

Artificial Intelligence Methods for Process Automation: A Systematic Literature Review

Ricardo Alexander Villegas Chavez¹; Christian Abraham Dios Castillo²

¹Universidad Tecnológica del Perú, Perú, U21214110@utp.edu.pe

²Universidad Tecnológica del Perú, Perú, C16763@utp.edu.pe

Abstract– Process automation through artificial intelligence improves accuracy and operational efficiency. In this systematic review of publications indexed in Web of Science and Scopus, using the PRISMA method, 66 articles were selected. Automation increases accuracy, strengthens robustness as models adapt to new data, and improves efficiency. In the literature from 2024 to 2025, machine learning predominates for structured data and deep learning for unstructured data; the YOLO family is the most frequent in deep learning and decision trees in machine learning. Deep learning models Darknet 19, ResNet 18, ResNet 50 and ResNet 10 reached 100%, and the Extra Trees algorithm in machine learning reached 99.7% in health studies, which account for the majority of experiments.

Keywords– artificial Intelligence, automation, deep learning, machine learning.

Métodos de Inteligencia Artificial para la Automatización de Procesos: Una revisión Sistemática de literatura

Ricardo Alexander Villegas Chavez¹; Christian Abraham Dios Castillo²

¹Universidad Tecnológica del Perú, Perú, U21214110@utp.edu.pe

²Universidad Tecnológica del Perú, Perú, C16763@utp.edu.pe

Resumen— La automatización de procesos mediante inteligencia artificial mejora la precisión y la eficiencia operativa. En esta revisión sistemática de publicaciones indexadas en Web of Science y Scopus, aplicando el método PRISMA, se seleccionaron 66 artículos. Se observó que la automatización incrementa la precisión, aumenta la robustez de los procesos al adaptarse con nuevos datos y optimiza la eficiencia. En la literatura 2024 a 2025 predominan el machine learning para datos estructurados y el deep learning para datos no estructurados; la familia YOLO es la más frecuente en deep learning y los árboles de decisión en machine learning. Los modelos de deep learning Darknet 19, ResNet 18, ResNet 50 y ResNet 10 alcanzaron 100% y el algoritmo Extra Trees en machine learning alcanzó 99.7% en estudios del área de salud, que concentra la mayor parte de los experimentos.

Palabras clave-- artificial Intelligence, automation, deep learning, machine learning.

I. INTRODUCCIÓN

En la actualidad la automatización de procesos mediante el uso de la inteligencia artificial (IA) ha transformado de forma significativa la manera en que las organizaciones optimizan sus operaciones. Estas técnicas automatizan tareas y aceleran procesos, adaptándose al crecimiento de datos y creando un marco replicable para futuras aplicaciones, en consecuencia, se obtiene una base sólida para la toma de decisiones [1].

En el ámbito del emprendimiento y la innovación el uso de estas tecnologías ofrece una oportunidad para que las empresas emergentes optimicen sus procesos y logren una diferenciación. Esta investigación se justifica en la medida que permite al emprendedor comprender las características técnicas de la automatización de procesos, los métodos adecuados para su implementación y medición, su innovación, lograr una diferenciación en el mercado y generar un desarrollo socio económico en la región.

Por lo tanto, el objetivo de esta Revisión Sistemática de Literatura (RSL) es determinar los modelos de IA más efectivos para la automatización en diferentes procesos.

II. METODOLOGÍA

Esta RSL consiste en un método que permite extraer, analizar y simplificar información de un tema en específico, tomando como base investigaciones anteriores relacionadas con la temática de estudio [2], [3]. Para lo cual se planteó la pregunta principal: ¿Cuál es el método de inteligencia artificial más efectivo para la automatización de procesos? y como preguntas específicas las siguientes, 1) ¿Qué características tiene un proceso automatizado?, 2) ¿Qué métodos de inteligencia

artificial existen para la automatización de un proceso? y 3) ¿Qué nivel de efectividad tienen los métodos de inteligencia artificial para la automatización de procesos? Las palabras clave se detallan en la tabla I.

TABLA I
RELACION PREGUNTAS-KEYWORDS

Ítem	Preguntas	Palabras clave
1	¿Qué características tiene la automatización de un proceso?	"automation" AND "process"
2	¿Qué métodos de inteligencia artificial existen para la automatización de un proceso?	"Artificial Intelligence"
3	¿Qué nivel de efectividad tienen los métodos de inteligencia artificial para la automatización de procesos?	"performance"

Las bases de datos científicas usadas para la búsqueda de información es Scopus y Web of Science.

Para Scopus la cadena de búsqueda es la siguiente:

(TITLE-ABS-KEY ("automation" AND "process") AND TITLE-ABS-KEY ("Artificial Intelligence") AND TITLE-ABS-KEY ("performance")).

Para Web of Science se usó la misma cadena de búsqueda ajustado a los comandos del motor de búsqueda de este:

ALL= ("automation" AND "process" AND "Artificial Intelligence" AND "performance").

Se aplicaron los mismos filtros para ambas bases de datos científicas, las cuales se pueden ver a detalle en la tabla II.

TABLA II
FILTROS DE BUSQUEDA

Filtro	Valor
Año de publicación	> 2023, < 2026
Acceso	Open Access
Área temática	Computer Science, Engineering
Tipo de documento	Artículo
Idioma	"English" o "Spanish"

La cadena de búsqueda con los filtros aplicados para Scopus es la siguiente:

(TITLE-ABS-KEY ("automation" AND "process") AND TITLE-ABS-KEY ("Artificial Intelligence") AND TITLE-ABS-KEY ("performance")) AND PUBYEAR > 2023 AND PUBYEAR < 2026 AND (LIMIT-TO (OA, "all")) AND

(LIMIT-TO (SUBJAREA, "COMP") OR LIMIT-TO (SUBJAREA, "ENGI")) AND (LIMIT-TO (DOCTYPE, "ar")) AND (LIMIT-TO (LANGUAGE, "English") OR LIMIT-TO (LANGUAGE, "Spanish"))).

De igual manera se aplicaron los filtros para Web of Science, pero a través de la interfaz de selección de filtros ya que no se aplican los filtros directamente a la cadena de búsqueda.

Los resultados obtenidos se descargaron para su análisis el 28 de abril del 2025 a las 7:48pm, siendo considerada con la fecha y hora de cierre del proceso de búsqueda. Debido a que Scopus y Web of Science son bases de datos que actualizan su información de manera constante, es probable que a la fecha de la publicación y lectura de este documento los resultados varíen. La hoja de trabajo se encuentra publicada para el análisis de los Interesados en: <https://doi.org/10.5281/zenodo.15856898>

Entre los criterios de inclusión y exclusión de los documentos para su análisis, se encuentran los siguientes contemplados en la tabla III y IV.

