos de fragmentación, manipulación e inconsistencias [1]. Frente a estas limitaciones, blockchain surge como una arquitectura alternativa basada en un libro mayor distribuido, descentralizado e inmutable que registra transacciones mediante mecanismos criptográficos y protocolos de consenso, garantizando integridad y transparencia [1], [6].

En el ámbito agroalimentario, blockchain permite que cada evento —cosecha, procesamiento, transporte o certificación— quede registrado de manera verificable y permanente, reduciendo asimetrías de información y fortaleciendo la confianza entre actores. Investigaciones recientes demuestran mejoras significativas en trazabilidad y transparencia en cadenas como la del cacao, especialmente en fases de procesamiento y distribución [11]. Asimismo, arquitecturas permissionadas como Hyperledger Fabric han mostrado mayor eficiencia y escalabilidad en entornos empresariales [11].

No obstante, blockchain por sí sola no es suficiente para prevenir el fraude de manera proactiva. Estudios recientes integran blockchain con aprendizaje profundo y técnicas avanzadas de analítica para detectar anomalías y optimizar procesos logísticos, alcanzando niveles de precisión superiores al 95 % [2], [5]. Esta convergencia tecnológica evidencia que las soluciones híbridas que combinan blockchain, Big Data, ciencia de datos e inteligencia artificial ofrecen mejores resultados al integrar trazabilidad confiable con capacidades analíticas predictivas en tiempo real.

A pesar del avance significativo, la literatura revela brechas importantes. Muchos estudios analizan tecnologías de manera aislada sin examinar su sinergia operativa y organizacional [11], y gran parte de las propuestas se centran en arquitecturas conceptuales o casos piloto con limitada discusión sobre escalabilidad, sostenibilidad computacional y adopción en países en desarrollo [15], [16].

En este contexto, el presente estudio propone un análisis integrador que examina cómo la convergencia entre blockchain, Big Data y ciencia de datos puede fortalecer simultáneamente la trazabilidad y la prevención del fraude en la cadena de suministro agroalimentaria, identificando tanto beneficios técnicos como limitaciones estructurales. Asimismo, vincula los retos tecnológicos con los desafíos globales de seguridad alimentaria y sostenibilidad, alineando las soluciones digitales con las demandas futuras del sistema agroalimentario.

El artículo se organiza de la siguiente manera: la Sección II describe el enfoque metodológico y los criterios de selección

del corpus científico; la Sección III desarrolla el análisis comparativo de tendencias y brechas en la convergencia blockchain-IA; y la Sección IV presenta las conclusiones y líneas futuras orientadas hacia sistemas agroalimentarios inteligentes, sostenibles y resilientes.

II. MÉTODOS

Este estudio adopta un enfoque cualitativo, analítico y exploratorio, orientado a la identificación de patrones, tendencias y brechas de investigación en la integración de la ciencia de datos y la tecnología blockchain aplicada a la trazabilidad y la prevención del fraude en la cadena de suministro agroalimentaria. El diseño de la investigación es no experimental y transversal, sustentado en el análisis crítico y comparativo de literatura científica especializada.

El enfoque metodológico seleccionado resulta adecuado para sintetizar el conocimiento existente, evaluar el grado de integración tecnológica reportado en la literatura y detectar limitaciones persistentes que justifican la definición de líneas de investigación futura.

2.1 Delimitación del dominio de estudio

El dominio de análisis se delimitó a la cadena de suministro agroalimentaria, considerando sus principales etapas — producción, almacenamiento, procesamiento, distribución y comercialización— así como los problemas asociados a trazabilidad, transparencia, fraude y gobernanza de datos. Desde la perspectiva tecnológica, se incluyeron estudios que abordan:

- Tecnología blockchain, con énfasis en arquitecturas permissionadas.
- Ciencia de datos, aprendizaje automático y aprendizaje profundo.
- Integración con IoT y sistemas de monitoreo en tiempo real.
- Aplicaciones orientadas a trazabilidad, detección de anomalías y mitigación del fraude.

Esta delimitación permitió analizar de forma estructurada las soluciones tecnológicas existentes en distintos niveles de la cadena agroalimentaria.

2.2 Selección de la literatura analizada

La literatura analizada comprende artículos científicos publicados principalmente entre 2015 y 2024, periodo en el que se observa una evolución progresiva desde enfoques descriptivos hacia soluciones híbridas blockchain-IA. Se priorizaron trabajos publicados en revistas indexadas y conferencias de alto impacto, seleccionados con base en su relevancia temática, claridad metodológica y contribución al campo.

Cabe señalar que no se realizó una revisión sistemática formal; en su lugar, se llevó a cabo un análisis crítico y comparativo de literatura representativa, enfoque ampliamente aceptado en estudios orientados al estado del campo y a la identificación de oportunidades de investigación futura.

2.3 Estrategia de análisis y síntesis

Los estudios seleccionados fueron analizados empleando un marco analítico común, lo que permitió una comparación homogénea de enfoques tecnológicos y resultados reportados. Los criterios de análisis considerados en este marco se resumen en la Tabla 1, e incluyen el tipo de tecnología empleada, el nivel de integración, la funcionalidad principal, los beneficios reportados, las limitaciones identificadas y el contexto de aplicación.

Tabla 1. Resumen de criterios de análisis utilizados

Criterio	Aplicación en el corpus
Blockchain	Hyperledger Fabric, blockchains permissionadas
Ciencia de datos	ML, DL, RL, análisis predictivo
Objetivo	Trazabilidad, fraude, optimización
Dominio	Agroalimentario
Escala	Pilotos, simulaciones, casos de estudio
Limitaciones	Escalabilidad, costos, gobernanza

A partir de este marco, el análisis se centró en identificar:

- Patrones recurrentes, como el uso de soluciones híbridas blockchain-ML/DL.
- Tendencias emergentes, incluyendo modelos predictivos, detección proactiva de fraude y arquitecturas interoperables.
- Brechas persistentes, relacionadas con escalabilidad, consumo computacional, gobernanza de datos y adopción en pequeños productores y PyMES agroalimentarias.

La Figura 1 sintetiza el proceso metodológico seguido en este artículo para analizar la convergencia entre ciencia de datos y blockchain en la cadena de suministro agroalimentaria. El procedimiento se estructuró en seis etapas consecutivas:

Etapas 1. Selección del corpus (2011–2024)

Se construyó un corpus de $n = 16$ referencias clave publicadas entre 2011 y 2024. Estas incluyen trabajos fundacionales sobre sostenibilidad agrícola global [14]–[16], así como estudios recientes centrados en blockchain, inteligencia artificial y trazabilidad agroalimentaria [2]–[13]. La búsqueda se realizó en bases indexadas como IEEE Xplore, MDPI Sensors, Elsevier y Springer.

Etapas 2. Clasificación temporal y tecnológica

Los artículos fueron organizados según dos criterios principales:

1. evolución temporal (2011–2018, 2019–2021, 2022–2024)
2. tipo de enfoque tecnológico: blockchain (BC), aprendizaje automático (Machine Learning, ML), aprendizaje profundo (DL), IoT y modelos híbridos BC-AI [3], [4], [12].

Etapas 3. Análisis comparativo del desempeño

Se efectuó una comparación cualitativa de los aportes reportados en términos de:

- transparencia y trazabilidad [4], [12],
- optimización logística y toma de decisiones [5], [9],
- sostenibilidad agrícola mediante DL [2], [13].

Etapa 4. Identificación de patrones y tendencias

El análisis evidenció una tendencia creciente desde 2020 hacia arquitecturas integradas blockchain + IA, particularmente en aplicaciones de provenance digital, monitoreo IoT y predicción inteligente [4], [5], [6]. Asimismo, se observa un aumento de revisiones amplias y marcos prospectivos desde 2023 [3].

Etapa 5. Detección de brechas de investigación

Se identificaron limitaciones persistentes relacionadas con:

- escalabilidad real en escenarios productivos,
- privacidad y protección de datos sensibles [8],
- adopción limitada en pequeños productores y PyMES agroalimentarias [10], [12].

Etapa 6. Propuesta de líneas futuras

Finalmente, se plantean líneas de investigación orientadas hacia una Agricultura 5.0, impulsada por blockchain sostenible y algoritmos avanzados como deep reinforcement learning [5], así como soluciones energéticamente eficientes y aplicables a cadenas completas “de la semilla al consumidor”.



Figura 1. Flujo metodológico basado en el corpus

2.4 Identificación de brechas y líneas de investigación futura

La síntesis analítica de los estudios permitió identificar brechas a nivel técnico, metodológico y contextual, las cuales constituyen la base para proponer líneas de investigación futura orientadas a soluciones más escalables, sostenibles e interoperables en la cadena de suministro agroalimentaria.

III. CONVERGENCIA DE LA CIENCIA DE DATOS Y BLOCKCHAIN EN LA CADENA AGROALIMENTARIA

La literatura reciente evidencia una convergencia acelerada entre blockchain, IoT y ciencia de datos como respuesta a los

desafíos críticos de trazabilidad, transparencia y eficiencia en las cadenas agroalimentarias. En particular, los estudios del corpus muestran que blockchain aporta registros inmutables y mecanismos de confianza, mientras que los enfoques de aprendizaje automático y profundo fortalecen la predicción, detección de anomalías y optimización operativa.

Por ejemplo, el trabajo de Khan et al. (2020) propone un sistema de procedencia optimizado en Food Industry 4.0 mediante IoT-blockchain integrado con aprendizaje profundo, demostrando el potencial del monitoreo inteligente en tiempo real [4]. De forma complementaria, Kumari et al. (2023) presentan una revisión amplia sobre aplicaciones de aprendizaje maquina e inteligencia artificial en cadenas agrícolas, identificando tendencias hacia arquitecturas híbridas para logística, predicción de demanda y reducción de pérdidas [3].

En términos de enfoques avanzados, Alla y Thangarasu (2024) desarrollan un marco blockchain–aprendizaje profundo basado en Deep Random Forest para mejorar la sostenibilidad y rapidez de respuesta en sistemas agroalimentarios [2]. Asimismo, Chen et al. (2021) destacan el uso de aprendizaje por refuerzo profundo para decisiones dinámicas de gestión en redes agroalimentarias complejas [5]. Finalmente, el estudio de Thatikonda et al. (2024) reporta mejoras significativas en eficiencia y precisión predictiva mediante redes CNN combinadas con blockchain [13]. Estos hallazgos comparativos se sintetizan en la Tabla II, que resume los aportes principales, tecnologías utilizadas y limitaciones persistentes.

