

DISEÑO DE UNA HERRAMIENTA METODOLÓGICA PARA LA EVALUACIÓN INTEGRAL Y SELECCIÓN DE ALTERNATIVAS DE VALORIZACIÓN ENERGÉTICA DE RESIDUOS SÓLIDOS MUNICIPALES

DANIEL D. OTERO MEZA
JUAN J. CABELLO ERAS
JAIRO G. SALCEDO MENDOZA



Universidad de Sucre



Daniel D. Otero Meza
Juan J. Cabello Eras
Jairo G. Salcedo Mendoza

**Diseño de una Herramienta
Metodológica para la Evaluación
Integral y Selección de Alternativas de
Valorización Energética de Residuos
Sólidos Municipales**

Otero Meza, Daniel D. y otros

Diseño de una Herramienta Metodológica para la Evaluación Integral y Selección de Alternativas de Valorización Energética de Residuos Sólidos Municipales / Daniel D. Otero Meza, Juan J. Cabello Eras, Jairo G. Salcedo Mendoza. --Primera edición. -- Sincelejo: Editorial Unisucré, 2025.

Incluye referencias al final de cada capítulo. 149 páginas, ilustraciones, figuras, gráficas.

ISBN: 978-628-96839-0-5

1. Residuos Sólidos Municipales. 2. Valorización Energética. 3. Análisis de Decisión Multicriterio. 4. Sostenibilidad. I. Otero Meza, Daniel D. II. Cabello Eras, Juan J. III. Salcedo Mendoza, Jairo G.

333.7938 O87d

CCD 20

Catalogación en publicación de la Biblioteca Pompeyo Molina –
COSiUS

Área: Ingeniería

1ª Edición, marzo de 2025.

©Daniel D. Otero Meza, Juan J. Cabello Eras y Jairo G. Salcedo Mendoza.

Comité Editorial: Ivon Patricia Quessep Tapias, Marcela Álvarez, Sandra Cabarcas, Jorge Mercado, Yefri Ruiz Hernández y Pedro Caraballo.

Coordinación Editorial: Pedro Caraballo.

Portada: Manuel Tamara.

©Universidad de Sucre

©Editorial Unisucré

editorial@unisucré.edu.co

Cra. 28 Nro. 5-267, Barrio Puerta Roja. Cel.: (+57)(312)884 4156

A mis amadas hijas, Isa y Emma, cuya risa y amor inspiran cada paso de mi camino; a mi amada esposa, María Teresa, mi compañera inquebrantable y fuente de fortaleza; a mi madre, Etilvia Isabel, cuya sabiduría y sacrificios han moldeado mi camino; y a mis queridos abuelos, Carmen Dilia y Joaquín Antonio (Q.E.P.D.), cuyo legado de amor y resiliencia vive en mi corazón.

Enero, 2025.

Daniel D. Otero Meza

Prefacio

En un mundo que se enfrenta a un volumen cada vez mayor de residuos sólidos municipales (RSM), con una asombrosa cifra de dos mil millones de toneladas producidas anualmente y una proyección de duplicación para mitad de siglo, la necesidad de soluciones sostenibles se ha vuelto ineludible. Las cargas ambientales, de salud pública y económicas asociadas con las prácticas tradicionales de gestión de residuos exigen un cambio de paradigma hacia enfoques que no solo mitiguen los daños, sino que también aprovechen el potencial latente de estos materiales desechados. Este libro, resultado de investigación y derivado de mi investigación doctoral en ingeniería energética, profundiza en el núcleo de ese desafío, explorando cómo metodologías innovadoras y soluciones tecnológicas pueden ser identificadas para transformar los RSM en un recurso valioso, específicamente en el contexto de la generación de energía.

Mi incursión en este campo comenzó con una temprana observación de la abundancia de residuos agrícolas, agroindustriales y municipales, y los efectos medioambientales y económicos de una mala gestión de estos, así como la ineficiente eliminación de residuos orgánicos que a menudo presenciaba en entornos urbanos, lo cual definió la trayectoria inicial de mi investigación. Como ingeniero agroindustrial, el concepto de optimización de recursos está profundamente arraigado en mi filosofía, lo que me llevó a realizar estudios avanzados en ingeniería energética, buscando una conexión tangible entre la generación de residuos orgánicos y la producción de energía. La literatura existente, aunque rica, frecuentemente carecía de análisis holísticos específicos en el área de la gestión de estos residuos, pasando por alto el contexto local y la importancia

de integrar diferentes facetas del paradigma de la sostenibilidad, incluyendo técnicas de pronóstico apropiadas. Esto me condujo a desarrollar una herramienta metodológica para abordar el complejo desafío de seleccionar las estrategias de valorización más adecuadas, teniendo en cuenta el contexto local, así como múltiples criterios técnicos, energéticos, económicos y ambientales.

Este libro presenta una exploración estructurada de la gestión de RSM, avanzando desde una revisión de los métodos tradicionales hasta el desarrollo de un marco integrado para seleccionar las tecnologías apropiadas de valorización energética. Comenzamos con una evaluación crítica de los métodos existentes y sus limitaciones, para luego profundizar en la caracterización de los RSM, su composición y su potencial energético. Esta comprensión fundamental se complementa con la implementación de un modelo de pronóstico de series temporales, que nos permite predecir la futura generación de residuos con rigurosidad estadística y, posteriormente, construir una metodología integral para la evaluación y selección de rutas de valorización energética de RSM apropiadas. Esta investigación culmina con una aplicación real en la ciudad de Sincelejo, Colombia. Los métodos empleados, que abarcan el análisis de series de tiempo, el método de la entropía para la ponderación objetiva de los criterios, la clasificación de alternativas y la aplicación práctica con datos del mundo real, representan una desviación de los métodos tradicionales que se basan únicamente en la ponderación subjetiva de los criterios estudiados.

Expreso mi absoluta gratitud a mi familia, cuyo estímulo inquebrantable y paciencia fueron esenciales durante el exigente proceso de investigación, formación doctoral y redacción de esta obra. Igualmente, estoy profundamente agradecido por el valioso apoyo de mis mentores académicos, el Dr. Juan José Cabello Eras y el Dr. Jairo Guadalupe Salcedo Mendoza, cuya guía y comentarios perspicaces dieron forma a la base de esta investigación, y por el apoyo de mis colegas en la Universidad de Sucre, Colombia, cuyo espíritu de colaboración enriqueció este proyecto de innumerables maneras.

Espero que los resultados presentados aquí sirvan como una guía práctica para ingenieros, planificadores urbanos, administradores públicos y todos aquellos comprometidos con la búsqueda de soluciones sostenibles para la gestión de RSM. Los métodos y enfoques presentados aquí no pretenden ser un destino final, sino un punto de partida, proporcionando un marco metodológico para implementar soluciones al creciente desafío de la gestión de RSM, al mismo tiempo que se facilita el acceso a un suministro de energía eléctrica. Les insto a ustedes, los lectores, a reflexionar sobre el potencial de transformar nuestros residuos, de una carga a una oportunidad, y confío en que el enfoque integrado para la selección de tecnologías descrito en las siguientes páginas nos acerque un paso más hacia el logro de un mundo más sostenible y eficiente en el uso de recursos.

Enero, 2025.

Daniel D. Otero Meza

Acerca de los Autores



Dr. Daniel David Otero Meza: Profesor Asistente del Departamento de Ingeniería Agrícola de la Universidad de Sucre. Ingeniero Agroindustrial egresado de la Universidad de Sucre. Doctor en Ingeniería Energética. Su trabajo se enfoca en modelado, simulación y valorización de procesos agroindustriales, y en la valorización química y energética de residuos sólidos orgánicos.



Dr. Juan José Cabello Eras: Profesor Asociado del Departamento de Ingeniería Mecánica de la Universidad de Córdoba. Doctor en Ciencias Técnicas. Investigador Senior. Su trabajo se centra en la sostenibilidad, la gestión energética y la mecánica aplicada, con impacto en la industria y el medio ambiente.



Dr. Jairo Guadalupe Salcedo Mendoza: Profesor Titular del Departamento de Ingeniería Agroindustrial de la Universidad de Sucre. Doctor en Ingeniería Química. Investigador Senior. Director del grupo “Procesos Agroindustriales y Desarrollo Sostenible (PADES)”. Su investigación se centra en bioprocesos, la valorización de residuos agroindustriales, la obtención de productos de alto valor agregado y las energías renovables.

Presentación

La presente investigación aborda la problemática global de los residuos sólidos municipales (RSM), cuyo volumen aumenta exponencialmente con el crecimiento urbano y el desarrollo socioeconómico, generando desafíos ambientales y de salud pública. Los métodos tradicionales de gestión, como rellenos sanitarios e incineración, presentan limitaciones importantes, incluyendo emisiones de gases de efecto invernadero, contaminación del agua, y costos elevados. Ante esto, la conversión de los RSM a energía (RSMaE) emerge como una alternativa prometedora, transformando residuos en energía útil, contribuyendo a la economía circular y diversificando la matriz energética nacional. No obstante, la selección de tecnologías de conversión de RSMaE adecuadas requiere la aplicación de un análisis de decisión multicriterio (ADM), que considere aspectos técnicos, económicos, ambientales y energéticos. El capítulo 1 explora las tendencias y limitaciones de los métodos de ADM, incluyendo la subjetividad en la asignación de pesos, la incertidumbre en los datos y la complejidad computacional implícita de algunos métodos, destacando la necesidad de herramientas metodológicas sólidas y adaptables. El capítulo 2 analiza las rutas tecnológicas de valorización energética (i.e., incineración, digestión anaeróbica, gasificación y rellenos sanitarios con captura de biogás), caracterizando sus componentes y su compatibilidad con distintos tipos de residuos. Se detallan la composición categórica y fisicoquímica de los RSM, fundamentales para la correcta implementación de cada tecnología. Se establecen relaciones para estimar sus potenciales técnicos, económicos, ambientales y energéticos, subrayando que la elección de cada ruta debe considerar una evaluación multicriterio. El capítulo 3 se enfoca en el

análisis de series de tiempo de la tasa de disposición de RSM (TDRSM), crucial para predecir tendencias futuras y estudiar estrategias de gestión de residuos, utilizando métodos autorregresivos integrados con promedio móvil (i.e., VAR, ARIMA, SARIMA y SARIMAX) y demostrando la importancia de considerar la estacionalidad y las variables exógenas en los modelos, además de la necesidad de una descomposición de los datos para identificar patrones de interés y poder estimar las capacidades de predicción con mayor precisión. El capítulo 4 se centra en el diseño de una herramienta metodológica para la evaluación y selección de alternativas de conversión de RSMaE, incorporando un ADM con énfasis en un método objetivo para la ponderación de criterios y uno de clasificación de alternativas mediante un indicador de cercanía a las soluciones ideales y no ideales (TOPSIS, por sus siglas en inglés de *Technique for Order Preference by Similarity to Ideal Solution*). Se definen criterios técnicos, económicos, energéticos y ambientales para la evaluación comparativa, presentando un marco detallado para la toma de decisiones informada. El capítulo 5 implementa la herramienta metodológica diseñada en el caso de la ciudad de Sincelejo, Colombia. Se analizan las características específicas de los RSM locales, se proyectan sus tasas de disposición para 2050 y se evalúan distintas rutas de valorización energética. Los resultados favorecen al relleno sanitario con captura de biogás como la opción más adecuada para la ciudad de estudio por su eficiencia técnica, económica y ambiental en comparación con las otras rutas analizadas, demostrando que no necesariamente las tecnologías de mayor nivel de sofisticación representan la mejor opción para todos los contextos, lo cual concuerda parcialmente con análisis previos de la Convención Marco de las Naciones Unidas sobre el Cambio Climático para la ciudad de estudio.

Palabras clave – Residuos Sólidos Municipales; Valorización Energética; Análisis de Decisión Multicriterio; Sostenibilidad.

Contenido

Nomenclatura	XIII
1 Métodos de Selección de Alternativas de Conversión de RSMaE: Estatus y Retos	13
1.1 Introducción	13
1.2 Vigilancia Científica	15
1.2.1 Análisis de coocurrencias de palabras clave	15
1.2.2 Revisión sistemática de literatura	22
1.3 Limitaciones de los métodos de selección	30
1.4 Conclusiones del capítulo	33
2 Rutas Tecnológicas de Valorización Energética de RSM	39
2.1 Introducción	39
2.2 Características categóricas de los RSM	41
2.3 Características fisicoquímicas de los RSM	44
2.4 Tecnologías de valorización energética de RSM	49
2.4.1 Incineración (INC)	49
2.4.2 Digestión Anaerobia (DA)	51
2.4.3 Gasificación (GAS)	53
2.4.4 Relleno Sanitario con Captura de Biogás (RSCB)	55
2.5 Potencial de valorización de las rutas	56
2.5.1 Potencial técnico	56
2.5.2 Potencial energético	58
2.5.3 Potencial económico	60
2.5.4 Potencial ambiental	63
2.6 Conclusiones del capítulo	66
3 Análisis de Series de Tiempo de RSM	75
3.1 Introducción	75
3.2 Datos de disposición de RSM	83
3.3 Características de las series de tiempo de disposición de TDRSM	84
3.4 Descomposición de series de tiempo	90

3.5	Características relevantes de las series de tiempo	93
3.6	Modelo de serie de tiempo estacional	96
3.7	Entrenamiento y validación de modelos	97
3.8	Conclusiones del capítulo	97
4	Selección de Alternativas de Valorización Energética de RSM	103
4.1	Introducción	103
4.2	Criterios para la evaluación de alternativas	105
4.2.1	Criterios Técnicos	105
4.2.2	Criterios Energéticos	107
4.2.3	Criterios Económicos	109
4.2.4	Criterios Ambientales	111
4.3	Selección de un método de análisis de decisión multicriterio	113
4.4	Clasificación de Alternativas	115
4.5	Estructura general de la herramienta de selección de alternativas	118
4.6	Conclusiones del capítulo	120
5	Evaluación Integral y Selección de Alternativas de Valorización Energética de RSM: caso de Sincelejo	125
5.1	Introducción	125
5.2	Sistema de gestión de RSM de Sincelejo	127
5.2.1	Tratamiento actual de los residuos sólidos municipales	127
5.2.2	Composición de los RSM	129
5.2.3	Proyección de TSRSM	132
5.3	Clasificación de alternativas	140
5.4	Conclusiones del capítulo	147

Nomenclatura

Abreviaciones

ACV Análisis de Ciclo de Vida.

ADM Análisis de Decisión Multicriterio.

AHP Proceso Analítico Jerárquico.

ARIMA Autorregresivo Integrado de Media Móvil.

CCS Captura y Almacenamiento de Carbono.

CHP Ciclo Combinado de Calor y Potencia.

DA Digestión Anaerobia.

DANE Departamento Administrativo Nacional de Estadística.

ELECTRE Eliminación y Elección Traduciendo la Realidad.

Fuzzy-AHP Proceso Analítico Jerárquico Difuso.

G-AHP Proceso Analítico Jerárquico Gris.

GAS Gasificación.

GEI Gases de Efecto Invernadero.

GIS Sistemas de Información Geográfica.

HTC Carbonización Hidrotermal.

HTL Hidrolización Térmica.

IDH Índice de Desarrollo Humano.

IEA Agencia Internacional de Energía.

INC Incineración.

IR Índice de Rentabilidad.

MBT Tratamiento Biológico Mecánico.

PCI Poder calorífico Inferior.

PCS Poder Calorífico Superior.

PIB Producto Interno Bruto.

PRISMA Elementos de Información Preferidos para Revisiones Sistemáticas y Meta-análisis.

PYR Pirólisis.

RBC Relación Beneficio Costo.

RDF Combustible Derivado de Residuos.

RSCB RSCB.

RSM Residuos Sólidos Municipales.

RSMaE RSM-a-Energía.

SARIMA ARIMA Estacional.

SARIMAX ARIMA Estacional con Variables Exógenas.

SSPD Superintendencia de Servicios Públicos Domiciliarios.

TDRSM Tasas de Disposición de los RSM.

TIR Tasa Interna de Retorno.

TOPSIS Técnica para Ordenar Preferencias por Similitud a la Solución Ideal.

VPN Valor Presente Neto.

Constantes

a_c Año de construcción de la ruta tecnológica (a).

f_{con} Factor de emisión de GEI de una planta térmica de generación electricidad (kg kWh^{-1}).

- j Incremento decimal de tiempo dentro de un año i (a).
- k Tasa potencial de generación de metano del RSCB (a^{-1}).
- M_C Masa molar del carbono (12 kg kmol^{-1}).
- M_{CH_4} Masa molar del metano (16 kg kmol^{-1}).
- n Años de estimación de emisiones de metano (a).
- n Vida útil del proyecto (a).
- r Número de variables exógenas.

Letras Griegas

- β_i Vector de coeficientes de $X_{i,t}$.
- η_{INC} Eficiencia de conversión eléctrica neta de la tecnología x (%).
- η_{RSCB} Eficiencia parásita del motor reciprocante en la ruta RSCB (%).
- ∇^d Operador diferencial no estacional equivalente a $(1 - B)$.
- $\phi_p(B)$ Polinomio autorregresivo.
- $\Phi_P(B^s)$ Polinomio autorregresivo estacional.
- ρ_{CH_4} Densidad del metano ($657 \times 10^{-6} \text{ t m}^{-3}$).
- $\theta_q(B)$ Polinomio de promedio móvil.
- $\Theta_Q(B^{sj})$ Polinomio de promedio móvil estacional.
- ε_t Error de la serie de tiempo.

Variables

- $\bar{M}_{\text{RSM},x}$ Porcentaje máximo de agua que deben contener los RSM para ser admitidos en la ruta x (%).
- $\dot{m}_{e,\text{RS},i}$ Flujo másico del contaminante e emitido por un relleno sanitario en el año i (kg).
- $\dot{m}_{e,x,i}$ Flujo másico del contaminante e emitido por el proyecto x en el año i (kg).
- $\dot{P}_{x,i}$ Potencia neta generada por la tecnología x en el año i (kW).

$\dot{W}_{x,i}$ Flujo de RSM que ingresan a la ruta tecnológica x en el año i (kg a^{-1}).
 ∇_s^D Operador diferencial estacional equivalente a $(1 - B^s)$.
 AP Precipitación local promedio (mm).
 $CAPEX_{x,0}$ CAPEX del proyecto x en el periodo de construcción (USD).
 $CAPEX_{x,i}$ Costo de capital de la planta de la tecnología x en el año i (USD).
 $COE_{x,1}$ Costo de generación de electricidad del proyecto x en el primer año (USD kWh^{-1}).
 $DOCF_q$ Fracción de DOC_q que puede decaer o convertirse en metano (%).
 DOC_q Contenido de carbono orgánico degradable de la fracción q de los RSM (kg kg^{-1}).
 $D_{x,i}$ Depreciación del CAPEX instalado del proyecto x en el año i (USD).
 $G_{x,i}$ Gastos del proyecto x en el año i (USD).
 $IMP_{d,x,i}$ Deducción total de impuestos del proyecto x en el año i (USD).
 $IMP_{x,i}$ Impuestos totales del proyecto x en el año i (USD).
 $IN_{x,i}$ Ingresos del proyecto x en el año i (USD).
 IR_x IR del proyecto x (USD USD^{-1}).
 $LCOE_x$ Costo nivelado de electricidad del proyecto x (USD kWh^{-1}).
 LHV_{CH_4} Poder calorífico inferior del metano (50 MJ m^{-3}).
 LHV_{RSM} Poder calorífico inferior de los RSM (kJ kg^{-1}).
 MCF Factor de corrección de metano del relleno.
 $OPEX_{x,i}$ Costo operacional global de la planta de la tecnología x en el año i (USD).
 $OPEX_{x,i}$ OPEX del proyecto x en el año i (USD).
 PCG_e Potencial de calentamiento global del contaminante e emitido por el proyecto x en el año i (kg kg^{-1}).
 $PEGEI_{x,i}$ Potencial evitable de emisiones de gases de efecto invernadero mediante plantas térmicas de generación de electricidad (kg).
 $PRGEI_{x,i}$ Potencial de reducción de emisión de gases de efecto invernadero (kg).

RCB_x	RBC del proyecto x (USD USD ⁻¹).
TIR_x	TIR del proyecto x (%).
UE_x	Margen de utilidad por la venta de la electricidad generada en el proyecto x (%).
VPN_x	VPN del proyecto x (USD).
$V_{C,x,i}$	Ventas de créditos carbono del proyecto x en el año i (USD).
$V_{E,x,i}$	Ventas de electricidad del proyecto x en el año i (USD).
A	Conjunto de las m alternativas.
$a_{i,j}$	Desempeño de la alternativa a_i bajo el criterio g_j .
$C_{el,x}$	Contribución al balance energético local (%).
$c_{F,i}$	Factor de capacidad horaria de ruta tecnológica x (h a ⁻¹).
$c_{I,x}$	Capacidad instalada de la tecnología x (kg a ⁻¹).
$cl(a_i)$	Coefficiente de cercanía de la alternativa a_i .
D	Orden diferencial estacional.
d	Orden diferencial no estacional.
d	Tasa de descuento (%).
d_g	Tasa de inflación de la economía local (%).
$d_{a_i}^+$	Distancia Euclídea entre la alternativa a_i y la solución ideal positiva.
$d_{a_i}^-$	Distancia Euclídea entre la alternativa a_i y la solución no ideal negativa.
e	Vector de entropía de cada criterio.
e_j	Entropía del criterio j .
$E_{L,i}$	Demanda energética local en el año i (kWh).
$E_{pc,x}$	Generación eléctrica per cápita local (kWh hab ⁻¹).
$E_{x,i}$	Electricidad neta generada en la ruta tecnológica x en el año i (kWh).
F_{RSCB}	Tasa de consumo de energía liberada en la combustión del CH ₄ requerida para generar un kWh de electricidad (11.87 MJ kWh ⁻¹).

$F_{m,x}$	Porcentaje de tiempo del año para mantenimiento de la tecnología x (%).
$f_{q,x}$	Peso relativo de la fracción q de las s fracciones de los RSM admitidos en la ruta x (%).
G	Conjunto de los n criterios.
G^+	Subconjunto de G de criterios de beneficio.
G^-	Subconjunto de G de criterios de costo.
h_i	Población local en el año i (hab).
L_0	Potencial de generación de metano de los RSM ($\text{m}^3 \text{t}^{-1}$).
L_{DA}	Potencial de generación de metano de la fracción orgánica, f_o , de los RSM en la ruta tecnológica de DA ($71 \text{ m}^3 \text{t}^{-1}$).
$M_{m,x}$	Proporción entre la cantidad de agua de los RSM y la admitida en la ruta tecnológica x .
M_{RSM}	Contenido de agua presente en los RSM del sitio de estudio (%).
P	Matriz de decisión normalizada.
P	Orden del componente autorregresivo estacional.
p	Orden del componente autorregresivo no estacional.
P_x	Potencia eléctrica neta por cantidad de RSM admitidos en la ruta tecnológica x (kW kg^{-1}).
$p_{i,j}$	Elemento (i, j) de la matriz de decisión normalizada.
Q	Orden del componente de promedio móvil estacional.
q	Fracción de RSM que cuenta con capacidad de generar metano.
q	Orden del componente de promedio móvil no estacional.
$Q_{\text{CH}_4,i}$	Emisión de metano en el año i del RSCB ($\text{m}^3 \text{a}^{-1}$).
R	Matriz de decisión normalizada.
r	Eficiencia de recolección del sistema de captura de biogás (%).
$r_{i,j}$	Elemento (i, j) de la matriz de decisión normalizada.

s	Número de fracciones de los RSM con carbono orgánico.
s	Periodo estacional.
$T_{a,x}$	Tasa de aprovechamiento de RSM de la tecnología x (%).
t_{ij}	Edad de la sección j de W_i dispuesta en el año i (a).
u_j^+	Valor máximo de la columna j -ésima de X .
u_j^-	Valor mínimo de la columna j -ésima de X .
V	Matriz de decisión ponderada.
v^+	Vector de solución ideal positiva.
v^-	Vector de solución no ideal negativa.
v_j^+	Componente j del vector de solución ideal positiva.
v_j^-	Componente j del vector de solución no ideal negativa.
$v_{i,j}$	Elemento (i, j) de la matriz de decisión ponderada.
W	Vector de pesos de los n criterios.
w_j	Peso del criterio g_j .
w_q	Peso relativo de la fracción q en las s fracciones de los RSM (%).
X	Matriz de decisión.
$X_{i,t}$	Serie de tiempo de la i -ava variable exógena.
Y_t	Serie de tiempo de la variable dependiente.
y_{CH_4}	Fracción volumétrica de metano en el biogás de relleno (%).

Introducción

La problemática mundial de los Residuos Sólidos Municipales (RSM) se ha convertido en uno de los desafíos ambientales más apremiantes del siglo XXI. A medida que las ciudades crecen y la urbanización avanza, la cantidad de residuos generados aumenta de manera alarmante. Según estimaciones del Banco Mundial (Kaza et al., 2018), en el globo se producen aproximadamente 2.01 Gt a^{-1} (miles de millones de toneladas de RSM por año), una cifra que se espera aumente a 3.4 Gt a^{-1} para 2050. Este incremento en la generación de residuos está directamente relacionado con el Índice de Desarrollo Humano (IDH) (Kocak & Baglitas, 2022). Las naciones con un IDH más alto tienden a generar más residuos debido a mayores niveles de consumo y estilos de vida más orientados al descarte (Velis et al., 2023). El aumento del poder adquisitivo en estas naciones conlleva a un incremento en la producción de residuos, lo que agrava la situación. La gestión de los RSM en estas naciones ha seguido tradicionalmente métodos como los rellenos sanitarios y la incineración (World Bank, 2019a), métodos que presentan serias desventajas que limitan su efectividad y sostenibilidad a largo plazo.

Los rellenos sanitarios, diseñados para confinar los residuos de manera controlada, generan metano (CH_4) a través de la descomposición anaeróbica de la materia orgánica (Sohoo et al., 2022). Este gas tiene un potencial de calentamiento global 28 veces mayor que el dióxido de carbono (CO_2) (U.S. EPA, 2023), lo que contribuye al cambio climático. Además, los lixiviados producidos pueden contaminar las fuentes de agua subterránea y superficial, afectando la salud humana y la biodiversidad (Yaashikaa et al., 2022). Por otro lado, la incineración reduce el volumen de residuos en más del 90 % y

recupera energía (Cudjoe & Acquah, 2021), pero emite contaminantes peligrosos como CO_x , NO_x , SO_x (Lin et al., 2015) y dioxinas (Wei et al., 2022), que tienen graves impactos en la calidad del aire y la salud pública (Shi et al., 2020). Además de las cuestiones ambientales, los métodos tradicionales de tratamiento de residuos también presentan desafíos económicos. Los rellenos sanitarios requieren grandes extensiones de tierra (Aracil et al., 2018), por lo que, para áreas urbanas densamente pobladas, la disponibilidad de terrenos adecuados puede ser limitada. La incineración, aunque tecnológicamente avanzada, requiere una alta inversión inicial y altos costos de operación y mantenimiento (Y. Liu et al., 2022; Silva et al., 2020; Sun et al., 2021). Estos factores económicos limitan la viabilidad de estos métodos en muchas regiones, especialmente en países en vías de desarrollo donde los recursos financieros son limitados. Desde una perspectiva técnica, la eficiencia de estos métodos también es cuestionable. Los rellenos sanitarios, aunque necesarios para la disposición final de ciertos tipos de residuos, no aprovechan el potencial energético de los RSM, llegando a alcanzar eficiencias netas cercanas al 15 % (Otero Meza et al., 2023). La incineración, por su parte, aunque genera energía con eficiencias de hasta el 30 % en ciclo combinado de calor y potencia (CHP), es menos eficiente en comparación con otras tecnologías más avanzadas como la gasificación (33 %) (IEA Bioenergy, 2018). Además, la gestión de los subproductos de la incineración, como las cenizas volantes, plantea problemas adicionales de manejo y disposición (Lassesson et al., 2014). Por lo tanto, la problemática mundial de los RSM es compleja y multifacética, afectando tanto a naciones con altos niveles de desarrollo humano como a aquellas en vías de desarrollo. La relación entre el IDH y la generación de residuos subraya la necesidad de abordar esta cuestión de manera integral. Los métodos tradicionales de tratamiento de residuos, aunque necesarios en ciertos contextos, presentan desventajas importantes desde perspectivas ambientales, económicas y técnicas. La búsqueda de soluciones más sostenibles y efectivas es imperativa para mitigar los impactos negativos de la gestión de RSM y avanzar hacia un futuro más sostenible.

La valorización de RSM-a-Energía (RSMaE) se perfila como una de las alternativas más viables para abordar la creciente problemática de la gestión de residuos a nivel mundial (Tsui & Wong, 2019). Este proceso implica la conversión de residuos en formas útiles de energía, como electricidad, calor o combustibles renovables, ofreciendo una solución que no solo reduce la cantidad de RSM destinados a vertederos, sino que también contribuye a la economía circular (Gołębiewski et al., 2019). Según estimaciones globales, la valorización energética podría procesar hasta un 23 % de los RSM generados, produciendo aproximadamente 20 EJ a^{-1} de energía eléctrica (Vlaskin, 2018), lo que representa el 31.7 % del total de electricidad generada en 2021 por fuentes fósiles (IEA, 2023), un potencial notable si se considera que la Agencia Internacional de Energía (IEA, por las siglas en inglés *International Energy Agency*) reporta que en 2021 el 61.5 % de la electricidad a nivel mundial se generó a partir de fuentes fósiles (i.e, carbón, petróleo y gas natural). Entre las tecnologías de valorización energética, destacan la

incineración, la gasificación, la digestión anaerobia y el relleno sanitario con captura de biogás (Fernández-González et al., 2017; Z. Liu, 2019; Tsui & Wong, 2019). Cada una de estas tecnologías presenta características únicas que deben ser evaluadas desde múltiples dimensiones, incluyendo aspectos técnicos, económicos, ambientales y energéticos, y la selección de la tecnología más adecuada debe abordarse como un proceso complejo que requiere la aplicación de métodos como el de Análisis de Decisión Multicriterio (ADM) (Alao et al., 2022; Kaneesamkandi et al., 2023; Van Thanh, 2022).

Los métodos de ADM son herramientas fundamentales para la toma de decisiones en la gestión de RSM, especialmente cuando se trata de seleccionar tecnologías de valorización energética. A pesar de su importancia, los métodos de ADM actuales presentan varias limitaciones que pueden afectar su efectividad y aplicabilidad en diferentes contextos (Vlachokostas et al., 2021). Una de las principales limitaciones de los métodos de ADM es la subjetividad inherente en la asignación de pesos a los diferentes criterios de evaluación (Ahmad et al., 2020). Este proceso, a menudo basado en juicios de expertos o preferencias de los tomadores de decisiones, puede introducir sesgos que afectan los resultados finales (Alao et al., 2020). Además, la falta de consenso sobre los criterios más relevantes y sus pesos relativos puede llevar a diferentes resultados dependiendo de los intereses y prioridades de los actores con poder de decisión involucrados (El Kourdi et al., 2023). Entre los métodos de ADM más utilizados a nivel mundial se encuentran el Proceso Analítico Jerárquico (AHP, por sus siglas en inglés de *Analytic Hierarchical Process*) (Yin et al., 2017), el Método PROMETHEE (por las siglas en inglés de *Preference Ranking Organization METHod for Enriched Evaluation*) (Ukpanyang et al., 2022), ELECTRE (por sus siglas en francés de *ELimination Et Choix Traduisant la REalité*), y TOPSIS (por sus siglas en inglés de *Technique of Order Preference Similarity to the Ideal Solution*) (Vlachokostas et al., 2021). Cada uno de estos métodos tiene sus pros y contras. El AHP es conocido por su capacidad para descomponer problemas complejos en una jerarquía de criterios y subcriterios (Uyan, 2014), facilitando la comparación de diferentes opciones. Por otro lado, su dependencia de comparaciones por pares y la escala de juicio pueden introducir inconsistencias en las evaluaciones (El Kourdi et al., 2023). El método PROMETHEE, por otro lado, es un enfoque basado en la preferencia que permite una comparación directa de alternativas en función de múltiples criterios. PROMETHEE es valorado por su flexibilidad y capacidad para manejar datos cualitativos y cuantitativos (Ukpanyang et al., 2022). No obstante, su complejidad en la definición de funciones de preferencia y la necesidad de una normalización adecuada de los datos pueden ser desafiantes para los usuarios sin experiencia (Vlachokostas et al., 2021). TOPSIS es una herramienta de toma de decisiones multicriterio que se utiliza para evaluar y seleccionar alternativas basándose en su proximidad a una solución ideal. Este enfoque se fundamenta en la idea de que la mejor alternativa debe tener la menor distancia posible a la solución ideal positiva y la mayor distancia a la solución ideal negativa (Tamasila et al., 2020). No obstante, la precisión de los resultados obtenidos

depende en gran medida de la adecuada ponderación de los criterios y de la calidad de los datos disponibles, lo que puede representar un desafío en escenarios con información incompleta o imprecisa (Vlachokostas et al., 2021). Además de estas limitaciones específicas, los métodos de ADM actuales también enfrentan desafíos relacionados con la integración de incertidumbre y variabilidad en los datos. La gestión de RSM implica múltiples fuentes de incertidumbre, incluyendo variaciones en la composición de los residuos (World Bank, 2019b), y fluctuaciones en los mercados de energía (IEA, 2024). La capacidad de los métodos de ADM para manejar esta incertidumbre de manera efectiva es crucial para proporcionar recomendaciones robustas y fiables (Qazi et al., 2018). Otro desafío relevante es la falta de enfoques integrados que combinen diferentes métodos de ADM para aprovechar sus fortalezas respectivas (Uhde et al., 2015). La mayoría de las aplicaciones de ADM tienden a utilizar un solo método, lo que puede limitar la capacidad de capturar todas las dimensiones relevantes de la toma de decisiones (Baltussen et al., 2019).

Por otro lado, los métodos de proyección de RSM juegan un papel crucial en la evaluación de alternativas de valorización energética, proporcionando estimaciones precisas y confiables de la generación futura de residuos. Estos métodos son esenciales para planificar y dimensionar adecuadamente las tecnologías de gestión de residuos (Sununta et al., 2018), asegurando que las soluciones adoptadas sean sostenibles y eficientes a largo plazo. La capacidad de proyectar la cantidad y composición de los RSM permite a los actores involucrados en la implementación de soluciones anticipar con mayor confianza los cambios en la generación de residuos (Paulauskaite-Taraseviciene et al., 2022) y adaptar las estrategias de gestión en consecuencia. Entre los métodos de proyección más utilizados se encuentran los modelos de crecimiento poblacional, los modelos econométricos y los enfoques basados en el análisis de tendencias históricas. Cada uno de estos métodos tiene sus pros y contras, y la elección del método adecuado depende de la disponibilidad de datos, el contexto específico y los objetivos de la proyección. Los modelos de crecimiento poblacional se basan en la relación directa entre el crecimiento de la población y la generación de residuos (Kaza et al., 2018). Este enfoque es sencillo y fácil de implementar, ya que utiliza datos demográficos que suelen estar ampliamente disponibles. Sin embargo, estos modelos pueden no capturar adecuadamente las variaciones en los patrones de consumo y generación de residuos, lo que puede llevar a estimaciones imprecisas en contextos con cambios rápidos en los hábitos de consumo. Los modelos econométricos, por otro lado, utilizan variables económicas como el ingreso per cápita y el nivel de industrialización para predecir la generación de residuos (Abdella Ahmed et al., 2022; Kim et al., 2023; Wen et al., 2023). Estos modelos pueden proporcionar estimaciones más precisas en contextos donde los factores económicos tienen una influencia dominante en la generación de residuos, para lo cual requieren datos detallados y actualizados, lo que puede ser un desafío en regiones con limitaciones en la disponibilidad de datos. Los enfoques basados en el análisis de tendencias histó-

ricas utilizan datos de generación de residuos recopilados durante períodos anteriores para extrapolar tendencias futuras (Kaur et al., 2023). Este método puede ser efectivo en contextos donde los patrones de generación de residuos son relativamente estables, pero puede no ser adecuado en situaciones donde se esperan cambios abruptos en las políticas de gestión de residuos, las tecnologías de tratamiento de residuos o los hábitos de consumo de la población. La precisión y confiabilidad de los métodos de proyección de RSM son cruciales para reducir la incertidumbre en la evaluación de alternativas de valorización energética (Xu et al., 2013). La incertidumbre en las proyecciones de generación de residuos puede llevar a una subestimación o sobreestimación de la capacidad necesaria de las tecnologías de tratamiento, lo que puede resultar en inversiones ineficientes y problemas operativos a largo plazo. La integración de métodos de proyección de RSM con métodos de ADM puede mejorar considerablemente la robustez de las evaluaciones, proporcionando una base más sólida para la toma de decisiones. Los métodos de proyección de RSM no solo ayudan a dimensionar adecuadamente las tecnologías de tratamiento, sino que también proporcionan información valiosa sobre los patrones de generación de los RSM, lo que es crucial para seleccionar las tecnologías más adecuadas. Ahora bien, sumado a una caracterización de los RSM aumentaría las probabilidades de éxito de la selección de alternativas. Por ejemplo, la digestión anaerobia es más efectiva para tratar fracciones orgánicas ricas en materia biodegradable (Lohani & Havukainen, 2018; Van Fan et al., 2019), mientras que la gasificación y la incineración son más adecuadas para residuos lignocelulósicos (e.g., residuos de madera o de poda y jardín), con alto contenido de energía y bajo contenido de agua (Arena et al., 2015). La proyección de la composición de los residuos permite adaptar las tecnologías de tratamiento a las características específicas de los residuos generados en su región desde los estudios de factibilidad.

En síntesis, la gestión ineficaz de los RSM constituye un desafío crucial a nivel global, afectando tanto a países desarrollados como en desarrollo. A medida que el volumen de residuos aumenta, impulsado por el crecimiento poblacional, la urbanización y el incremento del consumo, la necesidad de encontrar soluciones sostenibles y eficaces se vuelve cada vez más urgente. Los métodos tradicionales de gestión de residuos, como los rellenos sanitarios y la incineración, han demostrado ser insuficientes y presentan múltiples desventajas. Los rellenos sanitarios, aunque controlan la disposición de residuos, generan metano, un gas de efecto invernadero con un potencial de calentamiento global mayor que el del dióxido de carbono. Además, los lixiviados de los rellenos pueden contaminar los recursos hídricos, afectando la salud humana y la biodiversidad. Por otro lado, la incineración, aunque reduce notablemente el volumen de residuos y recupera energía, produce emisiones tóxicas como dioxinas y furanos, que tienen serias implicaciones para la salud pública y el medio ambiente. Estos métodos también enfrentan desafíos económicos, ya que requieren inversiones iniciales considerables y altos costos de operación y mantenimiento, lo que limita su viabilidad en muchas regiones,

especialmente en países en vías de desarrollo. En contraste, la valorización energética se presenta como una alternativa prometedora que no solo mitiga los impactos negativos de los métodos tradicionales, sino que también contribuye a la economía circular al convertir los residuos en energía útil. Tecnologías como la incineración con recuperación de energía, la gasificación, la digestión anaerobia y el relleno sanitario con captura de biogás ofrecen diferentes beneficios y desafíos, y su selección adecuada requiere un enfoque sistemático y multidimensional. Aunque los métodos de ADM proporcionan un marco robusto para evaluar y comparar estas tecnologías en función de múltiples criterios, incluyendo eficiencia energética, impacto ambiental, viabilidad técnica y económica, presentan varias limitaciones, como la subjetividad en la asignación de pesos a los criterios y la falta de enfoques integrados que combinen diferentes métodos para capturar todas las dimensiones relevantes de la toma de decisiones. Además, la integración de métodos de proyección de RSM es crucial para reducir la incertidumbre en la evaluación de alternativas, proporcionando estimaciones precisas y confiables de la generación futura de residuos. Estos métodos ayudan a planificar y dimensionar adecuadamente las tecnologías de tratamiento, asegurando que las soluciones adoptadas sean sostenibles y eficientes a largo plazo. En este contexto, la necesidad de desarrollar una herramienta metodológica integral que supere algunas de las limitaciones de los enfoques actuales y proporcione una evaluación holística y robusta de las alternativas de valorización energética se vuelve evidente, por lo cual surge la siguiente pregunta de investigación: *¿Cómo diseñar una herramienta metodológica para la evaluación integral de alternativas de valorización energética de los RSM que permita una toma de decisiones más efectiva y sostenible?*

Explorar la respuesta a esta pregunta implica abordar algunas de las deficiencias de los métodos tradicionales y proponer una solución que integre múltiples criterios, reduzca la incertidumbre y facilite la selección de tecnologías de valorización energética que sean técnicas, económicas, ambientales y socialmente viables, aplicando el conocimiento generado a un caso de estudio. Por lo tanto, el objetivo de esta investigación fue diseñar una herramienta metodológica para la evaluación integral y selección de alternativas de valorización energética de los RSM. Esta herramienta se propone con la intención de superar algunas limitaciones de las metodologías actuales, proporcionando un marco unificado y robusto que integra múltiples criterios esenciales para una toma de decisiones efectiva y sostenible. El logro del objetivo se abordó mediante una estructura lógica y sistemática, planeada para construir una herramienta metodológica que luego fue aplicada a la ciudad de Sincelejo. Por lo tanto, este trabajo de investigación se esquematizó mediante capítulos que tributan a los siguientes objetivos específicos:

1. Establecer las tendencias y limitaciones de los métodos de selección de alternativas de valorización energética de RSM a partir de un análisis bibliométrico y sistemático de literatura.

2. Caracterizar los métodos para estimar el potencial técnico, económico, ambiental y energético de alternativas de valorización energética de los RSM.
3. Diseñar una metodología para desarrollar proyecciones de las tasas de disposición de los RSM.
4. Establecer un método objetivo de análisis de decisión multicriterio para evaluar integralmente las alternativas de valorización energética de los RSM.
5. Implementar una evaluación integral de alternativas de valorización energética de los RSM de la ciudad de Sincelejo.

La herramienta metodológica diseñada representa una alternativa de planeación para la gestión de residuos, planificadores urbanos, y responsables políticos un marco decisivo y adaptativo para seleccionar la opción más adecuada de valorización energética según las condiciones locales y los objetivos de sostenibilidad. Esta herramienta pretende ser un referente nacional en el campo de la gestión de residuos, impulsando la adopción de prácticas más sostenibles y eficientes.

La contribución fundamental de esta investigación se centra en el desarrollo de una metodología novedosa para la evaluación de alternativas de valorización energética de los RSM. Esta metodología se distingue por su capacidad para integrar, de manera cohesiva, diversas dimensiones de análisis —técnicas, económicas, ambientales y energéticas— que tradicionalmente no son abordadas de forma simultánea. La naturaleza innovadora de esta herramienta radica en su enfoque integral, que aborda las complejidades y las interconexiones inherentes a la gestión sostenible de residuos. En términos de la novedad del aporte se destaca:

- *Integración de múltiples disciplinas:* A diferencia de los enfoques convencionales, la herramienta propuesta en este estudio une criterios técnicos, económicos, ambientales y energéticos en un único marco evaluativo. Esto permite una visión más completa y equilibrada de las tecnologías de valorización energética, buscando garantizar su sostenibilidad en el tiempo.
- *Flexibilidad y adaptabilidad:* La metodología diseñada es adaptable a diferentes contextos geográficos y socioeconómicos, lo que permite su aplicación en diversas realidades municipales, regionales y nacionales. Esta flexibilidad asegura que las decisiones tomadas sean pertinentes y efectivas en el ámbito local, considerando factores como las políticas públicas o incentivos tributarios.
- *Enfoque proactivo en la formulación de políticas:* La herramienta metodológica propone un enfoque proactivo para la formulación de políticas, al ofrecer datos cuantitativos que pueden guiar la creación de regulaciones, incentivos y programas que fomenten prácticas de gestión de residuos más sostenibles y eficientes.

Adicionalmente, el desarrollo de esta herramienta aporta al cuerpo teórico de la gestión de residuos y la valorización energética, proveyendo un nuevo modelo que puede ser utilizado como referencia en futuras investigaciones y desarrollos en el campo. En términos prácticos, la implementación de esta metodología tiene el potencial de transformar la gestión de residuos a nivel nacional. Al facilitar la selección de tecnologías de valorización energética más adecuadas y sostenibles, la herramienta puede contribuir a la reducción de la dependencia de rellenos sanitarios convencionales, la mitigación de emisiones de gases de efecto invernadero, y la promoción de la economía circular. Finalmente, este estudio ofrece análisis valiosos para la planificación urbana y la formulación de políticas ambientales. Al proporcionar un entendimiento más profundo de las interacciones entre tecnologías de valorización energética y sus impactos ambientales, facilitando la integración de la gestión de residuos en estrategias con mayor potencial de desarrollo sostenible.

