

Performance of Artificial Intelligence Algorithms in Municipal Solid Waste Management: A Comparative Systematic Review

Lisbeth Yoanella Jaquima-Chambi¹; Janeth Yajaira Torres-Luna²; Gerson José Márquez³

^{1,2,3}Universidad Tecnológica del Perú, Perú, U19220275@utp.edu.pe, U21207271@utp.edu.pe, gmarquez@utp.edu.pe

Abstract– Given the increasing environmental crisis and the logistical challenges inherent in municipal solid waste management in modern cities, due to population growth and limitations in final disposal, it has become essential to evaluate advanced technological solutions. Therefore, this Systematic Literature Review (SLR) aimed to analyze and compare the performance of Artificial Intelligence (AI) algorithms applied to waste generation prediction, waste classification, and collection route optimization, against conventional methods. The methodology involved an SLR without meta-analysis, structured using the PICOC strategy and adhering to PRISMA guidelines, resulting in the selection of 56 studies from the Scopus and Scilit databases for synthesis. The findings revealed the consistent superiority of AI approaches. In the prediction domain, Deep Learning and Boosting models (DNN, XGBoost) achieved R^2 coefficients near 1.00 and predictive error reductions exceeding 40% compared to traditional linear regression. For classification, computer vision architectures like Swin Transformer V2 and hybrid CNN + Morph-HSV models achieved accuracies above 97% (up to 99.58%). In the logistics domain, metaheuristics such as I-ACO and PSO, integrated with IoT, demonstrated high operational efficiency, achieving average reductions of 25% to 42% in distance traveled, fuel consumption, and CO₂ emissions. It is concluded that AI is an essential tool for sustainability, demonstrating high adaptability in diverse urban contexts. However, critical challenges have been identified, such as methodological and metric heterogeneity in studies, which complicate generalization, and the persistent difficulty in discriminating waste based on visual similarity.

Keywords– Municipal solid waste, waste management, artificial intelligence, machine learning, deep learning.

Desempeño de Algoritmos de IA en la Gestión de Residuos Sólidos Urbanos: Una Revisión Sistemática Comparativa

Lisbeth Yoanella Jaquima-Chambi¹; Janeth Yajaira Torres-Luna²; Gerson José Márquez³

^{1,2,3}Universidad Tecnológica del Perú, Perú, U19220275@utp.edu.pe, U21207271@utp.edu.pe, gmarquez@utp.edu.pe

Resumen– Dada la creciente crisis ambiental y los desafíos logísticos inherentes a la gestión de residuos sólidos urbanos en las ciudades modernas, debido al crecimiento poblacional y las limitaciones en la disposición final, se ha vuelto imprescindible la evaluación de soluciones tecnológicas avanzadas. Por ello, la presente Revisión Sistemática de Literatura (RSL) tuvo como objetivo analizar y comparar el desempeño de los algoritmos de Inteligencia Artificial (IA) aplicados a la predicción de generación, clasificación de residuos y optimización de rutas de recolección, frente a los métodos convencionales. La metodología se basó en una RSL sin metaanálisis, utilizando la estrategia PICOC y siguiendo las directrices PRISMA, lo que resultó en la selección de 56 estudios provenientes de las bases de datos Scopus y Scilit para la síntesis de resultados. Los hallazgos revelaron la superioridad consistente de los enfoques de IA. En predicción, modelos de Deep Learning y Boosting (DNN, XGBoost) lograron coeficientes de determinación (R^2) cercanos a 1.00, con reducciones del error predictivo superiores al 40 % en contraste con la regresión lineal tradicional. En clasificación, arquitecturas de visión por computadora como Swin Transformer V2 y modelos híbridos CNN + Morph-HSV alcanzaron precisiones por encima del 97 % (hasta 99.58 %), permitiendo la segregación automatizada y la minimización del riesgo laboral. En el ámbito logístico, algoritmos como I-ACO y PSO, integrados con IoT, demostraron una alta eficiencia operativa, consiguiendo reducciones promedio del 25 % al 42 % en la distancia recorrida y las emisiones de CO₂. Se concluye que la IA es un instrumento esencial para la sostenibilidad, mostrando una alta adaptabilidad en contextos urbanos diversos. No obstante, se identifican desafíos críticos, como la heterogeneidad metodológica y métrica de los estudios, que complican la generalización, y la persistente dificultad en la discriminación de residuos por similitud visual.

Palabras clave– residuos sólidos municipales, gestión de residuos, inteligencia artificial, aprendizaje automático, aprendizaje profundo.

I. INTRODUCCIÓN

La gestión de residuos sólidos urbanos (RSU) se ha convertido en uno de los principales desafíos ambientales y sociales en las ciudades modernas, como consecuencia del crecimiento poblacional, el aumento del consumo y las capacidades limitadas de disposición final, lo que compromete la sostenibilidad de los procesos de recolección y tratamiento, dificultando una gestión adecuada de los residuos [1].

En los últimos años, la implementación de las tecnologías digitales ha propiciado importantes transformaciones en la gestión de residuos. Herramientas como Machine Learning (ML), el internet de las cosas (IoT) y el blockchain propician la transición a sistemas más inteligentes a través de la

automatización, la predicción de la generación y la trazabilidad de los residuos [2]. Hamdan et al. [3] muestran que en la India apenas el 20 % de los residuos se trata adecuadamente, lo que contrasta con las importantes cantidades aún sin aprovecharse, lo que evidencia la urgencia de la implementación de soluciones tecnológicas innovadoras para la gestión de los RSU.

Asimismo, la integración de Inteligencia Artificial (IA) ha promovido el desarrollo de modelos avanzados en clasificación, predicción y optimización de gestión de residuos. De esta manera, Dao et al. [4] realizaron un análisis detallado de algoritmos de ML y Deep Learning (DL) en la gestión de residuos usando redes neuronales convolucionales (CNN), máquinas de soporte de vectores (SVM), Random Forest (RF), K-Nearest Neighbors (KNN) y métodos híbridos, incluyendo la combinación de MobileNetV3 para la extracción de características y el Harris Hawk Optimization (HHO) para la selección de variables. Sin embargo, a pesar de que los algoritmos tradicionales, como la regresión logística o los árboles de decisión, pueden proporcionar soluciones rápidas y de bajo coste computacional, los enfoques de DL tienden a presentar mejor rendimiento en precisión y capacidad de generalización, alcanzando niveles superiores al 95 % en la tasa de exactitud de la clasificación de residuos.

Hannan et al. [5] señalan que los modelos de optimización tradicionales presentan dificultades metodológicas, como la incertidumbre de los datos de demanda, la variabilidad temporal y espacial de la generación de residuos y las fluctuaciones del tráfico urbano. Además, se observan restricciones de escalabilidad, ya que muchos modelos tienen buen desempeño en escenarios pequeños, pero su rendimiento disminuye al aplicarse a grandes ciudades o situaciones complejas.

Por otro lado, Fang et al. [6] afirman que puede reducirse hasta 36.8 % el recorrido de las flotas y un 13.35 % el coste incurrido, si se aplica la IA en la logística de residuos. Estos resultados reflejan tanto la diversidad de enfoques como el potencial de las soluciones basadas en IA para mejorar la gestión de residuos.

A pesar de estos avances, la evidencia comparativa disponible es aún limitada para identificar los algoritmos de IA más eficaces en la gestión de RSU en diversos contextos urbanos. En este sentido, se plantea una Revisión Sistemática de Literatura (RSL) orientada a sistematizar y comparar los algoritmos de IA aplicados a este ámbito.

La presente RSL tiene como objetivo analizar y comparar el desempeño de dichos algoritmos en la predicción de la generación, la clasificación de residuos y la optimización de rutas de recolección, en contraste con métodos convencionales, con el fin de proporcionar un marco comparativo que integre avances, limitaciones y aplicaciones en distintos contextos urbanos.

II. METODOLOGÍA

A. Estrategia de Búsqueda de Información

La presente investigación corresponde a una Revisión Sistemática de Literatura sin metaanálisis. Para la búsqueda sistemática de información se empleó el método PICOC, a partir de la siguiente pregunta de investigación principal, que orientó todo el proceso de identificación y selección de fuentes: ¿Qué algoritmos de inteligencia artificial son más efectivos, en comparación con los métodos convencionales, para optimizar la gestión de residuos sólidos urbanos en términos de predicción, clasificación y rutas de recolección en contextos urbanos?

