



# **Universidad Católica de Santa María**

**Facultad de Arquitectura e Ingenierías Civil y del Ambiente**

**Escuela Profesional de Ingeniería Ambiental**

**Modelamiento predictivo mediante simulación computacional de la  
generación de residuos sólidos municipales y su impacto en la vida útil del  
Relleno Sanitario de Quebrada Honda, Arequipa 2026-2041**

Tesis presentada por:

**Gamero Nuñez, Valeria del Carmen**

**ORCID: 0009-0005-0845-4423**

para optar el Título Profesional de Ingeniero Ambiental

Asesor:

**Mg. Medina Ramos, Robert Joaquin**

**ORCID: 0000-0001-5504-0446**

Arequipa - Perú

2026

UCSM-ERP

**UNIVERSIDAD CATÓLICA DE SANTA MARÍA**

**INGENIERIA AMBIENTAL**

**TITULACIÓN CON TESIS**

**DICTAMEN APROBACIÓN DE BORRADOR**

Arequipa, 21 de Agosto del 2026

**Dictamen: 019011-C-EPIA-2026**

Visto el borrador del expediente 019011, presentado por:

**2020202232 - GAMERO NUÑEZ VALERIA DEL CARMEN**

Titulado:

**MODELAMIENTO PREDICTIVO MEDIANTE SIMULACIÓN COMPUTACIONAL DE LA  
GENERACIÓN DE RESIDUOS SÓLIDOS MUNICIPALES Y SU IMPACTO EN LA VIDA ÚTIL DEL  
RELLENO SANITARIO DE QUEBRADA HONDA, AREQUIPA 2026-2041**

Nuestro dictamen es:

**APROBADO**

Titulo Profesional/Titulo de Segunda Especialidad/Grado Académico a optar:

**INGENIERO AMBIENTAL**

**29727348 - LAZARTE ARREDONDO SONIA  
DICTAMINADOR**



**29611452 - ARENAZAS RODRIGUEZ ARMANDO JACINTO  
DICTAMINADOR**



**46769238 - CHANOVE MANRIQUE ANDREA MARIETA  
DICTAMINADOR**



# Modelamiento predictivo mediante simulación computacional de la generación de residuos sólidos municipales y su impacto en la vida útil del Relleno Sanitario de Quebrada Honda, Arequipa 2026-2041

## INFORME DE ORIGINALIDAD

|                     |                     |               |                         |
|---------------------|---------------------|---------------|-------------------------|
| 11 %                | 9 %                 | 6 %           | 4 %                     |
| INDICE DE SIMILITUD | FUENTES DE INTERNET | PUBLICACIONES | TRABAJOS DEL ESTUDIANTE |

## FUENTES PRIMARIAS

|    |                                                                                                                                                                                                                                                    |      |
|----|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------|
| 1  | repositorio.ucsm.edu.pe                                                                                                                                                                                                                            | 2 %  |
|    | Fuente de Internet                                                                                                                                                                                                                                 |      |
| 2  | Submitted to Universidad Católica de Santa María                                                                                                                                                                                                   | 1 %  |
|    | Trabajo del estudiante                                                                                                                                                                                                                             |      |
| 3  | www.coursehero.com                                                                                                                                                                                                                                 | <1 % |
|    | Fuente de Internet                                                                                                                                                                                                                                 |      |
| 4  | repositorio.upsc.edu.pe                                                                                                                                                                                                                            | <1 % |
|    | Fuente de Internet                                                                                                                                                                                                                                 |      |
| 5  | hdl.handle.net                                                                                                                                                                                                                                     | <1 % |
|    | Fuente de Internet                                                                                                                                                                                                                                 |      |
| 6  | repositorio.unu.edu.pe                                                                                                                                                                                                                             | <1 % |
|    | Fuente de Internet                                                                                                                                                                                                                                 |      |
| 7  | caritasuniversityjournals.org                                                                                                                                                                                                                      | <1 % |
|    | Fuente de Internet                                                                                                                                                                                                                                 |      |
| 8  | cdn.www.gob.pe                                                                                                                                                                                                                                     | <1 % |
|    | Fuente de Internet                                                                                                                                                                                                                                 |      |
| 9  | repositorio.continental.edu.pe                                                                                                                                                                                                                     | <1 % |
|    | Fuente de Internet                                                                                                                                                                                                                                 |      |
| 10 | ru.iiec.unam.mx                                                                                                                                                                                                                                    | <1 % |
|    | Fuente de Internet                                                                                                                                                                                                                                 |      |
| 11 | #N/A. "PIGARS de la Provincia de Arequipa 2017-IGA0006661", O.M. N° 1072, 2020                                                                                                                                                                     | <1 % |
|    | Publicación                                                                                                                                                                                                                                        |      |
| 12 | Paredes Rodríguez, Ebed David. "Modelo de gestión ambiental de residuos sólidos urbanos para disminuir la contaminación ambiental de la ciudad de Juliaca, provincia de San Román, región Puno", Universidad Nacional del Altiplano de Puno (Peru) | <1 % |
|    | Publicación                                                                                                                                                                                                                                        |      |
| 13 | repositorio.upeu.edu.pe                                                                                                                                                                                                                            | <1 % |
|    | Fuente de Internet                                                                                                                                                                                                                                 |      |

*Dedicatoria*

*Al angelito que guía y cuida mi camino desde el arcoíris  
cada día.*



### *Agradecimientos*


*Agradezco a mi asesor y docente Robert Medina quién me proporcionó un gran apoyo no solo en el desarrollo del presente trabajo, sino también a lo largo de la carrera.*

*A cada uno de los docentes que me instruyeron y formaron como persona y profesional a lo largo de los cinco años de la carrera.*

*A mis padres por sus enseñanzas, consejos y compañía en cada etapa de este camino.*

*A Dios y a la vida por permitirme llegar hasta este momento en mi vida.*

*A mis perritos que hicieron más fácil y llevadero lo difícil.*



## RESUMEN

La presente investigación tuvo como objetivo evaluar el impacto volumétrico de la generación futura de residuos sólidos municipales sobre la vida útil remanente del Relleno Sanitario de Quebrada Honda en la provincia de Arequipa para el periodo 2026-2041, mediante el desarrollo de un modelo de simulación computacional predictivo. La metodología adoptada fue de tipo aplicada, con un enfoque cuantitativo y un diseño no experimental de corte longitudinal ex post facto. Se recopilaron y depuraron registros históricos (2018-2025) del SIGERSOL y del INEI utilizando un algoritmo desarrollado en Python, aplicando técnicas de análisis multivariado y clasificación jerárquica distrital. Los análisis de correlación lineal revelaron que la masa total de residuos está fuertemente traccionada por el crecimiento de la población provincial ( $r = 0.991$ ), mientras que el índice de generación per cápita está supeditado al ingreso promedio mensual del hogar ( $r = 0.932$ ).

El algoritmo predictivo, calibrado por clústeres de simulación biofísica (materia orgánica y plásticos poliméricos), demostró una alta fidelidad algorítmica y generalización en la etapa de validación ex post facto, registrando un coeficiente de determinación  $R^2 = 0.998$ , un Error Absoluto Medio (MAE) de 374.2 t/año y una Raíz del Error Cuadrático Medio (RMSE) de 437.8 t/año. El análisis de residuales confirmó una distribución simétrica y gaussiana del error, libre de sesgos predictivos. Las simulaciones estocásticas determinaron que, bajo un esquema inercial pesimista, la celda de contingencia transitoria de emergencia (840,000.00 m<sup>3</sup>) colapsará por completo en el bienio 2028-2029 debido al confinamiento masivo de basura cruda. Por el contrario, la modelación del Escenario 3: Optimista (Ecoeficiente / Cumplimiento Normativo D.L. 1278) circular —alineado con las exigencias del Decreto Legislativo N° 1278— demostró que el desvío progresivo de la materia orgánica (42.5%) y de los plásticos poliméricos (37.5%) reduce la velocidad de llenado geométrico entre un 28.6% y un 43%. Se concluye que la valorización técnica de los flujos húmedos y secos reduce la velocidad de llenado, liberando un espacio geométrico acumulado de 1,997,517 m<sup>3</sup> al año 2041, lo cual retrasa el colapso de la celda de contingencia y otorga el tiempo necesario para la implementación de una nueva infraestructura provincial.

### Palabras claves:

Simulación computacional, Residuos sólidos municipales, Economía circular.

## ABSTRACT

This research aimed to evaluate the volumetric impact of future municipal solid waste generation on the remaining lifespan of the Quebrada Honda Landfill in the province of Arequipa for the 2026-2041 period, through the development of a predictive computational simulation model. The methodology was applied, featuring a quantitative approach and a non-experimental, longitudinal, ex post facto design. Historical records (2018-2025) from SIGERSOL and INEI were collected and cleaned using a Python-based algorithm, applying multivariate analysis techniques and district hierarchical clustering. Linear correlation analyses revealed that the total waste mass is heavily driven by provincial population growth ( $r = 0.991$ ), whereas the per capita generation rate is dependent on the monthly average household income ( $r = 0.932$ ).

The predictive algorithm, calibrated by biophysical simulation clusters (organic matter and polymeric plastics), demonstrated outstanding algorithmic fidelity and generalization during the ex post facto validation phase, registering a coefficient of determination  $R^2 = 0.998$ , a Mean Absolute Error (MAE) of 374.2 t/year, and a Root Mean Squared Error (RMSE) of 437.8 t/year. Residual analysis confirmed a symmetrical and Gaussian distribution of the error, free from predictive biases. Stochastic simulations determined that, under a pessimistic inertial scheme, the temporary emergency contingency cell (840,000.00 m<sup>3</sup>) will fully collapse within the 2028-2029 biennium due to the massive landfilling of raw waste. Conversely, the modeling of the optimistic circular scenario—aligned with the requirements of Legislative Decree No. 1278—demonstrated that the progressive diversion of organic matter (42.5%) and polymeric plastics (37.5%) contracts the geometric filling rate by 28.6% to 43%, yielding an accumulated landfill space savings of 1,997,517 m<sup>3</sup> by the year 2041. This volumetric benefit delays the physical collapse of the current temporary contingency cell by an additional year (until 2029) and translates into a technical lifespan extension of 4.8 years, providing the provincial administration with the necessary spatial margin and technical justification for the correct dimensioning of the new regional sanitary infrastructure project.

### Keywords:

Computer simulation, Municipal solid waste, Circular economy.

# ÍNDICE

**DEDICATORIA**

**AGRADECIMIENTOS**

**EPIGRAFE**

**RESUMEN**

**ABSTRACT**

**INTRODUCCIÓN..... 1**

**CAPITULO I..... 3**

**1. PLANTEAMIENTO DEL PROBLEMA ..... 3**

1.1. Problemática de la investigación ..... 3

1.2. Justificación de la investigación ..... 5

1.2.1. Justificación ambiental ..... 5

1.2.2. Justificación social ..... 5

1.2.3. Justificación económica ..... 6

1.3. Hipótesis ..... 6

1.4. Objetivo de la Investigación..... 7

1.4.1. Objetivo principal..... 7

1.4.2. Objetivos específicos..... 7

1.5. Variables e indicadores..... 8

**CAPÍTULO II..... 9**

**2. FUNDAMENTO TEORICO..... 9**

2.1. Antecedentes de la Investigación ..... 9

2.1.1. Antecedentes nacionales ..... 10

2.2. Marco teórico..... 12

2.2.1. Ingeniería y gestión integral de residuos sólidos municipales (GIRS) ..... 12

2.2.2. Modelamiento matemático y análisis estadístico multivariado..... 17

2.2.3. Simulación computacional y proyección estocástica ..... 20


2.2.4. Sostenibilidad, ecoeficiencia y valorización de residuos ..... 23

2.3. Marco legal ..... 27

2.3.1. Decreto Legislativo N° 1278 - Ley de Gestión Integral de Residuos Sólidos

|                                                                                                                             |           |
|-----------------------------------------------------------------------------------------------------------------------------|-----------|
| 2.3.2. Decreto Supremo N° 014-2017-MINAM - Reglamento del Decreto Legislativo N° 1278 .....                                 | 27        |
| 2.3.3. Decreto Legislativo N° 1501 - Modificatoria del Decreto Legislativo N° 1278<br>28                                    |           |
| 2.3.4. Ley N° 27972 - Ley Orgánica de Municipalidades.....                                                                  | 28        |
| 2.3.5. Ley N° 30884 - Ley que regula el plástico de un solo uso y los recipientes o<br>envases descartables.....            | 28        |
| 2.3.6. Plan Provincial de Gestión Integral de Residuos Sólidos (PIGARS) de<br>Arequipa.....                                 | 28        |
| 2.3.7. Ley N° 32212 .....                                                                                                   | 28        |
| <b>CAPÍTULO III .....</b>                                                                                                   | <b>29</b> |
| <b>3. METODOLOGÍA .....</b>                                                                                                 | <b>29</b> |
| 3.1. Tipo, nivel y diseño de investigación .....                                                                            | 29        |
| 3.1.1. Tipo de investigación .....                                                                                          | 29        |
| 3.1.2. Nivel de investigación.....                                                                                          | 29        |
| 3.1.3. Diseño de investigación .....                                                                                        | 30        |
| 3.2. Procedimientos metodológicos.....                                                                                      | 31        |
| 3.2.1. Diagnóstico y Correlación.....                                                                                       | 31        |
| 3.2.2. Modelamiento y Simulación .....                                                                                      | 36        |
| 3.2.3. Evaluación de Impacto y Propuesta .....                                                                              | 39        |
| 3.3. Esquema metodológico.....                                                                                              | 42        |
| <b>CAPÍTULO IV .....</b>                                                                                                    | <b>43</b> |
| <b>4. RESULTADOS Y DISCUSIÓN .....</b>                                                                                      | <b>43</b> |
| 4.1. Diagnóstico de la Generación de Residuos Sólidos Municipales y Correlación<br>Histórica (2018–2025) .....              | 43        |
| 4.1.1. Evolución Demográfica y de los Parámetros de Generación (2018–2025)43                                                |           |
| 4.1.2. Análisis de Correlación Multivariada Socioeconómica.....                                                             | 49        |
| 4.2. Formulación y Calibración del Algoritmo Computacional para el Modelamiento y<br>Simulación Predictiva (2026–2041)..... | 53        |
| 4.2.1. Formulación Matemática de las Ecuaciones de Proyección Ambiental y<br>Parametrización.....                           | 53        |
| 4.2.2. Proyecciones Anualizadas de Población por Distrito (2026–2041).....                                                  | 55        |
| 4.2.3. Protocolo de Validación Estadística del Modelo Computacional.....                                                    | 58        |

|                                                                                                                                        |           |
|----------------------------------------------------------------------------------------------------------------------------------------|-----------|
| 4.3. Evaluación del Impacto Volumétrico y Simulación de Escenarios de Desvío de Flujos en el Relleno Sanitario de Quebrada Honda ..... | 60        |
| 4.3.1. Cálculo del Consumo Volumétrico Geométrico de Celdas .....                                                                      | 60        |
| 4.3.2. Simulación Computacional de Escenarios de Gestión Operativa .....                                                               | 63        |
| 4.3.3. Cuantificación del Beneficio Ambiental y Extensión de la Vida Útil .....                                                        | 66        |
| <b>CAPÍTULO V .....</b>                                                                                                                | <b>73</b> |
| <b>5. CONCLUSIONES Y RECOMENDACIONES.....</b>                                                                                          | <b>73</b> |
| 5.1. Conclusiones.....                                                                                                                 | 73        |
| 5.2. Recomendaciones .....                                                                                                             | 74        |
| <b>REFERENCIAS .....</b>                                                                                                               | <b>77</b> |



## ÍNDICE DE TABLAS

|                                                                                                                                           |    |
|-------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Tabla 1</b> Matriz de operacionalización de variables e indicadores.....                                                               | 8  |
| <b>Tabla 2</b> Evolución poblacional de los distritos del área metropolitana.....                                                         | 44 |
| <b>Tabla 3</b> Evolución de la Generación Per Cápita (GPC) domiciliaria oficial.....                                                      | 45 |
| <b>Tabla 4</b> Masa total de residuos sólidos municipales recolectados (t/año, 2018–2025).....                                            | 46 |
| <b>Tabla 5</b> Niveles Socioeconómicos e Ingreso Promedio Mensual por Hogar.....                                                          | 49 |
| <b>Tabla 6</b> Coeficientes estocásticos de caracterización física de RSM.....                                                            | 54 |
| <b>Tabla 7</b> Proyección anualizada de población de los distritos metropolitanos.....                                                    | 56 |
| <b>Tabla 8</b> Parámetros y coeficientes ingenieriles para la simulación del relleno sanitario de Quebrada Honda.....                     | 62 |
| <b>Tabla 9</b> Simulación comparativa de consumo volumétrico de celdas en Quebrada Honda bajo tres escenarios operativos (2026–2041)..... | 66 |



## ÍNDICE DE FIGURAS

|                                                                                                                                                |    |
|------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Figura 1</b> Esquema metodológico.....                                                                                                      | 42 |
| <b>Figura 2</b> Tendencias de crecimiento en la masa de RSM recolectada por grupo distrital .....                                              | 48 |
| <b>Figura 3</b> Mapa de calor de la densidad espacial de generación de RSM en el área metropolitana de Arequipa (2025).....                    | 48 |
| <b>Figura 4</b> Matriz de Correlación de Pearson (r). .....                                                                                    | 50 |
| <b>Figura 5</b> Gráfico de Dispersión - Población Provincial vs. Masa Total Anual.....                                                         | 51 |
| <b>Figura 6</b> Gráfico de Dispersión - Ingreso Promedio Mensual por Hogar vs. GPC Domiciliaria. ....                                          | 51 |
| <b>Figura 7</b> Curvas de proyección demográfica por grupo de simulación biofísica (2026–2041) .....                                           | 58 |
| <b>Figura 8</b> Gráfico de dispersión de calibración estadística.....                                                                          | 59 |
| <b>Figura 9</b> Curvas de agotamiento del volumen útil disponible en la celda transitoria según escenario de simulación (2026–2029).....       | 69 |
| <b>Figura 10</b> Simulación de metros cúbicos (m <sup>3</sup> ) de espacio geométrico liberado en el relleno provincial hacia el año 2041..... | 69 |

## ÍNDICE DE ANEXOS

|                                                                                                         |    |
|---------------------------------------------------------------------------------------------------------|----|
| <b>Anexo 1.</b> Código Fuente del Modelo Predictivo en Python .....                                     | 93 |
| <b>Anexo 2.</b> Matrices Completas de Datos Históricos y Proyecciones Demográficas (2018–2041)<br>..... | 96 |
| <b>Anexo 3.</b> Avanzados de Validación Estadística y Gráficos de Residuales.....                       | 97 |



## INTRODUCCIÓN

A nivel global y regional, la gestión integral de residuos sólidos municipales (RSM) se ha consolidado como uno de los desafíos ambientales más complejos para las administraciones urbanas contemporáneas. Al respecto, Jalalipour et al. (2025) explican que las aceleradas dinámicas demográficas y la urbanización desordenada en América Latina han incrementado exponencialmente el caudal másico de descarte en las ciudades. Históricamente, la fracción orgánica ha mantenido una dominancia persistente en la composición física regional, oscilando entre el 56% y el 57% del peso total recolectado (Sánchez-Romero & Recalde-Gracey, 2024). No obstante, investigaciones de Ocaña Valencia y Vite Cevallos (2021) advierten que los patrones de consumo modernos reflejan una clara transición en el metabolismo urbano hacia materiales sintéticos y persistentes, como los plásticos y polímeros de baja degradabilidad.

Esta acumulación indiscriminada de componentes secos y húmedos tensiona de forma severa la capacidad instalada de las infraestructuras de disposición final tradicionales, propiciando la aparición de pasivos ambientales en las periferias urbanas (De La Cruz Cabrera et al., 2021). De acuerdo con Rosas-Prado et al. (2021), los vertederos municipales que operan bajo esquemas de baja eficiencia técnica aceleran la degradación de suelos y la contaminación de acuíferos mediante lixiviados, además de incrementar el inventario regional de emisiones de gases de efecto invernadero. Asimismo, eventos de alcance sanitario global agudizaron el descarte masivo de equipos de protección personal, cuyos fragmentos plásticos se transforman en microplásticos persistentes que alteran drásticamente las dinámicas ecológicas de los ecosistemas (Ortiz-Alvarez et al., 2026).

En el contexto peruano, el procesamiento analítico de datos masivos a través del SIGERSOL permitió a Padilla-Vento y Soria (2025) establecer que el número de habitantes explica el 99.09% de la varianza interdepartamental en la masa total de generación. Sin embargo, a escala intraurbana, Yactayo-Flores et al. (2025) demostraron que el índice de Generación Per Cápita (GPC) manifiesta una elasticidad condicionada por variables microeconómicas específicas, identificando una correlación positiva directa entre la capacidad adquisitiva de los hogares y la tasa de descarte de materiales aprovechables.

A pesar de la certeza matemática respecto a la influencia conjunta de los vectores de población e ingresos, Da Silva Júnior et al. (2024) sostienen que la planificación sanitaria local adolece de un marcado vacío metodológico debido a la escasez de modelos predictivos capaces de absorber la volatilidad intrínseca de los flujos residuales. Esta dispersión territorial genera perfiles de descarte diferenciados que desmitifican la efectividad de las proyecciones basadas en promedios globales estáticos (Poma et al., 2025).

La provincia de Arequipa refleja críticamente esta realidad, aportando una masa anual total de 355,362 toneladas de basura que satura sistemáticamente la celda transitoria de emergencia del Relleno Sanitario de Quebrada Honda. Ante la urgencia de respaldar las decisiones operativas con base científica, esta investigación desarrolla, calibra y valida un modelo de simulación computacional predictivo en Python para el periodo 2026-2041. Esta herramienta estocástica faculta la cuantificación geométrica del espacio útil liberado mediante escenarios normativos de desvío de flujos, proporcionando el sustento técnico indispensable para transicionar de forma segura hacia un modelo integral de economía circular y ecoeficiencia pública.

## **CAPITULO I**

### **1. PLANTEAMIENTO DEL PROBLEMA**

#### **1.1. Problemática de la investigación**

A nivel de América Latina, la gestión de residuos sólidos urbanos (RSU) se ha consolidado como uno de los desafíos ambientales y logísticos más críticos para las administraciones municipales. En el entorno regional, autores como Sánchez-Romero y Recalde-Gracey (2024), así como Ocaña Valencia y Vite Cevallos (2021), coinciden en que la fracción orgánica continúa siendo la predominante, oscilando en rangos aproximados del 56% al 57% del peso total de recolección. Sin embargo, las dinámicas de consumo moderno han generado una transición acelerada en las características de los descartes; estudios desarrollados por Rosas-Prado et al. (2021) y Ortiz-Alvarez et al. (2026) reportan una reducción porcentual de componentes tradicionales como el papel o el vidrio, frente a un incremento sostenido de materiales sintéticos y persistentes como plásticos y cauchos, los cuales ya alcanzan entre el 42% y el 43% de la masa total generada.

Esta acumulación descontrolada agrava la persistencia contaminante en el entorno debido a los prolongados periodos de degradación de los polímeros. La ausencia de programas consolidados de educación ambiental y la debilidad en la aplicación de normativas locales efectivas provocan que un porcentaje significativo de estos componentes sea dispuesto de manera inadecuada, propiciando la proliferación de vectores sanitarios, el deterioro paisajístico y la afectación directa a la salud pública (Sánchez-Romero & Recalde-Gracey, 2024). Al respecto, De La Cruz Cabrera et al. (2021) y Rosas-Prado et al. (2021) señalan que los vertederos y basurales que operan bajo esquemas de baja eficiencia técnica desencadenan impactos severos, destacando la generación de lixiviados que amenazan acuíferos subterráneos y suelos colindantes, además de propiciar enfermedades respiratorias o cutáneas en asentamientos precarios. Asimismo, durante crisis sanitarias como la pandemia de COVID-19, este problema se agudizó mediante el descarte masivo de mascarillas y equipos de protección, cuyos fragmentos plásticos se transformaron en microplásticos que alteran la dinámica de los ecosistemas (Ortiz-Alvarez et al., 2026).

La provincia de Arequipa y su núcleo metropolitano no son ajenos a esta realidad descrita en la literatura. La disposición final de los RSU provinciales converge de forma casi exclusiva en el Relleno Sanitario de Quebrada Honda, recinto que enfrenta una severa presión operativa debido al envío directo y masivo de residuos sin segregación en origen. A nivel distrital, Ponce-Ponce y Salvatierra-Pilozo (2025), junto con Ramírez (2025), señalan que la externalización de los servicios de limpieza suele coexistir con una deficiente supervisión técnica y una escasa colaboración ciudadana, propiciando la formación de puntos críticos de acumulación informal en la vía pública.

En el plano nacional, las evaluaciones de Valdivia-Espinoza y Guardia-Muguruza (2023) sitúan a Arequipa como una de las zonas de mayor vulnerabilidad operativa, aportando una masa anual de 355,362 toneladas de basura (equivalente al 4.33% del inventario nacional). Esta concentración de descartes, desprovista de un sistema de confinamiento con cobertura técnica integral, ha originado 89 áreas degradadas que comprometen 103.36 hectáreas y elevan las emisiones de gases de efecto invernadero (Valdivia-Espinoza & Guardia-Muguruza, 2023).

Al priorizar el transporte directo hacia el relleno sanitario como única solución operativa, las comunas reducen drásticamente el potencial de reciclaje de los plásticos y anulan las oportunidades de aprovechamiento biológico de la materia orgánica. Frente a ello, evaluaciones desarrolladas por Culi (2025), así como por Medina-Mijangos y Seguí-Amortegui (2021), demuestran que la implementación de infraestructuras alternativas, tales como plantas de clasificación o sistemas de digestión anaerobia, resultan técnica y socialmente rentables frente a la simple disposición en celdas de confinamiento. Adicionalmente, el diseño de estas estrategias requiere de herramientas de valoración económica contingente para respaldar la viabilidad de las decisiones tarifarias y de inversión pública (Maqui et al., 2021).

Ante este panorama, se requiere el desarrollo de herramientas de simulación computacional en Python que permitan proyectar la generación y composición de residuos a largo plazo, justificando con bases científicas la transición provincial hacia la economía circular. Por ello, se formula la siguiente pregunta central:

¿En qué medida el desarrollo e implementación de un modelo de simulación computacional predictivo permite proyectar la generación y composición física de los residuos sólidos municipales en la provincia de Arequipa para el periodo 2026–2041, orientando los resultados cuantitativos hacia la optimización de las estrategias de valorización y la sostenibilidad de la gestión ambiental pública?

## **1.2. Justificación de la investigación**

### **1.2.1. Justificación ambiental**

Desde una perspectiva ambiental, la investigación se fundamenta en la necesidad imperativa de mitigar los impactos derivados del confinamiento lineal tradicional. Como advierten De La Cruz Cabrera et al. (2021) y Rosas-Prado et al. (2021), la disposición masiva sin tratamiento contamina acuíferos y suelos mediante la lixiviación, además de acelerar la proliferación de vectores y la persistencia de polímeros sintéticos en el entorno. A ello se suma el riesgo ecológico introducido por la fragmentación de plásticos en microplásticos (Ortiz-Alvarez et al., 2026).

Frente a esta problemática, la formulación de un modelo computacional predictivo permite cuantificar con exactitud el volumen de las fracciones críticas de residuos. De acuerdo con Culi (2025) y Monrroy et al. (2025), contar con proyecciones certeras viabiliza alternativas de ingeniería como el compostaje y la digestión anaerobia para el flujo húmedo, reduciendo drásticamente la masa confinada en Quebrada Honda y prolongando la vida útil del relleno sanitario provincial.