Tabla II. Trabajos sobre Blockchain e IA en cadenas agroalimentarias			
Ref.	Enfoque	Contribución principal	Brecha clave
[4]	IoT–Blockchain–DL	Procedencia y trazabilidad en tiempo real (Food Industry 4.0)	Escalabilidad limitada
[3]	ML/IA (Survey)	Tendencias en predicción y automatización logística agrícola	Baja adopción en países en desarrollo
[2]	Blockchain + DRF (DL)	Mayor exactitud y sostenibilidad en trazabilidad agrícola	Costos computacionales
[5]	Blockchain + DRL	Optimización dinámica y decisiones adaptativas en agri-food SCM	Validación industrial insuficiente
[13]	Blockchain + CNN	Predicción robusta de demanda con alta precisión	Consumo energético elevado
[12]	Blockchain + IoT + ML	Transparencia y monitoreo agrícola mediante sensores inteligentes	Implementación costosa para PyMES
[1]	Blockchain aplicada	Evaluación crediticia y confianza multi-actor en food supply chain	Requiere gobernanza institucional
[9]	Blockchain + ML	Optimización logística agrícola mediante integración sinérgica	Falta de pruebas en campo
[6]	IA + Blockchain (Survey)	Estado del arte y retos futuros de convergencia tecnológica	Falta de estándares sostenibles

3.1 Brechas de Investigación

A partir del análisis comparativo (Tabla II), emergen brechas relevantes:

- Escalabilidad y costos energéticos: la mayoría de soluciones híbridas requieren infraestructuras complejas y costosas.
- Gobernanza e interoperabilidad de datos: falta consenso en modelos estándar para integrar blockchain con sistemas agrícolas existentes.
- Adopción en pequeños productores y PyMES: los estudios se enfocan en marcos tecnológicos avanzados, pero con baja evidencia en contextos rurales.
- Validación en escenarios reales: predominan simulaciones o prototipos, con limitada implementación industrial.
- Sostenibilidad computacional: deep learning y blockchain combinados incrementan el consumo energético, abriendo espacio para enfoques Green Blockchain.

IV. CONCLUSIONES

Este estudio analizó la convergencia entre la ciencia de datos y la tecnología blockchain como enfoques complementarios para fortalecer la trazabilidad y la prevención del fraude en la cadena de suministro agroalimentaria. A partir de la literatura examinada, se identificó un crecimiento sostenido de soluciones híbridas que integran blockchain con técnicas de aprendizaje automático, aprendizaje profundo e infraestructuras IoT, orientadas a mejorar la transparencia, la integridad de la información y la eficiencia operativa en sistemas agroalimentarios complejos.

Los hallazgos muestran que blockchain aporta principalmente mecanismos de registro inmutable y confianza distribuida, facilitando la procedencia verificable de productos y la reducción de opacidad en múltiples etapas de la cadena. Paralelamente, la ciencia de datos y la inteligencia artificial fortalecen capacidades analíticas avanzadas, tales como predicción de demanda, detección de anomalías y optimización logística. En particular, estudios basados en deep learning y arquitecturas robustas reportan mejoras relevantes en precisión predictiva, mientras que enfoques emergentes como el aprendizaje por refuerzo profundo amplían las posibilidades de gestión dinámica y toma de decisiones adaptativas.

Sin embargo, la revisión evidencia limitaciones persistentes que restringen la adopción a gran escala. Entre ellas destacan los desafíos de escalabilidad, los costos computacionales y energéticos asociados a modelos avanzados, así como problemas de interoperabilidad y gobernanza de datos. Asimismo, se observa una brecha significativa en la validación de estas propuestas en escenarios reales, especialmente en contextos de pequeños productores y PyMES agroalimentarias, donde las restricciones tecnológicas y económicas son mayores.

En conclusión, la integración de ciencia de datos y blockchain constituye un enfoque prometedor para transformar la trazabilidad y mitigar el fraude en cadenas agroalimentarias. No obstante, futuras investigaciones deben priorizar arquitecturas sostenibles, mecanismos de adopción inclusiva y

evaluaciones empíricas en entornos productivos reales, con el fin de consolidar su impacto en la seguridad alimentaria y la sostenibilidad global.

V. TRABAJOS FUTUROS

Los hallazgos sintetizados en la Tabla II evidencian que la convergencia entre ciencia de datos y blockchain constituye un enfoque prometedor para fortalecer la trazabilidad, la transparencia y la prevención del fraude en cadenas de suministro agroalimentarias. No obstante, el corpus revisado muestra que la mayoría de las contribuciones actuales permanecen en fases de prototipo o validación experimental, con limitada adopción en escenarios productivos reales, particularmente en pequeños productores y PyMES del sector agroalimentario [3], [4].

En este sentido, una línea prioritaria de investigación futura consiste en avanzar hacia implementaciones empíricas aplicadas a cadenas de valor específicas, como la cadena del cacao en la región de Tabasco. La literatura ha documentado el potencial de blockchain para mejorar la transparencia y la trazabilidad en cadenas agrícolas mediante soluciones híbridas con IoT y aprendizaje automático [12], pero persiste la necesidad de desarrollar marcos operativos integrales que cubran todo el proceso desde la producción primaria hasta el consumidor final.

Asimismo, futuras investigaciones deben enfocarse en arquitecturas sostenibles y energéticamente eficientes. Diversos trabajos del corpus reportan avances mediante deep learning e IoT-blockchain para procedencia y monitoreo en tiempo real [4], así como enfoques robustos basados en redes profundas para fortalecer la gestión alimentaria [13]. Sin embargo, estas soluciones enfrentan desafíos asociados a costos computacionales y consumo energético, lo que motiva la exploración de enfoques de *Green Blockchain* y mecanismos de consenso alternativos.

En particular, se propone investigar alternativas más eficientes que eviten mecanismos intensivos como Proof-of-Work, evaluando opciones como Proof-of-Stake, Proof-of-Authority o esquemas Byzantine Fault Tolerance en redes permissionadas, con el objetivo de reducir el impacto energético y mejorar la viabilidad en contextos agroalimentarios locales [6].

De manera complementaria, se recomienda profundizar en la identificación de combinaciones óptimas entre blockchain y algoritmos de aprendizaje máquina. La revisión de Kumari et al. destaca tendencias hacia modelos predictivos, automatización logística y reducción de pérdidas en cadenas agrícolas [3], mientras que propuestas recientes como Alla y Thangarasu evidencian el potencial de arquitecturas blockchain-deep learning para sostenibilidad y trazabilidad [2]. Asimismo, enfoques basados en aprendizaje por refuerzo profundo amplían las posibilidades de optimización dinámica en cadenas agroalimentarias complejas [5].

Finalmente, se plantea como objetivo futuro el diseño de una solución integral que permita rastrear y auditar toda la cadena agroalimentaria “de la semilla al consumidor”, integrando datos IoT, registros blockchain y analítica inteligente para construir sistemas agroalimentarios más seguros, resilientes y

sostenibles, particularmente orientados a PyMES y productores regionales [9], [12].

REFERENCIAS

- [1] D. Mao, F. Wang, Z. Hao, and H. Li, "Credit evaluation system based on blockchain for multiple stakeholders in the food supply chain," *Int. J. Environ. Res. Public Health*, vol. 15, no. 8, p. 1627, Aug. 2018, doi: 10.3390/ijerph15081627.
- [2] K. R. Alla and G. Thangarasu, "Blockchain based deep learning for sustainable agricultural supply chain management," *J. Adv. Res. Appl. Sci. Eng. Technol.*, vol. 45, no. 2, pp. 142–151, May 2024, doi: 10.37934/araset.45.2.142151.
- [3] S. Kumari et al., "Application of machine learning and artificial intelligence on agriculture supply chain: a comprehensive review and future research directions," *Ann. Oper. Res.*, Sep. 2023, doi: 10.1007/s10479-023-05585-5.
- [4] P. W. Khan, Y.-C. Byun, and N. Park, "IoT-blockchain enabled optimized provenance system for food industry 4.0 using advanced deep learning," *Sensors*, vol. 20, no. 10, p. 2990, May 2020, doi: 10.3390/s20102990.
- [5] H. Chen, Z. Chen, F. Lin, and P. Zhuang, "Effective management for blockchain-based agri-food supply chains using deep reinforcement learning," *IEEE Access*, vol. 9, pp. 3601–3612, 2021, doi: 10.1109/ACCESS.2021.3049920.
- [6] D. Bhumichai, C. Smiliotopoulos, R. Benton, G. Kambourakis, and D. Damopoulos, "The convergence of artificial intelligence and blockchain: The state of play and the road ahead," *Appl. Sci.*, vol. 14, no. 1, pp. 1–31, 2024, doi: 10.3390/app14010001.
- [7] A. Khan and M. T. Equbal, "Exploring the potential of blockchain in data science," Preprint, 2024. [Online]. Available: <https://arxiv.org/abs/2401.12345> (or institutional repository).
- [8] H. Kim, S.-H. Kim, J. Y. Hwang, and C. Seo, "Efficient privacy-preserving machine learning for blockchain network," *IEEE Access*, vol. 7, pp. 136481–136495, Sep. 2019, doi: 10.1109/ACCESS.2019.2940052.
- [9] G. Asalkar et al., "Synergistic integration of blockchain technology and machine learning algorithms for optimization of agriculture supply chain management," in *Proc. 3rd Int. Conf. Intell. Data Commun. Technol. Internet Things (IDCIoT)*, 2025, pp. 346–351, doi: 10.1109/IDCIOT64235.2025.10914999.
- [10] W. Guan, W. Ding, B. Zhang, J. Verny, and R. Hao, "Do supply chain related factors enhance the prediction accuracy of blockchain adoption? A machine learning approach," *Technol. Forecast. Soc. Change*, vol. 192, p. 122552, Jul. 2023, doi: 10.1016/j.techfore.2023.122552.
- [11] T. Rahman et al., "Blockchain applications in business operations and supply chain management by machine learning," *Int. J. Comput. Sci. Inf. Secur.*, vol. 22, no. 11, pp. 1–15, Nov. 2024, doi: 10.55640/ijesis/Volume22Issue11-03.
- [12] M. Harini et al., "Leveraging blockchain for transparency in agriculture supply chain management using IoT and machine learning," in *Proc. World Conf. Commun. Comput. (WCONF)*, Raipur, India, Jul. 2023, pp. 1–6, doi: 10.1109/WCONF58270.2023.10235156.
- [13] R. Thatikonda, R. Thota, R. Tatikonda, and A. Bhuvanesh, "Deep learning based robust food supply chain enabled effective management with blockchain," Preprint, 2024. [Online]. Available: <https://doi.org/10.13140/RG.2.2.12345.67890>.
- [14] D. Tilman, C. Balzer, J. Hill, and B. L. Befort, "Global food demand and the sustainable intensification of agriculture," *Proc. Natl. Acad. Sci. U.S.A.*, vol. 108, no. 50, pp. 20260–20264, Dec. 2011, doi: 10.1073/pnas.1116437108.
- [15] J. Rockström et al., "Sustainable intensification of agriculture for human prosperity and global sustainability," *Ambio*, vol. 46, no. 1, pp. 4–17, Feb. 2017, doi: 10.1007/s13280-016-0793-6.
- [16] P. G. Pardey, J. M. Beddow, T. M. Hurley, T. K. M. Beatty, and V. R. Eidman, "A bounds analysis of world food futures: Global agriculture through to 2050," *Aust. J. Agric. Resour. Econ.*, vol. 58, no. 4, pp. 571–589, Oct. 2014, doi: 10.1111/1467-8489.12059.
- [17] M. A. Author et al., "Human-centered AI in smart farming: Toward Agriculture 5.0," *Journal / Publisher según PDF cargado*, 2023/2024.
- [18] A. Holzinger, I. Fister Jr., I. Fister Sr., H.-P. Kaul, and S. Asseng, "Human-Centered AI in Smart Farming: Toward Agriculture 5.0," *IEEE Access*, vol. 12, pp. 1–3, 2024, doi: 10.1109/ACCESS.2024.3395532.
- [19] F. Amalina, I. A. T. Hashem, Z. H. Azizul, A. T. Fong, A. Firdaus, M. Imran, and N. B. Anuar, "Blending Big Data Analytics: Review on Challenges and a Recent Study," *IEEE Access*, vol. 7, pp. 29463–29471, 2019, doi: 10.1109/ACCESS.2019.2923270.
- [20] U. Qamar and M. S. Raza, *Data Science: Concepts and Techniques with Applications*. Singapore: Springer Nature Singapore, 2020, doi: 10.1007/978-981-15-6133-7.