TABLA III
CRITERIOS DE INCLUSION

ítem	Criterio
CI1	Estar relacionados con el estudio de la automatización de procesos
CI2	Incluir el uso de métodos de inteligencia artificial específicos aplicados a dichos procesos
CI3	Presentar resultados concretos sobre la eficacia, eficiencia, rendimiento u otros indicadores de efectividad de los métodos analizados

TABLA IV
CRITERIOS DE EXCLUSION

ítem	Criterio
CE1	No estar relacionados con el estudio de la automatización de procesos
CE2	No incluir el uso de métodos de inteligencia artificial aplicados a procesos (por ejemplo, estudios que solo traten sobre métodos tradicionales de automatización sin IA)
CE3	No presentar resultados concretos sobre la eficacia, eficiencia, rendimiento u otros indicadores de efectividad de los métodos analizados

Estos criterios se pusieron en práctica en el análisis detallado, aplicando la metodología Preferred Reporting Items for Systematic reviews and Meta-Analyses conocida por sus siglas (PRISMA), la cual es una guía que garantiza la transparencia, precisión e integridad de la información en las revisiones sistemáticas de literatura[4] En la Fig. 1 se puede apreciar que en la fase inicial se obtuvo un total de 127 artículos, 74 de Scopus y 53 de Web of Science, se descartaron 20 artículos duplicados, 11 artículos por criterios de exclusión en el Abstract, 5 artículos no se lograron recuperar, y finalmente se descartaron 25 artículos por criterios de exclusion de contenido de los documentos, finalmente, se realizó el análisis de contenido de 66 documentos.

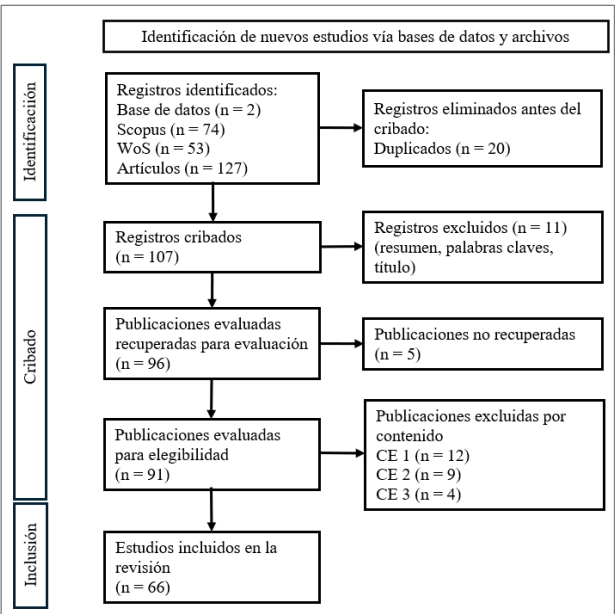


Fig. 1 Diagrama de flujo Prisma.

En síntesis, de los 127 artículos identificados (74 en Scopus y 53 en Web of Science), se eliminaron 20 por duplicados, 11 por no cumplir los criterios de inclusión en el resumen, 5 no se recuperaron y 25 se excluyeron por contenido, quedando 66 estudios para el análisis final.

III. RESULTADOS

A. Bibliometría

Para realizar la bibliometría de los documentos analizados seleccionados para esta RSL se realizó una clasificación del número de testeos de los modelos de IA dentro de los documentos, los cuales dieron una suma total de 188, estos se clasificaron de acuerdo con el área en el cual se orientaban o se ponían en práctica dentro de su respectivo artículo. En la Fig. 2 se muestra la cantidad de experimentos por área desde el año 2024 al 2025.

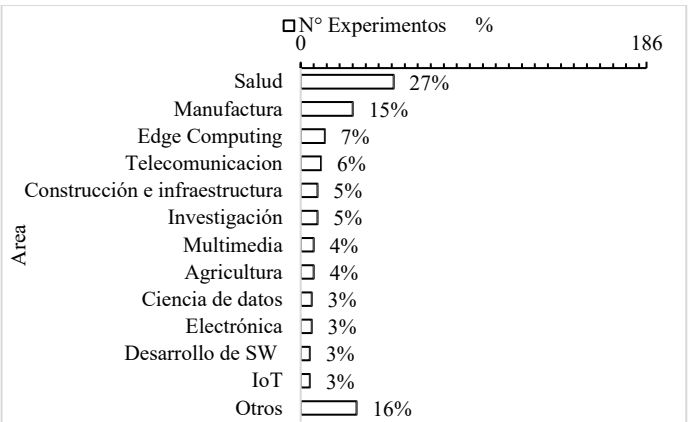


Fig. 2 Experimentos indizados por área

Es importante recalcar que no se ha considerado el análisis evolutivo por años, debido a que se deseaba tener un panorama actualizado del tema de investigación, considerando solamente documentos desde el año 2024 al 2025.

Como se puede apreciar las áreas con menor producción dentro del top 12 son IoT, Desarrollo de Software y Electrónica. El área con mayor producción fue Salud, mostrando que es el área que más interés representa en la literatura científica, el área que le sigue es Manufactura, ocupando el segundo lugar en el ranking, lo cual demuestra el interés en esta área dentro de la literatura científica. De igual manera, es interesante ver que áreas como Edge Computing y Telecomunicaciones, Construcción e infraestructura cuentan con una presencia razonable, no logran alcanzar el nivel de atención que se ha dedicado a Salud y Manufactura. Esta información deja en evidencia una variedad de oportunidades en el ámbito de la investigación aún por aprovechar en campos emergentes como IoT, Electrónica y Desarrollo de Software, donde la demanda tecnológica está creciendo, pero la producción académica es todavía limitada. De igual forma, la categoría “Otros” muestra la diversidad de la aplicación de la automatización con IA en sectores tan variados como la seguridad de redes, logística y finanzas, lo que deja en claro un panorama científico extenso y en constante desarrollo. En común, estos hallazgos apuntan tanto las áreas consistentes de estudio, como los nichos de investigación con gran potencial para trabajos futuros.

Finalmente, se realizó el análisis de co-ocurrencia de Keywords lo cual corrobora que los artículos analizados tienen nexos con el tema de investigación. En la tabla V se presenta las 8 Keywords con mayor ocurrencia en los documentos, cabe mencionar que el Total link strength es una medida que marca la fuerza de las conexiones entre las palabras clave y la frecuencia con la que aparecen en los documentos.

TABLA V
 CO-OCURENCIA DE KEYWORDS

keywords	ocurrences	Total link strength
artificial Intelligence	29	37
automation	18	32
deep learning	17	28
machine Learning	13	26
learning Systems	6	15
object detection	7	11
computer visión	6	10
natural lenguaje processing	6	9

Nota: Trabajo a partir de los documentos analizados

La keyword más ocurrente es “artificial Intelligence”, le prosigue “automation”, “deep learning”, “machine learning” con ocurrencia moderada y por último “learning Systems”, “object detection”, “computer visión” y “natural lenguaje processing” con una ocurrencia baja. Cabe recalcar que en términos de total link strength, “artificial Intelligence” alcanza 37 puntos, subrayando su rol integrador; le siguen “automation” con 32, “deep learning” con 28 y “machine learning” con 26. Por lo

tanto, estos 4 keywords serán incluidos en el Abstract de este manuscrito, con el propósito de lograr un posicionamiento en los resultados de búsqueda en Scopus y Web of Science, así como incorporarlo dentro de la literatura científica relacionada con la temática.

B. Respuesta a las preguntas específicas

Para responder a la primera pregunta específica “¿Qué características tiene la automatización de un proceso?” se realizó un análisis de los documentos seleccionados, como resultado se identificó una serie de características propias de automatizar un proceso. Como resultado se obtuvo una distribución de características contenidas en los procesos mencionados dentro de los artículos, dicha distribución de características se muestra en la Fig.3.