Referencias

- Abdella Ahmed, A. K., Ibraheem, A. M., & Abd-Ellah, M. K. (2022). Forecasting of municipal solid waste multi-classification by using time-series deep learning depending on the living standard. *Results in Engineering*, 16. <https://doi.org/10.1016/j.rineng.2022.100655>
- Ahmad, S. I., Ho, W. S., Hassim, M. H., Elagroudy, S., Abdul Kohar, R. A., Bong, C. P. C., Hashim, H., & Rashid, R. (2020). Development of quantitative SHE index for waste to energy technology selection. *Energy*, 191. <https://doi.org/10.1016/j.energy.2019.116534>
- Alao, M. A., Ayodele, T. R., Ogunjuyigbe, A. S., & Popoola, O. M. (2020). Multi-criteria decision based waste to energy technology selection using entropy-weighted TOPSIS technique: The case study of Lagos, Nigeria. *Energy*, 201. <https://doi.org/10.1016/j.energy.2020.117675>
- Alao, M. A., Popoola, O. M., & Ayodele, T. R. (2022). A novel fuzzy integrated MCDM model for optimal selection of waste-to-energy-based-distributed generation under uncertainty: A case of the City of Cape Town, South Africa. *Journal of Cleaner Production*, 343. <https://doi.org/10.1016/j.jclepro.2022.130824>
- Aracil, C., Haro, P., Fuentes-Cano, D., & Gómez-Barea, A. (2018). Implementation of waste-to-energy options in landfill-dominated countries: Economic evaluation and GHG impact. *Waste Management*, 76, 443-456. <https://doi.org/10.1016/j.wasman.2018.03.039>
- Arena, U., Ardolino, F., & Di Gregorio, F. (2015). A life cycle assessment of environmental performances of two combustion- and gasification-based waste-to-energy technologies. *Waste Management*, 41, 60-74. <https://doi.org/10.1016/j.wasman.2015.03.041>

- Baltussen, R., Marsh, K., Thokala, P., Diaby, V., Castro, H., Cleemput, I., Garau, M., Iskrov, G., Olyaeemanesh, A., Mirelman, A., Mobinizadeh, M., Morton, A., Tringali, M., van Til, J., Valentim, J., Wagner, M., Youngkong, S., Zah, V., Toll, A., . . . Broekhuizen, H. (2019). Multicriteria Decision Analysis to Support Health Technology Assessment Agencies: Benefits, Limitations, and the Way Forward. *Value in Health*, 22(11), 1283-1288. <https://doi.org/10.1016/j.jval.2019.06.014>
- Cudjoe, D., & Acquah, P. M. (2021). Environmental impact analysis of municipal solid waste incineration in African countries. *Chemosphere*, 265. <https://doi.org/10.1016/j.chemosphere.2020.129186>
- El Kourdi, S., Aboudaoud, S., Abderafi, S., Cheddadi, A., & Ammar, A. (2023). Pyrolysis Technology Choice to Produce Bio-oil, from Municipal Solid Waste, Using Multi-criteria Decision-making Methods. *Waste and Biomass Valorization*, 14(11), 3705-3722. <https://doi.org/10.1007/s12649-023-02076-w>
- Fernández-González, J. M., Grindlay, A. L., Serrano-Bernardo, F., Rodríguez-Rojas, M. I., & Zamorano, M. (2017). Economic and environmental review of Waste-to-Energy systems for municipal solid waste management in medium and small municipalities. *Waste Management*, 67, 360-374. <https://doi.org/10.1016/j.wasman.2017.05.003>
- Gołębiewski, J., Takala, J., Juszczak, O., & Drejerska, N. (2019). Local contribution to circular economy. A case study of a Polish rural municipality. *Economia Agro-Alimentare*, 21(3), 771-791. <https://doi.org/10.3280/ECAG2019-003011>
- IEA. (2023). Electricity generation by source. <https://www.iea.org/data-and-statistics/data-tools/energy-statistics-data-browser?country=WORLD%5C&fuel=Energy%5C%20supply%5C&indicator=ElecGenByFuel>
- IEA. (2024). Energy Prices. <https://www.iea.org/data-and-statistics/data-product/energy-prices#overview>
- IEA Bioenergy. (2018). Gasification of waste for energy carriers - a review. <https://www.ieabioenergy.com/blog/publications/gasification-of-waste-for-energy-carriers-a-review/>
- Kaneesamkandi, Z., Ur-Rehman, A., & Usmani, Y. (2023). Selection of Ideal MSW Incineration and Utilization Technology Routes Using MCDA for Different Waste Utilization Scenarios and Variable Conditions. *Processes*, 11(7). <https://doi.org/10.3390/pr11071921>
- Kaur, J., Parmar, K. S., & Singh, S. (2023). Autoregressive models in environmental forecasting time series: a theoretical and application review. *Environmental Science and Pollution Research*, 30(8), 19617-19641. <https://doi.org/10.1007/s11356-023-25148-9>

- Kaza, S., Yao, L. C., Bhada-Tata, P., & Van Woerden, F. (2018, septiembre). *What a Waste 2.0: A Global Snapshot of Solid Waste Management to 2050*. Washington, DC: World Bank. <https://doi.org/10.1596/978-1-4648-1329-0>
- Kim, H., Park, S., & Kim, S. (2023). Time-series clustering and forecasting household electricity demand using smart meter data. *Energy Reports*, 9, 4111-4121. <https://doi.org/10.1016/j.egyr.2023.03.042>
- Kocak, E., & Baglitasi, H. H. (2022). The path to sustainable municipal solid waste management: Do human development, energy efficiency, and income inequality matter? *Sustainable Development*, 30(6), 1947-1962. <https://doi.org/10.1002/sd.2361>
- Lassesson, H., Fedje, K. K., & Steenari, B.-M. (2014). Leaching for recovery of copper from municipal solid waste incineration fly ash: Influence of ash properties and metal speciation. *WASTE MANAGEMENT & RESEARCH*, 32(8), 755-762. <https://doi.org/10.1177/0734242X14542147>
- Lin, X., Yan, M., Dai, A., Zhan, M., Fu, J., Li, X., Chen, T., Lu, S., Buekens, A., & Yan, J. (2015). Simultaneous suppression of PCDD/F and NO_x during municipal solid waste incineration. *Chemosphere*, 126, 60-66. <https://doi.org/10.1016/j.chemosphere.2015.02.005>
- Liu, Y., Liao, C., Tang, Y., Tang, J., Sun, Y., & Ma, X. (2022). Techno-environmental-economic evaluation of the small-scale municipal solid waste (MSW) gasification-based and incineration-based power generation plants. *Journal of the Taiwan Institute of Chemical Engineers*, 141. <https://doi.org/10.1016/j.jtice.2022.104594>
- Liu, Z. (2019). Gasification of municipal solid wastes: a review on the tar yields. *Energy Sources, Part A: Recovery, Utilization and Environmental Effects*, 41(11), 1296-1304. <https://doi.org/10.1080/15567036.2018.1548508>
- Lohani, S., & Havukainen, J. (2018). *Anaerobic Digestion: Factors Affecting Anaerobic Digestion Process*. https://doi.org/10.1007/978-981-10-7413-4_18
- Otero Meza, D. D., Sagastume Gutiérrez, A., Cabello Eras, J. J., Salcedo Mendoza, J., & Hernández Ruydiaz, J. (2023). Techno-economic and environmental assessment of the landfill gas to energy potential of major Colombian cities. *Energy Conversion and Management*, 293, 117522. <https://doi.org/10.1016/j.enconman.2023.117522>
- Paulauskaite-Taraseviciene, A., Raudonis, V., & Sutiene, K. (2022). Forecasting municipal solid waste in Lithuania by incorporating socioeconomic and geographical factors. *Waste Management*, 140, 31-39. <https://doi.org/10.1016/j.wasman.2022.01.004>
- Qazi, W., Abushammala, M., & Azam, M.-H. (2018). Multi-criteria decision analysis of waste-to-energy technologies for municipal solid waste management in Sultanate of Oman. *Waste Management and Research*, 36(7), 594-605. <https://doi.org/10.1177/0734242x18777800>

- Shi, Y., Li, Y., Yuan, X., Fu, J., Ma, Q., & Wang, Q. (2020). Environmental and human health risk evaluation of heavy metals in ceramsites from municipal solid waste incineration fly ash. *ENVIRONMENTAL GEOCHEMISTRY AND HEALTH*, 42(11), 3779-3794. <https://doi.org/10.1007/s10653-020-00639-7>
- Silva, L. J. d. V. B. d., Santos, I. F. S. d., Mensah, J. H. R., Gonçalves, A. T. T., & Barros, R. M. (2020). Incineration of municipal solid waste in Brazil: An analysis of the economically viable energy potential. *Renewable Energy*, 149, 1386-1394. <https://doi.org/10.1016/j.renene.2019.10.134>
- Sohoo, I., Ritzkowski, M., Guo, J., Sohoo, K., & Kuchta, K. (2022). Municipal Solid Waste Management through Sustainable Landfilling: In View of the Situation in Karachi, Pakistan. *International Journal of Environmental Research and Public Health*, 19(2). <https://doi.org/10.3390/ijerph19020773>
- Sun, Y., Qin, Z., Tang, Y., Huang, T., Ding, S., & Ma, X. (2021). Techno-environmental-economic evaluation on municipal solid waste (MSW) to power/fuel by gasification-based and incineration-based routes. *Journal of Environmental Chemical Engineering*, 9(5). <https://doi.org/10.1016/j.jece.2021.106108>
- Sununta, N., Sedpho, S., & Sampattagul, S. (2018). City carbon footprint evaluation and forecasting case study: Dan Sai municipality. *Chemical Engineering Transactions*, 63, 277-282. <https://doi.org/10.3303/CET1863047>
- Tamasila, M., Prostean, G., Ivascu, L., Cioca, L.-I., Draghici, A., & Diaconescu, A. (2020). Evaluating and prioritizing municipal solid waste management-related factors in Romania using fuzzy AHP and TOPSIS. *JOURNAL OF INTELLIGENT & FUZZY SYSTEMS*, 38(5), 6111-6127. <https://doi.org/10.3233/JIFS-179695>
- Tsui, T.-H., & Wong, J. (2019). A critical review: emerging bioeconomy and waste-to-energy technologies for sustainable municipal solid waste management. *Waste Disposal and Sustainable Energy*, 1(3), 151-167. <https://doi.org/10.1007/s42768-019-00013-z>
- Uhde, B., Andreas Hahn, W., Griess, V. C., & Knoke, T. (2015). Hybrid MCDA Methods to Integrate Multiple Ecosystem Services in Forest Management Planning: A Critical Review. *Environmental Management*, 56(2), 373-388. <https://doi.org/10.1007/s00267-015-0503-3>
- Ukpanyang, D., Terrados-Cepeda, J., & Hermoso-Orzaez, M. J. (2022). Multi-Criteria Selection of Waste-to-Energy Technologies for Slum/Informal Settlements Using the PROMETHEE Technique: A Case Study of the Greater Kuru Urban Area in Nigeria. *Energies*, 15(10), 3481. <https://doi.org/10.3390/en15103481>
- U.S. EPA. (2023). IPCC AR4, AR5, and AR6 20-, 100-, and 500-year GWPs. <https://catalog.data.gov/dataset/ipcc-ar4-ar5-and-ar6-20-100-and-500-year-gwps>
- Uyan, M. (2014). MSW landfill site selection by combining AHP with GIS for Konya, Turkey. *Environmental Earth Sciences*, 71(4), 1629-1639. <https://doi.org/10.1007/s12665-013-2567-9>

- Van Fan, Y., Klemeš, J. J., Lee, C. T., & Perry, S. (2019). GHG emissions of incineration and anaerobic digestion: Electricity mix. *Chemical Engineering Transactions*, 72, 145-150. <https://doi.org/10.3303/CET1972025>
- Van Thanh, N. (2022). Optimal Waste-to-Energy Strategy Assisted by Fuzzy MCDM Model for Sustainable Solid Waste Management. *Sustainability (Switzerland)*, 14(11). <https://doi.org/10.3390/su14116565>
- Velis, C. A., Wilson, D. C., Gavish, Y., Grimes, S. M., & Whiteman, A. (2023). Socio-economic development drives solid waste management performance in cities: A global analysis using machine learning. *Science of The Total Environment*, 872, 161913. <https://doi.org/10.1016/j.scitotenv.2023.161913>
- Vlachokostas, C., Michailidou, A. V., & Achillas, C. (2021). Multi-Criteria Decision Analysis towards promoting Waste-to-Energy Management Strategies: A critical review. *Renewable and Sustainable Energy Reviews*, 138. <https://doi.org/10.1016/j.rser.2020.110563>
- Vlaskin, M. S. (2018). Municipal solid waste as an alternative energy source. *Proceedings of the Institution of Mechanical Engineers, Part A: Journal of Power and Energy*, 232(8), 961-970. <https://doi.org/10.1177/0957650918762023>
- Wei, J., Li, H., & Liu, J. (2022). Curbing dioxin emissions from municipal solid waste incineration: China's action and global share. *Journal of Hazardous Materials*, 435, 129076. <https://doi.org/10.1016/j.jhazmat.2022.129076>
- Wen, C., Lin, X., Ying, Y., Ma, Y., Yu, H., Li, X., & Yan, J. (2023). Dioxin emission prediction from a full-scale municipal solid waste incinerator: Deep learning model in time-series input. *Waste Management*, 170, 93-102. <https://doi.org/10.1016/j.wasman.2023.08.004>
- World Bank. (2019a). City level dataset. <https://datacatalog.worldbank.org/search/dataset/0039597/What-a-Waste-Global-Database>
- World Bank. (2019b). Solid Waste Management. <https://www.worldbank.org/en/topic/urbandevelopment/brief/solid-waste-management>
- Xu, L., Gao, P., Cui, S., & Liu, C. (2013). A hybrid procedure for MSW generation forecasting at multiple time scales in Xiamen City, China. *Waste Management*, 33(6), 1324-1331. <https://doi.org/10.1016/j.wasman.2013.02.012>
- Yaashikaa, P. R., Kumar, P. S., Nhung, T. C., Hemavathy, R. V., Jawahar, M. J., Neshaanthini, J. P., & Rangasamy, G. (2022). A review on landfill system for municipal solid wastes: Insight into leachate, gas emissions, environmental and economic analysis. *Chemosphere*, 309, 136627. <https://doi.org/10.1016/J.CHEMOSPHERE.2022.136627>
- Yin, L.-J., Wang, C., Hu, Y.-Y., Chen, D.-Z., Xu, J.-F., & Liu, J. (2017). AHP-based approach for optimization of waste disposal method in urban functional zone. *Environmental Technology (United Kingdom)*, 38(13–14), 1689-1695. <https://doi.org/10.1080/09593330.2016.1244565>

Capítulo 1

Métodos de Selección de Alternativas de Conversión de RSMaE: Estatus y Retos

Resumen del capítulo: Este capítulo evalúa los métodos de ADM para la valorización energética de RSM, destacando su importancia y limitaciones. El análisis bibliométrico identifica tendencias hacia la sostenibilidad, la eficiencia energética y la modelización. La revisión sistemática de literatura revela la aplicación de AHP, TOPSIS y métodos híbridos para la selección de tecnologías de conversión de RSMaE. Se identifican limitaciones como la subjetividad en la asignación de pesos, la complejidad computacional y la falta de pronósticos de residuos, resaltando la necesidad de métodos más robustos y adaptables.

Palabras clave – Análisis de Decisión Multicriterio; Valorización energética; Revisión sistemática; Sostenibilidad; Gestión de residuos.

1.1. Introducción

La correcta implementación de alternativas de RSMaE es crucial para abordar los desafíos ambientales y energéticos contemporáneos (Unidad de Planeación Minero Energética (UPME) & INERCO Consultoría Colombia, 2018; World Bank, 2019). Los RSM representan una fuente importante de contaminación si no se gestionan adecuadamente, y la creciente generación de residuos en las áreas urbanas subraya la necesidad de soluciones sostenibles (Kaza et al., 2018). Las rutas tecnológicas de conversión de RSMaE ofrecen una doble ventaja: por un lado, contribuye a la reducción del volumen de residuos enviados a los rellenos sanitarios, disminuyendo así los impactos ambientales

negativos asociados con la disposición final; por otro lado, permite la recuperación de energía, proporcionando una fuente adicional de energía renovable, contribuyendo a la diversificación de la matriz energética local. No obstante, la implementación efectiva de tecnologías de conversión de RSMaE requiere una evaluación exhaustiva y rigurosa de las alternativas disponibles para asegurar que se seleccionen las soluciones más adecuadas desde una perspectiva técnica, energética, económica, y ambiental (Antonopoulos et al., 2014). La variabilidad en la composición de los residuos, las condiciones locales y las expectativas de la comunidad son factores que complican esta tarea, haciendo indispensable el uso de metodologías de evaluación robustas y sistemáticas (AlQattan et al., 2018).

En este contexto, los métodos de ADM ha emergido como una herramienta estratégica para la selección de alternativas de valorización energética de RSM. Estos permiten la integración de múltiples criterios en el proceso de toma de decisiones, proporcionando una evaluación más holística y equilibrada de las opciones disponibles (AlNouss et al., 2024; Martínez López et al., 2023). La principal ventaja del ADM es su capacidad para manejar y sintetizar información diversa y compleja, facilitando así decisiones que consideran, entre otros, aspectos técnicos, energéticos, económicos y ambientales de manera integrada (El Kourdi et al., 2023). En estudios recientes, se ha demostrado que el ADM es particularmente efectivo para manejar la incertidumbre y variabilidad inherentes a la gestión de residuos, utilizando enfoques avanzados como los conjuntos difusos y la optimización multiobjetivo (Luo et al., 2020; Tamasila et al., 2020). Esta capacidad para adaptar y aplicar múltiples criterios a escenarios complejos hace que el ADM sea una herramienta esencial para la planificación y gestión sostenible de los sistemas de conversión de RSMaE.

Al comparar cualitativamente los principales métodos de ADM reportados en la literatura, se observa una diversidad de enfoques que reflejan la flexibilidad y adaptabilidad de estas herramientas. El método AHP (Yin et al., 2017) es ampliamente utilizado por su capacidad para descomponer un problema complejo en una jerarquía de subproblemas más manejables, facilitando así la asignación de pesos y la comparación de alternativas a través de comparaciones por pares, aunque el grado de subjetividad del cálculo de los pesos de los criterios le confiere un sesgo relativo al nivel de experiencia y asertividad de los encuestados. El método TOPSIS (Z. Li et al., 2022) es valorado por su enfoque en identificar soluciones que se aproximan más a una solución ideal y se alejan de una solución no ideal, proporcionando un marco claro para la evaluación de alternativas. Otros métodos, como el ELECTRE (Uhde et al., 2015), ofrecen ventajas específicas en términos de robustez frente a la variabilidad de los datos y la capacidad para manejar grandes conjuntos de datos y criterios conflictivos. La elección del método de ADM más adecuado depende en gran medida del contexto específico y de las características del problema a resolver, así como de las preferencias y prioridades de los tomadores de decisiones.

No obstante, es importante establecer las tendencias y limitaciones de estos métodos ADM con el objetivo de identificar oportunidades de contribución al cuerpo del conocimiento. Por eso, el objetivo de este capítulo es estudiar las tendencias de aplicación de los métodos de ADM e identificar sus principales limitaciones. Para esto se desarrolla una búsqueda en bases de datos de reconocido prestigio y se analizan: (i) los metadatos mediante bibliometría, y (ii) se aplica un proceso de revisión sistemática para encontrar los estudios más relevantes y establecer los principales antecedentes de investigación. Posteriormente, se plantean las limitaciones de los métodos ADM implementados de acuerdo con el análisis de los resultados obtenidos.

1.2. Vigilancia Científica

1.2.1. Análisis de coocurrencias de palabras clave

El análisis de coocurrencia de palabras clave es una herramienta valiosa para identificar tendencias de investigación en áreas específicas del conocimiento, permitiendo a los investigadores y profesionales entender la evolución y las interconexiones temáticas dentro de un campo determinado (H. Li et al., 2016). Este análisis se basa en la recopilación y el procesamiento de grandes volúmenes de datos bibliográficos, donde se examinan las frecuencias y las relaciones entre palabras clave que aparecen juntas en publicaciones científicas. Para estimar los parámetros del análisis, se utilizan técnicas de minería de textos y algoritmos de red, que incluyen la construcción de matrices de coocurrencia y la aplicación de medidas de asociación como el índice de Jaccard o el coeficiente de correlación. Estas matrices se transforman en grafos donde los nodos representan las palabras clave y las aristas indican la fuerza de su coocurrencia, permitiendo identificar clústeres de términos que suelen aparecer juntos, revelando así temas de investigación emergentes y bien establecidos.

La aplicación de este análisis es particularmente importante en el área de métodos de selección multicriterio de alternativas de conversión de RSMaE (Boloy et al., 2021), un campo que se centra en la evaluación y optimización de diferentes tecnologías y procesos para convertir RSM en energía útil. En este contexto, el análisis de coocurrencia de palabras clave no solo ayuda a mapear el paisaje actual de la investigación, sino también a identificar qué metodologías y criterios son más relevantes y cómo se interrelacionan. Por ejemplo, al analizar la coocurrencia de términos como “*bioenergy*”, “*sustainability*”, “*MCDA*” (multi-criteria decision analysis), y “*waste management*”, los investigadores pueden identificar qué enfoques y tecnologías son más frecuentemente investigados y cómo se alinean con los objetivos de sostenibilidad y eficiencia.

Además, este análisis proporciona una base sólida para la toma de decisiones informadas al resaltar las áreas con mayor densidad de investigación y citación, lo cual es crucial para priorizar proyectos y enfoques dentro del ámbito de valorización energética de los RSM. Al identificar los temas y métodos que están en el centro del debate académico, los responsables de políticas y los investigadores pueden enfocar sus esfuerzos en las áreas más prometedoras y con mayor impacto potencial. Esto no solo facilita la transferencia de conocimiento y tecnología, sino que también mejora la eficiencia en la asignación de recursos y el diseño de políticas públicas, contribuyendo al desarrollo de soluciones más sostenibles y efectivas para la gestión de residuos y la producción de energía.

La Figura 1.1 muestra un diagrama de coocurrencias entre las principales palabras clave obtenidas mediante Scopus con la ecuación de búsqueda: “(TITLE (*selection OR criteria OR decision*) AND TITLE-ABS-KEY (*waste-to-energy OR energy OR bioenergy*)) AND PUBYEAR >2018 AND PUBYEAR <2025 AND (LIMIT-TO (DOCTYPE , “ar”)) AND (LIMIT-TO (LANGUAGE , “English”))”.

La Figura 1.1 proporciona una herramienta útil en el análisis de interrelación entre diferentes campos de estudio. Este análisis se puede desarrollar por cada clúster y luego de forma general:

- Clúster 3 (FTE: 1132): incluye palabras clave principales como “*bioenergy*”, “*bio-mass*”, “*renewable energy*”, “*sustainability*”, “*waste management*” y “*multi-criteria decision analysis*”. La presencia de estas palabras clave sugiere que este clúster está centrado en temas relacionados con la valorización de residuos para la producción de energía renovable, específicamente bioenergía. Esto implica investigaciones sobre cómo convertir la biomasa en energía de manera sostenible, abarcando aspectos de gestión de residuos y eficiencia energética. La integración del ADM en estas investigaciones permite evaluar y priorizar diferentes rutas de producción de bioenergía, considerando múltiples criterios como el impacto ambiental, la viabilidad económica y la eficiencia energética. Este clúster refleja un área del conocimiento donde se exploran diversas rutas para aprovechar residuos orgánicos y materiales de desecho en la producción de energía limpia, contribuyendo a la sostenibilidad ambiental y la reducción de dependencia en combustibles fósiles. La alta frecuencia de coocurrencia de estas palabras clave indica un interés común y continuo en mejorar las tecnologías y métodos relacionados con la bioenergía, incluyendo la optimización de procesos y la evaluación de impactos ambientales mediante el uso del ADM para tomar decisiones informadas y equilibradas.
- Clúster 1 (FTE: 1113): incluye palabras clave como “*ahp*”, “*analytic hierarchy process*”, “*multi-criteria decision making*”, “*decision support systems*”, “*supply chain management*”, y “*MCDA*”. Este clúster está enfocado en métodos de análisis multicriterio y su aplicación en la toma de decisiones complejas, especialmente

- Clúster 5 (FTE: 630): incluye palabras clave como “*machine learning*”, “*artificial intelligence*”, “*big data*”, “*predictive analytics*”, “*data mining*”, y “*MCDA*”. Este clúster está claramente centrado en el área de tecnologías de la información y análisis de datos, particularmente en el uso de técnicas de aprendizaje automático y análisis predictivo. La inclusión del ADM en este clúster indica la aplicación de métodos multicriterio en la interpretación y utilización de grandes volúmenes de datos, optimizando la toma de decisiones basada en datos, mejorando la precisión de las predicciones y optimizando operaciones en diversos campos, desde la industria hasta la ciencia de datos.
- Clúster 2 (FTE: 562): Incluye palabras clave como “*hydrogen*”, “*fuel cells*”, “*renewable energy systems*”, “*energy storage*”, “*sustainable development*”, y “*MCDA*”. Este clúster está orientado hacia la investigación en tecnologías de hidrógeno y sistemas de energía renovable, subrayando su importancia en el desarrollo de soluciones sostenibles de almacenamiento y producción de energía. La aplicación del ADM en este clúster permite evaluar la viabilidad de diferentes tecnologías de hidrógeno y sistemas de almacenamiento de energía, considerando múltiples criterios como la eficiencia, el costo, la sostenibilidad y el impacto ambiental, promoviendo un desarrollo energético más limpio y sostenible.
- Clúster 4 (FTE: 382): incluye palabras clave como “*biogas*”, “*anaerobic digestion*”, “*organic waste*”, “*waste to energy*”, “*circular economy*”, y “*MCDA*”. Este clúster se enfoca en la conversión de residuos orgánicos en biogás a través de la digestión anaeróbica, y su integración en la economía circular. La utilización del ADM en este clúster permite evaluar diferentes tecnologías y procesos de conversión de residuos, optimizando la producción de energía y minimizando el impacto ambiental, contribuyendo a la reducción de desechos y la generación de energía renovable.
- Clúster 6 (FTE: 279): Incluye palabras clave como “*lca*”, “*life cycle assessment*”, “*environmental impact*”, “*sustainability assessment*”, “*eco-efficiency*”, y “*MCDA*”. Este clúster está centrado en la evaluación del ciclo de vida y la evaluación de impacto ambiental de productos y procesos. La inclusión del ADM en este clúster sugiere un enfoque hacia la medición y mejora de la sostenibilidad y la eficiencia ecológica, permitiendo evaluar y comparar diferentes opciones tecnológicas y operacionales en términos de su impacto ambiental y sostenibilidad, promoviendo prácticas más sostenibles en diversos sectores industriales y productivos.

La fortaleza total de enlaces de un clúster es una medida crítica que indica la cohesión y relevancia de un grupo de palabras clave en el contexto de investigación. Un clúster con alta fortaleza total de enlaces, como el clúster 3 (1132) y el clúster 1 (1113), sugiere una red muy interconectada y central para el campo de estudio. Estos clústeres no solo

muestran una alta frecuencia de coocurrencia de palabras clave, sino también un alto nivel de citaciones mutuas entre los estudios que las utilizan. Por un lado, el clúster 3, con palabras clave como “*bioenergy*”, “*biomass*” y “*MCDA*”, destaca la importancia de la investigación en energías renovables y la gestión sostenible de residuos. Este clúster refleja áreas maduras y bien establecidas en el campo, donde los investigadores colaboran y se citan extensivamente, reforzando su centralidad y relevancia. La inclusión del ADM en este clúster indica un enfoque integral y multidimensional para evaluar y optimizar procesos de bioenergía, considerando múltiples criterios para tomar decisiones equilibradas y sostenibles. Por otro lado, clústeres con menor fortaleza de enlaces, como el clúster 6 (279) y el clúster 4 (382), aunque menos prominentes, representan nichos importantes y áreas emergentes de investigación. Estos clústeres pueden estar en etapas iniciales de desarrollo o tratar temas muy especializados que, aunque menos citados, son esenciales para ciertos avances científicos y tecnológicos. La fortaleza de enlace menor no disminuye su importancia; de hecho, indica áreas con potencial de crecimiento e innovación. La aplicación del ADM en estos clústeres permite evaluar y priorizar tecnologías emergentes y procesos innovadores, optimizando su desarrollo y aplicación en contextos específicos.

La comparación de la fortaleza total de enlaces entre los clústeres resalta una jerarquía temática dentro del campo de estudio. Clústeres con alta fortaleza, como el clúster 3 y el clúster 1, no solo indican áreas de alta actividad y cohesión, sino también subcampos con mayor influencia en el desarrollo del conocimiento. Clústeres con fortaleza menor, aunque menos influyentes en términos generales, representan áreas donde la investigación está avanzando y que pueden ser críticas para futuras innovaciones. La fortaleza total de enlaces proporciona una visión profunda de la estructura y dinámica del campo de investigación, destacando tanto las áreas establecidas como los nichos emergentes, y ofreciendo una comprensión holística de la interconexión temática y la evolución del conocimiento. La aplicación del ADM en estos clústeres resalta su importancia para la toma de decisiones informadas y equilibradas en diversas áreas de investigación y desarrollo tecnológico.

Por otro lado, la tendencia de publicación y ocurrencia de las palabras clave permite analizar el interés reciente de las investigaciones en el área de estudio. La [Figura 1.2](#) revela las principales tendencias de investigación en el área de estudio basadas en un análisis de ocurrencias. Por un lado, el clúster 1 se centra en la energía renovable y las metodologías ADM, destacando palabras clave como “*renewable energy*”, “*TOPSIS*”, “*multi-criteria decision making*”, “*MCDM*”, y “*multi-criteria decision-making*”. Este clúster refleja un enfoque en la evaluación y selección de alternativas en proyectos de energía renovable, cruciales para mitigar el cambio climático y reducir la dependencia de combustibles fósiles. Las técnicas de decisión multicriterio, como TOPSIS, se utilizan para evaluar diferentes alternativas energéticas basadas en criterios como costo, eficiencia e impacto ambiental. La integración de MCDM en la planificación de proyectos

de energía renovable permite considerar factores socioeconómicos y ambientales, promoviendo decisiones equilibradas y sostenibles. La palabra clave “*renewable energy*” resalta la importancia de fuentes como solar, eólica, hidráulica y biomasa, asociados a la sostenibilidad.




Figura 1.2: Año promedio de ocurrencia de palabras clave por clúster. Fuente: elaboración propia. Software empleado: SCIImago Graphica

El clúster 2 agrupa palabras clave como “*decision-making*”, “*site selection*”, “*GIS*”, “*solar energy*”, y “*multi-criteria decision analysis*”, destacando la importancia de decisiones informadas y basadas en datos para la selección de ubicaciones y planificación de proyectos de energía solar. La selección de sitios es crucial en la implementación de proyectos de energía renovable, donde factores como recursos disponibles, condiciones ambientales e infraestructura existente juegan un papel vital. La integración de Sistemas de Información Geográfica (GIS) con metodologías de ADM es una tendencia clave, facilitando la evaluación de criterios geográficos y ambientales en la selección de

sitios. “*Solar energy*” subraya la relevancia de la energía solar, una fuente de energía renovable ampliamente adoptada. La identificación de sitios óptimos para instalaciones solares maximiza la eficiencia y sostenibilidad de estos proyectos. “*Multi-criteria decision analysis*” resalta la necesidad de métodos robustos para decisiones complejas, permitiendo evaluar y equilibrar diferentes criterios y preferencias. En resumen, el clúster 2 refleja la integración de herramientas avanzadas como GIS y ADM en la selección de sitios y planificación de proyectos de energía solar, optimizando ubicación y diseño y contribuyendo a un sistema energético más sostenible y resiliente.

El clúster 3, con palabras clave como “*waste management*”, “*circular economy*”, “*sustainable development*”, “*LCA (Life Cycle Assessment)*”, y “*environmental impact*”, refleja la importancia creciente de la gestión de residuos y la economía circular en la sostenibilidad ambiental. La gestión de residuos es fundamental para la economía circular, que busca minimizar la generación de residuos y maximizar la reutilización y el reciclaje. El Análisis del Ciclo de Vida (ACV) o LCA (por las siglas en inglés de *Life Cycle Assessment*) es crucial para analizar los impactos ambientales de productos y procesos a lo largo de su ciclo de vida, identificando áreas para mejorar la sostenibilidad. “*Circular economy*” destaca un enfoque sistémico para gestionar recursos, promoviendo la reutilización y reciclaje en contraste con el modelo lineal tradicional. “*Sustainable development*” enfatiza equilibrar el crecimiento económico, la inclusión social y la protección ambiental. “*Environmental impact*” es vital para mitigar efectos negativos de actividades humanas en el entorno.

El clúster 4 incluye palabras clave como “*energy policy*”, “*bioenergy*”, “*energy efficiency*”, “*renewable resources*”, y “*energy systems*”, destacando la importancia de las políticas energéticas y la gestión de recursos renovables en la transición hacia un sistema energético sostenible. “*Energy policy*” refleja los esfuerzos gubernamentales para promover la adopción de tecnologías limpias y prácticas sostenibles, mediante subsidios, impuestos y normativas. “*Bioenergy*” destaca el uso de biomasa como fuente renovable, ofreciendo soluciones sostenibles para generar biocombustibles y bioelectricidad. La investigación en bioenergía abarca la producción y conversión de biomasa, evaluando impactos ambientales y socioeconómicos. “*Energy efficiency*” subraya la importancia de optimizar el uso de energía, reduciendo el consumo y las emisiones de carbono. “*Renewable resources*” y “*energy systems*” enfatizan la necesidad de gestionar recursos renovables y diseñar sistemas integrados que maximicen la energía limpia.

El clúster 5, con palabras clave como “*energy planning*”, “*biomass*”, “*climate change*”, “*resource management*”, y “*energy transition*”, destaca la planificación energética y la gestión de recursos para facilitar la transición hacia un sistema energético sostenible. “*Energy planning*” es vital para desarrollar estrategias a largo plazo que guíen proyectos energéticos, considerando aspectos económicos, ambientales y sociales. “*Biomass*” se refiere al uso de materiales orgánicos como fuente de energía, con investigaciones enfocadas en tecnologías sostenibles y evaluación de impactos. Esto incluye a los residuos

biodegradables al igual que a los lignocelulósicos. “*Climate change*” resalta la urgencia de mitigar el cambio climático mediante la adopción de energías renovables. “*Resource management*” y “*Energy transition*” subrayan la gestión eficiente y enfoque en recursos naturales renovables para optimizar su uso y reducir impactos ambientales.

El clúster 6, con palabras clave como “*sustainability*”, “*energy management*”, “*energy storage*”, “*decision support*”, y “*decision support system*”, subraya la importancia de la sostenibilidad y los sistemas de apoyo a la decisión en la gestión energética. “*Sustainability*” refleja un enfoque multidimensional para desarrollar proyectos energéticos que equilibren aspectos económicos, sociales y ambientales. La investigación en sostenibilidad abarca evaluación de impactos ambientales y desarrollo de tecnologías limpias. “*Energy management*” se refiere a la optimización del uso de energía en edificios, industrias y sistemas de transporte, mejorando la eficiencia y reduciendo costos. “*Energy storage*” destaca la importancia de tecnologías de almacenamiento para mejorar la estabilidad del sistema energético y gestionar la variabilidad de fuentes renovables. “*Decision support*” y “*decision support system*” resaltan la necesidad de herramientas que faciliten la toma de decisiones informada, integrando análisis y visualización de datos.

En resumen, las principales tendencias de investigación en el ámbito de los métodos de ADM aplicados a la selección de alternativas de conversión de RSMaE destacan por su enfoque en la integración de energías renovables, la adopción de metodologías analíticas avanzadas, y la promoción de la sostenibilidad. La energía renovable, especialmente solar y biomasa, es un tema central, con estudios que abordan tanto la evaluación de su potencial como la planificación óptima de su implementación mediante herramientas como GIS. Las políticas energéticas y la eficiencia también son áreas de creciente interés, con investigaciones centradas en el desarrollo de marcos regulatorios y tecnologías que faciliten la transición hacia sistemas energéticos más limpios y eficientes. Además, la economía circular y la gestión de residuos emergen como campos vitales, con énfasis en la reutilización y el reciclaje de materiales para minimizar impactos ambientales. La sostenibilidad y los sistemas de apoyo a la decisión se integran en estos estudios, proporcionando plataformas para decisiones informadas que consideran múltiples criterios y escenarios.

1.2.2. Revisión sistemática de literatura

Conocer los antecedentes de esta investigación es crucial, especialmente cuando el objetivo consiste en conocer las limitaciones de los métodos de selección de alternativas de valorización energética de los RSM. Estos proporcionan un contexto histórico y teórico que sitúa el estudio dentro del marco existente de conocimientos, permitiendo

identificar investigaciones previas relevantes, evita la duplicación de esfuerzos y destaca brechas en el conocimiento que el nuevo análisis puede abordar, y permite establecer la relevancia y justificación del estudio al mostrar problemas persistentes o preguntas no resueltas en la selección de métodos de valorización energética.

El método de Elementos de Información Preferidos para Revisiones Sistemáticas y Metaanálisis o PRISMA (Boly et al., 2021), es una herramienta estructurada y rigurosa utilizada para realizar revisiones sistemáticas y metaanálisis. El proceso comienza con la definición clara del problema de investigación, donde se formula una pregunta específica que guiará toda la revisión, estableciendo el alcance de esta. La siguiente etapa es la búsqueda exhaustiva de literatura en las bases de datos seleccionadas utilizando palabras clave relevantes, las cuales pueden establecerse en base a la experticia de un investigador o un grupo de estos, o bien mediante retroalimentación de búsquedas iniciales que permiten perfeccionar la selección de estas palabras clave. Posteriormente, los estudios identificados son filtrados según los criterios de inclusión y exclusión, evaluando su calidad y relevancia. En este estudio, se consideraron las bases de datos reportadas en la web para excluir las revistas científicas depredadoras como criterio principal en la evaluación del riesgo de incertidumbre, en tanto que se ha identificado que las publicaciones ahí realizadas exhiben una alta inseguridad para la integridad de la literatura académica debido a la baja calidad de los procesos de revisión por pares y la falta de rigor científico en los artículos que aceptan. Los datos relevantes de los estudios seleccionados se extraen cuidadosamente, incluyendo información sobre los métodos utilizados, los criterios utilizados, y los resultados obtenidos. Posteriormente, se sintetizan los resultados extraídos, identificando lagunas en la literatura existente. Este enfoque estructurado garantiza que la revisión sea exhaustiva, objetiva y de alta calidad, proporcionando una base sólida para futuras investigaciones y decisiones informadas.

Para el caso particular de este estudio, se estableció el objetivo de la revisión sistemática como identificar los estudios en bases de datos científicas (Scopus y Web of Science) cuyos objetivos se relacionen estrechamente con la aplicación de métodos de ADM en problemas de selección de alternativas de valorización energética de RSM. Las consultas en bases de datos se realizaron teniendo en cuenta las siguientes palabras clave en las secciones del documento relacionadas, así como las siguientes restricciones:

- En el título de los documentos: *“selection OR criteria OR decision”*,
- En el título, resumen, o palabras clave de los documentos: *“waste-to-energy OR bioenergy AND ‘municipal solid waste’ AND NOT (site OR location)”*,
- Año de publicación: 2019 a 2024,
- Tipo de documento: artículo de investigación,
- Lenguaje: inglés.

La [Figura 1.3](#) muestra el diagrama de flujo que se siguió mediante la aplicación del método PRISMA para curar la base de datos de documentos obtenidos, para lo cual, se tuvo en cuenta como uno de los parámetros de calidad el riesgo de incertidumbre por debilidad de revisión por pares de la fuente, el cual fue evaluado teniendo en cuenta el tiempo que tardó el proceso de aceptación del documento para publicación desde la fecha de sometimiento, excluyendo los documentos con lapsos menores a 30 días entre estas dos fechas, considerándose un tiempo demasiado corto para completar un proceso de revisión por pares riguroso. Si bien este criterio puede resultar subjetivo para el lector, lo cual consideramos perfectamente válido, por el principio de precaución fue tenido en cuenta para evitar sesgos del proceso PRISMA.




Figura 1.3: Resumen de resultados obtenidos de la aplicación del método PRISMA. Fuente: elaboración propia, según recomendaciones de Haddaway et al. ([2022](#))

Los resultados de la revisión sistemática de literatura evidencian múltiples enfoques empleados para decisión multicriterio relacionados con la valorización energética de los RSM, así como la aplicación de métodos híbridos (i.e., combinaciones entre métodos) buscando reducir la incertidumbre del componente subjetivo que caracteriza la mayoría de las aplicaciones convencionales de los métodos de ADM. Entre los estudios obtenidos, destaca el realizado por Adenuga et al. ([2020](#)), quienes aplicaron el método AHP para evaluar y seleccionar la tecnología de conversión de RSMaE más adecuada para diferentes clases de residuos en el municipio de Western Cape, Sudáfrica. Este enfoque permitió considerar indicadores sostenibles como impacto ambiental, implicaciones socioculturales, viabilidad económica y factores técnicos. La metodología AHP se basó

en una comparación por pares expertos. Entre las tecnologías evaluadas, la digestión anaeróbica (DA) se destacó con un puntaje global del 57 %, siendo preferida por su impacto positivo en el medio ambiente, en comparación con la incineración (INC) con 24 %, la gasificación (GAS) con 13 % y la pirólisis (PYR) con 6 %. Los resultados del estudio destacaron la importancia de adoptar enfoques sistemáticos y cuantitativos para la selección de tecnologías de conversión de RSMaE.

Desde otro enfoque, Shah y Longsheng (2022) abordaron los factores que impiden el desarrollo de energías renovables en Pakistán mediante un enfoque de decisión multicriterio integrado que combina el método Delphi difuso con el Proceso Analítico Jerárquico Gris (G-AHP). Este enfoque permitió a los investigadores identificar y evaluar las barreras que afectan a las alternativas de energía renovable, incluyendo la energía solar, eólica, biomasa, geotérmica, RSM y micro-hidroeléctrica. El uso del Delphi difuso permitió seleccionar las barreras relevantes a través de la opinión de expertos, mientras que el G-AHP facilitó la ponderación de estas barreras y la evaluación de las alternativas de energía renovable bajo cada una de ellas. Los resultados del estudio revelaron que las barreras políticas y regulatorias son las más notables, seguidas de la inestabilidad política y la corrupción institucional. Entre las alternativas, la energía solar enfrentó menos barreras y, por lo tanto, se consideró la más viable para su desarrollo en Pakistán, mientras que la energía geotérmica y la generación de energía a partir de RSM enfrentaron las mayores dificultades. Este análisis subraya la importancia de aplicar métodos ADM para la selección entre alternativas energéticas.

En el estudio realizado por Isigonis et al. (2022), se introduce un enfoque de ADM que integra el método 3T con el método PROMETHEE-GAIA para evaluar plantas de conversión de RSMaE y biorrefinerías. El método 3T se basa en una evaluación termodinámica que no solo considera la eficiencia CHP producida, sino también la calidad de los materiales recuperados, como metales y productos derivados como el char y el syngas. El estudio propone el uso del método de análisis multicriterio PROMETHEE-GAIA, que permite una evaluación más holística de las plantas de conversión de RSMaE considerando múltiples criterios técnicos, económicos y ambientales. Se analizaron cinco plantas de conversión de RSMaE, y los resultados demostraron que la planta centrada en la producción de materiales obtuvo los mejores flujos netos en comparación con otras plantas evaluadas. Este enfoque integrado de ADM proporciona una herramienta importante para la toma de decisiones en la gestión de residuos y la promoción de la economía circular, permitiendo evaluar de manera ponderada las tecnologías de valorización energética y su impacto en la sostenibilidad del proyecto combinada como aprovechamiento no energético.

En el estudio realizado por Firouzi et al. (2021), se empleó un enfoque híbrido de toma de decisiones multicriterio para priorizar los recursos de biomasa más apropiados para la producción de biocombustibles en la provincia de Guilán, Irán. Los métodos ADM utilizados fueron TOPSIS, ARAS (Additive Ratio Assessment) y WASPAS (Weighted

Aggregates Sum Product Assessment). Este enfoque permitió evaluar once tipos de biomasa, incluyendo RSM, residuos de madera, desechos de aves de corral y ganado, entre otros, utilizando diez criterios de evaluación como la creación de empleos, la conservación de recursos energéticos no renovables, y los impactos ambientales de la acumulación de biomasa. Los resultados indicaron que los RSM y las aguas residuales, junto con los residuos forestales y agrícolas, fueron identificados como las fuentes de biomasa más importantes para la generación de bioenergía en la región. Este estudio resalta la efectividad de los enfoques híbridos de ADM en la gestión de la energía renovable y la importancia de integrar múltiples criterios para tomar decisiones informadas sobre el uso de recursos locales para la producción de biocombustibles, contribuyendo así a la mitigación de gases de efecto invernadero y la producción de energía limpia en contextos regionales específicos. No obstante, el incremento de la complejidad de los enfoques híbrido implica un incremento en la demanda de recursos computacionales, así como del nivel de habilidad requerido para aplicar el método e interpretar los resultados.

Alao et al. (2022), introducen un modelo integrado basado en ADM difuso para la selección óptima de tecnologías de generación distribuida basadas en residuos en la Ciudad del Cabo, Sudáfrica. Este modelo híbrido combina el Proceso Analítico Jerárquico Difuso (Fuzzy-AHP), la Entropía Difusa y el método Fuzzy-MULTIMOORA. La aplicación de este enfoque permitió evaluar cuatro tecnologías de conversión de RSMaE (DA, INC, PYR y GAS) a través de catorce subcriterios que abarcan aspectos técnicos, económicos, ambientales y sociales de la sostenibilidad. Los resultados indicaron que la DA es la tecnología de conversión de RSMaE más sostenible para la inversión en la Ciudad del Cabo, seguida por GAS, PYR e INC. El análisis de sensibilidad realizado demostró una alta consistencia y estabilidad en los resultados obtenidos. Este estudio destaca la importancia de integrar métodos subjetivos y objetivos en un entorno difuso para abordar la incertidumbre en las evaluaciones de expertos y la variabilidad en los datos de rendimiento.

Habibollahzade y Houshfar (2020), presentaron un rediseño de una planta de valorización energética de RSM utilizando una combinación de optimización exerгонómica y el método de optimización multicriterio Grey Wolf (MCGWO). El sistema propuesto incluye la inyección de CO₂ reciclado en el gasificador después de su separación mediante una membrana, lo cual aumenta la eficiencia de la GAS y reduce considerablemente las emisiones de GEI. La evaluación del sistema rediseñado se llevó a cabo mediante análisis termodinámicos y exergoeconómicos, comparando el rendimiento de la nueva configuración con una planta de conversión de RSMaE convencional. El estudio mostró que la eficiencia de la primera y segunda ley de la termodinámica del sistema propuesto es mayor en comparación con el sistema convencional, con un aumento del 6 % y 3 %, respectivamente. Además, la optimización tri-objetivo realizada con el algoritmo MCGWO permitió encontrar un equilibrio óptimo entre las funciones objetivo, logrando una

reducción del 35 % en las emisiones equivalentes de CO₂ y un aumento del 22 % en la generación neta de energía. Los resultados del estudio sugieren que el rediseño de plantas de conversión de RSMaE mediante técnicas avanzadas de optimización y reciclaje de CO₂ puede mejorar su rendimiento energético y económico.

Por otro lado, El Kourdi et al. (2023), evaluaron diversas tecnologías de PYR para la producción de bio-aceite a partir de RSM aplicando métodos de ADM para selección la mejor alternativa. Se seleccionaron cuatro tecnologías de PYR: reactor de lecho fijo, lecho fluidizado, tornillo y horno rotatorio. La metodología empleada fue el método Fuzzy-TOPSIS, que permite evaluar y clasificar las tecnologías según criterios técnicos, económicos y ecológicos. Para determinar el rendimiento relativo de cada tecnología respecto a los criterios establecidos, se realizó una revisión exhaustiva de la literatura. Los pesos de los criterios se calcularon utilizando dos métodos objetivos: ENTROPY y CRITIC, los cuales demostraron ser comparables. Los resultados obtenidos clasificaron al reactor de horno rotatorio como la mejor tecnología, seguida por el reactor de lecho fluidizado, el reactor de tornillo y, finalmente, el reactor de lecho fijo. El análisis de sensibilidad mostró la robustez del método Fuzzy-TOPSIS para la elección adecuada del reactor de horno rotatorio, confirmando su idoneidad técnica, económica y ecológica para la producción de bio-aceite a partir de RSM.

Alfonso-Cardero et al. (2021), se centraron en la gestión de RSM en La Habana, Cuba, y la selección de tecnologías de recuperación de materiales y energía (MRF + WtE) mediante un análisis multicriterio utilizando el AHP. El estudio considera siete escenarios de tratamiento de residuos que incluyen tecnologías de combustión, GAS, carbonización hidrotermal (HTC) con y sin captura de carbono, y DA. La evaluación se basó en criterios ambientales, técnico-económicos y sociales, utilizando tanto datos cualitativos de juicios de expertos como cuantitativos de modelos de simulación en Aspen Plus. Los resultados mostraron que los criterios ambientales tenían la mayor prioridad, con una ponderación notoriamente mayor que los criterios sociales y técnico-económicos. Entre los escenarios evaluados, el MRF combinado con DA fue el más adecuado, debido a su menor impacto ambiental, alta aceptación social y estabilidad financiera a largo plazo. Este estudio resalta la utilidad del AHP como herramienta de toma de decisiones en la selección de tecnologías de gestión de residuos en economías emergentes, proporcionando un enfoque integral que puede ser aplicado en otros contextos similares para mejorar la sostenibilidad del sistema de manejo de RSM.

En el estudio de Gombojav y Matsumoto (2023), se implementó un ADM para optimizar el escenario de gestión de RSM en Ulaanbaatar, Mongolia. Utilizando el método TOPSIS, el estudio evaluó varios métodos de disposición de residuos con el objetivo de identificar la opción más eficiente y sostenible. Este enfoque permitió considerar factores técnicos, ambientales, económicos y sociales en la selección de la mejor estrategia de gestión de residuos. La investigación incluyó el ACV para estimar las emisiones de GEI de diferentes métodos de tratamiento de residuos, como el vertido, la INC, el tratamiento

biológico mecánico (MBT) y el compostaje. Además, se realizó un análisis de escenarios para prever la evolución futura de los residuos municipales hasta 2030 bajo diferentes planes de gestión. Los resultados indicaron que la INC de residuos es la opción más atractiva para las condiciones del lugar de estudio, mientras que los métodos de reciclaje y MBT también mostraron beneficios importantes. El uso de TOPSIS permitió clasificar las alternativas de disposición de residuos en contextos urbanos en crecimiento.