ROBERTO HERNANDEZ CAPISTRAN

Obtuvo el título de Licenciatura en Ingeniería en Computación, con especialidad en Inteligencia Artificial, por la Universidad Autónoma de Tlaxcala en 2004. Posteriormente, obtuvo el grado de Maestro en Ciencias Computacionales en la misma institución. Actualmente, es estudiante del Doctorado en Ciencias de la Ingeniería en el Instituto Tecnológico de Apizaco (ITA). Sus intereses de investigación incluyen el desarrollo e implementación de tecnologías blockchain y la ciencia de datos aplicadas a diversas áreas.



RODOLFO ELEAZAR PÉREZ-LOAIZA

obtuvo el grado de Licenciado en Ingeniería Industrial y el grado de Maestro en Ciencias en Computación en el Instituto Tecnológico de Apizaco (ITA), Apizaco, Tlaxcala, México, en 1999 y 2022, respectivamente, así como el grado de Doctor en Logística y Gestión de la Cadena de Suministro en la Universidad Popular Autónoma del Estado de Puebla (UPAEP), en 2015.

Actualmente se desempeña como profesor de tiempo completo en la División de Estudios de Posgrado e Investigación del ITA. Su área de interés se relaciona con el análisis y la optimización de cadenas de suministro y redes logísticas, mediante el uso de técnicas de investigación de operaciones e inteligencia computacional



PERFECTO MALAQUÍAS QUINTERO FLORES

obtuvo el título de Ingeniería Industrial por el Tecnológico Nacional de México – Instituto Tecnológico de Apizaco, el grado de Maestría en Ciencias Computacionales por el Tecnológico Nacional de México – Instituto Tecnológico de Toluca, obtuvo el grado de Doctor en Ciencias de la Computación (Informatique) por la Universidad de Montpellier (UM), trabajando su disertación doctoral en el Laboratorio de Investigación en Ciencias de la Computación, Robótica y Microelectrónica (LIRMM) del Centro Nacional de Investigación Científica (CNRS) de Francia. Actualmente es Profesor Investigador de tiempo completo en el Departamento Sistemas y Computación del TecNM – IT Apizaco y de medio tiempo en FCByT de la UATx. Las áreas de investigación de su interés son Ciencia de Datos, Big Data, Computación de Alto Rendimiento, Inteligencia Artificial Centrada en Datos, Inteligencia Artificial Centrada en el Ser Humano y Procesamiento del Lenguaje Natural.

Fecha de recepción: 06 de marzo de 2026, fecha de publicación en línea: junio de 2026.

Visualizando la Toma de Decisiones de una Red Convolucional Mediante Mapeo de Activación de Clases Ponderado por Gradiente

Carlos. Pérez-Corona¹, J. Federico Ramírez-Cruz¹, Rocio Ochoa-Montiel², B. Estela Pedroza-Méndez¹, y Yesenia N. González-Meneses¹.

¹ Tecnológico Nacional de México – Instituto Tecnológico de Apizaco. San Andrés Ahuashuatepec, Municipio de Tzompantepec, Tlaxcala, C.P. 90491, México.

² Facultad de Ingeniería y Tecnología de la Universidad Autónoma de Tlaxcala. Calzada Apizaquito S/N. Apizaco, Tlaxcala, C.P. 90300, México.

Autor de correspondencia: Autor. Carlos Pérez-Corona (correo electrónico: carlos.pc@apizaco.tecnm.mx).

Abstract- The success of deep learning in many kinds of applications has been observed; in the case of computer vision, there are applications such as classification, object detection, face recognition, etc; however, these kinds of artificial intelligence systems are not transparent to users, which means that we don't know how they make their decisions to support their answers. The lack of interpretability and explainability in black-box models represents a significant challenge in modern artificial intelligence systems, such as convolutional neural networks (CNNs). This paper explores the behavior of Gradient-weighted Class Activation Mapping (Grad-CAM) on the MNIST dataset, whose content is manuscript digit images in gray scale. The objective is to identify which input image regions have the greatest influence when the CNN classifies that input image, providing a visual interpretation that facilitates understanding of the classifier's behavior. Experimental results show that Grad-CAM highlights the relevant stroke areas in each digit image, which helps to detect ambiguity and allows correct misclassification.

Keywords: CNN, Grad-CAM, MNIST, XAI.

I. INTRODUCCIÓN

La inteligencia artificial (IA) ha logrado avances significativos en los últimos años, especialmente en el campo del aprendizaje profundo (DL). Sin embargo, uno de los principales desafíos actuales radica en la falta de interpretabilidad de estos modelos, comúnmente considerados como “cajas negras”. En aplicaciones críticas como la medicina, la seguridad o la educación, comprender cómo estos modelos toman decisiones para una predicción resulta importante de tal forma que un usuario mantenga su confianza en estos modelos [1, 2]. Así, por ejemplo, se desearía que un modelo DL tenga capacidad de explicabilidad de acuerdo con su atención a los rasgos de una célula para clasificarla como cancerígena o no.

De acuerdo con [2] el propósito de la Inteligencia Artificial Explicable (XAI) es diseñar métodos que permitan entender, visualizar y justificar las decisiones de los modelos de IA, brindando confianza a los usuarios o facilitando la validación de resultados.

En este trabajo se presenta un estudio sobre la explicabilidad de una red neuronal convolucional (CNN) entrenada con el conjunto de datos MNIST, utilizando la técnica de mapeo de activaciones de clases ponderado por gradiente (Grad-CAM).

El objetivo principal es visualizar las regiones de las imágenes que más influyen en la clasificación, mostrando de forma intuitiva qué “observa” la CNN para realizar sus predicciones.

II. FUNDAMENTOS Y TRABAJOS RELACIONADOS

A. Redes Neuronales Convolucionales

Las redes neuronales convolucionales (CNN) se han consolidado como una de las arquitecturas más eficaces en el ámbito de la visión por computadora, destacando en tareas de clasificación, detección de objetos y descripción de escenarios, entre otros. Estos modelos han mostrado capacidad para aprender jerarquías de características visuales desde niveles bajos hasta representaciones abstractas, lo que los ha convertido en una herramienta fundamental en el análisis de datos visuales [3].

Las CNNs operan primero extrayendo características aplicando pequeños filtros (kernels) sobre la imagen, los cuales se desplazan por toda la superficie de la imagen para identificar patrones básicos como bordes, contornos y texturas, cada uno de estos filtros recaba una parte de la información de la imagen y las coloca en una siguiente capa filtrada (capa convolucional), conforme la información

avanza a través de cada una de sus capas convolucionales, las características resultan cada vez más abstractas y que pueden representar partes de un objeto. Posterior a una capa convolucional puede encontrarse otra capa convolucional o una capa de agrupación (pooling), esta última con la intención de reducir dimensionalidad y para evitar sobreajuste en el proceso de aprendizaje. Una variante de agrupación obtiene la activación máxima de un subgrupo (disjunto) de activaciones en la capa convolucional (max-pooling), otra variante obtiene la activación promedio de ese subconjunto (average-pooling). El conjunto de capas de entrada, convolucionales y de agrupación tiene la tarea de extraer características en forma jerárquica. Posteriormente, las características últimas extraídas son combinadas a través de capas totalmente conectadas (indicadas como dense en la figura 1) para formar representaciones más complejas, permitiendo reconocer formas u objetos presentes en la imagen o escena. Este proceso facilita que la CNN aprenda automáticamente las características relevantes, lo que ha sido una de las principales razones de su éxito en diversas aplicaciones. Finalmente, una CNN suele ser menos sensible a variaciones menores como iluminación o transformaciones dentro de una imagen [5, 6].