Fig.3 % de Características de la automatización de procesos contenidas en el total de artículos

Nota 1: Se muestran el porcentaje de artículos que contienen una característica identificada (Ejemplo: El 89% de los artículos contiene la característica de “Precisión”).

Nota 2: El total no suma 100% porque un artículo puede contener más de una característica.

Como se puede apreciar, “Precisión” es la característica predominante con el 89.39% del total de artículos que lo contienen, lo cual significa que a automatizar un proceso este se vuelve más preciso. La siguiente característica con mayor presencia es “capacidad de aprendizaje” con el 84.85% del total de artículos, lo que quiere decir que el proceso se vuelve mucho más robusto ya que el modelo de inteligencia artificial mejora al procesar datos nuevos y obteniendo retroalimentación. Del mismo modo el 81.82% de artículos menciona que el proceso automatizado se vuelve más eficiente. Asimismo, “repetitividad” tiene una fuerte presencia, lo cual indica que un proceso contiene una serie de tareas repetitivas y fijas. Por otro lado, las características con presencia moderada son “adaptabilidad”, “compatibilidad”, “consistencia”,

“escalabilidad” y “reducción de costos”. Es decir, la automatización con IA no solo mejora el rendimiento de un proceso, si no que también la viabilidad de este. Por último, con poca presencia tenemos “Monitoreo en tiempo real” que permite supervisar en vivo el proceso automatizado, detectar problemas y realizar los ajustes necesarios, y de la misma forma “Paralelismo” con el 19.70% del total de artículos, esta permite ejecutar tareas de forma simultánea, lo cual no es tan común pero su presencia señala su adopción en la literatura científica. Otra característica propia de la automatizar procesos con IA es que los modelos deben procesar datos, estos datos tienen una naturaleza estructural, las cuales se clasifican en 3 categorías grandes de datos, lo cual se explica en la tabla VI.

TABLA VI
 NATURALEZA DE TIPOS DE DATOS

Tipo de dato	Explicación
Estructurado	Datos que se encuentran organizados de forma rígida en un formato o esquema [5], como tablas con columnas y filas.
No estructurado	Son datos que no tienen una organización predefinida ni una estructura fija [5], por ejemplo, texto libre, videos, imágenes etc.
Semiestructurado	Estos datos se encuentran en un punto intermedio entre los anteriores mencionados, estos no tienen una estructura rígida como por ejemplo una tabla, pero si se cuenta con etiquetas que hacen que cuenten con cierta estructura[5], por ejemplo, HTML, XML, JSON, etc.

Una vez explicado cada una las categorías generales de datos, se procede a clasificar todos los datos de entrada y salida del total de experimentos de acuerdo con su naturaleza, lo cual se muestra en la Fig. 4.




Fig. 4 Comparación de frecuencia de tipo de dato de entrada y salida
 Nota: “Múltiple” se refiere a que devuelve 2 o más tipos de datos.

Se encontró que la mayoría de los datos de entrada que reciben los modelos de IA son de naturaleza no estructural, le siguen datos estructurados, de igual manera para los datos de salida se encontró que los modelos de IA devuelven en su gran mayoría datos estructurados.

La segunda pregunta: ¿Qué métodos de inteligencia artificial existen para la automatización de procesos?, para responder a esta pregunta se realizó un metaanálisis, cuyos detalles se muestran en la tabla VII.

TABLA VII
 DETALLES ANALISIS

Unidad de análisis: Experimento	Un experimento se desarrolla con un modelo específico.
Población:	186
Muestra:	186
Muestreo:	No probabilístico, por cuotas

Nota: Los 66 documentos analizados contenían 186 experimentos.

Los modelos de IA se clasificaron según el método general al que pertenecen, lo que da el total de experimentos, un experimento es igual a uno o más modelos, el número de experimentos por método general de IA se muestra en la tabla VIII.

TABLA VIII
 DISTRIBUCION DE METODOS DE IA

Método de Analítica de Datos	N°	%	Id referencia
Deep Learning	108	58%	[6], [7], [8], [9], [10], [11], [12], [13], [14], [15], [16], [17], [18], [19], [20], [21], [22], [23], [24], [25], [26], [27], [28], [29], [30], [31], [32], [33], [34], [35], [36], [37], [38], [39], [40], [41], [42], [43], [44], [45], [46], [47], [48], [49], [50]
Machine Learning	47	25%	[16], [30], [32], [35], [38], [43], [45], [51], [52], [53], [54], [55], [56], [57], [58], [59], [60], [61], [62]
Metaheurística	12	6%	[23], [28], [56], [63], [64]
IA genérica	3	2%	[65]
Spiking Neural Networks	3	2%	[66]
IA simbólica	3	2%	[16], [27]
RPA	2	1%	[67], [68]
Black-box predictivo	2	1%	[28]
Otros	6	3%	[69][70][43][28][71]
Total	186	100%	-

Debido a que el deep learning y el machine learning son los métodos que más experimentos contemplan, se decidió filtrar la naturaleza de los datos de entrada y salida para estos 2, los cuales se muestran en la Fig. 5 y Fig. 6.

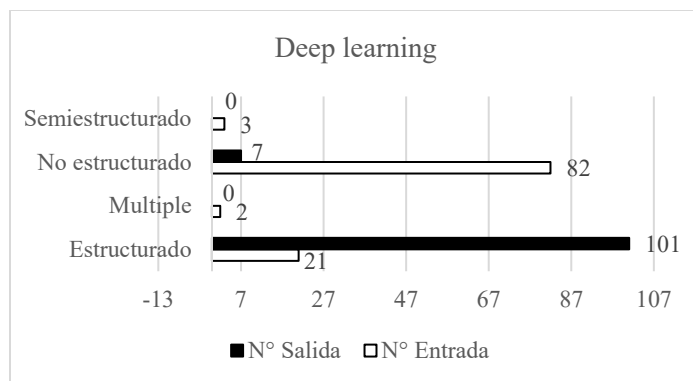


Fig. 5 Tipo de dato de entrada y salida del Deep learning.

En los experimentos los modelos de deep learning reciben de entrada más datos “no estructurados” y devuelve más datos “estructurados”




Fig. 6 Tipo de dato de entrada y salida del Machine learning

En experimentos de modelos de Machine learning de entrada recibe más datos “estructurados” y de salida solo devuelve datos estructurados.

A continuación se muestra las familias de modelos de IA más recurrente para automatizar procesos, en la Tabla IX y en la tabla X Machine learning.

TABLA IX
TOP 4 FAMILIAS DE MODELOS MAS RECURRENTES DE
DEEP LEARNING

Familias	N°	%	Tipo de dato de entrada más recurrente	Tipo de dato de Salida más recurrente
YOLO	15	14%	No estructurado (Imágenes)	Estructurado (Tabular/Numérico)
LLM	14	13%	Estructurado (Tabular)/No estructurado (texto libre)	Estructurado (binario/tabular)
CNN	15	14%	No estructurado (Imágenes)	Estructurado (Tabular/ Numérico)
ResNet	12	11%	No estructurado (Imágenes)	Estructurado(binario/t abular)
Otros	52	48%	-	-
Total	108	100%	-	-

Nota: el 100% es 108, debido a que ese es el número de experimentos de deep learning.