Shahnazari et al. (2020), evaluaron tecnologías termales mediante un enfoque que combina AHP y TOPSIS. El objetivo del estudio fue seleccionar la mejor tecnología de termoconversión para la gestión de RSM considerando criterios técnicos, económicos y ambientales. Se seleccionaron cuatro tecnologías principales: INC, GAS, PYR y plasma. A través de un cuestionario completado por expertos, se recopilieron datos sobre la importancia relativa de varios subcriterios como el nivel tecnológico, la facilidad de uso, la seguridad en el lugar de trabajo, las emisiones, el uso de la tierra y los costos operativos. Los resultados mostraron que los criterios ambientales, económicos y técnicos fueron los más influyentes en la selección de tecnologías. Entre las tecnologías evaluadas, el plasma fue identificado como la opción óptima debido a su mayor eficiencia en términos de criterios ambientales y económicos. La INC y la GAS ocuparon los siguientes lugares, con la PYR siendo la menos favorable debido a su menor eficiencia energética y mayores requisitos de preprocesamiento. Este estudio destaca la utilidad de los enfoques ADM para integrar múltiples factores en la toma de decisiones sobre tecnologías de gestión de residuos.

Alao et al. (2021), emplearon un enfoque híbrido de entre el método IDOCRIW (Integrated Determination of Criteria Weights) y el TOPSIS para seleccionar la tecnología de valorización energética de RSM más adecuada para la generación distribuida en la ciudad de Johannesburgo, Sudáfrica. El método IDOCRIW combina los métodos ENTROPY y CILOS (Criterion Impact Loss) para determinar los pesos de los criterios, mientras que el método TOPSIS se utiliza para clasificar las tecnologías de valorización energética según su proximidad a la solución ideal. Se consideraron catorce criterios que abarcan factores técnicos, económicos, ambientales y sociales para evaluar cinco tecnologías de valorización energética: DA, recuperación de gas de relleno sanitario, INC, PYR y GAS. Los resultados indicaron que la DA es la tecnología más atractiva, con una cercanía relativa de aproximadamente 0.97 a la solución ideal, mientras que la INC fue clasificada como la peor opción con una cercanía de aproximadamente 0.65. El estudio también reveló que la integración de la DA y la GAS podría ser más prometedora en términos de gestión de residuos y generación distribuida en aplicaciones de microrredes, actuando como generador local de energía cuando se integra en los sistemas de gestión de RSM.

Alao et al. (2020), aplicaron el método TOPSIS ponderado por entropía para seleccionar la tecnología de valorización energética de RSM más adecuada para la generación distribuida en Lagos, Nigeria. Este método permitió evaluar diversas opciones tecnológicas de conversión de RSMaE, incluyendo DA, INC, GAS, PYR y recuperación de gas de relleno sanitario, considerando múltiples criterios técnicos, económicos y ambientales. Los resultados mostraron que la DA es la mejor opción de tecnología de conversión de RSMaE para la generación de electricidad en Lagos, debido a su menor costo de inversión, menores costos operativos y de mantenimiento, y menor costo de energía en comparación con otras tecnologías. Este enfoque híbrido permite ponderar las diferentes dimensiones de la sostenibilidad en las alternativas de conversión de RSMaE, reduciendo el componente subjetivo de la ponderación de los pesos de los criterios.

Ossei-Bremang y Kemausuor (2021), emplearon un enfoque híbrido de ADM para la selección de recursos de biomasa sostenibles para la producción de bioenergía en Ghana. Utilizando una combinación del AHP y Fuzzy-TOPSIS, los investigadores evaluaron una variedad de recursos de biomasa, incluyendo residuos de cultivos, estiércol animal, residuos forestales, cultivos energéticos y RSM. Este enfoque permitió abordar la vaguedad y ambigüedad en los datos, transformando valores difusos en valores concretos y garantizando la precisión en cada matriz de decisión. Los criterios de sostenibilidad considerados incluyeron aspectos sociales, ambientales y económicos, junto con trece subcriterios. Los resultados del análisis indicaron que el estiércol animal era el recurso más deseable para la producción de bioenergía en Ghana, seguido de los cultivos energéticos, RSM, residuos forestales y residuos de cultivos. Este estudio destaca la utilidad de la combinación de AHP y Fuzzy-TOPSIS para resolver problemas complejos de toma de decisiones en la planificación de energía renovable.

Shahsavar et al. (2022), propusieron un marco de ADM integrado para la gestión de la fracción plástica de los RM en Mashhad, Irán. Este marco incluyó una combinación de varios métodos de ADM: la entropía de Shannon, la OWA, AHP, TOPSIS y ELECTRE. Estos métodos se utilizaron para evaluar y priorizar diferentes alternativas de biodegradación de plásticos utilizando hongos, considerando criterios económicos, energéticos y ambientales. El estudio mostró que la biodegradación de residuos plásticos utilizando hongos es una opción viable y ambientalmente amigable, destacando la eficiencia de *Aspergillus flavus* en la descomposición de polietileno de alta densidad (HDPE) y de *Mucor rouxii* en la descomposición de polietileno de baja densidad (LDPE). Además, se demostró que la aplicación de este marco integrado puede aumentar la satisfacción de los ciudadanos con el sistema de gestión de RSM y reducir las emisiones de materiales peligrosos.

Mujtaba et al. (2024), aplicaron un enfoque ADM para evaluar escenarios sostenibles de gestión de RSM en Lahore, Pakistán. Utilizando los métodos TOPSIS, PROMETHEE II, AHP y lógica difusa, el estudio desarrolló diez escenarios de manejo de RSM evaluados bajo criterios económicos, ambientales, sociales, y técnicos. Los escenarios

incluyeron combinaciones de tecnologías de gestión de residuos como DA, GAS, INC, hidrolización térmica (HTL), reciclaje de combustible derivado de residuos (RDF), y compostaje. Los resultados indicaron que el escenario óptimo consiste en una gestión del 54 % de los RSM mediante DA, 37 % mediante GAS y 9 % de mediante relleno sanitario, debido a su capacidad para mitigar el impacto ambiental y satisfacer las demandas energéticas de la ciudad.

1.3. Limitaciones de los métodos de selección

Los métodos de toma de decisiones multicriterio, ADM, aunque ofrecen un marco valioso para evaluar y seleccionar alternativas de valorización energética de RSM (para más detalles), se puede identificar varias limitaciones que deben ser consideradas para una aplicación efectiva:

- *Incertidumbre y datos Incompletos:* Una de las principales limitaciones de los ADM es la gestión de la incertidumbre y los datos incompletos. La información necesaria para evaluar las alternativas a menudo está sujeta a variabilidad y falta de precisión, lo que puede afectar la fiabilidad de los resultados. Aunque los enfoques difusos y probabilísticos pueden ayudar a manejar la incertidumbre, aún existen desafíos en la obtención y el procesamiento de datos precisos y completos. Por ejemplo, Mishra et al. (2020) destacaron la robustez de los conjuntos difusos intuicionistas para abordar la incertidumbre en la evaluación de tecnologías de producción de bioenergía, pero la variabilidad inherente a los datos sigue siendo un desafío crucial.
- *Subjetividad en la asignación de pesos:* La asignación de pesos a los diferentes criterios es un aspecto crucial en los ADM, y a menudo implica un alto grado de subjetividad. Los tomadores de decisiones pueden tener diferentes opiniones y prioridades, lo que puede llevar a resultados sesgados. Aunque los métodos como AHP intentan reducir la subjetividad mediante comparaciones por pares, la influencia de las percepciones individuales persiste. En el estudio de Shahnazari et al. (2020), se utilizó AHP para determinar los pesos de los criterios, pero la subjetividad en las opiniones de los expertos puede afectar la objetividad de los resultados.
- *Complejidad computacional:* Los ADM, especialmente cuando se combinan múltiples métodos o se utilizan técnicas avanzadas como la programación matemática o los algoritmos de optimización, pueden ser computacionalmente intensivos. Esta complejidad puede limitar la aplicabilidad práctica, especialmente en situaciones

donde se necesita una toma de decisiones rápida o donde los recursos computacionales son limitados. Firouzi et al. (2021) utilizaron una combinación de TOPSIS, ARAS y WASPAS, lo que implicó una considerable complejidad computacional para integrar y procesar los datos de manera efectiva.

- *Integración de criterios múltiples:* integrar múltiples criterios de manera coherente y balanceada es un desafío inherente en los ADM. Los criterios pueden ser conflictivos (por ejemplo, costo versus impacto ambiental), y encontrar un equilibrio adecuado que satisfaga a todas las partes interesadas puede ser difícil. Además, algunos criterios pueden ser cualitativos y difíciles de cuantificar, lo que añade otro nivel de complejidad. Kuznetsova et al. (2019) desarrollaron un sistema integrado de gestión de residuos a energía que consideraba aspectos técnicos, económicos y ambientales, pero la integración de estos criterios requiere una cuidadosa evaluación y balance.
- *Limitaciones en la Adaptabilidad:* Los modelos ADM pueden no ser fácilmente adaptables a diferentes contextos y escenarios debido a las variaciones en las condiciones locales, como la disponibilidad de tecnologías, las políticas gubernamentales y las preferencias de la comunidad. Un modelo que funciona bien en un contexto específico puede no ser aplicable en otro sin una considerable modificación. Esto fue evidente en el estudio de Ilbahar et al. (2021), donde la adaptación del modelo de programación lineal difusa a diferentes regiones requeriría ajustes sustanciales para considerar las variaciones locales en la disponibilidad de biomasa y las infraestructuras existentes.
- *Requerimientos de experiencia:* La implementación de ADM requiere un alto nivel de experiencia en los métodos y en la comprensión de los contextos específicos de los problemas a resolver. Esto puede ser una barrera para su uso en organizaciones con recursos limitados o sin acceso a expertos en ADM. El estudio de Rabbani et al. (2021) demostró la necesidad de una profunda comprensión de las técnicas de optimización multiobjetivo y de las dinámicas de gestión de residuos para implementar efectivamente su modelo en el sureste de Teherán.
- *Evolución tecnológica y normativa:* Los ADM deben ser dinámicos para adaptarse a la evolución tecnológica y normativa. Las tecnologías de valorización energética están en constante desarrollo, y las regulaciones ambientales y de residuos cambian con el tiempo. Los modelos ADM deben actualizarse regularmente para reflejar estos cambios, lo que puede ser un proceso costoso y laborioso. Pluskal et al. (2021) subrayaron la necesidad de ajustar continuamente los modelos de gestión de residuos para alinearse con las nuevas tecnologías y regulaciones de la economía circular.

- *Impacto de Factores Externos:* Factores externos como cambios en los mercados de energía, políticas gubernamentales y condiciones económicas globales pueden influir en la viabilidad y preferencia de las alternativas de valorización energética. Los ADM pueden no captar completamente estos factores dinámicos, lo que puede llevar a decisiones subóptimas. Kurbatova y Abu-Qdais (2020) resaltaron que las fluctuaciones en los precios de la energía y las políticas ambientales pueden afectar la selección de tecnologías de conversión de residuos en energía en Moscú.
- *Falta de Pronóstico de Residuos:* Una limitación crítica en los estudios de evaluación técnico-económica de las alternativas de valorización energética de los RSM es que a menudo no se utiliza un pronóstico de residuos que considere la tendencia y patrones de generación en los lugares de estudio. Esto puede resultar en evaluaciones inexactas y decisiones que no están alineadas con las futuras necesidades y capacidades de gestión de residuos, afectando la sostenibilidad a largo plazo de las soluciones propuestas. Luo et al. (2020) subrayaron la importancia de incorporar pronósticos precisos de generación de residuos en la planificación de sitios para plantas de INC WtE, destacando que la falta de tales pronósticos puede llevar a una infrautilización o sobrecarga de las instalaciones planificadas.

Adicionalmente, aunque los ADM son herramientas poderosas para la selección de alternativas de valorización energética de RSM, presentan varias limitaciones que deben ser abordadas para mejorar su eficacia y aplicabilidad. La incertidumbre y los datos incompletos son desafíos constantes, ya que la variabilidad y falta de precisión en la información pueden afectar negativamente la fiabilidad de los resultados. Además, la subjetividad en la asignación de pesos a los diferentes criterios, debido a las percepciones individuales y prioridades de los tomadores de decisiones, puede introducir sesgos y afectar la objetividad de las evaluaciones. La complejidad computacional de los ADM, especialmente cuando se combinan múltiples métodos o se utilizan técnicas avanzadas como la programación matemática, puede limitar su aplicabilidad práctica en situaciones que requieren decisiones rápidas y donde los recursos computacionales son limitados.

La integración de múltiples criterios de manera coherente y balanceada también presenta un desafío, ya que los criterios pueden ser conflictivos y algunos aspectos cualitativos son difíciles de cuantificar. La adaptabilidad de los modelos ADM a diferentes contextos y escenarios es otra limitación, ya que las variaciones en las condiciones locales y las necesidades específicas pueden requerir modificaciones sustanciales en los modelos, dificultando su aplicación universal. Los requerimientos de experiencia para implementar efectivamente los ADM pueden ser una barrera para organizaciones con recursos limitados o sin acceso a expertos en estos métodos. La evolución tecnológica y normativa requiere que los modelos ADM se actualicen regularmente para reflejar los cambios, lo que puede ser un proceso costoso y laborioso.

El impacto de factores externos, como los cambios en los mercados de energía, las políticas gubernamentales y las condiciones económicas globales, puede influir en la viabilidad y preferencia de las alternativas de valorización energética, lo que puede llevar a decisiones subóptimas si no se consideran adecuadamente. Finalmente, una limitación crítica es la falta de pronósticos de residuos que consideren las tendencias y patrones de generación en los lugares de estudio, lo que puede resultar en evaluaciones inexactas y decisiones que no están alineadas con las futuras necesidades y capacidades de gestión de residuos, comprometiendo la sostenibilidad a largo plazo de las soluciones propuestas. Es crucial abordar estas limitaciones para mejorar la eficacia y la aplicabilidad de los ADM en el campo de la gestión de residuos y la producción de energía a partir de residuos.

1.4. Conclusiones del capítulo

La correcta implementación de alternativas de conversión de RSMaE para la valorización de residuos es esencial para abordar los crecientes desafíos ambientales y energéticos. Los métodos de ADM han demostrado ser herramientas poderosas en este contexto, proporcionando un marco robusto para la evaluación y selección de alternativas que integran criterios técnicos, económicos, ambientales y sociales. La capacidad de los ADM para manejar la incertidumbre y sintetizar información compleja y variada ha sido fundamental para mejorar la toma de decisiones en la planificación de sistemas de conversión de RSMaE.

Se logró resaltar la necesidad de utilizar ADM debido a sus múltiples ventajas, como la integración de múltiples criterios y la capacidad de incluir las opiniones de diferentes grupos de interés. Por otro lado, también se identificaron varias limitaciones importantes que deben ser abordadas para mejorar su eficacia y aplicabilidad. Estas limitaciones incluyen la incertidumbre y datos incompletos, la subjetividad en la asignación de pesos, la complejidad computacional, la integración de criterios múltiples, las limitaciones en la adaptabilidad a diferentes contextos, los requerimientos de experiencia, la evolución tecnológica y normativa, el impacto de factores externos, y la falta de pronósticos de residuos que consideren las tendencias y patrones de generación.

El análisis de coocurrencia de palabras clave ha revelado tendencias importantes en la investigación sobre ADM y RSMaE. Las palabras clave más comunes, como “*MCDA*”, “*sostenibilidad*”, “*eficiencia energética*”, “*emisiones*”, y “*optimización*”, subrayan el enfoque en desarrollar soluciones que no solo sean eficientes desde el punto de vista económico, sino también sostenibles a largo plazo, empleando métodos de selección multicriterios. Además, la coocurrencia de términos como “*incertidumbre*”, “*modelos difusos*” y “*análisis de sensibilidad*”, refleja la importancia de manejar la variabilidad y la imprecisión en los datos, así como la necesidad de modelos adaptativos y robustos.

Es fundamental que futuras investigaciones continúen explorando y desarrollando metodologías ADM que puedan adaptarse a las cambiantes condiciones tecnológicas y regulatorias. La integración de pronósticos de generación de residuos y la consideración de tendencias y patrones locales son aspectos cruciales que deben incorporarse en los modelos para asegurar la sostenibilidad a largo plazo de las soluciones propuestas. Además, se debe prestar atención a la reducción de la subjetividad en la asignación de pesos y la mejora de la accesibilidad y facilidad de uso de estas herramientas para un público más amplio.

Finalmente, aunque los ADM presentan desafíos y limitaciones, su aplicación en la gestión de residuos y la valorización energética ofrece un camino prometedor hacia soluciones más sostenibles y eficaces. Abordar las limitaciones identificadas y aprovechar las tendencias emergentes en la investigación permitirá mejorar la toma de decisiones en este campo, contribuyendo así a una gestión de residuos más eficiente y a la promoción de la economía circular.

Referencias

- Adenuga, O., Mpofu, K., & Modise, K. (2020). An approach for enhancing optimal resource recovery from different classes of waste in South Africa: Selection of appropriate waste to energy technology. *Sustainable Futures*, 2. <https://doi.org/10.1016/j.sft.2020.100033>
- Alao, M. A., Ayodele, T. R., Ogunjuyigbe, A. S., & Popoola, O. M. (2020). Multi-criteria decision based waste to energy technology selection using entropy-weighted TOPSIS technique: The case study of Lagos, Nigeria. *Energy*, 201. <https://doi.org/10.1016/j.energy.2020.117675>
- Alao, M. A., Popoola, O. M., & Ayodele, T. R. (2021). Selection of waste-to-energy technology for distributed generation using IDOCRIW-Weighted TOPSIS method: A case study of the City of Johannesburg, South Africa. *Renewable Energy*, 178, 162-183. <https://doi.org/10.1016/j.renene.2021.06.031>
- Alao, M. A., Popoola, O. M., & Ayodele, T. R. (2022). A novel fuzzy integrated MCDM model for optimal selection of waste-to-energy-based-distributed generation under uncertainty: A case of the City of Cape Town, South Africa. *Journal of Cleaner Production*, 343. <https://doi.org/10.1016/j.jclepro.2022.130824>
- Alfonso-Cardero, A., Pagés-Díaz, J., Kalogirou, E., Psomopoulos, C. S., & Lorenzo-Llanes, J. (2021). To dream or not to dream in Havana: multi-criteria decision-making for material and energy recovery from municipal solid wastes. *Environmental Science and Pollution Research*, 30(4), 8601-8616. <https://doi.org/10.1007/s11356-021-17360-2>

- AlNouss, A., Alherbawi, M., Parthasarathy, P., Al-Thani, N., McKay, G., & Al-Ansari, T. (2024). Waste-to-energy technology selection: A multi-criteria optimisation approach. *Computers and Chemical Engineering*, 183. <https://doi.org/10.1016/j.compchemeng.2024.108595>
- AlQattan, N., Acheampong, M., Jaward, F., Ertem, F., Vijayakumar, N., & Bello, T. (2018). Reviewing the potential of Waste-to-Energy (WTE) technologies for Sustainable Development Goal (SDG) numbers seven and eleven. *Renewable Energy Focus*, 27, 97-110. <https://doi.org/10.1016/j.ref.2018.09.005>
- Antonopoulos, I.-S., Perkoulidis, G., Logothetis, D., & Karkanias, C. (2014). Ranking municipal solid waste treatment alternatives considering sustainability criteria using the analytical hierarchical process tool. *Resources, Conservation and Recycling*, 86, 149-159. <https://doi.org/10.1016/j.resconrec.2014.03.002>
- Boloy, R. A. M., da Cunha Reis, A., Rios, E. M., de Araújo Santos Martins, J., Soares, L. O., de Sá Machado, V. A., & de Moraes, D. R. (2021). Waste-to-Energy Technologies Towards Circular Economy: a Systematic Literature Review and Bibliometric Analysis. *Water, Air, & Soil Pollution*, 232(7), 306. <https://doi.org/10.1007/s11270-021-05224-x>
- El Kourdi, S., Aboudaoud, S., Abderafi, S., Cheddadi, A., & Ammar, A. (2023). Pyrolysis Technology Choice to Produce Bio-oil, from Municipal Solid Waste, Using Multi-criteria Decision-making Methods. *Waste and Biomass Valorization*, 14(11), 3705-3722. <https://doi.org/10.1007/s12649-023-02076-w>
- Firouzi, S., Allahyari, M., Isazadeh, M., Nikkhah, A., & Van Haute, S. (2021). Hybrid multi-criteria decision-making approach to select appropriate biomass resources for biofuel production. *Science of the Total Environment*, 770. <https://doi.org/10.1016/j.scitotenv.2020.144449>
- Gombojav, D., & Matsumoto, T. (2023). Multi criteria decision analysis to develop an optimized municipal solid waste management scenario: a case study in Ulaanbaatar, Mongolia. *Journal of Material Cycles and Waste Management*, 25(3), 1344-1358. <https://doi.org/10.1007/s10163-023-01603-0>
- Habibollahzade, A., & Houshfar, E. (2020). Improved performance and environmental indicators of a municipal solid waste fired plant through CO2 recycling: Exergoeconomic assessment and multi-criteria grey wolf optimisation. *Energy Conversion and Management*, 225. <https://doi.org/10.1016/j.enconman.2020.113451>
- Haddaway, N. R., Page, M. J., Pritchard, C. C., & McGuinness, L. A. (2022). PRISMA2020: An R package and Shiny app for producing PRISMA 2020-compliant flow diagrams, with interactivity for optimised digital transparency and Open Synthesis. *Campbell Systematic Reviews*, 18(2). <https://doi.org/10.1002/cl2.1230>
- Ilbahar, E., Kahraman, C., & Cebi, S. (2021). Location selection for waste-to-energy plants by using fuzzy linear programming. *Energy*, 234. <https://doi.org/10.1016/j.energy.2021.121189>

- Isigonis, P., Moustakas, K., & Vakalis, S. (2022). Multicriteria analysis as a supporting decision tool for expanding the use of the 3T method for waste-to-energy technologies and biorefineries. *Sustainable Chemistry and Pharmacy*, 28. <https://doi.org/10.1016/j.scp.2022.100715>
- Kaza, S., Yao, L. C., Bhada-Tata, P., & Van Woerden, F. (2018, septiembre). *What a Waste 2.0: A Global Snapshot of Solid Waste Management to 2050*. Washington, DC: World Bank. <https://doi.org/10.1596/978-1-4648-1329-0>
- Kurbatova, A., & Abu-Qdais, H. (2020). Using multi-criteria decision analysis to select waste to energy technology for a Mega city: The case of Moscow. *Sustainability (Switzerland)*, 12(23), 1-18. <https://doi.org/10.3390/su12239828>
- Kuznetsova, E., Cardin, M.-A., Diao, M., & Zhang, S. (2019). Integrated decision-support methodology for combined centralized-decentralized waste-to-energy management systems design. *Renewable and Sustainable Energy Reviews*, 103, 477-500. <https://doi.org/10.1016/j.rser.2018.12.020>
- Li, H., An, H., Wang, Y., Huang, J., & Gao, X. (2016). Evolutionary features of academic articles co-keyword network and keywords co-occurrence network: Based on two-mode affiliation network. *Physica A: Statistical Mechanics and its Applications*, 450, 657-669. <https://doi.org/10.1016/j.physa.2016.01.017>
- Li, Z., Luo, Z., Wang, Y., Fan, G., & Zhang, J. (2022). Suitability evaluation system for the shallow geothermal energy implementation in region by Entropy Weight Method and TOPSIS method. *Renewable Energy*, 184, 564-576. <https://doi.org/10.1016/j.renene.2021.11.112>
- Luo, C., Ju, Y., Santibanez Gonzalez, E., Dong, P., & Wang, A. (2020). The waste-to-energy incineration plant site selection based on hesitant fuzzy linguistic Best-Worst method ANP and double parameters TOPSIS approach: A case study in China. *Energy*, 211. <https://doi.org/10.1016/j.energy.2020.118564>
- Martínez López, L., Ishizaka, A., Qin, J., & Álvarez Carrillo, P. A. (2023). *Multi-Criteria Decision-Making Sorting Methods*. Elsevier. <https://doi.org/10.1016/C2020-0-02008-6>
- Mishra, A., Rani, P., Pandey, K., Mardani, A., Streimikis, J., Streimikiene, D., & Al-rasheedi, M. (2020). Novel multi-criteria intuitionistic fuzzy SWARA-COPRAS approach for sustainability evaluation of the bioenergy production process. *Sustainability (Switzerland)*, 12(10). <https://doi.org/10.3390/su12104155>
- Mujtaba, M., Munir, A., Imran, S., Nasir, M., Muhayyuddin, M., Javed, A., Mehmood, A., Habila, M., Fayaz, H., & Qazi, A. (2024). Evaluating sustainable municipal solid waste management scenarios: A multicriteria decision making approach. *Heliyon*, 10(4). <https://doi.org/10.1016/j.heliyon.2024.e25788>
- Ossei-Bremang, R., & Kemausuor, F. (2021). A decision support system for the selection of sustainable biomass resources for bioenergy production. *Environment Systems and Decisions*, 41(3), 437-454. <https://doi.org/10.1007/s10669-021-09810-6>

- Pluskal, J., Šomplák, R., Nevrlý, V., Smejkalová, V., & Pavlas, M. (2021). Strategic decisions leading to sustainable waste management: Separation, sorting and recycling possibilities. *Journal of Cleaner Production*, 278. <https://doi.org/10.1016/j.jclepro.2020.123359>
- Rabbani, M., Mokarrari, K., & Akbarian-saravi, N. (2021). A multi-objective location inventory routing problem with pricing decisions in a sustainable waste management system. *Sustainable Cities and Society*, 75. <https://doi.org/10.1016/j.scs.2021.103319>
- Shah, S., & Longsheng, C. (2022). Evaluating renewable and sustainable energy impeding factors using an integrated fuzzy-grey decision approach. *Sustainable Energy Technologies and Assessments*, 51. <https://doi.org/10.1016/j.seta.2021.101905>
- Shahnazari, A., Rafiee, M., Rohani, A., Bhushan Nagar, B., Ebrahiminik, M., & Aghkhani, M. (2020). Identification of effective factors to select energy recovery technologies from municipal solid waste using multi-criteria decision making (MCDM): A review of thermochemical technologies. *Sustainable Energy Technologies and Assessments*, 40. <https://doi.org/10.1016/j.seta.2020.100737>
- Shahsavari, M., Akrami, M., Kian, Z., Gheibi, M., Fathollahi-Fard, A., Hajiaghahi-Keshteli, M., & Behzadian, K. (2022). Bio-recovery of municipal plastic waste management based on an integrated decision-making framework. *Journal of Industrial and Engineering Chemistry*, 108, 215-234. <https://doi.org/10.1016/j.jiec.2022.01.002>
- Tamasila, M., Prosteian, G., Ivascu, L., Cioca, L.-I., Draghici, A., & Diaconescu, A. (2020). Evaluating and prioritizing municipal solid waste management-related factors in Romania using fuzzy AHP and TOPSIS. *JOURNAL OF INTELLIGENT & FUZZY SYSTEMS*, 38(5), 6111-6127. <https://doi.org/10.3233/JIFS-179695>
- Uhde, B., Andreas Hahn, W., Griess, V. C., & Knoke, T. (2015). Hybrid MCDA Methods to Integrate Multiple Ecosystem Services in Forest Management Planning: A Critical Review. *Environmental Management*, 56(2), 373-388. <https://doi.org/10.1007/s00267-015-0503-3>
- Unidad de Planeación Minero Energética (UPME) & INERCO Consultoría Colombia. (2018). Valorización energética de residuos: proyecto WtE Colombia. <http://bdigital.upme.gov.co/handle/001/1339>
- World Bank. (2019). What a Waste Global Database. <https://datacatalog.worldbank.org/search/dataset/0039597>
- Yin, L.-J., Wang, C., Hu, Y.-Y., Chen, D.-Z., Xu, J.-F., & Liu, J. (2017). AHP-based approach for optimization of waste disposal method in urban functional zone. *Environmental Technology (United Kingdom)*, 38(13–14), 1689-1695. <https://doi.org/10.1080/09593330.2016.1244565>

Capítulo 2

Rutas Tecnológicas de Valorización Energética de RSM

Resumen del capítulo: Este capítulo explora las rutas tecnológicas para la valorización energética de RSM. Se analizaron la INC, DA, GAS y rellenos sanitarios con captura de biogás (RSCB), evaluando sus potenciales técnicos, energéticos, económicos y ambientales. Se resalta la influencia de la composición de los RSM, con alta variabilidad en sus componentes categóricos y fisicoquímicos, en la selección de la tecnología apropiada. La GAS destaca por su eficiencia, pero la DA es viable para residuos orgánicos, mientras que el RSCB es una opción económica. Se concluye que integrar estos factores es esencial para una gestión sostenible de RSM.

Palabras clave – Residuos-a-Energía; Conversión térmica; Gasificación; Digestión Anaerobia; Incineración; Relleno Sanitario con Captura de Biogás.

2.1. Introducción

La gestión adecuada de los RSM ha emergido como un desafío crucial para el desarrollo sostenible global, especialmente en un contexto de creciente urbanización y avances socioeconómicos que exacerban su generación (Chen, [2018a](#); Ming et al., [2014](#)). Las tasas de generación de RSM están intrínsecamente ligadas a variables socioeconómicas como el incremento poblacional, la densidad urbana, el crecimiento del Producto Interno Bruto (PIB) y el IDH (Paulauskaite-Taraseviciene et al., [2022](#)). A medida que las poblaciones urbanas crecen, también lo hace la cantidad de residuos generados, ejerciendo presión sobre los sistemas de gestión existentes que, sin una planificación adecuada, pueden convertirse en serios problemas de salud pública (Y. Shi et al., [2020](#)), contaminación ambiental (Juárez-Hernández, [2021](#)) y consumo ineficiente de recursos económicos

(Kaza et al., 2018). Adicionalmente, el incremento en la generación de RSM presenta desafíos importantes, no solo en términos de acumulación y disposición sino también en lo que respecta a la oportunidad de recuperar energía a partir de estos materiales desechados (Bui et al., 2023). En este contexto, la intersección entre la gestión de RSM y la generación de energía se vuelve crítica. Globalmente, la capacidad para transformar los residuos en energía mediante tecnologías de valorización energética de los RSM ha cobrado importancia, dado que contribuyen tanto a la reducción de la cantidad de residuos destinados a vertederos como a la producción de energía (Tsui & Wong, 2019), apoyando así la diversificación de la matriz energética. Estas tecnologías representan un componente esencial en la generación de electricidad a nivel mundial, contribuyendo no solo a la sostenibilidad ambiental sino también a la seguridad energética (IRENA, 2021; Tonjes & Greene, 2012).

Las tecnologías de conversión de RSMaE más establecidas incluyen INC, DA, GAS y RSCB (Khan et al., 2022). Cada una de estas tecnologías presenta ventajas y desventajas que se deben evaluar desde múltiples dimensiones, entre las cuales destacan las técnicas, económicas, ambientales, y energéticas. Desde el punto de vista técnico, estas tecnologías han demostrado capacidad para procesar grandes volúmenes de RSM y convertirlos en energía de forma eficiente (Schneider & Ragossnig, 2015; Sun et al., 2021). Económicamente, aunque la inversión inicial y los costos operativos pueden ser elevados, especialmente para la INC (Rodrigues et al., 2022) y la GAS (Liu et al., 2022), el retorno sobre la inversión a través de la generación de energía y la venta de subproductos como biofertilizantes puede ser considerable (Coral Medina et al., 2021). Ambientalmente, las tecnologías de conversión de RSMaE ayudan a reducir la huella de carbono y la dependencia de los vertederos (IRENA, 2022; OCDE, 2022; U.S. EPA, 2021a), aunque deben gestionarse cuidadosamente para minimizar las emisiones de contaminantes (Ahmad et al., 2020). Socialmente, la aceptación de estas tecnologías puede verse afectada por percepciones públicas negativas, aunque también generan empleo y fomentan el desarrollo tecnológico (Cucchiella et al., 2016; Wójtowicz-Wróbel, 2017). En términos energéticos, contribuyen a la diversificación y estabilidad de la matriz energética (Kaza et al., 2018), especialmente útil para países en vía de transición energética. La necesidad de valorizar energéticamente los RSM es particularmente relevante para contribuir a la diversificación de la matriz energética (Congreso de la República de Colombia, 2014), un objetivo global que cobra especial importancia en países en desarrollo como Colombia. Un país con una amplia diversidad geográfica y objeto de fenómenos naturales que generan variaciones en los niveles de los embalses de agua, lo cual afecta la volatilidad de los precios de la electricidad (Villa-Loaiza et al., 2023; XM, 2023) debido a la alta dependencia que el país presenta en relación con la generación hidroeléctrica, lo permite destacar la importancia de desarrollar capacidades locales de generación de energía a partir de recursos disponibles, como los RSM. La implementación de tecnologías de

conversión de RSMaE en Colombia podría no solo mitigar estos efectos sino también aprovechar el potencial energético de los residuos urbanos para mejorar la sostenibilidad y la autosuficiencia energética (Unidad de Planeación Minero Energética (UPME) & INERCO Consultoría Colombia, 2018).

El objetivo de este capítulo es proporcionar una base sólida y práctica para la evaluación y comparación de los potenciales técnicos, económicos, ambientales y energéticos de la INC, DA, GAS y RSCB. Esto permitirá en capítulos posteriores, mediante la implementación de método de selección multicriterio, establecer un marco de referencia que permita identificar las opciones más viables y sostenibles para la valorización energética de los RSM en diferentes contextos, incluyendo el colombiano, contribuyendo así al avance hacia sistemas de gestión de residuos más integrados y sustentables. Este capítulo busca no solo abordar los aspectos técnicos y aplicativos de las tecnologías de conversión de RSMaE, sino también fomentar una comprensión más profunda de su rol dentro de la gestión de residuos y la producción de energía a nivel global y local, resaltando su potencial para mejorar la eficiencia energética y la sostenibilidad ambiental en la era moderna.

2.2. Características categóricas de los RSM

La composición categórica de los RSM (e.g., plásticos, madera, orgánicos) varía considerablemente de una ciudad a otra, reflejando una diversidad de factores que influyen en la generación y disposición de estos residuos (Kaza et al., 2018). Esta variabilidad puede atribuirse a múltiples causas, incluyendo diferencias en los hábitos de consumo, niveles de desarrollo económico, políticas de gestión de residuos, y prácticas culturales (Izquierdo-Horna et al., 2022). En ciudades con economías más desarrolladas, es común encontrar una mayor proporción de residuos de papel y cartón debido al elevado consumo de productos empaquetados y material de oficina, mientras que, en áreas rurales o menos desarrolladas, los residuos orgánicos tienden a ser más predominantes debido a una mayor dependencia de alimentos frescos y actividades agrícolas (World Bank, 2019). Las políticas locales y las infraestructuras disponibles también juegan un papel crucial; ciudades con sistemas de reciclaje bien establecidos y campañas educativas eficaces suelen presentar menores proporciones de materiales reciclables como vidrio, papel y plásticos en sus RSM (U.S. EPA, 2021b). En contraste, lugares donde las políticas de gestión de residuos son deficientes o inexistentes, estos materiales suelen terminar en los vertederos, aumentando la proporción de residuos reciclables en el flujo de residuos generales (Aracil et al., 2018). La cultura y los hábitos de consumo también influyen en la composición de los RSM; culturas con alto consumo de productos empaquetados generan más residuos de plásticos y papel (Zambrano-Monserrate et al., 2021), mientras que prácticas alimentarias centradas en alimentos frescos y preparados en casa generan más residuos orgánicos (Ozcan et al., 2016). La estacionalidad puede afectar la genera-

ción de ciertos tipos de residuos, como los de poda y jardín, comunes en temporadas de mantenimiento de jardines y parques. El desarrollo industrial y comercial de una ciudad impacta notablemente la composición de los RSM, con áreas industriales y comerciales generando mayores cantidades de residuos metálicos y de papel (Zia et al., 2017). Por ejemplo, las industrias de la construcción contribuyen con la generación de residuos de madera y metales, mientras que oficinas y establecimientos comerciales aportan a la generación de papel y cartón. El nivel de educación y concienciación ambiental de la población también es un factor clave; comunidades con mayor acceso a la educación ambiental tienden a tener tasas más altas de separación y reciclaje de residuos, reduciendo la proporción de materiales reciclables en el flujo de residuos sólidos municipales (OCDE, 2022). Características demográficas, como el tamaño de la población y la densidad poblacional, también influyen en la composición de los RSM, con ciudades densamente pobladas generando mayores cantidades de residuos per cápita debido a la intensa actividad económica y social (Paulauskaite-Taraseviciene et al., 2022). Las ciudades más grandes a menudo tienen más recursos para implementar programas avanzados de gestión de residuos, lo que puede influir en la composición de los residuos (Kaza et al., 2018).

La Figura 2.1 revela que la composición categórica de los RSM varía notablemente entre las ciudades. Los residuos orgánicos y plásticos y lignocelulósicos son los de mayor relevancia, destacando la necesidad de programas o proyectos de conversión de RSMAE y/o de compostaje y reciclaje efectivos. Conocer la composición específica de los RSM es crucial para la implementación de tecnologías de conversión de RSMAE, ya que permite diseñar soluciones adaptadas a las características locales, optimizando así la eficiencia y sostenibilidad del sistema de gestión de residuos. Por ejemplo, los residuos orgánicos constituyen una porción mayoritaria de los RSM, representando normalmente entre el 34 % a 57 % de los RSM, con un valor promedio de 45.42 %. Esta alta proporción subraya la importancia de implementar programas de compostaje y DA para gestionar eficientemente este tipo de residuos. En contraste, el vidrio tiene una menor participación en los RSM, con valores que oscilan entre el 1.5 % a 5.0 %, y un promedio de 4.1 %. Estos datos sugieren que mejorar las tasas de reciclaje de vidrio podría reducir la cantidad de este material en los RSM, disminuyendo así la carga sobre los sistemas de gestión de residuos.

Por otro lado, los metales representan una pequeña fracción de los RSM, con una participación que varía entre el 1 % a 4 % y una media de 2.98 %. Si bien esto puede atribuirse a la efectividad de los programas de reciclaje de metales, en algunas ciudades se cuenta con un potencial destacable para mejorar la recolección y reciclaje de estos residuos, lo cual podría generar beneficios económicos y ambientales. Asimismo, la




Figura 2.1: Variación de la composición categórica de los RSM. Fuente de los datos: 330 ciudades analizadas por World Bank (2019)

categoría de Otros abarca una amplia variedad de materiales y tiene una participación que oscila entre el 8.93 % a 26.43 %, con una media de 20.31 %. Esta variabilidad sugiere la necesidad de caracterizar mejor estos residuos para identificar oportunidades de reciclaje o recuperación.

En cuanto al papel y cartón, estos materiales tienen una media de 12.69 % en los RSM, con una participación que va del 6.6 % a 17.0 %. En muchas ciudades, estos materiales son componentes con alta participación en la composición de los RSM. La variabilidad en los datos sugiere diferencias en el reciclaje y consumo de productos de papel y cartón. Incrementar las tasas de reciclaje de papel y cartón podría reducir la cantidad de residuos que necesitan ser gestionados. Similarmente, los plásticos constituyen una parte considerable de los RSM, con una participación que varía entre el 7.02 % a 15 %, y una media de 11.46 %. La alta proporción de plásticos resalta la necesidad de estrategias efectivas de reciclaje y reducción, así como el desarrollo de alternativas biodegradables.

El cuero, con una participación media de 2.13 % en los RSM, presenta una variabilidad que va del 0.6 % a 2.7 %. Aunque en la mayoría de las ciudades, el cuero no representa una gran proporción de los residuos, la implementación de programas de reciclaje y reutilización podría ser beneficiosa para reducir la carga de este tipo de residuos. Igualmente, la madera presenta una media de 3.01 % en los RSM, con una participación que oscila entre el 0.9 % a 4.0 %. Aunque en muchas ciudades la madera no constituye una fracción apreciable de los residuos, la variabilidad observada indica

que algunas ciudades podrían beneficiarse de programas de reciclaje y reutilización de madera, especialmente en áreas con actividades de construcción y demolición. Finalmente, los residuos de poda y jardín tienen una media de 10.24 %, con una participación que varía entre el 2.58 % a 12.25 %. Esta variabilidad considerable en la generación de estos residuos sugiere la necesidad de implementar programas de compostaje y reciclaje de residuos verdes para reducir la cantidad de residuos enviados a los vertederos.

2.3. Características fisicoquímicas de los RSM

Conocer la composición química de los RSM es crucial para la planificación y optimización de las estrategias de gestión de residuos y la selección de tecnologías de conversión de RSMaE. La composición química influye directamente en la eficiencia y la viabilidad de los procesos de tratamiento y conversión. Los principales factores que afectan la composición proximal, elemental y el poder calorífico de los RSM incluyen las fuentes de residuos, las prácticas de gestión, y las características demográficas y económicas de las regiones. La composición proximal, que abarca la humedad, las cenizas, la materia volátil y el carbón fijo, es afectada por la proporción de residuos orgánicos, inorgánicos y el contenido de humedad de los materiales desechados. La composición elemental, que incluye los porcentajes de carbono (C), hidrógeno (H), oxígeno (O), nitrógeno (N), azufre (S) y cloro (Cl), depende de la naturaleza de los residuos, como la presencia de plásticos, alimentos, papel y otros materiales. El poder calorífico de los RSM, tanto el poder calorífico inferior (PCI) como el poder calorífico superior (PCS), es esencial para los análisis energéticos, ya que determina la cantidad de energía que se puede recuperar de los residuos. Conocer el poder calorífico permite diseñar y operar plantas de conversión de residuos en energía de manera eficiente, maximizando la recuperación de energía y minimizando los costos operativos y las emisiones. En ese sentido, la [Figura 2.2](#) muestra una recopilación de datos típicos de características fisicoquímicas de los RSM reportadas por múltiples fuentes halladas en la literatura científica del área de estudio.

La [Figura 2.2](#) revela que el contenido de carbono varía notoriamente entre las fracciones de residuos, siendo los textiles y los plásticos los más ricos en carbono, lo que los hace ideales para la INC y la GAS debido a su alto poder calorífico. Los residuos orgánicos, aunque tienen menor contenido de carbono, son perfectos para la DA y los RSCB gracias a su alta biodegradabilidad. La madera, con un contenido de carbono similar a los textiles y plásticos, es eficiente tanto en procesos térmicos como biológicos. El papel y el cartón, con un contenido intermedio de carbono, son adecuados para la INC y la GAS, pero su eficiencia puede verse afectada por aditivos y recubrimientos, haciéndolos




Figura 2.2: Composición típica de los RSM. Fuente de los datos: Boumanchar et al. (2019), Huang y Lo (2020), Ibikunle et al. (2020), H. Shi et al. (2016) y Zhou et al. (2014).

menos ideales para procesos biológicos. La variabilidad en el contenido de carbono es mayor en textiles y plásticos, lo que puede afectar la consistencia del rendimiento en los procesos de valorización energética, mientras que los residuos orgánicos, la madera y el papel/cartón son más homogéneos, lo que facilita la planificación y operación.

El contenido de hidrógeno también varía entre las fracciones de RSM, siendo los textiles y los plásticos los que presentan los valores más altos, lo que los hace ideales para la INC y la GAS debido a su contribución al poder calorífico. Los residuos orgánicos, aunque tienen menor contenido de hidrógeno, siguen siendo viables para estos procesos, pero son más adecuados para la DA y los RSCB debido a su alta biodegradabilidad. La madera, con un contenido de hidrógeno similar a los textiles y plásticos, es eficiente para ambos tipos de procesos. La variabilidad en el contenido de hidrógeno es mayor en textiles y plásticos, mientras que los residuos orgánicos, la madera y el papel/cartón son más homogéneos.

El contenido de oxígeno en las fracciones de RSM también muestra una alta variabilidad. Los textiles y los plásticos tienen los valores más bajos, lo que es desfavorable para la INC y la GAS, ya que el oxígeno no contribuye a la generación de energía. Los residuos orgánicos, aunque tienen un mayor contenido de oxígeno, son más adecuados para la DA y los RSCB debido a su biodegradabilidad. La madera, con un contenido de oxígeno similar a los textiles y plásticos, tiene una eficiencia reducida para la INC y la GAS, pero es viable para procesos biológicos. El papel y el cartón tienen un contenido intermedio de oxígeno, pero su eficiencia puede verse afectada por aditivos y recubrimientos.

El contenido de nitrógeno es un factor crítico en la INC y la GAS debido a la formación potencial de NO_x , contaminantes atmosféricos. Textiles y plásticos tienen los valores más altos, aunque estos son manejables con tecnologías de control de emisiones. Los residuos orgánicos tienen niveles de nitrógeno aún más bajos, lo que reduce el riesgo de formación de NO_x . En la DA y los RSCB, el nitrógeno es menos problemático, pero puede influir en la calidad del compost o digestato. La madera también es viable para estos procesos.

El contenido de azufre es otro factor crítico en la INC y la GAS debido a la formación potencial de SO_x , contaminantes atmosféricos. Textiles y plásticos tienen los valores más altos, aunque estos son manejables. Los residuos orgánicos tienen niveles de azufre aún más bajos. En la DA y los RSCB, el azufre es menos problemático, pero puede influir en la calidad del biogás. La madera también es viable para estos procesos.

Desde una perspectiva energética, el PCS y el PCI indican el potencial energético de los residuos. Textiles y plásticos tienen los valores más altos, haciéndolos atractivos para la INC y la GAS. Los residuos orgánicos, con valores ligeramente inferiores, siguen siendo viables para estos procesos, pero son más efectivos en la DA y los RSCB. La madera tiene un contenido energético similar a los textiles y plásticos, siendo viable para ambos tipos de procesos. El papel y el cartón tienen un contenido energético intermedio, pero su eficiencia puede verse afectada por aditivos y recubrimientos. La variabilidad en el poder calorífico es mayor en textiles y plásticos, mientras que los residuos orgánicos, la madera y el papel/cartón son más homogéneos.

Por otra parte, las relaciones atómicas resultan especialmente útiles para establecer restricciones prácticas al momento de analizar los resultados de caracterización de los RSM. Mediante el diagrama van Krevelen mostrado en la [Figura 2.3](#) se puede observar que una reducción de las relaciones H/C y O/C favorecen la densidad energética de los RSM, lo que podría mejorar las eficiencias energéticas de INC o GAS.




Figura 2.3: Diagrama van Krevelen por fracciones de RSM. Fuente de datos: Boumanchar et al. (2019), Huang y Lo (2020), Ibikunle et al. (2020), H. Shi et al. (2016) y Zhou et al. (2014).

Las relaciones atómicas H/C y O/C en las fracciones de RSM son indicadores cruciales de la composición química y eficiencia de combustión, siendo los textiles y el plástico los que presentan los valores más favorables, con una alta probabilidad de ocurrencia entre 1.28 a 0.51 para H/C y entre 0.43 a 0.51 para O/C en los textiles, lo que indica una mayor cantidad de energía liberada durante la combustión, haciendo estos materiales especialmente adecuados para INC y GAS; los residuos orgánicos, con un rango de 1.2 a 1.4 para H/C y 0.4 a 0.5 para O/C, aunque con relaciones ligeramente inferiores, siguen siendo viables para estos procesos, aunque con una eficiencia energética algo menor, en la DA y RSCB, estas relaciones son menos relevantes pero pueden influir en la calidad del biogás producido y la estabilidad del proceso, siendo los residuos orgánicos más efectivos debido a su mayor biodegradabilidad; la madera, con relaciones similares al de los textiles y plásticos, también es viable para DA y RSCB, aunque su eficiencia puede

ser ligeramente inferior; el papel y cartón, aunque presentan relaciones en un rango intermedio, son efectivos para INC y GAS, aunque su eficiencia puede verse afectada por la presencia de aditivos y recubrimientos, y son menos adecuados para DA y RSCB debido a su menor biodegradabilidad en comparación con los residuos orgánicos; en términos de variabilidad, los textiles y plásticos muestran una mayor variación en sus relaciones atómicas, lo que puede influir en la consistencia del rendimiento en los procesos de conversión de RSMaE, mientras que los residuos orgánicos, madera, y papel y cartón tienden a ser más homogéneos, lo que facilita una planificación y operación más predecible de las instalaciones de tratamiento; además, es importante considerar los valores extremos que, aunque menos comunes, indican una heterogeneidad clara en los residuos textiles y plásticos, lo que requiere estrategias de manejo específicas para optimizar su conversión a energía; por otro lado, los residuos orgánicos y la madera, con menor variabilidad, presentan un comportamiento más estable en los procesos de conversión de RSMaE, aunque el papel y cartón pueden presentar desafíos adicionales debido a su variabilidad en composición y la presencia de contaminantes.