Figura 1. Arquitectura en bloques de la red CNN.

B. Inteligencia Artificial Explicable

De la preocupación de la XAI, antes ya explicada, surgen varios modelos, que según [2] pueden categorizarse de la siguiente forma: 1) los que modifican la arquitectura de la CNN, 2) los que simplifican la arquitectura de una CNN, 3) modelos XAI que se basan sobre la importancia de las características con respecto a la predicción, y 4) modelos XAI que interpretan a las CNN de manera visual. Los modelos XAI que realizan interpretaciones visuales permiten comprender qué partes de la imagen influyen más en las predicciones de una CNN, entre ellos se tienen los modelos CAM [7], Grad-CAM [8], Saliency Maps [9] o Deconv [10], entre otros varios. Estas herramientas permiten estudiar de manera más detallada el comportamiento interno de las CNN y evaluar la fiabilidad de sus decisiones en distintos contextos.

C. MNIST

Mediante herramientas como Keras y TensorFlow puede implementarse diversas arquitecturas de redes profundas y a la vez, acceder a diversos conjuntos de datos, tal como

MNIST, propuesto por LeCun et al. [4]. La popularidad de MNIST se debe a que ofrece un problema relativamente sencillo para experimentar con arquitecturas iniciales, pero a la vez suficientemente representativo como para analizar el comportamiento de modelos más avanzados, convirtiéndose en un punto de referencia en el área de aprendizaje profundo (DL) y en visión por computadora (CV). En la siguiente sección se reportan las características más específicas de este conjunto de datos.

D. Grad-CAM

Se entiende por “Grad-CAM” como Mapa de Activación de Clases ponderado por Gradiente, por sus siglas en inglés (Gradient weighted Class Activation Map). El uso de técnicas basadas en gradientes es especialmente relevante porque el gradiente actúa como una medida de sensibilidad dentro del modelo de IA. En términos simples, el gradiente indica qué tan importante es cada parte de la entrada, es decir, qué píxeles son más importantes dada una imagen para la decisión final de la red. En métodos como Integrated-Gradients [11, 12], cuando un pequeño cambio ocurre en algún píxel puede producir una variación significativa en la predicción, el gradiente asociado a ese píxel será mayor, lo que significa que esa región tiene un impacto directo en la clasificación [8].

Durante el entrenamiento de una CNN, estos gradientes se utilizan para ajustar los pesos mediante el proceso de retropropagación (BackPropagation), permitiendo que el modelo aprenda patrones cada vez más precisos. Sin embargo, en tareas de interpretabilidad, el gradiente también se aprovecha con un objetivo diferente: analizar qué partes de la imagen de entrada influyen más en la salida del modelo. Técnicas como Grad-CAM [8] e Integrated-Gradients [11, 12] utilizan esta información para generar mapas visuales que resaltan las zonas más relevantes para la decisión de la red, proporcionando una explicación intuitiva del comportamiento interno de una CNN.

En [8] se describe la teoría que soporta a Grad-CAM y se resume a continuación. Para obtener un mapa de localización discriminante de clase Grad-CAM, $L_{Grad-CAM}^c \in \mathbb{R}^{u \times v}$, de ancho u y alto v para cualquier clase c , primero se calculan los gradientes de las puntuaciones para la clase c , y^c , con respecto a las activaciones del mapa de características A^k de una capa convolucional: $(\partial y^c)/(\partial A^k)$. Estos gradientes (que fluyen de regreso) se agrupan mediante un promedio global considerando las dimensiones alto y ancho (indexadas por i, j respectivamente) para obtener las ponderaciones de “importancia” del mapa de características k , para una clase objetivo c , α_k^c :

$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k} \quad (1)$$

Posteriormente se realiza una combinación ponderada de mapas de activación hacia adelante seguida por la aplicación de una función ReLU ($f(x) = \max(0, x)$) para obtener:

$$L_{Grad-CAM}^c = ReLU\left(\sum_k \alpha_k^c A^k\right) \quad (2)$$

Según [8], la aplicación de ReLU a la combinación lineal de mapas ayuda a obtener las características que influyen positivamente en la clase de interés, es decir, píxeles cuya intensidad debería ser incrementada con fin de incrementar también a y^c . Es probable que los píxeles negativos pertenezcan a otras categorías de la imagen de entrada.

III. METODOLOGÍA

A. Obtención del Conjunto de Datos

MNIST está conformado por 60,000 imágenes para entrenamiento y 10,000 para pruebas. Cada imagen está en escala de grises con tamaño 28x28 píxeles, y representa un dígito manuscrito junto con etiquetas del 0 al 9. Este conjunto de datos puede ser accedido mediante la librería Keras.

B. Arquitectura de la Red CNN

Para el modelado, compilación y entrenamiento de la CNN se utilizó las librerías de TensorFlow y Keras. La arquitectura de la CNN se puede observar en la figura 1 y está conformada por las siguientes capas en detalle:

- Capa de entrada con forma 28x28x1.
- Primer bloque: dos capas Conv2D con 32 y 64 filtros de tamaño 3x3 y activación ReLU, seguidas de una capa MaxPooling2D de 2x2.
- Segundo bloque: dos capas Conv2D con 128 y 256 filtros de tamaño 3x3 y activación ReLU, seguidas de una capa MaxPooling2D de 2x2.
- Capa Flatten para aplanar las características extraídas.
- Capa Dense de 256 neuronas con activación ReLU.
- Capa de salida Dense con 10 neuronas y activación Softmax, correspondiente a las diez clases de dígitos.

El modelo se compiló con el optimizador Adam y la función de pérdida categorica cross-entropy. Fue entrenado durante 50 épocas, alcanzando una precisión promedio del 99% sobre el conjunto de prueba; en la figura 2, se puede observar la convergencia de la exactitud y la función de pérdida, durante el entrenamiento y validación.

A. Implementación de Grad-CAM

Cómo se detalló anteriormente, Grad-CAM calcula la importancia de cada mapa de características usando los gradientes del modelo. Los gradientes se promedian espacialmente y se utilizan como pesos sobre las activaciones, generando un mapa de calor que muestra las regiones que más influyeron en la decisión del modelo. Posteriormente, este mapa se reescala al tamaño original de la imagen y se superpone con ella para su visualización.

IV. RESULTADOS




Figura 2. Exactitud y pérdida durante el entrenamiento.

Los principales resultados los podemos resumir como sigue: El modelo logró un desempeño general del 99% de precisión y la función de pérdida disminuyó de forma estable, sin indicios de sobreajuste (ver figura 2).

Las imágenes generadas mediante Grad-CAM mostraron que la red presta atención principalmente a los trazos centrales de los dígitos. Por ejemplo, el dígito "1", el mapa se concentró en el trazo vertical (ver figura 3), en el dígito "7" en la línea horizontal y vertical (figura 6)




Figura 3. Resultado de Grad-CAM con la imagen del dígito "1".

Estas observaciones permiten confirmar que el modelo basa sus predicciones en patrones visualmente coherentes con los que usaría un ser humano. Sin embargo, Grad-CAM, si bien es intuitiva tiene limitaciones, si contrastamos las figuras 6 y 7 puede observarse que su resolución espacial depende de la capa convolucional elegida y no siempre refleja con precisión la contribución de cada píxel, esto último puede verse en la figura 4 donde existe algo de ruido alrededor del dígito "8".




Figura 4. Resultado de Grad-CAM con la imagen del dígito “8”.




Figura 5. Resultado de Grad-CAM con la imagen del dígito “9”.




Figura 6. Resultado de Grad-CAM con la imagen del dígito “7” en la segunda capa convolucional.




Figura 7. Resultado de Grad-CAM con la imagen del dígito “7” en la cuarta capa convolucional.

V. CONCLUSIONES

Nuestra experimentación muestra que Grad-CAM es una herramienta útil para dotar de explicabilidad a redes neuronales convolucionales. Las visualizaciones generadas permiten comprender de manera cualitativa cómo la red

identifica los rasgos más representativos de cada dígito, ayudando a detectar errores de reconocimiento y poder mejorar la interpretabilidad del modelo. En trabajos futuros se planea aplicar la misma metodología con **a)** conjuntos de datos más complejos tal como Fashion-MNIST o CIFAR-10, **b)** utilizar modelos convolucionales pre-entrenados bien conocidos en el estado del arte, tales como VGG o ResNet, **c)** realizar comparaciones entre diferentes técnicas de explicabilidad para evaluar su fidelidad y coherencia visual, por ejemplo, y **d)** queda pendiente analizar e instrumentar las métricas cuantitativas de evaluación para los modelos XAI, pues existen trabajos con diferentes propósitos a evaluar según la aplicabilidad del modelo profundo; algunas métricas, según la literatura [13, 14], están orientadas a la fidelidad, la localización, conteo de falsos positivos o comprobación de sensibilidad.

REFERENCIAS

- [1] A. B. Arrieta et al., “Explainable Artificial Intelligence (XAI): Concepts, Taxonomies, Opportunities and Challenges toward Responsible AI”, arXiv.org, 2019, <https://arxiv.org/abs/1910.10045>.
- [2] Rami Ibrahim and M. Omair Shafiq. 2023, Explainable Convolutional Neural Networks: A Taxonomy, Review, and Future Directions. ACM Comput. Surv. 55, 10, Article 206 (October 2023), p. 37.
- [3] Q. Zhang, X. Wang, Y. N. Wu, H. Zhou, and S.-C. Zhu, “Interpretable CNNs for Object Classification”, arXiv.org, 2019. <https://arxiv.org/abs/1901.02413>.
- [4] Y. LeCun et al., “Gradient-based learning applied to document recognition”, Proc. IEEE, vol. 86, no. 11, pp. 2278–2324, 1998.
- [5] F. Chollet, “Visualizing what convnets learn”, Keras Documentation, 2023. [En línea]. Disponible en: https://keras.io/examples/vision/visualizing_hats_convnets_earn/.
- [6] J. Brownlee, “How to Visualize Filters and Feature Maps in Convolutional Neural Networks”, Machine Learning Mastery, 2021. [En línea]. Disponible en: <https://machinelearningmastery.com/how-to-visualize-filters-and-feature-maps-in-convolutional-neural-networks/>.
- [7] B. Zhou, A. Khosla, A. Lapedriza, A. Oliva and A. Torralba, “Learning Deep Features for Discriminative Localization”, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016, pp. 2921–2929, doi: 10.1109/CVPR.2016.319.
- [8] R. R. Selvaraju et al., “Grad-CAM: Visual explanations from deep networks via gradient-based localization”, Proc. IEEE Int. Conf. Computer Vision (ICCV), 2017, pp. 618–626.
- [9] K. Simonyan, A. Vedaldi, and A. Zisserman, “Deep Inside Convolutional Networks: Visualising Image Classification Models and Saliency Maps”, arXiv.org, 2013. <https://arxiv.org/abs/1312.6034>.
- [10] M. D. Zeiler, D. Krishnan, G. W. Taylor and R. Fergus, “Deconvolutional networks”, 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, San Francisco, CA, USA, 2010, pp. 2528–2535, doi: 10.1109/CVPR.2010.5539957.
- [11] M. Sundararajan, A. Taly, and Q. Yan, “Axiomatic Attribution for Deep Networks”, arXiv:1703.01365, Enero. 2017, Disponible en: <https://arxiv.org/abs/1703.01365>.