Como se aprecia, YOLO es la familia con más modelos presentes en la literatura con respecto a automatización de procesos, este mismo en su mayor recurrencia recibe datos no estructurados y devuelve datos estructurados.

TABLA X
TOP 4 FAMILIAS DE MODELOS MAS RECURRENTES DE
MACHINE LEARNING

Familias	N°	%	Tipo de dato de entrada más recurrente	Tipo de dato de Salida más recurrente
Árboles de Decisión	9	19%	Estructurado (tabular/ numérico)	Estructurado(binario/numérico)
RL (Aprendizaje por refuerzo)	6	13%	Estructurado (serie temporal)	Estructurado(numérico)
Boosting (XGBoost, LightGBM, CatBoost, AdaBoost)	5	11%	Estructurado(tabular/binario) No estructurado (Imágenes)	Estructurado(binario)
SVM (Support Vector Machine)	4	9%	Estructurado(tabular) No estructurado (Imágenes)	Estructurado(binario)
Otros	23	48%	-	-
Total	47	100%	-	-

Nota: el 100% es 47, debido a que ese es el número de experimentos de Machine learning.

La familia de modelos más usadas en los experimentos para automatizar procesos es arboles de decisión, estos en la mayoría de los experimentos reciben y devuelven datos estructurados.

Debido a que el método de analítica de datos que más experimentos contempla es Deep Learning con 108 experimentos, equivalente al 57% del total de estos. Por lo tanto, para responder a la 3 pregunta específica, “¿qué nivel de efectividad tienen los métodos de inteligencia artificial para la automatización de procesos?” el método del cual se realizó un metaanálisis del nivel de eficacia es Deep Learning.

Se realizo un Análisis de normalidad, para determinar el nivel de homogeneidad de los datos. Debido a que el número de experimentos es mayor a 50, se usará el estadístico de Kolmogórov-Smirnov.

TABLA XI
DETALLES DE ANALISIS

Distribución del N° de experimentos por modelo			
H0	La distribución del número de experimentos por modelo es homogénea.		
Ha	La distribución del número de experimentos por modelo no es homogénea.		
Variable	Test	Estadístico	p
N° Experimentos por Modelo	Shapiro–Wilk	0.364	< .001
	Kolmogorov–Smirnov	0.490	< .001
	Anderson–Darling	23.5	< .001

Según el estadístico de Kolmogórov-Smirnov. El p-valor < 0,001,

Por lo tanto, la distribución de los modelos de deep learning es heterogénea.

Ya que en 64 experimentos de deep learning dentro de los artículos no muestran métricas de eficiencia y los que sí, resultan muy variadas, algunas cualitativas, lo que imposibilita su comparación, solo se realizará el metaanálisis con pruebas no paramétricas para nivel de eficacia de deep learning el cual se muestra en la tabla XII.

TABLA XII
TOP 4 METRICAS DE EFICACIA MAS USADAS DE DEEP
LEARNING

Métricas	Experimentos	Valor promedio
Accuracy (%)	48	91%
Jaccard index (4 runs)	9	88%
F1 Score	9	57.55%
AUC	4	88%
Otros	24	-
Total	94	-

Nota: El total no suma 108, porque se descartaron datos cualitativos

El total de experimentos de deep learning que muestra resultados cuantitativos son 94 es decir el 87.85%.

La métrica de mayor uso en deep learning es Accuracy, con 48 experimentos en diversos métodos, el valor promedio es del 91%. Esta métrica indica la proporción de predicciones realizadas correctamente comparado con el total de predicciones, es decir mide que tan cercanas estan las predicciones de un modelo con respecto a los valores correctos[72].

La métrica “Tasa de detección exitosa” Tiene un valor del 100%, pero solamente se ha probado con experimentos de 2 modelos. Por lo tanto, la métrica más utilizada en los experimentos para medir el nivel de eficacia de un modelo es Accuracy, por ello se realizó el análisis del índice de eficacia de este mismo, el cual se muestra en la tabla XIII.

TABLA XIII
DETALLE DE ANALISIS

Análisis del índice de eficacia del Accuracy			
Variable	Test	Estadístico	p
Accuracy	Shapiro–Wilk	0.674	< .001
Kolmogorov–Smirnov		0.226	0.015
Anderson–Darling		4.94	< .001

Los resultados del nivel de eficacia de Accuracy en modelos de deep learning son heterogéneos, según p-valor de Shapiro-Wilk <0.001. Cabe recalcar que los resultados son variables dependiendo del modelo que se utilice.

C. Respuesta a la pregunta principal

Para responder a la pregunta principal “¿Cuál es el método más efectivo para la automatización de procesos?”, A continuación, se muestra en la Fig. 7 un top 4 modelos con mayor valor de eficacia.




Fig. 7 Top 4 Modelos de deep learning con mayor valor Accuracy

Los 4 modelos que muestran mayor valor de eficacia con 100% de Accuracy son Darknet-19, Resnet-18, Resnet-50, Resnet-101. En la tabla XIV se muestra el área y proceso que automatiza, aunque no se descarta un posible sobre ajuste.

TABLA XIV
DETALLES DE TOP 4 MODELOS MAS EFICACES DE DEEP
LEARNING

Área	Proceso Automatizado	Tipo de dato entrada	Tipo de dato de salida	Modelo de IA	ID
Salud	Clasificación de células sanguíneas	No estructurado (imagenes)	Estructurado (tabular)	Darknet-19	[14]
Salud	Clasificación de células sanguíneas	No estructurado (imagenes)	Estructurado (tabular)	ResNet-18	[14]
Salud	Clasificación de células sanguíneas	No estructurado (imagenes)	Estructurado (tabular)	ResNet-50	[14]
Salud	Clasificación de células sanguíneas	No estructurado (imagenes)	Estructurado (tabular)	ResNet101	[14]

Los 4 modelos se encuentran en el área “Salud”, todos tienen el mismo proceso, el mismo tipo de dato de entrada, imágenes (no estructurado) y de salida, información en formato tabular(estructurado), debido a que todos los modelos se encuentran en experimentos comparativos dentro de un mismo artículo.

De la misma forma se muestra un top 4 de modelos con menor valor de eficacia en la Fig. 8.




Fig. 8 Top 4 Modelos de deep learning con menor valor Accuracy

Como se puede observar GPT-3.5 turbo (base) tiene el menor valor Accuracy con solo 29.70%, en la TABLA XV se muestra el proceso que automatiza dentro de su respectivo artículo

TABLA XV
DETALLES DE TOP 4 MODELOS MENOS EFICACES DE DEEP LEARNING

Área	Proceso Automatizado	Tipo de dato entrada	Tipo de dato de salida	Modelo de IA	ID
Salud	Asignación de códigos ICD (1)	No estructurado (texto)	Estructurado (tabular)	GPT-3.5 Turbo (base)	[7]
Salud	Asignación de códigos ICD (1)	No estructurado (texto)	Estructurado (tabular)	GPT-3.5 Turbo (fine-tuneado)	[7]
Salud	Clasificación de SCC (2)	No estructurado (imagen)	Estructurado (binario)	AlexNet	[35]
Salud	Clasificación automática de SCC (2)	No estructurado (imagen)	Estructurado (binario) (3)	Inception Net-V3	[35]

Nota 1: Códigos “ICD” se refiere a códigos que se usan para la clasificación de enfermedades.