### **1.2.2. Justificación social**

En el plano social, el estudio responde a la protección de la salud pública y la mejora de la calidad de vida de las poblaciones asentadas en las proximidades de las infraestructuras de disposición final. La acumulación descontrolada y la descomposición ineficiente de los residuos generan focos infecciosos que elevan la prevalencia de enfermedades respiratorias y cutáneas (Rosas-Prado et al., 2021).

Al simular escenarios de segregación y valorización eficientes, esta investigación aporta datos cuantitativos sólidos para el diseño de políticas municipales orientadas a erradicar los puntos críticos en las vías urbanas (Ponce-Ponce & Salvatierra-Pilozo, 2025; Ramírez, 2025). Asimismo, Monrroy et al. (2025) destacan que estas herramientas actúan como instrumentos de transferencia tecnológica que fortalecen la cultura ambiental y promueven una participación ciudadana informada.

### **1.2.3. Justificación económica**

Económicamente, se sustenta en que la transición desde la disposición final hacia esquemas de recuperación material y energética optimiza los presupuestos de los gobiernos locales. Medina-Mijangos y Seguí-Amortegui (2021) comprobaron que las plantas de clasificación, el reciclaje de polímeros y la valorización biológica superan la rentabilidad de los rellenos convencionales al internalizar externalidades ambientales y reinsertar recursos secundarios al mercado.

El algoritmo desarrollado facilita la estimación del volumen futuro de materiales comercializables, propiciando la formalización del empleo en las cadenas de reciclaje (Ocaña Valencia & Vite Cevallos, 2021). Finalmente, las proyecciones de masa proveen un soporte cuantitativo para aplicar metodologías de valoración contingente, optimizando la estructura tarifaria de los arbitrios y garantizando la sostenibilidad financiera de las inversiones públicas (Maqui et al., 2021).

### **1.3. Hipótesis**

El desarrollo de un modelo de simulación computacional predictivo, basado en variables demográficas y socioeconómicas, permite proyectar de manera precisa el incremento de la masa total y la variación de la composición física de los residuos sólidos municipales en la provincia de Arequipa hacia el año 2041.

## **1.4.Objetivo de la Investigación**

### **1.4.1. Objetivo principal**

Evaluar el impacto volumétrico de la generación futura de residuos sólidos municipales sobre la vida útil remanente del Relleno Sanitario de Quebrada Honda mediante el desarrollo de un modelo de simulación computacional predictivo para el periodo 2026–2041.

### **1.4.2. Objetivos específicos**

- Diagnosticar la evolución histórica (2018–2025) de la generación de residuos sólidos municipales en la provincia de Arequipa, determinando su correlación estadística con los vectores demográficos y socioeconómicos locales
- Formular y calibrar el algoritmo computacional en Python para simular las tendencias de proyección de la masa total y el desglose de las fracciones físicas críticas (materia orgánica y plásticos poliméricos) para el periodo 2026–2041.
- Cuantificar matemáticamente la variación geométrica del consumo de celdas en el Relleno Sanitario de Quebrada Honda bajo escenarios estocásticos de desvío de flujos y valorización material.

## 1.5. Variables e indicadores

**Tabla 1**

*Matriz de operacionalización de variables e indicadores para el modelamiento de residuos*

| Tipo de variable      | Variable de estudio       | Definición operacional                                        | Indicadores numéricos                      | Unidad de medida  |
|-----------------------|---------------------------|---------------------------------------------------------------|--------------------------------------------|-------------------|
| <b>Independientes</b> | Población provincial      | Volumen de habitantes por distrito según registros oficiales. | Tasa de crecimiento poblacional anual      | Habitantes        |
|                       | Ingreso socioeconómico    | Capacidad adquisitiva indexada por el estrato distrital.      | Ingreso económico promedio por hogar       | Soles (S/.)       |
|                       | Dimensión temporal        | Eje cronológico continuo para la proyección del modelo.       | Periodo anual de la simulación             | Años              |
| <b>Dependientes</b>   | Masa total de residuos    | Cantidad absoluta de desechos municipales recolectados.       | Generación total anual de RSU              | Toneladas (t/año) |
|                       | Tasa de generación diaria | Producción promedio de desechos por habitante al día.         | Generación Per Cápita (GPC)                | kg/hab/día        |
|                       | Composición física        | Fracción porcentual de los componentes críticos del flujo.    | Porcentaje de materia orgánica y plásticos | Porcentaje (%)    |

**Nota.** Elaboración Propia.

## CAPÍTULO II

### 2. FUNDAMENTO TEORICO

#### 2.1. Antecedentes de la Investigación

En el ámbito de la ingeniería ambiental contemporánea, el pronóstico predictivo de los residuos sólidos urbanos (RSU) se ha consolidado como un componente fundamental para el diseño técnico de infraestructuras de disposición final, la optimización logística de rutas de recolección y la formulación de políticas públicas de ecoeficiencia. A nivel global, la literatura científica ha experimentado una transición paradigmática irreversible durante los últimos años, caracterizada por el desplazamiento gradual de las herramientas estadísticas clásicas y el despliegue de arquitecturas basadas en inteligencia artificial y aprendizaje automatizado (Dawar et al., 2025; Pillai et al., 2023). Al respecto, revisiones sistemáticas como la desarrollada por Xia et al. (2021) confirman que el uso de algoritmos avanzados abarca actualmente todo el ciclo de gestión de las mermas municipales, destacando la aplicación de Redes Neuronales Artificiales (ANN), Máquinas de Vectores de Soporte (SVM), Bosques Aleatorios (RF) y redes de Memoria de Largo Corto Plazo (LSTM) para modelar tanto la tasa de generación absoluta como las propiedades físicas de los flujos de descarte.

La adopción de estos entornos responde a la naturaleza no lineal y multivariable de los factores que condicionan la generación de residuos. Autores como Billal y Kumar (2025), Liu et al. (2025) y Mudannayake et al. (2022) demostraron matemáticamente que los algoritmos de aprendizaje superan la capacidad explicativa de la Regresión Lineal Múltiple (MLR). Al evaluar series temporales dinámicas, estos modelos capturan oscilaciones estocásticas con menores tasas de error absoluto medio (MAE) y porcentual (MAPE), superando esquemas rígidos como ARIMA (Baziar et al., 2025; Gudeta et al., 2025). De esta forma, mientras la modelación lineal se emplea habitualmente para líneas base, las redes neuronales profundas reportan coeficientes de ajuste que oscilan entre  $R^2 = 0.97$  y  $0.999$  (Shekoohiyan et al., 2023; Yang et al., 2021).

Respecto a los predictores del sistema, existe consenso internacional en que las variables demográficas y socioeconómicas concentran el mayor peso estadístico. Investigaciones de Frimpong et al. (2025) y Ochoa-Barragán et al. (2023) destacan que la población absoluta, el ingreso familiar y el área construida representan los insumos fundamentales para entrenar algoritmos estables. Aunque diversos autores incorporan registros climáticos estacionales para afinar la modelación de la humedad en la fracción orgánica (Gudeta et al., 2025; Jayaraman et al., 2023), los análisis de correlación demuestran que las dinámicas de urbanización y consumo ejercen una influencia estructural notablemente superior frente a la variabilidad meteorológica (Xia et al., 2021).

Pese al avance de arquitecturas complejas, la programación de modelos de regresión multivariada en Python —mediante librerías de código abierto como Scikit-Learn y Pandas— constituye una solución técnica de alto valor para entornos con restricciones presupuestarias o de equipamiento (Wilujeng, 2025). Asimismo, esquemas híbridos utilizan regresiones lineales para depurar bases de datos socioeconómicas y alimentar modelos posteriores de optimización (Ochoa-Barragán et al., 2023). No obstante, la literatura reconoce que la principal barrera operativa en países en desarrollo sigue siendo la dispersión y vacíos en los datos históricos desagregados (Namoune et al., 2022). Esta restricción fundamenta la pertinencia de desarrollar herramientas predictivas en Python que procesen bases de datos públicas oficiales para guiar con rigor matemático los planes de valorización y economía circular a escala provincial.

#### **2.1.1. Antecedentes nacionales**

En el contexto peruano, el análisis cuantitativo de los residuos sólidos municipales (RSM) ha adquirido solidez metodológica gracias al empleo centralizado del Sistema de Información para la Gestión de Residuos Sólidos (SIGERSOL), adscrito al MINAM. Un estudio representativo a escala nacional fue conducido por Padilla-Vento y Soria (2025), quienes evaluaron una muestra histórica de 14,852 registros oficiales entre 2014 y 2021 en los 24 departamentos, estableciendo parámetros clave sobre el comportamiento de la generación domiciliar y la Generación Per Cápita (GPC). Estas evaluaciones, articuladas con los diagnósticos de Valdivia-Espinoza y Guardia-Muguruza (2023), evidencian que el país produce diariamente alrededor de 22,505 toneladas de RSM, de las cuales apenas el 61.29% se confina en infraestructuras reguladas como rellenos sanitarios.

Al analizar los motores de generación, Padilla-Vento y Soria (2025) comprobaron mediante estadística multivariada que la dimensión demográfica ejerce una dominancia determinante, explicando por sí sola el 99.09% de la varianza en la masa total de residuos domésticos a nivel departamental. En contraste, la GPC manifiesta una relación más estrecha con indicadores microeconómicos.

Así lo demostraron Yactayo-Flores et al. (2025) al analizar la metrópoli limeña, hallando una correlación positiva directa entre el ingreso de los hogares y la generación de residuos inorgánicos aprovechables, lo que confirma que los estratos de mayor capacidad adquisitiva incrementan la tasa de descarte de componentes secos frente al flujo húmedo.

En lo concerniente a la región de Arequipa, Valdivia-Espinoza y Guardia-Muguruza (2023) identificaron un escenario crítico de vulnerabilidad operativa, dado que la región reporta una generación anual de 355,362 toneladas de basura (4.33% del total nacional) y concentra 89 áreas degradadas por residuos que abarcan 103.36 hectáreas sin confinamiento técnico. Metodológicamente, investigaciones locales aplican técnicas como el Análisis de Componentes Principales (PCA) y el Análisis de Clúster Jerárquico para categorizar municipios según sus perfiles de descarte (Padilla-Vento & Soria, 2025; Yactayo-Flores et al., 2025). Sin embargo, se constata un vacío respecto a modelos computacionales que simulen de forma dinámica las tendencias distritales de Arequipa hacia el largo plazo. Esta necesidad justifica el desarrollo de un algoritmo predictivo en Python que procese los datos históricos de SIGERSOL e INEI para anticipar la demanda volumétrica en Quebrada Honda y diseñar escenarios viables de economía circular.

## **2.2. Marco teórico**

### **2.2.1. Ingeniería y gestión integral de residuos sólidos municipales (GIRS)**

#### **2.2.1.1. Definición, clasificación y ciclo de vida de los residuos urbanos.**

En el marco de la ingeniería ambiental contemporánea, la Gestión Integral de Residuos Sólidos Municipales (GIRS) se define como un sistema complejo, interdependiente y multivariable que abarca el control normativo, operativo y técnico de las distintas etapas del ciclo de vida de los desechos urbanos. Este enfoque sistémico comprende de manera secuencial los procesos de generación, segregación en la fuente, almacenamiento, recolección, transferencia, transporte, tratamiento, valorización material o energética, y disposición final de los descartes producidos en núcleos urbanos (Culi, 2025; Poma et al., 2025; Rodríguez & Castro, 2023). La finalidad primordial de la GIRS consiste en articular estas operaciones unitarias bajo criterios técnicos rigurosos para minimizar los impactos ambientales negativos y los riesgos a la salud pública, maximizando al mismo tiempo la eficiencia económica y la aceptación social del sistema de limpieza pública (Suárez et al., 2025).

El análisis del ciclo de vida de los residuos permite identificar las fuentes de origen (domiciliario, comercial, institucional e industrial ligero) y clasificarlos según sus propiedades físicas y químicas en fracciones aprovechables o no aprovechables, facilitando la intervención de la ingeniería en los puntos críticos del flujo hídrico y seco de las mermas municipales.

Históricamente, las administraciones gubernamentales de la región han abordado la gestión de residuos bajo un enfoque lineal tradicional basado en la extracción, consumo y descarte rápido. Esta práctica rudimentaria reconoce la alta generación de residuos como una consecuencia inevitable, consolidando al vertedero o al relleno sanitario convencional como la opción tecnológica dominante para el confinamiento directo de la masa cruda de basura (Suárez et al., 2025; Rodríguez & Castro, 2023). No obstante, el confinamiento masivo de materiales sin tratamiento previo interrumpe su ciclo de vida útil y desencadena impactos ambientales severos, tales como la degradación sistemática de los suelos, la proliferación de vectores biológicos infecciosos y la generación de lixiviados altamente contaminantes que amenazan la integridad de los acuíferos subterráneos (De La Cruz Cabrera et al., 2021; Rosas-Prado et al., 2021). Frente a este escenario, el paradigma moderno de la ingeniería ambiental promueve la transición hacia esquemas de economía circular y sostenibilidad

operativa. Esta perspectiva redefine el ciclo de vida de los residuos urbanos mediante una jerarquía de manejo que prioriza de forma estricta la prevención, la minimización, la reutilización, el reciclaje mecánico y la valorización biológica o energética (Culi, 2025; Poma et al., 2025; Valdivia-Espinoza & Guardia-Muguruza, 2023). Bajo este enfoque circular, la disposición final en un relleno sanitario deja de ser el eje central del sistema y queda relegada exclusivamente al confinamiento seguro de los rechazos remanentes que carecen por completo de potencial de recuperación tecnológica, fundamentando las decisiones operativas en evaluaciones de costo-beneficio sostenible que internalizan tanto los costos privados como las externalidades ambientales y sociales del entorno (Suárez et al., 2025).

#### **2.2.1.2. Parámetros de caracterización física: masa total y Generación Per Cápita (GPC).**

La modelación matemática y la simulación computacional de los sistemas de gestión integral requieren la determinación precisa de los parámetros de caracterización física de los residuos, siendo la masa total anual y la Generación Per Cápita (GPC) los indicadores cuantitativos fundamentales para dimensionar cualquier infraestructura ambiental.

La modelación matemática y la simulación computacional de los sistemas de gestión integral requieren la determinación precisa de los parámetros de caracterización física de los residuos, siendo la masa total anual y la Generación Per Cápita (GPC) los indicadores fundamentales para dimensionar cualquier infraestructura sanitaria. Al respecto, Culi (2025) define la GPC como la masa promedio de descartes generada diariamente por un habitante, expresada en kilogramos por habitante al día (kg/hab·día).

En los entornos urbanos de América Latina, estudios compilados por Rodríguez y Castro (2023), así como por Ocaña Valencia y Vite Cevallos (2021), sitúan este índice típicamente entre 0.7 y 1.1 kg/hab·día. Dicho parámetro manifiesta una dinámica directamente proporcional al crecimiento económico, los procesos de urbanización acelerada y las transformaciones en los hábitos cotidianos de consumo.

Por su parte, la masa total de residuos sólidos municipales generada en una jurisdicción territorial es una variable dependiente que responde de forma directa a la interacción de la densidad poblacional acumulada y la tasa de la GPC local.

A nivel de la república del Perú, la masa total de generación diaria de residuos de origen municipal alcanza las 22,505 toneladas, reflejándose una severa brecha en las capacidades de tratamiento debido a que únicamente el 61.29 por ciento de dicho volumen global logra ser dispuesto formalmente en rellenos sanitarios regulados (Valdivia-Espinoza & Guardia-Muguruza, 2023). El análisis estadístico multivariado de la base de datos oficial del Estado peruano confirma que la dimensión demográfica es el predictor dominante de la masa total, demostrando que el número de habitantes explica por sí solo el 99.09 por ciento de la variación en la generación de residuos domésticos entre los departamentos del país, respaldado por un indicador de eta cuadrado que valida una correlación positiva lineal sumamente robusta (Padilla-Vento & Soria, 2025).

Asimismo, variables microeconómicas como el ingreso per cápita de los hogares ejercen una influencia directa en el comportamiento de la masa total, alterando la densidad y tipología de las mermas generadas (Yactayo-Flores et al., 2025). Para la provincia de Arequipa, este comportamiento demográfico adquiere una relevancia crítica, puesto que la región genera una masa anual total de 355,362 toneladas de residuos —equivalente al 4.33 por ciento del inventario nacional—, consolidándose como el volumen más alto del país concentrado en una zona con severas deficiencias estructurales en infraestructura de disposición final formal, lo cual se evidencia en la proliferación de 89 áreas degradadas por basura que abarcan una superficie geográfica de 103.36 hectáreas y deterioran de forma directa la calidad de vida y el perfil de emisiones de gases de efecto invernadero en la provincia (Valdivia-Espinoza & Guardia-Muguruza, 2023).

### **2.2.1.3. Fracciones críticas del flujo residual: materia orgánica y plásticos poliméricos.**

Dentro del flujo volumétrico global de los residuos sólidos municipales, la ingeniería ambiental identifica a la materia orgánica y a los plásticos poliméricos como las dos fracciones críticas y prioritarias para el modelamiento predictivo, debido a su dominancia en peso, su comportamiento diferenciado en el entorno y su alto potencial de inserción en cadenas de valorización. En las ciudades latinoamericanas, la fracción orgánica representa el componente mayoritario y predominante del inventario de descarte, oscilando de manera persistente en rangos aproximados del 56 al 57 por ciento de la masa total recolectada por los servicios municipales (Sánchez-Romero & Recalde-Gracey, 2024; Ocaña Valencia & Vite Cevallos, 2021). Esta fracción se caracteriza técnicamente por poseer elevados índices de humedad y una alta biodegradabilidad, condiciones que, si bien representan un riesgo severo de generación de vectores, lixiviados y malos olores en rellenos mal gestionados, le otorgan un extraordinario potencial para la valorización biológica mediante tecnologías de compostaje o digestión anaerobia en sistemas de biodigestores a escala piloto o industrial (Culi, 2025; Monrroy et al., 2025; Ocaña Valencia & Vite Cevallos, 2021). El procesamiento tecnificado de la materia orgánica permite la co-generación de subproductos de alto valor agronómico y energético, tales como enmiendas orgánicas estables (compost y digestato) y biogás rico en metano apto para la conversión en bioenergía, mitigando simultáneamente la emisión de gases de efecto invernadero derivados de la descomposición anaeróbica descontrolada en el suelo (González-Jiménez & Villalobos-Morales, 2021; Valdivia-Espinoza & Guardia-Muguruza, 2023).

En contraposición al flujo húmedo, las transiciones socioeconómicas modernas han desencadenado una alteración epidemiológica en los residuos secos, caracterizada por la reducción de materiales tradicionales como el vidrio o el papel, y un incremento exponencial de los plásticos y el caucho sintético, componentes que ya representan entre el 40 y el 43 por ciento de la masa total de RSU en diversos contextos regionales (Sánchez-Romero & Recalde-Gracey, 2024; Rosas-Prado et al., 2021; Ortiz-Alvarez et al., 2026).

Los plásticos poliméricos constituyen una fracción crítica de alta persistencia debido a la notable estabilidad química de sus cadenas moleculares, condición que prolonga su degradación por siglos y propicia escenarios de acumulación en el medio biofísico. De acuerdo con De La Cruz Cabrera et al. (2021) y Sánchez-Romero y Recalde-Gracey (2024), en zonas urbanas vulnerables hasta el 75% de los residuos recuperados informalmente o acumulados en riberas corresponden a polímeros plásticos. Esta problemática se agudizó drásticamente durante eventos de emergencia sanitaria como la pandemia de COVID-19, periodo en el cual el descarte masivo de equipos de protección aceleró la fragmentación macroplástica hacia microplásticos persistentes en el agua y el suelo (Ortiz-Alvarez et al., 2026).

Para contrarrestar este impacto, las estrategias de ingeniería se concentran en la valorización material a través del reciclaje mecánico de polímeros de alta densidad y el coprocesamiento térmico como combustible alternativo en industrias cementeras, disminuyendo de manera drástica el volumen absoluto de rechazo enviado al Relleno Sanitario de Quebrada Honda en Arequipa y abriendo oportunidades ecoeficientes para la generación de empleo verde e inclusión social en las cadenas locales de reciclaje (Culi, 2025; Rosas-Prado et al., 2021; Ocaña Valencia & Vite Cevallos, 2021).

En el contexto particular de la zona metropolitana de Arequipa, los fundamentos de la GIRS y la economía circular sustentan de forma directa la necesidad de evaluar el desvío analítico de la materia orgánica y los plásticos poliméricos. Comprender la alta humedad de los componentes orgánicos y la marcada persistencia de las cadenas poliméricas permite justificar técnicamente el diseño de escenarios de mitigación frente al confinamiento lineal masivo que actualmente satura de mermas crudas la infraestructura provincial.

## **2.2.2. Modelamiento matemático y análisis estadístico multivariado**

### **2.2.2.1. Principios de la Regresión Lineal Múltiple (MLR) aplicada a variables ambientales.**

En la ingeniería ambiental, el modelamiento predictivo de sistemas complejos se soporta inicialmente en el establecimiento de relaciones lineales funcionales entre variables de control y variables de respuesta. La Regresión Lineal Múltiple (MLR) constituye la herramienta estadística fundamental para determinar el efecto simultáneo de dos o más variables independientes o predictores sobre una variable dependiente, permitiendo modelar las tendencias de generación de residuos sólidos urbanos, la fluctuación de la generación per cápita y el enrutamiento de flujos de masa hacia las diferentes opciones de tratamiento y valorización (Maqui et al., 2021; Rodríguez & Castro, 2023; Suárez et al., 2025). La estructura básica del modelo MLR asume que la respuesta del sistema ambiental puede explicarse mediante una combinación lineal de parámetros demográficos o socioeconómicos, sujeta a una tasa de error aleatorio, expresándose matemáticamente de la siguiente manera:

$$Y = b_0 + b_1(X_1) + b_2(X_2) + \dots + b_n(X_n) + e$$

Donde Y representa el indicador dependiente (como la masa total anual de residuos), X<sub>1</sub>, X<sub>2</sub> hasta X<sub>n</sub> representan las variables independientes explicativas (tales como la población o el nivel de ingresos), b<sub>0</sub> es la constante de intercepto, b<sub>1</sub> hasta b<sub>n</sub> son los coeficientes de regresión parcial que cuantifican el impacto de cada predictor, y e representa el término de error que absorbe la variabilidad no explicada por el modelo lineal.

A pesar del surgimiento de arquitecturas de aprendizaje automatizado no lineales, la modelación lineal múltiple conserva una vigencia operativa fundamental debido a su simplicidad computacional y validez de bajo costo en entornos reales con limitaciones de datos de origen. Investigaciones en contextos municipales con presupuestos restringidos demuestran que el ajuste de regresiones lineales ejecutadas en código Python, a través de librerías de libre acceso como Scikit-Learn y Pandas, proporciona una solución técnica viable para estimar la masa de residuos basándose en indicadores logísticos indirectos como los volúmenes de transporte, alcanzando niveles de ajuste estadístico funcionales en zonas desprovistas de balanzas industriales (Wilujeng, 2025).

Asimismo, metodologías híbridas de vanguardia recurren a las ecuaciones de regresión lineal y polinómica como un filtro de procesamiento analítico primario; estas herramientas se ajustan sobre bases de datos socioeconómicas agregadas para depurar y alimentar de forma limpia a algoritmos posteriores de programación matemática y optimización de cadenas de suministro de residuos (Ochoa-Barragán et al., 2023). La MLR actúa, por lo tanto, como el marco de referencia lineal indispensable sobre el cual se evalúa la necesidad de introducir mayor complejidad estocástica o algorítmica en la simulación ambiental.

#### **2.2.2.2. Coeficientes de correlación y análisis multivariado de variables socioeconómicas y demográficas.**

El análisis estadístico multivariado se enfoca en explorar, clasificar e interpretar las complejas interacciones y el grado de co-dependencia que exhiben múltiples variables medidas simultáneamente dentro de un ecosistema urbano. En el campo de la GIRS, la literatura internacional establece de manera concluyente que la tasa de generación de residuos no ocurre de forma aislada, sino que se encuentra fuertemente determinada por un conjunto de vectores socioeconómicos y demográficos dominantes, entre los que destacan la población absoluta, la densidad poblacional, el Producto Interno Bruto (PIB) o ingresos financieros de los hogares, el área urbana construida y la intensidad de las actividades comerciales (Billal & Kumar, 2025; Frimpong et al., 2025; Mudannayake et al., 2022; Ochoa-Barragán et al., 2023; Xia et al., 2021; Yang et al., 2021). Para desentrañar estas relaciones, la estadística ambiental recurre al cálculo de coeficientes de correlación y análisis de varianza avanzados que miden la fuerza y dirección de la asociación lineal entre los predictores y la masa residual.

En el territorio peruano, evaluaciones cuantitativas sobre series históricas del SIGERSOL confirman la dominancia del vector demográfico en los modelos ambientales. Mediante análisis multivariados, Padilla-Vento y Soria (2025) demostraron que la población explica por sí sola el 99.09% de la varianza en la generación de residuos domésticos a nivel departamental, registrando una correlación positiva y lineal sumamente robusta.

Paralelamente, factores microeconómicos como el ingreso familiar condicionan la tipología del descarte. Al respecto, investigaciones de agrupamiento distrital conducidas por Yactayo-Flores et al. (2025) identificaron que una mayor capacidad adquisitiva eleva prioritariamente la generación de materiales inorgánicos secos y aprovechables, en contraste con el comportamiento estable del flujo orgánico húmedo. Para procesar estas extensas matrices sin incurrir en redundancia estadística, la ingeniería ambiental recurre a técnicas como el Análisis de Componentes Principales (PCA) y el Análisis de Clúster Jerárquico de Ward (Padilla-Vento & Soria, 2025; Yactayo-Flores et al., 2025).

Estas herramientas de análisis multivariado transforman datos gubernamentales dispersos en estructuras de información ordenadas, identificando los verdaderos motores socio-demográficos del residuo y configurando la base técnica indispensable para alimentar de forma precisa cualquier algoritmo de proyección temporal.

#### **2.2.2.3. Métricas de validación matemática y análisis de error estadístico ( $R^2$ , RMSE, MAE).**

La validez científica y la confiabilidad de un modelo de simulación ambiental dependen estrictamente de su fase de validación matemática, proceso que cuantifica la discrepancia existente entre los valores de generación de residuos proyectados por el algoritmo y los valores reales observados en las estaciones de monitoreo o bases de datos históricas oficiales. La evaluación del desempeño predictivo se realiza mediante el cálculo de un conjunto estandarizado de métricas de error estadístico, siendo las más utilizadas el Coeficiente de Determinación ( $R^2$ ), el Error Absoluto Medio (MAE), el Error Porcentual Absoluto Medio (MAPE) y el Error Cuadrático Medio (RMSE) (Baziar et al., 2025; Frimpong et al., 2025; Mudannayake et al., 2022). Cada una de estas métricas aporta un criterio analítico diferenciado para evaluar la estabilidad de la simulación.

El Coeficiente de Determinación ( $R^2$ ) mide la proporción de la varianza total de la variable dependiente (generación de residuos o GPC) que es explicada de forma satisfactoria por el conjunto de variables independientes introducidas en el modelo. En aplicaciones de regresión lineal simple aplicadas a la gestión operativa de transporte, se reportan valores de  $R^2$  cercanos a 0.56, los cuales se consideran aceptables como línea base de planificación para zonas con baja disponibilidad de infraestructura de medición (Wilujeng, 2025). Sin embargo, cuando las interacciones urbanas introducen comportamientos no lineales complejos, los ingenieros ambientales desarrollan y entrenan arquitecturas avanzadas de aprendizaje automatizado y redes neuronales (como ANN, SVM, Random Forest o LSTM) con el objetivo explícito de optimizar estas métricas de validación.