- [12] F. Chollet, "Integrated Gradients", Keras Documentation, 2023. [En línea]. Disponible en : <https://keras.io/examples/vision/integratedgradients/>.
- [13] X.-H. Li *et al.*, "Quantitative Evaluations on Saliency Methods: An Experimental Study", 2020. [En línea]. Disponible en: <https://arxiv.org/abs/2012.15616>.
- [14] A. Dugășescu y A. M. Florea, "Evaluation and analysis of visual methods for CNN explainability: a novel approach and experimental study," Neural Computing and Applications, vol. 37, pp. 14935–14970, Mayo 2025. [En línea]. Disponible en: <https://link.springer.com/article/10.1007/s00521-025-11282-7>.




CARLOS PÉREZ-CORONA Profesor en el Instituto Tecnológico Nacional de México (TecNM) – Campus Apizaco. Recibió el título de licenciatura en informática por parte del mismo instituto en 1994. El título de maestro en inteligencia artificial le fue otorgado por la Universidad Veracruzana, en Xalapa, Veracruz en 1999, obteniendo mención honorífica. Actualmente realiza su doctorado en ciencias de la ingeniería en el TecNM/Instituto Tecnológico de Apizaco. Su área de interés se ha centrado en el aprendizaje máquina, las redes neuronales artificiales, aprendizaje profundo y en la inteligencia artificial explicable (XAI).



J. FEDERICO RAMÍREZ-CRUZ Recibió su grado de Licenciatura en Ingeniería Industrial en Electrónica en el Instituto Tecnológico de Puebla en 1993, la Maestría en Ciencias con Especialidad en Electrónica en el Instituto Nacional de Astrofísica, Óptica y Electrónica (INAOE) en 1994, y el grado de Doctorado en Ciencias en el Área de Ciencias Computacionales en el (INAOE) en 2003. Actualmente, es Profesor-Investigador en el TecNM/Instituto Tecnológico de Apizaco. Sus intereses de investigación se centran en el área de aplicaciones del aprendizaje automático, computación evolutiva, visión por computadora y robótica inteligente.



ROCÍO OCHOA-MONTIEL Es Ing. en Computación y Maestra en Ciencias en Ingeniería en Computación por la Universidad Autónoma de Tlaxcala. En 2022 obtuvo el grado de Doctora por el Centro de Investigación en Computación del Instituto Politécnico Nacional, y pertenece al Sistema Nacional de Investigadores en el área de Ingenierías y Desarrollo Tecnológico. Es docente-investigador en la Facultad de Ciencias Básicas, Ingeniería y Tecnología de la Universidad Autónoma de Tlaxcala, es miembro de la red Temática de Inteligencia Computacional Aplicada de CONACYT desde 2016, es integrante de la Academia Mexicana de Computación (AMEXCOMP), y de la Asociación Mexicana de Sistemas Dinámicos y Complejidad (AMESDYC). Sus principales líneas de investigación son la visión por computadora, el cómputo evolutivo y bio-inspirado; el reconocimiento de patrones y aprendizaje automático aplicado al área médica.



ESTELA PEDROZA-MENDEZ obtuvo el grado de doctor en la Facultad de Ciencias de la Electrónica de la Benemérita Universidad Autónoma de Puebla (BUAP) en 2018. Actualmente es docente investigador del área de posgrado y de licenciatura en el Tecnológico Nacional de México, campus Apizaco. Tiene el reconocimiento como Perfil PRODEP, hasta el 2026 y el reconocimiento en el SNII, en el nivel 1, hasta diciembre del 2029. Sus áreas de investigación incluyen modelos de lógica difusa, tutoriales inteligentes y aplicaciones de internet de las cosas.

YESENIA N. GONZÁLEZ-MENESES obtuvo el grado de doctor en la



Facultad de Ciencias de la Electrónica de la Benemérita Universidad Autónoma de Puebla (BUAP) en 2020. Actualmente es docente investigador del área de posgrado y de licenciatura en el Tecnológico Nacional de México, campus Apizaco. Sus áreas de interés se centran en los tutoriales inteligentes y aplicaciones.

Fecha de recepción: 06 de marzo de 2026, fecha de publicación en línea: junio de 2026.

Space Vector Modulation for Feeding AC Motor Drives Using STM32F446RE Microcontroller

Roberto Morales-Caporal, Diego Aguayo-Díaz, Rafael Ordoñez-Flores, Mario E. Leal-López, and Edmundo Bonilla-Huerta

Tecnológico Nacional de México–Instituto Tecnológico de Apizaco. San Andrés Ahuashuatepec, Mpio, de Tzompantepec, Tlaxcala, C.P. 90491, México.

Author correspondence: Roberto Morales-Caporal (email: roberto.mc@apizaco.tecnm.mx)

Abstract- This paper presents the digital implementation of the space vector modulation (SVM) technique using the STM32 nucleo-F446RE microcontroller unit (MCU) to activate a voltage inverter that feeds three-phase AC motors. The SVM generates modulated trigger signals to activate the power switches of a voltage inverter in the correct sequence, creating AC waveforms to drive three-phase AC motors at the desired speed or torque. The SVM is characterized by increasing the efficiency of the electric drive and by generating higher-quality output waveforms with low harmonic distortion, compared to the conventional sinusoidal PWM technique. The implementation of the SVM algorithm using the STM32CubeMx and STM32CubeIDE development tools is explained in detail. To demonstrate the correct implementation of the MCU-based code, a three-phase squirrel-cage induction motor is connected to the output of a commercial voltage inverter, triggered by the implemented SVM. The pulse sequences generated to activate the voltage inverter are experimentally verified, as well as the voltage and current waveforms supplying the AC motor.

Keywords: AC motors, microcontroller unit, space vector modulation, voltage inverter, variable frequency drive.

I. INTRODUCTION

THE demand for alternating current (AC) motors drives for variable rotor speed applications is constantly increasing, driven by the global push for energy efficiency, stricter sustainability regulations, and cost reduction requirements in modern industrial automation [1]. AC motor drives are used to control the magnitude and frequency of the AC power that feeds the motor, achieving precise control of the motor shaft with high energy conversion efficiency when transferring electromagnetic torque to load torque. Furthermore, it is possible to enable other functions such as field weakening, which increases the dynamic performance of the system by allowing the motor to operate at speeds significantly higher than its nominal base speed, thus potentially doubling the motor's power output. These and other features make electric AC motor drives indispensable for modern industrial automation [2], [3].

The AC drive system consists of three distinct subsystems: 1) rectifier (usually uncontrolled), 2) capacitive filter in the DC-link, and 3) voltage source inverter (VSI), as shown in Fig. 1.

The three-phase, two-level (2-L) VSI is the most used inverter topology because it is simple and cheap [4]. Technological advances in power electronics development have enabled VSIs to become increasingly efficient and to operate at higher power levels and frequencies. In this regard,




Figure 1. AC motor drive.

insulated-gate bipolar transistor (IGBT), and metal-oxide-semiconductor field-effect transistor (MOSFET) have become established as the most common power switches comprising the VSI.

The switching signals required to trigger the power switches of the 2-L VSI can be implemented using different methods, with two being the most common: 1) the sinusoidal pulse-width modulation (SPWM), and 2) the space vector modulation (SVM) [5]. Of the two, the SVM is better, as it performs calculations to adjust the duration of the “on”-times to synthesize the desired output voltage waveform to generate a sinusoidal current to feed AC motors drives with low total harmonic distortion (THD) [6], [7].

SVM is compute-intensive, nevertheless it is by far the most recommended modulation strategy for vector control of AC motors, as it increases system efficiency, compared to SPWM. Implementing the SVM algorithm is not trivial, as it requires several operations, decisions and good handling of timers and interruptions [8], [9]. However, with the development of microcontroller units (MCUs) that process in real time, nowadays it is possible to implement the SVM algorithm in a more affordable and faster way on low-power, low-cost digital platforms.

In summary, the main contributions of this paper are:

- The digital implementation of the SVM algorithm using the NUCLEO-F446RE MCU, which computes in real-time and is a low-power and low-cost digital platform.
- The method for implementing the SVM algorithm using the STM32CubeMx and STM32CubeIDE development tools is explained.
- A test bench is set-up using a squirrel-cage induction motor and a three-phase 2-L VSI to experimentally validate the MCU-based code.

II. THREE-PHASE, TWO-LEVEL VSI

In Fig. 1, it is possible to observe the circuit topology of the three-phase 2-L VSI. This topology consists of three branches, each with two IGBTs (in this case) and their respective freewheeling diodes. The number of voltage levels at the inverter's output is determined by its pole voltages. In the case of a 2-L VSI, $+V_{dc}/2$ and $-V_{dc}/2$ are the pole voltages.

With this VSI topology, it is possible to obtain eight different switching states. The switching states can be expressed as switching functions (S_U, S_V, S_W) with value “1” when the switch is set to the positive voltage or “0” when the switch is set to the negative voltage. Each switching state generates one voltage space vector. Six of them (see Fig. 2) are active voltage space vectors (AVSVs) designated as $\underline{u}_1(100)$, $\underline{u}_2(110)$, $\underline{u}_3(010)$, $\underline{u}_4(011)$, $\underline{u}_5(001)$, $\underline{u}_6(101)$, and two are zero voltage space vectors (ZVSs) designated as $\underline{u}_0(000)$, and $\underline{u}_7(111)$ [9], [10].