A partir de la pregunta de investigación principal, se identificaron los componentes PICOC que se presentan en la Tabla I. Además, asociados a cada uno de estos componentes, se formularon las siguientes subpreguntas:

RQ1: ¿Qué deficiencias de gestión se presentan en los procesos de generación, clasificación y recolección de residuos sólidos urbanos?

RQ2: ¿Qué técnicas y algoritmos de inteligencia artificial se aplican para la predicción de generación de residuos, clasificación de materiales reciclables y optimización de rutas?

RQ3: ¿Qué diferencias existen entre los algoritmos de IA y los métodos tradicionales en la gestión de residuos urbanos?

RQ4: ¿Qué resultados de eficiencia, eficacia, precisión, escalabilidad y beneficios de sostenibilidad se reportan en la aplicación de algoritmos de IA en la gestión de RSU?

RQ5: ¿En qué contextos urbanos (ciudades inteligentes, en desarrollo, densamente pobladas y sostenibles) se ha evaluado el desempeño de los algoritmos de IA en la gestión de residuos?

En la Tabla I se presentan las palabras clave asociadas a los componentes PICOC, las cuales fueron combinadas mediante los operadores booleanos AND y OR para elaborar las ecuaciones de búsqueda aplicadas en las bases de datos.

1) Ecuación de búsqueda aplicada en Scopus:

("urban solid waste" OR "municipal solid waste" OR "urban waste" OR "waste management") AND ("artificial intelligence" OR "AI" OR "machine learning" OR "deep learning" OR "evolutionary algorithm*" OR optimiz*) AND ("traditional method*" OR "conventional approach*" OR "conventional method*") AND ("waste generation prediction" OR "recyclable material classification" OR "collection route optimization" OR efficien* OR accurac* OR sustainab*) AND ("smart cit*")

TABLA I
DESCRIPCIÓN DE LOS COMPONENTES PICOC Y PALABRAS CLAVE

Componentes	Descripción	Palabras Clave
P (Problema)	Residuos sólidos urbanos en contextos urbanos	Urban solid waste, waste management, municipal solid waste, urban garbage, waste
I (Intervención)	Algoritmos y técnicas de inteligencia artificial aplicados	Artificial intelligence, algorithms, machine learning, deep learning, evolutionary algorithms, optimization
C (Comparación)	Comparación entre algoritmos o con métodos tradicionales	Traditional methods, conventional methods, conventional approaches
O (Resultados)	Resultados de eficiencia, precisión y sostenibilidad	Waste generation prediction, recyclable material sorting, collection route, optimization, efficiency, accuracy, sustainability
C (Contexto)	Entornos urbanos o ciudades inteligentes	Smart cities

2) Ecuación de búsqueda aplicada en Scilit:

("urban solid waste" OR "municipal solid waste" OR "urban waste" OR "waste management") AND ("artificial intelligence" OR "AI" OR "machine learning" OR "deep learning" OR "evolutionary algorithm*" OR optimiz*) AND ("waste generation prediction" OR "recyclable material classification" OR "collection route optimization" OR efficien* OR accurac* OR sustainab*) OR ("traditional method*" OR "conventional approach*" OR "conventional method*" OR "smart cit*")

B. Criterios de Elegibilidad

Se establecieron los siguientes criterios de inclusión (CI) y exclusión (CE) para la selección de los estudios:

CI1: Los estudios incluidos deben abordar la gestión de residuos sólidos urbanos.

CI2: Los estudios deben aplicar o describir técnicas y algoritmos de inteligencia artificial.

CI3: Los estudios incluidos deben reportar resultados estadísticos de la aplicación de predicción y clasificación de materiales reciclables y optimización de rutas.

CI4: Los estudios deben reportar resultados sobre la eficiencia, precisión o beneficios de sostenibilidad (ambiental, económica) de los algoritmos aplicados.

CI5: Los estudios se han desarrollado en entornos urbanos (ciudades inteligentes, en desarrollo, densamente pobladas y sostenibles).

CE1: Estudios que no sean artículos originales, como artículos de conferencia, artículos de revisión, tesis o libros.

CE2: Documentos publicados antes de 2018.

CE3: Publicaciones en idiomas diferentes al inglés y español.

CE4: Artículos que solo describen un marco o concepto general sin presentar métodos, resultados o comparaciones específicos.

C. Proceso de Selección de Estudios

El proceso de selección de estudios se realizó conforme a las directrices de la declaración PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) y se resume en el diagrama de flujo de la Fig. 1. En la fase de identificación se recuperaron 1,187 registros a partir de dos bases de datos: Scilit ($n = 927$) y Scopus ($n = 260$). Tras la eliminación de registros duplicados o triplicados ($n = 34$), se obtuvieron 1,153 registros únicos para el cribado.

Durante el cribado inicial se excluyeron 599 registros según los criterios previamente definidos, eliminándose principalmente documentos que no correspondían a artículos originales ($n = 564$), publicaciones anteriores a 2018 ($n = 33$) y trabajos en idiomas distintos del inglés o el español ($n = 2$). Posteriormente, el cribado por la lectura de títulos y resúmenes llevó a la exclusión de 316 registros adicionales por no cumplir los criterios establecidos. Como resultado, se seleccionaron 238 registros para revisión a texto completo; sin embargo, sólo pudieron recuperarse 161 estudios para la evaluación de elegibilidad.

Finalmente, tras la lectura a texto completo, se excluyeron 105 estudios por no satisfacer los criterios de elegibilidad. En consecuencia, la muestra final incluida para el análisis y la síntesis de resultados estuvo compuesta por 56 estudios.




Fig. 1 Diagrama de flujo PRISMA.

III. RESULTADOS

A. Deficiencias de la Gestión de RSU

La gestión de los residuos sólidos urbanos se ha consolidado como un desafío ambiental y social prioritario [7]. A escala global se generan aproximadamente 2,010 millones de toneladas de residuos al año [8], y la presión del crecimiento poblacional y la urbanización ha evidenciado que los enfoques tradicionales no logran responder con eficiencia a volúmenes crecientes, lo que sustenta la necesidad de incorporar soluciones tecnológicas basadas en IA [9], [10].

La crisis se agrava por la tendencia sostenida al alza en la generación de residuos. Se proyecta que la producción mundial alcanza 2,200 millones de toneladas anuales para 2025 [11], [12] y que hacia 2050 llegue a unos 3,400 millones de toneladas [13]. Sin embargo, los sistemas actuales muestran una capacidad insuficiente: entre 33 % y 40 % de los residuos no se gestiona adecuadamente y termina en vertidos o quema abierta [14], mientras que el reciclaje global permanece en niveles reducidos (≈ 13.5 %) [15], reflejando pérdidas importantes de material valorizable y un desempeño limitado en economía circular.

En contextos regionales, la evidencia reporta déficits estructurales y operativos que se manifiestan tanto en disposición final como en procesamiento. En Mauricio, el vertedero absorbe alrededor del 97 % de los residuos, evidenciando dependencia de esquemas convencionales [16]. Incluso en ciudades o países con metas avanzadas persisten brechas, como el déficit de reciclaje de vidrio del 84 % que existe en Singapur [17]. En Perú, casi la mitad de los residuos generados se gestiona incorrectamente [18], mientras que en Indonesia solo se procesa el 55.87 % de la basura anual, con un déficit del 44.13 % [19]. Estas diferencias muestran que el problema no solo depende de infraestructura, sino también de la eficiencia del sistema y la articulación de sus etapas.

Las limitaciones se acentúan en la clasificación y la recolección. La separación convencional depende en gran medida del trabajo manual, lo que la hace lenta, propensa a errores y poco escalable, elevando costos y reduciendo eficiencia [20], [21]. La heterogeneidad de los RSU (variaciones en composición, forma, tamaño, textura y color) complica la segregación tradicional [16], y la separación en origen se ve restringida por brechas de comprensión ciudadana, con efectos directos en la disposición inadecuada [22], [23]. En términos económicos, la clasificación incorrecta puede generar costos significativos; por ejemplo, en una ciudad sueca se ha reportado un impacto del orden de 13 millones de coronas suecas anuales [13].