Al comparar los modelos predictivos contra los registros de calibración, se determina matemáticamente la superioridad de los enfoques no lineales, los cuales consiguen reducir drásticamente los errores absolutos (MAE y MAPE) y alcanzar coeficientes de ajuste sobresalientes de  $R^2$  situados entre 0.97 y 0.999, tanto para la predicción de volúmenes de masa total como para la estimación de propiedades específicas como el poder calorífico de los residuos en vertederos (Baziar et al., 2025; Billal & Kumar, 2025; Chau et al., 2025; Mudannayake et al., 2022; Shekoohiyan et al., 2023; Xia et al., 2021; Yang et al., 2021).

### **2.2.3. Simulación computacional y proyección estocástica**

#### **2.2.3.1. Fundamentos de la simulación de tendencias y series de tiempo temporales.**

En el ámbito de la planificación ambiental de largo plazo, la simulación computacional de tendencias se define como la réplica algorítmica de un sistema real a lo largo del tiempo para evaluar su comportamiento bajo diferentes condiciones operativas. Tal como explican Rodríguez y Castro (2023), este enfoque se apoya en el análisis de series temporales continuas, las cuales permiten identificar la tendencia secular, la estacionalidad y las fluctuaciones cíclicas del flujo residual. Al introducir el tiempo como variable continua, la ingeniería sanitaria faculta la proyección estocástica de mermas mediante estimaciones multi-paso (Mudannayake et al., 2022).

La evolución metodológica en este campo evidencia un desplazamiento desde las herramientas estadísticas rígidas hacia modelos de aprendizaje computacional. Aunque tradicionalmente las proyecciones se formulaban mediante modelos autorregresivos (ARIMA) o suavizado exponencial (ETS), la dinámica urbana actual introduce perturbaciones no lineales que limitan su precisión (Baziar et al., 2025). Por ello, autores como Gudeta et al. (2025) y Mudannayake et al. (2022) destacan la integración de redes neuronales recurrentes (LSTM) para absorber la volatilidad del descarte y minimizar los márgenes de error predictivo.

#### **2.2.3.2. Modelos de simulación estocástica y variabilidad de composición física.**

Un sistema de gestión de residuos sólidos es intrínsecamente inestable debido a que las tasas de generación y, específicamente, la composición física de las mermas no son constantes, sino que exhiben una naturaleza estocástica. La simulación estocástica es aquella que incorpora la incertidumbre y la variabilidad aleatoria del mundo real mediante la introducción de distribuciones de probabilidad dentro de las variables de entrada del modelo, permitiendo que un mismo conjunto de datos iniciales genere múltiples escenarios probables en lugar de un único resultado rígido o determinista (Chau et al., 2025; Frimpong et al., 2025).

En la provincia de Arequipa, esta variabilidad es evidente en las fracciones críticas del flujo: mientras que la materia orgánica fluctúa según temporadas agrícolas o dinámicas de comercio local, la fracción plástica polimérica experimenta picos condicionados por cambios macroeconómicos, patrones estacionales o eventos disruptivos globales, como ocurrió con el incremento masivo de mascarillas y equipos de protección durante la pandemia de COVID-19 (Sánchez-Romero & Recalde-Gracey, 2024; Ortiz-Alvarez et al., 2026; Shekoohiyan et al., 2023).

Para capturar matemáticamente esta volatilidad sin distorsionar la realidad del ecosistema urbano, la literatura especializada recurre a modelos basados en aprendizaje de ensamble (ensemble learning), vectores de soporte y bosques aleatorios. Investigaciones recientes de Alhathlaul et al. (2025) y Billal y Kumar (2025) señalan que estos algoritmos permiten parametrizar las tasas de descarte y los porcentajes de caracterización física como rangos dinámicos sujetos a desviaciones estándar. Mediante iteraciones probabilísticas continuas, el software proyecta escenarios de gestión estándar: tendencial, pesimista y optimista o de ecoeficiencia (Suárez et al., 2025).

Este esquema estocástico disminuye los errores absolutos medios y dota a la administración pública de una matriz de riesgo cuantitativa para dimensionar con seguridad la infraestructura sanitaria (Baziar et al., 2025; Chau et al., 2025; Frimpong et al., 2025).

#### **2.2.3.3. Estructuras lógicas de código abierto en Python para la ciencia de datos ambientales.**

El desarrollo operativo de un modelo de simulación computacional predictivo requiere de un entorno de programación robusto, flexible y capaz de procesar matrices masivas de datos espaciales y temporales.

En la actualidad, el lenguaje de programación de código abierto Python se ha consolidado como la plataforma líder para la ciencia de datos ambientales, debido a que elimina la dependencia de licencias de software propietario costosas y permite estructurar algoritmos personalizados bajo una lógica transparente y reproducible (Ochoa-Barragán et al., 2023; Wilujeng, 2025). El procesamiento analítico dentro de Python se soporta en un ecosistema de librerías especializadas que automatizan la carpintería de datos: *Pandas* para la estructuración y depuración de tablas e índices históricos, *NumPy* para el cálculo de matrices vectoriales complejas, y *Scikit-Learn* para el entrenamiento, calibración y validación de los modelos de regresión lineal y no lineal (Wilujeng, 2025).

La estructura lógica de una simulación ambiental en Python funciona mediante la creación de funciones secuenciales integradas. En la primera etapa, el script automatiza la lectura de las bases de datos gubernamentales masivas (como las miles de filas de registros de población del INEI y las toneladas reportadas en el SIGERSOL), procediendo a limpiar los valores nulos o atípicos mediante filtros estadísticos (Padilla-Vento & Soria, 2025; Wilujeng, 2025). En la segunda etapa, el código ejecuta el análisis multivariado, calculando las matrices de correlación cruzada para aislar los verdaderos motores del residuo (Yactayo-Flores et al., 2025). Finalmente, en la etapa de proyección, el algoritmo utiliza bucles iterativos (*loops*) para estirar las curvas de crecimiento demográfico y socioeconómico hacia el horizonte de planeación fijado, multiplicando dichos vectores por las matrices estocásticas de composición física para imprimir en pantalla gráficos dinámicos y reportes de masa listos para la toma de decisiones técnicas (Ochoa-Barragán et al., 2023; Wilujeng, 2025). Esta versatilidad lógica convierte a Python en una herramienta de ingeniería de vanguardia para el desarrollo de gemelos digitales operacionales a costo cero.

De este modo, el entorno de código abierto en Python faculta la automatización de las proyecciones estocásticas para el flujo residual de la provincia hacia el horizonte de planeación 2026–2041. El despliegue de bucles iterativos y librerías especializadas resulta una estrategia idónea para procesar las matrices demográficas locales y simular escenarios dinámicos que absorban la volatilidad inherente a la caracterización física de la zona, transformando inventarios estáticos en estructuras de datos listas para la toma de decisiones sanitarias.

Para la presente investigación, el ajuste de ecuaciones de regresión lineal múltiple y la evaluación mediante parámetros de error como  $R^2$ , MAE y RMSE constituyen el soporte analítico indispensable para validar el comportamiento histórico de los distritos arequipeños. Esta estructura matemática permite comprobar la precisión con la que los vectores de población e ingresos explican las variaciones en las toneladas recolectadas, asegurando la fiabilidad del modelo previo a su uso como herramienta predictiva.

#### **2.2.4. Sostenibilidad, ecoeficiencia y valorización de residuos**

##### **2.2.4.1. Enfoque de Economía Circular y Producción Más Limpia (PML) en gobiernos locales.**

La transición hacia modelos sostenibles en la administración pública municipal exige la sustitución definitiva del enfoque lineal de gestión de residuos por el paradigma de la economía circular y la Producción Más Limpia (PML). Desde la perspectiva de los gobiernos locales, la GIRS orientada a la circularidad no se limita a las labores básicas de recolección y confinamiento, sino que prioriza de manera jerárquica las acciones de prevención en la fuente, reducción, reutilización, reciclaje y valorización material y energética antes de contemplar la disposición final como alternativa operativa (Culi, 2025; González-Jiménez & Villalobos-Morales, 2021; Poma et al., 2025; Suárez et al., 2025; Valdivia-Espinoza & Guardia-Muguruza, 2023). Este enfoque permite reconceptualizar a los residuos municipales no como desechos carentes de utilidad, sino como recursos secundarios valiosos susceptibles de reingresar a las cadenas productivas, minimizando la huella ecológica urbana y optimizando la eficiencia en el uso de los recursos públicos.

Para viabilizar la implementación de la economía circular a nivel municipal, es indispensable que los tomadores de decisiones apliquen metodologías de análisis de costo-beneficio sostenible que trasciendan los criterios puramente financieros privados. Las evaluaciones técnico-económicas tradicionales suelen ignorar las externalidades ambientales y sociales del confinamiento masivo, perpetuando el uso de vertederos y rellenos como la opción dominante debido a su aparente bajo costo operativo a corto plazo (Rodríguez & Castro, 2023; Suárez et al., 2025).

La ingeniería ambiental contemporánea demuestra que un balance integral debe internalizar económicamente los costos y beneficios ocultos asociados con la salud pública, el impacto en la calidad de vida y la degradación de los ecosistemas locales (Suárez et al., 2025). Al contrastar de forma científica la simple disposición en rellenos frente a opciones de vanguardia, el enfoque de costo-beneficio sostenible demuestra que la valorización e inserción de la PML reduce drásticamente los pasivos ambientales y maximiza los dividendos socioambientales en el largo plazo (Suárez et al., 2025).

#### **2.2.4.2. Tecnologías de valorización material y biológica (Reciclaje mecánico y Compostaje/Digestión).**

La operacionalización de la ecoeficiencia en los sistemas de gestión integral se materializa mediante la aplicación de un portafolio diversificado de tecnologías de valorización material y biológica, diseñadas específicamente para responder a la caracterización física de cada flujo residual. Para la fracción orgánica, la cual constituye el componente mayoritario de la basura urbana, la ingeniería ambiental despliega procesos biotecnológicos orientados a la biorefinería de residuos vegetales y mermas alimentarias; entre estos destacan el compostaje aeróbico y la digestión anaerobia en sistemas de biodigestores tecnificados (Culi, 2025; González-Jiménez & Villalobos-Morales, 2021; Monrroy et al., 2025). El procesamiento anaeróbico controlado de la materia orgánica permite estabilizar los componentes biológicos y co-generar productos de alto valor ecoeficiente, tales como bioenergía y biogás rico en metano para el autoabastecimiento energético, además de abonos orgánicos y digestatos que actúan como enmiendas de alta calidad para restaurar la fertilidad de los suelos agrícolas locales (Culi, 2025; Monrroy et al., 2025; Valdivia-Espinoza & Guardia-Muguruza, 2023).

En lo que respecta al flujo de residuos secos o inorgánicos, las estrategias de valorización se concentran en mitigar el impacto ambiental de los plásticos poliméricos persistentes mediante el reciclaje mecánico de alta fidelidad y el coprocesamiento térmico industrial (Culi, 2025; Rosas-Prado et al., 2021).

El aprovechamiento de los polímeros plásticos reciclables y su inserción como combustible alternativo en industrias de alta temperatura (como las fábricas cementeras) reduce la masa absoluta destinada al colapso de los vertederos, disminuyendo la persistencia de estos polímeros en matrices terrestres y acuáticas (Culi, 2025; Rosas-Prado et al., 2021; Ocaña Valencia & Vite Cevallos, 2021). Es fundamental subrayar que la implementación de estas infraestructuras de valorización genera importantes oportunidades socioeconómicas subaprovechadas por los gobiernos locales.

La formalización de plantas de clasificación y la dinamización de las cadenas de reciclaje actúan como un motor de desarrollo que propicia la creación de empleos verdes directos e indirectos, dignificando la labor de los recicladores informales y consolidando un modelo de negocio sostenible que asocia el beneficio ambiental con la inclusión social y la rentabilidad financiera en los centros de abasto y entornos municipales (Maqui et al., 2021; Ponce-Ponce & Salvatierra-Pilozo, 2025; Ocaña Valencia & Vite Cevallos, 2021).

#### **2.2.4.3. Modelamiento de capacidad volumétrica y estimación de vida útil en rellenos sanitarios.**

El componente final y de cierre dentro del marco de la GIRS es el modelamiento de la capacidad volumétrica y la estimación matemática de la vida útil remanente en las infraestructuras de disposición final reguladas. Un relleno sanitario es un sistema de ingeniería diseñado con un volumen de almacenamiento limitado, cuya tasa de agotamiento espacial se encuentra directamente condicionada por la masa total de residuos que ingresa diariamente de forma cruda a sus celdas de compactación. La literatura científica evidencia que las deficiencias estructurales en los sistemas de tratamiento y la ausencia de plantas de segregación aceleran el colapso volumétrico de estos recintos, transformándolos en focos de degradación territorial con severos impactos sobre la calidad de vida y un incremento sustancial en el inventario regional de emisiones de gases de efecto invernadero (GEI) (Valdivia-Espinoza & Guardia-Muguruza, 2023).

En la provincia de Arequipa, este dimensionamiento adquiere una urgencia crítica debido a la brecha existente entre la tasa de generación poblacional y la capacidad instalada de confinamiento. Al registrarse una masa provincial anual de 355,362 toneladas sin una segregación técnica en origen, Quebrada Honda experimenta una saturación acelerada de celdas que fomenta la aparición de pasivos ambientales (Valdivia-Espinoza & Guardia-Muguruza, 2023). El acoplamiento de modelos predictivos y simulación estocástica en Python permite modelar con precisión matemática los metros cúbicos de terreno que se liberarían mediante la implementación de políticas de desvío de flujos (Rodríguez & Castro, 2023; Suárez et al., 2025).

La integración de variables operacionales y factores de compactación traduce las toneladas recuperadas de materia orgánica y plásticos en volumen geométrico neto disponible. De acuerdo con Suárez et al. (2025), cuantificar esta extensión de vida útil remanente constituye el sustento técnico indispensable para justificar la viabilidad y rentabilidad de los proyectos de inversión pública orientados a la economía circular.

Finalmente, la integración de modelos de capacidad volumétrica y celdas de compactación permite cuantificar matemáticamente el impacto de los escenarios de desvío sobre el Relleno Sanitario de Quebrada Honda. Al traducir las toneladas recuperadas de materia orgánica y plásticos en metros cúbicos reales de espacio disponible ahorrado, se genera un indicador geométrico de extensión de vida útil que actúa como el argumento definitivo de ingeniería para respaldar la viabilidad de los proyectos de inversión pública ambiental en la provincia.

### **2.3. Marco legal**

El desarrollo metodológico, la recopilación de información oficial y la posterior propuesta de valorización material de este proyecto se encuentran estrictamente alineados y respaldados por el marco jurídico e institucional que regula la gestión ambiental y el manejo de los residuos sólidos en la república del Perú. A continuación, se detallan las principales normativas vigentes, su resumen técnico y su aplicación directa al modelo predictivo implementado para la provincia de Arequipa:

#### **2.3.1. Decreto Legislativo N° 1278 - Ley de Gestión Integral de Residuos Sólidos**

Esta norma constituye la columna vertebral de la política ambiental de residuos en el país. Introduce un cambio de paradigma al abandonar el enfoque tradicional de eliminación de desechos y priorizar la economía circular, la minimización en la fuente, la valorización material y energética (reciclaje, compostaje, co-procesamiento) y la responsabilidad extendida del productor, relegando la disposición final como la última opción técnica.

#### **2.3.2. Decreto Supremo N° 014-2017-MINAM - Reglamento del Decreto Legislativo N° 1278**

Reglamenta las operaciones unitarias, responsabilidades institucionales y procedimientos técnicos para el manejo seguro de los residuos. Establece las condiciones operativas mínimas que deben cumplir las infraestructuras de valorización, las plantas de clasificación municipal y las celdas de compactación en los rellenos sanitarios a nivel nacional.

### **2.3.3. Decreto Legislativo N° 1501 - Modificatoria del Decreto Legislativo N° 1278**

Modifica e introduce artículos críticos orientados a fortalecer la obligatoriedad de la segregación en la fuente por parte de los generadores (ciudadanos y comercios) y consolida la responsabilidad de los gobiernos locales en la implementación de rutas de recolección selectiva. Asimismo, endurece los mecanismos de fiscalización y las sanciones ante la proliferación de botaderos informales o áreas degradadas.

### **2.3.4. Ley N° 27972 - Ley Orgánica de Municipalidades**

Otorga a las municipalidades provinciales y distritales la competencia exclusiva y la responsabilidad jurídica de organizar, reglamentar y administrar los servicios de limpieza pública, recolección, transporte, transferencia y disposición final de los residuos sólidos de su jurisdicción territorial.

### **2.3.5. Ley N° 30884 - Ley que regula el plástico de un solo uso y los recipientes o envases descartables**

Establece el marco regulatorio para desincentivar el consumo y reducir la generación de bolsas, sorbetes y envases poliméricos de un solo uso, promoviendo la transición hacia materiales reutilizables o biodegradables para mitigar la contaminación por plásticos y microplásticos.

### **2.3.6. Plan Provincial de Gestión Integral de Residuos Sólidos (PIGARS) de Arequipa**

Instrumento de planificación local emitido por la Municipalidad Provincial de Arequipa que diagnostica la situación sanitaria de la provincia, identifica las brechas de cobertura y traza las metas estratégicas para la recolección masiva y la disposición final regulada en el Relleno Sanitario de Quebrada Honda.

### **2.3.7. Ley N° 32212**

Ley que modifica el Decreto Legislativo N° 1278 para promover la valorización obligatoria de residuos orgánicos e inorgánicos. Esta norma fortalece el régimen sancionador y el principio de responsabilidad compartida, estableciendo la obligatoriedad de la segregación en la fuente tanto para generadores domiciliarios como no domiciliarios.

## **CAPÍTULO III**

### **3. METODOLOGÍA**

#### **3.1. Tipo, nivel y diseño de investigación**

##### **3.1.1. Tipo de investigación**

La presente investigación se clasificó dentro del tipo aplicada y adoptó un enfoque eminentemente cuantitativo. Fue un estudio de naturaleza aplicada debido a que no se limitó a la mera acumulación de postulados teóricos o abstractos, sino que utilizó los fundamentos consolidados de la ingeniería ambiental, la estadística multivariada y el modelamiento computacional para resolver una problemática operativa concreta y de urgente atención en la gestión pública local, la cual fue la saturación volumétrica acelerada del Relleno Sanitario de Quebrada Honda en la provincia de Arequipa y la necesidad de optimizar los escenarios de desvío de flujos mediante la valorización material.

Por otra parte, el proyecto respondió al enfoque cuantitativo ya que el análisis del entorno y la posterior validación de la hipótesis se sostuvieron de forma estricta en la recopilación, el procesamiento numérico y la simulación algorítmica de variables medibles con sus respectivos indicadores técnicos. Estas variables fueron extraídas de registros y plataformas oficiales, tales como las toneladas anuales de residuos sólidos municipales reportadas en el sistema SIGERSOL y los indicadores demográficos y económicos provistos por el INEI, transformando magnitudes matemáticas crudas en un modelo predictivo robusto.

##### **3.1.2. Nivel de investigación**

El alcance metodológico de este proyecto se desplegó de manera progresiva a través de tres niveles de investigación bien definidos, los cuales correspondieron al nivel descriptivo, correlacional y predictivo. En el nivel descriptivo, el estudio se enfocó en caracterizar de forma pormenorizada la evolución histórica y la línea base de la generación total de residuos y las tasas de generación per cápita en el ámbito de los distritos metropolitanos de la provincia de Arequipa durante el periodo cronológico 2018-2025. Posteriormente, la investigación ascendió al nivel correlacional al determinarse estadísticamente el grado de asociación, influencia y co-dependencia matemática que ejercieron los vectores independientes socio-demográficos, representados por el crecimiento de la población y los niveles de ingreso por hogar, sobre las variaciones de la masa residual acumulada.

Finalmente, el proyecto alcanzó su máxima complejidad en el nivel predictivo, el cual constituyó el núcleo de la tesis, mediante el desarrollo, entrenamiento y calibración de algoritmos computacionales programados en Python, los cuales fueron diseñados específicamente para simular escenarios futuros de masa y desagregación por composición física en un horizonte de planeación proyectado para el periodo 2026-2041.

### **3.1.3. Diseño de investigación**

El diseño metodológico que direccionó la recolección y el análisis de la información fue de carácter no experimental, cuantitativo, de corte longitudinal evolutivo de series de tiempo, y de nivel correlacional-predictivo ex post facto. Se definió como un diseño no experimental debido a que no existió una manipulación deliberada ni control activo por parte del investigador sobre las variables independientes de población e ingresos socioeconómicos, limitándose a observar y registrar los fenómenos de generación residual tal y como se manifestaron en el área metropolitana de Arequipa. Asimismo, asumió una propiedad longitudinal de series de tiempo, puesto que se examinaron datos cuantitativos continuos que abarcaron el diagnóstico histórico (2018–2025) y la proyección estocástica futura (2026–2041). Finalmente, se consolidó como una investigación correlacional-predictiva ex post facto fundamentada en una estratificación temporal estructurada en tres rangos cronológicos técnicamente justificados:

1. **Periodo de Diagnóstico Histórico y Calibración (2018–2025; 8 años):** Delimita la línea base analítica. Este rango se seleccionó rigurosamente debido a que a partir de 2018 entra en plena operatividad y vigencia administrativa el Sistema de Información para la Gestión de Residuos Sólidos (SIGERSOL) bajo el marco del Decreto Legislativo N° 1278 (publicado a fines de 2016 y reglamentado mediante el D.S. N° 014-2017-MINAM). Esto garantizó una serie temporal continua, oficial y metodológicamente homogénea de 8 años, cerrando en 2025 como el año de corte técnico previo a la simulación.
2. **Periodo de Corto Plazo y Contingencia Operativa (2026–2029; 4 años):** Corresponde a la ventana temporal de diseño asignada a la celda de contingencia transitoria de emergencia habilitada mediante la inversión IOARR en Quebrada Honda (capacidad volumétrica neta de 840,000 m<sup>3</sup>). Su delimitación temporal permite evaluar matemáticamente el año exacto de colapso físico de esta infraestructura provisional bajo los diferentes esquemas de gestión.

3. **Horizonte de Planeación de Largo Plazo (2026–2041; 16 años):** La fijación del año 2041 como hito de culminación responde al marco metodológico del Sistema Nacional de Programación Multianual y Gestión de Inversiones (*Invierte.pe*) y los criterios de la Guía Técnica del MINAM para proyectos de inversión pública (PIP) en infraestructura de disposición final, los cuales establecen formalmente un horizonte de diseño operativo y vida útil estándar de 15 años para rellenos sanitarios mecanizados y plantas de valorización provinciales. Al iniciar el horizonte de simulación predictiva en 2026, la extensión de 16 años (2026–2041) cubre con exactitud el ciclo completo de preinversión, diseño geométrico y los 15 años de operatividad requeridos para dimensionar el nuevo Complejo Sanitario de Tratamiento Integral proyectado para la provincia de Arequipa (KfW / MINAM), asegurando que el modelo proporcione los volúmenes de diseño indispensables para su correspondiente expediente técnico.

### **3.2.Procedimientos metodológicos**

#### **3.2.1. Diagnóstico y Correlación**

##### **3.2.1.1. Técnica de recopilación documental digital.**

La población de estudio estuvo constituida por la totalidad de los 13 distritos que integran la conurbación metropolitana de la provincia de Arequipa (*Cercado, Cayma, Cerro Colorado, Yanahuara, Paucarpata, José Luis Bustamante y Rivero, Sachaca, Socabaya, Jacobo Hunter, Mariano Melgar, Miraflores, Tiabaya y Sabandía*), los cuales concentraron una población total proyectada de 1,029,919 habitantes al año de cierre 2025.

El universo de datos estuvo compuesto por una matriz histórica de 104 registros anuales distritales ( $13 \text{ distritos} \times 8 \text{ años continuos del periodo } 2018\text{--}2025$ ). La unidad de análisis se definió formalmente como *el vector anualizado de datos de gestión municipal para un distrito específico  $d$  en un año  $t$  ( $Vector_{d,t}$ )*, integrado cuantitativamente por cuatro variables numéricas clave:

1. Masa total de residuos sólidos municipales recolectados ( $Masa\_Total_{d,t}$ , expresada en t/año).
2. Generación Per Cápita domiciliaria ( $GPC_{d,t}$ , en kg/hab/día).
3. Población distrital oficial ( $Población_{d,t}$ , en número de habitantes).
4. Ingreso económico promedio mensual por hogar ( $Ingreso\_Hogar_{d,t}$ , en Soles - S/).

#### **Criterios de Inclusión y Exclusión de Datos**

Para garantizar la representatividad y trazabilidad de la línea base, se aplicaron los siguientes criterios metodológicos estrictos:

- **Criterios de Inclusión:**

1. Registros de masa total y *GPC* validados y publicados oficialmente en la plataforma del Sistema de Información para la Gestión de Residuos Sólidos (SIGERSOL-MINAM) para la serie de tiempo 2018–2025.
2. Datos demográficos e indicadores de ingresos por hogar provistos en los compendios y proyecciones oficiales del Instituto Nacional de Estadística e Informática (INEI - ENAHO).
3. Datos de composición física (porcentaje de materia orgánica y plásticos) validados en los Estudios de Caracterización de Residuos Sólidos (ECRS) del PIGARS Provincial de Arequipa.
4. Distritos con continuidad geográfica directa en el área metropolitana cuya disposición final confluya en el Relleno Sanitario de Quebrada Honda.

- **Criterios de Exclusión:**

1. Registros de residuos peligrosos biocontaminados hospitalarios (EO-RES) y residuos industriales de gestión privada ajenos al ámbito municipal.
2. Distritos rurales o periféricos no integrados a la red continua de recolección hacia Quebrada Honda (*ej. San Juan de Tarucani, Pocsi, Polobaya, Chiguata rural*).
3. Reportes municipales con omisiones temporales no subsanables que superaran el 40% de la serie histórica.

## Procedimiento Algorítmico de Depuración y Acondicionamiento en Python

La matriz maestra ( $104 \times 4$  datos) fue procesada en el entorno de Python utilizando la librería pandas mediante un protocolo de tres etapas:

1. **Imputación por Interpolación Lineal:** Para cubrir vacíos o saltos de reporte municipal en el SIGERSOL (ocurridos principalmente durante el bienio de emergencia sanitaria 2020–2021), se programó una interpolación temporal continua mediante la ecuación:

$$Y_{d,t} = Y_{d,t-1} + \frac{Y_{d,t+1} - Y_{d,t-1}}{(t+1) - (t-1)}$$

Ejecutada en código mediante el comando `df.interpolate(method='linear', axis=1)`.

2. **Detección y Tratamiento de Valores Atípicos (*Outliers*):** Se auditaron errores de digitación en los pesajes de balanza aplicando el criterio del Rango Intercuartílico (*IQR*):

$$IQR = Q_3 - Q_1$$

$$\text{Límite Inferior} = Q_1 - 1.5 \times IQR \quad ; \quad \text{Límite Superior} = Q_3 + 1.5 \times IQR$$

Cualquier dato fuera de este intervalo ajustado fue aislado y acotado mediante la función `clip()`, sustituyendo el valor anómalo por la mediana histórica del clúster distrital correspondiente.

3. **Normalización y Escalamiento Min-Max:** Con el fin de evitar que la escala numérica de la población (orden de  $10^5$  habitantes) distorsionara el peso estadístico de los ingresos (orden de  $10^3$  Soles) durante las regresiones multivariadas, se aplicó la transformación Min-Max:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Codificada mediante la clase `sklearn.preprocessing.MinMaxScaler(feature_range=(0, 1))`, escalando todas las variables independientes a un rango uniforme  $[0,1]$ .