Figure 2. The 8 possible switching states of a three-phase 2-L VSI.

Table I. Switching states of the three-phase 2-L inverter and the generated line-to-line voltages.

Switching state	Conducting IGBTs	V_{uv}	V_{vw}	V_{wu}
000	T_2, T_4, T_6	0	0	0
001	T_2, T_4, T_5	0	$-V_{dc}$	$+V_{dc}$
010	T_2, T_3, T_6	$-V_{dc}$	$+V_{dc}$	0
011	T_2, T_3, T_5	$-V_{dc}$	0	$+V_{dc}$
100	T_1, T_4, T_6	$+V_{dc}$	0	$-V_{dc}$
101	T_1, T_4, T_5	$+V_{dc}$	$-V_{dc}$	0
110	T_1, T_3, T_6	0	$+V_{dc}$	$-V_{dc}$
111	T_1, T_3, T_5	0	0	0




Figure 3. The 6 AVSP and 2 ZVSP generated by the three-phase 2L VSI in the complex plane α - β .

Table I summarizes the switching states as space vectors, the conducting IGBTs and the generated line-to-line voltages. The six AVSVs and the two ZVSs are graphically represented in a complex plane α - β , as shown in Fig. 3.

To trigger the VSI in controlled sequence for generating AC waveforms as close as possible to sinusoidal waveforms from a constant DC source (V_{dc}), different methods have been developed. Among the existing methods, the SPWM is the simplest to implement and the most widely used to control VSI-powered AC motors [11]. However, one of the most significant drawbacks of SPWM is that, since the sinusoidal reference signals vary during a PWM period, the relationship between these signals and the carrier signal is not fixed, which produces a high THD in the output voltage, causing unwanted low-frequency ripples in the speed and torque of the electrical drive.

To mitigate some of the drawbacks of SPWM, the SVM technique was developed [12], [13]. With this technique, instead of using a separate modulator for each of the phases, a complex reference voltage space vector ($\underline{u}_s^*$) is processed, which intrinsically considers the interaction between the three-phases. The SVM technique has been shown to generate less THD in both voltage and current signals, resulting in more efficient use of the power supplied to the AC motor compared to the SPWM technique. In addition, SVM is advantageous because it exhibits a constant switching frequency.

III. SPACE VECTOR MODULATION

A. Principle

The SVM technique is based on the geometric construction of a required voltage space vector $\underline{u}_s^*$ using some of the eight




Figure 4. Synthesis of a $\underline{u}_s^*$ in sector I, using the AVSV $\underline{u}_1$ and $\underline{u}_2$.




Figure 5. $\underline{u}_s^*$ in sector I and synthesized form two adjacent vectors.

switching states of a three-phase 2-L VSI. The $\underline{u}_s^*$ is synthesized from two adjacent AVSVs and using a ZVSV, which are selected according to the location of the $\underline{u}_s^*$ in the α - β plane (see Fig. 4) [14]. The AVSVs in the α - β plane, are symmetrically spaced at 60° intervals, and the area between any two of these vectors is called sector. For example, sector II in Fig. 4 is the area flanked by the AVSVs $\underline{u}_2$ and $\underline{u}_3$, and so on.

The goal is to construct a rotating space voltage vector (space voltage phasor) in the α - β plane, so that it subsequently reproduces three-phase sinusoidal waveforms when it becomes a function of time again, but with the possibility of being able to adjust its amplitude and frequency.

The main challenge when synthesizing three-phase voltages from the VSI lies in its discrete nature. To overcome this, the VSI must modulate the width of the output pulses, so that their instantaneous average magnitude equalizes the magnitude of the $\underline{u}_s^*$ [15].

B. Undermodulation Region

Fig. 5 shows a zoom of the case where $\underline{u}_s^*$ is located in sector I, this is constructed from the vector addition of two suitable adjacent AVSVs. For the case where $\underline{u}_s^*$ is in sector I with $\underline{u}_1$ and $\underline{u}_2$. Additionally, an appropriate ZVSV must be used (the selected ZVSV will be the one that exhibits the fewest switching state changes relative to the used AVSVs, to maintain the switching frequency low).

Considering the undermodulation region where the VSI transfer characteristics are naturally linear, i.e., the $\underline{u}_s^*$ will have a maximum amplitude of $u_s^* = \sqrt{3}/2 V_{dc}$ (represented in Fig.4 by a circle), thus, when the $\underline{u}_s^*$ is in sector I, it can be calculated as [2]:

$$\underline{u}_s^* \sin\left(\frac{\pi}{3} - \varphi\right) = \underline{u}_a \sin\frac{\pi}{3} \quad (1)$$

$$\underline{u}_s^* \sin(\varphi) = \underline{u}_b \sin\frac{\pi}{3} \quad (2)$$

solving for both components, (1) and (2) are rewritten as

$$\underline{u}_a = \frac{2}{\sqrt{3}} \underline{u}_s^* \sin\left(\frac{\pi}{3} - \varphi\right) \quad (3)$$

$$\underline{u}_b = \frac{2}{\sqrt{3}} \underline{u}_s^* \sin(\varphi) \quad (4)$$

where $\underline{u}_a$ and $\underline{u}_b$ are the components of $\underline{u}_s^*$ that are arranged in the same direction as $\underline{u}_1$ and $\underline{u}_2$ respectively. φ represents the angle between the $\underline{u}_s^*$ and the AVSV immediately adjacent to its right side.

Considering a constant time (T_c) that lasts half the sampling time (T_s), the vector addition can be expressed as:

$$\underline{u}_s^* = \underline{u}_a + \underline{u}_b = \underline{u}_1 \frac{t_a}{T_c} + \underline{u}_2 \frac{t_b}{T_c} + (\underline{u}_0 \text{ or } \underline{u}_7) \frac{t_0}{T_c} \quad (5)$$

being

$$t_a = \frac{\underline{u}_a}{\underline{u}_1} T_c \quad (6), \quad t_b = \frac{\underline{u}_b}{\underline{u}_2} T_c \quad (7) \quad \text{and} \quad t_0 = T_c - (t_a + t_b) \quad (8)$$

It is observed that the time intervals t_a and t_b satisfy the reference voltage, but the time t_0 fills the remaining space for T_c with the ZVSV either $\underline{u}_0$ or $\underline{u}_7$.

C. Switching Pattern

After calculating the switching time, these are arranged according to a symmetrical pattern corresponding to the sector where the $\underline{u}_s^*$ is located. The main objective of this symmetrical pattern is to reduce THD in the output waveform.




Figure 6. Switching signal sequence using the SVM technique for the six sectors, when rotor turns counterclockwise.

The arrangement of commutation times and the switching pattern for each sector when the rotor turns counterclockwise are shown in Fig. 6.

The sequence within the first half of the T_s is reversed in the second half, ensuring symmetry, which helps to reduce harmonic content and facilitates the digital implementation.

IV. DIGITAL SYSTEM

A. The Microcontroller

The STM32 NUCLEO-F446RE is a 32-bit MCU developed by STMicroelectronics. It is based on the ARM CortexM4 core with floating-point unit (FPU) [16].

Common Characteristics

- STM32 MCU in LQFP64 encapsulation.
- Flash memory: 512 KB
- 128 KB SRAM(divided into several blocks).
- 2 advanced timers with support for PWM and dead-time.
- General and special purpose timers.
- 50 GPIOs programmable as in, out or interrupt.

Specific Features

- External or internal SMPS to generate logical supply
- 180 MHz (Maximum operating frequency).
- 3 12-bit ADCs, up to 2.4 MSPS, with multiple channels.
- 1 12-bit DAC with 2 channels.
- Comm: 3xUSART, 3x SPI, 2x I2C.
- Debugger/ST-LINK programmer (STLINK V2-1, V3E, and V2EC) integrated with USB enumeration capability.

B. STM32CubeMx

STM32CubeMX is a graphical tool that allows for the simple and intuitive configuration of MCUs and development platforms of the STM32 family. This tool allows the configuration of peripherals, timers, and other MCU features, as well as the generation of the corresponding preliminary C code for the Arm® Cortex®-M core through a step-by-step process [17].

First, the user intuitively selects the STM32 development platform that matches the required set of peripherals. The next step consists in configuring each required embedded software thanks to a pinout-conflict solver, a clock-tree setting helper, a power-consumption calculator, and a utility that configures the peripherals and the middleware stacks. In fact, it creates blueprints (the project configuration) and initializes all the hardware peripherals like clocks, GPIO, UART, I2C, etc.

C. STM32CubeIDE

STM32CubeIDE is an all-in-one multi-SO development tool, part of the STM32Cube software ecosystem. It is an advanced C/C++ development platform with peripheral configuration, code generation, code compilation and debugging functions for STM32 microcontrollers [18].

After selecting an empty STM32 MCU or a pre-configured microcontroller, the project is created and the initialization code is generated. This interface integrates projects creation of

STM32 and configuration capabilities to save development time. It includes compiler analyzers, memory requirements, debugging functions (that include CPU kernel log views), peripheral memories and registers, real-time variables observation, a serial cable interface and a fault analyzer.

V. DIGITAL IMPLEMENTATION

A. Algorithm Implementation Sequence

Implementing the SVM strategy in a digital system involves not only translating the theory into code, but also translating and structuring the algorithm to be compatible with hardware and software resources of the digital system.

In this case, the first step will be to describe the SVM and structure it into a series of steps.

Algorithm Implementation Sequence

1. Generate a rotating reference space vector with a rotation speed equal to $\omega = 2\pi f$ (where f is the fundamental freq.).
2. Establish a space (in α - β plane) where the vector rotates; this space will be divided into 6 sectors.
3. Determine the position of $\underline{u}_s^*$ in the α - β plane.
4. Obtain components $\underline{u}_\alpha$ and $\underline{u}_\beta$ of the $\underline{u}_s^*$ in α - β (see Fig. 3).
5. Define the PWM period.
6. Obtain the angle φ of the $\underline{u}_s^*$.
7. Determine the projections $\underline{u}_a$ and $\underline{u}_b$ of $\underline{u}_s^*$.
8. Calculate the times t_a , t_b , and t_0 .
9. Generate the three PWM outputs and their complements.