Nota 2: “SCC” se refiere a la enfermedad Carcinoma de Células Escamosas.

Nota 3: “Estructurado (binario)” se refiere a un falso o positivo.

Los modelos “GPT-3.5 turbo(base)” y “GPT-3.5 turbo(fine-tuneado)” procesan texto como dato “no estructurado” de entrada y devuelven información en formato tabular “estructurado”, por otro lado “AlexNet” y “InceptionNet-V3” reciben de dato de entrada imágenes (no estructurado), y devuelven un formato binario, positivo o negativo (estructurado) todos pertenecen a la misma área “Salud”.

De la misma forma se muestra un top 4 modelos con mayor valor de eficacia para Machine learning en la figura 9.




Fig. 9 Top 4 modelos con mayor valor Accuracy de Machine learning

Como se puede observar el modelo con mayor valor de eficacia es “Extra Trees” perteneciente a la familia de árboles de decisiones, en la TABLA XVI se muestra los detalles de los modelos

TABLA XVI
DETALLES DE TOP 4 MODELOS MAS EFICACES DE MACHINE LEARNING

Área	Proceso Automatizado	Tipo de dato entrada	Tipo de dato de salida	Modelo de IA	ID
telecomunicación	Predicción binaria de viabilidad de un canal QoT	Estructurado (tabular)	Estructurado (binario)	Extra Trees	[54]
telecomunicación	Predicción binaria de viabilidad de un canal QoT	Estructurado (tabular)	Estructurado (binario)	Stochastic Gradient Descent	[54]
telecomunicación	Detección y mitigación automática de anomalías de red	Estructurado (numérico)	Estructurado (binario)	AutoML + Voting Ensemble Learning	[58]
telecomunicación	QoT classification (predicción binaria de viabilidad de un canal)	Estructurado (tabular)	Estructurado (binario)	Histogram-based Gradient Boosting Classification Tree	[54]

Como se puede apreciar todos son del área de “telecomunicaciones”, tanto AutoML + Voting ensemble learning, SGD y Extra Trees fueron usados en el mismo proceso “detección y mitigación automática de anomalías de red”, procesando datos estructurados numéricos y devolviendo datos estructurados en formato binario debido a que son experimentos en un mismo documento, de la misma forma el modelo “HGBCT” se usó para automatizar la “Clasificación de viabilidad de un canal QoT”, el modelo recibía datos estructurados en formato tabular y devolvía datos estructurados en formato binario.

De la misma forma se muestra un top 4 modelos con menos valor de eficacia en machine learning en la Fig.10.




Fig. 10 Top 4 modelos con menor valor Accuracy de Machine learning

Como se puede observar el modelo con menor valor de eficacia es “Decisión Tree” de igual forma perteneciente a la familia de árboles de decisiones, en la TABLA XVII se muestran los detalles de los modelos.

TABLA XVII
 DETALLES DE TOP 4 MODELOS MENOS EFICACES DE DEEP
 MACHINE LEARNING

Área	Proceso Automatizado	Tipo de dato entrada	Tipo de dato de salida	Modelo de IA	ID
Salud	Predicción de diabetes	Estructurado (tabular)	Estructurado (binario)	Decision Tree (DT)	[51]
Salud	Predicción de diabetes	Estructurado (tabular)	Estructurado (binario)	LightGBM (LGB)	[51]
Salud	Predicción de diabetes	Estructurado (tabular)	Estructurado (binario)	AdaBoost (AB)	[51]
Salud	Predicción de diabetes	Estructurado (tabular)	Estructurado (binario)	Extra Trees (XT)	[51]

Todos los modelos con menor valor fueron puestos a prueba en el área de salud específicamente en el proceso de “Predicción de diabetes” Recibiendo datos en formato tabular y devolviendo datos en formato binario, un positivo o negativo, los 4 experimentos pertenecen a un mismo artículo.

IV. CONCLUSIONES

Luego de llevar a cabo un análisis exhaustivo de la literatura sobre la efectividad de la automatización de procesos usando inteligencia artificial en el último año, se obtuvieron una serie de hallazgos importantes: La automatización de procesos con IA se orienta más hacia el área de salud. La característica predominante de automatizar un proceso con IA es la precisión. La mayoría de los datos de entrada que reciben los modelos de IA son de naturaleza “no estructurados” para Deep Learning y “estructurados” para Machine Learning, y los datos de salida que devuelven en su gran mayoría son “estructurados” en ambos casos.

La mayoría de los experimentos no muestran métricas de eficiencia, en su mayoría se orientan a la precisión (eficacia) y los experimentos que muestran métricas de eficiencia, son métricas diferentes, lo que impide una comparación completa entre modelos. La distribución del número de experimentos de los modelos de deep learning son heterogéneos, lo cual evidencia que las investigaciones se orientan al estudio de diversas técnicas y modelos de IA.

La familia de modelos de Deep learning más presente en la literatura es YOLO, la cual procesa en su mayoría datos no estructurados y devuelve datos estructurados y la más presente en Machine learning son arboles de decisiones, aquel en su mayoría recibe y devuelve datos estructurados.

La métrica de mayor recurrencia en experimentos con modelos de deep learning es Accuracy, el cual está orientado a la precisión, es decir mide qué tan cercanas están las predicciones de un modelo con respecto a los valores correctos, obteniendo un valor promedio del 91%. La distribución de los valores de Accuracy usado en deep learning son heterogéneos. Los modelos más efectivos para la automatización de procesos son Darknet-19, Resnet-18, Resnet-50 y Resnet-10, estos reciben

imágenes (no estructurado) y devuelven datos en formato tabular (estructurado), los 4 alcanzan un Accuracy de 100%, aunque no se descarta un posible sobre ajuste. Su aplicación es en el área de Salud, específicamente en el proceso de clasificación de células sanguíneas.

El modelo de Machine learning que mayor valor obtuvo ses “Extra Trees” con un Accuracy de 99.7%, el cual se uso para automatizar el proceso de “Predicción binaria de viabilidad de un canal QoT” en el cual el modelo recibía datos estructurados en formato tabular y devolvía datos en formato binario.

El modelo GPT-3.5 turbo (base) tiene el menor valor Accuracy con solo 29.70%, recibe texto (no estructurado) y devuelve datos en formato tabular (estructurado), el cual fue usado para automatizar el proceso de Asignación de códigos ICD (códigos de clasificación de detección de enfermedades).

El proceso automatizado de manera más eficaz fue la clasificación de células, en el área de la salud, cuyos modelos usados fueron Darknet-19, Resnet-18, Resnet-50 y Resnet-10, todos obteniendo un 100% de eficacia.

Estos resultados orientan a empresas y gobiernos en la elección de modelos de inteligencia artificial para procesos críticos y ofrecen un enfoque holístico de los tipos de datos, métodos más eficaces y áreas con mayor presencia en la literatura. También resaltan oportunidades de investigación en campos menos explorados como internet de las cosas, desarrollo de software y electrónica, impulsando nuevas aplicaciones en la automatización de procesos.

V. AGRADECIMIENTOS

Agradezco a mi familia, en especial a mis padres, por su apoyo y confianza, fundamentales para la realización de este trabajo. También expreso mi gratitud al Maestro Óscar Alex Serquén Yparraguirre por su orientación y valiosas observaciones durante el desarrollo de la investigación.