Por otro lado, persiste un enfoque de recolección periódica con rutas y frecuencias fijas que no considera el nivel real de llenado de contenedores, lo que provoca desplazamientos innecesarios y menor eficiencia [24]. Estas prácticas incrementan emisiones y costos; se han estimado emisiones de recolección del orden de 0.21 kg CO₂/km [20]. Además, limitaciones de enrutamiento y de programación dificultan la localización precisa y la planificación óptima, lo

que puede traducirse en retrasos, desbordamientos y problemas higiénico-sanitarios urbanos [24]. En la Fig. 2 se comparan los porcentajes de ineficiencia logística y de procesamiento de residuos en algunos países, evidenciando niveles elevados de ineficacia asociados a sistemas tradicionales de gestión.




Fig. 2 Porcentaje de ineficiencia logística y de procesamiento de residuos en distintos países.

B. Clasificación de las Tecnologías de Gestión de RSU

En la Tabla II se presentan las categorías de las tecnologías de gestión de RSU, clasificadas en tradicionales y basadas en IA (de nivel intermedio y avanzado). Esta clasificación se fundamenta en la capacidad de procesamiento y la adaptabilidad operativa de las tecnologías, lo que permite distinguir claramente entre modelos estadísticos básicos y arquitecturas de aprendizaje profundo.

TABLA II
TECNOLOGÍAS DE GESTIÓN DE RSU

Categoría	Descripción	Algoritmos/Métodos
Métodos Tradicionales	Procesos manuales o modelos estáticos con baja capacidad de generalización.	Segregación manual, Rutas fijas, Regresión Lineal, Regresión Logística, Árboles de Decisión (DT), ARIMA
IA de Nivel Intermedio	Algoritmos de aprendizaje supervisado que ofrecen soluciones rápidas, pero con limitaciones en datos masivos.	SVM, KNN, Random Forest (RFR)
IA de Nivel Avanzado	Arquitecturas de aprendizaje profundo y metaheurísticas capaces de manejar incertidumbre y tiempo real.	Deep Learning (CNN, LSTM, YOLO, Swin Transformer V2, VGG16), XGBoost, Metaheurísticas (I-ACO, PSO)

C. Algoritmos y Técnicas de IA Aplicados

Las técnicas de Inteligencia Artificial identificadas se concentran en tres dominios: predicción de volúmenes y nivel de llenado, clasificación de materiales y optimización logística de la recolección, con el objetivo de convertir sistemas estáticos en esquemas predictivos y dinámicos.

En predicción, predominan modelos capaces de capturar relaciones no lineales y patrones temporales. Los enfoques de boosting, especialmente XGBoost, se reportan entre los más precisos para pronosticar volúmenes de RSU [9], [18], y su variante GSO-XGBoost mejora el rendimiento al estimar categorías específicas como papel/cartón, plástico y restos de

comida [17]. Para escenarios multirregionales, Kernel Ridge Regression (KRR) destaca por robustez, con $R^2 = 0.966$ y MAPE = 4.55 % [25]. En Deep Learning, las redes LSTM superan consistentemente a modelos clásicos para pronosticar llenado/vaciado de contenedores y muestran buen desempeño en predicción de RSU en Etiopía ($R^2 = 0.93$) y tasas de reciclaje ($R^2 = 0.92$) [26]–[28], mientras que las DNN alcanzan alta precisión a escala provincial en China ($R^2 = 0.97$) [26]–[28]. Para flujos complejos, se emplean híbridos como MC-ITD-GEP con $R^2 = 0.782$ [29].

En clasificación, la evidencia se centra en visión por computadora con CNN y arquitecturas optimizadas para velocidad o despliegue en borde. La familia YOLO (v3, v8, v11) es ampliamente usada, y YOLOv8 destaca por el equilibrio entre exactitud y rapidez en RVMs, con 14.1 ms por imagen [10], [23], [30], [31]; YOLOv5 también se aplicó para cuantificar “litter” urbano en Japón [32]. Para edge computing, MobileNetV2 se optimiza en dispositivos como Raspberry Pi 4 con inferencia de 120 ms por fotograma [21], [33], [34], y MobileNetV3 se selecciona por su tamaño reducido (49.5 MB) [22]; asimismo, SSD MobileNetV2 en TensorFlow Lite logra reconocimiento robusto en tiempo real para 12 categorías [35], [36]. En precisión alta, se reportan Swin Transformer V2 (99.52 %) [37], el híbrido SVM–CNN + Morph-HSV (99.34 %) [19], [38], FOMO MobileNetV2 0.35 cuantizado (99.31 %) [12] y SWSO–NC–DBN (99.1 %) [39]. También se documentan sistemas robustos con rendimientos intermedios-altos, como YOLOv3 + ResNet-50 + XGBoost (98.88 %) [40], EBMOHDL-WC (98.04 %) [41], AMLWRF (96.1 %) [42], combinaciones con ResNet-50, YOLOv5 y CNN débilmente supervisada (~96 %) [43], y RWC-Net (95.01 %) [36].

En optimización logística, se observa la integración de metaheurísticas con predicción de demanda. PSO supera a Clarke & Wright [44], mientras que I-ACO incorpora restricciones de carbono y mejora la eficiencia [45]; además, se reporta ACO en optimización dinámica junto con Swin Transformer V2 [37]. Para habilitar rutas adaptativas, Random Forest predice el estado del contenedor con 99.25 % de precisión [46], y el CVRP implementado mediante VROOM se utiliza para optimizar la recolección basada en señales [20]. Otros enfoques incluyen IMFO para optimización de rutas [40] y STO-TSP para enrutamiento en redes IoT con retraso mínimo (0.11 s) [24].

Finalmente, persisten desafíos asociados al dato y a la percepción visual. Se reportan errores por similitud visual (p. ej., plástico transparente vs vidrio) en YOLOv11 [10], confusiones en YOLOv5 (latas vs botellas) [23] y limitaciones con EfficientNet al diferenciar plástico y metal, atribuidas también al desequilibrio de clases [47]. El sesgo de datos afecta métricas por clase, como en RWC-Net, donde “basura” presenta la F1 más baja (88.55 %) por baja representación [36], y en un estudio con YOLOv8 la categoría orgánicos fue la menos precisa [7]. Además, la generalización puede verse restringida por datasets pequeños, como en SSD MobileNetV2 entrenado con 1,800 imágenes [33].

D. Comparativa de Algoritmos con IA vs. Métodos Tradicionales

La evidencia empírica demuestra una superioridad consistente de los enfoques avanzados de IA, especialmente Deep Learning y las técnicas de Boosting, en comparación con los métodos tradicionales y de Machine Learning más simples. En la Tabla III se presentan las diferencias claves de desempeño de los algoritmos de IA y enfoques convencionales.

TABLA III
DIFERENCIAS CLAVE DE DESEMPEÑO DE ALGORITMOS DE IA Y ENFOQUES CONVENCIONALES

Área de aplicación	Algoritmo superior (IA/DL)	Desempeño clave	Método inferior comparado	Ref.
Predicción de generación	XGBoost	$R^2 = 0.996$	Árboles de decisión ($R^2 = 0.978$)	[18]
	LSTM	$R^2 = 0.92$	Regresión lineal ($R^2 = 0.62$), ARIMA ($R^2 = 0.78$)	[48]
	DNN	$R^2 = 0.97$	MLR, SVR y KNN ($R^2 < 0.90$)	[28]
Clasificación (Precisión)	MobileNetV2	Precisión: 96.57 %	SVM (63 %), AlexNet (87.69 %), ResNet (88.66 %)	[11]
Clasificación (Híbrido)	SVM - CNN	Precisión: 99.34 %	SVM individual (83.61 %), CNN (98.92 %), VGG16 (97 %)	[19]
Clasificación (Híbrido)	YOLOv3 + ResNet - 50 + XGBoost	Precisión: 98.88 %	FastR-CNN (81.60 %), MobileNetV2 (88 %), DNet12 (95 %)	[40]
Clasificación (DL)	Swin Transformer V2	Precisión: 99.52 %, F1-score: 99.38 %	CNN (95.31 %), ResNet50V2 (98.95 %)	[37]
Optimización de rutas	PSO (Metaheurística)	Reducción del 41 % en distancia y 41.37 % en CO_2	Heurística Clarke & Wright (35.42 % en CO_2)	[44]
Predicción multirregional	KRR	R^2 más alto (0.966)	SVR ($R^2 = 0.956$), RNA ($R^2 = 0.953$)	[25]

E. Desempeño y Beneficios de Sostenibilidad

El desempeño de los algoritmos de IA aplicados a la gestión de RSU es consistentemente superior al de los métodos tradicionales en tres dimensiones complementarias: precisión algorítmica, eficiencia temporal de inferencia y optimización logística. Estas mejoras se explican por la convergencia entre Deep Learning, IoT y metaheurísticas de optimización, que habilita el procesamiento de grandes volúmenes de datos en tiempo real y la adaptación a condiciones urbanas dinámicas, con beneficios ambientales y económicos medibles [19], [22], [37], [40], [45], [46], [49]. En la literatura revisada, los resultados se organizan principalmente en tres dominios: predicción, clasificación y optimización logística.