### **3.2.1.2. Algoritmo de limpieza, normalización y depuración de datos en Python.**

Una vez estructurado el archivo maestro, se inició el tratamiento computacional mediante un script automatizado en Python para auditar la calidad de la información y corregir inconsistencias en los reportes municipales, siguiendo la metodología computacional propuesta por Wilujeng (2025). Inicialmente, el programa importó los registros mediante la librería Pandas, estructurando una matriz indexada por distrito y año. Acto seguido, se identificaron celdas vacías producto de omisiones burocráticas; ante la presencia de un vacío temporal, el algoritmo calculó automáticamente un valor de reemplazo mediante interpolación lineal basada en los años adyacentes para garantizar la continuidad de la serie sin distorsionar la tendencia real (Namoune et al., 2022). Posteriormente, se aislaron valores atípicos mediante el rango intercuartílico, sustituyendo datos anómalos por la mediana del clúster correspondiente. Finalmente, se aplicó una normalización Min-Max mediante Scikit-Learn para reescalar las magnitudes demográficas y de ingresos a un intervalo uniforme entre 0 y 1, evitando sesgos por disparidad de escalas en los modelos estadísticos posteriores.

Cabe precisar que este tratamiento computacional respondió directamente a una limitación intrínseca de la investigación, asociada a la heterogeneidad y calidad variable de los reportes históricos provistos por las municipalidades distritales en la plataforma SIGERSOL. La ausencia de sistemas de pesaje automatizado y continuo en las balanzas de algunas comunas generó el riesgo de trabajar con omisiones temporales o errores de digitación en la línea base oficial. Por este motivo, el despliegue del algoritmo de depuración y la prueba del rango intercuartílico no fueron opcionales, sino que constituyeron la salvaguarda metodológica para aislar dichas anomalías e interpolar los vacíos de forma matemática, garantizándose la confiabilidad del modelo antes de ejecutar las proyecciones definitivas hacia el año 2041.

### **3.2.1.3. Pruebas estadísticas multivariadas de normalidad y correlación lineal.**

El cierre metodológico del primer objetivo consistió en evaluar estadísticamente la relación de codependencia entre los factores de crecimiento urbano y la masa residual. En primer lugar, se auditó la distribución de las series temporales mediante la prueba de normalidad de Kolmogorov-Smirnov en Scipy.stats; de acuerdo con el criterio metodológico de Padilla-Vento y Soria (2025), un nivel de significancia  $p > 0.05$  confirma la parametría gaussiana de los datos, justificando el empleo de matrices de correlación de Pearson frente a pruebas no paramétricas.

Comprobada la normalidad, el script calculó los coeficientes de correlación  $r$  para determinar la magnitud y sentido de la influencia que ejercen la población y el nivel socioeconómico sobre el volumen provincial de residuos. Finalmente, se implementó un Análisis de Componentes Principales (PCA) para reducir la dimensionalidad de las matrices, acoplado a un Análisis de Clúster Jerárquico bajo el método de vinculación de Ward, procedimiento que segmentó automáticamente los 13 distritos metropolitanos en tres conglomerados homogéneos de descarte (Padilla-Vento & Soria, 2025; Yactayo-Flores et al., 2025).

### **3.2.2. Modelamiento y Simulación**

#### **3.2.2.1. Formulación de las ecuaciones de proyección ambiental y parametrización de variables.**

Para el desarrollo del segundo objetivo específico, enfocado en el modelamiento y la simulación computacional de los residuos, se procedió en primer lugar con la formulación de las ecuaciones de proyección ambiental y la parametrización de las variables de estudio. En este paso, se establecieron formalmente las relaciones matemáticas básicas que permitieron estimar la generación futura, utilizando como datos de entrada las proyecciones demográficas del INEI y los perfiles socioeconómicos obtenidos en el diagnóstico previo.

La ecuación base asumió que la masa total de residuos es una función dependiente del crecimiento poblacional y el nivel de ingresos distrital, permitiendo calcular la evolución de las toneladas métricas anuales hacia el horizonte del año 2041. Inmediatamente después, se parametrizaron los coeficientes de composición física introduciendo los porcentajes históricos de las fracciones críticas; de este modo, el modelo matemático dividió de forma automática el flujo global en subcomponentes específicos para la materia orgánica y los plásticos poliméricos. Este procedimiento técnico aseguró que cada distrito metropolitano de Arequipa contara con una función matemática personalizada y ajustada a su realidad socio-demográfica particular, proporcionando un modelo estructurado y listo para su automatización (Nguyen et al., 2021; Popli et al., 2021; Singh & Uppaluri, 2022).

#### **3.2.2.2. Programación del script de proyección en Python.**

Una vez consolidadas las funciones de proyección, se procedió con la programación del script en el lenguaje de código abierto Python. Siguiendo los esquemas de desarrollo implementados por Chau et al. (2025) y Liu et al. (2025), el código cargó la matriz depurada mediante la librería Pandas y extendió las trayectorias de crecimiento demográfico anualizadas desde 2026 hasta 2041. Seguidamente, un algoritmo de series de tiempo modeló la evolución de la masa total, multiplicando las toneladas anuales por los coeficientes de segregación física para exportar curvas desagregadas de materia orgánica y plásticos poliméricos (Wilujeng, 2025).

Una vez consolidadas las funciones de proyección, se procedió con la programación del script en el lenguaje de código abierto Python. Siguiendo los esquemas de desarrollo implementados por Chau et al. (2025) y Liu et al. (2025), el código cargó la matriz depurada mediante la librería Pandas y extendió las trayectorias de crecimiento demográfico anualizadas desde 2026 hasta 2041. Seguidamente, un algoritmo de series de tiempo modeló la evolución de la masa total, multiplicando las toneladas anuales por los coeficientes de segregación física para exportar curvas desagregadas de materia orgánica y plásticos poliméricos (Wilujeng, 2025).

La evaluación final del modelo se realizó mediante el análisis de residuales ( $e_i = Y_i - \hat{Y}_i$ ). Tal como recomiendan Elshaboury et al. (2021) y Younes et al. (2016), se comprobó que la dispersión de errores fuera homocedástica, simétrica y con media cero, certificando un comportamiento de ruido blanco puramente aleatorio y descartando patrones de sesgo sistemático en la modelación estocástica distrital (Chau et al., 2025).

### 3.2.2.3. Validación estadística del modelo de residuos.

Para asegurar la validez científica de las proyecciones y respaldar la confiabilidad del algoritmo computacional, se estableció un protocolo estandarizado de validación estadística y análisis de errores estructurado en cuatro componentes fundamentales:

#### 1. Criterios Formales de Aceptación del Modelo:

Para que el modelo computacional fuera considerado matemáticamente válido y apto para la proyección temporal hacia el año 2041, se fijaron los siguientes umbrales de control:

- a) Coeficiente de Determinación  $R^2 \geq 0.90$ , garantizando que más del 90% de la varianza histórica del flujo de residuos quede explicada por las variables independientes.
- b) Error Absoluto Medio (MAE) y Raíz del Error Cuadrático Medio (RMSE) minimizados, exigiendo que la dispersión del error no supere el 5% del promedio provincial de generación anual.
- c) Nivel de significancia estadística  $p < 0.05$  para la validación de los coeficientes de regresión y descriptores socioeconómicos.

#### 2. Pruebas de Normalidad y Parametría:

Previo al modelamiento, se auditó la distribución de las series de tiempo históricas (2018–2025) mediante la prueba de normalidad de Kolmogorov-Smirnov. Al obtenerse un valor de significancia  $p > 0.05$ , se confirmó la distribución paramétrica gaussiana de los datos, justificando formalmente el uso de matrices de correlación de Pearson y ecuaciones de regresión multivariada.

#### 3. Esquema de Entrenamiento y Validación Cruzada (*k*-Fold Cross-Validation):

La base de datos histórica validada de Arequipa se fraccionó en dos bloques analíticos: un 80% de los datos se destinó al entrenamiento del algoritmo (*train*), reservando el 20% restante como bloque testigo *ex post facto* (*test*). La robustez del aprendizaje se auditó mediante un esquema de validación cruzada (*k*-fold cross-validation con  $k = 5$ ), donde el código ejecutó iteraciones aleatorias dividiendo la muestra en 5 subconjuntos para verificar que el desempeño predictivo mantuviera su estabilidad sin incurrir en sobreajuste (*overfitting*).

#### 4. Análisis de Residuales e Inspección de Sesgos:

La evaluación final del modelo se realizó mediante el análisis numérico y gráfico de los residuales ( $e_i = Y_i - \hat{Y}_i$ ). Se verificó que la distribución de los errores fuera simétrica, homocedástica (varianza constante a lo largo de toda la serie de predicción) y centrada en una media igual a cero. Este comportamiento de "ruido blanco" aleatorio descartó la presencia de sesgos o patrones ocultos de sobreestimación o subestimación sistemática en la masa residual proyectada por distrito (Chau et al., 2025; Elshaboury et al., 2021; Younes et al., 2016).

**Protocolo de Recalibración Dinámica y Gobernanza del Algoritmo:** Con el propósito de garantizar que el modelo no opere como una proyección estática invariable ("fotografía fija"), la arquitectura del código fue parametrizada de manera modular mediante variables dinámicas. Esto permite que el flujo de datos admita una retroalimentación computacional continua (*feed-forward update*). La estructura matemática contempla que la entidad rectora provincial (Municipalidad Provincial de Arequipa) o el administrador del SIGERSOL incorpore anualmente las matrices reales de pesaje en balanza de Quebrada Honda, los resultados de los nuevos Estudios de Caracterización de Residuos Sólidos (ECRS) distritales y los censos demográficos actualizados del INEI, reejecutando los módulos de regresión y optimización de residuales al término de cada ejercicio anual para recalibrar de forma automática los coeficientes predictivos y corregir las desviaciones estocásticas del sistema.

##### 3.2.3. Evaluación de Impacto y Propuesta

###### 3.2.3.1. Cálculo del consumo volumétrico en el Relleno Sanitario de Quebrada Honda.

Para el cumplimiento del tercer objetivo específico, que evaluó el impacto físico de las mermas proyectadas, se aplicó en primer lugar un método de modelamiento espacial basado en ecuaciones de compactación geométrica. En este paso, se utilizó el algoritmo de Python para transformar de manera automática las toneladas métricas anuales de residuos (calculadas en el Objetivo 2) en unidades de volumen efectivo, es decir, en metros cúbicos de espacio consumido dentro de las celdas de confinamiento.

Para ello, se incorporaron en las fórmulas de cálculo variables operacionales de ingeniería sanitaria real extraídas directamente del Plan Provincial de Gestión Integral de Residuos Sólidos (PIGARS) de la Municipalidad Provincial de Arequipa y de los informes técnicos de supervisión del Organismo de Evaluación y Fiscalización Ambiental (OEFA). Estos parámetros indispensables incluyeron la densidad de compactación alcanzada por el equipo mecánico pesado en el frente de trabajo (estimada en un rango de 0.7 a 0.9 t/m<sup>3</sup>), el factor de adición por el uso de material de cobertura diaria (fijado en un 20%), y la capacidad volumétrica total de diseño de las celdas operativas. La disponibilidad pública e institucional de estos datos se encontró plenamente ratificada, ya que formaron parte de los instrumentos oficiales de gestión ambiental aprobados por el gobierno local y reportados de forma obligatoria ante el Sistema Nacional de Información Ambiental (SINIA) y el Ministerio del Ambiente (MINAM). De este modo, se aseguró el sustento empírico de las constantes matemáticas requeridas, garantizándose la viabilidad metodológica y la ejecución del tercer objetivo específico sin restricciones de acceso a la información.

Posteriormente, el volumen acumulado anual se restó de la capacidad volumétrica remanente declarada en Quebrada Honda. Este procedimiento geométrico continuo permitió trazar la curva de agotamiento del espacio disponible, determinando el horizonte cronológico en el cual la infraestructura alcanzará su saturación técnica, metodología validada en evaluaciones sanitarias de rellenos por Hoque y Rahman (2020), Janga y Reddy (2025) y Lu y Feng (2020).

#### **3.2.3.2. Simulación de escenarios de desvío de residuos.**

Una vez determinada la línea de colapso del relleno, se procedió a programar en Python la simulación de tres escenarios operativos de gestión pública ambiental para evaluar alternativas de mitigación a largo plazo. El primer entorno simulado fue el Escenario 2: Moderado (Tendencial / Valorización Parcial), donde el programa calculó el impacto si la provincia mantenía su gestión lineal actual, asumiendo que el 100 por ciento de la masa de basura recolectada continuaría ingresando directamente al Relleno Sanitario de Quebrada Honda sin ningún tipo de segregación ni tratamiento.

El segundo entorno correspondió al Escenario Pesimista, donde el algoritmo modeló un escenario crítico condicionado por el aumento descontrolado del consumo ciudadano y una baja eficiencia municipal, lo que elevaría la tasa de generación de plásticos y orgánicos acelerando el llenado de las celdas de tierra. Finalmente, se programó el Escenario de Ecoeficiencia u Optimista, el cual introdujo ecuaciones de desvío de flujos basadas en la economía circular; en este paso, el software restará matemáticamente de la masa total de ingreso al relleno un porcentaje estimado de materia orgánica (asumiendo su desvío hacia plantas de compostaje o digestión) y un porcentaje de plásticos poliméricos (direccionados a cadenas de reciclaje mecánico y coprocesamiento industrial), de acuerdo con las metas progresivas de valorización que exigía la normativa peruana (Popli et al., 2021; Sardarmehni et al., 2022; Ya et al., 2023; Younes et al., 2016).

### **3.2.3.3. Cuantificación del beneficio ambiental y estimación de extensión de vida útil.**


Como paso final de la receta metodológica, se cuantificaron los dividendos ambientales y técnicos que obtuvo la provincia de Arequipa al migrar hacia el Escenario 3: Optimista (Ecoeficiente / Cumplimiento Normativo D.L. 1278) propuesto. En primer lugar, el script de Python recalculó de forma automática la velocidad de llenado del Relleno Sanitario de Quebrada Honda, restando del flujo volumétrico diario el espacio que ya no sería ocupado gracias a la recuperación de orgánicos y plásticos en la fuente. El programa evaluó si este desvío tecnificado permitió alcanzar los niveles de ahorro de terreno reportados en la literatura internacional, los cuales lograron optimizaciones de espacio que oscilaron entre el 28.6 por ciento y el 43 por ciento de la demanda de área de confinamiento.

En segundo lugar, mediante la comparación directa entre la curva del escenario inercial y la curva del escenario optimista, el algoritmo calculó la extensión de vida útil física ganada. Conforme al marco metodológico propuesto por Younes et al. (2016) y Ya et al. (2023), este indicador expresa el número de años adicionales que gana el recinto al reducir su velocidad de llenado geométrico, aportando la justificación de ingeniería necesaria para respaldar las inversiones en economía circular (Valdivia-Espinoza & Guardia-Muguruza, 2023).

### 3.3. Esquema metodológico

**Figura 1**

*Esquema metodológico*



**Nota.** Elaboración Propia.

## **CAPÍTULO IV**

### **4. RESULTADOS Y DISCUSIÓN**

#### **4.1. Diagnóstico de la Generación de Residuos Sólidos Municipales y Correlación Histórica (2018–2025)**

El primer paso metodológico consistió en la reconstrucción, depuración y consolidación de la línea de base histórica del área metropolitana de Arequipa, comprendida por 13 distritos. Este diagnóstico permitió evaluar las dinámicas temporales de la población, la Generación Per Cápita (GPC) domiciliaria y la masa total anual de residuos sólidos municipales (RSM) recolectados, estableciendo su relación cuantitativa con los perfiles socioeconómicos locales.

##### **4.1.1. Evolución Demográfica y de los Parámetros de Generación (2018–2025)**

La dinámica poblacional del área metropolitana presenta un comportamiento heterogéneo. Mientras el Cercado de Arequipa muestra un proceso de estabilización y sutil decrecimiento debido a la transición de predios residenciales a comerciales, los distritos periféricos como Cerro Colorado y Paucarpata operan como polos de atracción demográfica. La Tabla 2 consolida la evolución de la población en el periodo histórico analizado.

**Tabla 2***Evolución poblacional de los distritos del área metropolitana de Arequipa (2018–2025)*

| <b>Dist.</b> | <b>2018</b> | <b>2019</b> | <b>2020</b> | <b>2021</b> | <b>2022</b> | <b>2023</b> | <b>2024</b> | <b>2025</b> | <b>Fuente</b> |
|--------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|---------------|
| <b>CER</b>   | 55,830      | 55,210      | 54,611      | 54,013      | 53,425      | 52,835      | 52,252      | 51,680      | INEI/MPA      |
| <b>CAY</b>   | 94,115      | 96,009      | 97,942      | 99,915      | 101,926     | 103,978     | 106,071     | 108,206     | INEI          |
| <b>CC</b>    | 150,910     | 154,843     | 158,881     | 163,023     | 167,276     | 171,635     | 176,112     | 180,705     | INEI/MPA      |
| <b>YAN</b>   | 24,780      | 25,100      | 25,424      | 25,752      | 26,085      | 26,421      | 26,762      | 27,110      | INEI/MPA      |
| <b>PAU</b>   | 129,510     | 130,420     | 131,339     | 132,263     | 133,197     | 134,136     | 135,084     | 136,040     | INEI          |
| <b>JLBR</b>  | 75,910      | 76,410      | 76,915      | 77,423      | 77,935      | 78,451      | 78,970      | 79,496      | INEI          |
| <b>SAC</b>   | 19,915      | 20,504      | 21,111      | 21,735      | 22,378      | 23,040      | 23,721      | 24,422      | INEI          |
| <b>SOC</b>   | 79,912      | 81,651      | 83,431      | 85,250      | 87,110      | 89,010      | 90,953      | 92,938      | INEI          |
| <b>JH</b>    | 50,115      | 50,544      | 50,978      | 51,416      | 51,858      | 52,303      | 52,752      | 53,205      | INEI          |
| <b>MM</b>    | 54,780      | 55,098      | 55,417      | 55,739      | 56,063      | 56,389      | 56,717      | 57,047      | INEI          |
| <b>MIR</b>   | 50,510      | 50,914      | 51,321      | 51,732      | 52,146      | 52,563      | 52,984      | 53,408      | INEI          |
| <b>TIA</b>   | 14,480      | 14,768      | 15,062      | 15,362      | 15,668      | 15,980      | 16,298      | 16,622      | INEI          |
| <b>SAB</b>   | 4,215       | 4,334       | 4,456       | 4,581       | 4,710       | 4,842       | 4,978       | 5,118       | INEI          |

**Nota:** Proyecciones oficiales del INEI y la MPA. CER: Cercado; CAY: Cayma; CC: Cerro Colorado; YAN: Yanahuara; PAU: Paucarpata; JLBR: J.L. Bustamante y Rivero; SAC: Sachaca; SOC: Socabaya; JH: Jacobo Hunter; MM: Mariano Melgar; MIR: Miraflores; TIA: Tiabaya; SAB: Sabandía.

A la par del crecimiento demográfico, la Generación Per Cápita (GPC) domiciliaria ha experimentado variaciones condicionadas por los hábitos de consumo y la reactivación económica post-pandemia. La Tabla 3 expone el comportamiento de la GPC, donde resalta que distritos de ingresos altos y alta densidad comercial (como Yanahuara y Cercado) registran los valores más elevados de descarte diario por habitante.

**Tabla 3**

*Evolución de la Generación Per Cápita (GPC) domiciliaria oficial (kg/hab/día, 2018–2025)*

| <b>Distrito</b>             | <b>2018</b> | <b>2019</b> | <b>2020</b> | <b>2021</b> | <b>2022</b> | <b>2023</b> | <b>2024</b> | <b>2025</b> | <b>Fuente Oficial</b> |
|-----------------------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-----------------------|
| <b>Cercado</b>              | 0.490       | 0.490       | 0.493       | 0.495       | 0.498       | 0.500       | 0.504       | 0.508       | SIGERSOL / PIGARS     |
| <b>Cayma</b>                | 0.480       | 0.480       | 0.482       | 0.485       | 0.488       | 0.491       | 0.495       | 0.499       | SIGERSOL / PIGARS     |
| <b>Cerro Colorado</b>       | 0.440       | 0.440       | 0.442       | 0.445       | 0.448       | 0.450       | 0.454       | 0.458       | SIGERSOL / PIGARS     |
| <b>Yanahuara</b>            | 0.560       | 0.560       | 0.565       | 0.568       | 0.572       | 0.575       | 0.580       | 0.585       | SIGERSOL / MINAM      |
| <b>Paucarpata</b>           | 0.460       | 0.460       | 0.462       | 0.464       | 0.467       | 0.470       | 0.474       | 0.478       | SIGERSOL / MINAM      |
| <b>J.L. Bustamante y R.</b> | 0.520       | 0.520       | 0.523       | 0.525       | 0.528       | 0.531       | 0.535       | 0.540       | SIGERSOL / MINAM      |
| <b>Sachaca</b>              | 0.460       | 0.460       | 0.463       | 0.465       | 0.468       | 0.471       | 0.475       | 0.479       | SIGERSOL / MINAM      |
| <b>Socabaya</b>             | 0.450       | 0.450       | 0.452       | 0.455       | 0.458       | 0.461       | 0.465       | 0.469       | SIGERSOL / MINAM      |
| <b>Jacobo Hunter</b>        | 0.440       | 0.440       | 0.442       | 0.444       | 0.447       | 0.450       | 0.453       | 0.457       | SIGERSOL / MINAM      |
| <b>Mariano Melgar</b>       | 0.430       | 0.430       | 0.431       | 0.433       | 0.436       | 0.438       | 0.441       | 0.445       | SIGERSOL / MINAM      |
| <b>Miraflores</b>           | 0.440       | 0.440       | 0.442       | 0.445       | 0.448       | 0.451       | 0.454       | 0.458       | SIGERSOL / MINAM      |
| <b>Tiabaya</b>              | 0.420       | 0.420       | 0.422       | 0.424       | 0.427       | 0.430       | 0.433       | 0.437       | SIGERSOL / MINAM      |
| <b>Sabandía</b>             | 0.400       | 0.400       | 0.403       | 0.405       | 0.408       | 0.411       | 0.415       | 0.419       | SIGERSOL / MINAM      |

**Nota:** Parámetros extraídos de los reportes anuales validados del Sistema de Información para la Gestión de Residuos Sólidos (SIGERSOL).

El producto directo de las variables anteriores determina la masa total de residuos sólidos municipales recolectados que se traslada hacia la infraestructura de disposición final. La Tabla 4 expone el volumen anual consolidado (expresado en toneladas métricas anuales), evidenciando que el crecimiento urbano periférico de Cerro Colorado ejerce la mayor presión sobre el sistema logístico provincial, alcanzando las 38,200 toneladas en el año 2025.

**Tabla 4***Masa total de residuos sólidos municipales recolectados (t/año, 2018–2025)*

| <b>Distrito</b>             | <b>2018</b> | <b>2019</b> | <b>2020</b>   | <b>2021</b>   | <b>2022</b> | <b>2023</b> | <b>2024</b> | <b>2025</b> | <b>Fuente de Información</b> |
|-----------------------------|-------------|-------------|---------------|---------------|-------------|-------------|-------------|-------------|------------------------------|
| <b>Cercado</b>              | 14,500      | 14,600      | <i>13,420</i> | <i>13,910</i> | 15,200      | 15,500      | 15,800      | 16,100      | SIGERSOL / MPA               |
| <b>Cayma</b>                | 18,200      | 18,900      | <i>17,540</i> | <i>18,310</i> | 20,500      | 21,200      | 22,000      | 22,800      | SIGERSOL / MPA               |
| <b>Cerro Colorado</b>       | 28,500      | 29,800      | <i>27,850</i> | <i>29,900</i> | 33,100      | 34,800      | 36,500      | 38,200      | SIGERSOL / MPA               |
| <b>Yanahuara</b>            | 6,100       | 6,300       | <i>5,620</i>  | <i>5,980</i>  | 6,800       | 7,100       | 7,300       | 7,600       | SIGERSOL / MPA               |
| <b>Paucarpata</b>           | 24,200      | 24,800      | <i>23,110</i> | <i>24,200</i> | 26,500      | 27,400      | 28,200      | 29,100      | SIGERSOL / MPA               |
| <b>J.L. Bustamante y R.</b> | 16,100      | 16,600      | <i>15,200</i> | <i>15,900</i> | 17,800      | 18,400      | 19,100      | 19,700      | SIGERSOL / MPA               |
| <b>Sachaca</b>              | 3,600       | 3,800       | <i>3,480</i>  | <i>3,750</i>  | 4,300       | 4,600       | 4,900       | 5,200       | SIGERSOL / MPA               |
| <b>Socabaya</b>             | 14,400      | 15,100      | <i>13,980</i> | <i>14,800</i> | 16,800      | 17,600      | 18,400      | 19,200      | SIGERSOL / MPA               |
| <b>Jacobo Hunter</b>        | 8,800       | 9,100       | <i>8,350</i>  | <i>8,890</i>  | 10,000      | 10,400      | 10,800      | 11,200      | SIGERSOL / MPA               |
| <b>Mariano Melgar</b>       | 9,400       | 9,700       | <i>8,950</i>  | <i>9,450</i>  | 10,600      | 11,000      | 11,400      | 11,800      | SIGERSOL / MPA               |
| <b>Miraflores</b>           | 8,900       | 9,200       | <i>8,540</i>  | <i>9,010</i>  | 10,100      | 10,500      | 10,900      | 11,300      | SIGERSOL / MPA               |
| <b>Tiabaya</b>              | 2,400       | 2,600       | <i>2,410</i>  | <i>2,590</i>  | 3,000       | 3,200       | 3,400       | 3,600       | SIGERSOL / MPA               |
| <b>Sabandía</b>             | 680         | 710         | <i>640</i>    | <i>690</i>    | 790         | 830         | 870         | 910         | SIGERSOL / MPA               |

**Nota:** Las cifras en cursiva para el periodo 2020–2021 corresponden a valores estimados formalmente mediante técnicas de imputación debido a inconsistencias o reportes incompletos en la plataforma SIGERSOL durante la fase crítica de la pandemia. Se precisa que la Masa Total reportada por el SIGERSOL incluye, además de los residuos domiciliarios, los flujos municipales no domiciliarios (tales como barrido de calles, mercados y comercios).


El impacto de este desplazamiento demográfico se manifiesta de forma directa en la logística de recolección de residuos sólidos municipales (RSM). Como se constata en la Tabla 4, Cerro Colorado ha consolidado una presión geométrica sobre el sistema provincial, alcanzando las 38,200 t/año en 2025, un volumen que cuadruplica la producción del centro histórico estabilizado.

Esta asimetría espacial ratifica las tesis de Hidalgo-Crespo et al. (2024) y Lu et al. (2022), las cuales demuestran que la expansión poblacional en los márgenes urbanos altera la densidad espacial de generación de residuos de manera no uniforme, provocando picos de acumulación física que saturan las rutas de transporte antes de que las administraciones locales puedan adecuar su capacidad operativa. Asimismo, este crecimiento periférico desordenado agrava la vulnerabilidad de las jurisdicciones con servicios de limpieza pública débiles, un problema recurrente en América Latina donde aproximadamente un tercio de los descartes municipales carece de un confinamiento técnico seguro (Espinosa-Aquino et al., 2023). Al contrastar la masa total frente a los índices per cápita, es fundamental precisar una distinción técnica operativa. La GPC evaluada es de naturaleza estrictamente domiciliaria; sin embargo, el tonelaje global que ingresa al relleno e impacta las rutas de recolección incluye también mermas no domiciliarias de responsabilidad municipal, tales como el barrido de calles, áreas verdes y residuos de mercados. Esta diferencia explica por qué la proyección de masa total supera matemáticamente al simple producto de la población por la GPC domiciliaria.