REFERENCIAS

- [1] P. Gomes, L. Verçosa, F. Melo, V. Silva, C. B. Filho, and B. Bezerra, “Artificial Intelligence-Based Methods for Business Processes: A Systematic Literature Review,” Mar. 01, 2022, *MDPI*. doi: 10.3390/app12052314.
- [2] D. I. L. Alama and C. A. Dios-Castillo, “Effectiveness of Machine Learning Models in Intrusion Detection in Information Systems and Their Applicability in the Context of Entrepreneurship and Innovation: A Systematic Literature Review,” in *Proceedings of the LACCEI international Multi-conference for Engineering, Education and Technology*, Latin American and Caribbean Consortium of Engineering Institutions, 2024. doi: 10.18687/LEIRD2024.1.1.237.
- [3] E. C. María De Los Angeles, C. A. Josué Israel, and D. C. Christian Abraham, “Effectiveness of Machine Learning Models for Entrepreneurship, Innovation, and Crop Growth Prediction: A Systematic Literature Review,” in *Proceedings of the LACCEI international Multi-conference for Engineering, Education and Technology*, Latin American and Caribbean Consortium of Engineering Institutions, 2024. doi: 10.18687/LEIRD2024.1.1.238.
- [4] M. J. Page *et al.*, “The PRISMA 2020 statement: An updated guideline for reporting systematic reviews,” Mar. 29, 2021, *BMJ Publishing Group*. doi: 10.1136/bmj.n71.
- [5] F. A. La Sorte, C. A. Lepczyk, J. L. Burnett, A. H. Hurlbert, M. W. Tingley, and B. Zuckerberg, “Opportunities and challenges for big

- data ornithology,” May 01, 2018, *American Ornithological Society*. doi: 10.1650/CONDOR-17-206.1.
- [6] J. S. Santana, D. S. M. Valente, D. M. Queiroz, A. L. F. Coelho, I. A. Barbosa, and A. Momin, “Automated Detection of Young Eucalyptus Plants for Optimized Irrigation Management in Forest Plantations,” *AgriEngineering*, vol. 6, no. 4, pp. 3752–3767, Dec. 2024, doi: 10.3390/agriengineering6040214.
- [7] K. Nawab *et al.*, “Fine-tuning for accuracy: evaluation of Generative Pretrained Transformer (GPT) for automatic assignment of International Classification of Disease (ICD) codes to clinical documentation,” *J Med Artif Intell*, vol. 7, no. June, 2024, doi: 10.21037/jmai-24-60.
- [8] A. Simeth, A. A. Kumar, and P. Plapper, “Flexible and robust detection for assembly automation with YOLOv5: a case study on HMLV manufacturing line,” *J Intell Manuf*, Jun. 2024, doi: 10.1007/s10845-024-02411-5.
- [9] L. Li and L. Schulze, “Failure Prediction of Automated Guided Vehicle Systems in Production Environments through Artificial Intelligence,” *Tehnicky Glasnik*, vol. 18, no. 2, pp. 268–272, 2024, doi: 10.31803/tg-20240416185206.
- [10] X. Zhang, O. Alhendi, S. H. A. Hamid, N. Japar, and A. M. Nor, “A Computer Vision Model for Seaweed Foreign Object Detection Using Deep Learning,” *Sustainability (Switzerland)*, vol. 16, no. 20, Oct. 2024, doi: 10.3390/su16209061.
- [11] Find, “PREQUALIFICATION OF CHEST RADIOGRAPHY AND COMPUTER-AIDED DETECTION (CXR-CAD) FOR TUBERCULOSIS.”
- [12] J. S. Lee *et al.*, “Automation of trimming die design inspection by zigzag process between AI and CAD domains,” *Eng Appl Artif Intell*, vol. 127, Jan. 2024, doi: 10.1016/j.engappai.2023.107283.
- [13] A. Awasthi, N. Le, Z. Deng, R. Agrawal, C. C. Wu, and H. Van Nguyen, “Bridging human and machine intelligence: Reverse-engineering radiologist intentions for clinical trust and adoption,” *Comput Struct Biotechnol J*, vol. 24, pp. 711–723, Dec. 2024, doi: 10.1016/j.csbj.2024.11.012.
- [14] N. G. Goswami, N. Sampathila, G. M. Bairy, A. Goswami, D. D. Brp Siddarama, and S. Belurkar, “Explainable Artificial Intelligence and Deep Learning Methods for the Detection of Sick Cell by Capturing the Digital Images of Blood Smears,” *Information (Switzerland)*, vol. 15, no. 7, Jul. 2024, doi: 10.3390/info15070403.
- [15] H. Saputra, K. Muchtar, N. Chitraningrum, A. Andria, and A. Febriana, “Performance evaluation of hyper-parameter tuning automation in YOLOv8 and YOLO-NAS for corn leaf disease detection,” *Sinergi (Indonesia)*, vol. 29, no. 1, pp. 197–206, 2025, doi: 10.22441/sinergi.2025.1.018.
- [16] S. Nasiri and M. Lahmer, “A Smart AI Framework for Backlog Refinement and UML Diagram Generation,” 2024. [Online]. Available: www.ijacsa.thesai.org
- [17] H. Raoofi, A. Sabahnia, D. Barbeau, and A. Motamedi, “Deep Learning Method to Detect Missing Welds for Joist Assembly Line,” *Applied System Innovation*, vol. 7, no. 1, Feb. 2024, doi: 10.3390/asi7010016.
- [18] N. Stelmakh, S. Mandrovskaya, and R. Galagan, “APPLICATION OF RESNET-152 NEURAL NETWORKS TO ANALYZE IMAGES FROM UAV FOR FIRE DETECTION,” *Informatyka, Automatyzacja, Pomiar w Gospodarce i Ochronie Srodowiska*, vol. 14, no. 2, pp. 77–82, 2024, doi: 10.35784/iapgos.5862.