En el dominio predictivo, los modelos de Machine Learning y Deep Learning muestran ventajas claras para anticipar tendencias de generación, flujos y niveles de llenado, superando a enfoques estadísticos convencionales. Se reportan desempeños elevados para modelos basados en XGBoost, Random Forest Regression (RFR) y DNN, con coeficientes de determinación (R^2) entre 0.93 y 1.00, junto con reducciones de RMSE superiores al 40 % frente a regresión lineal en varios casos [18], [28], [50]. Estos resultados son relevantes porque, al mejorar la capacidad de pronóstico, se fortalece la planificación operativa y la asignación de recursos. En particular, los modelos recurrentes como LSTM y combinaciones del tipo 1D-CNN + LSTM aportan una ventaja específica en la alineación temporal de las series, mejorando la predicción del llenado de contenedores y apoyando la programación diaria de recolección [26], [27]. Asimismo, la incorporación de estrategias híbridas con optimización evolutiva, como GSO-XGBoost y GA-ANN, contribuye al ajuste de hiperparámetros y a la mitigación del sobreajuste, lo que favorece la transferencia del modelo a escenarios reales [17], [51]. En esta línea, métodos como Gradient Boosting Regression Trees (GBRT) se vinculan con beneficios operativos y energéticos al habilitar decisiones más dinámicas (p. ej., reducción de recorridos innecesarios y asignación eficiente de recursos) en sistemas urbanos de recolección. La Tabla IV resume los modelos con mejor desempeño predictivo en los distintos contextos analizados, mientras que la Fig. 3 compara el R^2 alcanzado por los principales modelos, evidenciando el alto ajuste de RFR y XGBoost ($R^2 \approx 1.00$) y su capacidad para modelar la variabilidad de los datos.

TABLA IV
DESEMPEÑO PREDICTIVO DE GENERACIÓN Y FLUJO DE RESIDUOS

Algoritmo	Variable	Métrica	Ref.
RFR	Generación RSU (OCDE 43 países)	$R^2 = 1$, MAPE: 3 – 9 %	[50]
XGBoost	Generación RSU (4 343 reg.)	$R^2 = 0.996$, RMSE: 2.014	[18]
DNN	Volumen RSU (China, 2008–2019)	$R^2 = 0.970$, RMSE: 1288.80	[28]
KRR	Determinantes RSU (UE)	$R^2 = 0.966$, MAPE: 4.55 %	[25]
LSTM	Tendencia RSU (Etiopía)	$R^2 = 0.930$, MSE: 1.62×10^8	[27]
	Llenado contenedores (Wyndham)	$R^2 = 0.925$, MAE: 0.602, RMSE: 1.579	[26]
	Tasas reciclaje	$R^2 = 0.920$, MAE: 3.5 %	[48]
GA-ANN	RSU (India)	$R^2 = 0.870$, RMSE: 95.7	[51]
GBRT	Edificio-nivel (NYC edificios)	$R^2 = 0.870$, RMSE: 0.034, MAE: 20 %	[52]

En clasificación, la visión por computadora y el aprendizaje profundo han reemplazado con eficacia la separación manual, al ofrecer automatización con alta precisión y menor exposición a errores operativos [19]. En términos de desempeño técnico, modelos como MobileNetV2 (TinyML), Swin Transformer V2, enfoques híbridos SVM–

CNN, así como arquitecturas de detección y clasificación como YOLOv11 y ResNet, alcanzan precisiones superiores al 97 %, además de tiempos de inferencia compatibles con despliegues en edge computing e integración con IoT [12], [37], [38], [48], [53].




Fig. 3 Desempeño predictivo (R^2) de los algoritmos aplicados a la generación de residuos.

La evidencia también muestra una expansión hacia tareas especializadas, como clasificación de biorresiduos, detección de plásticos degradados e identificación de residuos metálicos en cenizas (MIBA), lo que amplía el alcance de la IA dentro de estrategias de economía circular y sostenibilidad urbana [20], [35], [54]. En varios estudios se reporta el uso de componentes como Global Average Pooling (GAP) para reducir el riesgo de sobreaprendizaje y mejorar la generalización [8]. La Tabla V sintetiza los resultados de desempeño y los beneficios de sostenibilidad, considerando tanto eficiencia operativa como efectos ambientales.

No obstante, el rendimiento no es homogéneo entre enfoques y existen resultados por debajo del umbral del 97 %, particularmente cuando se priorizan modelos compactos o cuando los datasets son limitados. Por ejemplo, un modelo basado en Xception y MobileNetV3 reporta una precisión promedio de 94.26 % en nueve categorías [22]. De manera similar, MobileNetV2 distribuido alcanza 96.57 % en seis clases y RWC-Net (DenseNet201 + MobileNetV2) registra 95.01 %; aunque son adecuados para entornos de baja latencia y despliegue en borde, tienden a quedar por debajo de arquitecturas híbridas u optimizadas en precisión [11], [36]. A la vez, se observan trade-offs claros entre exactitud y costo computacional: VGG16 logra alrededor de 96 % pero con un tamaño del orden de 138 millones de parámetros, lo que implica un entrenamiento costoso y una generalización condicionada por el tamaño del dataset y la simplicidad de las categorías evaluadas [55]. En el extremo de eficiencia, una CNN ligera de cinco capas entrenada con imágenes de baja resolución (80×45 píxeles) reporta 80.88 %, pero reduce significativamente la huella computacional (tamaño $\approx$ 1.27 MB) y disminuye el tiempo de entrenamiento de 65.46 a 6.40 horas, siendo útil en escenarios con memoria limitada y cámaras de baja resolución [15]. Otros modelos, como ScrapNet basado en EfficientNet B3, muestran precisión de 92.87 % (y valores más altos en datasets específicos como

TABLA V DESEMPEÑO CUANTITATIVO EN LA CLASIFICACIÓN DE RESIDUOS				
Algoritmo	Tipo de clasificación	Métricas	Sostenibilidad	Ref.
CNN + Morph-HSV	Clasificación binaria (orgánico / inorgánico)	Precisión 99.58 %, Pérdida: 1.57 %	Reduce error visual, óptimo para compostaje.	[38]
Swin Transformer V2 + ACO	Clasificación de 6 categorías (TrashNet)	Precisión: 99.52 %, F1: 99.38 %	Clasificación con ruteo IoT, disminuye tiempos y emisiones.	[37]
O-AlexNetCNN-DBN	Clasificación automatizada de RSU	Precisión: 99.50 %, $R^2 = 0.942$, RMSE: 0.02, Latencia: 198 ms	Incrementa la velocidad y exactitud; disminuye el costo computacional.	[56]
AIEWO-WMC	Detección y clasificación de 6 categorías	Precisión: 99.50 %, F1: 98.37 %	Favorece reutilización y biodegradabilidad.	[57]
SVM-CNN híbrido+ Morph-HSV	Clasificación binaria (orgánico / inorgánico) 25,077 imágenes (Kaggle)	Precisión: 99.34 %, Pérdida: 1.67 %	Incrementa precisión de segregación y reducción de riesgos laborales.	[19]
FOMO MobileNetV2 0.35 TinyML	Clasificación de plásticos y metales	Precisión: 99.31 %, F1: 96.55 % Latencia: 200 ms	Edge AI de bajo costo; disminuye el 69 % gasto de eliminación.	[12]
SWSO+ NC-DBN	Clasificación de residuos contaminados y no contaminados	Precisión 99.10 %, F1: 99.5 %, Latencia: 3.1 ms	Detecta materiales degradados e incrementa la eficiencia industrial.	[39]
CNN (ResNet)	Clasificación 12 categorías	Precisión: 98.06 %, F1: 97.98 %	Incrementa la tasa de reciclaje y disminuye los errores en segregación automatizada.	[53]
EBMO + MobileNetV2 + HDL	Clasificación mixta en entorno IoT sostenible	Precisión: 98.04 %, F1: 93.6 %	Reducción energética del 18 %.	[41]
YOLO-11m /MobileNetV2	Clasificación de plásticos (WaDaBa 11 000 img)	Precisión: 98.00 %, mAP ₅₀ 0.992	Detecta partículas pequeñas y transparentes; alta eficiencia de reciclaje plástico.	[58]
DLSODC-GWM	Detección y clasificación de objetos de 6 categorías	Precisión: 98.61 %	Capacidad de identificar y clasificar pequeños objetos.	[59]
Red Neuronal Convocional Multipath (mp-CNN)	Detección de vertederos ilegales	Precisión: 97.82 % F1: 98.34 %	Monitoreo ambiental de alta precisión.	[60]
CNN + GAP (MIBA)	Identificación de metales, baterías y plásticos en cenizas	Precisión: 83.1–97.3 %, Top-1: 97 %	Recuperación de metales y recursos.	[54]

TrashNet), mientras que diversos estudios reportan métricas elevadas pero mixtas o por debajo del umbral, reflejando la influencia del dominio, el dataset y las clases consideradas [31], [32], [35], [43], [46], [61].