Por otra parte, la variación de la Generación Per Cápita (GPC) expuesta en la Tabla 3 desmitifica la concepción de que el volumen individual de descarte diario está indisolublemente condicionado por el tamaño absoluto de la población. Distritos con poblaciones reducidas pero con perfiles socioeconómicos consolidados, como Yanahuara, lideran el índice de descarte diario con 0.585 kg/hab/día en 2025, superando a polos demográficos masivos como Paucarpata (0.474 kg/hab/día). Esta discrepancia corrobora las evidencias empíricas recolectadas por Da Silva Júnior et al. (2024) en Sergipe y Poma et al. (2025) en la región amazónica y de Galápagos, donde se determinó la inexistencia de una correlación lineal simple entre el número de habitantes y la GPC domiciliaria. La variabilidad local de la GPC a escala metropolitana responde a determinantes multicausales vinculados a la infraestructura disponible, los hábitos de consumo individuales, el acceso a programas de educación ambiental y la presencia de dinámicas comerciales locales (Cavalheiro et al., 2024; Da Silva Júnior et al., 2024). De este modo, la línea de base histórica de Arequipa demuestra que si bien la expansión demográfica periférica dicta el tonelaje global que ingresa al Relleno Sanitario de Quebrada Honda, el comportamiento intradistrital de descarte responde a una matriz de variables socioeconómicas complejas, validando la necesidad de segmentar el modelo de simulación predictivo en clústeres biofísicos diferenciados.

**Figura 2**


*Tendencias de crecimiento en la masa de RSM recolectada por grupo distrital*



*Nota.* Elaboración Propia.

**Figura 3**

*Mapa de calor de la densidad espacial de generación de RSM en el área metropolitana de Arequipa (2025)*



*Nota.* Elaboración Propia.

#### 4.1.2. Análisis de Correlación Multivariada Socioeconómica

Para dar rigurosidad al cumplimiento metodológico del plan de tesis y justificar la estructura del modelo matemático, se ejecutó una correlación estadística multivariada mediante el entorno informático de Python. Se analizaron las variables independientes: población total distrital ( $P_d$ ) e ingreso económico promedio mensual por hogar ( $I_d$ ), frente a las variables dependientes de generación (GPC y Masa Total). La Tabla 5 recopila los ingresos promedio indexados por estrato socioeconómico que sirvieron de base para el análisis.

**Tabla 5**

*Niveles Socioeconómicos e Ingreso Promedio Mensual por Hogar (Periodo 2018–2025)*

| Distrito                    | Estrato Socioeconómico Predominante | Ingreso Promedio Mensual por Hogar (S/) | Distribución de Hogares por NSE (%)  | Fuente de Referencia |
|-----------------------------|-------------------------------------|-----------------------------------------|--------------------------------------|----------------------|
| <b>Cercado</b>              | Medio-Alto / Alto                   | 4,120                                   | Alto: 24%, M-Alto: 46%, Medio: 30%   | APEIM / INEI         |
| <b>Cayma</b>                | Medio / Medio-Alto                  | 2,850                                   | M-Alto: 20%, Medio: 48%, M-Bajo: 32% | APEIM / INEI         |
| <b>Cerro Colorado</b>       | Medio-Bajo / Medio                  | 1,980                                   | Medio: 15%, M-Bajo: 52%, Bajo: 33%   | APEIM                |
| <b>Yanahuara</b>            | Alto                                | 4,890                                   | Alto: 71%, M-Alto: 24%, Medio: 5%    | APEIM / INEI         |
| <b>Paucarpata</b>           | Medio-Bajo / Bajo                   | 1,920                                   | Medio: 12%, M-Bajo: 55%, Bajo: 33%   | APEIM                |
| <b>J.L. Bustamante y R.</b> | Medio-Alto                          | 3,350                                   | Alto: 8%, M-Alto: 52%, Medio: 40%    | APEIM                |
| <b>Sachaca</b>              | Medio                               | 2,450                                   | M-Alto: 15%, Medio: 55%, M-Bajo: 30% | APEIM                |
| <b>Socabaya</b>             | Medio                               | 2,380                                   | M-Alto: 10%, Medio: 52%, M-Bajo: 38% | APEIM                |
| <b>Jacobo Hunter</b>        | Medio-Bajo                          | 2,010                                   | Medio: 18%, M-Bajo: 54%, Bajo: 28%   | APEIM                |
| <b>Mariano Melgar</b>       | Medio-Bajo                          | 1,950                                   | Medio: 14%, M-Bajo: 56%, Bajo: 30%   | APEIM                |
| <b>Miraflores</b>           | Medio-Bajo                          | 1,990                                   | Medio: 16%, M-Bajo: 55%, Bajo: 29%   | APEIM                |
| <b>Tiabaya</b>              | Medio-Bajo / Medio                  | 2,210                                   | Medio: 25%, M-Bajo: 48%, Bajo: 27%   | APEIM                |
| <b>Sabandía</b>             | Medio-Alto / Medio                  | 2,950                                   | M-Alto: 28%, Medio: 50%, M-Bajo: 22% | APEIM                |


**Nota:** La caracterización económica de los hogares constituye un factor condicionante que explica la elasticidad de la generación de RSM, estructurada mediante la indexación de variables de la Encuesta Nacional de Hogares (ENAHOG) y publicaciones sectoriales de la Asociación Peruana de Empresas de Inteligencia de Mercado (APEIM).

El procesamiento matemático en Python arrojó los coeficientes de correlación de Pearson ( $r$ ) descritos a continuación:

- **Población vs. Masa Total Anual** ( $r = 0.991$ ;  $p < 0.01$ ): Demuestra una correlación lineal directa y estadísticamente muy significativa. Este resultado confirma que el incremento demográfico vegetativo y las expansiones periféricas constituyen el principal motor volumétrico de presión hacia el Relleno Sanitario de Quebrada Honda.
- **Ingreso Mensual del Hogar vs. GPC Domiciliaria** ( $r = 0.932$ ;  $p < 0.01$ ): Revela una correlación positiva fuerte. El poder adquisitivo del sector residencial determina directamente la tasa de descarte diario, lo que valida la estratificación socioeconómica como variable predictora clave dentro del algoritmo computacional.

**Figura 4**


*Matriz de Correlación de Pearson ( $r$ ).*



**Nota.** Elaboración Propia.

**Figura 5**


*Gráfico de Dispersión - Población Provincial vs. Masa Total Anual.*



**Nota.** Elaboración Propia.

**Figura 6**

*Gráfico de Dispersión - Ingreso Promedio Mensual por Hogar vs. GPC Domiciliaria.*



**Nota.** Elaboración Propia.

En contraposición a la naturaleza macro-demográfica de la masa total, el índice de Generación Per Cápit (GPC) domiciliario exhibe una elasticidad ligada de forma directa al vector microeconómico local. La fuerte correlación positiva identificada entre el Ingreso Mensual del Hogar y la GPC ( $r = 0.932; p < 0.01$ ) sitúa a la capacidad adquisitiva residencial como el predictor determinante de la tasa de descarte diario por habitante.

Esta vinculación matemática concuerda con las tendencias reportadas en la literatura internacional, donde autores como Anteneh y Tolasa (2025), así como Jodder et al. (2022) y Joy et al. (2025), hallaron coeficientes de correlación que oscilan entre rangos moderados ( $r=0.436$ ) y niveles de ajuste casi perfectos ( $r=0.997$ ) en muestras de hogares indexados. El sustrato teórico que explica esta dependencia radica en que los estratos socioeconómicos de ingresos altos —representados en Arequipa por distritos como Yanahuara y Cercado— manifiestan patrones de consumo caracterizados por una mayor adquisición de bienes empaquetados y una rápida rotación material, elevando su tasa de descarte per cápita (Agbebaku et al., 2022; Noman et al., 2023).

No obstante, la estructuración de estas correlaciones devela matices metodológicos fundamentales para la ingeniería sanitaria contemporánea. Tal como sostienen He et al. (2022) y Liu et al. (2025), la relación entre el desarrollo económico y la producción de residuos no se rige por una causalidad unidimensional estática. Estudios de panel desarrollados en entornos urbanos maduros advierten que si bien un aumento en los ingresos incrementa de forma sistemática la generación de fracciones secas complejas, como los plásticos poliméricos y empaques sintéticos, puede exhibir un comportamiento inverso o neutro respecto a la fracción orgánica húmeda tradicional, debido a cambios en las conductas de consumo fuera del hogar y una mayor conciencia de desperdicio (Nell et al., 2022; Yu et al., 2025).

Esta divergencia analítica adquiere un sentido crítico al contrastar la realidad andina de Arequipa con los modelos de agrupamiento de la costa peruana propuestos por Yactayo-Flores et al. (2025), confirmando que las transiciones económicas distritales alteran la composición fisicoquímica intrínseca del flujo residual seco de manera mucho más drástica que el tonelaje bruto. Por consiguiente, los coeficientes de correlación calculados justifican matemáticamente el rechazo a cualquier intento de aplicar políticas uniformes de gestión sanitaria a nivel provincial.

La fuerte asimetría entre el vector de ingresos y la GPC obliga a desestimar las proyecciones basadas en promedios globales agregados —un vacío recurrente en las planificaciones municipales del país— y valida la arquitectura lógica del modelo estocástico desarrollado en esta investigación, el cual segmenta las tasas de descarte y los coeficientes de caracterización por clústeres socioeconómicos para blindar de exactitud matemática los cálculos futuros de saturación y espacio geométrico útil en el Relleno Sanitario de Quebrada Honda.

#### **4.2. Formulación y Calibración del Algoritmo Computacional para el Modelamiento y Simulación Predictiva (2026–2041)**

El segundo paso metodológico consistió en la codificación, calibración y validación del modelo predictivo desarrollado en el lenguaje de programación Python. Esta herramienta permite simular de manera dinámica las trayectorias de crecimiento de la masa total de residuos sólidos municipales (RSM) y su correspondiente desagregación en fracciones críticas (materia orgánica y plásticos poliméricos) a lo largo de un horizonte de planificación de 16 años (2026–2041).

##### **4.2.1. Formulación Matemática de las Ecuaciones de Proyección Ambiental y Parametrización**

La arquitectura lógica del software predictivo se fundamenta en el establecimiento de relaciones funcionales continuas entre las dinámicas demográficas y los coeficientes de descarte distrital. Siguiendo las metodologías demográficas del Instituto Nacional de Estadística e Informática (INEI), las proyecciones de población se parametrizaron aplicando una tasa de crecimiento geométrico e intercensal, expresada mediante la siguiente ecuación base:

$$P_d(t) = P_{d,0} \cdot (1 + r_d)^t$$

Donde  $P_d(t)$  representa la población proyectada para el distrito en el año de simulación  $t$ ;  $P_{d,0}$  es la población base del año de corte histórico 2025;  $r_d$  corresponde a la tasa de crecimiento anualizada calculada de acuerdo con el análisis intercensal histórico del INEI; y  $t$  representa el tiempo continuo transcurrido en años a partir del año 2025 ( $t = 1$  para el año 2026). La adopción de este modelo geométrico faculta al algoritmo para absorber la desaceleración y saturación urbana de los centros consolidados, frente a la aceleración registrada en las áreas de expansión urbana periférica.

Para la proyección y desglose cuantitativo de la masa, se parametrizaron coeficientes estocásticos de segregación física basados en los muestreos estacionales consolidados en el Plan Integral de Gestión Ambiental de Residuos Sólidos (PIGARS) de la provincia de Arequipa. El algoritmo automatiza la división del flujo global en subcomponentes volumétricos específicos, aislando la materia orgánica por su alta tasa de generación de biogás y lixiviados, y los plásticos poliméricos por su estabilidad química y persistencia ambiental. La Tabla 6 detalla la distribución de los tres grupos de simulación biofísica indexados en la memoria lógica del script informático.

**Tabla 6**

*Coefficientes estocásticos de caracterización física de RSM para el horizonte de simulación (2026–2041)*

| <b>Grupo de Simulación Biofísica</b>               | <b>Distritos Asignados</b>                                            | <b>Materia Orgánica - Flujo Húmedo (%)</b> | <b>Plásticos Poliméricos - Flujo Seco (%)</b> | <b>Humedad Promedio Residuo (%)</b> | <b>Documento Técnico de Referencia</b> |
|----------------------------------------------------|-----------------------------------------------------------------------|--------------------------------------------|-----------------------------------------------|-------------------------------------|----------------------------------------|
| <b>Grupo 1: Alto Comercial y de Altos Ingresos</b> | Cercado, Yanahuara, J.L. Bustamante y Rivero, Sabandía                | 54.0%                                      | 12.5%                                         | 69.29%                              | PIGARS Arequipa / ECRS Provincial MPA  |
| <b>Grupo 2: Residencial de Ingresos Medios</b>     | Cayma, Sachaca, Socabaya, Tiabaya                                     | 57.5%                                      | 10.0%                                         | 70.80%                              | PIGARS Arequipa / SIGERSOL             |
| <b>Grupo 3: Densidad Media e Ingresos Bajos</b>    | Cerro Colorado, Paucarpata, Jacobo Hunter, Mariano Melgar, Miraflores | 62.0%                                      | 8.5%                                          | 72.10%                              | Caracterización MPA / SIGERSOL         |

**Nota:** Parametrización asignada en el entorno computacional para modelar de forma diferenciada la velocidad de degradación y el desvío analítico de flujos hídricos y secos.

A pesar de las ventajas predictivas de este enfoque segmentado, la parametrización de estas fracciones en la literatura científica actual continúa siendo mayoritariamente indirecta, recurriendo habitualmente a covariables meteorológicas como velocidad del viento, humedad relativa y temperatura para aproximar los porcentajes de generación (Özkan et al., 2021).

Al respecto, investigaciones como la de Adeleke et al. (2021) logran capturar la variabilidad mensual en vertederos mediante estas variables climáticas ( $R=0.916$  para orgánicos y  $r=0.834$  para plásticos); no obstante, Thaiprayoon et al. (2025) advierten que este criterio introduce un sesgo determinista que ignora la memoria y hábitos de consumo a largo plazo en el entorno urbano.

Para subsanar esta limitación, la arquitectura diseñada para Arequipa opta por una parametrización de variables continuas basada en perfiles socioeconómicos distritales estables. Este refinamiento es crítico para la fracción orgánica húmeda, pues Mousania et al. (2024) demostraron que omitir una calibración mecanística bajo condiciones operativas reales induce a sobreestimaciones de hasta un 75% en subproductos como metano y lixiviados. De igual modo, emplear rangos continuos para los plásticos evita distorsiones asociadas a la heterogeneidad polimérica (Cheng et al., 2023), dotando al modelo del rigor necesario para proyectar el metabolismo urbano hacia el año 2041 sin las restricciones de transferencia de datos comunes en el hemisferio sur (Ali et al., 2024; Lamborn, 2024).

#### **4.2.2. Proyecciones Anualizadas de Población por Distrito (2026–2041)**

El procesamiento iterativo multi-paso ejecutado mediante bucles programados permitió extender las tendencias demográficas oficiales de la provincia hacia el horizonte fijado. La Tabla 7 consolida los hitos poblacionales anualizados extraídos del script para los años clave de la proyección (2026, 2031, 2036 y 2041), reflejando la marcada reconfiguración territorial del área metropolitana.

**Tabla 7**

*Proyección anualizada de población de los distritos metropolitanos (Hitos del periodo 2026–2041)*

| <b>Distrito</b>             | <b>Tasa de Crecimiento Anual (r)</b> | <b>Año 2026</b> | <b>Año 2031</b> | <b>Año 2036</b> | <b>Año 2041</b> | <b>Fuente de Proyección</b> |
|-----------------------------|--------------------------------------|-----------------|-----------------|-----------------|-----------------|-----------------------------|
| <b>Cerro Colorado</b>       | +0.023                               | 184,861         | 207,121         | 232,060         | 260,004         | INEI                        |
| <b>Paucarpata</b>           | +0.006                               | 137,400         | 144,409         | 151,775         | 159,517         | INEI                        |
| <b>Cayma</b>                | +0.015                               | 109,829         | 118,317         | 127,461         | 137,311         | INEI                        |
| <b>Socabaya</b>             | +0.019                               | 94,704          | 104,049         | 114,317         | 125,597         | INEI                        |
| <b>J.L. Bustamante y R.</b> | +0.007                               | 80,132          | 83,389          | 86,779          | 90,306          | INEI                        |
| <b>Miraflores</b>           | +0.006                               | 53,728          | 55,360          | 57,041          | 58,772          | INEI                        |
| <b>Mariano Melgar</b>       | +0.005                               | 57,332          | 58,780          | 60,264          | 61,786          | INEI                        |
| <b>Jacobo Hunter</b>        | +0.007                               | 53,577          | 55,479          | 57,448          | 59,487          | INEI                        |
| <b>Cercado</b>              | -0.005                               | 51,422          | 50,149          | 48,908          | 47,697          | INEI / MPA                  |
| <b>Yanahuara</b>            | +0.009                               | 27,354          | 28,607          | 29,918          | 31,289          | INEI / MPA                  |
| <b>Sachaca</b>              | +0.018                               | 24,862          | 27,181          | 29,717          | 32,490          | INEI                        |
| <b>Tiabaya</b>              | +0.008                               | 16,755          | 17,436          | 18,145          | 18,882          | INEI                        |
| <b>Sabandía</b>             | +0.012                               | 5,179           | 5,498           | 5,835           | 6,194           | INEI                        |

**Nota:** Matrices de población calculadas mediante la aplicación algorítmica de tasas intercensales continuas e indexadas por distrito para estimar los escenarios de saturación territorial.


Las proyecciones consolidadas en la Tabla 7 evidencian que el crecimiento poblacional y la huella de expansión física de la provincia de Arequipa experimentan un marcado proceso de desacoplamiento espacial, un fenómeno conocido conceptualmente como dispersión urbana o *urban sprawl*. Mientras distritos centrales e históricos manifiestan un estancamiento o crecimiento negativo —revelado drásticamente en el Cercado con una tasa de  $-0.005$ —, las periferias metropolitanas operan bajo esquemas de aceleración exponencial, destacando Cerro Colorado con una proyección que prevé alcanzar los 260,004 habitantes para el año 2041.

Este patrón de expansión asimétrica coincide con los hallazgos de Mahmoudzadeh et al. (2022) y Saganeiti et al. (2021), quienes demuestran que las ciudades que crecen bajo dinámicas de dispersión periférica tienden a duplicar su huella construida a una velocidad muy superior a su ritmo de crecimiento poblacional vegetativo. Las implicaciones técnicas de este fenómeno para la gestión de RSM son severas: el sprawl periférico eleva de forma exponencial los costos unitarios de transporte y debilita la eficiencia de las rutas de recolección, induciendo a errores de subestimación operativa si las proyecciones se realizan utilizando curvas de crecimiento agregadas a nivel provincial (Pour & Oja, 2021; Saganeiti et al., 2021).

Por esta razón, la estrategia metodológica adoptada en esta tesis rechaza el uso de una curva demográfica homogénea para toda la metrópoli y opta por calibrar reglas de transición y tasas intercensales particionadas individualmente para cada uno de los trece distritos metropolitanos. Este enfoque híbrido, defendido en la modelación de megaciudades por Xia y Zhang (2021), permite segmentar los umbrales de crecimiento por subregiones, aislando los polos de atracción habitacional periférica de las zonas comerciales consolidadas. Al integrar estas trayectorias demográficas diferenciadas con escenarios estocásticos de generación, el script de Python no solo actúa como un estimador estático de habitantes de diseño, sino que se transforma en una herramienta de geoprocésamiento predictivo capaz de localizar con precisión matemática en qué puntos de la geografía provincial se concentrarán las mayores cargas volumétricas de residuos (Karutz et al., 2023; Mesta et al., 2022). Esto proporciona un marco conceptual robusto para anticipar el colapso de los servicios de saneamiento y guiar la planificación de infraestructuras sanitarias con un enfoque de asignación espacial explícita (Mhangara et al., 2025; Yaagoubi et al., 2024).

**Figura 7**

*Curvas de proyección demográfica por grupo de simulación biofísica (2026–2041)*



**Nota.** Elaboración Propia.

#### 4.2.3. Protocolo de Validación Estadística del Modelo Computacional


Para garantizar la validez científica del gemelo digital y descartar sesgos en el cálculo futuro del consumo volumétrico, se ejecutó un protocolo estándar de validación estadística y análisis de errores. La base de datos histórica depurada (2018–2025) fue fraccionada en dos bloques: las series temporales de los primeros años sirvieron para calibrar las constantes matemáticas del código, reservando el bienio más reciente como un bloque testigo de comprobación ex post facto.

La evaluación del desempeño predictivo sobre el bloque testigo (2024–2025) arrojó un Coeficiente de Determinación  $R^2 = 0.998$ , un Error Absoluto Medio  $MAE = 374.2$  t/año y una Raíz del Error Cuadrático Medio  $RMSE = 437.8$  t/año.

La obtención de un coeficiente  $R^2$  tan cercano a la unidad se explica detalladamente por tres factores metodológicos y físicos concordantes con la literatura especializada: en primer lugar, la masa total de residuos en un entorno urbano cerrado se encuentra fuertemente traccionada por el crecimiento poblacional absoluto ( $r = 0.991; p < 0.01$ ), una variable agregada sumamente estable y con baja dispersión estocástica en registros oficiales del INEI; en segundo lugar, el algoritmo no opera sobre datos individuales crudos, sino sobre la suma física conservativa de masas por clústeres sociodemográficos previamente depurados mediante interpolación y filtros IQR; en tercer lugar, el acoplamiento de la tasa de descarte *GPC* con el ingreso monetario ( $r = 0.932$ ) elimina la variabilidad no explicada en los distritos comerciales. Este alto nivel de ajuste es consistente con lo reportado por Billal & Kumar (2025) y Xia et al. (2021), quienes demuestran que los modelos predictivos de residuos fundamentados en variables demográficas agregadas y algoritmos de optimización alcanzan de forma recurrente coeficientes  $R^2$  en el rango de 0.970 a 0.999, confirmando que la varianza restante (0.2%) corresponde a ruido blanco aleatorio no estructurado.

**Figura 8**

*Gráfico de dispersión de calibración estadística*



**Nota.** Elaboración Propia.

No obstante, la validez científica de un modelo predictivo aplicado a la gestión de residuos no puede fundamentarse exclusivamente en la presentación aislada de métricas resumidas, sesgo que suele ocultar estructuras de error no deseadas o sobreajustes de la muestra (Chicco et al., 2021).

Para blindar la robustez del gemelo digital ante el comité evaluador, el protocolo implementado en Python contempló una partición rigurosa de datos entre entrenamiento (train) y prueba (test), acoplada a un análisis explícito de la distribución de los residuales, procedimiento metodológico recomendado por Li et al. (2025) y Gebremariam et al. (2026) para descartar heterocedasticidad en series temporales.

Mediante funciones de visualización en Python, se examinaron de forma sistemática los residuales frente a los valores predichos, así como diagramas Q-Q e histogramas de frecuencia (Hasan et al., 2025). Tal como sostienen Das et al. (2022) y Wei et al. (2026), la confirmación de errores simétricos centrados en una media cero y con varianza homogénea garantiza un comportamiento de ruido blanco puramente aleatorio, descartando patrones de sobreestimación o subestimación sistemática. Asimismo, el esquema de validación cruzada (k-fold) y la optimización de hiperparámetros aseguran una alta capacidad de generalización algorítmica sin incurrir en sobreajuste (Raghavendran et al., 2026; Vardhan et al., 2023).

#### **4.3.Evaluación del Impacto Volumétrico y Simulación de Escenarios de Desvío de Flujos en el Relleno Sanitario de Quebrada Honda**

El tercer paso metodológico consistió en evaluar matemáticamente el impacto físico del caudal másico proyectado sobre la capacidad espacial remanente de la infraestructura de disposición final provincial, contrastando las políticas tradicionales de confinamiento lineal frente a las ventajas operativas de la economía circular.

##### **4.3.1. Cálculo del Consumo Volumétrico Geométrico de Celdas**

El Relleno Sanitario de Quebrada Honda se encuentra emplazado sobre un terreno fiscal de 216.96 hectáreas en el distrito de Yura, operando bajo la administración directa de la Municipalidad Provincial de Arequipa. Esta infraestructura centraliza la disposición final de los residuos sólidos municipales (RSM) metropolitanos, procesando un volumen promedio diario que superó las 1,000 toneladas en el año 2025 y cuya proyección prevé superar las 1,500 toneladas diarias a mediano plazo.

El vaso de vertido principal (Vaso de Disposición N° 1) fue diseñado originalmente con una capacidad volumétrica neta de  $2,334,555.60 \text{ m}^3$  ; sin embargo, el acelerado incremento de la masa y la ausencia de segregación técnica en origen provocaron que este espacio alcanzara su colapso operativo y límite técnico entre finales de 2024 e inicios del año 2025.

Para mitigar la emergencia sanitaria, se ejecutó una celda de contingencia transitoria bajo la modalidad de Inversión de Optimización, Ampliación Marginal, Rehabilitación y Reposición (IOARR) , la cual expandió temporalmente la capacidad de almacenamiento en un 20% sobre el diseño original , habilitando un volumen volumétrico adicional de entre 700,000.00 m<sup>3</sup> y 840,000.00 m<sup>3</sup>.

Para modelar la velocidad de agotamiento de este volumen remanente útil en el script de Python, el consumo de espacio anualizado ( $V_{\text{anual}}(t)$ ) se calculó integrando los parámetros mecánicos y de cobertura terrestre del recinto mediante la siguiente ecuación de compactación geométrica:

$$V_{\text{anual}}(t) = \frac{M_{\text{RSM}}(t)}{\rho_c} \cdot (1 + f_c)$$

Donde:

- $M_{\text{RSM}}(t)$  es la masa total de residuos sólidos municipales que ingresa al relleno sanitario en el año de simulación  $t$ , expresada en toneladas métricas.
- $\rho_c$  representa la densidad de compactación inicial lograda en el frente de trabajo diario por el paso de la maquinaria pesada, parametrizada en un rango técnico de 0.70 a 0.90 t/m<sup>3</sup>.
- $f_c$  es el factor de adición por el uso de material de cobertura de tierra arcillosa diaria para el control de olores y vectores, fijado formalmente en un 20% (0.20).

Adicionalmente, el modelo incorporó una constante de densidad de estabilización mecánica de 1.20 t/m<sup>3</sup>, la cual cuantifica la consolidación natural y degradación biológica que experimenta la masa confinada a mediano plazo.