El análisis proximal incluye el contenido de cenizas, materia volátil y carbón fijo en las fracciones de RSM, siendo los textiles los que presentan los valores más bajos de cenizas, con una alta probabilidad de ocurrencia entre 11.57 % a 13.6 %, indicando una baja cantidad de residuos inorgánicos poscombustión, lo cual es beneficioso para INC y GAS ya que menos cenizas significan una mayor eficiencia de combustión y menos residuos a manejar; la materia volátil en los textiles varía entre 79.68 % a 89.5 %, siendo favorable para INC y GAS debido a que un mayor contenido de materia volátil mejora la reactividad del material durante la combustión, aumentando la eficiencia energética; el contenido de carbón fijo en los textiles se sitúa entre 68 % a 100 %, indicando un alto potencial energético que es esencial para estos procesos; en comparación, el plástico presenta valores similares en cenizas, materia volátil y carbón fijo, lo que sugiere una eficiencia comparable en INC y GAS; los residuos orgánicos, con un rango de cenizas entre 10 % a 12 %, materia volátil entre 75 % a 85 %, y carbón fijo entre 60 % a 100 %, son más adecuados para DA y RSCB debido a su mayor biodegradabilidad y capacidad de producción de biogás; la madera, con un contenido de cenizas, materia volátil y carbón fijo similar al de los textiles y plásticos, es viable para DA y RSCB, aunque su eficiencia puede ser ligeramente inferior; el papel y cartón, aunque presentan un contenido intermedio en estos parámetros, son efectivos para INC y GAS, aunque su eficiencia puede verse afectada por la presencia de aditivos y recubrimientos, y son menos adecuados para DA y RSCB debido a su menor biodegradabilidad en comparación con los residuos orgánicos; en términos de variabilidad, los textiles y plásticos muestran una mayor variación en sus contenidos de cenizas, materia volátil y carbón fijo, lo que puede influir en la consistencia del rendimiento en los procesos de conversión de RSMaE, mientras que los residuos orgánicos, madera, y papel y cartón tienden a ser más homogéneos, lo que facilita una planificación y operación más predecible de las

instalaciones de tratamiento; además, es importante considerar los valores extremos que, aunque menos comunes, indican una heterogeneidad notable en los residuos textiles y plásticos, lo que requiere estrategias de manejo específicas para optimizar su conversión a energía; por otro lado, los residuos orgánicos y la madera, con menor variabilidad, presentan un comportamiento más estable en los procesos de conversión de RSMaE, aunque el papel y cartón pueden presentar desafíos adicionales debido a su variabilidad en composición y la presencia de contaminantes.

El análisis de rutas de conversión de RSMaE es un enfoque interdisciplinario que integra principios de gestión de residuos, ingeniería ambiental y energías renovables. Existen múltiples rutas de conversión de RSMaE, incluyendo tecnologías emergentes y convencionales. De las que tienen madurez tecnológica comercial, las más ampliamente implementadas son el RSCB, la DA, la INC y la GAS. El RSCB maneja grandes volúmenes de residuos y genera biogás, pero presenta desventajas como la emisión de lixiviados y la ocupación prolongada de terrenos. La DA trata residuos orgánicos produciendo biogás y compost, aunque requiere segregación adecuada de residuos y alta inversión. La INC reduce en gran medida el volumen de residuos y genera energía, pero emite contaminantes atmosféricos y necesita sistemas avanzados de control de emisiones. La GAS transforma residuos en gas de síntesis con alta eficiencia y bajas emisiones, aunque es compleja y costosa de implementar. Cada ruta tiene ventajas y desafíos únicos, subrayando la importancia de un análisis multicriterio para seleccionar la alternativa más adecuada según las condiciones locales y los objetivos de sostenibilidad.

2.4. Tecnologías de valorización energética de RSM

2.4.1. Incineración (INC)

La INC de RSM es una tecnología de conversión térmica que implica la combustión controlada de residuos en presencia de oxígeno para reducir el volumen de residuos y generar energía, como se muestra en la [Figura 2.4](#). Este proceso se lleva a cabo en instalaciones especializadas que operan a altas temperaturas, típicamente entre 850 °C a 1200 °C, en dos etapas: la cámara de combustión primaria y la secundaria, donde los residuos se queman completamente y los gases de combustión se tratan para reducir las emisiones de contaminantes atmosféricos (Briones-Hidrovo et al., [2021](#)). Las tecnologías de INC han evolucionado rápidamente desde sus inicios en el siglo XIX, pasando de simples incineradores de residuos a instalaciones avanzadas que incorporan mecanismos de recuperación de calor y energía, así como sistemas sofisticados de control de emisiones (Makarichi et al., [2018](#)). Las principales tecnologías de INC incluyen incineradores de parrilla móvil, hornos rotatorios e incineradores de lecho fluidizado, cada una con configuraciones y capacidades específicas para optimizar la transferencia de masa y energía (Munir et al., [2021](#)). Los incineradores de parrilla móvil son los más comunes

y se utilizan ampliamente debido a su capacidad para manejar grandes volúmenes de residuos con alta eficiencia, procesando entre $555 \text{ t}_{\text{RSM}} \text{ d}^{-1}$ a $4400 \text{ t}_{\text{RSM}} \text{ d}^{-1}$, alcanzando eficiencias eléctricas netas del 13.5 % a 30.6 %, lo que permite producir entre 360 kWh a 1491 kWh y 1491 kWh por tonelada de residuos procesados (Satiada & Calderon, 2021). Los costos de capital para las plantas de INC varían sustancialmente, desde aproximadamente $70\,035 \text{ USD t}_{\text{RSM}}^{-1} \text{ d}^{-1}$ a $633\,213 \text{ USD t}_{\text{RSM}}^{-1} \text{ d}^{-1}$ de capacidad instalada, mientras que los costos operativos oscilan entre $40 \text{ USD t}_{\text{RSM}}^{-1} \text{ year}^{-1}$ a $70 \text{ USD t}_{\text{RSM}}^{-1} \text{ year}^{-1}$ (Khan et al., 2022). A pesar de los altos costos iniciales, la inversión en INC se justifica por su capacidad para reducir considerablemente el volumen de residuos destinados a vertederos y generar energía de manera continua (Makarichi et al., 2018). Además, la INC es especialmente adecuada para tratar residuos peligrosos, como los desechos hospitalarios, debido a su capacidad para destruir patógenos y sustancias tóxicas a altas temperaturas (Moya et al., 2017).




Figura 2.4: Diagrama de Flujo Conceptual de INC. Fuente: elaboración propia basada en descripción de Briones-Hidrovo et al. (2021), Makarichi et al. (2018) y U.S. EPA (2021a).

La calidad del residuo alimentado en los incineradores es un factor crítico para el rendimiento del proceso, ya que residuos con un contenido de humedad superior al 65 % pueden reducir la eficiencia del proceso y aumentar los costos operativos (Munir et al., 2021). En términos ambientales, la INC presenta desafíos debido a las emisiones de contaminantes tóxicos, como dioxinas, furanos y NO_x , que requieren sistemas avanzados de limpieza de gases para cumplir con los estándares internacionales de emisiones, como el límite de dioxinas de $0.1 \text{ ng}_{\text{TEQ}} \text{ Nm}^{-3}$ establecido por la Directiva 2000/76/EC de la Comisión Europea (Khan et al., 2022). La INC genera residuos sólidos, como cenizas de fondo y cenizas volantes, que deben gestionarse adecuadamente para evitar la

contaminación ambiental. La ceniza de fondo, que constituye aproximadamente el 23 % de la masa de entrada total, puede utilizarse en materiales de construcción, mientras que la ceniza volante, clasificada como residuo peligroso debido a sus componentes tóxicos, requiere métodos especiales de manejo y disposición (Briones-Hidrovo et al., 2021).

Desde una perspectiva de ciclo de vida, la INC tiene un impacto negativo en varias categorías ambientales, como la formación de material particulado fino, acidificación terrestre y la emisión de gases de efecto invernadero. Los estudios de ACV han demostrado que la fase de gestión de residuos es la principal fuente de formación de material particulado fino y acidificación terrestre debido a las emisiones de SO_2 y NO_x , mientras que la etapa de conversión de energía tiene un impacto importante en la formación de ozono y la escasez de recursos minerales debido al uso de acero y cobre en la construcción de las plantas (Makarichi et al., 2018). A pesar de estos desafíos, la INC sigue siendo una parte crucial de las estrategias integradas de gestión de residuos, especialmente en áreas urbanas con espacio limitado para vertederos. La capacidad de reducir el volumen de residuos hasta en un 90 % y recuperar energía la convierte en una opción viable para manejar el aumento de la generación de residuos (Munir et al., 2021). Los avances en tecnología continúan mejorando la eficiencia y el desempeño ambiental de las plantas de INC, como la implementación de sistemas de combustión en lecho fluidizado que ofrecen una eficiencia térmica mejorada y menores emisiones al mantener una distribución uniforme de temperatura y una mejor mezcla de materiales de desecho (Satiada & Calderon, 2021). Esta tecnología es particularmente efectiva para corrientes de residuos con alto contenido de humedad y valores caloríficos variables (Khan et al., 2022).

2.4.2. Digestión Anaerobia (DA)

La DA es un proceso biológico en el que los microorganismos descomponen la materia orgánica en ausencia de oxígeno para producir biogás, que consiste principalmente en CH_4 y CO_2 , junto con otros gases menores como sulfuro de hidrógeno (H_2S) y amoníaco (NH_3). Este proceso se lleva a cabo en cuatro etapas principales: hidrólisis, acidogénesis, acetogénesis y metanogénesis. En la primera etapa, las macromoléculas orgánicas como carbohidratos, proteínas y lípidos se descomponen en compuestos más simples como azúcares, aminoácidos y ácidos grasos (Munir et al., 2021). Durante la acidogénesis, estos compuestos se convierten en ácidos grasos volátiles, alcoholes y otros compuestos menores. La acetogénesis transforma estos productos en acetato (CH_3COO), H_2 y CO_2 , y finalmente, en la metanogénesis, los metanógenos convierten el CH_3COO y el H_2 en CH_4 y CO_2 (Briones-Hidrovo et al., 2021).

El biogás producido en la DA mostrado en la Figura 2.5, tiene un contenido de metano que varía entre el 55 % a 75 %, lo que lo convierte en un combustible viable para la generación de energía eléctrica y térmica (Alves et al., 2021). La eficiencia eléctrica de los sistemas de DA oscila entre el 20 % a 40 %, dependiendo del tipo de reactor, las

condiciones operativas y la composición del residuo alimentado (Khan et al., 2022). Los sistemas más eficientes son los que operan en condiciones termofílicas (45 °C a 65 °C), aunque los sistemas mesofílicos (30 °C a 40 °C) también son comunes debido a su menor requerimiento de energía para el calentamiento (Dalke et al., 2021).




Figura 2.5: Diagrama de Flujo Conceptual de DA. Fuente: elaboración propia basada en descripción de U.S. EPA (2021a).

Las ventajas de la DA incluyen la reducción del volumen de residuos, la producción de biogás como fuente renovable de energía, y la generación de un digestato que puede ser utilizado como fertilizante en la agricultura (Munir et al., 2021). Además, este proceso ayuda a mitigar las emisiones de gases de efecto invernadero al capturar y utilizar el metano que de otro modo se liberaría en los vertederos (Briones-Hidrovo et al., 2021). No obstante, también presenta desafíos, como la necesidad de una alta inversión de capital para la construcción y operación de plantas a escala comercial, y la gestión adecuada de residuos peligrosos que puedan estar presentes en la corriente de residuos sólidos municipales (Alves et al., 2021).

Los sistemas de DA también pueden ser optimizados mediante el ajuste de parámetros clave como la tasa de carga orgánica, la relación C/N, el pH, la temperatura, el contenido de humedad y el tiempo de retención. Las condiciones óptimas incluyen una tasa de carga orgánica de aproximadamente $10.1 \text{ g}_{\text{COD}} \text{ L}^{-1} \text{ d}^{-1}$, una relación C/N de 30:1, un pH en el rango de 6.8 a 7.2, temperaturas mesofílicas o termofílicas, un contenido de humedad alrededor del 85 % y un tiempo de retención de aproximadamente 15 d (Khan et al., 2022). Además, el rendimiento neto de energía en la DA puede alcanzar de $9.0 \text{ kg}_{\text{peq}} \text{ t}_{\text{RSM}}^{-1}$ a $13.5 \text{ kg}_{\text{peq}} \text{ t}_{\text{RSM}}^{-1}$ bajo condiciones óptimas, lo que demuestra su potencial como una

¹ Kilogramos de petróleo equivalente por tonelada de RSM

tecnología eficiente de conversión de residuos en energía (Briones-Hidrovo et al., 2021). Asimismo, la DA puede ser integrada con otras tecnologías de conversión de residuos para mejorar su eficiencia y viabilidad económica, como la GAS o la co-digestión con otros tipos de residuos orgánicos (Munir et al., 2021).

La implementación de la DA ha crecido en varios países debido a sus beneficios ambientales y económicos. En Estados Unidos, Islandia y Malasia, por ejemplo, se ha incrementado el procesamiento de materia orgánica para la generación de energía, reducción de vertederos y promoción de una economía circular (Alves et al., 2021). Sin embargo, para maximizar estos beneficios, es crucial optimizar los procesos de DA y superar desafíos como los costos de capital y operación, y la gestión adecuada de residuos no biodegradables (Dalke et al., 2021).

2.4.3. Gasificación (GAS)

La GAS es una tecnología avanzada de conversión térmica utilizada para transformar RSM en energía y productos químicos valiosos mediante la descomposición térmica de los residuos en un entorno controlado con una cantidad limitada de oxígeno, generalmente a temperaturas entre 700 °C a 1000 °C (IEA Bioenergy, 2018; Vallejo et al., 2020). Como se muestra en la Figura 2.6, este proceso produce un gas de síntesis (syngas) compuesto principalmente por CO, H₂, CH₄ y otros hidrocarburos ligeros, junto con CO₂ y N₂. La eficiencia de conversión de energía de la GAS varía entre el 20 % a 40 %, dependiendo del diseño del reactor, las condiciones operativas y la composición del residuo alimentado (Briones-Hidrovo et al., 2021; IEA Bioenergy, 2018; Khan et al., 2022). El syngas producido puede ser utilizado directamente para la generación de electricidad mediante motores de combustión interna, turbinas de gas o calderas, o puede ser purificado y convertido en productos químicos como metanol, amoníaco o combustibles sintéticos a través de procesos de síntesis catalítica (Alves et al., 2021; Munir et al., 2021).

La GAS ofrece múltiples varias ventajas sobre la INC convencional, incluyendo una mayor eficiencia de conversión de energía, menores emisiones de contaminantes atmosféricos, y mayor atractivo a nivel industrial por su mayor flexibilidad en la gestión de diferentes tipos de residuos. Además, la GAS permite la recuperación de materiales valiosos como metales y productos químicos, lo que puede mejorar la rentabilidad económica y la circularidad del proceso. Los sistemas de limpieza de syngas son cruciales para eliminar contaminantes como alquitranes, metales pesados y partículas sólidas, lo que garantiza la calidad del gas para su uso en aplicaciones de generación de energía o síntesis química (Woolcock & Brown, 2013). Los reactores de lecho fluidizado y de lecho fijo son las configuraciones más comunes en la GAS de RSM, con eficiencias de conversión de energía típicas que oscilan entre el 25 % a 35 % para reactores de lecho fluidizado y entre el 20 % a 30 % para reactores de lecho fijo (Briones-Hidrovo et al., 2021; Munir et al., 2021). Una de las aplicaciones más importantes de la GAS




Figura 2.6: Diagrama de Flujo Conceptual de GAS. Fuente: elaboración propia basada en descripción de IEA Bioenergy (2018), U.S. EPA (2021a) y Vallejo et al. (2020).

es la producción de hidrógeno, que es un combustible limpio y de alto valor que puede ser utilizado en celdas de combustible, procesos industriales y como un componente clave en la producción de amoníaco y metanol. La GAS de residuos para la producción de hidrógeno puede ser particularmente atractiva en regiones con acceso limitado a fuentes de hidrógeno convencionales, como el gas natural. Además, la integración de la GAS con procesos de captura y almacenamiento de carbono (CCS) puede reducir las emisiones de gases de efecto invernadero, mejorando aún más la sostenibilidad ambiental del proceso (Alves et al., 2021). En términos de costos, la GAS de RSM requiere una inversión inicial considerable en infraestructura y tecnología, con costos de capital que varían entre 50 000 USD t⁻¹ d⁻¹ a 150 000 USD t⁻¹ d⁻¹ de capacidad instalada, y costos operativos que oscilan entre 30 USD a 70 USD por tonelada de residuos procesados (Khan et al., 2022).

Si bien, el impacto ambiental de la GAS es generalmente menor en comparación con la INC, ya que el proceso produce menores cantidades de dioxinas, furanos y otros contaminantes tóxicos, es importante señalar que la gestión adecuada de los subproductos del proceso, como las cenizas y los residuos líquidos, es esencial para minimizar los riesgos ambientales. Las cenizas resultantes de la GAS pueden contener metales pesados y otros compuestos tóxicos, lo que requiere métodos de disposición adecuados o su reutilización en aplicaciones como materiales de construcción, siempre que cumplan con las normativas ambientales (Munir et al., 2021). Además, el proceso de GAS puede ser optimizado para mejorar la eficiencia de conversión de energía y reducir las emisiones mediante el uso de catalizadores y tecnologías avanzadas de limpieza de gases, lo que puede contribuir a la viabilidad económica y ambiental del proceso (Briones-Hidrovo et al., 2021).

2.4.4. Relleno Sanitario con Captura de Biogás (RSCB)

El RSCB es una tecnología ampliamente utilizada en la gestión de RSM (Mukherjee et al., 2020), especialmente en países en desarrollo donde los métodos tradicionales de eliminación aún prevalecen debido a consideraciones económicas. Esta tecnología implica la construcción y operación de vertederos controlados que incluyen sistemas de impermeabilización, drenaje de lixiviados y captura de biogás, una mezcla de gases que contiene principalmente CH_4 y CO_2 , con trazas de otros compuestos (Briones-Hidrovo et al., 2021; Khan et al., 2022). La captura y utilización del biogás de vertederos permite no solo la reducción del volumen y peso de los residuos, sino también la generación de energía renovable mediante la combustión del metano en turbinas de gas, motores de combustión interna y calderas para producir electricidad y calor (Khan et al., 2022), como se observa en la Figura 2.7. El biogás capturado en los rellenos sanitarios puede ser aprovechado para generar electricidad con eficiencias que varían de 20 % a 40 %, dependiendo de la cantidad y composición de los residuos, la eficiencia de los sistemas de captura y las tecnologías de generación de energía utilizadas (Alves et al., 2021). La producción de electricidad a partir del biogás se realiza comúnmente en motores de combustión interna o turbinas de gas. Estos sistemas no solo permiten la generación de energía, sino que también ayudan a reducir las emisiones de gases de efecto invernadero, ya que el metano, un potente gas de efecto invernadero, se convierte en CO_2 durante la combustión, que tiene un menor impacto ambiental.




Figura 2.7: Diagrama de Flujo Conceptual de RSCB. Fuente: elaboración propia basada en descripción de U.S. EPA (2021a).

Desde una perspectiva ambiental, los proyectos de RSCB tienen un impacto positivo en la reducción de las emisiones de gases de efecto invernadero (GEI). El potencial de reducción de GEI se debe principalmente a la captura y combustión del metano, que es hasta 28 veces más potente que el CO_2 en términos de su potencial de calentamiento

global (Briones-Hidrovo et al., 2021). Además, la generación de energía a partir de biogás reduce la dependencia de combustibles fósiles y, por lo tanto, disminuye las emisiones asociadas con la generación de energía convencional. Por otro lado, la implementación de sistemas de RSCB requiere una planificación cuidadosa y la selección de tecnologías adecuadas para la captura y utilización del biogás. Esto incluye el diseño de infraestructuras eficientes y la integración de los proyectos en el contexto energético y regulatorio local. La evaluación del potencial de generación de metano se realiza utilizando modelos de descomposición de primer orden y el modelo LandGEM (U.S. EPA, 2005a), que permiten estimar la capacidad de generación de metano de las fracciones orgánicas degradables de los RSM, considerando factores como la tasa de generación de metano, la fracción de carbono orgánico degradable y la eficiencia de captura de biogás (Khan et al., 2022). La eficiencia de los sistemas de captura de biogás también depende de factores como el diseño del sistema de colección, la cantidad y tipo de residuos, y las condiciones operativas del vertedero. Los sistemas de colección de biogás suelen incluir pozos de extracción perforados en el relleno sanitario, tuberías de recolección y sistemas de bombeo que transportan el gas a una instalación de procesamiento. Una vez capturado, el biogás se purifica para eliminar impurezas como H_2S , NH_3 y otros compuestos volátiles antes de su utilización en generadores de energía (Alves et al., 2021). Además de los beneficios económicos y ambientales, los proyectos de RSCB también pueden contribuir al desarrollo sostenible y la seguridad energética en países en desarrollo. La implementación de estos proyectos puede crear empleos, mejorar la infraestructura local y proporcionar una fuente de energía renovable y confiable. Por lo tanto, es crucial superar desafíos como la financiación inicial, la capacitación técnica y la gestión adecuada de los residuos no biodegradables para garantizar el éxito a largo plazo de los proyectos (Khan et al., 2022; Otero Meza et al., 2023).

2.5. Potencial de valorización de las rutas

2.5.1. Potencial técnico

Desde la perspectiva del potencial técnico, las tecnologías de conversión de RSMaE ofrecen diversas capacidades y desafíos en la conversión de RSM en energía eléctrica utilizable. La evaluación de este potencial técnico es crucial para determinar qué tecnología es la más adecuada para un contexto específico, basándose en factores como la eficiencia de conversión energética, la capacidad de procesamiento, y la adaptabilidad a diferentes tipos de residuos (Bertanza et al., 2018; Perera et al., 2013; Prabowo et al., 2019; Rezaei et al., 2018). La Tabla 2.1 proporciona una comparación detallada de estos aspectos técnicos, ayudando a ilustrar las fortalezas y debilidades de cada tecnología de conversión de RSMaE en términos de su potencial técnico en el manejo de los residuos.

Tabla 2.1: Características técnicas de las rutas de conversión de RSMaE. Fuente de los datos: Alves et al. (2021), Arslan y Yilmaz (2022), Briones-Hidrovo et al. (2021), Brynda et al. (2020), Dalke et al. (2021), Gutiérrez et al. (2021), IEA Bioenergy (2018), Khan et al. (2022), Munir et al. (2021) y Otero Meza et al. (2023)

Tec.	Compatibilidad	η_x^c (%)	Tasa de rechazo (%) ^a	Complejidad ^b	Factor de ca- pacidad (%)
GAS	Plásticos, papel, cartón, madera, poda y jardín, textiles.	33±8	20±5	9	90
INC	Orgánicos, plásticos, papel, cartón, textiles, residuos de poda y jardín, madera, mixtos.	25±5	18±8	8	85
DA	Residuos orgánicos, residuos alimentarios.	28±4	40±10	6	80
RSCB	Orgánicos, plásticos, papel, cartón, textiles, mixtos.	15	10±5	7	93

^a Valores estimados según información de literatura. Los valores reales dependerán de la composición de los RSM del caso de estudio.

^b Complejidad de implementación, medida cualitativamente con una escala de 1 a 10, donde 1 es “Muy bajo” y 10 es “Muy alto”.

^c Eficiencia neta de conversión de RSM a electricidad de la tecnología x .

La GAS se destaca por su alta eficiencia de generación eléctrica neta, que puede alcanzar hasta el 40 % (IEA Bioenergy, 2018). Pero requiere residuos con baja humedad, homogéneos y con bajo tamaño de partícula. Además, la complejidad de implementación y la necesidad de mantenimiento de GAS son elevadas debido a los requisitos técnicos avanzados y el control preciso del proceso. La INC, en contraste, es una tecnología más establecida y ampliamente utilizada que puede aceptar una variedad más amplia de residuos, con una eficiencia de conversión energética de 20 % a 30 %. Aunque la tasa de rechazo en INC puede ser menor que la GAS, su complejidad de implementación es media, y la tecnología está bien desarrollada y probada en diversas aplicaciones a nivel mundial.

Por otro lado, la DA y los RSCB representan enfoques distintos dentro de las tecnologías de conversión de RSMAE. La DA es particularmente eficaz para residuos orgánicos y húmedos, produciendo biogás con una eficiencia de generación eléctrica neta de hasta el 32 %. Este proceso tiene una alta tasa de rechazo, ya que solo los residuos orgánicos de alta biodegradabilidad son procesables, o bien residuos lignocelulósicos pretratados –lo que eleva considerablemente los costos de inversión y operación–, y requiere mantenimientos con mediana frecuencia debido a la gestión de los sistemas de digestión y la producción de lodos. No obstante, la complejidad de implementación de DA es media, ya que requiere condiciones controladas para la DA. Por otro lado, el RSCB aprovecha el metano generado por la descomposición de residuos orgánicos, con una eficiencia de generación eléctrica del 10 % a 15 %. Esta tecnología tiene una baja complejidad de implementación y mantenimiento, ya que los son relativamente sencillos de gestionar entre las demás opciones discutidas en ese estudio. No obstante, la eficiencia de los RSCB está limitada por la composición de los residuos y la gestión del vertedero (U.S. EPA, 2005b).

2.5.2. Potencial energético

El potencial energético de rutas tecnológicas de conversión de RSMAE se evalúa mediante variables críticas, incluyendo la cantidad y composición de los residuos, la eficiencia de conversión energética, y la capacidad de generación de energía. Estimar este potencial resulta imperativo para establecer la capacidad de transformación de los RSM en formas de energía como la electricidad, pero esta capacidad puede variar considerablemente entre diferentes tecnologías. Las Ecuaciones (2.1)–(2.11), adaptadas de Gómez et al. (2010), Gutiérrez et al. (2021), Otero Meza et al. (2023) y Silva et al. (2020), pueden emplearse para estimar la capacidad eléctrica instalada y electricidad neta generada por tecnología.

$$\dot{P}_{GAS,i} = \frac{LHV_{RSM} \cdot \eta_{GAS} \cdot \dot{W}_{x,i}}{3600 \cdot c_{F,GAS}} \quad (2.1)$$

$$E_{GAS,i} = \dot{P}_{GAS,i} \cdot c_{F,GAS} \quad (2.2)$$

$$\dot{P}_{INC,i} = \frac{LHV_{RSM} \cdot \eta_{INC} \cdot \dot{W}_{x,i}}{3600 \cdot c_{F,INC}} \quad (2.3)$$

$$E_{INC,i} = \dot{P}_{INC,i} \cdot c_{F,INC} \quad (2.4)$$

$$\dot{P}_{DA,i} = \frac{LHV_{CH_4} \cdot \eta_{DA} \cdot \rho_{CH_4} \cdot L_{DA} \cdot \dot{W}_{x,i}}{3600 \cdot c_{F,DA}} \quad (2.5)$$

$$E_{DA,i} = \dot{P}_{DA,i} \cdot c_{F,DA} \quad (2.6)$$

$$Q_{CH_4,i} = \sum_{i=1}^n \sum_{j=0.1}^1 .0 \left(k \cdot L_0 \cdot \frac{\dot{W}_{x,i}}{10} \cdot e^{-k \cdot t_{ij}} \right) \quad (2.7)$$

$$k = 32 \times 10^{-6} \cdot AP + 10^{-3} \quad (2.8)$$

$$L_0 = \frac{y_{CH_4} \cdot MCF \cdot M_{CH_4}}{\rho_{CH_4} \cdot M_C} \cdot \sum_{q=1}^s (DOC_q \cdot DOCF_q \cdot w_q) \quad (2.9)$$

$$\dot{P}_{RSCB,i} = Q_{CH_4,i} \cdot LHV_{CH_4} \cdot r \cdot \eta_{RSCB} \cdot \frac{1}{F_{RSCB}} \quad (2.10)$$

$$E_{RSCB,i} = \dot{P}_{RSCB,i} \cdot c_{F,RSCB} \quad (2.11)$$

Donde: $\dot{P}_{x,i}$ es la potencia neta generada por la tecnología x en el año i (kW); $E_{x,i}$ es la electricidad neta generada en la ruta tecnológica x en el año i (kWh); LHV_{RSM} es el poder calorífico inferior de los RSM (kJ kg^{-1}); η_{INC} es la eficiencia de conversión eléctrica neta de la tecnología x (%); $\dot{W}_{x,i}$ es el flujo de RSM que ingresan a la ruta tecnológica x en el año i (kg a^{-1}); $c_{F,i}$ es el factor de capacidad horaria de ruta tecnológica x (h a^{-1}); $Q_{CH_4,i}$ representa la emisión de metano en el año i del RSCB ($\text{m}^3_{CH_4} \text{ a}^{-1}$); n denota los años de estimación de emisiones de metano (50 a); j es el incremento decimal de tiempo dentro de un año i (0.1 a); k es la tasa potencial de generación de metano del RSCB (a^{-1}); L_0 es el potencial de generación de metano de los RSM ($\text{m}^3_{CH_4} \text{ t}_{RSM}^{-1}$); t_{ij} es la edad de la sección j de W_i dispuesta en el año i (a); AP es la precipitación local promedio (mm); y_{CH_4} es la fracción volumétrica de metano en el biogás de relleno (50 %); MCF es el factor de corrección de metano del relleno (asumida como 1 para rellenos sanitarios anaerobios (IPCC, 2019)); M_{CH_4} es la masa molar del metano ($16 \text{ kg}_{CH_4} \text{ kmol}_{CH_4}^{-1}$); M_C es la masa molar del carbono ($12 \text{ kg}_C \text{ kmol}_C^{-1}$); ρ_{CH_4} es la densidad del metano ($657 \times 10^{-6} \text{ t}_{CH_4} \text{ m}_{CH_4}^{-3}$); q es la fracción de RSM que cuenta con capacidad de generar metano; s es el número de fracciones de los RSM con carbono orgánico; DOC_q es el contenido de carbono orgánico degradable de la fracción q de los RSM ($\text{kg}_C \text{ kg}_q^{-1}$); $DOCF_q$ es la fracción de DOC_q que puede decaer o convertirse en metano (%); w_q es el peso relativo de la fracción q en las s fracciones de los RSM (% bs); LHV_{CH_4} es el poder calorífico inferior del metano ($50 \text{ MJ m}_{CH_4}^{-3}$); r es la eficiencia de recolección del sistema de captura de biogás (85 %); η_{RSCB} es la eficiencia parásita del motor reciprocante en la ruta RSCB (es decir, debido a las necesidades parasitas de compresión y tratamiento del biogás) (93 %); F_{RSCB} representa la tasa de consumo de energía liberada en la combustión del CH_4 requerida para generar un kWh de electricidad ($11.87 \text{ MJ kWh}^{-1}$); L_{DA} es el potencial de generación de metano de la fracción orgánica, f_o , de los RSM en la ruta tecnológica de DA ($71 \text{ m}^3 \text{ t}_{RSM}^{-1}$).

Las relaciones mostradas requieren un análisis preliminar para su correcta aplicación. En primer lugar, los flujos $\dot{W}_{x,i}$ no se consideran iguales para todos los escenarios tecnológicos estudiados. Esto depende de la compatibilidad de los residuos con la tecnología como se discutió en la [Subsección 2.5.1](#), y de la eficiencia de la planta de separación mecánica de la línea de proceso, así como de la eficiencia de los procesos de pretratamiento que sean requeridos para que los residuos cumplan con los requisitos de humedad, homogeneidad y tamaño de cada tecnología. Por ejemplo, la GAS requiere

que los RSM que ingresen al reactor contengan menos del 10 % de humedad, al igual que un tamaño de pellets que pueden ser menores a 1.0 mm (Wilk & Hofbauer, 2013) debido a dos razones principales, la primera relacionada con el área superficial de los pellets, el cual se desea que sea la mayor posible, y la segunda, garantizar la fluidización dentro del lecho, a fin de alcanzar las fuerzas de sustentación requeridas para las partículas (en el caso de la GAS fluidizada, la cual es el modo de operación analizado en este estudio). Esto con el objetivo de garantizar que los fenómenos de transferencia de masa, calor y momentum se desarrollen de forma apropiada.

Por otro lado, la INC requiere que los RSM ingresen con un contenido similar de humedad al requerido por la GAS, ya que esto permite mejorar la eficiencia de conversión eléctrica del proceso. El caso contrario puede ocurrir en la DA, la cual busca que la fracción orgánica de los RSM contenga una alta humedad de forma que se favorezcan el crecimiento microbiano y con esto se logren altas tasas de generación de CH₄. No obstante, el RSCB opera con menores exigencias, ya que el principal factor que afecta la generación de metano es el modo de operación y la integridad del sitio de disposición en sí. En este caso, no resulta obligatorio realizar algún pretratamiento a los RSM luego de su recolección en los sitios de generación, sino que el proceso puede verse favorecido por la precipitación local o bien mediante recirculación de los lixiviados (Zhang et al., 2023).

2.5.3. Potencial económico

El potencial económico de las tecnologías de conversión de RSMaE es crucial en la toma de decisiones, ya que estos proyectos representan inversiones cuantiosas y tienen el potencial de generar importantes retornos económicos y beneficios ambientales. Las tecnologías analizadas en este estudio, presentan distintas ventajas y desafíos económicos que deben considerarse cuidadosamente. Las Ecuaciones (2.12) – (2.21), adaptadas de Alves et al. (2021), Baoding Baonan Machinery And Equipment Manufacturing Co. Ltd. (2024), Gómez et al. (2010), IEA Bioenergy (2018), Otero Meza et al. (2023), Peters et al. (2003) y Zhucheng Holy Shield Environmental Science & Technology Co. Ltd. (2024), se pueden emplear para calcular el CAPEX y OPEX de las rutas de valorización energética, así como para etapa de separación mecánica (SM).

$$\text{CAPEX}_{\text{RSCB},i} = \left(1300 \cdot \dot{P}_{\text{RSCB},i} + 1.35 \times 10^6 \right) \cdot (1 + d_e)^{i+(a_c-2013)} \quad (2.12)$$

$$\text{OPEX}_{\text{RSCB},i} = 0.025 \cdot \frac{E_{\text{RSCB},i}}{\eta_{\text{RSCB}}} \cdot (1 + d_g)^{i+(a_c-2013)} \quad (2.13)$$

$$\text{CAPEX}_{\text{DA}} = \left(1.0 \times 10^6 + 3500 \cdot \dot{P}_{\text{DA}} \right) \cdot (1 + d_g)^{i+(a_c-2010)} \quad (2.14)$$

$$\text{OPEX}_{\text{DA},i} = 0.16 \cdot \text{CAPEX}_{\text{DA},0} \cdot (1 + d_g)^i \quad (2.15)$$

$$\text{CAPEX}_{\text{INC},i} = 2.1 \times 10^5 \cdot \dot{P}_{\text{INC},i}^{0.57} \cdot (1 + d_g)^{i+(a_c-2018)} \quad (2.16)$$

$$\text{OPEX}_{\text{INC},i} = 0.05 \cdot \text{CAPEX}_{\text{INC},0} \cdot (1 + d_g)^i \quad (2.17)$$

$$\text{CAPEX}_{\text{GAS},i} = 6.3 \times 10^5 \cdot \dot{P}_{\text{GAS},i}^{0.57} \cdot (1 + d_g)^{i+(a_c-2019)} \quad (2.18)$$

$$\text{OPEX}_{\text{GAS},i} = 0.17 \cdot \text{CAPEX}_{\text{GAS},0} \cdot (1 + d_g)^i \quad (2.19)$$

$$\text{CAPEX}_{\text{SM},i} = 3.3 \cdot \dot{W}_i^{0.5} \cdot (1 + d_g)^{i+(a_c-2024)} \quad (2.20)$$

$$\text{OPEX}_{\text{SM},i} = 0.20 \cdot \text{CAPEX}_{\text{SM},0} \cdot (1 + d_g)^i \quad (2.21)$$

Donde: $\text{CAPEX}_{x,i}$ es el costo de capital de la planta de la tecnología x en el año i e incluye las fases de diseño, diseños de ingeniería civil, construcción, permisos, interconexión de equipos, red eléctrica, planta de generación de electricidad, tuberías, y sistemas de pretratamiento de los RSM (excluyendo la separación mecánica) (USD); $\text{OPEX}_{x,i}$ es el costo operacional global de la planta de la tecnología x en el año i e incluye los costos de operación, mantenimiento, nómina de empleados, seguridad social, materiales y suministros, logística interna, y administración de la planta (USD); d_g es la tasa de inflación de la economía local (asumida según inflación promedio entre enero de 2019 y abril de 2024 en 6.38 % Banco de la república de Colombia, 2023); y a_c representa el año de construcción de la ruta tecnológica (2025). Los costos de capital de estas tecnologías pueden presentar marcadas diferencias entre las rutas tecnológicas. Aunque cada tecnología presentará una potencia energética diferente para un mismo lugar de estudio (i.e., por sus diferencias en potencial técnico y energético), al comparar las relaciones económicas de arriba se logra comprender en mayor detalle las diferencias económicas entre estas tecnologías.

El análisis comparativo del CAPEX global (Figura 2.8a) para las tecnologías de estudiadas revela diferencias notables en términos de inversión inicial requerida. La INC presenta un CAPEX que aumenta progresivamente con la capacidad instalada, iniciando en 2.90 MUSD para 100 kW y alcanzando 148.67 MUSD para 100 MW. Este incremento puede ser atribuido a la infraestructura y tecnología avanzada necesarias para la INC eficiente y segura de residuos. En comparación, la GAS muestra un CAPEX global mayor, comenzando en 8.70 MUSD para 100 kW y escalando hasta 446.01 MUSD para 100 MW. Este considerable costo puede ser explicado por la complejidad técnica y los sistemas de control avanzados necesarios para la conversión de residuos en gas de síntesis. Los RSCB, por otro lado, presentan los costos de inversión inicial más bajos, con un CAPEX global de 1.48 MUSD para 100 kW y 131.35 MUSD para 100 MW. Esto refleja la menor complejidad tecnológica y la infraestructura menos costosa necesaria para esta tecnología. La DA, que también implica la conversión de residuos orgánicos en biogás, presenta un CAPEX global intermedio, comenzando en 31.35 MUSD para 100 kW y alcanzando 351.00 MUSD millones para 100 MW. Esta tecnología, aunque más costosa que los RSCB, ofrece beneficios adicionales como la producción de biogás y la reducción de residuos orgánicos, lo que puede justificar su mayor inversión inicial. La variabilidad en los costos de CAPEX global entre estas tecnologías destaca la importancia de considerar tanto los costos iniciales como los beneficios a largo plazo en la toma de

decisiones sobre la implementación de tecnologías de gestión de residuos. En particular, las tecnologías con menores costos de capital inicial pueden ser más atractivas para proyectos con limitaciones presupuestarias, mientras que las tecnologías con mayores costos iniciales pueden ser justificadas por sus beneficios adicionales y su capacidad para manejar mayores volúmenes de residuos de manera más eficiente.




Figura 2.8: (a) Variación absoluta y (b) relativa del CAPEX de las tecnologías evaluadas.

Al evaluar el CAPEX relativo por unidad de potencia ([Figura 2.8b](#)), se obtiene una perspectiva más clara sobre la eficiencia económica de cada tecnología en función de su capacidad de generación de energía. La INC muestra una disminución en el CAPEX relativo a medida que aumenta la capacidad instalada, comenzando en $28.99 \text{ MUSD MW}^{-1}$ para 100 kW y reduciéndose a $1.49 \text{ MUSD MW}^{-1}$ para 100 MW. Este comportamiento sugiere que la INC se vuelve más viable económicamente a medida que se incrementa la escala del proyecto, haciendo que los costos de capital por unidad de energía producida disminuyan notablemente. La GAS, aunque presenta una tendencia similar, mantiene valores mucho más altos en comparación con las otras tecnologías. Para una capacidad de 100 kW, el CAPEX relativo es de $86.96 \text{ MUSD MW}^{-1}$, y aunque disminuye a $4.46 \text{ MUSD MW}^{-1}$ para 100 MW, sigue siendo considerablemente alto. Este hecho refleja los elevados costos asociados con la implementación y operación de sistemas de GAS, lo cual podría limitar su viabilidad económica a gran escala. En el caso de RSCB, el CAPEX relativo también disminuye con el aumento de la capacidad, siendo de $14.80 \text{ MUSD MW}^{-1}$ para 100 kW y reduciéndose a $1.31 \text{ MUSD MW}^{-1}$ para 100 MW. Esta tendencia muestra que los RSCB pueden ser una opción económicamente eficiente,

especialmente para proyectos a gran escala debido a sus bajos costos de implementación y operación. La DA presenta un patrón similar, con un CAPEX relativo de USD\$13.50 mil/kW para 100 kW que disminuye a 3.51 MUSD kW⁻¹ para 100 MW. Aunque menos eficiente en términos económicos comparada con los RSCB, la DA ofrece beneficios adicionales como la generación de biogás y la capacidad de manejar residuos orgánicos, lo que puede justificar su elección en contextos específicos. Este análisis del CAPEX relativo sugiere que, aunque todas las tecnologías mejoran su eficiencia económica con el aumento de la capacidad instalada, los RSCB presentan la opción más económica a gran escala, seguidos por la INC y la DA, mientras que la GAS, aunque tecnológicamente avanzada, enfrenta desafíos relevantes en términos de costos que podrían limitar su adopción a gran escala. No obstante, la elección de la tecnología óptima debe considerar no solo los costos iniciales y relativos, sino también factores como la complejidad tecnológica, los beneficios adicionales y la capacidad de la tecnología para manejar los volúmenes de residuos previstos.

Adicionalmente, los OPEX representan otro de los retos económicos de estas rutas tecnológicas, llegando a impactar notablemente los indicadores de viabilidad económica. Entre las DA, INC y GAS el OPEX promedio varía entre el 5 % a 17 % del CAPEX de cada tecnología. Los OPEX más altos se relacionan con la DA y la GAS. Por su parte, la DA requiere de operaciones de pretratamiento que consumen energía e insumos de forma moderada ya que se busca garantizar la máxima disponibilidad posible de sustrato en el medio para que los microorganismos no requieran demasiado esfuerzo en generar el biogás, mientras que la GAS requiere etapas de pretratamiento de la biomasa ligadas a la homogeneidad y contenido de humedad bajo requerido por esta tecnología, y etapas posteriores de remoción de alquitrán y cenizas. Ambas, DA y GAS, requieren de personal altamente calificado dadas las complejidades de sus operaciones unitarias. Por otro lado, el RSCB resulta menos complejo de operar y el requerimiento de insumos, mantenimiento y personal calificado es relativamente menor que el de las demás tecnologías evaluadas en este estudio.

2.5.4. Potencial ambiental

Estimar el potencial ambiental de las rutas tecnológicas evaluadas nos permitirá establecer cuál de estas generan un mayor impacto sobre el medio ambiente, que al compararlo con los métodos de tratamiento convencionales locales al lugar de estudio se puede establecer un nivel de mejora en la mitigación ambiental de las emisiones de GEI de los RSM. Existen múltiples métodos para estimar el potencial real de una tecnología, y algunos, como el Análisis de Ciclo de Vida, aunque más detallado y preciso, puede representar un esfuerzo relevante dependiendo de la metodología empleada, aumentando la complejidad de integración en una herramienta metodológica de selección de alternativas de conversión de RSMaE. No obstante, organizaciones de amplio reconocimiento en la lucha contra el cambio climático recomiendan que en las fases de prefactibilidad

de proyectos de conversión de RSMaE se haga uso de indicadores relativamente menos complejos de calcular e interpretar (U.S. EPA, 2021a). Es así cómo, haciendo uso de factores de emisiones, se puede integrar fácilmente los cálculos ambientales con las estimaciones energéticas y económicas, articulando de forma interactiva los diferentes componentes de la herramienta de selección de alternativas. La [Tabla 2.2](#) presenta los principales factores de especies contaminantes emitidas por las tecnologías estudiadas, en comparación con el tratamiento convencional del relleno sanitario (RS).

Tabla 2.2: Datos de emisiones y tecnologías de conversión de RSMaE. Fuente: adaptados utilizando datos de Briones-Hidrovo et al. (2021), Chandel et al. (2012), Chen (2018b), Gutiérrez et al. (2021), Kaur-Sidhu et al. (2020), Singh y Kalamdhad (2022), UKWIn (2018) y U.S. EPA (2023).

Especie	PCG100 (kg _{CO₂,eq} kg ⁻¹)	Tec. de Conversión de RSMaE (g kWh _e ⁻¹)				Tratamiento conven- cional (g m _{CH₄} ⁻³) RS
		INC	GAS	DA	RSCB ^a	
CO ₂	1.0	694	91	140	469	1,976
CO	1.9	-	5.0 × 10 ⁻⁶	1.1	3.0 × 10 ⁻³	0.2
CH ₄	28.0	-	4 × 10 ⁻⁶	-	1.1 × 10 ⁻²	657
N ₂ O	298.0	2.6 × 10 ⁻⁵	-	5.8 × 10 ⁻³	3.1 × 10 ⁻²	0.8

^a Estimado considerando un $f_c=93\%$, y combustión completa.

La [Tabla 2.2](#) revela que, entre las tecnologías evaluadas, la GAS es la de menor intensidad de emisiones de CO₂ siendo hasta ocho veces menor que la INC. Además, la DA se presenta como una tecnología con intensidad de emisión similar a la GAS, aunque 1.5 veces mayor que esta. Asimismo, el RSCB tiene emisiones cercanas a las de la INC aunque mucho menores que la del RS operando en modo convencional. Otros gases, como el CO, CH₄ o N₂O, pueden encontrarse presentes en las emisiones que estas rutas tecnológicas liberan al medioambiente por la valorización energética de los RSM, y aunque sus participaciones pueden ser mucho menores que las del CO₂, su PCG puede ser mucho mayor que este último, por lo que es recomendable estimar su aporte en los cálculos globales de CO₂ equivalente de cada tecnología.

La [Tabla 2.2](#) proporciona una comparación importante de las emisiones de GEI entre diferentes tecnologías de conversión de RSMaE, y el tratamiento convencional de RS. La GAS se destaca por su baja intensidad de emisiones de CO₂, siendo notablemente más eficiente en términos de reducción de emisiones en comparación con la INC. La DA también muestra una eficiencia considerable, aunque con una intensidad de emisiones ligeramente superior a la de GAS. El RSCB presenta una reducción notable de emisiones

en comparación con el tratamiento convencional, aunque sus emisiones son más cercanas a las de INC. Estos resultados sugieren que la adopción de tecnologías como GAS y DA podría desempeñar un papel crucial en la reducción de las emisiones de GEI asociadas con el manejo de RSM.