En optimización logística y energética, la evidencia muestra impactos particularmente cuantificables sobre sostenibilidad al combinar metaheurísticas, ML predictivo e IoT para ajustar rutas en función de la demanda real. Algoritmos como ACO, PSO, IMFO y enfoques basados en SVM reportan reducciones promedio del 25 % al 42 % en distancia recorrida, consumo de combustible y emisiones de CO₂ [20], [40], [45], [49], [62]. Estas mejoras se sostienen en la disponibilidad de información en tiempo real obtenida mediante sensores (p. ej., ultrasónicos), GPS y redes como LoRaWAN, lo que permite ajustar dinámicamente las rutas según niveles de llenado, reducir desbordamientos y optimizar tiempos de operación. La integración AIoT refuerza esta capacidad adaptativa en entornos urbanos complejos y contribuye a mejorar la distribución de flota y el mantenimiento predictivo de sistemas de transporte [24], [37], [40]. La Tabla VI resume el desempeño de los métodos logísticos evaluados, destacando sus efectos en reducción de costos, distancias, tiempos operativos y emisiones de gases de efecto invernadero (GEI).

F. Contextos de Implementación Urbana

El grado de digitalización, la infraestructura tecnológica y la madurez institucional condicionan de forma directa los contextos urbanos donde se implementan modelos de IA para la gestión de residuos sólidos. La evidencia muestra que los modelos de predicción y clasificación tienden a alcanzar un rendimiento más alto en ciudades con amplia disponibilidad de datos y ecosistemas consolidados de “smart city”. En Singapur, el modelo GSO-XGBoost logró errores MAPE entre 4.93 % y 6.79 % para la predicción de residuos por categoría de material, lo que permitió una planificación más precisa y una redistribución eficiente de recursos de recolección [17]. En Nueva York, el uso de GBRT y redes neuronales profundas alcanzó $R^2 = 0.87$, con capacidad para predecir tasas de generación en más de 750,000 propiedades residenciales,

aportando evidencia de beneficios logísticos y potencial reducción de emisiones asociadas al transporte [52].

En contraste, los entornos de economías en desarrollo presentan un énfasis en soluciones más ligeras y adaptadas a restricciones de infraestructura, conectividad y costos. En Etiopía, la predicción de generación anual mediante LSTM reportó $R^2 = 0.93$, respaldando una planificación municipal más proactiva [27]. En Omán, un enfoque híbrido IoT–Machine Learning logró una reducción del 28 % en consumo de combustible y un rendimiento operacional del 92 %, destacando la viabilidad de arquitecturas de bajo gasto energético para contextos urbanos emergentes [49]. Estos casos sugieren que la efectividad de la IA no depende exclusivamente de modelos complejos, sino de la adecuación entre algoritmo, disponibilidad de datos y capacidades operativas locales.

En ciudades densamente pobladas, la aplicación de IA se orienta con frecuencia a disminuir impactos ambientales y optimizar la logística de recolección a gran escala. En Huzhou (China), I-ACO redujo costos operativos en 31.2 % y emisiones de CO₂ en 25.3 % [45], mientras que en Paraná (Brasil) la aplicación de PSO permitió disminuir alrededor de 41 % tanto la distancia recorrida como las emisiones, confirmando el valor de las metaheurísticas para mejorar eficiencia en sistemas urbanos complejos [44]. De manera complementaria, las soluciones basadas en visión por computadora también muestran aplicabilidad para el control territorial: el modelo mp-CNN para detección de vertederos ilegales alcanzó 97.82 % de precisión y F1 = 98.34 %, fortaleciendo la vigilancia urbana y la automatización del cumplimiento ambiental [60].

En conjunto, los resultados revisados demuestran que la IA urbana es adaptable a distintos niveles de infraestructura, desde ciudades altamente digitalizadas hasta contextos con recursos limitados. Las experiencias analizadas reportan reducciones verificables del 25 % al 42 % en consumo energético y emisiones de CO₂, junto con mejoras en eficiencia operativa y resiliencia urbana, lo que refuerza el papel de la IA como instrumento clave para contribuir al logro de los ODS 11 y 12 [9], [10], [21].

TABLA VI
DESEMPEÑO Y BENEFICIOS DE SOSTENIBILIDAD DE LOS ALGORITMOS DE IA EN LA OPTIMIZACIÓN DE RUTAS

Algoritmo	Métrica	Reducción de costos	Reducción de emisiones de CO ₂	Reducción de recorrido	Otros beneficios	Referencia
I-ACO	-	31.2 % costos operativos	25.3 %	25 %	-	[45]
PSO	-	-	41.37 %	41 %	30 % (2.35 s) tiempo	[44]
k-means + CVRP VROOM	-	-	35 %	35 %	-	[20]
SVM + IoT	$R^2 = 0.81$	42 % combustible	-	27.2 km/d	35 % frecuencia de recolección	[62]
IoT-ML	Eficiencia: 92 %	28 % combustible 40 % laboral	-	-	-	[49]
IDLCVR-MSW IMFO	-	18.3 % costos operativos	12 – 18 %	15 – 20 %	-	[40]
STO-TSP	PDR: 0.99	-	-	-	Delay 0.11 s 38.4 Mbps	[24]

IV. DISCUSIONES

Los hallazgos de esta RSL confirman que la integración de Inteligencia Artificial —en particular Deep Learning y métodos de Boosting— ofrece una respuesta técnicamente robusta frente a las deficiencias estructurales y las ineficiencias logísticas asociadas a la gestión tradicional de RSU. El problema es global y creciente: se proyectan 3,400 millones de toneladas para 2050, mientras las tasas de reciclaje siguen siendo bajas ($\approx 13.5\%$) [10]–[15]. Paralelamente, el 33–40 % de los residuos no se gestionan adecuadamente debido a modelos operativos dependientes del trabajo manual y esquemas rígidos de recolección que generan viajes innecesarios y emisiones de $0.21 \text{ kg CO}_2/\text{km}$, lo que justifica la urgencia de migrar hacia sistemas predictivos y adaptativos [16]–[20], [22], [23].

En este marco, la evidencia comparativa (Tabla III) indica que los enfoques avanzados superan a los tradicionales no solo por su mayor precisión, sino porque resuelven limitaciones estructurales como la baja escalabilidad y la sensibilidad a la incertidumbre. En contraste, algoritmos de IA como XGBoost y LSTM modelan eficazmente la complejidad de los residuos, alcanzando una capacidad casi perfecta ($R^2 \approx 1.00$) para modelar la variabilidad compleja de los residuos [9], [28], [48]. Esta diferencia conceptual es clave, debido a que la IA avanzada no es solo un reemplazo del cálculo, sino un sistema de adaptación dinámica que permite pasar de un monitoreo administrativo estático a una ejecución operativa proactiva, lo que se traduce en mejoras en segregación, menor contaminación de flujos reciclables y mayor estabilidad del material recuperado [11], [19], [37]. No obstante, estos resultados deben interpretarse con cautela, ya que su alto desempeño proviene de entornos controlados (fondos neutros e iluminación ideal), lo que favorece el sobreajuste y limita su generalización en entornos reales.