**Tabla 8**

*Parámetros y coeficientes ingenieriles para la simulación del relleno sanitario de Quebrada Honda*

| <b>Parámetro Operativo</b>                                | <b>Unidad</b>    | <b>Rango / Valor de Simulación</b> | <b>Ingenieril en el Modelo Predictivo</b>                                                          | <b>Fuente Técnico-Oficial</b>     |
|-----------------------------------------------------------|------------------|------------------------------------|----------------------------------------------------------------------------------------------------|-----------------------------------|
| <b>Capacidad de Diseño Vaso 1</b>                         | m <sup>3</sup>   | 2,334,555.60                       | Capacidad geométrica límite del diseño del vaso original.                                          | Memoria de Cálculo IOARR          |
| <b>Volumen de Ampliación Transitoria</b>                  | m <sup>3</sup>   | 700,000.00 a 840,000.00            | Volumen neto habilitado mediante la celda de contingencia transitoria (2026–2029).                 | Memoria de Cálculo IOARR          |
| <b>Densidad de Compactación (Maquinaria)</b>              | t/m <sup>3</sup> | 0.70 a 0.90                        | Densidad lograda tras el extendido, homogeneización y paso del compactador mecánico pesado.        | Criterios de Ingeniería Sanitaria |
| <b>Densidad de Estabilización Mecánica</b>                | t/m <sup>3</sup> | 1.20                               | Densidad última que alcanzan los residuos a mediano plazo por consolidación natural y degradación. | Memoria de Cálculo IOARR          |
| <b>Factor de Material de Cobertura (<math>f_c</math>)</b> | %                | 20%                                | Adición volumétrica de tierra diaria para control de olores, lixiviados y vectores.                | Guía Técnica MINAM                |
| <b>Ingreso Diario Promedio de Residuos</b>                | t/día            | 1,000.00 a 1,500.00                | Caudal másico promedio de ingreso registrado y proyectado en el frente de trabajo.                 | Informe de Contraloría            |

**Nota:** Parámetros operativos y mecánicos utilizados como constantes matemáticas estables en el script de Python para la conversión de masa a volumen efectivo.

Asimismo, la parametrización de la densidad dentro del script de Python adquiere una dimensión física de alta complejidad debido a que este indicador no representa una constante estática, sino que fluctúa en función de la madurez del residuo, la adición de suelo arcilloso y los procesos de biocompresión orgánica (Karimi et al., 2023). En ensayos de laboratorio, Pantić et al. (2022) destacan que los valores de peso unitario máximo seco ( $\gamma_{dmax}$ ) varían notablemente entre 5.9 kN/m<sup>3</sup> y 14 kN/m<sup>3</sup> en estrecha dependencia con el contenido óptimo de humedad confinada.

Esta variabilidad hídrica altera el comportamiento hidráulico intrínseco de las celdas. Conforme aumenta la energía de compactación mecánica y se eleva la densidad, los vacíos intersticiales se contraen y los caminos de flujo se vuelven más tortuosos, induciendo una caída en la conductividad hidráulica que puede descender de  $1.23 \times 10^{-4}$  m/s a  $2.55 \times 10^{-5}$  m/s (Al-Isawi et al., 2021). Por consiguiente, Dang et al. (2022) señalan que un adecuado control de compactación no solo optimiza el volumen útil, sino que incrementa la estabilidad geotécnica de los taludes frente a riesgos de falla por sobrecarga de lixiviados.

#### **4.3.2. Simulación Computacional de Escenarios de Gestión Operativa**

El algoritmo computacional evaluó tres escenarios de gestión pública ambiental condicionados por el grado de acatamiento del marco normativo nacional, específicamente respecto a las obligaciones de separación en la fuente detalladas en el Decreto Legislativo N° 1278 (Ley de Gestión Integral de Residuos Sólidos), su modificatoria mediante el Decreto Legislativo N° 1501 y la Ley N° 32212. Las tres trayectorias analizadas corresponden a las siguientes estructuras de comportamiento:

- 1. Escenario 1: Pesimista (Inercial / Confinamiento Lineal):** Pesimista (Inercial) contempla la continuación estricta del modelo lineal de gestión de "extraer, consumir y enterrar", asumiendo un cumplimiento nulo de las metas de segregación en la fuente y valorización dispuestas por el Decreto Legislativo N° 1278 y la Ley N° 32212. Bajo este esquema operativo, el 100% de la masa de basura cruda generada en los 13 distritos metropolitanos (compuesta por un 58.5% de materia orgánica húmeda y un 10.2% de plásticos poliméricos) es recolectada de forma mezclada y transportada directamente hacia el Relleno Sanitario de Quebrada Honda. Este escenario asume una presión volumétrica máxima sobre el frente de trabajo, donde la ausencia de desvío de flujos acelera la generación de lixiviados y biogás, incrementando la necesidad de material de cobertura diaria ( $f_c = 0.20$ ) y consumiendo aceleradamente la capacidad geométrica remanente de la celda de contingencia transitoria IOARR.
- 2. Escenario 2: Moderado (Tendencial / Valorización Parcial) (Tendencial):** Representa un cumplimiento parcial y rezagado de la legislación ambiental, logrando estabilizar las tasas de valorización de la fracción orgánica húmeda en un 15% y de la fracción inorgánica seca en un 20% constante hacia el horizonte del año 2041.

### 3. Escenario 3: Optimista (Ecoeficiente / Cumplimiento Normativo Articulado):

Simula el cumplimiento progresivo de las metas de valorización dispuestas por el Ministerio del Ambiente (MINAM), sustentado no de forma pasiva en la mera promulgación legal del Decreto Legislativo N° 1278 y la Ley N° 32212, sino en la operatividad concurrente de instrumentos de política pública y mecanismos coactivos de control. Este escenario asume la articulación activa del Programa de Incentivos a la Mejora de la Gestión Municipal del MEF (mediante el condicionamiento de transferencias presupuestales distritales al cumplimiento de metas de segregación y valorización), la implementación de esquemas de fiscalización ambiental coactiva a nivel comunal (EFA local / OEFA) con sanciones económicas tipificadas a comercios e industrias no segregadoras según el Decreto Legislativo N° 1501, y la aplicación de incentivos económicos directos al vecino segregador (bonificaciones tributarias en arbitrios de limpieza pública). Bajo este marco de gobernanza, el modelo programa para la fracción orgánica una tasa de recuperación del 20% en 2026, con un incremento lineal de 1.5% anual hasta alcanzar el 42.5% en 2041; paralelamente, para la fracción inorgánica seca reciclable, se programa una captura inicial del 15% en 2026 con un incremento sostenido del 1.5% anual hasta consolidar el 37.5% en el año 2041.

Para el contexto de municipalidades metropolitanas en economías emergentes, este enfoque dinámico se enriquece mediante el despliegue de estructuras metodológicas tipo M-GRCT, las cuales evalúan las variables socioculturales y la disponibilidad de maquinaria real para validar la viabilidad técnica de la transición (Vargas-Terranova et al., 2022). Asimismo, el acoplamiento de balances de Análisis de Flujo de Materiales (MFA) con matrices de Análisis de Ciclo de Vida (LCA) permite cuantificar con precisión matemática cómo las alteraciones epidemiológicas en las fracciones secas y húmedas reconfiguran los impactos ambientales globales del sistema (Bendiuh et al., 2023; Istrate et al., 2021; Starostina & Christensen, 2022).

Los resultados de estas simulaciones internacionales demuestran con consistencia que el escenario inercial (ESCENARIO 1: PESIMISTA (INERCIAL / CONFINAMIENTO LINEAL)) perpetúa una dependencia insostenible hacia el Relleno Sanitario y maximiza las externalidades negativas sobre el entorno (Peiris & Dayarathne, 2022).

Sin embargo, la superioridad teórica de un modelo circular no se traduce automáticamente en un éxito operativo uniforme en todas las jurisdicciones; investigaciones desarrolladas en municipios de bajos ingresos revelan que la viabilidad financiera del sistema se encuentra estrictamente condicionada por factores macroeconómicos como la inflación, el volumen neto de recursos comercializables y la capacidad de recaudación de los arbitrios de limpieza pública, existiendo escenarios específicos donde los costos de la planta de clasificación superaron los dividendos de la valorización, obligando a mantener esquemas lineales optimizados (Abu-Qdais et al., 2023; Vargas-Terranova et al., 2022).

En concordancia con estas evidencias, se reconoce como una limitación intrínseca de la presente investigación que el modelo computacional desarrollado evalúa el comportamiento del sistema desde una perspectiva estrictamente física, estocástica y volumétrica, prescindiendo de una modelación econométrica o financiera de flujos de caja (CAPEX y OPEX). La recomendación de implementar macroinfraestructuras de biorefinería anaerobia y complejos de reciclaje mecánico de alta densidad responde al potencial técnico de desvío volumétrico necesario para evitar el colapso del vaso de vertido; no obstante, su sostenibilidad operativa real dependerá de la capacidad de recaudación tributaria local, la fluctuación en los precios de venta de los materiales secundarios recuperados y los costos logísticos de operación y mantenimiento. Asumir la viabilidad automática de estas tecnologías sin un examen financiero riguroso induciría a distorsiones presupuestarias en las comunas distritales, por lo que las estimaciones aquí obtenidas deben interpretarse como metas de capacidad física que demandan, de forma complementaria, una evaluación económica contingente previa a la asignación de recursos públicos.

De este modo, la estructura lógica programada para la zona metropolitana de Arequipa se consolida como un instrumento de soporte para la decisión pública, parametrizando las metas del Decreto Legislativo N° 1278 y vinculándolas con la eficiencia real de captura de los programas locales de segregación selectiva (Di Foggia & Beccarello, 2023; Domingues, 2025; D'Adamo et al., 2024).

### 4.3.3. Cuantificación del Beneficio Ambiental y Extensión de la Vida Útil

Al integrar los módulos de desvío estocástico de masa con las ecuaciones de compactación volumétrica, el script de Python calculó las trayectorias de agotamiento espacial del volumen de contingencia habilitado. La Tabla 9 recopila los resultados de volumen anual consumido e inventario acumulado para años clave del horizonte de la tesis.

**Tabla 9**

*Simulación comparativa de consumo volumétrico de celdas en Quebrada Honda bajo tres escenarios operativos (2026–2041)*

| <b>Año de Simulación</b> | <b>Pesimista:<br/>Consumo Anual (m³)</b> | <b>Pesimista:<br/>Acumulado (m³)</b> | <b>Moderado:<br/>Consumo Anual (m³)</b> | <b>Moderado:<br/>Acumulado (m³)</b> | <b>Optimista:<br/>Consumo Anual (m³)</b> | <b>Optimista:<br/>Acumulado (m³)</b> |
|--------------------------|------------------------------------------|--------------------------------------|-----------------------------------------|-------------------------------------|------------------------------------------|--------------------------------------|
| <b>2026</b>              | 271,850                                  | 271,850                              | 239,228                                 | 239,228                             | 224,548                                  | 224,548                              |
| <b>2028</b>              | 298,420                                  | 854,990                              | 256,641                                 | 742,869                             | 236,945                                  | 691,238                              |
| <b>2031</b>              | 332,600                                  | <b>Colapso Absoluto</b>              | 282,710                                 | 1,612,420                           | 251,113                                  | 1,432,608                            |
| <b>2036</b>              | 384,150                                  | --                                   | 326,528                                 | 3,135,515                           | 268,905                                  | 2,732,653                            |
| <b>2041</b>              | 442,900                                  | --                                   | 376,465                                 | 4,893,000                           | 279,027                                  | 4,102,483                            |

**Nota:** Volúmenes proyectados mediante el script computacional asumiendo una densidad de compactación promedio de 0.80 t/m³ y 20% de cobertura terrestre diaria. El guion (--) explicita la inexistencia de espacio físico remanente debido al colapso técnico anticipado de la celda de contingencia transitoria de emergencia.

Con el propósito de evitar ambigüedades en la interpretación de los resultados de la simulación, se definen matemáticamente los dos indicadores volumétricos presentados en la Tablas 9:

- **Consumo Volumétrico Acumulado ( $m^3$ ):** Representa la suma física progresiva e integrada del volumen de celdas efectivamente ocupado por la masa de residuos compactada y su correspondiente material de cobertura diaria, desde el año base de inicio de la simulación ( $t = 2026$ ) hasta un año hito  $T$ . Se calcula mediante la integral discreta:

$$V_{acum}(T) = \sum_{t=2026}^T V_{anual}(t)$$

- **Espacio Físico Liberado o Ahorrado Acumulado ( $m^3$ ):** Constituye el beneficio neto de economía circular, definido como el volumen de terreno que se deja de consumir en el relleno sanitario gracias al desvío progresivo de orgánicos y plásticos. Se calcula restando geoméricamente el consumo acumulado del Escenario Optimista del consumo acumulado del Escenario Pesimista:

$$V_{liberado}(T) = V_{acum,Pesimista}(T) - V_{acum,Optimista}(T)$$


Hacia el año 2041, este valor alcanza los  $1,997,517 m^3$ , lo que equivale al volumen completo de un vaso sanitario provincial.

El análisis estocástico computacional determina de forma unívoca que, bajo el Escenario 1: Pesimista (Inercial / Confinamiento Lineal), la celda de contingencia transitoria de emergencia IOARR (cuya capacidad volumétrica máxima neta es de  $840,000.00 m^3$ ) alcanzará su colapso físico absoluto durante el transcurso del año 2028. Específicamente, los resultados de la simulación muestran que al cierre del año 2026 se habrá consumido un acumulado de  $271,850 m^3$ , en 2027 se alcanzarán los  $556,868.60 m^3$ , y hacia el tercer trimestre del año 2028 la demanda geométrica acumulada llegará a los  $854,990 m^3$ , superando en un 1.78% el límite físico de diseño del recinto ( $840,000 m^3$ ) y provocando la saturación definitiva del vaso transitorio.

Es imperativo aclarar que, en el corto plazo, este desvío normativo otorga solo un año extra de operatividad a la actual celda transitoria de contingencia (retrasando su colapso inminente de 2028 a 2029). Sin embargo, a largo plazo, la reducción sistemática de toneladas de entrada genera un ahorro de terreno crítico de casi 2 millones de metros cúbicos, traducándose en una extensión de vida útil de 4.8 años aplicable directamente al diseño geométrico del nuevo complejo de tratamiento provincial, prolongando la operatividad del futuro sistema sanitario metropolitano más allá de su horizonte original. Este horizonte operativo de corto plazo evidencia un pasivo ambiental crítico que demanda atención inmediata: aun bajo el cumplimiento estricto del Escenario Optimista, la celda de contingencia transitoria IOARR continuará recibiendo más de 220,000 toneladas anuales de residuos crudos mezclados durante el periodo 2026–2029. La persistencia en el confinamiento de esta fracción húmeda no valorizada intensificará de forma inevitable la degradación anaerobia y la percolación de lixiviados con alta carga orgánica y metales pesados, sumado a la acumulación y migración descontrolada de biogás ( $\text{CH}_4$  y  $\text{CO}_2$ ). Considerando que la infraestructura opera sobre formaciones sedimentarias y quebradas de permeabilidad variable sin plantas de ósmosis o sistemas avanzados de reinyección, existe un riesgo inminente de migración subsuperficial y contaminación de acuíferos locales. Resulta técnico y normativamente imprescindible que la administración del relleno articule, en paralelo a la compactación física, un plan integral de monitoreo ambiental continuo que incluya la instalación inmediata de piezómetros de control hidrogeológico aguas arriba y aguas abajo de la celda transitoria, balances hidroquímicos estacionales de la balsa de lixiviados y el quemado o captura obligatoria de gases en antorchas para mitigar riesgos toxicológicos y de explosividad durante este periodo de transición.

**Figura 9**


*Curvas de agotamiento del volumen útil disponible en la celda transitoria según escenario de simulación (2026–2029)*



*Nota.* Elaboración Propia.

**Figura 10**

*Simulación de metros cúbicos (m³) de espacio geométrico liberado en el relleno provincial hacia el año 2041*



*Nota.* Elaboración Propia.

La modelación retrospectiva desarrollada en el Complejo Técnico de Boughareb en Constantine aporta un sustento analítico análogo al escenario arequipeño: en dicho recinto,

la persistencia de una gestión lineal inercial provocó la saturación absoluta de la infraestructura de emergencia en un periodo menor a los 3 años (2 años y 313 días), mientras que la implementación de un desvío selectivo orientado exclusivamente al reciclaje mecánico extendió la vida útil a más de 4 años, alcanzando su máximo rendimiento operativo bajo un escenario de compostaje centralizado que prolongó la funcionalidad del recinto por 5 años y 319 días (Soukehal & Bouadam, 2022). El extraordinario desempeño de la valorización biológica en dicha investigación radica en la composición intrínseca del flujo de entrada, el cual se encontraba fuertemente dominado por la fracción orgánica húmeda, una coincidencia metabólica exacta con el perfil biofísico de los distritos de la provincia de Arequipa, donde la materia orgánica representa hasta el 62% de la masa total recolectada en los polos periféricos de expansión urbana.

Esta relación directa entre la tipología del descarte y la ganancia geométrica de espacio útil queda ratificada por las evaluaciones desarrolladas en la región de Klaten, donde la introducción de un programa de compostaje para un flujo biodegradable del 48% generó un ahorro de volumen real de 136.99 m<sup>3</sup>/día, retrasando de forma sistemática la saturación de las celdas por un periodo neto de 712 días adicionales de operación (Ratnawati et al., 2022). De igual manera, análisis de sensibilidad ejecutados en metrópolis de alta densidad como Curitiba demuestran que transiciones agresivas en las metas de segregación en la fuente —elevando las tasas de desvío del 23% al 85%— poseen el potencial matemático de prolongar la expectativa de vida del relleno sanitario por casi tres décadas (Devendran et al., 2023).

La optimización espacial obtenida en el Escenario 3 de esta tesis —que proyecta una contracción en la demanda anual de celdas de entre el 28.6% y el 43%— coincide con los rangos de diseño internacional, donde autores como Etri et al. (2023) y Kafle et al. (2025) demuestran que el desvío selectivo de biodegradables y plásticos constituye la estrategia de mayor impacto para mitigar la huella territorial del confinamiento. En ese mismo sentido, Ermayendri et al. (2025) comprobaron que metas normativas ambiciosas en origen pueden reducir la necesidad de suelo fiscal para vertido en más del 85%, mientras que incrementos sostenidos de separación doméstica logran desviar anualmente decenas de miles de toneladas de descarte crudo hacia cadenas industriales (Shbool et al., 2025).

Por consiguiente, los resultados de la simulación trascienden el cálculo geométrico y aportan el respaldo técnico indispensable para la gestión sanitaria provincial. Como evidencian Valdivia-Espinoza y Guardia-Muguruza (2023), las ampliaciones marginales mediante IOARR resultan paliativas frente a una masa metropolitana desprovista de segregación técnica en origen. Para asegurar la operatividad del nuevo complejo sanitario proyectado con la Cooperación Alemana (KfW), resulta imperativo que los municipios articulen de manera obligatoria el Programa RECICLA con plantas de biorefinería (Brglez et al., 2025; Costa et al., 2025), maximizando la recuperación de recursos y minimizando externalidades socioambientales asociadas a lixiviados y emisiones de gases de efecto invernadero (Caro et al., 2023; Eid et al., 2026; Nordahl & Scown, 2024).

En este marco de reestructuración operativa, es indispensable abordar la dimensión sociolaboral del sistema de limpieza metropolitano. El modelo de simulación proyecta el desvío de hasta 773,430 toneladas acumuladas de plásticos y materiales secos hacia el año 2041 mediante el "Programa RECICLA"; sin embargo, dicho supuesto no debe concebirse bajo un esquema automatizado que desplace o ignore el rol histórico de los recicladores informales que operan en las calles y botaderos de la provincia. La literatura especializada enfatiza que excluir a este eslabón socioeconómico intensifica la precarización y genera conflictos sociales que truncan la eficiencia de captura en origen (Espinosa-Aquino et al., 2023; Ocaña Valencia & Vite Cevallos, 2021). Por el contrario, la transición ecoeficiente proyectada en este estudio se fundamenta estrictamente en la formalización e integración de las asociaciones de recicladores de base bajo el amparo de la Ley N° 29419 (Ley que regula la actividad de los recicladores) y el D.L. 1278. Esta formalización implica dotar a los recicladores de rutas exclusivas de recolección selectiva barrial, equipamiento de protección personal adecuado y personería jurídica para abastecer y operar las estaciones municipales de transferencia y las plantas de clasificación secundaria. De esta forma, el modelo matemático no desplaza mano de obra, sino que dignifica y reconvierte el reciclaje informal en empleo verde formalizado, incrementando las tasas netas de recuperación inorgánica y dotando de cohesión social al Escenario Optimista.

Para evitar la proliferación de áreas degradadas informales y blindar la sostenibilidad física del nuevo complejo de tratamiento de 236 millones de soles gestionado por el MINAM y la Cooperación Alemana (KfW), los gobiernos locales de la provincia deben reestructurar de forma imperativa sus cadenas de recolección selectiva, transformando el Programa RECICLA y la valorización biológica en procesos complementarios obligatorios (Brglez et al., 2025; Costa et al., 2025). La evaluación integral del sistema demuestra que el beneficio definitivo de esta transición circular no se limita a los años ganados de operación en Quebrada Honda, sino que se traduce en una drástica reducción en el inventario regional de emisiones de gases de efecto invernadero (GEI), menores costos sociales por enfermedades respiratorias periféricas y una efectiva recuperación de recursos secundarios aptos para reinsertarse de forma ecoeficiente en el mercado de la economía circular (Caro et al., 2023; Eid et al., 2026; Nordahl & Scown, 2024).

## CAPÍTULO V

### 5. CONCLUSIONES Y RECOMENDACIONES

#### 5.1. Conclusiones

- Se diagnosticó la evolución histórica (2018–2025) de la generación de residuos sólidos municipales en la provincia de Arequipa (355,362 t/año al año de cierre 2025), determinándose que la masa total recolectada está fuertemente traccionada por el crecimiento demográfico distrital ( $r = 0.991$ ;  $p < 0.01$ ), concentrándose la mayor presión en el polo periférico de Cerro Colorado (38,200 t/año). Asimismo, la Generación Per Cápita (*GPC*) domiciliaria responde directamente al nivel de ingresos del hogar ( $r = 0.932$ ;  $p < 0.01$ ), evidenciando asimetrías marcadas entre sectores de altos ingresos como Yanahuara (0.585 kg/hab/día) y sectores periféricos de menor capacidad adquisitiva como Paucarpata (0.474 kg/hab/día).
- Se formuló, calibró y validó con éxito el algoritmo computacional en Python estructurado en tres clústeres biofísicos para simular las tendencias de proyección de masa total y el desglose de materia orgánica (54.0%–62.0%) y plásticos poliméricos (8.5%–12.5%) para el periodo 2026–2041. El protocolo de validación estadística sobre el bloque testigo (*ex post facto*) demostró una alta fidelidad algorítmica ( $R^2 = 0.998$ ,  $MAE = 374.2$  t/año,  $RMSE = 437.8$  t/año), mientras que la validación cruzada ( $k$ -fold con  $k = 5$ ) y el gráfico de residuales confirmaron una distribución simétrica gaussiana del error, demostrando la ausencia de sesgos predictivos en el modelo.
- Se cuantificó matemáticamente que, bajo el Escenario 1: Pesimista (Inercial / Confinamiento Lineal), la celda transitoria de contingencia IOARR de Quebrada Honda (840,000.00 m<sup>3</sup>) colapsará por completo durante el año 2028 debido al enterramiento masivo de basura cruda. En contraste, la simulación del Escenario 3: Optimista (Ecoeficiente / Cumplimiento Normativo D.L. 1278) demuestra que el desvío progresivo de materia orgánica (42.5%) y plásticos poliméricos (37.5%) reduce la velocidad de llenado geométrico entre un 28.6% y un 43%, liberando un espacio acumulado no consumido de 1,997,517 m<sup>3</sup> al año 2041; este beneficio volumétrico retrasa el colapso de la celda transitoria hasta el año 2029 y le otorga a la administración provincial una extensión de vida útil técnica de 4.8 años adicionales para el nuevo complejo de tratamiento sanitario.

## 5.2.Recomendaciones

- Diseñar e implementar políticas públicas diferenciadas por clúster socioeconómico respaldadas por mecanismos vinculantes de incentivos presupuestales, incentivos ciudadanos y fiscalización sancionadora. Para viabilizar las metas de desvío del Escenario Optimista, se recomienda a las comunas distritales articularse de manera obligatoria al Programa de Incentivos a la Mejora de la Gestión Municipal del Ministerio de Economía y Finanzas (MEF), supeditando la captación de recursos adicionales al cumplimiento de las metas de recolección selectiva. Asimismo, se debe aprobar en ordenanza provincial un esquema de incentivos tributarios municipales que contemple descuentos porcentuales en los arbitrios de limpieza pública para los generadores domiciliarios y comerciales que participen activamente en la separación en origen. En el plano coercitivo, se deben fortalecer las facultades de fiscalización ambiental de las Entidades de Fiscalización Ambiental (EFA) locales y el OEFA, aplicando el régimen sancionador y las multas tipificadas en el Decreto Legislativo N° 1501 y la Ley N° 32212 a establecimientos comerciales, centros de abasto y administradores de predios que omitan la entrega segregada de sus descartes.
- Institucionalizar el script computacional en Python como una herramienta viva de gobernanza ambiental mediante un protocolo de recalibración anual a cargo de la MPA y el MINAM (SIGERSOL). Se recomienda a la Municipalidad Provincial de Arequipa, a través de la Subgerencia de Gestión Ambiental y en articulación técnica con la Dirección General de Gestión de Residuos Sólidos del MINAM, adoptar formalmente el modelo predictivo no como un reporte estático, sino como un instrumento continuo de planificación operativa. Para ello, se debe establecer por directiva provincial la obligación de actualizar anualmente los vectores de entrada del script (incorporando los registros consolidados de pesaje en balanza del SIGERSOL, los nuevos Estudios de Caracterización de Residuos Sólidos [ECSR] y las proyecciones intercensales del INEI). Este procedimiento permitirá recalibrar sistemáticamente los coeficientes de regresión y las matrices de composición física al cierre de cada periodo fiscal, dotando a la gestión provincial de un gemelo digital predictivo permanentemente ajustado a la realidad territorial de Arequipa.

- Transicionar de forma urgente del actual modelo inercial de confinamiento lineal hacia la ejecución y puesta en marcha del megaproyecto definitivo de inversión estatal de 236 millones de soles gestionado en articulación con la Cooperación Alemana (KfW). Se recomienda blindar la vida útil física de esta nueva infraestructura garantizando que el diseño de sus frentes de trabajo incorpore de manera obligatoria la construcción de un complejo tecnificado con plantas de biorefinería para el compostaje/digestión anaerobia de la materia orgánica hídrica desviada, así como líneas automatizadas de clasificación y reciclaje mecánico de alta densidad para las cadenas de polímeros plásticos, de acuerdo con los ratios geométricos de ahorro de terreno calculados en este estudio. Asimismo, la implementación operativa del nuevo complejo de valorización y las rutas del Programa RECICLA debe incorporar formalmente el Padrón Municipal de Recicladores de Base, en estricto cumplimiento de la Ley N° 29419. Se debe prohibir la tercerización que desplace a los recuperadores tradicionales; por el contrario, los gobiernos distritales deben financiar su formalización como microempresas ambientales o cooperativas de reciclaje, garantizándoles condiciones dignas de bioseguridad, salarios justos y prioridad en la operación de las plantas de clasificación secundaria y comercialización de polímeros.
- Desarrollar estudios complementarios de evaluación económica, análisis costo-beneficio (ACB) y viabilidad financiera multianual previo a la adjudicación e inversión en infraestructura de valorización. Se recomienda que la Municipalidad Provincial de Arequipa y el Ministerio del Ambiente elaboren los estudios de perfil socioeconómico y sensibilidad financiera bajo el marco del Invierte.pe para las plantas de compostaje, digestión anaerobia y clasificación de polímeros. Dicha modelación deberá internalizar los costos de capital (CAPEX), costos operativos y de mantenimiento (OPEX), tasas de recaudación de arbitrios y elasticidad de precios de mercado de los subproductos (compost, biogás y plástico molido), asegurando que los esquemas de economía circular propuestos sean económicamente autosostenibles y no generen desbalances fiscales en los presupuestos municipales.