Desde una perspectiva ambiental, es esencial considerar no solo las emisiones de CO₂, sino también otros GEI como el CH₄ y el N₂O, que, aunque presentes en menores cantidades, tienen un PCG considerablemente alto. Las tecnologías de conversión de RSMAE deben ser evaluadas no solo por su capacidad de reducir las emisiones de CO₂, sino también por su eficacia en la mitigación de estos otros gases. La GAS y la DA son particularmente eficaces en la minimización de las emisiones de CH₄ y N₂O, lo que contribuye a una reducción general en el impacto climático. En contraste, la INC, aunque eficiente en la reducción de volumen de residuos, sigue emitiendo grandes cantidades de CO₂ y otros contaminantes, lo que le confiere una característica indeseable al momento de evaluar alternativas de tratamiento de los RSM por tecnologías más limpias y eficientes.

Además de las emisiones directas de GEI, es importante considerar otros impactos ambientales asociados con estas tecnologías. Por ejemplo, la INC genera cenizas que pueden contener metales pesados y otros contaminantes, los cuales deben ser gestionados adecuadamente para evitar la contaminación del suelo y el agua. La GAS y la DA, por otro lado, generan subproductos que pueden ser reutilizados. El digestato producido por la DA, por ejemplo, puede ser utilizado como fertilizante, cerrando el ciclo de nutrientes y reduciendo la necesidad de fertilizantes químicos. Sin embargo, la calidad del digestato debe ser monitoreada para asegurar que no contenga contaminantes que puedan afectar negativamente el suelo y las aguas subterráneas. En el caso de la GAS, el gas sintético producido puede ser utilizado no solo para la generación de electricidad, sino también como materia prima para la producción de combustibles líquidos y productos químicos, hecho que aumenta la versatilidad y el valor añadido de esta tecnología.

La evaluación de las tecnologías de conversión de RSMAE también puede incluir un análisis de ciclo de vida completo para capturar todos los impactos ambientales asociados desde la recolección y transporte de residuos hasta la disposición final de los subproductos. Este enfoque permite identificar oportunidades para mejorar la eficiencia y reducir las emisiones en todas las etapas del proceso. Por ejemplo, el transporte de RSM a largas distancias puede aumentar colateralmente las emisiones de GEI, aunque la implementación de plantas de tratamiento más cerca de las fuentes de generación de RSM puede reducir estas emisiones de transporte. Además, la integración de tecnologías de CCS en estas rutas tecnológicas podría ofrecer una solución para capturar las emisiones de CO₂ antes de que sean liberadas a la atmósfera, mejorando aún más el perfil ambiental de estas tecnologías.

2.6. Conclusiones del capítulo

La gestión de RSM varía de forma notable entre ciudades, destacando la necesidad de adaptar los programas de gestión de residuos a las características locales. Los residuos orgánicos, que constituyen una gran proporción de los RSM, requieren la implementación de programas de compostaje y DA para una gestión eficiente. Los plásticos y materiales lignocelulósicos también necesitan estrategias de reciclaje y reducción debido a su importante contribución. La menor participación del vidrio y metales sugiere que mejorar las tasas de reciclaje podría aliviar la carga sobre los sistemas de gestión de residuos. La variabilidad en residuos como papel, cartón, madera, y residuos de poda y jardín indican la necesidad de una mejor caracterización para identificar oportunidades de reciclaje y recuperación.

La composición química de los RSM influye en su idoneidad para tecnologías de conversión de RSMaE. Materiales lignocelulósicos y plásticos, con altos contenidos de carbono e hidrógeno, son atractivos para la INC y GAS debido a su alto potencial energético, aunque su variabilidad requiere estrategias de manejo específicas. Los residuos orgánicos, con menor contenido de carbono, pero alta biodegradabilidad, son adecuados para DA y RSCB. La madera y el papel/cartón también son viables para estos procesos, aunque su eficiencia puede verse afectada por etapas de pretratamiento en DA.

Cada tecnología de conversión de RSMaE presenta ventajas y desventajas específicas. La GAS destaca por su alta eficiencia de generación eléctrica, aunque requiere residuos homogéneos y de baja humedad, además de un mantenimiento complejo. La INC es más flexible y tiene una eficiencia atractiva, siendo una tecnología bien probada. La DA es ideal para residuos orgánicos húmedos, con una eficiencia aceptable, aunque su alta tasa de rechazo y costos de pretratamiento aumentan la complejidad y costos operativos. Los RSCB tienen una eficiencia más baja, pero ofrecen una implementación y mantenimiento menos complejos y mayor economía de inversión. La elección de la tecnología óptima dependerá de las características de los residuos, condiciones operativas y objetivos del proyecto de gestión de RSM.

El análisis comparativo del CAPEX y OPEX revela que los RSCB son la opción más económica a gran escala. La INC y la DA muestran mejoras en eficiencia económica con el aumento de la capacidad instalada. La GAS enfrenta desafíos económicos considerables debido a sus elevados costos iniciales y operativos. La adopción de tecnologías avanzadas de conversión de RSMaE puede ofrecer reducciones deseables en las emisiones de GEI en comparación con los métodos tradicionales de manejo de RSM. Evaluar integralmente estas tecnologías es crucial para desarrollar estrategias de gestión de residuos sostenibles y efectivas en la mitigación del cambio climático.

Referencias

- Ahmad, S. I., Ho, W. S., Hassim, M. H., Elagroudy, S., Abdul Kohar, R. A., Bong, C. P. C., Hashim, H., & Rashid, R. (2020). Development of quantitative SHE index for waste to energy technology selection. *Energy*, 191. <https://doi.org/10.1016/j.energy.2019.116534>
- Alves, O., Calado, L., Panizio, R. M., Gonçalves, M., Monteiro, E., & Brito, P. (2021). Techno-economic study for a gasification plant processing residues of sewage sludge and solid recovered fuels. *Waste Management*, 131, 148-162. <https://doi.org/10.1016/j.wasman.2021.05.026>
- Aracil, C., Haro, P., Fuentes-Cano, D., & Gómez-Barea, A. (2018). Implementation of waste-to-energy options in landfill-dominated countries: Economic evaluation and GHG impact. *Waste Management*, 76, 443-456. <https://doi.org/10.1016/j.wasman.2018.03.039>
- Arslan, M., & Yılmaz, C. (2022). Thermodynamic Optimization and Thermoeconomic Evaluation of Afyon Biogas Plant assisted by organic Rankine Cycle for waste heat recovery. *Energy*, 248, 123487. <https://doi.org/10.1016/j.energy.2022.123487>
- Banco de la república de Colombia. (2023). Inflación total y meta. <https://www.banrep.gov.co/es/estadisticas/inflacion-total-y-meta>
- Baoding Baonan Machinery And Equipment Manufacturing Co. Ltd. (2024). Municipal solid waste sorting plant/sorting machine. https://www.alibaba.com/product-detail/Municipal-solid-waste-sorting-plant-sorting%5C_1600618514423.html?spm=a2700.7724857.0.0.1c395e2fO506RW
- Bertanza, G., Ziliani, E., & Menoni, L. (2018). Techno-economic performance indicators of municipal solid waste collection strategies. *WASTE MANAGEMENT*, 74, 86-97. <https://doi.org/10.1016/j.wasman.2018.01.009>
- Boumanchar, I., Chhiti, Y., M'hamdi Alaoui, F. E., Sahibed-dine, A., Bentiss, F., Jamma, C., & Bensitel, M. (2019). Municipal solid waste higher heating value prediction from ultimate analysis using multiple regression and genetic programming techniques. *Waste Management and Research*, 37(6), 578-589. <https://doi.org/10.1177/0734242X18816797>
- Briones-Hidrovo, A., Copa, J., Tarelho, L. A., Gonçalves, C., Pacheco da Costa, T., & Dias, A. C. (2021). Environmental and energy performance of residual forest biomass for electricity generation: Gasification vs. combustion. *Journal of Cleaner Production*, 289, 125680. <https://doi.org/10.1016/j.jclepro.2020.125680>
- Brynda, J., Skoblia, S., Pohořelý, M., Beňo, Z., Soukup, K., Jeremiáš, M., Moško, J., Zach, B., Trakal, L., Šyc, M., & Svoboda, K. (2020). Wood chips gasification in a fixed-bed multi-stage gasifier for decentralized high-efficiency CHP and biochar production: Long-term commercial operation. *Fuel*, 281, 118637. <https://doi.org/10.1016/j.fuel.2020.118637>

- Bui, T.-D., Tseng, J.-W., Tseng, M.-L., Wu, K.-J., & Lim, M. (2023). Municipal solid waste management technological barriers: A hierarchical structure approach in Taiwan. *Resources, Conservation and Recycling*, 190. <https://doi.org/10.1016/j.resconrec.2022.106842>
- Chandel, M. K., Kwok, G., Jackson, R. B., & Pratson, L. F. (2012). The potential of waste-to-energy in reducing GHG emissions. *Carbon Management*, 3(2), 133-144. <https://doi.org/10.4155/cmt.12.11>
- Chen, Y.-C. (2018a). Effects of urbanization on municipal solid waste composition. *Waste Management*, 79, 828-836. <https://doi.org/10.1016/j.wasman.2018.04.017>
- Chen, Y.-C. (2018b). Evaluating greenhouse gas emissions and energy recovery from municipal and industrial solid waste using waste-to-energy technology. *Journal of Cleaner Production*, 192, 262-269. <https://doi.org/10.1016/j.jclepro.2018.04.260>
- Congreso de la República de Colombia. (2014, mayo). *Ley 1715 de 2014*. Diario Oficial 49.150. <http://svrpubindc.imprenta.gov.co/diario>
- Coral Medina, J. D., Alomia, F. B., Magalhaes, A. I., Cesar de Carvalho, J., Woiciechowsky, A. L., & Soccol, C. R. (2021). Simulation of different biorefinery configuration including environmental, technical and economic assay using sugarcane bagasse. *Journal of Cleaner Production*, 316, 128162. <https://doi.org/10.1016/j.jclepro.2021.128162>
- Cucchiella, F., D'Adamo, I., & Rosa, P. (2016). Urban waste to energy (WTE) plants: A social analysis. *JP Journal of Heat and Mass Transfer*, 13(3), 421-444. <https://doi.org/10.17654/MT013030421>
- Dalke, R., Demro, D., Khalid, Y., Wu, H., & Urgan-Demirtas, M. (2021). Current status of anaerobic digestion of food waste in the United States. *Renewable and Sustainable Energy Reviews*, 151, 111554. <https://doi.org/10.1016/j.rser.2021.111554>
- Gómez, A., Zubizarreta, J., Rodrigues, M., Dopazo, C., & Fueyo, N. (2010). Potential and cost of electricity generation from human and animal waste in Spain. *Renewable Energy*, 35(2), 498-505. <https://doi.org/10.1016/j.renene.2009.07.027>
- Gutiérrez, A. S., Mendoza Fandiño, J. M., & Cabello Eras, J. J. (2021). Alternatives of municipal solid wastes to energy for sustainable development. The case of Barranquilla (Colombia). *International Journal of Sustainable Engineering*, 14(6), 1809-1825. <https://doi.org/10.1080/19397038.2021.1993378>
- Huang, Y.-F., & Lo, S.-L. (2020). Predicting heating value of lignocellulosic biomass based on elemental analysis. *Energy*, 191, 116501. <https://doi.org/10.1016/j.energy.2019.116501>

- Ibikunle, R. A., Lukman, A. F., Titiladunayo, I. F., Akeju, E. A., & Dahunsi, S. O. (2020). Modeling and robust prediction of high heating values of municipal solid waste based on ultimate analysis. *Energy Sources, Part A: Recovery, Utilization and Environmental Effects*. <https://doi.org/10.1080/15567036.2020.1841343>
- IEA Bioenergy. (2018). Gasification of waste for energy carriers - a review. <https://www.ieabioenergy.com/blog/publications/gasification-of-waste-for-energy-carriers-a-review/>
- IPCC. (2019). Volume 5: Waste. *2019 Refinement to the 2006 IPCC Guidelines for National Greenhouse Gas Inventories*. <https://www.ipcc-nggip.iges.or.jp/public/2019rf/vol5.html>
- IRENA. (2021). *Perspectivas de la transición energética mundial: camino de 1.5 °C*. <https://www.irena.org/publications/2021/Jun/Perspectivas-de-la-transicion-energetica-mundial>
- IRENA. (2022). *Renewable power generation costs in 2021*. <https://www.irena.org/Publications/>
- Izquierdo-Horna, L., Kahhat, R., & Vázquez-Rowe, I. (2022). Reviewing the influence of sociocultural, environmental and economic variables to forecast municipal solid waste (MSW) generation. *Sustainable Production and Consumption*, 33, 809-819. <https://doi.org/10.1016/J.SPC.2022.08.008>
- Juárez-Hernández, S. (2021). Energy, environmental, resource recovery, and economic dimensions of municipal solid waste management paths in Mexico city. *Waste Management*, 136, 321-336. <https://doi.org/10.1016/j.wasman.2021.10.026>
- Kaur-Sidhu, M., Ravindra, K., Mor, S., & John, S. (2020). Emission factors and global warming potential of various solid biomass fuel-cook stove combinations. *Atmospheric Pollution Research*, 11(2), 252-260. <https://doi.org/10.1016/j.apr.2019.10.009>
- Kaza, S., Yao, L. C., Bhada-Tata, P., & Van Woerden, F. (2018, septiembre). *What a Waste 2.0: A Global Snapshot of Solid Waste Management to 2050*. Washington, DC: World Bank. <https://doi.org/10.1596/978-1-4648-1329-0>
- Khan, A. H., López-Maldonado, E. A., Alam, S. S., Khan, N. A., López, J. R. L., Herrera, P. F. M., Abutaleb, A., Ahmed, S., & Singh, L. (2022). Municipal solid waste generation and the current state of waste-to-energy potential: State of art review. *Energy Conversion and Management*, 267, 115905. <https://doi.org/10.1016/j.enconman.2022.115905>
- Liu, Y., Liao, C., Tang, Y., Tang, J., Sun, Y., & Ma, X. (2022). Techno-environmental-economic evaluation of the small-scale municipal solid waste (MSW) gasification-based and incineration-based power generation plants. *Journal of the Taiwan Institute of Chemical Engineers*, 141. <https://doi.org/10.1016/j.jtice.2022.104594>

- Makarichi, L., Jutidamrongphan, W., & Techato, K.-A. (2018). The evolution of waste-to-energy incineration: A review. *Renewable and Sustainable Energy Reviews*, 91, 812-821. <https://doi.org/10.1016/j.rser.2018.04.088>
- Ming, Z., Jinhui, D., Liang, W., & Shanshan, G. (2014). Effect of urbanization on generation in China. *Power*, 158(8). <https://www.powermag.com/effects-of-urbanization-on-generation-in-china/>
- Moya, D., Aldás, C., López, G., & Kaparaju, P. (2017). Municipal solid waste as a valuable renewable energy resource: A worldwide opportunity of energy recovery by using Waste-To-Energy Technologies. *Energy Procedia*, 134, 286-295. <https://doi.org/10.1016/j.egypro.2017.09.618>
- Mukherjee, C., Denney, J., Mbonimpa, E., Slagley, J., & Bhowmik, R. (2020). A review on municipal solid waste-to-energy trends in the USA. *Renewable and Sustainable Energy Reviews*, 119, 109512. <https://doi.org/10.1016/j.rser.2019.109512>
- Munir, M., Mohaddespour, A., Nasr, A., & Carter, S. (2021). Municipal solid waste-to-energy processing for a circular economy in New Zealand. *Renewable and Sustainable Energy Reviews*, 145. <https://doi.org/10.1016/j.rser.2021.111080>
- OCDE. (2022). Municipal waste (indicator). <https://doi.org/10.1787/89d5679a-en>
- Otero Meza, D. D., Sagastume Gutiérrez, A., Cabello Eras, J. J., Salcedo Mendoza, J., & Hernández Ruydiaz, J. (2023). Techno-economic and environmental assessment of the landfill gas to energy potential of major Colombian cities. *Energy Conversion and Management*, 293, 117522. <https://doi.org/10.1016/j.enconman.2023.117522>
- Ozcan, H., Guvenc, S., Guvenc, L., & Demir, G. (2016). Municipal solid waste characterization according to different income levels: A case study. *Sustainability (Switzerland)*, 8(10). <https://doi.org/10.3390/su8101044>
- Paulauskaite-Taraseviciene, A., Raudonis, V., & Sutiene, K. (2022). Forecasting municipal solid waste in Lithuania by incorporating socioeconomic and geographical factors. *Waste Management*, 140, 31-39. <https://doi.org/10.1016/j.wasman.2022.01.004>
- Perera, A. T. D., Madusanka, A. N., & De Alwis, A. A. P. (2013). Techno-economical optimization of a solid waste management system using evolutionary algorithms. *International Conference on Advances in ICT for Emerging Regions, ICTer 2013 - Conference Proceedings*, 92-97. <https://doi.org/10.1109/ICTer.2013.6761161>
- Peters, M. S., Timmerhaus, K. D., & West, R. E. (2003). *Plant Design and Economics for Chemical Engineers*. McGraw-Hill Education. <https://books.google.com.co/books?id=3uVFkBBHyP8C>
- Prabowo, B., Simanjuntak, F. S. H., Saldi, Z. S., Samyudia, Y., & Widjojo, I. J. (2019). Assessment of waste to energy technology in Indonesia: A techno-economical perspective on a 1000 ton/day scenario. *International Journal of Technology*, 10(6), 1228-1234. <https://doi.org/10.14716/ijtech.v10i6.3607>

- Rezaei, M., Ghobadian, B., Samadi, S. H., & Karimi, S. (2018). Electric power generation from municipal solid waste: A techno-economical assessment under different scenarios in Iran. *Energy*, 152, 46-56. <https://doi.org/10.1016/j.energy.2017.10.109>
- Rodrigues, L., Santos, I., Santos, T., Barros, R., & Tiago Filho, G. (2022). Energy and economic evaluation of MSW incineration and gasification in Brazil. *Renewable Energy*, 188, 933-944. <https://doi.org/10.1016/j.renene.2022.02.083>
- Satiada, M. A., & Calderon, A. (2021). Comparative analysis of existing waste-to-energy reference plants for municipal solid waste. *Cleaner Environmental Systems*, 3, 100063. <https://doi.org/10.1016/j.cesys.2021.100063>
- Schneider, D. R., & Ragossnig, A. M. (2015). Recycling and incineration, contradiction or coexistence? *Waste Management and Research*, 33(8), 693-695. <https://doi.org/10.1177/0734242X15593421>
- Shi, H., Mahinpey, N., Aqsha, A., & Silbermann, R. (2016). Characterization, thermochemical conversion studies, and heating value modeling of municipal solid waste. *Waste Management*, 48, 34-47. <https://doi.org/10.1016/j.wasman.2015.09.036>
- Shi, Y., Li, Y., Yuan, X., Fu, J., Ma, Q., & Wang, Q. (2020). Environmental and human health risk evaluation of heavy metals in ceramsites from municipal solid waste incineration fly ash. *ENVIRONMENTAL GEOCHEMISTRY AND HEALTH*, 42(11), 3779-3794. <https://doi.org/10.1007/s10653-020-00639-7>
- Silva, L. J. d. V. B. d., Santos, I. F. S. d., Mensah, J. H. R., Gonçalves, A. T. T., & Barros, R. M. (2020). Incineration of municipal solid waste in Brazil: An analysis of the economically viable energy potential. *Renewable Energy*, 149, 1386-1394. <https://doi.org/10.1016/j.renene.2019.10.134>
- Singh, P., & Kalamdhad, A. S. (2022). Assessment of agricultural residue-based electricity production from biogas in India: Resource-environment-economic analysis. *Sustainable Energy Technologies and Assessments*, 54, 102843. <https://doi.org/10.1016/j.seta.2022.102843>
- Sun, Y., Qin, Z., Tang, Y., Huang, T., Ding, S., & Ma, X. (2021). Techno-environmental-economic evaluation on municipal solid waste (MSW) to power/fuel by gasification-based and incineration-based routes. *Journal of Environmental Chemical Engineering*, 9(5). <https://doi.org/10.1016/j.jece.2021.106108>
- Tonjes, D. J., & Greene, K. L. (2012). A review of national municipal solid waste generation assessments in the USA. *WASTE MANAGEMENT & RESEARCH*, 30(8), 758-771. <https://doi.org/10.1177/0734242X12451305>
- Tsui, T.-H., & Wong, J. (2019). A critical review: emerging bioeconomy and waste-to-energy technologies for sustainable municipal solid waste management. *Waste Disposal and Sustainable Energy*, 1(3), 151-167. <https://doi.org/10.1007/s42768-019-00013-z>

- UKWin. (2018). Evaluation of the climate change impacts of waste incineration in the United Kingdom. <https://ukwin.org.uk/files/pdf/UKWIN-2018-Incineration-Climate-Change-Report.pdf>
- Unidad de Planeación Minero Energética (UPME) & INERCO Consultoría Colombia. (2018). Valorización energética de residuos: proyecto WtE Colombia. <http://bdigital.upme.gov.co/handle/001/1339>
- U.S. EPA. (2005a). EPA Software and Manuals. <https://www.epa.gov/catc/clean-air-technology-center-products#software>
- U.S. EPA. (2005b). LandGEM V3.02. <https://www.epa.gov/>
- U.S. EPA. (2021a). LFGcost-Web — Landfill Gas Energy Cost Model. <https://www.epa.gov/lmop/lfgcost-web-landfill-gas-energy-cost-model>
- U.S. EPA. (2021b). Zero Waste Case Study: San Francisco. <https://www.epa.gov/transforming-waste-tool/zero-waste-case-study-san-francisco>
- U.S. EPA. (2023). IPCC AR4, AR5, and AR6 20-, 100-, and 500-year GWPs. <https://catalog.data.gov/dataset/ipcc-ar4-ar5-and-ar6-20-100-and-500-year-gwps>
- Vallejo, F., Díaz-Robles, L., Cubillos, F., Espinoza, A., Espinoza, L., Pinilla, F., & Pino-Cortes, E. (2020). Valorization of municipal solid waste using hydrothermal carbonization and gasification: A review. *Chemical Engineering Transactions*, 81, 1045-1050. <https://doi.org/10.3303/CET2081175>
- Villa-Loaiza, C., Taype-Huaman, I., Benavides-Franco, J., Buenaventura-Vera, G., & Carabalí-Mosquera, J. (2023). Does climate impact the relationship between the energy price and the stock market? The Colombian case. *Applied Energy*, 336, 120800. <https://doi.org/10.1016/j.apenergy.2023.120800>
- Wilk, V., & Hofbauer, H. (2013). Influence of fuel particle size on gasification in a dual fluidized bed steam gasifier. *Fuel Processing Technology*, 115, 139-151. <https://doi.org/10.1016/j.fuproc.2013.04.013>
- Wójtowicz-Wróbel, A. (2017). Social reception of thermal waste processing system structures. *International Multidisciplinary Scientific GeoConference Surveying Geology and Mining Ecology Management, SGEM*, 17(41), 209-216. <https://doi.org/10.5593/sgem2017/41/S18.027>
- Woolcock, P. J., & Brown, R. C. (2013). A review of cleaning technologies for biomass-derived syngas. *Biomass and Bioenergy*, 52, 54-84. <https://doi.org/10.1016/j.biombioe.2013.02.036>
- World Bank. (2019). City level dataset. <https://datacatalog.worldbank.org/search/dataset/0039597/What-a-Waste-Global-Database>
- XM. (2023). Precio de bolsa y escasez. <https://www.xm.com.co/transacciones/cargo-por-confiabilidad/precio-de-bolsa-y-escasez>

- Zambrano-Monserrate, M., Ruano, M., & Ormeño-Candelario, V. (2021). Determinants of municipal solid waste: a global analysis by countries' income level. *Environmental Science and Pollution Research*, 28(44), 62421-62430. <https://doi.org/10.1007/s11356-021-15167-9>
- Zhang, G., Liu, K., Lv, L., Gao, W., Li, W., Ren, Z., Yan, W., Wang, P., Liu, X., & Sun, L. (2023). Enhanced landfill process based on leachate recirculation and micro-aeration: A comprehensive technical, environmental, and economic assessment. *Science of The Total Environment*, 857, 159535. <https://doi.org/10.1016/j.scitotenv.2022.159535>
- Zhou, H., Meng, A., Long, Y., Li, Q., & Zhang, Y. (2014). An overview of characteristics of municipal solid waste fuel in China: Physical, chemical composition and heating value. *Renewable and Sustainable Energy Reviews*, 36, 107-122. <https://doi.org/10.1016/j.rser.2014.04.024>
- Zhucheng Holy Shield Environmental Science & Technology Co. Ltd. (2024). Municipal Solid Waste Sorting Machines Automatic Waste Sorting Machine. https://www.alibaba.com/product-detail/Municipal-Solid-Waste-Sorting-Machines-Automatic%5C_1600919537394.html?spm=a2700.7724857.0.0.1c395e2fO506RW
- Zia, A., Batool, S. A., Chauhdry, M. N., & Munir, S. (2017). Influence of Income Level and Seasons on Quantity and Composition of Municipal Solid Waste: A Case Study of the Capital City of Pakistan. *SUSTAINABILITY*, 9(9). <https://doi.org/10.3390/su9091568>

Capítulo 3

Análisis de Series de Tiempo de RSM

Resumen del capítulo: Este capítulo presenta un análisis de series de tiempo para la gestión de RSM, destacando la importancia de modelos predictivos para la planificación. Se examinaron métodos como el Autorregresivo Integrado de Media Móvil (ARIMA), ARIMA estaiconal (SARIMA) y SARIMA con varibales exógenas (SARIMAX), seleccionando SARIMAX por su capacidad para integrar estacionalidad y variables exógenas. El análisis de series temporales de las Tasas de Disposición de los RSM (TDRSM) reveló patrones estacionales con picos en diciembre y enero, correlacionados con factores socioeconómicos. La descomposición de series de tiempo identificó una tendencia creciente de TDRSM y cambios en su estacionalidad. El modelo SARIMAX, validado con un MAPE menor al 5 %, demostró ser una herramienta precisa para la proyección de TDRSM.

Palabras clave – Series de tiempo; Modelos ARIMA; Pronóstico residuos; Estacionalidad; Gestión de RSM

3.1. Introducción

La gestión de los RSM es un desafío crítico para las ciudades modernas debido al crecimiento poblacional y la urbanización, lo que resulta en un aumento sostenido en la generación de residuos (Kaza et al., 2018). No obstante, la planeación de estrategias apropiadas para el manejo de los RSM implica contar con una incertidumbre aceptable al momento de proyectar la generación de estos residuos en el futuro (Singh & Uppaluri, 2022). En ese orden, el análisis de series de tiempo provee una herramienta valiosa para predecir futuras tendencias, optimizar estrategias de recolección y tratamiento, y evaluar el impacto de políticas de gestión (Andreas et al., 2022). Además, este enfoque facilita la identificación de eventos atípicos y permite evaluar su impacto en la generación de

residuos, contribuyendo a una gestión más eficiente y sostenible (Gonçalves & Silva, 2021). El análisis de series de tiempo ha ganado relevancia en la investigación científica y en la gestión de RSM dado que permite comprender la evolución de las tasas de generación de estos residuos a lo largo del tiempo, identificando tendencias, patrones estacionales y variaciones cíclicas (Andreas et al., 2022).

Los métodos reportados para desarrollar proyecciones de los RSM (Tabla 3.1) han experimentado una evolución importante en la última década, principalmente desde el año 2021, por lo que hoy en día se puede encontrar enfoques de análisis de series de tiempo, aplicación de métodos de inteligencia artificial, abordajes Bayesianos, e incluso modelos híbridos entre diferentes enfoques. Entre estos, el análisis de series de tiempo destaca sobre otros enfoques por varias razones. En primer lugar, su capacidad para capturar patrones temporales inherentes a la generación de residuos permite una comprensión integral de la evolución de las tasas de generación de RSM (Li et al., 2022). Este enfoque también facilita la identificación de tendencias a largo plazo y de variaciones estacionales, lo que es fundamental para la planificación y la gestión eficaces de los residuos. Además, la simplicidad de los modelos de series de tiempo, como el modelo ARIMA, permite una implementación práctica en la gestión de RSM, ofreciendo predicciones precisas con requerimientos computacionales moderados (Dodo et al., 2022). A diferencia de otros enfoques, el análisis de series de tiempo puede capturar de manera efectiva la estacionalidad y las fluctuaciones cíclicas (Box et al., 2015), proporcionando información crítica para la toma de decisiones en el sector de la gestión de RSM. Esta fortaleza inherente, combinada con su flexibilidad para integrar nuevos datos, hace que el análisis de series de tiempo sea un pilar esencial en el campo de la gestión sostenible de RSM.

Tabla 3.1: Métodos y variables exógenas utilizadas en modelos de predicción de RSM

Método	Variables Exógenas	Fuente
Sistemas dinámicos	Métodos de tratamiento de RSM	(Al-Shihabi et al., 2023)
SARIMA	-	(Mahmud et al., 2023)
GM	Densidad poblacional; PIB	(Pudcha et al., 2023)
ANN	Población urbana; Densidad poblacional; Desempleo; PIB; Consumo; Suministro de agua; otros.	(Zhu et al., 2023)
ETS	-	(Otero Meza et al., 2023)

(Continúa en la siguiente página.)

Tabla 3.1 (continuación)

Método	Variables Exógenas	Fuente
GM	Población; Número de hogares; Ingreso; PIB; Velocidad del viento; Temperatura; Humedad	(Islam et al., 2022)
CNN; LSTM; NN	Población; Hogares; PIB; Empleo; otros.	(Lin et al., 2022)
kNN	Población; Desempleo; Turismo; PIB; Exportación; Importación; otros.	(Paulauskaite-Taraseviciene et al., 2022)
LSTM	Población; Turismo; PIB; Consumo; Inversión.	(Wang et al., 2022)
ANN; SVM	Población; Empleo formal; Desempleo; Número de unidades familiares	(Ayeleru et al., 2021)
Bayesian approach	Edad; Estado marital; Inmigración; Educación; Ingreso; Género	(Cubillos et al., 2021)
Evolutionary-decomposition model	Precipitación; Temperatura máxima; Temperatura promedio; Población; Tamaño de vivienda; Población de hombres educados; Población de mujeres educadas; Ingreso.	(Fan et al., 2021)
ANN	Gross domestic product (GDP); population; household size; numbers of months	(Liang et al., 2021)
CNN; LSTM	Población; Hogares; PIB; Empleo.	(Lin et al., 2022)
LM; SVM; Cubist; RF; kNN	Ingreso per cápita; Gasto per cápita; Densidad poblacional; Ventas minoristas; Población urbana; Camas de hospital; Área residencial	(Nguyen et al., 2021)
LSTM; ANN; ARIMA	-	(Niu et al., 2021)
LM; Non-Linear; NNAR	-	(Sunayana et al., 2021)

Adicionalmente, el modelo ARIMA y sus variantes avanzadas, como SARIMA, se destacan por incorporar la estacionalidad de manera explícita (Adu et al., 2023), permitiendo modelar con precisión las variaciones cíclicas asociadas a la generación de RSM a lo largo del año. Esto es crucial en el sector de la gestión de residuos, donde las tendencias estacionales pueden influir notablemente en la generación y recolección de residuos. Por otro lado, modelos como SARIMAX amplía aún más la versatilidad de SARIMA al permitir la inclusión de variables exógenas en el modelo (Connolly, 2021), como factores socioeconómicos, demográficos o eventos atípicos que pueden impactar en la generación

de residuos. Esto facilita la construcción de modelos más realistas y predictivos, superando limitaciones de métodos como redes neuronales, modelos k-nearest, SVM, CNN y el enfoque bayesiano, que a menudo requieren una gran cantidad de datos o una mayor complejidad computacional para captar adecuadamente estas dinámicas. No obstante, la aplicación de un modelo que contemple variables exógenas depende principalmente de la disponibilidad de series de tiempo de variables predictoras de los RSM, lo que resulta especialmente desafiante en países en desarrollo por manejar sistemas de información de baja calidad (Otero Meza et al., 2023). Finalmente, la simplicidad de implementación y la capacidad de adaptarse a series de tiempo con diferentes componentes, incluyendo tendencias, estacionalidades y variables exógenas, hace que ARIMA y sus variaciones sean altamente efectivas para el análisis de RSM. En comparación con modelos como el Grey Model (Modelo Gris), SARIMA representa una opción viable para ajustar y predecir patrones complejos, convirtiéndose en herramientas fundamentales para la gestión sostenible y eficiente de RSM. Una de las limitaciones al aplicar métodos de aprendizaje automático, tales como las redes neuronales, es el tamaño de las observaciones en los conjuntos de datos, que pueden variar desde miles hasta millones (Mariano-Hernández et al., 2022). Por esta razón, métodos como SARIMAX resultan más adecuados para analizar series temporales que muestran patrones y tendencias característicos de variables como la TDRSM.

El enfoque de Dinámica de Sistemas tiene sus raíces en la modelización de sistemas interconectados (Al-Shihabi et al., 2023), desde una perspectiva holística que maneja diferentes componentes interdependientes, destacando la importancia de comprender la dinámica de dichos sistemas complejos. Una desventaja de este enfoque es su potencial rigidez, la cual podría verse afectada por patrones típicos de variaciones inesperadas en la generación de RSM, especialmente en áreas o regiones con un rápido crecimiento económico.

La inteligencia artificial y el aprendizaje automático para la predicción de series de tiempo son una alternativa útil. Por ejemplo, los métodos de Redes Neuronales Artificiales (ANN) y Memoria a Largo Plazo (LSTM) proyectan una mayor adaptabilidad en la modelización de series de tiempo en el futuro cercano (Lin et al., 2022; Zhu et al., 2023). Estos modelos pueden analizar conjuntos de datos multifacéticos, reconociendo patrones sutiles y refinando iterativamente sus capacidades predictivas al integrar diversas fuentes de datos para mejorar las proyecciones. Una preocupación principal al utilizar estos métodos es su naturaleza de “caja negra”, lo que resulta difícil de comprender, especialmente para las partes interesadas que requieren un proceso de toma de decisiones más transparente. Además, su desempeño está estrechamente relacionado con la disponibilidad y la calidad de grandes conjuntos de datos, lo que puede ser una limitación en varios casos.

El Modelo Gris (GM), orientado a manejar información “gris” o incierta, es adecuado para predecir conjuntos de datos de tamaño limitado o con información incompleta (Islam et al., 2022; Pudcha et al., 2023). Las principales fortalezas de los modelos GM son su simplicidad y eficiencia, requiriendo a menudo datos mínimos para hacer predicciones. Estos modelos funcionan al desarrollar una relación entre los datos acumulados e incrementales para proporcionar proyecciones rápidas y son valiosos para escenarios con registros históricos limitados. No obstante, su simplicidad también es una limitación al tratar con sistemas o conjuntos de datos complejos.

El modelo ETS descompone los datos de la serie de tiempo en tres componentes principales: error, tendencia y estacionalidad (Otero Meza et al., 2023). Al abordar estos componentes por separado, este modelo es particularmente efectivo para conjuntos de datos con patrones temporales evidentes, y su versatilidad le permite adaptarse a diferentes tendencias y estacionalidades. Sin embargo, la dependencia de la descomposición de estos componentes puede afectar su desempeño en conjuntos de datos donde cambios repentinos e inesperados interrumpen patrones establecidos.

Las Redes Neuronales Convolucionales (CNN) y la Memoria a Largo Plazo (LSTM) se basan en el aprendizaje profundo para la predicción (Lin et al., 2022). Por un lado, los métodos CNN se utilizan principalmente para el reconocimiento de imágenes. Estos métodos han sido aplicados en la predicción de series de tiempo al detectar patrones dentro de secuencias de datos, de manera similar a su capacidad para identificar formas o texturas en imágenes. Por otro lado, LSTM es una forma especializada del método de Redes Neuronales Recurrentes (RNN), y es útil para aprender de dependencias a largo plazo en secuencias de datos. La arquitectura de LSTM le permite “recordar” patrones durante períodos prolongados, lo que la hace ideal para series de tiempo con efectos de largo plazo. Aunque ambos métodos, RNN y LSTM, ofrecen alta precisión, requieren recursos computacionales sustanciales y grandes conjuntos de datos para su entrenamiento, lo que, en algunos casos, limita su aplicación.

El método Bayesiano integra el conocimiento previo de un sistema con datos observados actuales para hacer predicciones (Cubillos et al., 2021). Su fortaleza radica en su naturaleza probabilística, ofreciendo un rango de resultados con probabilidades asociadas en lugar de una predicción determinista única. Por lo tanto, proporciona un marco para incorporar la incertidumbre en las proyecciones, haciéndolo valioso para escenarios con variabilidad inherente. Entre sus desventajas, destaca el hecho que su aplicación requiere distribuciones previas bien definidas, lo que puede introducir subjetividad (si la distribución previa no se alinea bien con los datos, puede conducir a predicciones sesgadas). Además, puede tener una alta demanda computacional, especialmente para modelos grandes o complejos.

Fan et al. (2021) introdujeron un modelo que combina algoritmos evolutivos y técnicas de descomposición tradicionales. Los algoritmos evolutivos, inspirados en la selección natural, evolucionan iterativamente un conjunto de soluciones para optimizar un objetivo dado. Cuando se combinan con la descomposición, donde los datos de la serie de tiempo se descomponen en partes, este modelo puede navegar hábilmente las complejidades de los datos de RSM. Al evolucionar soluciones basadas en las partes componentes, se pueden identificar relaciones difíciles y patrones temporales. Para esto, su naturaleza evolutiva requiere numerosas iteraciones, lo que a su vez resulta en una alta demanda computacional.

SARIMA es una herramienta adecuada para el análisis de series de tiempo utilizada para conjuntos de datos que presentan estacionalidad pronunciada y patrones temporales recurrentes (Mahmud et al., 2023). La fortaleza de SARIMA radica en su capacidad para predecir fluctuaciones cíclicas, lo que es crucial en la planificación de la gestión de residuos. Adicionalmente, SARIMAX genera pronósticos con menor incertidumbre al integrar variables exógenas (por ejemplo, cambios en la política, fluctuaciones económicas, etc.), logrando explicar mejor las influencias externas que afectan la generación de RSM. La versatilidad de este método, combinada con su capacidad para considerar la influencia de variables externas, lo hace una alternativa atractiva, aunque su aplicación efectiva requiere comprender las relaciones subyacentes entre las variables exógenas y las tasas de generación de RSM.

La predicción de RSM no se trata de encontrar una solución “*única para todos*”, sino de alinear el método adecuado con conjuntos de datos específicos (dependiendo de las características del conjunto de datos). La planificación efectiva de la gestión de residuos depende de la capacidad para seleccionar el método adecuado para predecir la generación de RSM. Adoptar el método de predicción apropiado no solo respalda el proceso de toma de decisiones tecnoeconómicas, sino que es fundamental en la gestión sostenible de recursos para mitigar los impactos ambientales y garantizar la viabilidad y sostenibilidad de los sistemas de valorización de RSM.

En esta sección, nos enfocamos en la presentación de una metodología útil para la construcción de un modelo para la serie de tiempo de disposición de RSM. La adecuada predicción y análisis de la generación de RSM es fundamental para la gestión eficiente de estos desechos y la reducción de su impacto ambiental negativo. Para abordar esta necesidad, se emplean técnicas avanzadas de análisis de series de tiempo que nos permiten entender y predecir las dinámicas de generación de residuos. La discusión se organiza en varias subsecciones críticas. Inicialmente, examinamos el comportamiento de las series de tiempo de generación de RSM, identificando patrones y tendencias en los datos. Seguido de esto, se aborda la descomposición de series de tiempo para desglosar los datos en componentes interpretables que faciliten un análisis más profundo. La sección de características relevantes de las series de tiempo se centra en identificar aquellos atributos clave que influyen la generación de RSM, aplicando pruebas estadísticas para

probar o rechazar hipótesis críticas. Posteriormente, se introduce el método SARIMAX, una técnica estadística de modelado y pronóstico que se adapta bien a series temporales no estacionarias con patrones estacionales, para lo cual se empleó el lenguaje R (R Core Team, 2024) a través de RStudio® (RStudio Team, 2020), siendo ‘fpp3’ (R. Hyndman, 2024) la librería principal utilizada en el algoritmo, con lo cual se obtuvieron tanto las estimaciones estadísticas como las figuras presentadas en este capítulo, con excepción de los diagramas de flujo. Finaliza, con la discusión sobre cómo implementar y validar el modelo propuesto para asegurar su eficacia y precisión en la predicción de la generación de RSM.

El algoritmo mostrado en la [Figura 3.1](#) representa un marco general del procedimiento de pronóstico, que generalmente involucra cinco pasos básicos según R. J. Hyndman y Athanasopoulos (2021):

- Paso 1. *Definición del problema*: este es frecuentemente el aspecto más desafiante del pronóstico. Definir el problema con precisión implica comprender cómo se utilizarán los pronósticos, identificar a los usuarios de los pronósticos y determinar cómo se integra el proceso de pronóstico dentro de la organización que lo necesita. Los pronosticadores deberían invertir tiempo en discusiones con las personas involucradas en la recolección de datos, la gestión de bases de datos y aquellos que utilizarán los pronósticos para la planificación estratégica.
- Paso 2. *Recolección de información*: generalmente hay dos tipos esenciales de información necesaria: (a) datos estadísticos, y (b) perspectivas de individuos con experiencia en la recopilación y aplicación de los datos a los pronósticos. A veces puede ser difícil recopilar suficientes datos históricos para un modelo estadístico robusto. En tales circunstancias, puede ser necesario depender del pronóstico basado en juicio. A veces, los datos históricos pueden volverse irrelevantes debido a cambios estructurales en el sistema objetivo; en tales casos, podría ser prudente considerar solo los datos más recientes. No obstante, los modelos estadísticos robustos están diseñados para adaptarse a cambios graduales en el sistema; por lo tanto, los datos valiosos no deben descartarse sin motivo.
- Paso 3. *Análisis inicial*: se comienza visualizando los datos para identificar cualquier patrón consistente, tendencias notables, estacionalidad o ciclos empresariales. ¿Hay anomalías que los expertos necesiten abordar? Es necesario evaluar la fuerza de las relaciones entre las variables en análisis. Hay diversas herramientas analíticas disponibles para facilitar este proceso.
- Paso 4. *Selección y aplicación del modelo*: la elección del modelo adecuado depende de la disponibilidad de datos históricos, la fuerza de las relaciones entre las variables y el uso previsto de los pronósticos. Es habitual evaluar varios modelos potenciales, cada uno basado en diferentes supuestos y parámetros que necesitan ser estimados a partir de datos históricos.




Figura 3.1: Marco metodológico utilizado para obtener la proyección de las TDRSM.
Fuente: elaboración propia.

Paso 5. *Implementación y evaluación del modelo de pronóstico*: tras seleccionar un modelo y estimar sus parámetros, se emplea para generar pronósticos. La eficacia del modelo solo puede juzgarse una vez que los datos reales correspondientes al período de pronóstico estén disponibles. Existen varios métodos para evaluar la precisión del pronóstico. Además, hay consideraciones organizacionales en la aplicación y respuesta a los pronósticos, incluyendo problemas prácticos como manejar datos faltantes y anomalías, o lidiar con datos de series temporales limitados.

3.2. Datos de disposición de RSM

Diferentes agencias reguladoras monitorean y supervisan los servicios públicos en Colombia, incluyendo la gestión de residuos, los mercados de energía, etc. En particular, los datos de gestión de RSM son reportados mensualmente por los diferentes sitios de disposición a la Superintendencia de Servicios Públicos Domiciliarios (SSPD) de Colombia, lo cual se resume en un informe anual. Además, el Departamento Administrativo Nacional de Estadística (DANE) recopila datos socioeconómicos, incluyendo demografía como población y PIB en conjuntos de datos públicos, lo que puede representar una fuente de posibles predictores de la TDRSM estudiada.

No obstante, la información recopilada puede ser irrelevante, presentar múltiples inconsistencias, datos faltantes, entre otros, por lo cual es necesario aplicar métodos de selección, curado y limpieza de las series de manera previa al proceso de modelado y pronóstico. En ese sentido, la [Figura 3.2](#) muestra el diagrama de flujo del procedimiento de recopilación de series de tiempo, curado y limpieza de las bases de datos del conjunto de series de tiempo con el cual se entrenarán, validarán y pronosticarán las TDRSM.

Una vez obtenida la base de datos del conjunto de series de tiempo se pueden clarificar en tres categorías principales:

1. *La variable respuesta TDRSM*: es el foco principal del análisis para evaluar y discutir en el desarrollo de pronósticos.
2. *Predictores (Variables con potencial para cointegración y una relación causal con la variable de respuesta)*: estas variables se presentan junto con la variable de respuesta. Es posible demostrar con significancia estadística la relación entre estas variables y la variable de respuesta, lo que puede explicar la dinámica y las relaciones en la evaluación.
3. *Indicadores de desagregación (variables que exhiben un comportamiento similar)*: estas variables son herramientas valiosas para desagregar series de tiempo obtenidas a una frecuencia menor a una mayor (por ejemplo, ayudando a convertir una serie anual en una serie mensual).

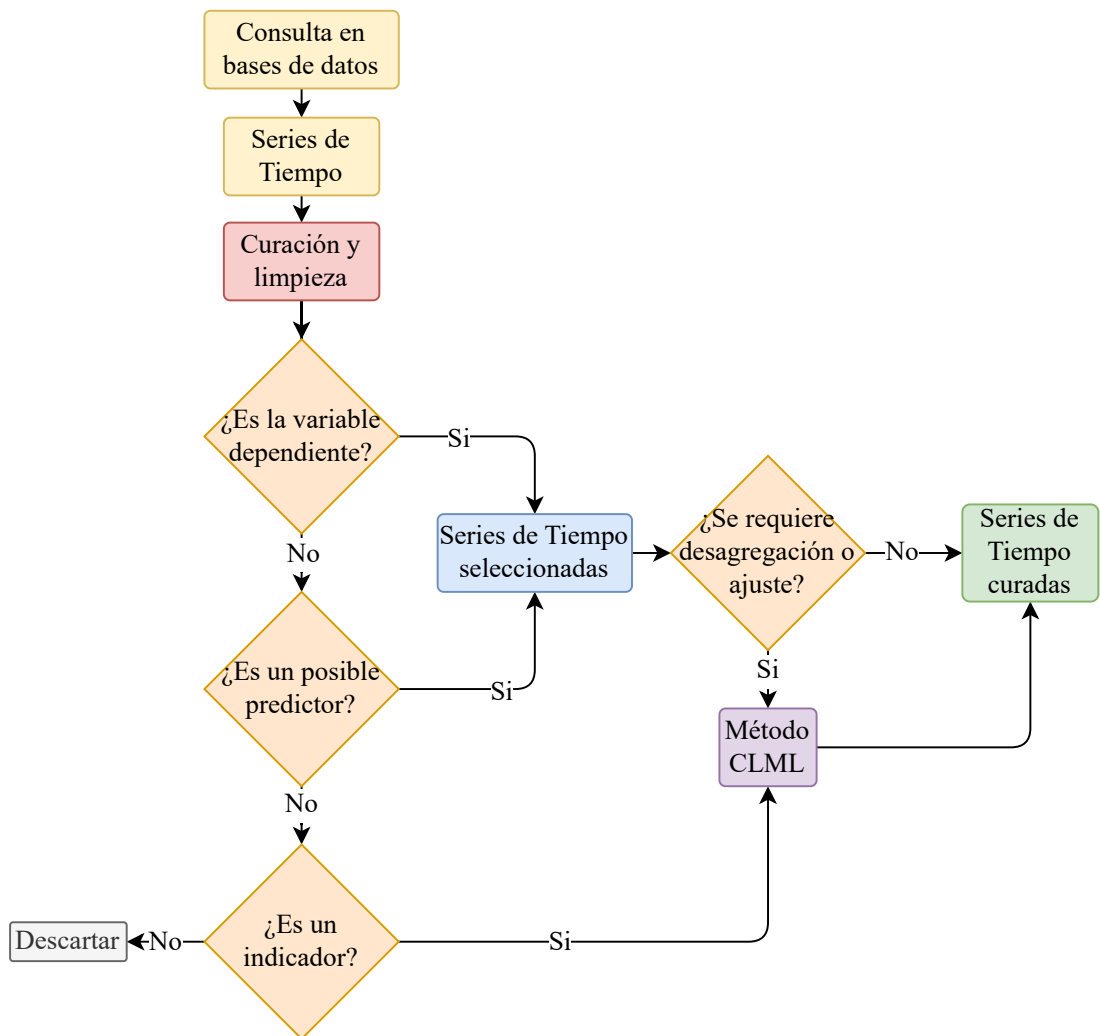


Figura 3.2: Procedimiento de recopilación, curado y limpieza de bases de datos.