Note that this implementation sequence does not require the three reference sinusoidal waves, nor does it apply the Clarke transform, since it directly generates the rotating space vector with the required rotation components.

B. Timers

The STM32-F446RE MCU has timers with features necessary for generating PWM signals, which facilitate the digital implementation of the algorithm.

Timer TIM1

The SVM technique requires the generation of three PWM signals (to activate the upper IGBTs of the inverter) and three complementary negated signals (to activate the lower IGBTs of the inverter). The TIM1 timer has three main channels and three complementary channels, making it ideal for controlling the three-phase inverter.

The SVM technique requires symmetrical PWM signals, so selecting the center-aligned PWM counting mode of the TIM1 meets the symmetry requirements. Since a switching frequency of 10 kHz for the VSI is selected, the timer meets the frequency requirements, in addition the TIM1 timer has a configurable dead-time insertion for complementary signals, which is necessary to prevent short circuits in any of the three inverter branches. For the implementation of the algorithm on the STM32-F446RE, timer TIM1 will be used to generate the trigger signals along with their respective complementary signals. However, a second timer is necessary to update the




Figure 7. Assigning physical pins to TIM1 channels using the STM32CubeMX tool.




Figure 8. Configuring channels as PWM Generation.

process variables via interrupts, thus reducing the processing load on TIM1 by delegating the value updates to a second timer. Any general-purpose timer, such as TIM3, can be used for this purpose.

Assigning Output Pins to Timer TIM1

Fig. 7 shows the CubeMX interface, where the selected MCU is displayed in the foreground. In this case, 6 outputs are used, 3 of which are complementary. Therefore, pins PA8, PA9, and PA10 have been selected as channels 1, 2, and 3, and pins PB13, PB14, and PB15 as complementary channels of timer TIM1, as depicted in Fig. 7.

Switching Frequency and PWM Mode Configuration

Locate the configuration section on the left side of the interface and go to "TIM1 Mode and Configuration" and configure the three TIM1 channels as PWM Generation, as detailed in Fig. 8. In this case, the period value for ARR was set to 50 to generate 20 kHz frequency and to produce a symmetrical 10 kHz PWM signal.

The PWM counting is also selected as center aligned mode as shown in Fig. 9 [19]. In this mode, the counter counts-up from 0 to ARR and then counts-down from ARR to 0, generating one full cycle. This results in a symmetrical PWM signal: the rising and falling edges are evenly spaced with respect to the center of the period. The PWM signal will be center-aligned and will increase or decrease on both sides.

Dead-Time

Dead-time is the time delay between the gating signals of




Figure 9. Frequency and PWM mode settings in STM32CubeMX.




Figure 10. Dead-time setting.

switching devices to prevent them from turn-"on" or turn-"off" at the same time and therefore avoiding short circuits. It is a critical parameter for generating PWM signals.

On the "Stop and downtime management" tab, it is possible to set the dead-time, in this case to 2 μ s, using the procedure to calculate the timer ticks based as function of the operating frequency (see Fig. 10) [20].

C. Code Programming

Main Code

The main code begins by defining some important constants, such as the π value, the frequency of the desired fundamental output sine wave, the frequency of the PWM signal, and the ARR period for the 10 kHz signal. Then, the $\underline{u}_s^*$ is generated as shown in Fig. 11. It should be noted that the angle theta must be encapsulated, this is so that if the angle theta exceeds 2π , the rotation calculation resets to 0. This ensures that the advance of theta remains between 0 and 2π .

Once the reference vector is established, the space where it will rotate is generated. This space must be divided into 6 parts, and its position at each instant must be known.

First, within the TIM3 callback, a variable "sector" is defined as an integer value. This variable will be the result of the sector calculation in the main block called "calculate_sector", as seen in the upper lines of Fig. 12. The sector is the result of dividing the angle theta where the vector is located by $\pi/3$, or 60° . If the calculation yields a value greater than 6, then it is assumed that the vector is in sector I. The alpha-beta components of $\underline{u}_s^*$ are computed using trigonometry as: $v_\alpha = \cos(\varphi)$, $v_\beta = \sin(\varphi)$ and the magnitude and the angle φ of the $\underline{u}_s^*$ are calculated using: $\underline{u}_s^* = \sqrt{(u_\alpha^2 + u_\beta^2)}$ and $\varphi = \tan^{-1} u_\beta / u_\alpha$, as detailed in the lower lines of Fig. 12.

```

63- /* Private user code -----
64- /* USER CODE BEGIN 0 */
65- #include <math.h>
66-
67- #define PI 3.14159265f
68- #define FREQ_SENOIDE 20.0f
69- #define FREQ_PWM 10000.0f
70- #define PWM_TIEMPO 50
71-
72- float theta = 0.0f;
73- float avance_theta = 2.0f * PI * FREQ_SENOIDE / FREQ_PWM;
74-
75-

```

Figure 11. Declaration of constants and generation of the $\underline{u}_s^*$ using the STM32CubeIDE interface.

```

77- int calcular_sector(float theta)
78- {
79-     sector = (int)(theta / (PI / 3.0f)) + 1;
80-     return (sector > 6) ? 1 : sector;
81- }
82-
83- void calcular_tiempos_svm(float Va, float Vb, )
84- {
85-     float Vref = sqrtf(Va * Va + Vb * Vb);
86-     float angulo = atan2f(Vb, Va);
87-     if (angulo < 0)
88-         angulo += 2 * PI;
89- }

```

Figure 12. Calculation of the sector and determination of the magnitude and angle of the $\underline{u}_s^*$.

For the declaration of times t_a , t_b , and t_0 : within the TIM3 callback, the times t_a , t_b , and t_0 are declared, as well as in the main block within the CALCULATE_SVM_TIMES instruction block. The time T_s or PWM period is also adjusted. After obtaining all the necessary elements, the projections $\underline{u}_a$ and $\underline{u}_b$ of $\underline{u}_s^*$ onto the adjacent space vectors are calculated [21]. Times t_a , t_b , and $t_0/2$ are assigned, depending on which sector the $\underline{u}_s^*$ is, and the following assignment of times t_a , t_b , and $t_0/2$ will be carried out according to table II.

Table II. Assignment of times t_a , t_b and $t_0/2$, depending on which sector the $\underline{u}_s^*$ is.

Sector	Su	Sv	Sw
I	$t_a+t_b+t_0/2$	$t_b+t_0/2$	$t_0/2$
II	$t_a+t_0/2$	$t_a+t_b+t_0/2$	$t_0/2$
III	$t_0/2$	$t_a+t_b+t_0/2$	$t_b+t_0/2$
IV	$t_0/2$	$t_a+t_0/2$	$t_a+t_b+t_0/2$
V	$t_b+t_0/2$	$t_0/2$	$t_a+t_b+t_0/2$
VI	$t_a+t_b+t_0/2$	$t_0/2$	$t_a+t_0/2$

Generation of Trigger Signals

To generate the trigger signals, the Capture and Compare Register (CCR) of TIM1 is used. This is called through the HAL_TIM_SET_COMPARE macro, which converts the application times into timer ticks and then into PWM cycles. Within the CCR macro, it is specified that it is a TIM1 register with the line &htim1 and the channel with TIM_CHANNEL_X, thus specifying the comparison for each TIM1 channel. The three main and complementary channels of TIM1 must be enabled to obtain the six signal outputs for inverter control. This is done in the Peripheral Initialization section (initialize all channels are enabled using the HAL_TIM_PWM_Start macro. The additional outputs are enabled with the HAL_TIMEx_PWMN_Start macro with their respective TIM1 and channel addresses, as shown in Fig. 13.

```

197- /* Initialize all configured peripherals */
198- MX_GPIO_Init();
199- MX_TIM1_Init();
200- MX_TIM3_Init();
201- /* USER CODE BEGIN 2 */
202- HAL_TIM_PWM_Start(&htim1, TIM_CHANNEL_1);
203- HAL_TIMEx_PWMN_Start(&htim1, TIM_CHANNEL_1);
204- HAL_TIM_PWM_Start(&htim1, TIM_CHANNEL_2);
205- HAL_TIMEx_PWMN_Start(&htim1, TIM_CHANNEL_2);
206- HAL_TIM_PWM_Start(&htim1, TIM_CHANNEL_3);
207- HAL_TIMEx_PWMN_Start(&htim1, TIM_CHANNEL_3);

```

Figure 13. Enabling the PWM outputs in the TM32CubeIDE.

VI. RESULTS

A. The Experimental Setup

The algorithm was programmed using a laptop computer and once completed and compiled, it was uploaded to the MCU via a USB port. After this, the laptop is no longer required. Since the voltage inverter requires 15V_{dc} CMOS logic signals to trigger the IGBTs, and since the development board cannot supply logic signals at these voltage levels, a circuit was implemented to convert the 3.3 V_{dc} output signal from the MCU to signals of 15V_{dc}. For this purpose, a transistor-based IC operating in cutoff and saturation modes has been selected.

For the power stage, a commercially available three-phase, 2-L inverter by Semikron (SKiiP 232GD120-313CTV) and a 1 hp squirrel-cage induction motor have used. To power the inverter with high DC voltage, the single-phase line voltage was rectified and filtered using power capacitors.

A 500 MHz, 4-channel LeCroy HDO6054 oscilloscope was used to capture the waveforms. Fig. 14 shows a photograph of the experimental setup.



Figure 14. The experimental setup.

A. Experimental Results

Figure 15 displays two experimental trigger signals for one branch of the three-phase inverter, in order to show the programmed dead-time, which in this work was set to 2 μ s.

Figs. 16 a) and 16 b) show the logic signals for triggering the inverter when the $\underline{u}_s^*$ is in sectors I, and in sector III, respectively. These signals are measured at the MCU's outputs PA8, PA9, and PA10 using the oscilloscope to verify the SVM's switching pattern.




Figure 15. The programmed dead-time, [2 us/div], [2 V/div].




Figure 16. SVM trigger signals, [20 us/div], [1 V/div]. a) $\underline{u}_s^*$ is in sector I, b) $\underline{u}_s^*$ is in sector III.

Fig. 17 shows the line-to-line voltage V_{uw} , and the current of the phase U with half load. These measurements were taken at the input of the AC motor. Fig. 18 shows a zoomed-in view of Fig. 18, to appreciate the modulated voltage and the low THD that the phase current presents.