- Establecer un programa de monitoreo ambiental y contingencia hidrogeológica intensiva para la celda transitoria IOARR durante el periodo operativo 2026–2029. Se recomienda a la Municipalidad Provincial de Arequipa (MPA) y al Organismo de Evaluación y Fiscalización Ambiental (OEFA) implementar de manera urgente una red perimetral de pozos y piezómetros de monitoreo de calidad del agua subterránea (con análisis trimestrales de DBO5, DQO, metales pesados y conductividad eléctrica), pozos de venteo y captación activa de biogás, y un sistema cerrado de recirculación o evaporación forzada de lixiviados. Dicha medida resulta prioritaria para salvaguardar la calidad ambiental del acuífero y el suelo colindante en la zona de Quebrada Honda mientras se consolida la transición hacia el nuevo complejo sanitario provincial.

## REFERENCIAS

- Abu-Qdais, H. A., Shatnawi, N., & Al-Shahrabi, R. (2023). Modeling the Impact of Fees and Circular Economy Options on the Financial Sustainability of the Solid Waste Management System in Jordan. Resources. <https://doi.org/10.3390/resources12030032>
- Adeleke, O., Akinlabi, S., Jen, T., & Dunmade, I. (2021). Application of artificial neural networks for predicting the physical composition of municipal solid waste: An assessment of the impact of seasonal variation. Waste Management & Research, 39, 1058 - 1068. <https://doi.org/10.1177/0734242x21991642>
- Agbebaku, H., Afolayan, O., Ojeifo, M., Okhae, E. S., & Abu, R. (2022). An Assessment of the Variability of Household Income on Volume of Waste Materials Generated in Benin City, Edo State, Nigeria. October 2022. <https://doi.org/10.36263/nijest.2022.02.0356>
- Alhathloul, N., Lakhout, A., Abdalla, G., Alghamdi, A., Shaban, M., Alshahir, A., Alshahr, S., Alali, I., & Alshammari, F. (2025). Assessing waste management using machine learning forecasting for sustainable development goal driven. Sustainability. <https://doi.org/10.3390/su17198654>
- Ali, S., Shoyaibur, M., Chowdhury, R., Hossain, S., Hasanuzzaman, M., Rabbi, R. E., Chowdhury, B. R., & Sohel, M. (2024). Global Plastic Waste Management: Analyzing Trends, Economic and Social Implications, and Predictive Modeling Using Artificial Intelligence. Journal of Environmental and Agricultural Studies. <https://doi.org/10.32996/jeas.2024.5.3.5>
- Al-Isawi, R. H. K., Idan, I., Hassan, A., Al-Zubaidi, H. A. M., & Al-Kulabi, N. (2021). Evaluation of the hydraulic conductivity for MSW using pilot plant test- A case study of Baghdad city/Iraq. IOP Conference Series: Earth and Environmental Science, 779. <https://doi.org/10.1088/1755-1315/779/1/012081>
- Anteneh, Y. A., & Tolasa, D. (2025). Household Solid Waste Generation Rate and Physical Composition Analysis in Case of Assosa Town, Benishangul Gumuz Regional State, Ethiopia. International Journal of Advanced Research and Interdisciplinary Scientific Endeavours. <https://doi.org/10.61359/11.2206-2530>

- Azma, A., Borthwick, A., Ahmadian, R., Liu, Y., & Zhang, D. (2025). Modeling the discharge coefficient of labyrinth sluice gates using hybrid support vector regression and metaheuristic algorithms. *Physics of Fluids*. <https://doi.org/10.1063/5.0260738>
- Baziar, M., Yousefi, M., Oskoei, V., Makhdoomi, A., Abdollahzadeh, R., & Dehghan, A. (2025). Machine learning-based prediction of heating values in municipal solid waste. *Scientific Reports*, 15. <https://doi.org/10.1038/s41598-025-99432-8>
- Bendiuh, V., Markina, L., Matsai, N., Kyrpychova, I., Boichenko, S., Priadko, S., Shkilniuk, I., Komarysta, B., Yermakovych, I., & Vlasenko, O. (2023). Integrated method for planning waste management based on the material flow analysis and life cycle assessment. *Eastern-European Journal of Enterprise Technologies*. <https://doi.org/10.15587/1729-4061.2023.273930>
- Billal, M., & Kumar, A. (2025). Forecasting residential and nonresidential solid waste generation, disposal, and diversion using three machine learning approaches. *Biofuels*, 19. <https://doi.org/10.1002/bbb.70010>
- Birgen, C., Grytli, T., & Becidan, M. (2024). Scenario analysis tool for estimating future waste composition and amounts toward a circular economy. *Journal of Material Cycles and Waste Management*, 26, 2724 - 2740. <https://doi.org/10.1007/s10163-024-01992-w>
- Brglez, K., Lukman, R. K., & Gumzej, R. (2025). Zero waste initiatives in Slovenian municipalities: A material flow and life cycle assessment analyses. *Cleaner Engineering and Technology*. <https://doi.org/10.1016/j.clet.2025.101120>
- Caro, D., Lodato, C., Damgaard, A., Cristóbal, J., Foster, G., Flachenecker, F., & Tonini, D. (2023). Environmental and socio-economic effects of construction and demolition waste recycling in the European Union.. *The Science of the total environment*, 168295. <https://doi.org/10.1016/j.scitotenv.2023.168295>
- Cavalheiro, E. A., Machado, R. H., Castro, A., & Falck, L. R. (2024). Urban solid waste generation and GDP per capita: a global analysis through the lens of the environmental Kuznets curve. *CONTRIBUCIONES A LAS CIENCIAS SOCIALES*. <https://doi.org/10.55905/revconv.17n.3-012>

- Chau, K., Moslehpour, M., Pan, S., & Akhundzada, A. (2025). Advanced predictive modeling of municipal solid waste management using robust machine learning. *Scientific Reports*, 15. <https://doi.org/10.1038/s41598-025-27237-w>
- Cheng, Y., Ekici, E., Yildiz, G., Yang, Y., Coward, B., & Wang, J. (2023). Applied machine learning for prediction of waste plastic pyrolysis towards valuable fuel and chemicals production. *Journal of Analytical and Applied Pyrolysis*. <https://doi.org/10.1016/j.jaap.2023.105857>
- Chicco, D., Warrens, M., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7. <https://doi.org/10.7717/peerj-cs.623>
- Costa, E., Oshita, K., & Takaoka, M. (2025). Municipal solid waste management in Portugal using material flow analysis: regional assessment. *Journal of Material Cycles and Waste Management*, 27, 3238 - 3251. <https://doi.org/10.1007/s10163-025-02279-4>
- Culi, M. (2025). Propuesta de estrategias de gestión de residuos sólidos en la ciudad de Santa Ana, El Salvador. *Revista Científica de Ingenierías y Arquitectura*, 4(1). <https://doi.org/10.56643/rcia.v4i1.185>
- D'Adamo, I., Daraio, C., Di Leo, S., Gastaldi, M., & Rossi, E. N. (2024). Driving EU sustainability: Promoting the circular economy through municipal waste efficiency. *Sustainable Production and Consumption*. <https://doi.org/10.1016/j.spc.2024.08.022>
- Da Silva Júnior, C. G., Vieira, Z. C., Santos, E. M. C. D., Barros, W. L. D. S., & Hussain, A. L. M. (2024). Correlation between waste generation, population and GDP of cities in Sergipe, Brazil. *REVISTA INTERDISCIPLINAR E DO MEIO AMBIENTE (RIMA)*. <https://doi.org/10.52664/rima.v6.n1.2024.e230>
- Dang, M., Chai, J., Xu, Z., & Qin, Y. (2022). Soil Water Characteristic Curve Test of Waste under Different Compaction Densities and Analysis of the Multi-Factors that Affect the Instability of Landfill Slopes. *Polish Journal of Environmental Studies*. <https://doi.org/10.15244/pjoes/142610>
- Das, M., Deb, C. K., Pal, R., & Marwaha, S. (2022). A Machine Learning Approach for the Non-Destructive Estimation of Leaf Area in Medicinal Orchid *Dendrobium nobile* L.. *Applied Sciences*. <https://doi.org/10.3390/app12094770>

- Dawar, I., Srivastava, A., Singal, M., Dhyani, N., & Rastogi, S. (2025). A systematic literature review on municipal solid waste management using machine learning and deep learning. *Artificial Intelligence Review*, 58. <https://doi.org/10.1007/s10462-025-11196-9>
- De La Cruz Cabrera, V., Cantón, R., Garibaldi, Y., & Ortega, V. (2021). Áreas naturales en zonas costeras, espacios en riesgo por disposición final de residuos sólidos de la comunidad de Gobeá. *Revista Saberes APUDEP*, 4(1), 68–83. <https://doi.org/10.48204/j.saberes.v4n1a5>
- Devendran, A., Mainali, B., Khatiwada, D., Golzar, F., Mahapatra, K., & Toigo, C. H. (2023). Optimization of Municipal Waste Streams in Achieving Urban Circularity in the City of Curitiba, Brazil. *Sustainability*. <https://doi.org/10.3390/su15043252>
- Di Foggia, G., & Beccarello, M. (2023). Designing circular economy-compliant municipal solid waste management charging schemes. *Utilities Policy*. <https://doi.org/10.1016/j.jup.2023.101506>
- Domingues, N. (2025). Energy Production from Landfill Gas: Short-Term Management. *Energies*. <https://doi.org/10.3390/en18081974>
- Eid, M., Albizzati, P. F., Dolci, G., Rigamonti, L., Tonini, D., & Grosso, M. (2026). Unlocking value from residual municipal waste: A primary data analysis of recovery rates and costs.. *Waste management*, 216, 115472. <https://doi.org/10.1016/j.wasman.2026.115472>
- Elshaboury, N., Abdelkader, E., Alfalah, G., & Al-Sakkaf, A. (2021). Predictive analysis of municipal solid waste generation using an optimized neural network model. *Processes*, 9(11). <https://doi.org/10.3390/pr9112045>
- Ermayendri, D., Simarmata, M., Arianto, W., Reflis, R., Riwandi, R., & Sukiyono, K. (2025). Dynamic Integrated Model for Sustainable Solid Waste Management in Bengkulu City. *Environment and Natural Resources Journal*. <https://doi.org/10.32526/ennrj/23/20250048>
- Esparza, J. (2021). Clasificación y afectación por residuos sólidos urbanos en la ciudad de La Plata, Buenos Aires, Argentina. *Revista Internacional de Contaminación Ambiental*, 37, 357-371. <https://doi.org/10.20937/rica.53758>

- Espinosa-Aquino, B., Durany, X. G., & Vargas, R. Q. (2023). The Role of Informal Waste Management in Urban Metabolism: A Review of Eight Latin American Countries. Sustainability. <https://doi.org/10.3390/su15031826>
- Etri, T., Samsami, O. A., & Baawain, M. (2023). Characterization of landfills solid waste in Muscat and estimation of their energy recovery. Environmental Science and Pollution Research, 30, 104901-104915. <https://doi.org/10.1007/s11356-023-29611-5>
- Fontaine, L., Legros, R., & Frayret, J. (2024). Solid waste generation prediction model framework using socioeconomic and demographic factors with real-time MSW collection data. Waste Management & Research, 43, 267-281. <https://doi.org/10.1177/0734242x241231414>
- Frimpong, A., Mensah, L., Rockson, M., & Kemausuor, F. (2025). Forecasting municipal solid waste generation and composition using machine learning and GIS techniques: A case study of Cape Coast, Ghana. Cleaner Waste Systems. <https://doi.org/10.1016/j.clwas.2025.100218>
- Gebremariam, H. G., Taye, S., & Tarekegn, A. (2026). Compressive strength prediction of carbonated recycled aggregate concrete using regression based machine learning models. Scientific Reports, 16. <https://doi.org/10.1038/s41598-026-36197-8>
- Gonçalves, T. (2021). Peer Review #1 of "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation (v0.2)". PeerJ. <https://doi.org/10.7287/peerj-cs.623v0.2/reviews/1>
- González-Jiménez, Y., & Villalobos-Morales, J. (2021). Manejo ambiental de residuos orgánicos. Tecnología en Marcha, 34(2). <https://doi.org/10.18845/tm.v34i2.4843>
- Gudeta, T., Mamo, G., & Neguse, Y. (2025). Municipal solid waste management using machine learning: A case study in Sheger City, Koye sub-city, Ethiopia. European Journal of Theoretical and Applied Sciences, 3(2), 42. [https://doi.org/10.59324/ejtas.2025.3\(2\).42](https://doi.org/10.59324/ejtas.2025.3(2).42)

- Hasan, M., Tarequzzaman, M., Moznuzzaman, M., & Juel, M. A. A. (2025). Prediction of energy consumption in four sectors using support vector regression optimized with genetic algorithm. *Heliyon*, 11. <https://doi.org/10.1016/j.heliyon.2025.e41765>
- He, R., Sandoval-Reyes, M., Scott, I., Semeano, R., Ferrão, P., Matthews, S., & Small, M. (2022). Global knowledge base for municipal solid waste management: Framework development and application in waste generation prediction. *Journal of Cleaner Production*. <https://doi.org/10.1016/j.jclepro.2022.134501>
- Hidalgo-Crespo, J., Velástegui-Montoya, A., Soto, M., Rivas, J. A. L., Zwolinski, P., Riel, A., & Rivas-García, P. (2024). Improving urban waste management: A comprehensive study on household waste generation and spatial patterns in the Grand Guayaquil Metropolitan Area. *Waste Management & Research*, 42, 918 - 931. <https://doi.org/10.1177/0734242x241262714>
- Hodson, T. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. *Geoscientific Model Development*. <https://doi.org/10.5194/gmd-15-5481-2022>
- Hoque, M., & Rahman, M. (2020). Landfill area estimation based on solid waste collection prediction using ANN model and final waste disposal options. *Journal of Cleaner Production*, 256, 120387. <https://doi.org/10.1016/j.jclepro.2020.120387>
- Istrate, I., Gálvez-Martos, J.-L., & Dufour, J. (2021). A Life Cycle-Based Scenario Analysis Framework for Municipal Solid Waste Management. Towards a Sustainable Future - Life Cycle Management. [https://doi.org/10.1007/978-3-030-77127-0\\_20](https://doi.org/10.1007/978-3-030-77127-0_20)
- Jalalipour, H., Morscheck, G., Schwetje, A., & Nelles, M. (2025). Sustainable solid waste management: The German case and lessons for South America. *Waste Management & Research*, 43, 1476 - 1490. <https://doi.org/10.1177/0734242x251364644>
- Janga, J., & Reddy, K. (2025). Data-driven prediction of landfill stabilization period using interpretable machine learning. *Computers and Geotechnics*. <https://doi.org/10.1016/j.compgeo.2025.107202>
- Jayaraman, V., Lakshminarayanan, A., Parthasarathy, S., & Suganthi, A. (2023). Forecasting the municipal solid waste using GSO-XGBoost model. *Intelligent*

Joy, M. A., Miah, M., Nirob, N. C., & Hassan, M. (2025). Solid Waste Disposal and Management System in Netrokona Sadar Municipality Area of Netrokona District. *Journal of Environmental Science and Natural Resources*.  
<https://doi.org/10.3329/jesnr.v14i1.81098>

Kafle, S., Karki, B. K., Sakhakarmy, M., & Adhikari, S. (2025). A Review of Global Municipal Solid Waste Management and Valorization Pathways. *Recycling*.  
<https://doi.org/10.3390/recycling10030113>

Karimi, S., Bareither, C., & Scalia, J. (2023). A critical review of municipal solid waste hydraulic conductivity: A mini review. *Waste Management & Research*, 42, 997 - 1007. <https://doi.org/10.1177/0734242x231204814>

Karutz, R., Klassert, C., & Kabisch, S. (2023). On Farmland and Floodplains—Modeling Urban Growth Impacts Based on Global Population Scenarios in Pune, India. *Land*.  
<https://doi.org/10.3390/land12051051>

Khan, M. A., Khan, R., Algarni, F., Kumar, I., Choudhary, A., & Srivastava, A. (2021). Performance evaluation of regression models for COVID-19: A statistical and predictive perspective. *Ain Shams Engineering Journal*, 13, 101574 - 101574.  
<https://doi.org/10.1016/j.asej.2021.08.016>

Kii, M. (2021). Projecting future populations of urban agglomerations around the world and through the 21st century. *npj Urban Sustainability*, 1, 1-12.  
<https://doi.org/10.1038/s42949-020-00007-5>

Lamborn, J. (2024). Characterisation of municipal solid waste composition into model inputs. *Waste Management & Research*, 42(3), 215–224.  
[https://www.researchgate.net/publication/228507204\\_Characterisation\\_of\\_municipal\\_solid\\_waste\\_composition\\_into\\_model\\_inputs](https://www.researchgate.net/publication/228507204_Characterisation_of_municipal_solid_waste_composition_into_model_inputs)

Li, X., Ghods, M., Kheirkhahan, N., & Shafi, J. (2025). M-polynomial driven machine learning models for predicting physicochemical properties of antibiotics. *PLOS One*, 20, e0338093 - e0338093. <https://doi.org/10.1371/journal.pone.0338093>

- Liu, X., Zhi, W., & Akhundzada, A. (2025). Enhancing performance prediction of municipal solid waste generation: A strategic management. *Frontiers in Environmental Science*. <https://doi.org/10.3389/fenvs.2025.1553121>
- Lu, M., Zhou, C., Wang, C., Jackson, R., & Kempes, C. P. (2022). Worldwide scaling of waste generation in urban systems. *Nature Cities*, 1, 126 - 135. <https://doi.org/10.1038/s44284-023-00021-5>
- Lu, S., & Feng, S. (2020). Comprehensive overview of numerical modeling of coupled landfill processes. *Waste Management*, 118, 161-179. <https://doi.org/10.1016/j.wasman.2020.08.029>
- Mahmoudzadeh, H., Abedini, A., & Aram, F. (2022). Urban Growth Modeling and Land-Use/Land-Cover Change Analysis in a Metropolitan Area (Case Study: Tabriz). *Land*. <https://doi.org/10.3390/land11122162>
- Maqui, M., Pinedo, C., Rojas, J., Fernández, G., & Puscan, M. (2021). Valoración económica para el adecuado manejo de residuos sólidos municipales: Una revisión sistemática entre los años 2010-2020. The 1st LACCEI International Multi-Conference on Entrepreneurship, Innovation, and Regional Development. <https://doi.org/10.18687/leird2021.1.1.31>
- Medina-Mijangos, R. A., & Seguí-Amortegui, L. (2021). The economic assessment of the environmental and social impacts generated by a light packaging and bulky waste sorting and treatment facility: a circular economy example. *Environmental Sciences Europe*, 33(1), 78. <https://doi.org/10.1186/s12302-021-00517-w>
- Mesta, C., Cremen, G., & Galasso, C. (2022). Urban growth modelling and social vulnerability assessment for a hazardous Kathmandu Valley. *Scientific Reports*, 12. <https://doi.org/10.1038/s41598-022-09347-x>
- Mhangara, P., Gidey, E., & Mayise, B. S. (2025). Using extreme gradient boosting for predictive urban expansion analysis in Rustenburg, South Africa from 2000 to 2030. *Scientific Reports*, 15. <https://doi.org/10.1038/s41598-025-04304-w>
- Monrroy, R., Quila, K., Cedeño, C., Arellano, J., & Monrroy, D. (2025). Biodigestores como recurso didáctico para fomentar el aprendizaje de la gestión ambiental de residuos

- orgánicos en la Unidad Educativa San Carlos, Ecuador. *Revista Multidisciplinar Epistemología de las Ciencias*. <https://doi.org/10.71112/z2de9631>
- Mousania, Z., Rafiee, R., Moeinaddini, M., & Atkinson, J. D. (2024). Anaerobic digestion of the organic fraction of municipal solid waste in a simulated bioreactor to improve predictive modeling of landfill systems. *Journal of Hazardous Materials Advances*. <https://doi.org/10.1016/j.hazadv.2023.100396>
- Mudannayake, O., Rathnayake, D., Herath, J., Fernando, D., & Fernando, M. (2022). Exploring machine learning and deep learning approaches for multi-step forecasting in municipal solid waste generation. *IEEE Access*, 10, 122570-122585. <https://doi.org/10.1109/access.2022.3221941>
- Namoune, A., Hussein, B., Tufail, A., Alrehaili, A., Syed, T., & Benrhouma, O. (2022). An ensemble learning based classification approach for the prediction of household solid waste generation. *Sensors*, 22(9). <https://doi.org/10.3390/s22093506>
- Nell, C., Schenck, C. J., & De Waal, J. H. (2022). Waste characterisation in Stellenbosch Local Municipality, South Africa. *South African Journal of Science*. <https://doi.org/10.17159/sajs.2022/12795>
- Ng, K. S., & Yang, A. (2022). Development of a system model to predict flows and performance of regional waste management planning: A case study of England.. *Journal of environmental management*, 325 Pt B, 116585. <https://doi.org/10.1016/j.jenvman.2022.116585>
- Nguyen, X., Nguyen, T., La, D., Kumar, G., Kumar, G., Rene, E., Nguyen, D., Chang, S., Chung, W., Nguyen, X., & Nguyen, V. (2021). Development of machine learning - based models to forecast solid waste generation in residential areas: A case study from Vietnam. *Resources, Conservation and Recycling*, 167. <https://doi.org/10.1016/j.resconrec.2020.105381>
- Noman, A., Rafizul, I. M., Moniruzzaman, S., Kraft, E., & Berner, S. (2023). Assessment of municipal solid waste from households in Khulna city of Bangladesh. *Heliyon*, 9. <https://doi.org/10.1016/j.heliyon.2023.e22446>

- Nordahl, S. L., & Scown, C. (2024). Recommendations for life-cycle assessment of recyclable plastics in a circular economy. *Chemical Science*, 15, 9397 - 9407. <https://doi.org/10.1039/d4sc01340a>
- Ocaña Valencia, V. A., & Vite Cevallos, H. (2021). Oportunidades socioeconómicas de la gestión y caracterización de residuos sólidos en centros de abasto municipales. *Revista Metropolitana de Ciencias Aplicadas*, 4(1), 143-149. <https://doi.org/10.62452/30c1pe97>
- Ochoa-Barragán, R., Del Carmen Munguía-López, A., & Ponce-Ortega, J. (2023). A hybrid machine learning-mathematical programming optimization approach for municipal solid waste management during the pandemic. *Environment, Development and Sustainability*, 1-20. <https://doi.org/10.1007/s10668-023-03354-2>
- Ortiz-Alvarez, C., Rodríguez-Morales, E., Rubio-López, O., & Martínez-Hernández, A. L. (2026). Microplásticos en el medio ambiente y separadores ciclónicos como alternativa de mitigación. Una revisión. *Tendencias en Energías Renovables y Sustentabilidad*, 5(1), 119-129. <https://doi.org/10.56845/terys.v5i1.505>
- Özkan, A., Özkan, K., Işık, Ş., & Banar, M. (2021). Evaluation of different curve fitting models for prediction of municipal solid waste composition. *Pamukkale University Journal of Engineering Sciences*. <https://doi.org/10.5505/pajes.2020.08377>
- Padilla-Vento, J., & Soria, J. (2025). Statistical approach for the evaluation of household solid waste generation in Peruvian households: 2014-2021. *Frontiers in Applied Mathematics and Statistics*, 11. <https://doi.org/10.3389/fams.2025.1498513>
- Pantić, J. J., Rakić, D., Ikodinović, I. B., Djurić, T., & Hadži-Niković, G. (2022). Geotechnical Effects of Municipal Solid Waste Destruction with Different Compaction Methods. *Proceedings of the Bulgarian Academy of Sciences*. <https://doi.org/10.7546/crabs.2022.01.13>
- Pillai, K., L, S., S, A., Anand, A., & Prasad, G. (2023). Municipal solid waste management: A review of machine learning applications. *E3S Web of Conferences*, 455. <https://doi.org/10.1051/e3sconf/202345502018>
- Poma, P., Polanco, M., Usca, K., Casella, C., & Toulkeridis, T. (2025). An evaluation of the public service of the integrated municipal management of urban solid waste in the

- Galapagos and the Amazonian region of Ecuador. *Sustainability*, 17(3). <https://doi.org/10.3390/s17031066>
- Ponce-Ponce, G. V., & Salvatierra-Pilozo, D. M. (2025). Indicadores de gestión integral de residuos sólidos en el centro de faenamiento municipal de Portoviejo. *Innova Science Journal*, 3(3), 97-109. <https://doi.org/10.63618/omd/isj/v3/n3/71>
- Popli, K., Park, C., Han, S., & Kim, S. (2021). Prediction of solid waste generation rates in urban region of Laos using socio-demographic and economic parameters with a multi linear regression approach. *Sustainability*, 13(6). <https://doi.org/10.3390/su13063038>
- Portugheis, A., & Wahlberg, F. (2024). Gestión integral de residuos de la administración pública - Provincia de Buenos Aires: El programa G.I.R.A analizado desde el ciclo de las políticas públicas (2020 a 2024). *Revista Estudios Ambientales*, 12(2). <https://doi.org/10.47069/estudios-ambientales.v12i2.2825>
- Pour, N. M., & Oja, T. (2021). Urban Expansion Simulated by Integrated Cellular Automata and Agent-Based Models; An Example of Tallinn, Estonia. *Urban Science*. <https://doi.org/10.3390/urbansci5040085>
- Priyanka, E., Vijayashanthi, S., Thangavel, S., Anand, R., Bhavana, G., Khan, B., Jeyanthi, K., & Ambikapathy, A. (2025). Prediction of waste generation forecast and emission potential on the Erode City solid waste dump yards based on machine learning approach. *Scientific Reports*, 15. <https://doi.org/10.1038/s41598-025-19288-w>
- Raghavendran, C., Mouli, K., Latha, S. B., & Motagi, A. U. (2026). A lightweight neural network approach for predicting national Gross Domestic Product (LightNet-GDP) with regression benchmarks. *Scientific Reports*, 16. <https://doi.org/10.1038/s41598-026-37672-y>
- Ramírez, C. (2025). Gestión de residuos sólidos domiciliarios y la calidad ambiental en el distrito de Jesús María, Lima, Perú 2024. *Arandu UTIC*, 12(2). <https://doi.org/10.69639/arandu.v12i2.1102>
- Ratnawati, B., Yani, M., S., & Hardjomijojo, H. (2022). Study of Remaining Service Life of a Municipal Solid Waste Landfill with the Composting Method: A Case Study in

- Klaten Regency. IOP Conference Series: Earth and Environmental Science, 950.  
<https://doi.org/10.1088/1755-1315/950/1/012027>
- Reflis, R., Jodder, P., Leya, R. S., Rana, M. S., & Sarkar, B. (2022). GENERATION AND CHARACTERISTICS OF HOUSEHOLD SOLID WASTE IN KHULNA CITY, BANGLADESH. Khulna University Studies.  
<https://doi.org/10.53808/kus.2022.19.01.2202-se>
- Rodríguez, R., & Castro, J. (2023). Gestión integral de residuos en plazas de mercado: Un enfoque para la investigación y el desarrollo sostenible. Publicaciones e Investigación, 17. <https://doi.org/10.22490/25394088.7431>
- Rosas-Prado, C. E., Cárdenas, M. F. U., Rodríguez, H. E., & Reyes, C. A R. (2021). Manejo integral de los residuos sólidos para mejorar la salud pública del distrito José Leonardo Ortiz, Chiclayo, 2019. Revista de la Universidad del Zulia, 12(32), 175-189. <https://doi.org/10.46925/rdluz.32.13>
- Saganeiti, L., Mustafa, A. M., Teller, J., & Murgante, B. (2021). Modeling urban sprinkling with cellular automata. Sustainable Cities and Society. <https://doi.org/10.1016/j.scs.2020.102586>
- Sánchez-Romero, F. E., & Recalde-Gracey, A. E. (2024). Gestión de residuos sólidos municipales 2021-2023: Revisión sistemática. Gestio et Productio. Revista Electrónica de Ciencias Gerenciales, 6(11), 246-255.  
<https://doi.org/10.35381/gep.v6i11.187>
- Sardarmehni, M., Anchieta, P., & Levis, J. (2022). Solid waste optimization life-cycle framework in Python (SwolfPy). Journal of Industrial Ecology, 26, 748-762.  
<https://doi.org/10.1111/jiec.13236>
- Selvia, S., Iemaniiah, Z. M., Dewi, R. A. S., Maftuh, M., Akbar, S., & Siddiqirly, M. (2023). Estimasi Kapasitas Daya Tampung Landfill dan Umur Pakai TPA Gili Trawangan. JURNAL SAINS TEKNOLOGI & LINGKUNGAN.  
<https://doi.org/10.29303/jstl.v9i4.524>
- Shbool, M. A., Al-Bazi, A., Jebril, L. S., Nasrallah, N. M., Al-Amad, S. A., & Al-Souliman, B. O. (2025). Promoting sustainability in Urban waste management in Amman for a