3.3. Características de las series de tiempo de disposición de TDRSM

Las series de tiempo relacionadas con la generación de RSM presentan características únicas que reflejan una variedad de factores ambientales, económicos y sociales (Chhay et al., 2018). Estas series son, por naturaleza, altamente variadas y complejas, dado que la generación de residuos no se distribuye uniformemente a lo largo del tiempo ni entre diferentes regiones. Uno de los primeros aspectos a considerar es la estacionalidad, característica que indica variaciones periódicas anuales o incluso semanales. Por ejemplo, durante periodos festivos o vacaciones, es común observar un aumento en la

producción de residuos debido al incremento de actividades comerciales y domésticas. Además, la tendencia general de la serie puede mostrar un crecimiento o decrecimiento a lo largo de los años, influenciada por cambios en la población y en las políticas de gestión de residuos (Teshome et al., 2023). En otras palabras, los factores que pueden influenciar la generación de RSM son diversos. En primer lugar, la demografía juega un papel crucial; áreas con mayor densidad poblacional tienden a generar más residuos debido a la concentración de actividades humanas (Oguz-Ekim, 2021). Asimismo, el crecimiento económico afecta la generación de residuos (Kaza et al., 2018); una economía en expansión usualmente implica un aumento en el consumo y, por ende, en la cantidad de residuos producidos. Otro factor importante es el comportamiento de consumo, que varía dependiendo de las tendencias de mercado, la disponibilidad de bienes y servicios, y las actitudes culturales hacia el consumo y el reciclaje. Con el fin de ejemplificar con datos reales estas relaciones, la [Figura 3.3](#) muestra la TDRSM como función del PIB de los departamentos de Colombia, en una escala logarítmica.

La [Figura 3.3](#) sugiere una relación de proporcionalidad entre los logaritmos de la TDRSM y el PIB (actividad económica). Esto se puede observar en la figura al contrastar la ubicación de los clústeres: mientras en el clúster más alto de la figura se ubican los departamentos de categoría especial y Bogotá (los más industrializados y urbanizados), en el clúster más cercano al origen de la figura se ubican los departamentos de categoría 4 (o de menores ingresos y menor población). La implementación de políticas públicas también tiene un impacto directo en las características de las series de tiempo de RSM. Las regulaciones que promueven el reciclaje y la reducción de residuos pueden disminuir la cantidad total de desechos generados, mientras que políticas menos restrictivas o la falta de infraestructuras adecuadas para el manejo de residuos pueden tener el efecto contrario. Además, la tecnología y la innovación en el sector de manejo de residuos pueden introducir cambios en los patrones de generación de RSM, como la adopción de procesos más eficientes para el reciclaje y la gestión de residuos, que pueden reducir la cantidad de desechos destinados a vertederos. Adicionalmente, las condiciones climáticas y ambientales también son determinantes en la generación de residuos. Por ejemplo, en ciudades con climas más fríos o en épocas de bajas temperaturas, la producción de residuos puede disminuir, mientras que climas cálidos o eventos climáticos extremos, como huracanes o inundaciones, pueden provocar un aumento temporal en la generación de residuos debido a la destrucción de infraestructuras y a las consecuentes labores de limpieza y reconstrucción. Asimismo, los cambios culturales hacia la sostenibilidad y la responsabilidad ambiental pueden modificar gradualmente los patrones de generación de residuos. La creciente conciencia sobre la importancia de reducir la huella de carbono y gestionar eficientemente los recursos ha llevado a muchas comunidades a




Figura 3.3: Correlación entre la TDRSM y el PIB de los departamentos de Colombia y Bogotá. Fuente de información: DANE (2024) y SSPD (2024a).

adoptar prácticas más sostenibles, lo que se refleja en la composición y cantidad de los RSM generados. Esta transición hacia prácticas más sostenibles es crucial para modelar futuras estrategias de gestión de residuos y para prever los cambios en las series de tiempo relacionadas con los RSM.

El monitoreo de la disposición de RSM a través de series de tiempo mensuales es fundamental para captar con precisión las fluctuaciones a corto plazo en la producción de residuos, lo cual es esencial para la planificación y ajuste eficaz de las estrategias de gestión. Al utilizar datos mensuales, los administradores pueden identificar con mayor

claridad los impactos de eventos estacionales o temporales específicos, como festividades, campañas de reciclaje, o incluso cambios económicos temporales que afectan la generación de residuos. Este nivel de granularidad facilita una respuesta más ágil y adaptada a las necesidades operativas y ambientales a lo largo del año. Esto permite la aplicación de técnicas estadísticas avanzadas, como el modelo SARIMA, que es especialmente útil para datos con patrones estacionales claros. Este modelo puede ayudar a identificar tanto las tendencias subyacentes como los ciclos estacionales dentro de los datos de RSM, proporcionando predicciones precisas que son cruciales para la planificación de la capacidad y la logística en la gestión de estos residuos. Por ejemplo, anticipar aumentos en la generación de residuos antes de temporadas altas de consumo puede permitir a los municipios optimizar la recolección y procesamiento de residuos antes de que estos se acumulen.

Al analizar la [Figura 3.4](#) se pueden obtener hallazgos detallados sobre el comportamiento de consumo y la efectividad de las políticas de gestión de residuos. Por ejemplo, se observa una tendencia de incremento de la TDRSM a través de los años, un comportamiento esperado debido a que con el incremento poblacional las TDRSM globales incrementa. Además, se logra identificar que el mes de menor disposición (asociado íntimamente a la generación) tiende a ser el mes de febrero, mientras que el mes de diciembre se muestra como el mes de mayor disposición. Igualmente, el mes de enero tiene a representar una TDRSM importante, mientras que los meses intermedios de marzo a agosto la TDRSM presenta valores medios. Por otro lado, se puede observar un cambio en el patrón de las TDRSM de la última década en comparación con la década anterior. Por ejemplo, la disposición en los meses de mayo se han vuelto mucho más pronunciados, al igual que los meses de marzo, octubre o julio, posiblemente por estímulos que generan incremento del consumo de la población (e.g., ofertas comerciales). Este tipo de análisis no solo proporciona una base para la toma de decisiones informada y basada en evidencia, sino que también apoya el desarrollo de políticas públicas más sostenibles y adaptadas a las dinámicas locales de residuos durante el transcurso del año.

Otro enfoque importante de análisis de estas series es la tendencia por meses de la TDRSM. La [Figura 3.5](#) aporta a la comprensión del comportamiento de la TDRSM al evidenciar que los valores para un mismo mes presentan un comportamiento específico. Por ejemplo, el mes de diciembre presenta una fuerte tendencia a incrementar lo que puede deberse a mejoras de la capacidad adquisitiva de la población. Asimismo, el comportamiento de meses como marzo, junio u octubre presentan tendencia a incrementar notablemente. Por otro lado, meses como febrero o septiembre evidencian cambios leves en las TDRSM. Los demás meses presentan tendencias importantes a incrementar con los años. Estos comportamientos pueden sugerir que la correlación entre los datos para un mismo mes puede representar un punto de partida importantes para estimar la fortaleza de la estacionalidad de las series, así como establecer una idea sobre la posible




Figura 3.4: Comportamiento estacional de las series de tiempo de TDRSM. Fuente de los datos: SSPD (2024b).

estructura parcial de un modelo ARIMA, sugiriendo que a un lag 12 (12 meses de retroceso para cada punto de la series), es probable encontrar una buena autocorrelación. No obstante, es importante estimar el número correcto de lag al cual se obtienen los mejores resultados.




Figura 3.5: Tendencia de valores de la serie segregados por meses del año. Fuente de los datos: SSPD (2024b).

La [Figura 3.6](#) muestra la serie TDRSM para diferentes retardos (lags), lo cual permite obtener más información en el proceso de análisis de la serie de tiempo. En primer lugar, se observa una fuerte autocorrelación para lags entre 1 y 12, lo que permite sugerir una fuerte estacionalidad de la series, y que a cualquier lag que se use en este rango se podrá obtener un buen modelo para TDRSM. Ahora bien, si la tendencia de la distribución es importante, también lo es la dispersión de esta con relación al eje de tendencia, lo cual ocurre a un lag 12 para las TDRSM.




Figura 3.6: Distribución de la serie TDRSM para diferentes lags. Fuente de los datos: SSPD ([2024b](#)).

Finalmente, los análisis abordados en esta subsección permiten establecer comportamientos preliminares de la serie dirigidos a evidenciar la existencia o carencia del comportamiento estacional esta. En el caso particular de las TDRSM de Sincelejo, se puede sugerir que un modelo SARIMA resultaría especialmente apropiado para modelar esta variable y que a un lag 12 se pueden obtener los mejores desempeños del modelo. Además, el cambio de comportamiento de la serie entre periodos anuales permite

identificar restricciones aplicables a los pronósticos obtenidos con modelos SARIMA, esperando que la tendencia de cambio de patrones entre décadas pueda variar según posibles cambios de poder adquisitivo, eventos comerciales que incentiven el consumo o leves cambios culturales que alteren la forma en cómo se generan los residuos.

3.4. Descomposición de series de tiempo

La descomposición de series de tiempo es un método analítico crucial para entender los componentes subyacentes que influyen los patrones observados en los datos a lo largo del tiempo. Esta técnica es útil para analizar datos de series de tiempo que muestran patrones estacionales, tendencias a largo plazo y otros componentes cíclicos. Uno de los métodos más robustos y flexibles para la descomposición de series de tiempo es el STL (Seasonal-Trend Decomposition Procedure based on Loess), desarrollado por Cleveland et al. (1990). El método STL descompone una serie de tiempo, Y_t , en tres componentes principales: la tendencia (T_t), la estacionalidad (S_t), y el residuo (R_t), como muestra la ecuación (22).

La tendencia muestra el cambio a largo plazo en los datos, sin la influencia de la estacionalidad o irregularidades. El componente estacional refleja las fluctuaciones periódicas que ocurren en ciclos regulares, y el residuo consiste en la variabilidad en los datos que no se explica por los componentes de tendencia o estacionales. Lo que distingue al STL de otros métodos de descomposición es su capacidad para manejar diferentes tipos de estacionalidad y su flexibilidad para tratar con series de tiempo con patrones estacionales que varían en el tiempo, haciendo de STL una herramienta poderosa para el análisis detallado y adaptativo de series de tiempo complejas (R. J. Hyndman & Athanasopoulos, 2021).

La Figura 3.7 proporciona preliminares importantes en el análisis de las TDRSM. En primer lugar, T_t muestra un comportamiento que crece de forma levemente exponencial. Esto es debido a varios factores, entre ellos el crecimiento poblacional, el cual causa un mayor número de habitantes e incrementa la generación global de RSM. Además, el crecimiento de la densidad poblacional y la mejora del nivel de desarrollo humano influyen el comportamiento de consumo de la población, generando mayor cantidad de residuos por persona cuando se presenta un mayor poder adquisitivo. Esto también se refleja en el componente S_t mostrado en la Figura 3.7. En los primeros periodos, antes de 2013, de las series el patrón y la variabilidad de la estacionalidad de las TDRSM permanece relativamente constante. Más adelante, en los periodos finales de la serie se evidencia un cambio en el comportamiento de generación de RSM y una mayor variabilidad del componente estacional. Finalmente, el componente R_t varía aleatoriamente alrededor de cero, aunque su varianza incrementa con el tiempo, lo que permite sugerir que, además de los efectos de los factores analizados para la tendencia

de la serie, es posible que la TDRSM haya experimentado el efecto de comportamientos que pudieran considerarse atípicos en periodos anteriores (e.g., mayor frecuencia de eventos artísticos, cambio en el orden de actividades económicas, presencia de nuevos centros comerciales).




Figura 3.7: Descomposición de series de tiempo de TDRSM. Fuente de los datos: SSPD (2024b).

Adicionalmente, el análisis de la [Figura 3.8](#) revela patrones definidos y variaciones estacionales en la generación de residuos. Estos patrones están profundamente influenciados por las características geográficas y socioeconómicas de la ciudad, así como por eventos culturales y económicos destacados. En términos de variaciones mensuales, se observa que los meses de enero y diciembre, presentan características distintivas en la generación de residuos, lo que coincide con la menor precipitación de la ciudad. Diciembre muestra un aumento en la generación de residuos, probablemente debido a las actividades festivas de fin de año y Navidad que incrementan el consumo. En contraste, enero, aunque es un mes seco, muestra un comportamiento mixto en la generación de residuos, posiblemente debido a la calma posterior a las festividades, pero aún influido el evento cultural de mayor participación e importancia de la ciudad, que atraen grandes multitudes y, por ende, aumentan la producción de residuos. Durante los meses desde mayo hasta agosto, también hay un incremento notable en la generación de RSM. Estos meses coinciden con la temporada de lluvias más intensa, lo que podría influir en las actividades de la población, tanto locales como de tránsito, dado que Sincelejo (la ciu-

dad donde se tomaron los datos para generar las figuras [Figura 3.4](#) a la [Figura 3.8](#)) sirve como ruta hacia ciudades costeras importantes. La alta precipitación podría complicar la recolección de residuos y, simultáneamente, el aumento de la humedad podría acelerar la descomposición de materia orgánica, contribuyendo así a una gestión más desafiante de los residuos. Por otro lado, el comportamiento de los residuos también refleja la influencia de los eventos culturales y económicos a lo largo del año. La apertura de centros comerciales de carácter regional, así como el aumento del tráfico de visitantes y de población flotante debido a la ubicación estratégica de la ciudad, contribuyen a aumentos esporádicos y estacionales en la generación de residuos. Estos picos están también en consonancia con la temporada de festividades y otros eventos culturales que atraen a visitantes de fuera y fomentan el consumo local.




Figura 3.8: Variación típica del componente estacional de las TDRSM. Fuente de los datos: SSPD ([2024b](#)).

3.5. Características relevantes de las series de tiempo

Comprender las características clave de las series de tiempo nos permite reducir la incertidumbre en su pronóstico. La [Tabla 3.2](#) presenta las características de mayor relevancia de una serie de tiempo, así como las pruebas y criterios estadísticos empleados en el análisis de estas series. Estas permiten identificar la calidad de los datos de la serie de tiempo, así como un panorama preliminar sobre la posible estructura del modelo (e.g., si la serie es estacional, se espera que el valor s de la [Ecuación 3.1](#), que se analizará más adelante, sea mayor a cero). Para esto es importante comprender el objetivo de cada prueba, lo cual se establece a continuación:

- Prueba 1. *Prueba de ruido blanco*: determina si una serie temporal es simplemente una secuencia aleatoria de valores, verificando características de ruido blanco: valores independientes y distribuidos al azar con media cero y varianza constante. Evalúa si la serie muestra patrones significativos, tendencias o autocorrelaciones, y también evalúa la integridad y fiabilidad de los datos. Si una serie se comporta como ruido blanco, los datos podrían considerarse sospechosos. Por lo tanto, es necesario un análisis detallado para entender la naturaleza de la serie temporal. Para las TDRSM, la literatura sugiere que la serie debería exhibir tendencias y estacionalidad.
- Prueba 2. *Prueba de estacionariedad*: examina si la serie es estacionaria alrededor de una media o una tendencia lineal. Evalúa si la serie puede considerarse como que tiene una media y varianza consistentes a lo largo del tiempo, sin cambios sistemáticos como tendencias. La prueba verifica la presencia de estacionariedad examinando si la estructura de la serie temporal permanece constante a lo largo de su duración. Un fracaso en pasar la prueba KPSS indica la presencia de una raíz unitaria, sugiriendo que la serie temporal puede ser no estacionaria y requerir diferenciación o transformación para alcanzar la estacionariedad.
- Prueba 3. *Fortaleza de Estacionalidad*: evalúa el grado de influencia que los patrones estacionales tienen sobre una serie de tiempo. Esta métrica se calcula como la proporción de la varianza explicada por el componente estacional respecto a la varianza total observada en la serie. Una fortaleza de estacionalidad cercana a uno indica una influencia estacional muy fuerte y dominante, lo que sugiere que los patrones estacionales son consistentes y predecibles a lo largo del tiempo. Por el contrario, un valor cercano a cero indica que la estacionalidad tiene poco o ningún efecto en la serie de tiempo, destacando la predominancia de otros factores como tendencias o componentes irregulares. Esta medida es

crucial para identificar la relevancia de incorporar modelos estacionales en el análisis y pronóstico de series temporales, y resulta esencial en sectores donde la estacionalidad afecta las dinámicas evaluadas, como en economía, meteorología y gestión de inventarios.

- Prueba 4. *Lambda de Guerrero*: es una técnica utilizada para determinar el parámetro de transformación óptimo en series de tiempo que requieren estabilización de la varianza. Este método calcula el valor de lambda que minimiza la variación de las medias móviles ponderadas calculadas a lo largo de varios subconjuntos de la serie de tiempo. La selección de un valor adecuado para lambda es esencial cuando se aplica la transformación de Box-Cox, ya que un valor de lambda apropiado ayuda a homogeneizar la varianza de los datos, lo que es crucial para muchos métodos analíticos en series de tiempo, como el modelado ARIMA. El lambda de Guerrero es particularmente útil en contextos donde la estabilidad de la varianza no puede ser asumida, facilitando así modelos más precisos y efectivos en el análisis de series temporales que exhiben heteroscedasticidad.
- Prueba 5. *Entropía espectral*: mide la distribución o dispersión de la energía de una serie de tiempo a lo largo de diferentes frecuencias. Esta medida se basa en la densidad espectral de potencia de la serie, proporcionando un valor numérico que cuantifica la incertidumbre o la aleatoriedad de la serie temporal observada. Si la entropía es alta, indica que la serie de tiempo es más impredecible y sus valores están distribuidos de manera más uniforme a través de las frecuencias. Por otro lado, una entropía baja sugiere que la serie de tiempo tiene una estructura más regular y predecible, con concentraciones de energía en frecuencias específicas. La entropía espectral de Shannon es crucial para analizar la complejidad dinámica de las series de tiempo y es especialmente útil en el análisis de señales y sistemas donde se busca entender la distribución de la energía a lo largo del espectro de frecuencia.
- Prueba 6. *Prueba de cointegración*: evalúa si existe una relación de equilibrio a largo plazo entre las series Y_t y X_t , a pesar de posibles desviaciones a corto plazo. Esta prueba identifica el número de vectores de cointegración que describen estadísticamente las relaciones a largo plazo entre las series. Si la prueba indica cointegración, sugiere que las series se mueven juntas a largo plazo, manteniendo una relación estable a pesar de las fluctuaciones a corto plazo. Esto es vital para modelos económicos y financieros donde se espera que las variables se influyan mutuamente a lo largo del tiempo. La aplicación efectiva de la prueba de Johansen ayuda en la construcción de modelos que reflejan con precisión las interdependencias dinámicas y son esenciales para el pronóstico y análisis de políticas.

Prueba 7. *Prueba de causalidad*: si una serie temporal puede predecir otra, estableciendo una influencia direccional entre ellas. Evalúa si los valores pasados de una serie ayudan a prever los valores futuros de otra serie de manera más efectiva que los pronósticos basados solo en los valores pasados de la serie. Si una serie X_t causa Granger a la serie Y_t , sugiere que X_t contiene información útil para predecir Y_t más allá de la información ya contenida en los valores pasados de Y_t por sí sola. Esta prueba es crucial en econometría y otras disciplinas donde entender la influencia direccional entre variables es necesario para la toma de decisiones efectiva y el desarrollo de políticas. La aplicación de la prueba de causalidad de Granger ayuda en la identificación y cuantificación de las relaciones entre series temporales, guiando intervenciones estratégicas y análisis (e.g., SARIMAX)

Tabla 3.2: Pruebas estadísticas principales para determinar características de las series de tiempo.

Característica	Prueba/método	Autores	Criterio/Hipótesis nula (H_0)
Ruido blanco	Prueba de Ljung-Box	Ljung y Box (1978)	Y_t es ruido blanco.
Estacionariedad	Prueba de KPSS	Kwiatkowski et al. (1992)	Y_t es estacionaria.
Estacionalidad	Fortaleza del Componente Estacional (F_S)	R. J. Hyndman y Athanasopoulos (2021)	Si $F_S > 0.64$, Y_t es estacional.
Lambda de Guerrero	Método de Guerrero	Guerrero (1993)	Minimizar $\text{Var}(Y_t)$
Entropía espectral	Entropía espectral de Shannon (Shannon, 1948a, 1948b)	Jung y Gibson (2006)	-
Cointegración	Prueba de Johansen	Johansen (2011)	Y_t y X_t no están cointegradas
Causalidad	Prueba de Granger	Granger (1969)	X_t no es causa de Granger de Y_t

3.6. Modelo de serie de tiempo estacional

SARIMA es un método para el análisis de series temporales utilizado para conjuntos de datos con una marcada estacionalidad y patrones temporales recurrentes (Mahmud et al., 2023). No obstante, SARIMAX, una extensión del modelo SARIMA, incorpora la influencia de variables exógenas en el análisis y pronóstico de series temporales (Sheng & Jia, 2020), combinando las capacidades de los modelos SARIMA para capturar la estacionalidad y los patrones autorregresivos y de media móvil con la flexibilidad de incluir factores externos que pueden afectar el comportamiento de las series temporales. Empero, su aplicación efectiva requiere la comprensión de las relaciones subyacentes entre las variables exógenas y las TDRSM.

El modelo SARIMAX puede representarse matemáticamente en términos del operador B (es decir, notación de rezagos, el cual, para un orden m , es $B^m Y_t = Y_{t-m}$, $\forall t > 1$) como se describe con las Ecuaciones (3.1)–(3.5) (Box et al., 2015; Kim et al., 2023).

$$\phi_p(B) \cdot \Phi_P(B^s) \cdot \nabla^d \cdot \nabla_s^D \cdot Y_t = \theta_q(B) \cdot \Theta_Q(B^s) \cdot \varepsilon_t + \sum_{i=1}^r \beta_i \cdot X_{i,t} \quad (3.1)$$

$$\phi_p(B) = 1 - \sum_{i=1}^p \phi_i \cdot B^i \quad (3.2)$$

$$\Phi_P(B^s) = 1 - \sum_{i=1}^P \Phi_i \cdot B^{si} \quad (3.3)$$

$$\theta_q(B) = 1 - \sum_{i=1}^q \theta_i \cdot B^i \quad (3.4)$$

$$\Theta_Q(B^{sj}) = 1 - \sum_{i=1}^Q \Theta_i \cdot B^{si} \quad (3.5)$$

Donde: $\phi_p(B)$ representa el polinomio autorregresivo; $\Phi_P(B^s)$ denota el polinomio autorregresivo estacional; $\theta_q(B)$ es el polinomio de promedio móvil; $\Theta_Q(B^{sj})$ es el polinomio de promedio móvil estacional; ∇^d es el operador diferencial no estacional equivalente a $(1 - B)$; ∇_s^D es el operador diferencial estacional equivalente a $(1 - B^s)$; Y_t es la serie de tiempo de la variable dependiente; ε_t representa el error de la serie de tiempo; $X_{i,t}$ denota la serie de tiempo de la i -ava variable exógena; y β_i es el vector de coeficientes de $X_{i,t}$.

La Ecuación 3.1 puede representarse de una forma acotada mediante la notación SARIMAX(p, d, q)(P, D, Q)[s, r], donde, p es el orden del componente autorregresivo no estacional; d es el orden diferencial no estacional; q es el orden del componente de promedio móvil no estacional; P es el orden del componente autorregresivo estacional; D es el orden diferencial estacional; Q es el orden del componente de promedio móvil estacional; s es el periodo estacional.

En ese orden, el método VAR se puede describir como:

$$\phi_p(B) \cdot (Y_t - \mu) = \epsilon_t \quad (3.6)$$

Donde: μ es el vector promedio de las k series de tiempo (i.e., $\mu_1, \mu_2, \dots, \mu_k$). Este método es especialmente útil cuando se realiza modelamiento de componentes de series de tiempo como la estacionalidad, cuando el objetivo pueda ser una retroproyección.

3.7. Entrenamiento y validación de modelos

La serie de tiempo (de longitud t con $T + h$ periodos estacionales) se divide en dos subconjuntos: uno de longitud T para la etapa de entrenamiento del modelo, y otro de longitud h para la etapa de validación, todo esto luego de una validación cruzada. Adicionalmente, variables endógenas de la serie de tiempo (e.g., S_t) pueden ser utilizadas como potenciales regresores del modelo de forma que este último pueda mejorar su desempeño. La selección del modelo apropiado contempla implica (i) seleccionar el modelo con el menor MAPE, el cual puede ser calculado mediante las Ecuaciones (3.7)–(3.8) (R. J. Hyndman & Athanasopoulos, 2021), (ii) que el MAPE sea menor al 5 %, y (iii) que los residuales del modelo cumplan el supuesto de ruido blanco.

$$e_{T+h} = Y_{T+h} - \hat{Y}_{T+h|T} \quad (3.7)$$

$$\text{MAPE} = \text{mean} \left(\left| \frac{e_t}{Y_t} \right| \cdot 100 \right) \quad (3.8)$$

3.8. Conclusiones del capítulo

El modelo SARIMAX demostró ser una herramienta altamente efectiva para analizar y predecir las TDRSM. Este modelo permitió capturar tanto la estacionalidad como la tendencia de las series temporales, incorporando además variables exógenas que enriquecieron la capacidad explicativa del modelo, ofreciendo predicciones precisas y con menor incertidumbre.

El análisis identificó una fuerte estacionalidad en las series de TDRSM, con un lag de 12 meses como el más adecuado debido a su alta autocorrelación y baja dispersión en los datos. Los resultados evidenciaron patrones cíclicos consistentes, con picos en meses como diciembre y enero, influenciados por eventos culturales y económicos, mientras que otros meses mostraron incrementos graduales relacionados con cambios en las dinámicas poblacionales y socioeconómicas.

La descomposición de las series de tiempo permitió separar componentes clave de tendencia, estacionalidad y ruido. Se observó un crecimiento sostenido en la generación de residuos, asociado al aumento poblacional y mejoras en la capacidad adquisitiva. Además, se detectaron cambios en los patrones estacionales en años recientes, posiblemente derivados de transformaciones culturales y económicas que han modificado la dinámica de generación de residuos.

El proceso de entrenamiento y validación del modelo SARIMAX confirmó su robustez al cumplir los supuestos de ruido blanco en los residuales y lograr un MAPE menor al 5 %. Esto asegura la confiabilidad del modelo para realizar proyecciones precisas y fundamentar decisiones estratégicas en la gestión de RSM.

Referencias

- Adu, W. K., Appiahene, P., & Afrifa, S. (2023). VAR, ARIMAX and ARIMA models for nowcasting unemployment rate in Ghana using Google trends. *Journal of Electrical Systems and Information Technology*, 10(1), 12. <https://doi.org/10.1186/s43067-023-00078-1>
- Al-Shihabi, S., Aydin, R., & Al Nahlawi, M. (2023). Forecasting the effects of municipal solid plastic waste generation and streaming using system dynamics: A case study in Dubai. *Science of The Total Environment*, 165204. <https://doi.org/10.1016/j.scitotenv.2023.165204>
- Andreas, C., Faricha, A., Ulyah, S. M., Susanti, R., Mardhiana, H., Nanda, M. A., & R., F. A. (2022). Comparison study using ARIMAX and VARX in cash flow forecasting, 030023. <https://doi.org/10.1063/5.0118519>
- Ayeleru, O. O., Fajimi, L. I., Oboirien, B. O., & Olubambi, P. A. (2021). Forecasting municipal solid waste quantity using artificial neural network and supported vector machine techniques: A case study of Johannesburg, South Africa. *Journal of Cleaner Production*, 289. <https://doi.org/10.1016/j.jclepro.2020.125671>
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time Series Analysis: Forecasting and Control*. Wiley.
- Chhay, L., Reyad, M., Suy, R., Islam, M., & Mian, M. (2018). Municipal solid waste generation in China: influencing factor analysis and multi-model forecasting. *Journal of Material Cycles and Waste Management*, 20(3), 1761-1770. <https://doi.org/10.1007/s10163-018-0743-4>

- Cleveland, R. B., Cleveland, W. S., McRae, J. E., & Terpenning, I. (1990). STL: A seasonal-trend decomposition. *Journal of Official Statistics*, 6(1), 3-73. <http://www.nniem.ru/file/news/2016/stl-statistical-model.pdf>
- Connolly, E. (2021). *The Suitability of Sarimax Time Series and LSTM Neural Networks for Predicting Electricity Consumption in Ireland* [Master Thesis]. National College of Ireland. <https://norma.ncirl.ie/5143/1/edmondconnolly.pdf>
- Cubillos, M., Wulff, J. N., & Wøhlk, S. (2021). A multilevel Bayesian framework for predicting municipal waste generation rates. *Waste Management*, 127, 90-100. <https://doi.org/10.1016/j.wasman.2021.04.011>
- DANE. (2024). Indicador de Seguimiento a la Economía (ISE). <https://www.dane.gov.co/index.php/estadisticas-por-tema/cuentas-nacionales/indicador-de-seguimiento-a-la-economia-ise>
- Dodo, U. A., Ashigwuike, E. C., & Emechebe, J. N. (2022). Municipal Solid Waste Generation Forecast using an ARIMA Model: A Focus on Abuja City, Nigeria. *2022 IEEE Nigeria 4th International Conference on Disruptive Technologies for Sustainable Development (NIGERCON)*, 1-5. <https://doi.org/10.1109/NIGERCON54645.2022.9803108>
- Fan, L., Abbasi, M., Salehi, K., Band, S. S., Chau, K. W., & Mosavi, A. (2021). Introducing an evolutionary-decomposition model for prediction of municipal solid waste flow: application of intrinsic time-scale decomposition algorithm. *Engineering Applications of Computational Fluid Mechanics*, 15(1), 1159-1175. <https://doi.org/10.1080/19942060.2021.1945496>
- Gonçalves, A. M., & Silva, V. H. (2021). Time Series Forecasting: A Study on Local Urban Waste Management in a Portuguese City. https://doi.org/10.1007/978-3-030-86973-1_37
- Granger, C. W. J. (1969). Investigating Causal Relations by Econometric Models and Cross-spectral Methods. *Econometrica*, 37(3), 424. <https://doi.org/10.2307/1912791>
- Guerrero, V. (1993). Time-series analysis supported by power transformations. *Journal of Forecasting*, 12(1), 37-48. <https://doi.org/10.1002/for.3980120104>
- Hyndman, R. (2024). *fpp3: Data for "Forecasting: Principles and Practice" (3rd Edition)* [R package version 1.0.1]. <https://CRAN.R-project.org/package=fpp3>
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice* (3rd ed). <https://otexts.com/fpp3/>
- Islam, M. R., Kabir, G., Ng, K. T. W., & Ali, S. M. (2022). Yard waste prediction from estimated municipal solid waste using the grey theory to achieve a zero-waste strategy. *Environmental Science and Pollution Research*, 29(31), 46859-46874. <https://doi.org/10.1007/s11356-022-19178-y>
- Johansen, S. (2011, enero). Cointegration in the VAR Model. <https://doi.org/10.1002/9781118032978.ch15>

- Jung, J., & Gibson, J. (2006). The interpretation of spectral entropy based upon rate distortion functions. *IEEE International Symposium on Information Theory - Proceedings*, 277-281. <https://doi.org/10.1109/ISIT.2006.261849>
- Kaza, S., Yao, L. C., Bhada-Tata, P., & Van Woerden, F. (2018, septiembre). *What a Waste 2.0: A Global Snapshot of Solid Waste Management to 2050*. Washington, DC: World Bank. <https://doi.org/10.1596/978-1-4648-1329-0>
- Kim, H., Park, S., & Kim, S. (2023). Time-series clustering and forecasting household electricity demand using smart meter data. *Energy Reports*, 9, 4111-4121. <https://doi.org/10.1016/j.egyr.2023.03.042>
- Kwiatkowski, D., Phillips, P. C., Schmidt, P., & Shin, Y. (1992). Testing the null hypothesis of stationarity against the alternative of a unit root. *Journal of Econometrics*, 54(1-3), 159-178. [https://doi.org/10.1016/0304-4076\(92\)90104-Y](https://doi.org/10.1016/0304-4076(92)90104-Y)
- Li, Z., Luo, Z., Wang, Y., Fan, G., & Zhang, J. (2022). Suitability evaluation system for the shallow geothermal energy implementation in region by Entropy Weight Method and TOPSIS method. *Renewable Energy*, 184, 564-576. <https://doi.org/10.1016/j.renene.2021.11.112>
- Liang, G., Panahi, F., Ahmed, A. N., Ehteram, M., Band, S. S., & Elshafie, A. (2021). Predicting municipal solid waste using a coupled artificial neural network with archimedes optimisation algorithm and socioeconomic components. *Journal of Cleaner Production*, 315. <https://doi.org/10.1016/j.jclepro.2021.128039>
- Lin, K., Zhao, Y., & Kuo, J. H. (2022). Deep learning hybrid predictions for the amount of municipal solid waste: A case study in Shanghai. *Chemosphere*, 307. <https://doi.org/10.1016/j.chemosphere.2022.136119>
- Ljung, G. M., & Box, G. E. P. (1978). On a Measure of Lack of Fit in Time Series Models. *Biometrika*, 65(2), 297. <https://doi.org/10.2307/2335207>
- Mahmud, T. S., Ng, K. T. W., Hasan, M. M., An, C., & Wan, S. (2023). A cross-jurisdictional comparison on residential waste collection rates during earlier waves of COVID-19. *Sustainable Cities and Society*, 96. <https://doi.org/10.1016/j.scs.2023.104685>
- Mariano-Hernández, D., Hernández-Callejo, L., Solís, M., Zorita-Lamadrid, A., Duque-Pérez, O., Gonzalez-Morales, L., Alonso-Gómez, V., Jaramillo-Duque, A., & Santos García, F. (2022). Comparative study of continuous hourly energy consumption forecasting strategies with small data sets to support demand management decisions in buildings. *Energy Science & Engineering*, 10(12), 4694-4707. <https://doi.org/10.1002/ese3.1298>
- Nguyen, X. C., Nguyen, T. T. H., La, D. D., Kumar, G., Rene, E. R., Nguyen, D. D., Chang, S. W., Chung, W. J., Nguyen, X. H., & Nguyen, V. K. (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>

- Niu, D., Wu, F., Dai, S., He, S., & Wu, B. (2021). Detection of long-term effect in forecasting municipal solid waste using a long short-term memory neural network. *Journal of Cleaner Production*, 290. <https://doi.org/10.1016/j.jclepro.2020.125187>
- Oguz-Ekim, P. (2021). Machine Learning Approaches for Municipal Solid Waste Generation Forecasting. *Environmental Engineering Science*, 38(6), 489-499. <https://doi.org/10.1089/ees.2020.0232>
- Otero Meza, D. D., Sagastume Gutiérrez, A., Cabello Eras, J. J., Salcedo Mendoza, J., & Hernández Ruydiaz, J. (2023). Techno-economic and environmental assessment of the landfill gas to energy potential of major Colombian cities. *Energy Conversion and Management*, 293, 117522. <https://doi.org/10.1016/j.enconman.2023.117522>
- Paulauskaite-Taraseviciene, A., Raudonis, V., & Sutiene, K. (2022). Forecasting municipal solid waste in Lithuania by incorporating socioeconomic and geographical factors. *Waste Management*, 140, 31-39. <https://doi.org/10.1016/j.wasman.2022.01.004>
- Pudcha, T., Phongphiphat, A., & Towprayoon, S. (2023). Greenhouse Gas Mitigation and Energy Production Potentials from Municipal Solid Waste Management in Thailand Through 2050. *Earth Systems and Environment*, 7(1), 83-97. <https://doi.org/10.1007/s41748-022-00323-z>
- R Core Team. (2024). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing. Vienna, Austria. <https://www.R-project.org/>
- RStudio Team. (2020). *RStudio: Integrated Development Environment for R*. RStudio, PBC. Boston, MA. <http://www.rstudio.com/>
- Shannon, C. (1948a). A Mathematical Theory of Communication. *Bell System Technical Journal*, 27(4), 623-656. <https://doi.org/10.1002/j.1538-7305.1948.tb00917.x>
- Shannon, C. (1948b). A Mathematical Theory of Communication. *Bell System Technical Journal*, 27(3), 379-423. <https://doi.org/10.1002/j.1538-7305.1948.tb01338.x>
- Sheng, F., & Jia, L. (2020). Short-Term Load Forecasting Based on SARIMAX-LSTM. *2020 5th International Conference on Power and Renewable Energy, ICPRE 2020*, 90-94. <https://doi.org/10.1109/ICPRE51194.2020.9233117>
- Singh, T., & Uppaluri, R. V. (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*. <https://doi.org/10.1007/s13762-022-04644-4>
- SSPD. (2024a). *Publicaciones y boletines*. <https://www.superservicios.gov.co/publicaciones>
- SSPD. (2024b). Sistema Único de Información de Servicios Públicos Domiciliarios - SUI de Colombia. <https://sui.superservicios.gov.co/>

- Sunayana, Kumar, S., & Kumar, R. (2021). Forecasting of municipal solid waste generation using non-linear autoregressive (NAR) neural models. *Waste Management*, 121, 206-214. <https://doi.org/10.1016/j.wasman.2020.12.011>
- Teshome, Y. M., Habtu, N. G., Molla, M. B., & Ulsido, M. D. (2023). Municipal solid wastes quantification and model forecasting. *Global Journal of Environmental Science and Management*, 9(2). <https://doi.org/10.22034/GJESM.2023.02.04>
- Wang, D., Yuan, Y. a., Ben, Y., Luo, H., & Guo, H. (2022). Long short-term memory neural network and improved particle swarm optimization-based modeling and scenario analysis for municipal solid waste generation in Shanghai, China. *Environmental Science and Pollution Research*, 29(46), 69472-69490. <https://doi.org/10.1007/s11356-022-20438-0>
- Zhu, L., Tian, Z., & Du, J. (2023). Spatial-temporal redundancy evaluation of the municipal solid waste incineration treatment capacity: the case study of China. *Environmental Science and Pollution Research*. <https://doi.org/10.1007/s11356-023-26989-0>

Capítulo 4

Selección de Alternativas de Valorización Energética de RSM

Resumen del capítulo: Este capítulo presenta una metodología para la selección de alternativas de valorización energética de RSM, considerando criterios técnicos, energéticos, económicos y ambientales. Se definieron indicadores cuantitativos para evaluar cada dimensión y se empleó el método ENTROPY para ponderar objetivamente los criterios, basándose en la dispersión de los datos. El método TOPSIS se utilizó para clasificar las alternativas, identificando la que presenta el mejor equilibrio entre los criterios. La herramienta propuesta integra la caracterización de RSM, proyección de tasas de disposición, evaluación de potenciales y clasificación de alternativas, facilitando la toma de decisiones informada para la gestión sostenible de RSM.

Palabras clave – MCDA; Criterios de selección; Método ENTROPY; Método TOPSIS; Sostenibilidad.

4.1. Introducción

La planificación de sistemas de gestión de RSM implica el análisis de múltiples variables e indicadores que deben ser atendidos en beneficio de la sociedad (Coban et al., 2018; Soltani et al., 2015). Para ello, se pueden diseñar programas que abarcan desde la recolección, transporte y tratamiento de los RSM, hasta incentivos fiscales (Congreso de la República de Colombia, 2014) que favorezcan la inversión en tratamientos alternativos o avanzados, como la gasificación (Yang et al., 2021). Estos programas no solo reducirían la cantidad de RSM que se dispone en rellenos sanitarios, sino que también generarían beneficios económicos (Lauber, 2007; L. Rodrigues et al., 2022), ambientales (Yaashikaa et al., 2022) y sociales (Ramos & Rouboa, 2020) que no son posibles con

los métodos tradicionales (e.g., rellenos sanitarios o incineración). Sin embargo, cada territorio presenta recursos y necesidades diversas que afectan la pertinencia y viabilidad de los sistemas de tratamiento de RSM. Una planificación inadecuada puede tener consecuencias negativas en los planes de inversión de una población, ya que estos sistemas pueden requerir entre el 20 % y el 50 % del presupuesto de una ciudad (World Bank, 2022).

Las alternativas de conversión de RSMaE, como la RSCB, INC, DA y GAS, son soluciones que pueden aportar al manejo de los RSM y contribuir a la generación de energía útil, diversificando las fuentes de energía de un territorio (Beyene et al., 2018). Para esto, resulta importante considerar que la complejidad de estas tecnologías requiere un análisis y planificación que consideren múltiples criterios representativos de las dimensiones de la sostenibilidad, articulados con los objetivos de desarrollo sostenible, los cuales pueden incluir aspectos económicos, ambientales y sociales (UNEP, 2024).

La dimensión económica abarca indicadores como el valor presente neto, la tasa interna de retorno o la relación beneficio-costos, que permiten determinar si una alternativa generará un retorno sobre la inversión inicial y su posible rentabilidad (Rezaei et al., 2018), factores cruciales para la inversión privada. La dimensión ambiental analiza indicadores como la reducción de emisiones de GEI que puede generar la operación de una alternativa de conversión de RSMaE, lo cual podría también representar ingresos adicionales a través de créditos de carbono (Otero Meza et al., 2023). La dimensión social es relevante para el análisis de estos proyectos, evaluando indicadores como la cantidad de empleo generado y la satisfacción de los usuarios (Lu et al., 2017). Además, otras dimensiones no convencionales de la sostenibilidad incluyen criterios técnicos y energéticos. La dimensión técnica puede abarcar indicadores como la capacidad de la planta para procesar una cantidad específica de RSM y la reducción global que cada tecnología representa para el sistema de gestión de RSM (Bashir et al., 2019). La dimensión energética puede relacionar el impacto energético del proyecto, evaluando su contribución a la matriz energética, la reducción de la necesidad de fuentes de energía fósil y la eficiencia de conversión energética neta obtenida al transformar los RSM en energía útil como electricidad (A. P. Rodrigues et al., 2018).

El conjunto de criterios seleccionados para analizar alternativas de conversión de RSMaE requiere la asignación de pesos de representación en la decisión final, ya que no todos los criterios tienen igual peso en el análisis multicriterio. Existen múltiples enfoques para esto, reportados en la literatura y aplicados en entornos reales (Vlachokostas et al., 2021). Entre los métodos más utilizados se encuentran aquellos con un fuerte componente subjetivo, obteniendo datos mediante encuestas a expertos y ponderándolos mediante diversos mecanismos (Yin et al., 2017). Otros métodos se basan exclusivamente en el desempeño de las alternativas para estimar la importancia de un criterio sobre otro (El Kourdi et al., 2023). Este último enfoque es útil, ya que, si los valores de desempeño de las alternativas son muy cercanos bajo un mismo criterio, estas recibirán

una calificación similar, indicando que el criterio tiene poco peso en la selección de alternativas. Este problema no se aborda adecuadamente con métodos subjetivos cuando las alternativas presentan similitudes de desempeño bajo ciertos criterios, lo que podría dar un peso relativamente alto a un criterio con valores muy similares entre las opciones. Métodos como ENTROPY (Alao et al., 2020) capturan esta particularidad asignando a cada criterio su peso en función de la dispersión de los datos. Además, existen técnicas para comparar las alternativas conociendo el peso de los criterios utilizados para evaluarlas. Uno de los métodos más útiles es el TOPSIS (Afrane et al., 2021), ampliamente usado, simple de aplicar, fácil de interpretar y compatible con otros métodos de asignación de pesos.

Este capítulo presenta los criterios seleccionados para el desarrollo del estudio (técnicos, energéticos, económicos y ambientales), así como los métodos de asignación de pesos y evaluación de alternativas de conversión de RSMaE. También se discute la estructura de la herramienta metodológica desarrollada para seleccionar la mejor alternativa de valorización energética de los RSM para cualquier lugar de estudio. Cabe destacar que, dada la dificultad para obtener información fiable sobre el posible impacto social de las alternativas analizadas, los criterios sociales no fueron incluidos en el alcance de la herramienta. Algunos indicadores, como el empleo formal generado durante las etapas de construcción y operación, requieren un análisis de factibilidad a nivel de ingeniería de detalle, mientras que el alcance de esta herramienta se limitó a la fase de prefactibilidad de proyectos de conversión de RSMaE.

4.2. Criterios para la evaluación de alternativas

Evaluar rutas tecnológicas de valorización energética de los RSM representa un desafío complejo que puede ser abordado mediante métodos de ADM para seleccionar la mejora ruta tecnológica para las condiciones locales del lugar de análisis. Esto implica el uso apropiado de un conjunto de criterios bajo los cuales se puedan evaluar las dimensiones técnica, energética, económica y ambiental de la sostenibilidad de los proyectos de conversión de RSMaE estudiados. Esta sección relaciona indicadores que pueden ser utilizados para comparar alternativas como INC, GAS, DA y RSCB.

4.2.1. Criterios Técnicos

La evaluación y selección de tecnologías de conversión de RSMaE debe considerar múltiples criterios, entre los que destacan los técnicos. Estos criterios son fundamentales para asegurar que las tecnologías de conversión de RSMaE no solo sean efectivas en la conversión de residuos en energía, sino también viables y sostenibles desde una perspectiva operativa y de gestión a largo plazo.

Las Ecuaciones (4.1)–(4.4) permiten calcular los criterios técnicos propuestos en este estudio.

$$c_{I,x} = \text{máx}(\dot{W}_{x,i}) \quad (4.1)$$

$$T_{a,x} = \sum_{q=i}^s f_{q,x} \quad (4.2)$$

$$F_{m,x} = 1 - \frac{c_F}{8640} \quad (4.3)$$

$$M_{m,x} = \frac{M_{RSM}}{\bar{M}_{RSM,x}} \quad (4.4)$$

Donde: $c_{I,x}$ representa la capacidad instalada de la tecnología x (kg a^{-1}); $T_{a,x}$ denota la tasa de aprovechamiento de RSM de la tecnología x (%); $f_{q,x}$ representa el peso relativo de la fracción q de las s fracciones que componen los RSM que son admitidos en la ruta tecnológica x (%); $F_{m,x}$ es el porcentaje de tiempo del año que debe invertirse en actividades de mantenimiento de la tecnología x con relación al total de las 8640 h laborales del año (%); $M_{m,x}$ representa la proporción entre la cantidad de agua de lo RSM y la admitida la ruta tecnológica x ; M_{RSM} es el contenido de agua presente en los RSM del sitio de estudio (%); y $\bar{M}_{RSM,x}$ representa el porcentaje máximo de agua que deben contener los RSM del sitio de estudio para ser admitidos en la ruta tecnológica x (%).

La capacidad instalada de una tecnología de conversión de RSMaE es un criterio técnico importante, ya que determina la cantidad de RSM que la instalación puede procesar anualmente. Una capacidad instalada adecuada es vital para manejar eficientemente los volúmenes de residuos generados en una localidad específica. Tecnologías como la INC y la GAS pueden tener capacidades instaladas muy altas, lo que las hace adecuadas para áreas urbanas con grandes tasas de generación de RSM. En contraste, tecnologías como la DA pueden tener capacidades instaladas menores, pero son muy efectivas para procesar residuos orgánicos en localidades con volúmenes moderados de residuos. La capacidad instalada debe ser alineada con las necesidades y la generación de residuos locales para asegurar una gestión eficiente y evitar sobrecargas o subutilización de la instalación.