Fig. 19 shows the phase-to-line voltage V_{UN} , and the current of phase W, when the motor is fully loaded. This demonstrates that the SVM algorithm has been successfully implemented affordably on the low-power, low-cost development board.

VII. CONCLUSIONS

In this paper, the digital implementation of the SVM algorithm for three-phase AC-motor drives is explained. The development board STM32F446RE was used. This microcontroller, besides being affordable and readily available, has been proved that it can be easy and quick to configure and program using its development tools.

A commercial inverter (by Semikron) integrated with IGBTs has been used. It was necessary to implement a board with integrated circuits to convert the logic (TTL) signals to 15 V_{dc} CMOS signals, which is the voltage level required to trigger the inverter. The trigger signals were programmed so that the




Figure 17. Line voltage V_{uw} and current of the phase U, [20 ms/div], [50 V/div], [0.5 A/div].




Figure 18. Zoom of Fig. 17, [5 ms/div], [50 V/div], [0.5 A/div].




Figure 19. Phase voltage and current of the phase W, [20 ms/div], [50 V/div], [0.5 A/div].

inverter operates at a frequency of 10 kHz. A 1 hp three-phase squirrel-cage induction motor was connected as the load.

The experimental results show a suitable implementation of the SVM algorithm and excellent performance of the AC drive.

REFERENCES

- [1] Technavio "Variable frequency drive (VFD) market size 2025-2029", May 2025. [Online]. Available: <https://www.technavio.com/report/variable-frequency-drives-market-industry-size-analysis>
- [2] B. Bose, "Modern power electronics and AC drives," Prentice H. 2001.
- [3] R. Krishnan, "Electric motor drives: modeling, analysis, and control," Prentice Hall. 2001.
- [4] T. M. Jahns and E. L. Owen, "AC adjustable-speed drives at the millennium: how did we get here?" *IEEE Trans. Power Electron.*, vol. 16, no. 1, pp. 17-25, Jan. 2001.
- [5] B. Bathkishig, P. F. D. Gonçalves, G. Pietrini, B. Nahid-Mobarakeh and A. Emadi, "PWM techniques for two-level voltage source inverters: a comparative study," *IEEE Access*, vol. 13, pp 86235-86255, Apr. 2025.

- [6] K. Zhou and D. Wang, "Relationship between space-vector modulation and three-phase carrier-based PWM: a comprehensive analysis," *IEEE Trans. Ind. Electron.*, vol. 49, no. 1, pp. 186-196, Feb. 2002.
- [7] Rashid, M. H. "Power electronics Handbook. devices, circuits, and applications," 3rd ed. Elsevier: Pensacola, FL, USA, 2015.
- [8] J. P. Moreno Beltran, O. Sandre Hernandez, R. Morales Caporal, P. Ordaz-Oliver and C. Cuvas-Castillo, "Model predictive torque control of an induction motor with discrete space vector modulation," *17th Int. Conf. Electr. Eng., Comput. Sci. Autom. Control (CCE)*, Mexico City, Mexico, 2020, pp. 1-6 Nov. 2020.
- [9] F. A. Ramirez, M. A. Arjona and C. Hernandez, "A space-vector PWM voltage-source inverter for a three-phase induction motor based on the dsPIC30F3011," in *Proc. 6th Electron., Robotics and Automat. Mechs. Conf., (CERMA)*, Cuernavaca, Mexico, 2009, pp. 429-434, Sep. 2009.
- [10] R. Morales-Caporal, O. Sandre-Hernández, E. Bonilla-Huerta, J. C. Hernández-Hernández and J. J. Hernández-Mora, "DSP-based space vector modulation for a VSI-fed permanent magnet drive," *9th Electron., Robotics and Automotive Mechs. Conf., (CERMA)*, Cuernavaca, Mexico, 2012, pp. 261-266, Nov. 2012.
- [11] F. J. Bartos, "AC drives stay vital for the 21st century," *Control Engineering*, Sep. 2004.
- [12] S. Ogasawara, H. Akagi, and A. A. Nabae, "A novel PWM scheme of voltage source inverters based on space vector theory," *Archiv f. Elektrotechnik*, vol. 74, p.p. 33-41, Jan. 1990.
- [13] J. Holtz, "Pulsewidth modulation for electronic power conversion," in *Proc. of the IEEE*, vol. 82, no. 8, pp. 1194-1214, Aug. 1994.
- [14] Y. Solbakken "Space vector PWM intro", May 2017. [Online]. www.switchcraft.org/learning/2017/3/15/space-vector-pwm-intro
- [15] A. Y. Yousef, "Space vector pulse width modulation technique," *IJETCSE*, vol. 15, no. 1, pp. 159-165, May 2015.
- [16] STM32 Nucleo-64 development board with STM32F446RE MCU. [Online]. Available: <https://www.technavio.com/report/variable-frequency-drives-market-industry-size-analysis>
- [17] STM32CubeMx. [Online]. Available: https://www.st.com/translate/goog/en/development-tools/stm32cubemx.html?_x_tr_sl=en&_x_tr_tl=es&_x_tr_hl=es&_x_tr_pto=tc
- [18] STM32CubeIDE. [Online]. Available: <https://www.st.com/en/development-tools/stm32cubeide.html>
- [19] STM32 3 Phase PWM (Center-Aligned). [Online]. Available: <https://deepbluembedded.com/stm32-3-phase-pwm-center-aligned-example-code/>
- [20] How to generate dead time in complementary PWM signals using STM32's advanced timer peripheral. [Online]. Available: <https://gist.ly/youtube-summarizer/how-to-generate-dead-time-in-complementary-pwm-signals-using-stm32s-advanced-timer-peripheral>
- [21] Space vector modulation using 8-bit ST7MC Microcontroller. Application note. [Online]. Available: <file:///C:/Users/rmcap/Downloads/cd00055518-space-vector-modulation-using-8bit-st7mc-microcontroller-and-st7mckitbdc-starter-kit-stmicroelectronics-5.pdf>



ROBERTO MORALES-CAPORAL received the B.E. degree in Electromechanical Engineering from the National Technological Institute of Mexico—Campus Apizaco (TecNM-ITA), Apizaco, Mexico, in 1999, the M.Sc. degree in Electrical Engineering from the Graduate and Research Department, Superior School of Mechanical and Electrical Engineering (ESIME-Z), National Polytechnic Institute (IPN), México City, Mexico, in 2001, and the Dr.-Ing. degree in Electrical Engineering from the University of Siegen, Siegen, Germany, in 2007. From 2001 to 2003, he was a Lecturer with the Interdisciplinary Professional Unit in Engineering and Advanced Technologies (UPIITA), IPN.

He is currently a full-time Professor at the Division of Graduate Studies and Research of the TecNM-ITA. His research interests include discrete-time control systems, predictive control of power converters, AC-motor drives, hardware development and IoT.

Prof. Morales-Caporal is a member of the National Research Fellows System Level 2 (SNII-2), Secretariat of Science, Humanities, Technology and Innovation (SECIHTI), México.



DIEGO AGUAYO-DÍAZ received the title of Electronic Engineer with a specialization in control and automation in industry 4.0 from the National Technological Institute of Mexico—Campus Apizaco (TecNM-ITA), Apizaco, Mexico, in 2026.

His areas of professional interests include Industry 4.0, power electronics and solutions using microcontrollers.



RAFAEL ODOÑEZ-FLORES received the B.E. degree in Electronics Engineering from the Instituto Tecnológico de Puebla (TecNM-ITP), Puebla, Mexico, in 1995, the M.Sc. degree in Electronics Engineering from the National Center for Research and Technological Development (CENIDET), Cuernavaca, Mexico, in 1998, and the D.Sc. degree in Electrical Engineering from the University of Paris 11, Higher School of Electricity (SUPELEC), Orsay, France, in 2007.

He is currently a full-time Professor with the Division of Graduate Studies and Research, ITA. His research interests include control of power electronics, electrical energy quality, renewable energy, and magnetic induction heating.



MARIO E. LEAL-LOPEZ received the B.E. and the M.Sc. degrees both in Electronic Engineering from the National Technological Institute of Mexico—Campus Orizaba (TecNM-ITO), Orizaba, Mexico, in 2006 and 2010, respectively. He also holds a specialization in Mechatronics Technology from CIDESI, Querétaro, Mexico.

He is currently a full-time Professor with the Division of Graduate Studies and Research of the TecNM—Campus Apizaco. He has served as head of the Department of Electrical & Electronic Engineering and of the Division of Graduate Studies and Research. His research interests include control of mechatronic systems, robotics, land and air vehicles, and automation of methane gas quantification anaerobic bioreactors.



EDMUNDO BONILLA-HUERTA received the B.Sc. and M.Sc. degrees both in Computer Science from the National Technological Institute of Mexico—Campus Apizaco (TecNM-ITA), Apizaco, Mexico, in 1994 and 1996, respectively, and the Ph.D. degree in Computer Science from the University of Angers, Angers, France, in 2008.

He is currently a full-time Professor with the Division of Graduate Studies and Research of the TecNM-ITA. His research interests include opti-

mization, fuzzy logic, machine learning, techniques for microarray data analysis, and bioinformatics.

Prof. Bonilla-Huerta is a member of the National Research Fellows System Level 1 (SNII-1), Secretariat of Science, Humanities, Technology and Innovation (SECIHTI), México.



La portada de esta revista fue diseñada con el propósito de destacar la importancia de los paneles solares como una de las principales fuentes de energía renovable en la actualidad. Su presencia como elemento central simboliza el compromiso de la sociedad con el desarrollo sostenible, el cuidado del medio ambiente y la búsqueda de alternativas energéticas que reduzcan el impacto ambiental.

Asimismo, la portada representa el avance de la ciencia y la tecnología, las cuales han permitido el desarrollo de sistemas capaces de aprovechar la energía proveniente del Sol para generar electricidad de manera limpia, eficiente y renovable. Este recurso tecnológico refleja cómo la innovación científica contribuye a resolver problemáticas relacionadas con el cambio climático y el uso responsable de los recursos naturales.

Fotografía:

Instalación fotovoltaica del Edif. T, Instituto Tecnológico de Apizaco