- circular economy. *Journal of Material Cycles and Waste Management*, 28, 176 - 198.  
<https://doi.org/10.1007/s10163-025-02405-2>
- Shekoohiyan, S., Hadadian, M., Heidari, M., & Hosseinzadeh-Bandbafha, H. (2023). Life cycle assessment of Tehran municipal solid waste during the COVID-19 pandemic and environmental impacts prediction using machine learning. *Case Studies in Chemical and Environmental Engineering*, 7, 100331.  
<https://doi.org/10.1016/j.cscee.2023.100331>
- Siddiqua, A., Hahladakis, J., & Al-Attiya, W. A. K. (2022). An overview of the environmental pollution and health effects associated with waste landfilling and open dumping. *Environmental Science and Pollution Research International*, 29, 58514 - 58536. <https://doi.org/10.1007/s11356-022-21578-z>
- Singh, T., & Uppaluri, R. (2022). Machine learning tool-based prediction and forecasting of municipal solid waste generation rate: A case study in Guwahati, Assam, India. *International Journal of Environmental Science and Technology*, 20, 12207-12230.  
<https://doi.org/10.1007/s13762-022-04644-4>
- Soukehal, I., & Bouadam, R. (2022). THE IMPACT OF LANDFILL DIVERSION ON LAND USE AND LIFESPAN: A CASE STUDY OF THE BOUGHAREB TECHNICAL LANDFILL CENTRE IN CONSTANTINE, ALGERIA. *Analele Universității din Oradea, Seria Geografie*. <https://doi.org/10.30892/auog.322101-884>
- Starostina, V., & Christensen, T. H. (2022). Life-cycle assessment for municipal waste management systems. *XXI Century. Technosphere Safety*.  
<https://doi.org/10.21285/2500-1582-2022-2-142-150>
- Suárez, I., Ruíz, O., Muñoz, P., & Ventura, I. (2025). Valoración económica ambiental de la gestión integral de residuos sólidos urbanos en Bambamarca, Perú. *Gestionar: Revista de Empresa y Gobierno*, 5(3). <https://doi.org/10.35622/j.rg.2025.03.002>
- Thaiprayoon, C., Kongson, J., & Sudsutad, W. (2025). Dynamics of a fractal-fractional mathematical model for the management of waste plastic in the ocean with four different numerical approaches. *AIMS Mathematics*.  
<https://doi.org/10.3934/math.2025405>

- Tsagkis, P. (2022). Urban growth models and calibration methods: a case study of Athens, Greece. *Bulletin of Geography. Socio-economic Series*.  
<https://doi.org/10.12775/bgss-2022-0008>
- Valdivia-Espinoza, A., & Guardia-Muguruza, X. (2023). Valorización energética de residuos orgánicos: El vínculo entre la política energética y la gestión integral de residuos sólidos. *South Sustainability*, 4(1). <https://doi.org/10.21142/ss-0401-2023-e074>
- Vardhan, B. V. S., Khedkar, M., Srivastava, I., Thakre, P., & Bokde, N. (2023). A Comparative Analysis of Hyperparameter Tuned Stochastic Short Term Load Forecasting for Power System Operator. *Energies*.  
<https://doi.org/10.3390/en16031243>
- Vargas-Terranova, C.-A., Rodrigo-Illarri, J., Rodrigo-Clavero, M., & Rozo-Arango, M.-A. (2022). M-GRCT: A Dynamic Circular Economy Model for the Optimal Design of Waste Management Systems in Low-Income Municipalities. *International Journal of Environmental Research and Public Health*, 19.  
<https://doi.org/10.3390/ijerph19052681>
- Vargas-Terranova, C.-A., Rodrigo-Illarri, J., Rodrigo-Clavero, M., & Parra-Saad, A. (2022). Implementing Circular Economy Techniques for the Optimal Management of Recyclable Solid Waste Using the M-GRCT Decision Support Model. *Applied Sciences*. <https://doi.org/10.3390/app12168072>
- Vega, D. I., & Bautista-Rodríguez, S. (2024). The Impact of Circular Economy Strategies on Municipal Waste Management: A System Dynamics approach. *Cleaner Engineering and Technology*. <https://doi.org/10.1016/j.clet.2024.100761>
- Vera, M., Pirola, M., Romanatti, M., Diez, S., Franco, F., & Paris, M. (2025). Gestión de residuos sólidos en instituciones públicas. Caso: Facultad de Ingeniería y Ciencias Hídricas (UNL). *Revista Estudios Ambientales*, 13(2).  
<https://doi.org/10.47069/estudios-ambientales.v13i2.3110>
- Vu, H., Ng, K. T. W., Richter, A., Karimi, N., & Kabir, G. (2021). Modeling of municipal waste disposal rates during COVID-19 using separated waste fraction models. *The Science of the Total Environment*, 789, 148024 - 148024.  
<https://doi.org/10.1016/j.scitotenv.2021.148024>

- Wei, X., Liang, S., & Diao, W. (2026). Prediction of athlete performance based on a gradient regression model. *Scientific Reports*, 16. <https://doi.org/10.1038/s41598-026-40117-1>
- Wilujeng, S. (2025). Estimating municipal solid waste using linear regression modelling at MRF South Jakarta. *International Journal of Multidisciplinary Research and Analysis*, 8(6). <https://doi.org/10.47191/ijmra/v8-i06-49>
- Xia, C., & Zhang, B. (2021). Exploring the effects of partitioned transition rules upon urban growth simulation in a megacity region: a comparative study of cellular automata-based models in the Greater Wuhan Area. *GIScience & Remote Sensing*, 58, 693 - 716. <https://doi.org/10.1080/15481603.2021.1933714>
- Xia, W., Jiang, Y., Chen, X., & Zhao, R. (2021). Application of machine learning algorithms in municipal solid waste management: A mini review. *Waste Management & Research*, 40, 609-624. <https://doi.org/10.1177/0734242x211033716>
- Ya, X., Guangyuan, Y., Yuqiang, L., Jingcai, L., Rui, X., & Can, Q. (2023). Theory, framework, and methodology for physical lifespan prediction of hazardous waste landfills. *The Science of the Total Environment*, 163154. <https://doi.org/10.1016/j.scitotenv.2023.163154>
- Yaagoubi, R., Lakber, C.-E., & Miky, Y. H. (2024). A comparative analysis on the use of a cellular automata Markov chain versus a convolutional LSTM model in forecasting urban growth using sentinel 2A images. *Journal of Land Use Science*, 19, 258 - 277. <https://doi.org/10.1080/1747423x.2024.2403789>
- Yactayo-Flores, A., Cruz, A., & Reyes-Mandujano, I. (2025). Agrupamiento de los distritos de la provincia de Lima, Perú, por similitud en los niveles de residuos sólidos (orgánicos e inorgánicos) domiciliarios aprovechables. *Revista Kawsaypacha: Sociedad y Medio Ambiente*, (15). <https://doi.org/10.18800/kawsaypacha.202502.d010>
- Yang, L., Zhao, Y., Niu, X., Song, Z., Gao, Q., & Wu, J. (2021). Municipal solid waste forecasting in China based on machine learning models. *Frontiers in Energy Research*, 9. <https://doi.org/10.3389/fenrg.2021.763977>

- Younes, M., Nopiah, Z., Basri, N., Basri, H., Abushammala, M., & Younes, M. (2016). Landfill area estimation based on integrated waste disposal options and solid waste forecasting using modified ANFIS model. *Waste Management*, 55, 3-11. <https://doi.org/10.1016/j.wasman.2015.10.020>
- Yu, Z., Liu, X., Yu, J.-U., & Okubo, K. (2025). Social factors influencing the household solid waste generation and recycling rate in urban areas of Japan. *Environmental Research Letters*, 20. <https://doi.org/10.1088/1748-9326/adb97d>



## ANEXOS

### Anexo 1. Código Fuente del Modelo Predictivo en Python

#### 1.1. Módulo de extracción, imputación lineal y depuración de datos

```
import pandas as pd
import numpy as np
from sklearn.preprocessing import MinMaxScaler

def cargar_y_depurar_datos(ruta_archivo):
    """
    Función para cargar la matriz del SIGESOL, identificar valores atípicos
    y aplicar interpolación matemática para subsanar omisiones temporales.
    """
    # 1. Carga de la matriz maestra en formato DataFrame
    try:
        df_sigesol = pd.read_excel(ruta_archivo, sheet_name='Generacion_Historica_2018_2025')
        print("Datos de Arequipa metropolitana cargados exitosamente.")
    except Exception as e:
        print(f"Error en la lectura del archivo: {e}")
        return None

    # 2. Imputación de datos faltantes mediante interpolación lineal (Series de tiempo)
    # Se aplica a lo largo de las columnas anuales para mantener la tendencia
    columnas_temporales = ['2018', '2019', '2020', '2021', '2022', '2023', '2024', '2025']
    df_sigesol[columnas_temporales] = df_sigesol[columnas_temporales].interpolate(method='linear', axis=1)

    # 3. Tratamiento de valores atípicos (Rango Inter cuartílico - IQR)
    Q1 = df_sigesol[columnas_temporales].quantile(0.25)
    Q3 = df_sigesol[columnas_temporales].quantile(0.75)
    IQR = Q3 - Q1
    limite_inferior = Q1 - 1.5 * IQR
    limite_superior = Q3 + 1.5 * IQR

    # Aplicación de máscara de corrección
    df_sigesol[columnas_temporales] = df_sigesol[columnas_temporales].clip(lower=limite_inferior, upper=limite_superior, axis=1)

    # 4. Normalización Min-Max de las variables sociodemográficas (Población e Ingresos)
    # Impide que la magnitud de los habitantes (6 dígitos) distorsione el peso del ingreso
    escalador = MinMaxScaler(feature_range=(0, 1))
    variables_a_escalas = ['Poblacion_2025', 'Ingreso_Promedio_Hogar']

    df_sigesol[['Pob_Normalizada', 'Ingreso_Normalizado']] = escalador.fit_transform(df_sigesol[variables_a_escalas])

    return df_sigesol

# Ejecución del módulo
df_maestro = cargar_y_depurar_datos('data_RAW_gramulos.xlsx')
```

#### 1.2. Módulo de análisis multivariado y calibración estocástica

```
import scipy.stats as stats
import seaborn as sns
import matplotlib.pyplot as plt

def analisis_correlacion_y_cluster(df_maestro):
    """
    Función para evaluar la normalidad de la serie y generar la matriz
    multivariada de Pearson para la parametrización del modelo predictivo.
    """
    # 1. Prueba de normalidad de Kolmogorov-Smirnov (p > 0.05 indica distribución normal)
    stat, p_valor = stats.kstest(df_maestro['Masa_Total_2025'], 'norm')
    if p_valor > 0.05:
        print("La serie temporal sigue una distribución paramétrica normal.")
    else:
        print("La serie no paramétrica requiere corrección o pruebas de Spearman.")

    # 2. Generación de la Matriz de Correlación Cruzada (Pearson)
    variables_estudio = ['Poblacion_2025', 'Ingreso_Promedio_Hogar', 'GPC_2025', 'Masa_Total_2025']
    matriz_correlacion = df_maestro[variables_estudio].corr(method='pearson')

    # 3. Parametrización de los clústeres biofísicos de simulación (Arequipa Metropolitana)
    # Segmentación basada en el análisis jerárquico de Ward
    cluster_1 = ['Cercado', 'Yanahuara', 'J.L. Bustamante y R.', 'Sabandía']
    cluster_2 = ['Cayma', 'Sachaca', 'Socabaya', 'Tiabaya']
    cluster_3 = ['Cerro Colorado', 'Pauca pata', 'Jacobo Hunter', 'Mariano Melgar', 'Miraflores']

    # Asignación de parámetros estocásticos de composición física (Humedad/Seco)
    parametros_simulacion = {
        'cluster_1': {'Materia_Organica': 0.540, 'Plasticos': 0.125},
        'cluster_2': {'Materia_Organica': 0.575, 'Plasticos': 0.100},
        'cluster_3': {'Materia_Organica': 0.620, 'Plasticos': 0.085}
    }

    return matriz_correlacion, parametros_simulacion

# Ejecución del módulo
matriz_pearson, config_simulacion = analisis_correlacion_y_cluster(df_maestro)
```

### 1.3. Código Python de Entrenado, Validación Cruzada y Residuales

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split, cross_val_score, KFold
from sklearn.linear_model import LinearRegression
from sklearn.metrics import r2_score, mean_absolute_error, mean_squared_error

def entrenar_y_validar_modelo(df_maestro):
    """
    Módulo para el entrenamiento del modelo, validación cruzada (k-fold),
    cálculo de métricas (R2, MAE, RMSE) y evaluación de residuales.
    """
    # 1. Selección de Variables Independientes (X) y Dependiente (Y)
    X = df_maestro[['Pob_Normalizada', 'Ingreso_Normalizado']]
    Y = df_maestro['Masa_Total_2025']

    # 2. Partición de Datos: 80% Entrenamiento (Train) y 20% Prueba (Test)
    X_train, X_test, Y_train, Y_test = train_test_split(X, Y, test_size=0.20, random_state=42)

    # 3. Entrenamiento del Modelo de Regresión
    modelo = LinearRegression()
    modelo.fit(X_train, Y_train)

    # 4. Predicción sobre el Bloque Testigo (Ex-post facto)
    Y_pred = modelo.predict(X_test)

    # 5. Cálculo de Métricas Oficiales de Aceptación
    r2 = r2_score(Y_test, Y_pred)
    mae = mean_absolute_error(Y_test, Y_pred)
    rmse = np.sqrt(mean_squared_error(Y_test, Y_pred))

    # 6. Validación Cruzada K-fold (k=5)
    kf = KFold(n_splits=5, shuffle=True, random_state=42)
    scores_r2 = cross_val_score(modelo, X, Y, cv=kf, scoring='r2')

    print(f"--- RESULTADOS DE VALIDACION ---")
    print(f"Coefficiente R2 (Test): {r2:.4f}")
    print(f"MAE (Error Absoluto Medio): {mae:.2f} t/año")
    print(f"RMSE (Raíz Error Cuadrático): {rmse:.2f} t/año")
    print(f"R2 Promedio K-Fold Cross-Validation: {scores_r2.mean():.4f}")

    # 7. Analisis de Residuales (Verificación de Ruido Blanco)
    residuales = Y_test - Y_pred

    plt.figure(figsize=(6, 4))
    plt.scatter(Y_pred, residuales, color='navy', alpha=0.7)
    plt.axhline(y=0, color='red', linestyle='--')
    plt.title("Análisis de Homocedasticidad de Residuales")
    plt.xlabel("Valores Predichos (t/año)")
    plt.ylabel("Residuales (Error)")
    plt.tight_layout()
    plt.savefig("Gráfico_Residuales_Validación.png", dpi=300)
    plt.close()

    return modelo, r2, mae, rmse
```

## 1.4. Módulo de simulación geométrica del relleno y exportación gráfica

```
def simulacion_volumetrica_celdas(df_proyectado, config_simulacion, capacidad_inicial=840000):
    """
    Transforma toneladas proyectadas en volumen consumido (m³) e itera
    el agotamiento espacial de la celda de contingencia bajo 3 escenarios de GIRS.
    """
    # 1. Parámetros de Ingeniería Sanitaria e Infraestructura
    densidad_compactacion = 0.88 # t/m³ (Alcanzada por el pool de maquinaria)
    factor_cobertura_diaria = 0.20 # 20% adicional por tierra arcillosa (F_c)

    # Vectores para almacenamiento del espacio remanente (2025-2042)
    vol_pesimista, vol_moderado, vol_optimista = [], [], []
    remanente_P, remanente_M, remanente_O = capacidad_inicial, capacidad_inicial, capacidad_inicial

    años_simulacion = np.arange(2026, 2042)

    # 2. Bucle Iterativo (Loop) de Ecuaciones de Desvío Circular
    for año in años_simulacion:
        masa_cruda = df_proyectado.loc[df_proyectado['Año'] == año, 'Masa_Total'].sum()

        # Escenario Pesimista (Confinamiento Lineal 100%)
        consumo_P = (masa_cruda / densidad_compactacion) * (1 + factor_cobertura_diaria)
        remanente_P = max(0, remanente_P - consumo_P)
        vol_pesimista.append(remanente_P)

        # Escenario Moderado (Valorización Parcial: 15% orgánicos, 20% inorgánicos)
        masa_moderada = masa_cruda * (1 - 0.15 - 0.20)
        consumo_M = (masa_moderada / densidad_compactacion) * (1 + factor_cobertura_diaria)
        remanente_M = max(0, remanente_M - consumo_M)
        vol_moderado.append(remanente_M)

        # Escenario Optimista (O.I. 1278: Incremento progresivo hasta 42.5% y 37.5%)
        # Tasa de desvío dinámica indexada por año
        tasa_org = min(0.20 + (año - 2026) * 0.015, 0.425)
        tasa_plast = min(0.15 + (año - 2026) * 0.015, 0.375)
        masa_optimista = masa_cruda * (1 - tasa_org - tasa_plast)

        consumo_O = (masa_optimista / densidad_compactacion) * (1 + factor_cobertura_diaria)
        remanente_O = max(0, remanente_O - consumo_O)
        vol_optimista.append(remanente_O)

    return vol_pesimista, vol_moderado, vol_optimista

def exportar_grafico_origin_pro(años, vol_pesimista, vol_moderado, vol_optimista):
    """
    Genera el entorno gráfico de alta densidad con encajonamiento ortogonal,
    ticks interiores y paleta ejecutiva libre de grids secundarios.
    """
    fig, ax = plt.subplots(figsize=(7.5, 5.5), facecolor='white')
    ax.grid(False)

    plt.rcParams['font.family'] = 'sans-serif'
    plt.rcParams['font.sans-serif'] = ['Arial', 'Helvetica']

    # Curvas de agotamiento
    ax.plot(años, vol_pesimista, color='#C53030', marker='X', linewidth=1.8,
            label='Escenario Pesimista', markeredgecolor='#C53030', markerfacecolor='white')
    ax.plot(años, vol_optimista, color='#0F4C81', marker='o', linewidth=1.8,
            label='Escenario Optimista', markeredgecolor='#0F4C81', markerfacecolor='white')

    # Configuración perimetral sellada (Box Frame)
    for spine in ['top', 'bottom', 'left', 'right']:
        ax.spines[spine].set_color('black')
        ax.spines[spine].set_linewidth(1.5)

    ax.tick_params(axis='both', direction='in', top=True, right=True, left=True, bottom=True,
                  width=1.5, length=5, colors='black', labelsize=10.5)

    ax.set_xlabel('Eje Cronológico de Simulación Operativa (Años)', fontsize=11.5, weight='bold')
    ax.set_ylabel('Volumen Útil Remanente Disponible (m³)', fontsize=11.5, weight='bold')
    ax.yaxis.set_major_formatter(plt.FuncFormatter(lambda x, p: format(int(x), ',.{}'))))

    plt.tight_layout()
    plt.savefig('Simulacion_Quebrada_Honda-OriginPro.png', dpi=300)
    plt.close()

# Ejecución del módulo
# v_pesimista, v_moderado, v_optimista = simulacion_volumetrica_celdas(df_proyectado, config_simulacion)
# exportar_grafico_origin_pro(np.arange(2026, 2042), v_pesimista, v_moderado, v_optimista)
```

## Anexo 2. Matrices Completas de Datos Históricos y Proyecciones Demográficas (2018–2041)

### 2.1. Matriz de consistencia histórica intradistrital (Año Base de Cierre: 2025)

Base de datos unificada y depurada de los 13 distritos metropolitanos de la provincia de Arequipa. Esta matriz consolida la población oficial proyectada por el INEI, las toneladas brutas recolectadas según los reportes municipales en el SIGERSOL, y la Generación Per Cápita (GPC) diaria derivada.

| Distrito Metropolitano | Población 2025 (Habitantes) | INEI Masa Recolectada (t/año) | Total 2025 | GPC Derivada 2025 (kg/hab/día) | Perfil Socioeconómico / Clúster |
|------------------------|-----------------------------|-------------------------------|------------|--------------------------------|---------------------------------|
| Cerro Colorado         | 180,705                     | 38,200                        |            | 0.458                          | Densidad Media / Ingresos Bajos |
| Paucarpata             | 136,040                     | 29,100                        |            | 0.478                          | Densidad Media / Ingresos Bajos |
| Cayma                  | 108,206                     | 22,800                        |            | 0.499                          | Residencial / Ingresos Medios   |
| Socabaya               | 92,938                      | 19,200                        |            | 0.461                          | Residencial / Ingresos Medios   |
| J.L. Bustamante y R.   | 79,496                      | 19,700                        |            | 0.540                          | Alto Comercial / Altos Ingresos |
| Miraflores             | 53,408                      | 11,300                        |            | 0.451                          | Densidad Media / Ingresos Bajos |
| Mariano Melgar         | 57,047                      | 11,800                        |            | 0.445                          | Densidad Media / Ingresos Bajos |
| Cercado                | 51,680                      | 16,100                        |            | 0.508                          | Alto Comercial / Altos Ingresos |
| Jacobo Hunter          | 53,205                      | 11,200                        |            | 0.450                          | Densidad Media / Ingresos Bajos |
| Sachaca                | 24,422                      | 5,200                         |            | 0.479                          | Residencial / Ingresos Medios   |
| Yanahuara              | 27,110                      | 7,600                         |            | 0.585                          | Alto Comercial / Altos Ingresos |
| Tiabaya                | 16,622                      | 3,600                         |            | 0.437                          | Residencial / Ingresos Medios   |
| Sabandía               | 5,118                       | 910                           |            | 0.419                          | Alto Comercial / Altos Ingresos |

### 2.2. Matriz de proyecciones demográficas anualizadas (2026–2041)

Datos computados mediante la ecuación de crecimiento geométrico continuo  $P_d(t) = P_{d0} \times (1 + r_d)^t$ . Para efectos de presentación en este anexo, se muestran los hitos quinquenales estratégicos de la simulación.

| Distrito             | Tasa Crecimiento (r) | Pob. 2026 | Pob. 2031 | Pob. 2036 | Pob. 2041 |
|----------------------|----------------------|-----------|-----------|-----------|-----------|
| Cerro Colorado       | +0.02                | 184,861   | 207,121   | 232,060   | 260,004   |
| Paucarpata           | +0.01                | 137,400   | 144,409   | 151,775   | 159,517   |
| Cayma                | +0.01                | 109,829   | 118,317   | 127,461   | 137,311   |
| Socabaya             | +0.01                | 94,704    | 104,049   | 114,317   | 125,597   |
| J.L. Bustamante y R. | +0.04                | 80,132    | 83,389    | 86,779    | 90,306    |
| Miraflores           | +0.02                | 53,728    | 55,360    | 57,041    | 58,772    |
| Mariano Melgar       | +0.01                | 57,332    | 58,780    | 60,264    | 61,786    |
| Cercado              | -0.005               | 51,422    | 50,149    | 48,908    | 47,697    |
| Jacobo Hunter        | +0.00                | 53,577    | 55,479    | 57,448    | 59,487    |
| Sachaca              | +0.018               | 24,862    | 27,181    | 29,717    | 32,490    |
| Yanahuara            | +0.009               | 27,354    | 28,607    | 29,918    | 31,289    |
| Tiabaya              | +0.008               | 16,755    | 17,436    | 18,145    | 18,882    |
| Sabandía             | +0.012               | 5,179     | 5,498     | 5,835     | 6,194     |

## 2.3. Hojas de balance de masa y volumen neto disponible en Quebrada Honda

| Año Operativo | Masa Cruda Total (t/año) | Consumo Escenario Pesimista (m³) | Volumen Remanente Pesimista (m³) | Consumo Optimista Cumplimiento D.L. 1278) (m³) | Escenario 3: (Ecoeficiente / Normativo | Volumen Remanente Optimista (m³) |
|---------------|--------------------------|----------------------------------|----------------------------------|------------------------------------------------|----------------------------------------|----------------------------------|
| 2025 (Base)   | 172,553.70               | -                                | 840,000.00                       | -                                              |                                        | 840,000.00                       |
| 2026          | 181,230.15               | 271,845.22                       | 568,154.78                       | 224,547.85                                     |                                        | 615,452.15                       |
| 2027          | 190,012.40               | 285,018.60                       | 283,136.18                       | 230,000.40                                     |                                        | 385,451.75                       |
| 2028          | 199,105.80               | 298,658.70                       | <b>0.00 (Colapso)</b>            | 236,689.50                                     |                                        | 148,762.25                       |
| 2029          | 208,650.35               | 312,975.52                       | 0.00                             | 244,120.10                                     |                                        | <b>0.00 (Colapso)</b>            |

| Hito Temporal | Desvío Orgánicos (t) | Acumulado | Desvío Plásticos (t) | Acumulado | Espacio Físico Liberado (m³) | Extensión de Vida Útil Ganada    |
|---------------|----------------------|-----------|----------------------|-----------|------------------------------|----------------------------------|
| 2026          | 31,540               |           | 18,320               |           | 47,302                       | -                                |
| 2028          | 109,168              |           | 63,410               |           | 163,752                      | + 1.2 años                       |
| 2031          | 273,666              |           | 158,945              |           | 410,500                      | -                                |
| 2036          | 700,000              |           | 406,580              |           | 1,050,000                    | -                                |
| 2041          | 1,331,678            |           | 773,430              |           | <b>1,997,517</b>             | <b>+ 4.8 años en macroceldas</b> |

## Anexo 3. Avanzados de Validación Estadística y Gráficos de Residuales

### 3.1. Tabla extendida de desempeño predictivo por clúster biofísico

| Clúster de Simulación Biofísica          | Coefficiente de Determinación (R2) | Error Medio [t/año] | Absoluto (MAE) | Raíz del Cuadrático (RMSE) [t/año] | Error Medio | Varianza Explicada (%) |
|------------------------------------------|------------------------------------|---------------------|----------------|------------------------------------|-------------|------------------------|
| Grupo 1: Alto Comercial / Altos Ingresos | 0.992                              | 210.45              |                | 285.60                             |             | 99.1%                  |
| Grupo 2: Residencial Ingresos Medios     | 0.989                              | 185.20              |                | 230.15                             |             | 98.8%                  |
| Grupo 3: Densidad Media / Ingresos Bajos | 0.994                              | 415.75              |                | 512.30                             |             | 99.5%                  |
| Promedio Global Metropolitano            | <b>0.998</b>                       | <b>270.46</b>       |                | <b>437.8</b>                       |             | <b>99.8%</b>           |

### 3.2. Gráficos de diagnóstico analítico de residuales (Homocedasticidad y Ruido Blanco)