La tasa de aprovechamiento de los RSM generados en el lugar de estudio es otro criterio técnico esencial. Esta tasa indica el porcentaje de RSM que una tecnología de conversión de RSMaE puede procesar efectivamente en comparación con la cantidad total generada en el área de estudio. Una alta tasa de aprovechamiento es un indicio de una tecnología eficaz que maximiza la conversión de residuos en energía, minimizando los residuos que deben ser gestionados mediante otras técnicas, como el vertido. Tecnologías como la INC y GAS suelen tener altas tasas de aprovechamiento debido a su capacidad de procesar una amplia variedad de residuos, mientras que la DA puede tener tasas de aprovechamiento más bajas pero específicas para residuos orgánicos.

4.2.2. Criterios Energéticos

Analizar criterios energéticos mediante un método de ADM es crucial ya que proporciona una visión holística de la eficiencia y viabilidad de cada tecnología, asegurando que las decisiones no solo se basen en un único aspecto sino en una combinación equilibrada de factores que en lo posible consideren el contexto local de estudio. Los criterios energéticos ayudan a evaluar la capacidad de las tecnologías para convertir residuos en energía, su impacto en el suministro energético local, y su contribución a la autosuficiencia y resiliencia energética. Además, permiten comparar el rendimiento y la sostenibilidad de diferentes tecnologías, como INC, GAS, DA y RSCB, asegurando que se seleccionen las soluciones más adecuadas para maximizar el rendimiento energético, optimizar el uso de recursos y ofrecer beneficios socioeconómicos tangibles. Esta evaluación integral es esencial para fomentar el desarrollo sostenible en la gestión de RSM y la generación de energía, contribuyendo a la eficiencia energética y la reducción de impactos ambientales negativos. En ese sentido, las Ecuaciones (4.5)–(4.7) representan la expresión matemática de indicadores energéticos propuestos para este estudio.

$$P_x = \frac{1}{n} \sum_{i=1}^n \frac{\dot{P}_{x,i}}{\dot{W}_{x,i}} \quad (4.5)$$

$$E_{pc,x} = \frac{1}{n} \sum_{i=1}^n \frac{E_{x,i}}{h_i} \quad (4.6)$$

$$C_{el,x} = \frac{100}{n} \sum_{i=1}^n \frac{E_{x,i}}{E_{L,i}} \quad (4.7)$$

Donde: P_x representa la potencia eléctrica neta por cantidad de RSM admitidos en la ruta tecnológica x (kW kg^{-1}); $E_{pc,x}$ representa la generación eléctrica per cápita local (kW hab^{-1}); h_i denota la población local en el año i (hab); $C_{el,x}$ representa la contribución al balance energético local (%); y $E_{L,i}$ denota la demanda energética local en el año i (kWh).

La potencia eléctrica neta por cantidad de RSM admitidos es un criterio esencial en el análisis multicriterio de las alternativas de conversión de RSMaE porque permite evaluar la eficiencia directa de conversión de residuos en energía para cada tecnología específica. Esta métrica es particularmente relevante dado que diferentes tecnologías tienen capacidades distintas para procesar y convertir RSM en energía eléctrica. Por ejemplo, la INC puede admitir una mayor variedad de residuos y en mayores volúmenes en comparación con la DA, que suele requerir residuos orgánicos específicos para un rendimiento óptimo. La GAS y RSCB también tienen variaciones en términos de admisión de residuos y eficiencia de conversión. Al medir la potencia eléctrica neta por kilogramo de residuos admitidos, se obtiene una imagen clara de la eficacia de cada tecnología

en términos de generación de energía. Este criterio ayuda a identificar cuál tecnología maximiza la producción de energía a partir de los residuos disponibles, optimizando así la utilización de los recursos y contribuyendo a una toma de decisiones más informada y sostenible.

La generación eléctrica per cápita local es otro indicador crucial en la evaluación de alternativas de conversión de RSMaE, ya que relaciona la producción de energía con la población servida. Este criterio es especialmente relevante en contextos urbanos y metropolitanos donde la densidad de población puede influir en la demanda y el suministro de energía. Al calcular la cantidad de electricidad generada por cada habitante, se obtiene una perspectiva sobre cómo cada tecnología de conversión de RSMaE (INC, GAS, DA, y RSCB) puede contribuir a satisfacer las necesidades energéticas de la población local. Este indicador permite evaluar la equidad y la eficiencia de distribución de los beneficios energéticos derivados de la valorización de los RSM. Además, proporciona una base para comparar el impacto social y económico de cada alternativa, favoreciendo aquellas tecnologías que no solo son eficientes en términos de generación de energía, sino que también ofrecen un beneficio tangible a la comunidad en términos de disponibilidad de electricidad.

La eficiencia eléctrica neta obtenida de los RSM dispuestos localmente es un criterio que mide la relación entre la energía eléctrica neta generada y el poder calorífico inferior total de RSM dispuestos. Este indicador es particularmente importante porque refleja la eficiencia global de cada ruta tecnológica en la conversión de los RSM en energía eléctrica. A diferencia de la potencia eléctrica neta por cantidad de residuos admitidos, este criterio toma en cuenta la totalidad de los residuos dispuestos localmente, proporcionando una visión más integral de la eficiencia energética, lo que puede verse como la cantidad de energía extraída del total potencialmente disponible. Tecnologías como INC y GAS suelen tener una eficiencia de conversión más alta debido a sus capacidades para manejar y procesar grandes volúmenes de residuos con un alto PCI. Por otro lado, DA y RSCB pueden presentar variaciones en eficiencia dependiendo de la composición y el tratamiento previo de los residuos. Este indicador permite una evaluación comparativa entre tecnologías, considerando no solo la cantidad de RSM, sino también la calidad y el potencial energético de los mismos, lo que es esencial para una planificación energética sostenible.

La contribución al balance energético local es un indicador crítico que evalúa el impacto de cada alternativa de conversión de RSMaE en el suministro energético de una comunidad o región. Este criterio se calcula como el porcentaje promedio de la generación eléctrica neta sobre la demanda eléctrica local, proporcionando una medida directa de cómo cada tecnología contribuye a la autosuficiencia energética y a la reducción de la dependencia de fuentes externas de energía convencionales y/o fósiles. Tecnologías como INC y GAS, que suelen tener una mayor capacidad de generación eléctrica, pueden ofrecer una contribución importante al balance energético, especialmente en áreas

con alta demanda energética. DA y RSCB, aunque pueden tener menores capacidades de generación, también pueden contribuir de manera relevante, especialmente si están optimizadas para procesar residuos específicos con alta eficiencia. Este indicador es vital para evaluar el impacto a largo plazo de las alternativas de conversión de RSMaE en la sostenibilidad energética local, ayudando a identificar aquellas tecnologías que no solo son viables en términos de eficiencia energética, sino que también fortalecen la resiliencia y la independencia energética de la comunidad.

En conjunto, estos criterios proporcionan un aporte importante a la consolidación de una base sólida para la toma de decisiones informadas, promoviendo tecnologías que no solo son eficientes y viables desde el punto de vista energético, sino que también ofrecen beneficios sociales y económicos tangibles, contribuyendo al desarrollo sostenible y resiliente en la gestión de residuos y generación de energía.

4.2.3. Criterios Económicos

La evaluación simultánea de los criterios económicos más utilizados en proyectos de conversión de RSMaE, como el Valor Presente Neto (VPN) y la Tasa Interna de Retorno (TIR) (Abushammala & Qazi, 2021), así como el Índice de Rentabilidad (IR) (Vidal-Barrero et al., 2022), y la Relación Costo-Beneficio (RCB) (Lui et al., 2022), es esencial para obtener una comprensión completa y precisa de la viabilidad financiera de estos proyectos. El VPN es crucial ya que calcula el valor actual de los flujos de caja futuros, proporcionando una medida clara del beneficio neto ajustado por el tiempo. La TIR ofrece una perspectiva sobre la eficiencia del capital invertido al mostrar el porcentaje de retorno que un proyecto genera, facilitando comparaciones directas con otras inversiones o tasas de referencia. El IR es importante para evaluar cuánto beneficio se genera por cada unidad de inversión, lo cual es vital para la asignación eficiente de recursos limitados. Por último, la RCB permite una evaluación directa de los beneficios económicos en relación con los costos, ofreciendo una visión panorámica de la economía del proyecto. Analizar todos estos indicadores juntos proporciona una base sólida para la toma de decisiones, asegurando que se consideren todos los aspectos de la rentabilidad y se minimicen los riesgos financieros. Los criterios económicos utilizados en este estudio se pueden estimar mediante la aplicación de las Ecuaciones (4.8)–(4.18).

$$LCOE_x = \frac{CAPEX_{x,0} + \sum_{i=1}^n \frac{OPEX_{x,i}}{(1 + d_g)^i}}{\sum_{i=1}^n \frac{E_{x,i}}{(1 + d_g)^i}} \quad (4.8)$$

$$COE_{x,1} = LCOE_x \cdot \frac{n \cdot d_g}{(1 + d_g)^n - 1} \quad (4.9)$$

$$V_{E,x,i} = PPE_i \cdot E_{x,i} \cdot (1 + d_g)^i \quad (4.10)$$

$$V_{C,x,i} = PPC_i \cdot C_{x,i} \cdot (1 + d_g)^i \quad (4.11)$$

$$IN_{x,i} = V_{E,x,i} + V_{C,x,i} \quad (4.12)$$

$$G_{x,i} = OPEX_{x,i} + D_{x,i} + IMP_{x,i} - IMP_{d,x,i} \quad (4.13)$$

$$VPN_x = \left[\sum_{i=1}^n \frac{IN_{x,i} - G_{x,i}}{(1 + d)^i} \right] - CAPEX_{x,0} \quad (4.14)$$

$$0 = \left[\sum_{i=1}^n \frac{IN_{x,i} - G_{x,i}}{(1 + TIR_x)^i} \right] - CAPEX_{x,0} \quad (4.15)$$

$$IR_x = \frac{VPN_x}{CAPEX_{x,0}} + 1 \quad (4.16)$$

$$RCB_x = \left[\sum_{i=1}^n \frac{IN_{x,i}}{(1 + d)^i} \right] \cdot \left\{ \sum_{i=1}^n \frac{G_{x,i}}{(1 + d)^i} + CAPEX_{x,0} \right\}^{-1} \quad (4.17)$$

$$UE_x = \left(\frac{PPE_i}{COE_x} - 1 \right) \cdot 100 \quad (4.18)$$

Donde: $LCOE_x$ es el costo nivelado de electricidad del proyecto x ($USD kWh^{-1}$); $COE_{x,1}$ es el costo de generación de electricidad del proyecto x en el primer año de operación ($USD kWh^{-1}$); $IN_{x,i}$ representa los ingresos del proyecto x en el año i (USD); $G_{x,i}$ denota los gastos del proyecto x en el año i (USD); $V_{E,x,i}$ representa las ventas de electricidad del proyecto x en el año i (USD); $V_{C,x,i}$ denota las ventas de créditos carbón del proyecto x en el año i (USD); $OPEX_{x,i}$ representa el OPEX del proyecto x en el año i (USD); $D_{x,i}$ representa la depreciación del CAPEX instalado del proyecto x en el año i (USD); $IMP_{x,i}$ representa los impuestos totales del proyecto x en el año i (USD); $IMP_{d,x,i}$ denota la deducción total de impuestos del proyecto x en el año i (USD); VPN_x es el VPN del proyecto x (USD); d es la tasa de descuento ($\%$); n representa la vida útil del proyecto (25 a); $CAPEX_{x,0}$ representa el CAPEX del proyecto x en el periodo de construcción (USD); TIR_x es la TIR del proyecto x ($\%$); IR_x es el IR del proyecto x ($USD USD^{-1}$); RCB_x es la RBC del proyecto x ($USD USD^{-1}$); y UE_x es margen de utilidad por la venta de la electricidad generada en el proyecto x ($\%$). Dentro del alcance de este estudio, se considero que un proyecto es rentable económicamente si cumple con las siguientes restricciones de rentabilidad simultáneamente:

- R1: $VPN_x > 0$ USD: Esto implica que el valor presente de los ingresos es mayor que el valor presente de los gastos, lo que se traduce como una ganancia neta del proyecto x .
- R2: $TIR_x > d$: Si la TIR es mayor que la tasa de descuento d , implica que el proyecto x genera un retorno a un porcentaje de ganancias mayor que d .

- R3: $IR_x > 1$: IR es la proporción entre el valor presente de los flujos de caja netos y el CAPEX del proyecto x . Un IR mayor a la unidad implica que el proyecto x genera mayor valor que la inversión inicial de este.
- R4: $RBC_x > 1$: La RBC de un proyecto x es la proporción entre el valor presente de los beneficios y el valor presente de los costos. Una RBC mayor a la unidad implica que los beneficios del proyecto superan sus costos.
- R5: $UE_x > 0 \%$: esto implica que el margen de utilidad por la venta de electricidad es positivo, es decir, que el precio de venta es mayor que el costo de producción.

El primer año, dedicado a la construcción de la planta ($i = 0$) se estableció en 2023, con una vida útil operativa desde 2024 hasta 2048 ($i = 1$ a $i = 25$). Para contextualizar los proyectos dentro del marco legal colombiano, se consideraron los beneficios de la ley colombiana para promover la inversión en proyectos de energía renovable no convencional y reducir las emisiones nacionales de GEI. La Resolución 1092 de 2022 (DNP, 2022) especifica una tasa de descuento del 6.4 % para la inversión pública en proyectos ambientales con vidas útiles entre 6 y 25 años. La tasa marginal de impuestos para las empresas públicas es del 9 % según la referencia (Presidencia de la República de Colombia, 1989). De acuerdo con los beneficios de la Ley 1715 de 2014 (Congreso de la República de Colombia, 2014), los impuestos sobre equipos y suministros para la implementación y operación de los proyectos se establecen en 0 %. Además, se consideró una deducción fiscal del 50 % de los impuestos marginales por hasta 15 años para proyectos de generación de energía renovable que reduzcan las emisiones de GEI, y hasta el 50 % del CAPEX del proyecto. Las transacciones de créditos de carbono se pueden negociar en mercados internacionales, con un precio que varía en el mercado entre 31 USD $t_{CO_2,eq}^{-1}$ en California y 99 USD $t_{CO_2,eq}^{-1}$ en el Reino Unido. En Colombia, el impuesto al carbono se establece en 5 USD $t_{CO_2,eq}^{-1}$ (World Bank, 2023).

La tasa de inflación de equipos (d_e) se puede considerar igual al 2 % según la recomendación de la U.S. EPA, dado que la inflación del precio de los equipos depende de la inflación del país fabricante y no del país de destino. Además, la tasa de inflación general oscila alrededor del 5.1 %, basada en el promedio de los últimos cinco años (abr., 2018–mar., 2023) de las tasas de inflación colombianas (Banco de la república de Colombia, 2023). La tasa de incremento anual de precios de los productos puede considerarse igual a d_g .

4.2.4. Criterios Ambientales

La evaluación de proyectos de conversión de RSMaE requiere un enfoque integral que considere criterios ambientales para asegurar su sostenibilidad y beneficios ecológicos. Los proyectos de conversión de RSMaE tienen el potencial de mitigar las emisiones de GEI y de ofrecer una alternativa viable a los métodos convencionales de gestión de RSM, como los rellenos sanitarios convencionales (i.e., sin captura de biogás), que

suelen tener un impacto ambiental negativo. Uno de los principales indicadores en la evaluación de proyectos de conversión de RSMaE es el potencial de reducción de GEI (PRGEI), que se define como la diferencia entre las emisiones de CO₂ equivalentes del proyecto de conversión de RSMaE y las de un RS. Este indicador es crucial, ya que permite cuantificar el impacto neto en las emisiones de GEI, proporcionando una medida clara de la efectividad del proyecto en términos de mitigación climática. Los RS emiten una cantidad considerable de CH₄, un GEI mucho más potente que el CO₂, y al compararlos con las emisiones de un proyecto de conversión de RSMaE, se puede demostrar la ventaja ambiental de este último.

Otro indicador relevante es el potencial evitable de emisiones de GEI (PEGEI), que se refiere a las emisiones evitadas al generar electricidad a partir de RSM en lugar de utilizar plantas térmicas de combustibles fósiles. Este indicador destaca un doble beneficio de los proyectos de conversión de RSMaE, que no solo gestionan los RSM de manera más limpia, sino que también contribuyen a la reducción de las emisiones de GEI asociadas a la generación de electricidad a partir de combustibles fósiles. La importancia de estos indicadores radica en su capacidad para proporcionar una evaluación cuantitativa y objetiva del impacto ambiental de los proyectos de conversión de RSMaE, lo que es esencial para la toma de decisiones informadas y para promover la adopción de tecnologías más sostenibles.

Estos indicadores, PRGEI y PEGEI, pueden calcularse mediante el empleo de las Ecuaciones (4.19) y (4.20), adaptadas de la U.S. EPA (2021).

$$\text{PRGEI}_{x,i} = \sum_{e=1}^s \sum_{i=1}^n \text{PCG}_e \cdot (\dot{m}_{e,x,i} - \dot{m}_{e,RS,i}) \quad (4.19)$$

$$\text{PEGEI}_{x,i} = f_{\text{con}} \cdot \sum_{i=1}^n E_{x,i} \quad (4.20)$$

Donde: $\text{PRGEI}_{x,i}$ es el potencial de reducción de emisión de gases de efecto invernadero (kg_{CO₂,eq}); $\text{PEGEI}_{x,i}$ es el potencial evitable de emisiones de gases de efecto invernadero mediante plantas térmicas de generación de electricidad (kg_{CO₂,eq}); PCG_e es el potencial de calentamiento global del contaminante e emitido por el proyecto x en el año i (kg_{CO₂,eq} kg_e⁻¹); $\dot{m}_{e,x,i}$ es el flujo másico del contaminante e emitido por el proyecto x en el año i (kg_e⁻¹); $\dot{m}_{e,RS,i}$ es el flujo másico del contaminante e emitido por un relleno sanitario convencional (sin captura de biogás) en el año i (kg_e⁻¹); y f_{con} es el factor de emisión de GEI de una planta térmica de generación electricidad (0.43 kg_{CO₂,eq} kWh_e⁻¹).

Los rellenos sanitarios convencionales representan diferentes fuentes de impactos ambientales a escala local, regional y global. Particularmente, las emisiones de GEI de estos sistemas se destacan como una fuente notable a nivel global. Calcular el PRGEI y el PEGEI de diferentes proyectos permite evaluar parcialmente los beneficios ambientales de los proyectos de conversión de RSMaE en términos de emisiones de GEI.

4.3. Selección de un método de análisis de decisión multicriterio

Los métodos de ADM son herramientas fundamentales en la toma de decisiones complejas, especialmente cuando se deben considerar múltiples criterios que pueden ser conflictivos entre sí. En el contexto de la gestión de residuos sólidos municipales y la valorización energética, estos métodos permiten evaluar y priorizar diversas tecnologías y estrategias, basándose en criterios técnicos, económicos, ambientales y sociales.

La elección del método de ADM adecuado es crucial, ya que cada método tiene sus propias fortalezas y debilidades. Para ayudar en esta selección, hemos evaluado 19 métodos de ADM comunes utilizando una serie de criterios específicos:

- i1: Maneja un gran número de criterios y alternativas
- i2: Proporciona una verificación de consistencia
- i3: Sencillo de calcular
- i4: Requiere menos información subjetiva al inicio
- i5: Indiferente a la interdependencia de criterios
- i6: Ampliamente utilizado en diferentes campos
- i7: Flexibilidad para combinar con otros métodos
- i8: Capacidad para manejar datos cualitativos y cuantitativos

La [Figura 4.1](#) presenta los resultados de las evaluaciones de cada método según estos criterios, basadas en los hallazgos de la [Sección 1.2](#). Estas evaluaciones están diseñadas para proporcionar una visión clara y diferenciada de las capacidades de cada método, facilitando así la selección del más adecuado para aplicaciones específicas en la gestión de residuos y la valorización energética.

La evaluación de los métodos de ADM mostrada en la [Figura 4.1](#) revela que TOPSIS y AHP son los más equilibrados y ampliamente utilizados, debido a su capacidad para manejar un gran número de criterios y alternativas, proporcionando verificación de consistencia robusta y flexibilidad para combinar con otros métodos, aunque pueden ser complejos de calcular y dependen de la subjetividad inicial. ELECTRE es también un método práctico, por su robustez en la evaluación multicriterio y amplia utilización, proporcionando una evaluación integral de criterios técnicos, económicos y ambientales, siendo ideal para situaciones que requieren una evaluación detallada y precisa de las alternativas. PROMETHEE-GAIA y WASPAS se destacan por su capacidad de manejo de incertidumbres y su enfoque holístico en la evaluación multicriterio, siendo ideales




Figura 4.1: Resultados de la evaluación de métodos de ADM.

para proyectos que requieren una consideración equilibrada de múltiples criterios, a pesar de su complejidad. Fuzzy-AHP y G-AHP también ofrecen ventajas adicionales en la gestión de incertidumbres mediante técnicas difusas y grises, lo que las hace útiles en situaciones donde la información es incompleta o incierta, aunque comparten la complejidad y dependencia de la subjetividad del AHP. ARAS y Fuzzy-TOPSIS, aunque menos conocidos, proporcionan evaluaciones robustas y prácticas, siendo útiles en contextos donde se necesita manejar la incertidumbre de manera efectiva. Otros métodos como Delphi difuso y Método 3T son prácticos y específicos para aplicaciones técnicas, aunque menos robustos en la verificación de consistencia y más complejos de implementar. Metodologías avanzadas como MCGWO y IDOCRIW son útiles para la optimización multicriterio y la determinación precisa de pesos de criterios, aunque su alta complejidad y necesidad de capacidad computacional pueden limitar su aplicabilidad. CILOS, ENTROPY, CRITIC, y OWA, aunque útiles para la evaluación de impacto de criterios y la determinación de pesos mediante técnicas de entropía y correlación, son menos conocidos y también complejos, lo que puede restringir su uso.

Ahora bien, el método TOPSIS es práctico y sencillo de aplicar, pero al igual que el AHP puede verse influenciado por la subjetividad en la asignación del valor de los pesos. Esta limitación se puede abordar empleando métodos objetivos como ENTROPY, cuyo algoritmo determina el valor de los pesos de los criterios basándose exclusivamente en la dispersión de los valores de desempeño de cada alternativa, como se verá en la siguiente sección.

4.4. Clasificación de Alternativas

La determinación de los pesos de un conjunto de criterios puede realizarse de múltiples formas. Entre los métodos objetivos el más popular es el método ENTROPY, el cual es especialmente útil en los casos donde no se cuenta con juicio de expertos. Este método permite el cálculo de los pesos de criterios en función de la intensidad de contraste entre los desempeños de las alternativas analizadas bajo cada criterio, y entre criterios simultáneamente. Adicionalmente, este método aplica teoría de probabilidad para estimar la incertidumbre de la información.

Para la correcta aplicación del método ENTROPY-TOPSIS se deben considerar algunas definiciones previas. En primer lugar, se define $A = (a_1, a_2, a_3, \dots, a_m)^T$ como el conjunto de las m alternativas y $G = (g_1, g_2, g_3, \dots, g_n)^T$ como el conjunto de los n criterios que serán usados para evaluar las alternativas. Adicionalmente, $W = (w_1, w_2, w_3, \dots, w_n)^T$ es un vector cuyas componentes w_j representan los pesos de los n criterios g_j . Por otro lado, considere G^+ y G^- como los subconjuntos de G que representan los criterios de beneficio y costo, respectivamente. $a_{i,j}$ representa el desempeño de la alternativa a_i bajo el criterio g_j .

A continuación, se describen los pasos del método ENTROPY (El Kourdi et al., 2023):

Paso 1. Normalizar la matriz de decisión X mediante la Ecuación 4.21.

$$P = [p_{i,j}]_{m \times n}, \quad p_{i,j} = \frac{a_{i,j}}{\sum_{i=1}^m a_{i,j}} \quad (4.21)$$

Si la matriz de decisión A presenta datos negativos, se requerirá una transformación de los datos para eliminar esta característica. Esta puede realizarse mediante la Ecuación 4.22.

$$a_{i,j} = a_{i,j} - \min a_{i,j} + 1 \quad (4.22)$$

Paso 2. Calcular la entropía de cada criterio empleando la Ecuación 4.23.

$$e = [e_1, e_2, e_3, \dots, e_n], \quad e_j = -\frac{1}{\ln(m)} \sum_{i=1}^m p_{i,j} \ln(p_{i,j}) \quad (4.23)$$

Paso 3. Estimar los pesos de cada criterio aplicando la [Ecuación 4.23](#).

$$w_j = \frac{1 - e_j}{n - \sum_{j=1}^n e_j} \quad (4.24)$$

Donde: $0 \leq w_j \leq 1$ y $\sum_{j=1}^n w_j = 1$.

El método TOPSIS es uno de los métodos de decisión multicriterio más populares en la evaluación de alternativas de conversión de RSMaE (El Kourdi et al., [2023](#)). Este método se caracteriza por requerir una cantidad relativamente pequeña de entradas para calificar las alternativas, y sus resultados son de fácil interpretación. En su forma convencional, el único parámetro que en teoría requiere un juicio subjetivo en este método sería el vector de pesos de los criterios, aunque esto puede ser superado mediante la aplicación de métodos de estimación objetiva de pesos de criterios, como el método ENTROPY descrito.

El método TOPSIS incluye los siguientes pasos (Martínez López et al., [2023](#)):

Paso 1. Normalizar la matriz de decisión $X = [a_{i,j}]_{m \times n}$, la cual representa el desempeño de las alternativas para cada criterio. El objetivo de este paso es unificar las dimensiones de los diferentes criterios (e.g., kWh, USD, m). Para los criterios de beneficio, cada desempeño se divide por el mayor valor de la columna de X , como muestra la [Ecuación 4.25](#). Para los criterios de costo, cada desempeño se divide por el valor menor de cada columna de X , como muestra la [Ecuación 4.26](#).

$$r_{i,j} = \frac{x_{i,j}}{u_j^+} \quad (4.25)$$

$$r_{i,j} = \frac{x_{i,j}}{u_j^-} \quad (4.26)$$

Donde: u_j^+ y u_j^- representan los valores máximos y mínimos de las columnas j -ésimas de X , respectivamente. Al completar este paso se obtiene una nueva matriz de decisión $R = [r_{i,j}]_{m \times n}$. Si se prefiere, o si se encuentran inconsistencias en los valores normalizados por las magnitudes de las escalas originales (e.g., obtener valores mayores a la unidad por dividir por valores entre 0 y 1, como puede suceder en criterios de costo), se puede utilizar la matriz normalizada $P = [p_{i,j}]_{m \times n}$.

Paso 2. Calcular la matriz de decisión $V = [v_{i,j}]_{m \times n}$ empleando la [Ecuación 4.27](#).

$$v_{i,j} = w_j \cdot r_{i,j} \quad (4.27)$$

Donde: $\sum_{j=1}^n w_j = 1$.

Paso 3. Determinar las soluciones ideal positiva y no ideal negativa. La solución ideal positiva corresponde a los mejores desempeños de cada criterio en la matriz de decisión V , como muestra la [Ecuación 4.28](#). En ese sentido, la solución no ideal negativa corresponde a los desempeños más deficientes de cada criterio en la matriz de decisión V , como muestra la [Ecuación 4.29](#).

$$v^+ = [v_1^+, v_2^+, v_3^+, \dots, v_n^+], \quad v_j^+ = \begin{cases} \max_i v_{i,j}, & g_j \in G^+ \\ \min_i v_{i,j}, & g_j \in G^- \end{cases} \quad (4.28)$$

$$v^- = [v_1^-, v_2^-, v_3^-, \dots, v_n^-], \quad v_j^- = \begin{cases} \min_i v_{i,j}, & g_j \in G^+ \\ \max_i v_{i,j}, & g_j \in G^- \end{cases} \quad (4.29)$$

Donde: v^+ y v^- denotan los vectores de la solución ideal positiva y la solución no ideal negativa, respectivamente.

Paso 4. Calcular las distancias Euclidianas entre cada alternativa y las soluciones ideal positiva ([Ecuación 4.30](#)) y no ideal negativa ([Ecuación 4.31](#)).

$$d_{a_i}^+ = \sqrt{\sum_{j=1}^n (v_{i,j} - v_{i,j}^+)^2} \quad (4.30)$$

$$d_{a_i}^- = \sqrt{\sum_{j=1}^n (v_{i,j} - v_{i,j}^-)^2} \quad (4.31)$$

Donde $d_{a_i}^+$ y $d_{a_i}^-$ representan las distancias Euclidianas entre cada alternativa y las soluciones ideal positiva y no ideal negativa, respectivamente.

Paso 5. Calcular el coeficiente de cercanía relativa de cada alternativa con respecto a la solución ideal en la base de las distancias Euclidianas obtenidas en el paso previo. Este coeficiente se determina mediante la [Ecuación 4.32](#).

$$cl(a_i) = \frac{d_{a_i}^-}{d_{a_i}^+ + d_{a_i}^-} \quad (4.32)$$

Donde: $cl(a_i)$ es el coeficiente de cercanía. Si la alternativa a_i se encuentra cerca a la solución ideal positiva, $cl(a_i)$ estará más cerca de 1, mientras que, si la alternativa se encuentra cerca de la solución no ideal negativa, $cl(a_i)$ estará más cerca de 0.

Paso 6. Clasificar las alternativas en orden descendente de acuerdo con el coeficiente de cercanía.

La idea básica del método TOPSIS es que la mejor solución es la solución con la mejor distancia a la solución ideal positiva, y con la mayor distancia a la solución no ideal negativa.

4.5. Estructura general de la herramienta de selección de alternativas

El diseño de estructuras integrales para evaluar alternativas de valorización energética de los RSM bajo múltiples criterios es estrategia que permite maximizar la sostenibilidad de las rutas tecnológicas evaluadas. Estas estructuras consisten en una evaluación holística que considera no solo el rendimiento técnico y económico, sino también impactos sobre medioambiente y la sociedad. Al adoptar un enfoque multicriterio, se pueden balancear las diversas prioridades y restricciones, facilitando la toma de decisiones informadas y alineadas con los objetivos de desarrollo sostenible.

La [Figura 4.2](#) revela el algoritmo de la herramienta desarrollada mediante lo descrito en las secciones y capítulos anteriores, aplicado para seleccionar la mejor alternativa de valorización energética de los RSM integrando aspectos locales del lugar de estudio. El primer nivel corresponde al análisis de los RSM y sus tasas de generación. En esta etapa se estima la composición categórica y fisicoquímica de los RSM, permitiendo obtener datos básicos y segregados requeridos para la estimación de los diferentes potenciales de las alternativas de conversión de RSMaE. Igualmente, se obtienen proyecciones de las tasas de disposición de los RSM, lo que permite establecer la disponibilidad de estos residuos para los años futuros. El segundo nivel corresponde a la estimación de los potenciales técnicos, energéticos, económicos y ambientales de cada ruta tecnológica, lo cual permite comprender el desempeño de estas alternativas y estudiar su dinámica. En el tercer nivel se calculan los valores de los criterios de sostenibilidad abordados para evaluar las diferentes alternativas de conversión de RSMaE. Finalmente, en el cuarto nivel se aplican métodos de ponderación de criterios, lo cual permite clasificar el desempeño sostenible de las alternativas y seleccionar la mejor para las condiciones del lugar de estudio.




Figura 4.2: Estructura de la herramienta integral de selección de alternativas de valorización energética de los RSM.

Esta estructura permite abordar la problemática de gestión de los RSM en función de múltiples dimensiones de la sostenibilidad desde un enfoque netamente objetivo, garantizando que la alternativa seleccionada represente la opción mejor equilibrada dentro del conjunto de rutas posibles. Luego, esta herramienta propuesta puede ser fácilmente utilizada por los administradores públicos locales dentro del ejercicio de estructuración de los planes de desarrollo de un lugar de estudio específico, permitiendo ahorrar cuantiosas cantidades de recursos en esta etapa de prefactibilidad. No obstante, si bien se pueden identificar limitaciones en el alcance de la estructura propuesta (e.g., dimensión social de la sostenibilidad, evaluación de rutas tecnológicas como pirólisis, gasificación plasma), el diseño de la herramienta permite modificar fácilmente la configuración de esta estableciendo el número de alternativas deseadas, o las dimensiones de la sostenibilidad abordadas.

4.6. Conclusiones del capítulo

Se establecieron múltiples criterios que abordan de forma integral la evaluación de alternativas de conversión de RSMaE. Estos comprenden el estudio de dimensiones convencionales y no convencionales de la sostenibilidad de proyectos de conversión de RSMaE, integrando estimaciones técnicas, energéticas, económicas y ambientales que permiten evaluar el desempeño de las rutas tecnológicas de forma holística y objetiva. En este contexto, se emplea el método ENTROPY para la estimación de los pesos de los criterios, permitiendo un cálculo objetivo de la contribución relativa de cada criterio en la selección final de la alternativa. Esto es particularmente ventajoso en contextos donde se desea reducir la incertidumbre que puede generar una ponderación subjetiva. El método ENTROPY, al cuantificar la dispersión de la información de cada criterio, asegura que aquellos criterios con mayor variabilidad tengan un mayor peso en el proceso de decisión, garantizando así una representación equitativa de la información disponible. Adicionalmente, el método TOPSIS aborda de manera apropiada el cálculo de un índice de sostenibilidad que permite comparar el equilibrio entre los criterios que representa cada una de las alternativas evaluadas. TOPSIS, al identificar la solución ideal positiva y negativa, proporciona una medida cuantitativa del desempeño de cada alternativa en relación con la mejor y peor solución posible, facilitando así la identificación de la alternativa que se encuentra más cerca del ideal teórico. Esta metodología es esencial para garantizar que las decisiones no solo se basen en el cumplimiento de ciertos criterios aislados, sino en un balance integral que maximice la sostenibilidad global del proyecto.

La integración de múltiples criterios en la evaluación de alternativas de conversión de RSMaE no solo mejora la toma de decisiones al considerar una gama más amplia de factores, sino que también se complementa con el uso de estructuras que permiten explorar y seleccionar alternativas con el mejor equilibrio entre los criterios analizados para los posibles tratamientos a ser integrados en el sistema de gestión de RSM de un

lugar de estudio. Esto, permite la adopción de un enfoque integral y multicriterio en la evaluación de alternativas de conversión de RSMAE, lo cual es fundamental para la implementación de soluciones sostenibles y eficientes en la gestión de RSM

Referencias

- Abushammala, M. F. M., & Qazi, W. A. (2021). Financial feasibility of waste-to-energy technologies for municipal solid waste management in Muscat, Sultanate of Oman. *Clean Technologies and Environmental Policy*, 23(7), 2011-2023. <https://doi.org/10.1007/s10098-021-02099-8>
- Afrane, S., Ampah, J., Jin, C., Liu, H., & Aboagye, E. (2021). Techno-economic feasibility of waste-to-energy technologies for investment in Ghana: A multicriteria assessment based on fuzzy TOPSIS approach. *Journal of Cleaner Production*, 318. <https://doi.org/10.1016/j.jclepro.2021.128515>
- Alao, M. A., Ayodele, T. R., Ogunjuyigbe, A. S., & Popoola, O. M. (2020). Multi-criteria decision based waste to energy technology selection using entropy-weighted TOPSIS technique: The case study of Lagos, Nigeria. *Energy*, 201. <https://doi.org/10.1016/j.energy.2020.117675>
- Banco de la república de Colombia. (2023). Inflación total y meta. <https://www.banrep.gov.co/es/estadisticas/inflacion-total-y-meta>
- Bashir, M. J. K., Ng, C. A., Sethupathi, S., & Lim, J. W. (2019). Assessment of the Environmental, Technical and Economic Issues Associated with Energy Recovery from Municipal Solid Waste in Malaysia. En H. B. S. L. Tong C.-W. Chin-Tsan W. (Ed.), *IOP Conference Series: Earth and Environmental Science* (Vol. 268). Institute of Physics Publishing. <https://doi.org/10.1088/1755-1315/268/1/012044>
- Beyene, H. D., Werkneh, A. A., & Ambaye, T. G. (2018). Current updates on waste to energy (WtE) technologies: a review. *Renewable Energy Focus*, 24, 1-11. <https://doi.org/10.1016/j.ref.2017.11.001>
- Coban, A., Ertis, I., & Cavdaroglu, N. (2018). Municipal solid waste management via multi-criteria decision making methods: A case study in Istanbul, Turkey. *Journal of Cleaner Production*, 180, 159-167. <https://doi.org/10.1016/j.jclepro.2018.01.130>
- Congreso de la República de Colombia. (2014, mayo). *Ley 1715 de 2014*. Diario Oficial 49.150. <http://svrpubindc.imprenta.gov.co/diario>
- DNP. (2022, abril). *Resolución Número 1092 de 2022*. Diario Oficial 52.011. <http://svrpubindc.imprenta.gov.co/diario>

- El Kourdi, S., Aboudaoud, S., Abderafi, S., Cheddadi, A., & Ammar, A. (2023). Pyrolysis Technology Choice to Produce Bio-oil, from Municipal Solid Waste, Using Multi-criteria Decision-making Methods. *Waste and Biomass Valorization*, 14(11), 3705-3722. <https://doi.org/10.1007/s12649-023-02076-w>
- Lauber, J. D. (2007). Economic and technical viability of various MSW, WTE waste to energy thermal treatment processes. *Proceedings of the Air and Waste Management Association's Annual Conference and Exhibition, AWMA*, 7, 4969-4970. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-44649119828%5C&partnerID=40%5C&md5=e74a045cd2671c08dc8a117507d0abc7>
- Lu, Y.-T., Lee, Y.-M., & Hong, C.-Y. (2017). Inventory analysis and social life cycle assessment of greenhouse gas emissions from waste-to-energy incineration in Taiwan. *Sustainability (Switzerland)*, 9(11). <https://doi.org/10.3390/su9111959>
- Lui, J., Paul, M. C., Sloan, W., & You, S. (2022). Techno-economic feasibility of distributed waste-to-hydrogen systems to support green transport in glasgow. *International Journal of Hydrogen Energy*, 47(28), 13532-13551. <https://doi.org/10.1016/j.ijhydene.2022.02.120>
- Martínez López, L., Ishizaka, A., Qin, J., & Álvarez Carrillo, P. A. (2023). *Multi-Criteria Decision-Making Sorting Methods*. Elsevier. <https://doi.org/10.1016/C2020-0-02008-6>
- Otero Meza, D. D., Sagastume Gutiérrez, A., Cabello Eras, J. J., Salcedo Mendoza, J., & Hernández Ruydiaz, J. (2023). Techno-economic and environmental assessment of the landfill gas to energy potential of major Colombian cities. *Energy Conversion and Management*, 293, 117522. <https://doi.org/10.1016/j.enconman.2023.117522>
- Presidencia de la República de Colombia. (1989, marzo). *DECRETO LEY 624 DE 1989*. <https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=6533>
- Ramos, A., & Rouboa, A. (2020). Renewable energy from solid waste: life cycle analysis and social welfare. *Environmental Impact Assessment Review*, 85, 106469. <https://doi.org/10.1016/j.eiar.2020.106469>
- Rodrigues, A. P., Fernandes, M. L., Rodrigues, M. F. F., Bortoluzzi, S. C., da Costa, S. E., & de Lima, E. (2018). Developing criteria for performance assessment in municipal solid waste management. *Journal of Cleaner Production*, 186, 748-757. <https://doi.org/10.1016/j.jclepro.2018.03.067>
- Rodrigues, L., Santos, I., Santos, T., Barros, R., & Tiago Filho, G. (2022). Energy and economic evaluation of MSW incineration and gasification in Brazil. *Renewable Energy*, 188, 933-944. <https://doi.org/10.1016/j.renene.2022.02.083>
- Soltani, A., Hewage, K., Reza, B., & Sadiq, R. (2015). Multiple stakeholders in multi-criteria decision-making in the context of municipal solid waste management: A review. *Waste Management*, 35, 318-328. <https://doi.org/10.1016/j.wasman.2014.09.010>

- UNEP. (2024). Global Waste Management Outlook 2024: Beyond an age of waste – Turning rubbish into a resource. <https://www.unep.org/resources/global-waste-management-outlook-2024>
- U.S. EPA. (2021). LFGcost-Web — Landfill Gas Energy Cost Model. <https://www.epa.gov/lmop/lfgcost-web-landfill-gas-energy-cost-model>
- Vidal-Barrero, F., Baena-Moreno, F. M., Preciado-Cárdenas, C., Villanueva-Perales, á., & Reina, T. R. (2022). Hydrogen production from landfill biogas: Profitability analysis of a real case study. *Fuel*, 324. <https://doi.org/10.1016/j.fuel.2022.124438>
- Vlachokostas, C., Michailidou, A. V., & Achillas, C. (2021). Multi-Criteria Decision Analysis towards promoting Waste-to-Energy Management Strategies: A critical review. *Renewable and Sustainable Energy Reviews*, 138. <https://doi.org/10.1016/j.rser.2020.110563>
- World Bank. (2022). Solid Waste Management. <https://www.worldbank.org/en/topic/urbandevelopment/brief/solid-waste-management>
- World Bank. (2023). Carbon Pricing Dashboard. https://carbonpricingdashboard.worldbank.org/map%5C_data
- Yaashikaa, P. R., Kumar, P. S., Nhung, T. C., Hemavathy, R. V., Jawahar, M. J., Neshaanthini, J. P., & Rangasamy, G. (2022). A review on landfill system for municipal solid wastes: Insight into leachate, gas emissions, environmental and economic analysis. *Chemosphere*, 309, 136627. <https://doi.org/10.1016/J.CHEMOSPHERE.2022.136627>
- Yang, Y., Liew, R. K., Tamothran, A. M., Foong, S. Y., Yek, P. N. Y., Chia, P. W., Van Tran, T., Peng, W., & Lam, S. S. (2021). Gasification of refuse-derived fuel from municipal solid waste for energy production: a review. *Environmental Chemistry Letters*. <https://doi.org/10.1007/s10311-020-01177-5>
- Yin, L.-J., Wang, C., Hu, Y.-Y., Chen, D.-Z., Xu, J.-F., & Liu, J. (2017). AHP-based approach for optimization of waste disposal method in urban functional zone. *Environmental Technology (United Kingdom)*, 38(13–14), 1689-1695. <https://doi.org/10.1080/09593330.2016.1244565>

Capítulo 5

Evaluación Integral y Selección de Alternativas de Valorización Energética de RSM: caso de Sincelejo

Resumen del capítulo: Este capítulo evalúa la valorización energética de los RSM dispuestos en la ciudad de Sincelejo, Colombia. Se desarrolló una metodología multicriterio que considera aspectos técnicos, económicos, energéticos y ambientales. Los resultados del análisis de series de tiempo proyectan un incremento del 170 % en las tasas de disposición de RSM para 2050, impulsado por el crecimiento poblacional. La evaluación comparativa de alternativas tecnológicas, como RSCB, GAS, INC y DA, concluyó que el RSCB es la opción más adecuada para Sincelejo, debido a su simplicidad técnica y menores costos, mientras que la GAS ofrece un mayor potencial de reducción de GEI. La metodología desarrollada integra múltiples dimensiones de la sostenibilidad para una toma de decisiones informada.

Palabras clave – Valorización energética; Caso de estudio; Sincelejo; Análisis multicriterio; Proyección residuos.

5.1. Introducción

En el ámbito de la gestión de RSM, la valorización energética emerge como una estrategia clave que permite no solo la reducción del volumen de residuos sino también la recuperación de energía, contribuyendo de manera importante a la sostenibilidad urbana y la mitigación del cambio climático. La ciudad de Sincelejo, como muchas otras en regiones en desarrollo, enfrenta desafíos importantes en la gestión de sus RSM,

exacerbados por un crecimiento poblacional e infraestructura de gestión de RSM que lucha por mantenerse al día con las demandas actuales. En este contexto, el desarrollo y la aplicación de una herramienta metodológica robusta para la evaluación y selección de alternativas de valorización energética se torna no solo relevante sino imperativo.

El análisis integral de alternativas de valorización energética para Sincelejo se justifica en varios frentes. En primer lugar, las metodologías tradicionales de gestión de residuos a menudo se centran en enfoques lineales que no logran integrar múltiples dimensiones críticas como los impactos económicos, ambientales y sociales. La falta de un enfoque holístico y objetivo en la toma de decisiones puede llevar a la implementación de soluciones subóptimas que no abordan de manera efectiva los desafíos complejos y multifacéticos de la gestión de RSM. Por otro lado, la herramienta metodológica desarrollada en esta investigación incorpora un marco de decisión multicriterio, lo que permite una evaluación más exhaustiva y equilibrada de las alternativas, considerando no solo la viabilidad técnica, energética y económica, sino también el impacto ambiental. Esto resulta esencial en un contexto como el de Sincelejo, donde la sostenibilidad de las soluciones implementadas es crucial para asegurar su éxito a largo plazo.

El enfoque metodológico desarrollado ofrece una serie de ventajas distintivas en la evaluación de alternativas de valorización energética. Primero, se basa en un análisis bibliométrico y sistemático de la literatura, lo que asegura que la herramienta esté alineada con las tendencias y mejores prácticas actuales en el campo de la valorización energética de los RSM. Este análisis preliminar no solo identifica las limitaciones de los métodos existentes, sino que también destaca áreas emergentes de oportunidad que pueden ser aprovechadas para mejorar la toma de decisiones. La metodología propuesta para estimar el potencial técnico, económico, ambiental y energético de las alternativas proporciona una base sólida para comparar diversas opciones de valorización, adaptándolas al contexto específico de Sincelejo. Esto es particularmente relevante dada la variabilidad en la composición de los RSM y las condiciones locales que pueden influir en la efectividad de diferentes tecnologías de valorización energética.

La herramienta metodológica también incorpora un componente de proyección de tasas de disposición de RSM, lo cual es fundamental para anticipar futuros escenarios de gestión de residuos y asegurar que las alternativas seleccionadas sean capaces de manejar eficientemente los flujos de residuos proyectados. Esta capacidad de proyección es esencial en ciudades en crecimiento como Sincelejo, donde las tasas de generación de residuos están en constante aumento debido al desarrollo urbano y el crecimiento demográfico. Una proyección precisa permite planificar de manera más efectiva y asegurar que las infraestructuras de valorización energética implementadas puedan adaptarse a las futuras necesidades de gestión de residuos sin requerir modificaciones complejas o inversiones adicionales a corto plazo.

Además, el método objetivo de análisis de decisión multicriterio desarrollado en esta investigación proporciona una herramienta poderosa para evaluar integralmente las alternativas de valorización energética. Este método integra diversas perspectivas y criterios, incluyendo la evaluación de impactos ambientales, costes económicos, y eficiencia energética, lo que asegura una decisión equilibrada y bien informada. El presente capítulo se centra en la implementación de la herramienta metodológica desarrollada en este estudio para el caso de Sincelejo, proporcionando una evaluación integral de las alternativas disponibles, con el objetivo de identificar la opción más viable y sostenible para la valorización energética de sus RSM. Para obtener las estimaciones, proyecciones, pruebas estadísticas y figuras [Figura 5.3](#) y posteriores, se empleó el lenguaje R (R Core Team, 2024) a través de RStudio® (RStudio Team, 2020), siendo ‘fpp3’ (Hyndman, 2024) la librería principal utilizada en el algoritmo desarrollado. El algoritmo desarrollado no se anexa a este estudio debido a que se sometió a un proceso de protección del conocimiento y desarrollo de software.