Los indicadores de ajuste refuerzan la explicación del alto desempeño predictivo en la Tabla IV y la Fig. 3, Random Forest Regression y XGBoost reportan R^2 cercanos a 1.00, asociado en varios estudios a reducciones de $\text{RMSE} > 40\%$ frente a regresiones lineales [18], [28], [50]. El uso de arquitecturas como Swin Transformer V2 garantiza la viabilidad técnica en dispositivos de Edge AI al optimizar la latencia, mientras que modelos ligeros como YOLOv8 y FOMO MobileNet V2 combinan alta precisión con tiempos de inferencia bajos ($\approx 3.1 \text{ ms}$) [10], [12], [23], [30], [32], [39]. No obstante, hay que destacar que rendimientos inferiores al umbral del 97 % (como RWC-Net con 95.01 %) y arquitecturas densas como VGG16 pueden acarrear costos computacionales elevados, lo que restringe su escalabilidad en entornos con recursos limitados [11], [36], [55]. El impacto más directo y cuantificable en sostenibilidad se observa en la optimización logística, al integrar predicción (IoT + ML) con metaheurísticas. Algoritmos como PSO e I-ACO reportan reducciones promedio del 25 % al 42 % en distancia recorrida, combustible y emisiones de CO_2 [20], [44], [45], [49], [62].

La eficacia de la IA avanzada para la gestión de RSU reside en la sincronización de las tres dimensiones: La predicción estratégica (XGBoost/DNN), la clasificación operativa de precisión (Swin Transformer V2) y la ejecución logística (I-ACO/PSO) [17], [18], [25]. Esta interconectividad bajo el paradigma AIoT permite transformar la exactitud técnica en impactos de sostenibilidad verificables. Sin este enfoque sistémico, los avances aislados resultan insuficientes para mitigar la ineficiencia estructural del 35 % que caracteriza a los métodos tradicionales [16]–[20]. Esta flexibilidad operativa consolida a la IA como un instrumento esencial para el cumplimiento de los ODS 11 y 12, mostrando alta adaptabilidad tanto en ciudades inteligentes con escalas masivas, como en contextos emergentes mediante soluciones ligeras y de bajo gasto energético [9], [17], [24], [27], [49].

Pese a los avances, persisten limitaciones críticas como; dificultades para discriminar residuos visualmente similares incluso en modelos avanzados (YOLOv11, EfficientNet), debido a texturas multi-estructuradas similares entre categorías y reflejos que dificultan la extracción de características únicas por parte de las CNN [10], [23], [47]; el desequilibrio en datasets como RealWaste o WaDaBa (p. ej., predomina plásticos vs minorías) infla artificialmente la exactitud global, pero reduce la precisión y la puntuación F1 en las clases menos representadas [7], [36], [58]; restricciones por datasets pequeños (p. ej., 1,800 imágenes en SSD MobileNet V2) provoca sobreajustes ante ausencia de una muestra masiva y diversa, el modelo tiende a memorizar el ruido estadístico y detalles específicos del entrenamiento en lugar de aprender patrones generalizables que permitan su escalabilidad en entornos reales [23], [33]; y costos computacionales elevados en modelos grandes [15], [55]. Para mitigar estas deficiencias y fortalecer futuras investigaciones, es crucial priorizar el desarrollo de datasets abiertos, masivos y normalizados que representen la diversidad de RSU en diversos contextos urbanos, permitiendo una base común para validar hallazgos y reducir el sesgo algorítmico. Por otra parte, se encuentra la heterogeneidad métrica, donde el uso dispar de indicadores obstaculiza la comparación universal y la extrapolación de resultados desde contextos ricos en datos hacia entornos con infraestructura limitada [12], [19], [28]. Para mitigar esta deficiencia, se propone “Set mínimo” un conjunto mínimo de métricas estandarizadas para futuras investigaciones: En predicción, el reporte obligatorio de R^2 junto al RMSE o MAPE; en clasificación, la puntuación F1 y la latencia de inferencia; y en logística, la normalización del ahorro de combustible y reducción de CO_2 . Esta estandarización es fundamental para garantizar una escalabilidad rigurosa. Finalmente, se recomienda orientar la investigación hacia modelos multimodales más allá de la visión RGB y optimizar soluciones de Edge AI (TinyML), ofreciendo un mejor balance entre precisión y latencia para una transferencia tecnológica efectiva a cualquier realidad municipal [19], [22], [34], [54].

V. CONCLUSIONES

En la gestión de residuos sólidos urbanos, los algoritmos de IA más efectivos son los modelos basados en Deep Learning, Boosting y metaheurísticas evolutivas integradas con sistemas IoT. En el dominio de predicción, los algoritmos como Random Forest y XGBoost disminuyen en más del 40 % el error predictivo de generación de residuos y el llenado de contenedores. En clasificación, las arquitecturas de visión por computadora como Swin Transformer V2, MobileNetV2 y modelos híbridos como CNN + Morph-HSV logran precisiones superiores al 99 %, permitiendo sistemas robustos de segregación y clasificación automática en tiempo real. En el ámbito logístico, los algoritmos de I-ACO y PSO, lograron reducciones de GEI de 25.3 % y 41.37 %, respectivamente, además de una reducción de costos operativos del 31.2 % con I-ACO. Asimismo, la IA tiene una alta adaptabilidad a diferentes niveles de infraestructura urbana, desde contextos con alta digitalización, como Estados Unidos y Singapur, hasta en contextos emergentes como Etiopía u Omán. No obstante, es necesario tener en cuenta la heterogeneidad metodológica y la variabilidad métrica entre estudios, que limitan el análisis comparativo y generalización de resultados. Asimismo, se identificaron desafíos en la similitud visual de algunos residuos y altos costos computacionales de arquitecturas profundas. Por lo tanto, es importante que los futuros trabajos den prioridad a la exploración de arquitecturas multimodales que integren análisis de textura o espectro de color para resolver la ambigüedad visual, y a la optimización de modelos ligeros para Edge AI, garantizando una mayor escalabilidad de los modelos en contextos urbanos reales.