- [19] M. Alkhalaf, P. Yu, M. Yin, and C. Deng, “Applying generative AI with retrieval augmented generation to summarize and extract key clinical information from electronic health records,” *J Biomed Inform*, vol. 156, Aug. 2024, doi: 10.1016/j.jbi.2024.104662.
- [20] I. S. Rahat, M. A. Ahmed, D. Rohini, A. Manjula, H. Ghosh, and A. Sobur, “A Step Towards Automated Haematology: DL Models for Blood Cell Detection and Classification,” *EAI Endorsed Trans Pervasive Health Technol*, vol. 10, Jan. 2024, doi: 10.4108/eetpht.10.5477.
- [21] N. Girubagari and T. N. Ravi, “Parallel ABILSTM and CBIGRU Ensemble Network Intrusion Detection System,” *International Journal of Intelligent Engineering and Systems*, vol. 17, no. 1, pp. 93–107, 2024, doi: 10.22266/ijies2024.0229.10.
- [22] I. Bennis and S. Mouwafaq, “Advancing AI-driven thematic analysis in qualitative research: a comparative study of nine generative models on Cutaneous Leishmaniasis data,” *BMC Med Inform Decis Mak*, vol. 25, no. 1, Dec. 2025, doi: 10.1186/s12911-025-02961-5.
- [23] R. Allafi and I. R. Alzahrani, “Enhancing Cybersecurity in the Internet of Things Environment Using Artificial Orca Algorithm and Ensemble Learning Model,” *IEEE Access*, vol. 12, pp. 63282–63291, 2024, doi: 10.1109/ACCESS.2024.3390093.
- [24] D. Kule, O. Elezaj, and U. Mehtre, “Socio-economic Challenges in COVID Detection using Transfer Learning-Based Methods,” *WSEAS Transactions on Information Science and Applications*, vol. 21, pp. 216–228, 2024, doi: 10.37394/23209.2024.21.21.
- [25] L. W. Lung and Y. R. Wang, “SSD-based innovations for improved construction management,” *Journal of Engineering Research (Kuwait)*, 2025, doi: 10.1016/j.jer.2025.02.004.
- [26] C. Liu, X. Lin, G. Xu, G. Han, and Y. Liu, “Improved identification and tracking of three-dimensional eddies in the Southern Ocean utilizing 3D-U-Res-Net,” *Front Mar Sci*, vol. 11, 2024, doi: 10.3389/fmars.2024.1482804.
- [27] Z. Gu *et al.*, “Automatic quantitative stroke severity assessment based on Chinese clinical named entity recognition with domain-adaptive pre-trained large language model,” *Artif Intell Med*, vol. 150, Apr. 2024, doi: 10.1016/j.artmed.2024.102822.
- [28] H. Vijayaraghavan, J. von Mankowski, and W. Kellerer, “ComputiFi: Latency-Optimized Task Offloading in Multipath Multihop LiFi-WiFi Networks,” *IEEE Open Journal of the Communications Society*, vol. 5, pp. 4444–4461, 2024, doi: 10.1109/OJCOMS.2024.3426278.
- [29] E. Govi, D. Sapienza, S. Toscani, I. Cotti, G. Franchini, and M. Bertogna, “Addressing challenges in industrial pick and place: A deep learning-based 6 Degrees-of-Freedom pose estimation solution,” *Comput Ind*, vol. 161, Oct. 2024, doi: 10.1016/j.compind.2024.104130.
- [30] R. Widyastuti *et al.*, “Performance Analysis of Random Forest Algorithm in Automatic Building Segmentation with Limited Data,” *ISPRS Int J Geoinf*, vol. 13, no. 7, Jul. 2024, doi: 10.3390/ijgi13070235.
- [31] L. Mata, M. Sousa, P. Vieira, M. P. Queluz, and A. Rodrigues, “On the Use of Spatial Graphs for Performance Degradation Root-Cause Analysis Toward Self-Healing Mobile Networks,” *IEEE Access*, vol. 12, pp. 20490–20508, 2024, doi: 10.1109/ACCESS.2024.3361284.
- [32] M. El Rajab, L. Yang, and A. Shami, “Zero-touch networks: Towards next-generation network automation,” Apr. 01, 2024, *Elsevier B.V.* doi: 10.1016/j.comnet.2024.110294.
- [33] K. A. Ibrahim, P. C. K. Luk, Z. Luo, S. Y. Ng, and L. Harrison, “Revolutionizing power electronics design through large language models: Applications and future directions,” *Computers and Electrical Engineering*, vol. 123, Apr. 2025, doi: 10.1016/j.compeleceng.2025.110248.
- [34] V. K. Velpula *et al.*, “Glaucoma detection with explainable AI using convolutional neural networks based feature extraction and machine learning classifiers,” *IET Image Process*, Nov. 2024, doi: 10.1049/ipr2.13211.
- [35] S. Prabhu, K. Prasad, T. Hoang, X. Lu, and S. I., “Multi-organ squamous cell carcinoma classification using feature interpretation technique for explainability,” *Biocybern Biomed Eng*, vol. 44, no. 2, pp. 312–326, Apr. 2024, doi: 10.1016/j.bbe.2024.03.001.
- [36] P. Kmecl, M. Muni, and J. Podobnik, “Towards Autonomous Retail Stocking and Picking: Methods Enabling Robust Vacuum-Based Robotic Manipulation in Densely Packed Environments,” *Sensors*, vol. 24, no. 20, p. 6687, Oct. 2024, doi: 10.3390/s24206687.
- [37] S. H. Oh and J. G. Kim, “AI-Based PdM Platform in Deciding Failure of Automobile SCU Equipment,” *Journal of Advances in Information Technology*, vol. 15, no. 2, pp. 164–169, 2024, doi: 10.12720/jait.15.2.164-169.
- [38] J. L. Mira, J. Barba, F. P. Romero, M. S. Escobar, J. Caba, and J. C. López, “Benchmarking of computer vision methods for energy-