REFERENCIAS

- [1] A. Lakhout, "Revolutionizing urban solid waste management with AI and IoT: A review of smart solutions for waste collection, sorting, and recycling," *Results Eng.*, vol. 25, p. 104018, 2025, doi: 10.1016/j.rineng.2025.104018.
- [2] S. Singh, R. Chhabra, and J. Arora, "A Systematic Review of Waste Management Solutions Using Machine Learning, Internet of Things and Blockchain Technologies: State-of-Art, Methodologies, and Challenges," *Arch. Comput. Methods Eng.*, vol. 31, no. 3, pp. 1255–1276, 2024, doi: 10.1007/s11831-023-10008-z.
- [3] A. Hamdan, S. Panda, M. S. Jain, V. Raj, and S. Mathew, "Assessing municipal solid waste in Indian smart cities: A path towards Waste-to-Energy," *Heliyon*, vol. 11, no. 6, p. e42770, 2025, doi: 10.1016/j.heliyon.2025.e42770.
- [4] S. V. T. Dao, T. M. Le, H. M. Tran, H. V. Pham, M. T. Vu, and T. Chu, "Integrating artificial intelligence for sustainable waste management: Insights from machine learning and deep learning," *Watershed Ecol. Environ.*, vol. 7, pp. 353–382, 2025, doi: 10.1016/j.wsee.2025.07.001.
- [5] M. A. Hannan *et al.*, "Solid waste collection optimization objectives, constraints, modeling approaches, and their challenges toward achieving sustainable development goals," *J. Clean. Prod.*, vol. 277, p. 123557, 2020, doi: 10.1016/j.jclepro.2020.123557.
- [6] B. Fang *et al.*, "Artificial intelligence for waste management in smart cities: a review," *Environ. Chem. Lett.*, vol. 21, no. 4, pp. 1959–1989, 2023, doi: 10.1007/s10311-023-01604-3.
- [7] E. Aboudoumat, A. Elburki, K. Ballam, and A. Radwan, "Development of an AI-Powered Waste Sorting System for Benghazi Using YOLOv8," *Univ. Zawia J. Eng. Sci. Technol.*, vol. 2, no. 2, pp. 208–217, 2024, doi: 10.26629/uzjest.2024.19.
- [8] M. A. Yenikaya, "Artificial Intelligence in Recycling: Waste Management with Convolutional Neural Networks," *Fiscaeconomia*, vol. 9, no. 2, pp. 1225–1236, 2025, doi: 10.25295/fsecon.1607759.
- [9] S. R. Krishna, B. Kranthikumar, S. Vodithala, M. S. Waseem, and K. Muppavaram, "A Machine Learning Framework For Predictive Waste Management Optimization In Smart Cities," *Int. J. Environ. Sci.*, vol. 11, no. 12s, pp. 328–334, 2025, doi: 10.64252/zp92vp11.
- [10] D. Nasien, M. H. Adiya, M. Farkhan, U. S. Rahmadhani, and A. A. Samah, "Automated Waste Classification Using YOLOv11 A Deep Learning Approach for Sustainable Recycling," *J. Appl. Bus. Technol.*, vol. 6, no. 1, pp. 68–74, 2025, doi: 10.35145/jabt.v6i1.205.
- [11] D. Ziouzos, D. Tsiktsiris, N. Baras, and M. Dasygenis, "A Distributed Architecture for Smart Recycling Using Machine Learning," *Futur. Internet*, vol. 12, no. 9, p. 141, 2020, doi: 10.3390/fi12090141.
- [12] A. Daas, B. Sari, F. Semchedine, and M. Amad, "Optimizing waste management with integrated AIoT, edge computing, and LoRaWAN communication technologies," *Internet of Things*, vol. 31, p. 101546, 2025, doi: 10.1016/j.iot.2025.101546.
- [13] H. M. Tran, T. M. Le, H. V. Pham, M. T. Vu, and S. Vu Truong Dao, "An Integrated Learning Approach for Municipal Solid Waste Classification," *IEEE Access*, vol. 12, pp. 176569–176585, 2024, doi: 10.1109/ACCESS.2024.3495982.
- [14] S. Pandey *et al.*, "Do-It-Yourself Recommender System: Reusing and Recycling With Blockchain and Deep Learning," *IEEE Access*, vol. 10, pp. 90056–90067, 2022, doi: 10.1109/ACCESS.2022.3199661.
- [15] N. Nnamoko, J. Barrowclough, and J. Procter, "Solid Waste Image Classification Using Deep Convolutional Neural Network," *Infrastructures*, vol. 7, no. 4, p. 47, 2022, doi: 10.3390/infrastructures7040047.
- [16] G. Suddul, A. Babajee, N. Rambarun, and S. Armoogum, "Enhancing biodegradable waste management in Mauritius through real-time computer vision-based sorting," *Int. J. Informatics Commun. Technol.*, vol. 14, no. 3, p. 1119, 2025, doi: 10.11591/ijict.v14i3.pp1119-1125.
- [17] V. Jayaraman, A. Raj Lakshminarayanan, S. Parthasarathy, and A. Suganthi, "Forecasting the Municipal Solid Waste Using GSO-XGBoost Model," *Intell. Autom. Soft Comput.*, vol. 37, no. 1, pp. 301–320, 2023, doi: 10.32604/iasc.2023.037823.
- [18] X. Liu, W. Zhi, and A. Akhundzada, "Enhancing performance prediction of municipal solid waste generation: a strategic management," *Front. Environ. Sci.*, vol. 13, 2025, doi: 10.3389/fenvs.2025.1553121.
- [19] Sunardi, A. Yudhana, and M. Fahmi, "SVM-CNN Hybrid Classification for Waste Image Using Morphology and HSV Color Model Image Processing," *Trait. du Signal*, vol. 40, no. 4, pp. 1763–1769, 2023, doi: 10.18280/ts.400446.
- [20] A. Lesieur, M. Zargayouna, and V. Loubière, "Evaluation of Different Biowaste Collection Scenarios and Comparison of Periodic and Dynamic Collection," *Sustainability*, vol. 17, no. 9, p. 4206, 2025, doi: 10.3390/su17094206.
- [21] A. Dedania, D. Panchal, J. Patel, and J. Jani, "AI-Powered Garbage Classification System with IoT Implementation," *Int. J. Innov. Res. Eng. Multidiscip. Phys. Sci.*, vol. 13, no. 2, pp. 1–10, 2025, doi: 10.37082/IJIRMP.S.v13.i2.232392.
- [22] C. Wang, J. Qin, C. Qu, X. Ran, C. Liu, and B. Chen, "A smart municipal waste management system based on deep-learning and Internet of Things," *Waste Manag.*, vol. 135, pp. 20–29, 2021, doi: 10.1016/j.wasman.2021.08.028.
- [23] A. Atalarais, K. Saputra S, H. Syahputra, S. I. Al Idrus, and I. Taufik, "Automatic Waste Type Detection Using YOLO for Waste Management Efficiency," *J. Artif. Intell. Eng. Appl.*, vol. 4, no. 2, pp. 883–892, 2025, doi: 10.59934/jaiea.v4i2.770.
- [24] R. Roshan and O. P. Rishi, "Optimized routing with efficient energy transmission using Seline Trustworthy optimization for waste management in the smart cities," *Energy Harvest. Syst.*, vol. 9, no. 1, pp. 1–17, 2022, doi: 10.1515/ehs-2021-0028.
- [25] U. Smailbegovic, E. Kadric, and S. Glöser-Chahoud, "Assessing the determinants of municipal solid waste generation in Europe: A machine learning approach," *Waste Manag.*, vol. 205, p. 115033, 2025, doi: 10.1016/j.wasman.2025.115033.
- [26] S. Ahmed, S. Mubarak, J. T. Du, and S. Wibowo, "Forecasting the Status of Municipal Waste in Smart Bins Using Deep Learning," *Int. J. Environ. Res. Public Health*, vol. 19, no. 24, p. 16798, 2022, doi:

- 10.3390/ijerph192416798.
- [27] T. H. Gudeta, G. T. Mamo, and Y. M. Neguse, "Municipal Solid Waste Management Using Machine Learning: A Case Study in Sheger City, Koye Sub-city, Ethiopia," *Eur. J. Theor. Appl. Sci.*, vol. 3, no. 2, pp. 511–525, 2025, doi: 10.59324/ejtas.2025.3(2).42.
 - [28] L. Yang, Y. Zhao, X. Niu, Z. Song, Q. Gao, and J. Wu, "Municipal Solid Waste Forecasting in China Based on Machine Learning Models," *Front. Energy Res.*, vol. 9, 2021, doi: 10.3389/fenrg.2021.763977.
 - [29] L. Fan, M. Abbasi, K. Salehi, S. S. Band, K.-W. Chau, and A. Mosavi, "Introducing an evolutionary-decomposition model for prediction of municipal solid waste flow: application of intrinsic time-scale decomposition algorithm," *Eng. Appl. Comput. Fluid Mech.*, vol. 15, no. 1, pp. 1159–1175, 2021, doi: 10.1080/19942060.2021.1945496.
 - [30] S. Kumar, D. Yadav, H. Gupta, O. P. Verma, I. A. Ansari, and C. W. Ahn, "A Novel YOLOv3 Algorithm-Based Deep Learning Approach for Waste Segregation: Towards Smart Waste Management," *Electronics*, vol. 10, no. 1, p. 14, 2020, doi: 10.3390/electronics10010014.
 - [31] B. B. Kestane, E. Guney, and C. Bayilmis, "Real-time Recyclable Waste Detection Using YOLOv8 for Reverse Vending Machines," *J. Ilm. Tek. Elektro Komput. dan Inform.*, vol. 10, no. 2, pp. 345–358, 2024, doi: 10.26555/jiteki.v10i2.29208.
 - [32] S. Kako, R. Muroya, D. Matsuoka, and A. Isobe, "Quantification of litter in cities using a smartphone application and citizen science in conjunction with deep learning-based image processing," *Waste Manag.*, vol. 186, pp. 271–279, 2024, doi: 10.1016/j.wasman.2024.06.026.
 - [33] S. Sundaralingam and N. Ramanathan, "Recyclable plastic waste segregation with deep learning based hand-eye coordination," *Environ. Res. Commun.*, vol. 6, no. 4, p. 045007, 2024, doi: 10.1088/2515-7620/ad3db7.
 - [34] S. Jin, Z. Yang, G. Królczkyg, X. Liu, P. Gardoni, and Z. Li, "Garbage detection and classification using a new deep learning-based machine vision system as a tool for sustainable waste recycling," *Waste Manag.*, vol. 162, pp. 123–130, 2023, doi: 10.1016/j.wasman.2023.02.014.
 - [35] D. K. Gude *et al.*, "Transforming Urban Sanitation: Enhancing Sustainability through Machine Learning-Driven Waste Processing," *Sustainability*, vol. 16, no. 17, p. 7626, 2024, doi: 10.3390/su16177626.
 - [36] M. M. Hossen *et al.*, "A Reliable and Robust Deep Learning Model for Effective Recyclable Waste Classification," *IEEE Access*, vol. 12, pp. 13809–13821, 2024, doi: 10.1109/ACCESS.2024.3354774.
 - [37] M. Reji, C. Joseph, R. Baskar, and R. Thavasimuthu, "A Solid Waste Management System based on IoT using Swin Transformer with Ant Colony Optimization Model," *Glob. NEST J.*, vol. 27, no. 3, 2025, doi: 10.30955/gnj.06966.
 - [38] M. Fahmi, A. Yudhana, Sunardi, Abdel-Nasser Sharkawy, and Furizal, "Classification for Waste Image in Convolutional Neural Network Using Morph-HSV Color Model," *Sci. J. Eng. Res.*, vol. 1, no. 1, pp. 18–25, 2025, doi: 10.64539/sjer.v1i1.2025.12.
 - [39] A. R. Raipurkar, M. B. Chandak, and S. G. Rawat, "Simplified white shark with centroid DBN for urban waste management in smart cities," *Case Stud. Chem. Environ. Eng.*, vol. 10, p. 100957, 2024, doi: 10.1016/j.csee.2024.100957.
 - [40] N. B. M. Ishaque and S. M. Florence, "An Intelligent Deep Learning based Classification with Vehicle Routing Technique for municipal solid waste management," *J. Hazard. Mater. Adv.*, vol. 18, p. 100655, 2025, doi: 10.1016/j.hazadv.2025.100655.
 - [41] J. Vijayalakshmi, A. Mohanarathinam, V. Nandini, and G. Priya, "Internet of Things Enabled Smart Solid Waste Management System," *Glob. NEST J.*, vol. 25, no. 5, pp. 98–105, 2023, doi: 10.30955/gnj.004744.
 - [42] X. Chen, "Machine learning approach for a circular economy with waste recycling in smart cities," *Energy Reports*, vol. 8, pp. 3127–3140, 2022, doi: 10.1016/j.egyr.2022.01.193.
 - [43] Y. Zhou *et al.*, "Optimization of automated garbage recognition model based on ResNet-50 and weakly supervised CNN for sustainable urban development," *Alexandria Eng. J.*, vol. 108, pp. 415–427, 2024, doi: 10.1016/j.aej.2024.07.066.
 - [44] M. I. Castillo Ulloa *et al.*, "Sustainability and Algorithmic Comparison of Segmented PVRP for Healthcare Waste Collection: A Brazilian Case Study," *Sustainability*, vol. 17, no. 19, p. 8536, 2025, doi: 10.3390/su17198536.
 - [45] T. Li, S. Deng, C. Lu, Y. Wang, and H. Liao, "Optimization of Green Vehicle Paths Considering the Impact of Carbon Emissions: A Case Study of Municipal Solid Waste Collection and Transportation," *Sustainability*, vol. 15, no. 22, p. 16128, 2023, doi: 10.3390/su152216128.
 - [46] C. A. Palagan, S. Sebastin Antony Joe, S. J. J. Mary, and E. E. Jijo, "Predictive analysis-based sustainable waste management in smart cities using IoT edge computing and blockchain technology," *Comput. Ind.*, vol. 166, p. 104234, 2025, doi: 10.1016/j.compind.2024.104234.
 - [47] H. Younis and M. Obaid, "Performance Comparison of Pretrained Deep Learning Models for Landfill Waste Classification," *Int. J. Adv. Comput. Sci. Appl.*, vol. 15, no. 11, 2024, doi: 10.14569/IJACSA.2024.0151166.
 - [48] M. A. Olawumi, B. I. Oladapo, and R. A. Olawale, "Revolutionising waste management with the impact of Long Short-Term Memory networks on recycling rate predictions," *Waste Manag. Bull.*, vol. 2, no. 3, pp. 266–274, 2024, doi: 10.1016/j.wmb.2024.08.006.
 - [49] K. S. Al Yarubi, S. O. F. Khairy, S. M. E. Hossain, and G. Hayder, "Internet of Things-Driven Waste Management: Paving the Way for Sustainable Smart Cities," *Processes*, vol. 13, no. 4, p. 1140, 2025, doi: 10.3390/pr13041140.
 - [50] J. Dunkel, D. Dominguez, Ó. G. Borzdynski, and Á. Sánchez, "Solid Waste Analysis Using Open-Access Socio-Economic Data," *Sustainability*, vol. 14, no. 3, p. 1233, 2022, doi: 10.3390/su14031233.
 - [51] U. Soni, A. Roy, A. Verma, and V. Jain, "Forecasting municipal solid waste generation using artificial intelligence models—a case study in India," *SN Appl. Sci.*, vol. 1, no. 2, p. 162, 2019, doi: 10.1007/s42452-018-0157-x.
 - [52] C. E. Kontokosta, B. Hong, N. E. Johnson, and D. Starobin, "Using machine learning and small area estimation to predict building-level municipal solid waste generation in cities," *Comput. Environ. Urban Syst.*, vol. 70, pp. 151–162, 2018, doi: 10.1016/j.compenurbysys.2018.03.004.
 - [53] G. Ahmad *et al.*, "Intelligent waste sorting for urban sustainability using deep learning," *Sci. Rep.*, vol. 15, no. 1, p. 27078, 2025, doi: 10.1038/s41598-025-08461-w.
 - [54] C.-Y. Chen and T.-T. Yu, "Towards a circular economy: Recapturing battery, metal, and plastic from soil-size and gravel-size municipal solid waste incineration bottom ash using convolutional neural networks," *J. Clean. Prod.*, vol. 432, p. 139737, 2023, doi: 10.1016/j.jclepro.2023.139737.
 - [55] S. M. Cheema, A. Hannan, and I. M. Pires, "Smart Waste Management and Classification Systems Using Cutting Edge Approach," *Sustainability*, vol. 14, no. 16, p. 10226, 2022, doi: 10.3390/su141610226.
 - [56] H. Zhang, H. Cao, Y. Zhou, C. Gu, and D. Li, "Hybrid deep learning model for accurate classification of solid waste in the society," *Urban Clim.*, vol. 49, p. 101485, 2023, doi: 10.1016/j.uclim.2023.101485.
 - [57] J. Rajalakshmi, K. Sumangali, J. Jayanthi, and K. Muthulakshmi, "Artificial Intelligence with Earthworm Optimization Assisted Waste Management System for Smart Cities," *Glob. NEST J.*, vol. 25, no. 4, pp. 190–197, 2023, doi: 10.30955/gnj.004712.
 - [58] S. Kunwar, B. R. Owabumoye, and A. S. Alade, "Plastic Waste Detection Using Deep Learning: Insights from the WaDaBa Dataset," *Ind. Domest. Waste Manag.*, vol. 5, no. 1, pp. 1–11, 2025, doi: 10.53623/ldwm.v5i1.580.
 - [59] F. S. Alsubaei, F. N. Al-Wesabi, and A. M. Hilal, "Deep Learning-Based Small Object Detection and Classification Model for Garbage Waste Management in Smart Cities and IoT Environment," *Appl. Sci.*, vol. 12, no. 5, p. 2281, 2022, doi: 10.3390/app12052281.
 - [60] S. Shahab and M. Anjum, "Solid Waste Management Scenario in India and Illegal Dump Detection Using Deep Learning: An AI Approach towards the Sustainable Waste Management," *Sustainability*, vol. 14, no. 23, p. 15896, 2022, doi: 10.3390/su142315896.
 - [61] A. Masand, S. Chauhan, M. Jangid, R. Kumar, and S. Roy, "ScrapNet: An Efficient Approach to Trash Classification," *IEEE Access*, vol. 9, pp. 130947–130958, 2021, doi: 10.1109/ACCESS.2021.3111230.
 - [62] O. A. Ogbolumani and M. Adekoya, "Intelligent Waste Management Optimization Through Machine Learning Analytics," *J. Sci. Res. Rev.*, vol. 2, no. 1, pp. 7–26, 2025, doi: 10.70882/josrar.2025.v2i1.25.