- efficient high-accuracy olive fly detection on edge devices,” *Multimed Tools Appl*, Oct. 2024, doi: 10.1007/s11042-024-18589-y.
- [39] J. Liu, X. Chen, and S. Yu, “From Junk to Genius: Robotic Arms and AI Crafting Creative Designs from Scraps,” *Buildings*, vol. 14, no. 12, Dec. 2024, doi: 10.3390/buildings14124076.
- [40] N. Faruqui *et al.*, “AI-Analyst: An AI-Assisted SDLC Analysis Framework for Business Cost Optimization,” *IEEE Access*, 2024, doi: 10.1109/ACCESS.2024.3519423.
- [41] R. Gonzales Martínez, V. Moreno, P. Rotta Saavedra, C. Chinguel Arrese, and A. Fraga, “A Methodology Based on Deep Learning for Contact Detection in Radar Images,” *Applied Sciences (Switzerland)*, vol. 14, no. 19, Oct. 2024, doi: 10.3390/app14198644.
- [42] Y. Jin, F. Gui, M. Chen, X. Chen, H. Li, and J. Zhang, “Deep learning-driven automated quality assessment of ultra-widefield optical coherence tomography angiography images for diabetic retinopathy,” *Visual Computer*, Jan. 2024, doi: 10.1007/s00371-024-03383-6.
- [43] K. Rezaee and H. Eslami, “Bridging machine learning and peptide design for cancer treatment: a comprehensive review,” *Artif Intell Rev*, vol. 58, no. 5, May 2025, doi: 10.1007/s10462-025-11148-3.
- [44] M. Khan, G. B. M. Mello, L. Habib, P. Engelstad, and A. Yazidi, “HITS-based Propagation Paradigm for Graph Neural Networks,” *ACM Trans Knowl Discov Data*, vol. 18, no. 4, Feb. 2024, doi: 10.1145/3638779.
- [45] G. Razzano, S. Brandi, M. S. Piscitelli, and A. Capozzoli, “Rule extraction from deep reinforcement learning controller and comparative analysis with ASHRAE control sequences for the optimal management of Heating, Ventilation, and Air Conditioning (HVAC) systems in multizone buildings,” *Appl Energy*, vol. 381, Mar. 2025, doi: 10.1016/j.apenergy.2024.125046.
- [46] E. Araya-Aliaga, E. Atencio, F. Lozano, and J. Lozano-Galant, “Automating Dataset Generation for Object Detection in the Construction Industry with AI and Robotic Process Automation (RPA),” *Buildings*, vol. 15, no. 3, Feb. 2025, doi: 10.3390/buildings15030410.
- [47] G. Bansal, A. Nawal, V. Chamola, and N. Herencsar, “Revolutionizing Visuals: The Role of Generative AI in Modern Image Generation,” *ACM Transactions on Multimedia Computing, Communications, and Applications*, Nov. 2024, doi: 10.1145/3689641.
- [48] G. Anichini, C. Natali, and F. Cabitza, “Invisible to Machines: Designing AI that Supports Vision Work in Radiology,” *Comput Support Coop Work*, Dec. 2024, doi: 10.1007/s10606-024-09491-0.
- [49] L. Chen *et al.*, “Large circuit models: opportunities and challenges,” *Science China Information Sciences*, vol. 67, no. 10, Oct. 2024, doi: 10.1007/s11432-024-4155-7.
- [50] C. Gerling and S. Lessmann, “Multimodal Document Analytics for Banking Process Automation,” Jul. 2023, doi: 10.1016/j.inffus.2025.102973.
- [51] G. L. Sumalata, C. Joshitha, and K. Meenaksh, “PREDICTION OF DIABETES MELLITUS USING ARTIFICIAL INTELLIGENCE TECHNIQUES,” *Scalable Computing*, vol. 25, no. 4, pp. 3200–3213, 2024, doi: 10.12694/scpe.v25i4.2884.
- [52] J. Bautista-Hernández and M. Á. Martín-Prats, “Artificial Intelligence Approach in Aerospace for Error Mitigation,” *Aerospace*, vol. 11, no. 4, Apr. 2024, doi: 10.3390/aerospace11040300.
- [53] C. D. Schultz, C. Koch, and R. Olbrich, “Dark sides of artificial intelligence: The dangers of automated decision-making in search engine advertising,” *J Assoc Inf Sci Technol*, vol. 75, no. 5, pp. 550–566, May 2024, doi: 10.1002/asi.24798.
- [54] C. Natalino, A. Panahi, N. Mohammadiha, and P. Monti, “AI/ML-as-a-Service for optical network automation: Use cases and challenges [Invited],” *Journal of Optical Communications and Networking*, vol. 16, no. 2, pp. A169–A179, Feb. 2024, doi: 10.1364/JOCN.500706.
- [55] G. Szabó, J. Pető, and A. Vidács, “Deployment options of AI components for network resource management in 5G-enabled agile industrial production cell,” *International Journal of Communication Systems*, Feb. 2024, doi: 10.1002/dac.5983.
- [56] H. Shin, M. Kwon, Y. Lee, Y. Kim, M. K. Cho, and I. Song, “Circuit-Centric Genetic Algorithm for the Optimization of a Radio-Frequency Receiver,” *Electronics (Switzerland)*, vol. 14, no. 4, Feb. 2025, doi: 10.3390/electronics14040770.
- [57] B. Kavas *et al.*, “In-situ controller autotuning by Bayesian optimization for closed-loop feedback control of laser powder bed fusion process,” *Addit Manuf*, vol. 99, Feb. 2025, doi: 10.1016/j.addma.2025.104641.
- [58] K. Abbas, A. Nauman, M. Bilal, J. H. Yoo, J. W. K. Hong, and W. C. Song, “AI-Driven Data Analytics and Intent-Based Networking for Orchestration and Control of B5G Consumer Electronics Services,” *IEEE Transactions on Consumer Electronics*, vol. 70, no. 1, pp. 2155–2169, Feb. 2024, doi: 10.1109/TCE.2023.3324010.
- [59] D. Gao *et al.*, “A Risk-Sensitive Intelligent Control Algorithm for Servo Motor Based on Value Distribution,” *Applied Sciences (Switzerland)*, vol. 14, no. 13, Jul. 2024, doi: 10.3390/app14135618.
- [60] H. Amini, K. Alanne, and R. Kosonen, “Building simulation in adaptive training of machine learning models,” Sep. 01, 2024, *Elsevier B.V.* doi: 10.1016/j.autcon.2024.105564.
- [61] M. Zagorowska, C. König, H. Yu, E. C. Balta, A. Rupenyan, and J. Lygeros, “Efficient safe learning for controller tuning with experimental validation,” Oct. 2023, [Online]. Available: <http://arxiv.org/abs/2310.17431>
- [62] R. Khelifi, B. Nini, and M. Berkane, “Enhanced Classification System for Real-Time Embedded Vision Applications,” *IEEE Access*, vol. 12, pp. 162311–162326, 2024, doi: 10.1109/ACCESS.2024.3489476.
- [63] L. Regenwetter, Y. A. Obaideh, and F. Ahmed, “MCD: A Model-Agnostic Counterfactual Search Method For Multi-modal Design Modifications,” Jun. 2024, [Online]. Available: <http://arxiv.org/abs/2305.11308>
- [64] M. Trzciński, S. Lukasik, and A. H. Gandomi, “Optimizing the Structures of Transformer Neural Networks Using Parallel Simulated Annealing,” *Journal of Artificial Intelligence and Soft Computing Research*, vol. 14, no. 3, pp. 267–282, Jun. 2024, doi: 10.2478/jaiscr-2024-0015.
- [65] H. Mohammed Zakaria, H. Mad Lazim, and R. Iteng, “A Qualitative Approach to Understanding the Effect of Technology Adoption on the Middle East Upstream Oil and Gas Company’s Operational Performance,” *Paper Asia*, vol. 40, no. 3, pp. 161–168, May 2024, doi: 10.59953/paperasia.v40i3b.117.
- [66] A. Carpegna, A. Savino, and S. Di Carlo, “Spiker+: a framework for the generation of efficient Spiking Neural Networks FPGA accelerators for inference at the edge,” *IEEE Trans Emerg Top Comput*, pp. 1–15, 2024, doi: 10.1109/TETC.2024.3511676.
- [67] V. Bhardwaj, A. Noonina, S. Chaurasia, M. Kumar, A. Rashid, and M. T. Ben Othman, “Optimizing Structured Data Processing Through Robotic Process Automation,” *Journal Européen des Systèmes Automatisés*, vol. 57, no. 5, pp. 1523–1530, Oct. 2024, doi: 10.18280/jesa.570528.
- [68] A. Tayab and Y. Li, “The contribution of the RPA technology in enhancing better business performance in Warehouse management,” *IEEE Access*, 2024, doi: 10.1109/ACCESS.2024.3470221.
- [69] R. Hayami, N. Yusoff, K. M. Daud, and Y. Fatma, “Job Resumes Recommendation using Integration of Fuzzy Discernibility Matrix Feature Selection and Convolutional Neural Network Multi-label Text Classification,” *Informatica (Slovenia)*, vol. 49, no. 13, pp. 49–58, Feb. 2025, doi: 10.31449/inf.v49i13.6848.
- [70] H. Fang *et al.*, “A new cooperative control solution of subway BAS: an improved fuzzy PID control algorithm,” *PeerJ Comput Sci*, vol. 10, 2024, doi: 10.7717/PEERJ-CS.1765.
- [71] J. Mietkiewicz *et al.*, “Enhancing Control Room Operator Decision Making,” *Processes*, vol. 12, no. 2, Feb. 2024, doi: 10.3390/pr12020328.
- [72] O. Rainio, J. Teuho, and R. Klén, “Evaluation metrics and statistical tests for machine learning,” *Sci Rep*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-56706-x.