5.2. Sistema de gestión de RSM de Sincelejo

5.2.1. Tratamiento actual de los residuos sólidos municipales

El tratamiento de los RSM en Sincelejo es una tarea de gran importancia, dados los desafíos que presenta la configuración demográfica y económica del municipio. Sincelejo cuenta con una población total de 310 456 hab, de las cuales el 88 % reside en el área urbana, mientras que la población rural representa el 22 % (DANE, 2018). Esta distribución implica que la mayoría de la gestión de RSM se centra en la zona urbana, que se extiende por 21.43 km², con una alta densidad poblacional que demanda una infraestructura de recolección eficiente y frecuente. La dispersión de la población rural sobre sus 263.67 km² agrega complejidad logística, requiriendo soluciones adaptadas a las distancias y accesibilidad variable de estas áreas (Alcaldía de Sincelejo, 2017). Las características topográficas de Sincelejo, con una altitud de 213 m sobre el nivel del mar, y un clima cálido seco con precipitaciones anuales de 500 mm a 1200 mm, también influyen en la estrategia de gestión de RSM (INTERASEO S.A.E.S.P. & CAEMA, 2012). Las condiciones de bosque seco tropical favorecen la descomposición rápida de los residuos orgánicos, lo que puede ser beneficioso para el compostaje, pero también requiere un manejo cuidadoso de los lixiviados generados en sitios de disposición para prevenir la contaminación.

La estructura económica de Sincelejo, donde las actividades terciarias dominan con un PIB de 928.1 MUSD de un total de 1072.9 MUSD en 2022, refleja una gran diversidad en la generación de residuos. Las actividades primarias, que incluyen ganadería y agricultura, contribuyen con 25.6 MUSD, mientras que las actividades secundarias, como la manufactura de alimentos, confecciones, calzado y procesamiento de productos

agropecuarios, aportan 119.2 MUSD (DANE, 2024b). Esta diversidad económica implica una variedad en la tipología de residuos generados, desde orgánicos y agrícolas hasta industriales y comerciales. La presencia de microempresas industriales añade una dimensión de residuos específicos que requieren tratamiento diferenciado, tales como restos de manufactura y embalaje (DANE, 2021). No obstante, la capacidad de Sincelejo para manejar estos desechos se ve reflejada en su cobertura de servicio de aseo del 100 %, con una frecuencia de recolección de tres veces por semana en zonas residenciales y diaria en zonas comerciales e industriales (SSPD, 2023a). Este nivel de servicio es esencial para prevenir la acumulación de basura, la proliferación de vectores y el deterioro de la calidad de vida urbana.

Los costos asociados a la gestión de residuos en Sincelejo son notables, pero reflejan un compromiso con la eficiencia y la sostenibilidad. El costo de recolección y transporte es de 23.70 USD t⁻¹, la disposición final cuesta 11.12 USD t⁻¹ y el tratamiento de lixiviados se valora en 0.25 USD t⁻¹. Estos costos se traducen en un gasto anual de 9.3 MUSD para el servicio de aseo, de los cuales el 80 % es cubierto por los suscriptores y el 20 % es subsidiado, demostrando un equilibrio financiero que aporta a la sostenibilidad del servicio (E.S.P., 2023). Este modelo financiero permite a Sincelejo mantener una infraestructura estable y mejorar continuamente sus prácticas de gestión de RSM. Además, el subsidio promedio del 20 % asegura que incluso las poblaciones más vulnerables tengan acceso a un servicio de recolección adecuado, mitigando riesgos sanitarios y ambientales.

Por otro lado, la Figura 5.1 muestra que el residuo que se genera en mayor cantidad es el papel y cartón con una participación del 51.03 % del total reciclado y 4.30 % del total dispuesto de Sincelejo, seguido del plástico con una participación del total reciclado y total dispuesto del 36.31 % y 15.87 %, respectivamente. No obstante, el 92 % del papel y cartón son reciclados, al igual que el 70 % del plástico. Además, la fracción orgánica representa cerca del 31.8 % del total que se dispone en la ciudad, mientras que solo el 3.5 % de los RSM de poda y jardín generados son aprovechados mediante compostaje.

Notablemente, la fracción orgánica se desaprovecha en su totalidad, lo que permite que tecnologías como la digestión anaerobia puedan presentarse como candidatas preliminares para la mejora del sistema de manejo de estos residuos. Además, la fracción de poda y jardín representa una parte importante del total dispuesto en relleno sanitario. Esta fracción, permite considerar tecnologías como la gasificación o pirólisis, aunque el proceso de separación de estas fracciones puede decantar el proceso de selección en una decisión más cercana al de relleno sanitario con captura de biogás, donde la separación de las fracciones es prácticamente nula, y su menor costo de inversión la resaltan como una alternativa más práctica que las otras discutidas en este estudio.




Figura 5.1: Tratamiento de los RSM en Sincelejo por categoría (2022). Fuente de los datos: Alcaldía de Sincelejo (2022) y SSPD (2023b, 2023c)

5.2.2. Composición de los RSM

Los resultados de la caracterización categórica evidencian que la fracción orgánica representa la mayor participación de los RSM vertidos en el relleno sanitario de la ciudad de estudio, como se muestra en la [Figura 5.2](#). Mientras que, el conjunto de la fracción orgánica, poda y jardín, y papel y cartón, suman cerca del 70 % de los RSM que son confinados en el sitio de disposición final. Esto permite destacar la importancia de aplicar tecnologías de valorización energética de estos residuos, cuyo potencial de valorización podría reducir la dependencia de este tipo de tratamiento convencional de forma apreciable. No obstante, otras fracciones, como el plástico, aún representan oportunidades de negocio que pueden complementar la sostenibilidad de las alternativas de conversión de RSMaE. Por otro lado, la [Tabla 5.1](#) muestra el resultado de la caracterización fisicoquímica de los RSM de la ciudad de estudio, obtenidos en laboratorio.




Figura 5.2: Composición categórica promedio de los RSM dispuestos en el Relleno Sanitario El Oasis de Sincelejo (2022). Fuente de los datos: Alcaldía de Sincelejo (2022)

Tabla 5.1: Composición fisicoquímica de los RSM de la ciudad de estudio.

Composición	Orgánicos (f_o)	Poda y jardín (f_{pj})	Papel y Cartón (f_{pc})	Lignocelulósicos ($f_{pj} + f_{pc}$)	Lignocelulósicos y orgánicos ($f_o + f_{pj} + f_{pc}$)
Análisis proximal (%bs.)					
Materia Volátil	77.82	69.23	83.32	71.53	74.96
Carbono Fijo	13.37	15.04	4.63	13.34	13.36
Cenizas	8.81	15.73	12.05	15.13	11.68
Análisis elemental (%bs. lce.)					
Carbono	37.63	38.86	39.31	38.93	38.22
Hidrógeno	5.64	5.35	5.24	5.33	5.50
Oxígeno	53.36	53.79	55.11	54.00	53.65
Nitrógeno	2.62	2.00	0.34	1.73	2.22
Azufre	0.75	-	-	-	0.41
Poder calorífico (MJ kg ⁻¹)					
Superior	13.09	15.77	15.83	15.78	14.31
Inferior	12.06	14.87	14.93	14.88	13.34

La [Tabla 5.1](#) revela información crucial para el análisis del caso de estudio. En el contexto de la DA, la alta proporción de materia volátil presente en las fracciones orgánicas (f_o) y poda y jardín (f_{pj}) resalta su potencial para la generación de biogás. No obstante, el contenido de lignocelulósicos, aunque menor, podría requerir pretratamientos para optimizar la degradación y maximizar el rendimiento energético. La baja proporción de cenizas en estas fracciones es también un factor favorable para la DA, minimizando la acumulación de sólidos inertes en el digestor.

Por otro lado, la GAS encuentra en el papel y cartón (f_{pc}) una materia prima interesante debido a su alto contenido de carbono fijo, esencial para la producción de gas de síntesis, pero el elevado contenido de cenizas en esta fracción, así como en la lignocelulósica (f_l), representa un desafío técnico que podría llevar a la formación de escorias y obstrucción de equipos. La mezcla de lignocelulósicos y orgánicos ($f_l + f_o$) se presenta como una alternativa prometedora, equilibrando un adecuado contenido de carbono fijo con un nivel moderado de cenizas. En cuanto a la INC, el alto poder calorífico de todas las fracciones, especialmente en papel y cartón, y en la mezcla lignocelulósicos y orgánicos, las convierte en candidatas atractivas para esta tecnología, aunque el contenido de cenizas sigue siendo un factor a considerar para evitar problemas operativos y ambientales. Finalmente, el RSCB se presenta como una opción viable para todas las fracciones, aunque con diferente potencial de generación. La fracción orgánica, rica en materia volátil, lideraría la producción de biogás, seguida de poda y jardín. La captura y aprovechamiento de este biogás podrían contribuir a la valorización energética de los RSM de manera complementaria a otras tecnologías.

5.2.3. Proyección de TSRSM

Las fases de recopilación de la información relevante de la disposición de RSM en la ciudad de Sincelejo reveló que existen brechas que impiden la estimación de pronósticos de forma práctica. Se evidenció que la SSPD dispone de las principales bases de datos de interés para el caso de estudio. No obstante, la información que se reporta en estos repositorios públicos requiere de la aplicación de métodos de limpieza y depuración para su uso en algoritmos propios del análisis de series de tiempo. La [Tabla 5.2](#) muestra las principales propiedades de las series de tiempo obtenidas para el caso de estudio, incluyendo algunos posibles predictores de la TDRSM, relacionando las fuentes públicas de acceso abierto empleadas para consultar los datos históricos de cada variable.

Tabla 5.2: Resumen de series de tiempo obtenidas para Sincelejo

Variable ^a	Unidad	Tipo	Periodicidad	Rango	Fuente
TDRSM	t	Respuesta	1M	2006 ago.–2023 dic.	SSPD (2024)
TDRSM	t	Respuesta	1Y	1998–2006	INTERASEO S.A.E.S.P. y CAEMA (2012)
POBU	hab	Predictor	12M	1985 jun.–2035 jun.	DANE (2018)
POBR	hab	Predictor	12M	1985 jun.–2035 jun.	DANE (2018)
PIBS	COP	Predictor	1Y	1980–2023	DANE (2024b)
ISE	-	Indicador	1M	2005 ene.–2023 dic.	DANE (2024a)

^a TDRSM: Tasas de disposición de RSM; POBU: Población urbana; POBR: Población Rural; PIBS: Producto interno bruto de Sucre; ISE: Indicador de Seguimiento a la Economía

La [Tabla 5.2](#) revela que la variable respuesta se encuentra representada por dos conjuntos de datos con frecuencias (anual y mensual) y dominios temporales diferentes. Esto genera la necesidad de aplicar el método de desagregación temporal desarrollado en un capítulo anterior (ver, [Capítulo 3](#)), de tal forma que pueda una sola serie temporal en una misma frecuencia, de preferencia mensual –debido a la naturaleza de la generación y/o disposición de los RSM. Por otro lado, las variables obtenidas como posibles predictores, resultan ser factores socioeconómicos que influyen la variable respuesta. No obstante, la limitación de accesibilidad de los datos permitió obtener la series de tiempo del PIB de Sucre (departamento del cual Sincelejo es la capital), en lugar de los datos de la ciudad de estudio de forma específica. Además, el ISE es una medida del comportamiento de la economía nacional, la cual, en mayor o menor medida, afecta a nivel municipal la TDRSM. Estas variables deben ser tratadas mediante los

métodos estadísticos descritos anteriormente para establecer el valor de significancia de estas como predictores apropiados para la TDRSM. La [Figura 5.3](#) nos permite analizar visualmente las series temporales recopiladas y curadas, con lo cual es posible observar el comportamiento histórico de las variables estudiadas para el caso de aplicación.




Figura 5.3: Series de tiempo obtenidas para el caso de estudio de la ciudad de Sincelejo.

Las series temporales que muestra la [Figura 5.3](#), evidencian que la serie TDRSM presenta una tendencia de incremento positiva, aunque la varianza en su componente estacional resulta en patrones menos sostenidos. Esto se puede contrastar con la serie PIB (Sucre), la cual muestra patrones más definidos a lo largo de la serie, además de la tendencia positiva. Por otro lado, las series temporales de la población urbana y rural evidencian que el comportamiento de la variable respuesta no presenta comportamiento estacional (como se esperaba), mientras que se notan cambios en su tendencia alrededor de los años 2018 y 2021, debido en gran medida a la inmigración extranjera agravada por las condiciones socioeconómicas de países vecinos y luego por la pandemia del COVID 19.

La [Tabla 5.3](#) muestra el resultado de las pruebas iniciales aplicadas a las series para estimar sus características principales, lo cual representa información relevante con significancia estadística de las series temporales estudiadas.

Tabla 5.3: Análisis de las características de las series de tiempo del caso de estudio.

Variable	F_S	λ -Guerrero	Prueba de KPSS	Prueba de Ljung-Box	Entropía espectral
TDRSM	0.73	-0.90	0.01*	<0.0001***	0.41
POBR	0.00	-0.90	0.01*	<0.0001***	0.23
POBU	0.00	-0.90	0.01*	<0.0001***	0.19
PIBS	0.87	0.36	0.01*	<0.0001***	0.25

Códigos de Significancia: *, **, y *** indican el rechazo de la hipótesis nula a un nivel de significancia de 5 %, 1 % y 0.1 %.

En primer lugar, las series TDRSM y PIBS presentan un fuerte componente estacional, lo que implica que su tratamiento a nivel de ajuste a un modelo debe contemplar esta característica. Por otro lado, los valores de λ -Guerrero evidencian que la serie PIBS presenta un valor, aunque relativamente bajo, requerido para estabilizar la varianza a lo largo de la serie, mientras que las demás series presentan valores negativos muy cercanos al -1, lo que indica que es muy probable requerir alguna transformación de los datos de manera previa a la aplicación de métodos de análisis de series de tiempo. Adicionalmente, la prueba KPSS demostró con una significancia estadística del 1 % que todas las series son no estacionarias, lo que concuerda con el resultado de la prueba de Ljung-Box, con el cual se demuestra que las series no se comportan como ruido blanco. Finalmente, los valores de la entropía espectral de Shannon revelan que la serie TDRSM es la de mayor complejidad de pronóstico, mientras que los predictores presentaron valores menores, lo que implica que la escogencia de los predictores resulta apropiada al menos en términos del manejo de la complejidad proporcional de aplicación de métodos de pronóstico (i.e., predecir una variable de alta complejidad de pronóstico en función de otra variable de baja complejidad de pronóstico). Para esto, se requiere conocer información adicional de la relación de estos predictores con la variable respuesta. En ese sentido, la [Figura 5.4](#) revela que entre todas las series estudiadas se presentan altos coeficientes de correlación lineal, a pesar de que el comportamiento de sus distribuciones individuales se aleje de la normalidad en casos como el de POBR. Esto permite establecer un nivel mayor de confianza para el empleo de estos predictores en los métodos de análisis de series de tiempo con el objetivo de pronosticar la variable TDRSM.

Por otra parte, la sola correlación lineal entre estas variables no implica por sí sola que sean adecuadas para ser empleadas como predictores. En ese orden, la [Tabla 5.4](#) muestra el resultado de las pruebas de Johansen y Granger aplicadas a las series temporales estudiadas evidenciando, con rigor estadístico la presencia de relaciones de cointegración y/o causalidad entre las combinaciones pareadas.




Figura 5.4: Comparaciones pareadas entre las series de tiempo estudiadas.

Tabla 5.4: Resultados de las pruebas de cointegración y causalidad de las series de tiempo estudiadas.

Relación $Y_t - X_t$	Cointegración		Causalidad de Granger (valor-p)			
			$X_t \rightarrow Y_t$		$Y_t \rightarrow X_t$	
	J_{Trace}	$J_{\text{máx}}$	ST	LT	ST	LT
TDRSM-POBR	20.08*	10.51	0.0359*	0.0990	0.1909	0.0251*
TDRSM-POBU	37.2**	18.22*	0.0004***	0.1537	0.0396*	0.0070**
TDRSM-PIBS	14.05	10.09	0.0012**	0.0361*	0.0057**	0.0629
POBR-POBU	335.93**	23.69**	0.0002***	<0.0001***	0.0013**	<0.0001***
POBR-PIBS	15.95	13.57	0.4929	0.3830	<0.0001***	<0.0001***
POBU-PIBS	16.83	11.65	<0.0001***	0.0265*	<0.0001***	<0.0001***

Códigos de Significancia: *, **, y *** indican el rechazo de la hipótesis nula a un nivel de significancia de 5 %, 1 % y 0.1 %.

Los resultados mostrados en la [Tabla 5.4](#) sugieren que las comparaciones pareadas que se encuentran cointegradas son TDRSM y POBU, y POBR y POBU, mientras que existe una relación de causalidad a corto plazo de POBU hacia TDRSM bajo una alta confianza estadística (99.9 %). Esto permite establecer que el predictor apropiado para la variable TDRSM es POBU, entre todas las series de tiempo exógenas analizadas. Por otro lado, la [Tabla 5.5](#) muestra el desempeño de los modelos de pronóstico analizados en cada una de las etapas del proceso.

Tabla 5.5: Resultado de las fases de entrenamiento y validación de diferentes estructuras de modelos de análisis de series de tiempo.

Variable	Modelo	Estructura	Conjunto	MAPE	LB (p-valor)
POBU	.arima=SARIMA(0,2,0)(1,0,1)[12]	POBU	T	<0.01	1.0000
POBU	.ets=ETS(M,Ad,N)	POBU $\sim T(t)$	T	<0.01	0.1533
POBU	.hybrid=2/3*.arima+1/3*.ets	-	T	<0.01	1.0000
POBU	.arima	POBU	h	0.73	-
POBU	.ets	POBU $\sim T(t)$	h	1.42	-
POBU	.hybrid	-	h	0.04	-
POBU	.hybrid	-	$T + h$	<0.01	1.0000
TDRSM	.arima0=SARIMAX(3,0,2)(1,1,0)[12,1]	log(TDRSM) $\sim$ POBU	T	2.77	0.1110
TDRSM	.arima1=SARIMAX(1,0,1)(2,0,0)[12,1]	log(TDRSM) $\sim$ POBU + $T(t)$	T	2.97	0.0379*
TDRSM	.arima2=SARIMAX(2,1,3)(1,0,0)[12,1]	log(TDRSM) $\sim$ POBU + $S(t)$	T	2.76	0.2350
TDRSM	.arima3=SARIMAX(1,0,1)(1,0,2)[12,1]	log(TDRSM) $\sim$ POBU + $T(t)$ + $S(t)$	T	2.76	0.0043*
TDRSM	.arima0	log(TDRSM) $\sim$ POBU	h	4.86	-
TDRSM	.arima2	log(TDRSM) $\sim$ POBU + $S(t)$	h	5.29	-
TDRSM	.arima0	log(TDRSM) $\sim$ POBU	$T + h$	3.10	0.0510
TDRSM	.arima2	log(TDRSM) $\sim$ POBU + $S(t)$	$T + h$	2.86	0.2636

Códigos de Significancia: *, **, y *** indican el rechazo de la hipótesis nula a un nivel de significancia de 5 %, 1 % y 0.1 %.

Los resultados de la [Tabla 5.5](#) revelan que, entre todos los modelos establecidos para la variable POBU, el enfoque híbrido (i.e., una combinación entre los modelos ARIMA y ETS), fue el que demostró mejor desempeño estadístico, logrando el menor MAPE en la fase de validación. Además, la prueba de los residuales se cumplió tanto en el conjunto de entrenamiento como en el ajuste final bajo la totalidad del set de datos. Esto permite confirmar que el modelo propuesto puede ser apropiado para obtener un pronóstico confiable de la variable POBU.

Por otro lado, los resultados del ajuste de la variable TDRSM muestran que la estructura de mejor desempeño en el conjunto de entrenamiento es .arima3, la cual considera tanto la variable exógena POBU como los componentes de tendencia y estacionalidad interpretados como variables endógenas. Además, el desempeño estadístico de este modelo se asemeja al modelo .arima2, el cual, a diferencia del modelo .arima3, no presenta dentro de su estructura el componente de tendencia como variable endógena. No obstante, entre las estructuras propuestas, solo los modelos .arima0 y .arima2 cumplen con la prueba de ruido blanco de los residuales, lo que se traduce en el descarte de los modelos .arima1 y .arima3 (i.e., sus residuales no se comportan como ruido blanco). Adicionalmente, los modelos .arima0 y .arima2 presentaron resultados positivos bajo el conjunto de validación, con diferencias menores al 9 % entre sus MAPE, lo que no permite descartarlos entre ellos. Adicionalmente, usando el conjunto de datos completos (i.e., entrenamiento y validación), el mejor desempeño se encontró en el modelo .arima2, con un MAPE del 8.4 % menor que el de .arima0, y con un valor-p de la prueba de ruido blanco mucho más alejada del valor de rechazo de 0.05.

La [Figura 5.5](#) revela un incremento exponencial en la proyección de la generación de residuos entre 2025 y 2050, impulsado principalmente por el crecimiento proyectado de la población urbana. Este aumento, que alcanza una proyección del 170 % para el año final del análisis, resalta la urgente necesidad de implementar estrategias efectivas para el aprovechamiento y valorización energética de los residuos. Es importante destacar que este análisis no considera explícitamente la influencia de variables económicas clave, como el Producto Interno Bruto de la ciudad de estudio, u otros indicadores económicos relevantes, lo cual podría enriquecer la comprensión de la dinámica de generación de residuos.

A pesar de esta limitación, el pronóstico indica un comportamiento multiplicativo en la generación de residuos, lo cual era esperable debido al aumento de la población urbana y la densidad poblacional, junto con la tendencia sostenida de crecimiento económico de la ciudad. Estos factores, que contribuyen a una mayor calidad de vida y capacidad adquisitiva, generan fluctuaciones más pronunciadas en la serie de datos. De no tomarse medidas para abordar este problema, la ciudad de estudio enfrentaría un escenario insostenible en el manejo de los residuos bajo el esquema de tratamiento actual, con implicaciones alarmantes para el medio ambiente y la calidad de vida de la población.




Figura 5.5: Datos históricos y pronosticados de las TDRSM de Sincelejo usando un modelo SARIMAX(2,1,3)(1,0,0)[12,1].

5.3. Clasificación de alternativas

La [Figura 5.6](#) muestra los resultados del desempeño de las diferentes alternativas evaluadas bajo los criterios establecidos en función de diferentes escalas. Cada escala representa un año específico de la proyección de las TDRSM considerado para establecer el tamaño del proyecto y su capacidad instalada inicial: Escala 1: año inicial de vida del proyecto (2025), Escala 2: año medio de vida del proyecto (2037); Escala 3: último año de vida del proyecto (2044). En el caso de que la Escala 1, los proyectos consideraron que una capacidad instalada de la planta igual al primer año de operación y constante durante los siguientes años del proyecto; para la Escala 2, los proyectos consideran una capacidad instalada inicial igual al año medio de evaluación del proyecto, de tal forma que el primer año de operación reciben menor cantidad de RSM de las que se pueden procesar, y esta capacidad aumenta en el tiempo de evaluación hasta el año de la Escala

2, luego permanece constante los años siguientes; finalmente la Escala 3 es similar a la Escala 2, con la diferencia de que el tamaño inicial de la planta considera el proyectado para el último año de análisis de los proyectos, lo que implica que solo en este último año es cuando la planta operaría a su máxima capacidad.




Figura 5.6: Influencia de la escala de procesamiento sobre el desempeño de los indicadores de la matriz de decisión.

Un análisis de la [Figura 5.6](#) revela el comportamiento de los criterios a través de las diferentes escalas de estudio. En primero lugar, para los criterios técnicos, se observa que la capacidad instalada (CI) y la humedad máxima admitida (MM) varían notablemente entre las tecnologías. RSCB muestra consistentemente la mayor capacidad instalada, aumentando notablemente desde la Escala 1 hasta la Escala 3, lo que indica su fuerte escalabilidad y adecuación para el procesamiento de grandes volúmenes de RSM. GAS e INC comienzan con una CI mínima en la Escala 1 pero demuestran mejoras considerables en escalas superiores, sugiriendo su potencial para ampliarse eficazmente. La tasa de aprovechamiento de RSM (TA) se mantiene relativamente estable en todas las escalas para todas las tecnologías, con RSCB manteniendo una ligera ventaja sobre las demás. En términos de humedad máxima admitida (MM), GAS exhibe una tolerancia inferior,

esta tecnología requiere un mayor porcentaje de remoción de humedad para su operación, manteniendo los valores más altos en todas las escalas, contrario a la DA que admite un mayor contenido de humedad en los RSM. El tiempo de mantenimiento (FM) varía ligeramente, pero RSCB requiere consistentemente menos mantenimiento en todas las escalas, mejorando su eficiencia operativa, mientras que INC y DA pueden incurrir en mayor tiempo de inactividad debido a necesidades de mantenimiento incrementadas en escalas mayores.

En cuanto a los criterios económicos, las tecnologías muestran diferentes grados de rentabilidad y viabilidad económica al escalarse. RSCB demuestra un sólido desempeño económico en todas las escalas, con su VPN manteniéndose alto y su TIR liderando consistentemente, lo que lo convierte en una opción atractiva para inversiones a gran escala. GAS muestra una disminución en los indicadores económicos en escalas superiores, sugiriendo rendimientos decrecientes y posibles desafíos financieros cuando se implementa en una escala mayor. INC mantiene un rendimiento económico relativamente estable a través de las escalas, ofreciendo un equilibrio entre rentabilidad y escalabilidad. DA presenta una viabilidad económica menor, con incrementos modestos en los indicadores económicos que pueden no ser suficientes para justificar una implementación a gran escala sin incentivos financieros adicionales o integración en una estrategia de gestión de residuos más amplia.

En términos de criterios energéticos, que se enfocan en las contribuciones de las tecnologías a la generación de energía y al cumplimiento de las demandas energéticas locales, GAS y INC destacan, especialmente al aumentar la escala. GAS mejora sustancialmente la generación eléctrica local per cápita (Epc), duplicando aproximadamente su contribución desde la Escala 1 hasta la Escala 3, y aumenta su participación en la demanda eléctrica local (CL), alcanzando valores notablemente mayores en la escala más grande. Esto indica que GAS es altamente efectivo en convertir RSM en energía utilizable, apoyando así más sustancialmente las necesidades energéticas locales en escalas mayores. INC también muestra tendencias positivas, con mejoras en Epc y CL a medida que se incrementa la escala, aunque no tan pronunciadas como en GAS. DA y RSCB contribuyen menos a la generación de energía, con sus valores de Epc y CL permaneciendo relativamente bajos en todas las escalas, lo que sugiere que sus beneficios principales pueden estar en otros aspectos, como la reducción del volumen de residuos o factores económicos, más que en la producción de energía.

Al analizar los criterios ambientales a través de las escalas, particularmente el potencial de reducción de emisiones de gases de efecto invernadero (PRGEI) y el potencial evitable de emisiones mediante plantas térmicas (PEGEI), GAS ofrece consistentemente los mayores beneficios ambientales, que se hacen más pronunciados en escalas mayores. El PRGEI para GAS aumenta aproximadamente al doble desde la Escala 1 hasta la Escala 3, indicando su capacidad mejorada para mitigar los impactos del cambio climático a medida que procesa más RSM. De manera similar, los valores de PEGEI para GAS

incrementan con la escala, subrayando su efectividad en reemplazar fuentes de energía tradicionales más contaminantes. INC también contribuye positivamente a los objetivos ambientales, con mejoras en ambos indicadores en escalas superiores, aunque no tan marcadas como en GAS. En contraste, RSCB muestra beneficios ambientales mínimos en estos criterios a través de todas las escalas, sugiriendo que, aunque puede sobresalir económica– y técnicamente, su impacto ambiental es menos favorable. DA mantiene beneficios ambientales bajos pero consistentes, que pueden ser potenciados cuando se combina con otras prácticas de gestión de residuos que priorizan la sostenibilidad y la reducción de emisiones.

Por otro lado, la [Figura 5.7](#) muestra los pesos estimados de subcriterios mediante la aplicación del método ENTROPY a la matriz de decisión normalizada donde: .CI: capacidad instalada; .CL: contribución a la demanda eléctrica local; .Epc: generación eléctrica per cápita local; .FM: porcentaje de tiempo del año invertido en actividades de mantenimiento; .IR: índice de rentabilidad; .MM: humedad máxima admitida; .PA: potencia eléctrica neta admitida por cantidad de RSM; .PEGEI: potencial evitable de emisiones de gases de efecto invernadero mediante plantas térmicas de generación de electricidad; .PRGEI: potencial de reducción de emisión de gases de efecto invernadero; .RBC: relación beneficio costo; .TA: tasa de aprovechamiento de RSM de la tecnología; .TIR: tasa interna de retorno; .VPN: valor presente neto.

Los resultados de la [Figura 5.7](#) revelan, de manera general, que los subcriterios de mayor relevancia para la selección de las alternativas evaluadas, sobre las condiciones de la ciudad de estudio, son la capacidad instalada y los potenciales de reducción y evitable de emisiones de GEI, seguidos de dos subcriterios energéticos relacionados con capacidad de transformación de energía y la generación eléctrica per cápita local. Esto permite establecer que, entre las diferentes alternativas, los valores con mayor dispersión se encuentran en estos subcriterios, lo que implica que su importancia relativa entre el conjunto total de indicadores es mayor. No obstante, esto no implica que estos criterios con mayor peso relativo sean los de mayor relevancia en todos los casos de estudio, sino que, para las condiciones específicas analizadas bajo las limitaciones o consideraciones establecidas de manera previa al análisis, el método ENTROPY priorizó estos criterios por ser los que representan las mayores diferencias entre las características de cada tecnología.

Analizar detenidamente los criterios, permite observar que el criterio CI (Capacidad Instalada) obtiene el peso más elevado en todas las escalas, representando aproximadamente un tercio del peso total. Esto significa que la capacidad instalada es el factor más influyente en la toma de decisiones, resaltando la necesidad de seleccionar tecnologías que puedan procesar eficientemente grandes volúmenes de residuos. La consistencia de este peso a través de las tres escalas subraya su importancia estratégica sin importar el tamaño del proyecto. Por otro lado, los criterios ambientales, como el PRGEI (Potencial de Reducción de Emisiones de Gases de Efecto Invernadero) y el PEGEI (Potencial




Figura 5.7: Pesos estimados de subcriterios mediante el método ENTROPY.

Evitable de Emisiones de Gases de Efecto Invernadero mediante Plantas Térmicas de Generación de Electricidad), también reciben pesos relevantes, sumando juntos más de una quinta parte del peso total en cada escala. Esto indica que los beneficios ambientales son cruciales en la evaluación de las tecnologías, y su importancia aumenta ligeramente con la escala, reflejando una mayor preocupación por el impacto ambiental en proyectos de mayor envergadura. Asimismo, el criterio Epc (Generación Eléctrica per cápita local) tiene un peso considerable que incrementa gradualmente con la escala. Esto resalta la relevancia de la contribución de las tecnologías a la generación de energía para la población local. Un aumento de alrededor del 7 % en su peso desde la Escala 1 hasta la Escala 3 sugiere una creciente valoración de este criterio en proyectos más grandes.

En contraste, los criterios como el VPN y el PA (Potencia Eléctrica Neta admitida por cantidad de RSM) tienen pesos moderados y relativamente estables a través de las escalas. Esto implica que, aunque la rentabilidad y la eficiencia energética son importantes, no son tan decisivos como los criterios técnicos y ambientales en la selección de la tecnología óptima. Adicionalmente, criterios operativos y de mantenimiento como la TA (Tasa de Aprovechamiento de RSM), el FM (Porcentaje de tiempo en mantenimiento) y la TIR

obtienen pesos muy bajos, representando menos del 1 % del peso total cada uno. Esto sugiere que estos factores tienen una influencia mínima en la decisión final, posiblemente debido a que presentan poca variación entre las tecnologías o porque se consideran menos críticos en comparación con otros criterios.

La [Figura 5.8](#) muestra el resultado de la clasificación de las alternativas evaluadas en la ciudad de estudio.




Figura 5.8: Coeficiente de cercanía de las alternativas tecnológicas para diferentes escalas de tamaño de la planta.

Los resultados de la [Figura 5.8](#) revelan que, bajo las condiciones de estudio, la alternativa más favorecida por los criterios e indicadores seleccionados para la ciudad de Sincelejo es RSCB, seguido de la GAS. El RSCB se presenta como una opción atractiva debido a su relativa simplicidad tecnológica y menores costos de inversión inicial. Su capacidad para capturar y aprovechar el biogás generado por la descomposición de los residuos ofrece una fuente adicional de energía renovable, lo que puede resultar beneficioso para municipios con recursos energéticos limitados como Sincelejo. Además, el RSCB puede adaptarse a diferentes escalas de operación, lo que lo hace adecuado para municipios pequeños con volúmenes de residuos más bajos. Sin embargo, es importante

considerar que la eficiencia de la captura de biogás y la calidad de este pueden verse afectadas por factores como la composición de los residuos y las condiciones climáticas. Asimismo, se observa que la influencia de la escala sobre la alternativa de valorización de RSM no es considerable para RSCB, en tanto que, esta ruta es la más favorable en cada escala sin diferencias importantes entre sí.

Por otro lado, la GAS, aunque tecnológicamente más compleja y costosa, ofrece un mayor potencial de valorización energética de los residuos. La conversión de los RSM en gas sintético permite su utilización como combustible para generar electricidad o calor, lo que puede contribuir a la autonomía energética del municipio. No obstante, la implementación de la gasificación requiere una inversión relativamente alta en infraestructura y personal capacitado, lo que puede resultar un desafío para municipios pequeños con recursos financieros y técnicos limitados. Además, la gasificación puede generar subproductos como cenizas que requieren un tratamiento adecuado para evitar impactos ambientales negativos. Además, el efecto sobre el coeficiente de cercanía a diferentes escalas es en la GAS es prácticamente invariable, mostrando así que la escala no coadyuva como influencia directa sobre la selección de la alternativa tecnológica para los RSM en Sincelejo.

En el caso de la DA, se muestra con el coeficiente de cercanía más bajo para los criterios seleccionados en el estudio. Lo anterior, revela que esta tecnología es la menos atractiva para implementarla como ruta de aprovechamiento de RSM en Sincelejo-Colombia. Si bien, los resultados muestran que la DA es más promisoría para su implementación a mayor escala respecto de las escalas pequeñas, su coeficiente de cercanía es el más bajo comparado con las tecnologías de INC, GAS y RSCB.

La alternativa con mejor desempeño (RSCB) manifiesta una acertada relación de pertinencia al contrastarse con casos reales como la financiación del proyecto “*INTERASEO Landfill Gas Mitigation Project*” (INTERASEO S.A.E.S.P. & CAEMA, 2012), aprobado por el programa para el cambio climático de las Naciones Unidas (UNFCCC), el cual contempla dentro de su alcance el relleno sanitario El Oasis que presta el servicio de disposición de los RSM generados en Sincelejo. Este proyecto no logró establecer una sostenibilidad económica para las intervenciones que se propusieron en el relleno sanitario, el cual consistía únicamente en la quema del metano generado por el sitio de disposición final, aun así, contó con aprobación por su amplio desempeño ambiental, demostrando que un único criterio, como el de rentabilidad económica, no es suficiente para tomar una decisión de inversión. Esto resalta la relevancia de la herramienta desarrollada, la cual integra múltiples dimensiones de la sostenibilidad para elegir una alternativa con mejor desempeño bajo múltiples criterios apropiados.

En términos de prioridades de la administración pública, la elección entre RSCB y GAS dependerá de los objetivos específicos del municipio. Si la prioridad es la gestión eficiente de los residuos con un enfoque en la recuperación energética a pequeña escala, el RSCB puede ser la opción más adecuada. Por otro lado, si el municipio

busca maximizar la valorización energética de los residuos y contribuir a la autonomía energética, la GAS puede ser una alternativa a considerar, siempre y cuando se cuente con los recursos necesarios para su implementación y operación. Adicionalmente, la necesidad de talento humano especializado podrá jugar un papel fundamental en esta hipotética elección.

5.4. Conclusiones del capítulo

En este capítulo se analizaron las condiciones y recursos de la ciudad de Sincelejo con el objetivo de establecer la mejor opción de valorización energética de los RSM que se disponen de forma convencional en un relleno sanitario que ha consumido la totalidad de su capacidad volumétrica de diseño. Además, este análisis se presenta como una aplicación de la herramienta tecnológica desarrollada y cuya descripción se abordó en capítulos anteriores.

La ciudad de Sincelejo presenta una infraestructura de manejo y gestión de aseo deficiente y limitada en cuanto a su capacidad, aunque se cumple la mayoría de las disposiciones legales de las autoridades sanitarias. No obstante, la caracterización de los RSM que ingresan al relleno sanitario no se reporta de forma periódica, sino que se cuenta con datos antiguos que han sido aceptados al momento de estructurar o actualizar los más recientes planes de manejo de estos residuos. Además, este municipio no presenta planes estratégicos con impacto real y eficiente sobre las conductas de separación en la fuente. Esto ha llevado a que una mayoritaria cantidad de RSM aprovechable termine dispuesta en el relleno sanitario. No obstante, las características físicas y químicas de estos residuos revelan que existe un gran potencial de valorización energética de esta biomasa residual, lo que permitiría un amplio espectro de efectos positivos sobre la población a nivel económico, ambiental y energético.

Se obtuvieron proyecciones de las TDRSM en función de una variable exógena representativa de la población urbana. Los pronósticos apuntan a que las TDRSM actuales se incrementarán un 170 % para 2050. Esto resulta alarmante debido a que, si bien el sistema de manejo actual, con sus limitaciones, logra prestar el servicio en la totalidad de la población, no tiene la capacidad para gestionar el incremento estimado.

El resultado de la evaluación de las diferentes alternativas de valorización energética analizadas reveló que la opción más equilibrada en términos de los criterios estudiados es el RSCB, seguido de la GAS. Debido a su alto potencial técnico, el RSCB permite una mayor tasa de aprovechamiento ya que admite un espectro más amplio de los RSM, mientras que la GAS presenta, entre otros factores, requerimientos específicos que los RSM deben cumplir antes de su admisión en esta ruta. No obstante, la GAS se presenta con un potencial evitable de emisión de GEI apreciablemente superior al de RSCB, pero sus complejidades económicas y operacionales, sus altos requerimientos de inversión inicial, así como su reducida capacidad instalada potencial, causan que sea una alterna-

tiva menos atractiva para ciudades pequeñas como Sincelejo, con relativamente bajas TDRSM y pocos recursos económicos para financiar esta alternativa ambientalmente amigable. Además, la herramienta metodológica posibilitó no solamente analizar y seleccionar la alternativa más pertinente para la ciudad de Sincelejo, sino que permitió observar la influencia de factores externos como el costo de los créditos carbono en la mejora del desempeño integral de la GAS a lo largo del tiempo de operación bajo esta alternativa, lo cual permite visibilizar posibles propuestas para alcanzar viabilidades para esta tecnología en un tiempo futuro, la cual dependerá no solo de su desempeño tecno-energético sino del marco regulatorio y social conexo a estas iniciativas, destacándose así el carácter multidimensional del análisis obtenido con el uso de la herramienta metodológica, y su potencial como recurso en la definición de prospecciones útiles para la toma de decisiones.

Referencias

- Alcaldía de Sincelejo. (2017). REVISIÓN Y ACTUALIZACIÓN PLAN DE GESTIÓN INTEGRAL DE RESIDUOS SOLIDOS –PGIRS–DEL MUNICIPIO DE SINCELEJO. <https://alcaldiadesincelejo.gov.co/Transparencia/Documentos%20PGIRS/Documento%20presentaci%C3%B3n%20PGIRS.pdf>
- Alcaldía de Sincelejo. (2022). Anexo 3. Caracterización de residuos. En *PLAN DE GESTIÓN INTEGRAL DE RESIDUOS SOLIDOS DEL MUNICIPIO DE SINCELEJO, Sucre 2022–2033*. <https://alcaldiadesincelejo.gov.co/Transparencia/PlaneacionGestionControl/Forms/AllItems.aspx>
- DANE. (2018). Proyecciones y retroproyecciones de población. <https://www.dane.gov.co/index.php/estadisticas-por-tema/demografia-y-poblacion/proyecciones-de-poblacion>
- DANE. (2021). *La información del DANE en la toma de decisiones regionales: Sincelejo - Sucre*. <https://www.dane.gov.co/files/investigaciones/planes-departamentos-ciudades/210115-InfoDane-Sincelejo-Sucre.pdf>
- DANE. (2024a). Indicador de Seguimiento a la Economía (ISE). <https://www.dane.gov.co/index.php/estadisticas-por-tema/cuentas-nacionales/indicador-de-seguimiento-a-la-economia-ise>
- DANE. (2024b). PIB por departamento. <https://www.dane.gov.co/index.php/estadisticas-por-tema/cuentas-nacionales/cuentas-nacionales-departamentales>
- E.S.P., I. S. (2023). INFORME DE AUDITORÍA EXTERNA DE GESTIÓN Y RESULTADOS. <https://sincelejo.interaseo.com.co/wp-content/uploads/sites/50/2024/04/INTERASEO-SUCRE-INDICADORES-DE-GESTION-2023.pdf>
- Hyndman, R. (2024). *fpp3: Data for "Forecasting: Principles and Practice" (3rd Edition)* [R package version 1.0.1]. <https://CRAN.R-project.org/package=fpp3>

- INTERASEO S.A.E.S.P. & CAEMA. (2012). INTERASEO landfill gas mitigation project. <https://cdm.unfccc.int/Projects/DB/DNV-CUK1356525322.33/view>
- R Core Team. (2024). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing. Vienna, Austria. <https://www.R-project.org/>
- RStudio Team. (2020). *RStudio: Integrated Development Environment for R*. RStudio, PBC. Boston, MA. <http://www.rstudio.com/>
- SSPD. (2023a). Informe de vigilancia o inspección especial, detallada o concreta INTERASEO S.A.S. E.S.P. <https://www.superservicios.gov.co/sites/default/files/inline-files/Informe-detallado-interaseo-fundacion-2023.pdf>
- SSPD. (2023b). Informe Nacional de Disposición Final de Residuos Sólidos 2022. <https://www.superservicios.gov.co/publicaciones>
- SSPD. (2023c). Informe Sectorial de la Actividad de Aprovechamiento 2022. <https://www.superservicios.gov.co/publicaciones>
- SSPD. (2024). Sistema Único de Información de Servicios Públicos Domiciliarios - SUI de Colombia. <https://sui.superservicios.gov.co/>

Limitaciones Principales

La herramienta metodológica desarrollada presenta limitaciones que deben considerarse antes de su aplicación. Si bien el método de estimación de pesos de los criterios resulta lo suficientemente objetivo, entre las principales limitaciones se encuentra la ausencia de un método que determine de forma específica los criterios que deben ser implementados para un caso de estudio. Además, no cuenta con capacidad de análisis a nivel de ingeniería de detalle, sino que sus resultados pueden ser interpretados a nivel de prefactibilidad. Asimismo, la disponibilidad y calidad de los datos de generación de RSM de una ciudad de estudio limitan la capacidad de la herramienta para ser aplicada. Para el caso de ciudades que no cuenten con datos directos de generación de RSM, se recomienda estudiar la cointegración entre los datos de consumo eléctrico de los hogares correlacionándolos con cifras económicas y poblacional, de tal forma que se logre establecer un patrón de generación de RSM en función del consumo de electricidad, empleando para eso los métodos de desagregación de series de tiempo desarrolladas en este estudio. A un nivel más técnico, el método TOPSIS es sensible a la técnica de normalización utilizada para escalar los datos. Diferentes métodos de normalización pueden llevar a diferentes rankings de alternativas, lo que introduce un grado de incertidumbre en los resultados. Asimismo, la selección del conjunto de alternativas para aplicar la herramienta puede arrojar diferentes resultados a nivel de pesos de los criterios y de clasificación de las alternativas.

La naturaleza del modelo SARIMAX implica la captura de los componentes de la serie de tiempo TDRSM, y obtención de parámetros del modelo con alta rigurosidad estadística. Esto permite que se puedan obtener proyecciones relativamente confiables con escalas de tiempo mayores que las del conjunto de datos usado para entrenar y validar el modelo. No obstante, estas proyecciones consideran que las condiciones causantes del comportamiento de los datos de TDRM perecerán invariables en el tiempo, lo que representa una limitación de esta proyección y todas las que se realicen con cualquier otro modelo, ya que omite el hecho de que las sociedades evolucionan constantemente y que un lapso de 25 años o más es suficiente para moldear la dinámica socioeconómica y alterar el desarrollo tecnológico de cualquier ciudad del mundo.

El método de normalización empleado puede alterar significativamente las escalas internas del algoritmo empleado por el método, lo que podría alterar el resultado final de la evaluación de las alternativas. Asimismo, emplear un conjunto diferente de alternativas puede arrojar resultados dispares con los obtenidos en los evaluados en este estudio. No obstante, el investigador debe establecer la escala de observación sobre la cual realizará las comparaciones entre alternativas para que sus resultados se encuentren correctamente circunscritos al objetivo de su estudio.

Por otro lado, entre las principales capacidades de la herramienta que pueden potenciarse en investigaciones o trabajos futuros se encuentra su adaptación al concepto de superestructura. Esto permitiría, además de estimar la mejor alternativa de forma objetiva, optimizar variables relevantes como el tamaño de una planta mediante la aplicación de funciones objetivo que maximicen la obtención de energía bajo múltiples restricciones. Adicionalmente, los métodos de pronósticos pueden mejorarse en función de mejoras en la capacidad computacional de la cual pueda disponerse, aplicando métodos más robustos de inteligencia artificial, aunque esto implique el manejo de un mayor conjunto de datos. Asimismo, investigaciones futuras orientadas a la integración de esta herramienta con tecnologías IoT podrían mejorar significativamente su desempeño a nivel de despliegue en tiempo real.

Conclusiones Generales

La gestión de RSM es un desafío complejo que requiere un enfoque integral y adaptado a las condiciones locales. Los métodos de toma de decisiones multicriterio (MCDA) han demostrado ser herramientas valiosas para evaluar y seleccionar alternativas de valorización de residuos teniendo en cuenta criterios técnicos, económicos, ambientales y sociales. Sin embargo, es crucial abordar sus limitaciones, como la subjetividad en la ponderación de criterios y la necesidad de datos precisos y actualizados.

Si bien las tecnologías de conversión de residuos en energía (WtE), como la gasificación (GAS), la incineración (INC), la digestión anaeróbica (DA) y los rellenos sanitarios con captura de biogás (RSCB), ofrecen oportunidades prometedoras para abordar los desafíos ambientales y energéticos asociados con los RSM, la elección de la tecnología más adecuada debe basarse en un análisis exhaustivo de la composición de los residuos, la flexibilidad en el aprovechamiento de estos, las condiciones operativas y los objetivos específicos del proyecto en función de las condiciones y recursos de una ciudad de estudio, así como del menor requerimiento en inversión.

La modelización de series temporales, como el modelo SARIMAX, es esencial para comprender los patrones de generación de RSM y realizar pronósticos precisos. Estos pronósticos son fundamentales para planificar y diseñar sistemas de gestión de residuos eficientes y sostenibles que puedan adaptarse a las futuras demandas y tendencias. Sin embargo, ante los vacíos encontrados en la literatura científica y técnica consultada sobre la metodología requerida para implementar estos modelos con la calidad de datos del caso de estudio y las restricciones deseables de confiabilidad del modelo, se desarrolló

un marco metodológico completo para trabajar bajo condiciones de acceso complejo a los datos de generación de RSM, compuesto por métodos ampliamente utilizados a nivel internacional en Machine Learning, así como pruebas estadísticas robustas aplicadas en análisis de series de tiempo, y métodos de desagregación de series de tiempo empleadas por entidades gubernamentales del orden mundial. El modelo SARIMAX obtenido para el caso de estudio demostró con alta confianza estadística que los datos de TDRSM se encuentran íntimamente cointegrados y en una relación de causalidad con los datos de población del municipio estudiado.

La evaluación multicriterio, utilizando métodos como ENTROPY y TOPSIS, permite una evaluación integral y objetiva de las alternativas de WtE. Al considerar una amplia gama de criterios, incluyendo aspectos técnicos, energéticos, económicos, y ambientales, se garantiza una toma de decisiones informada y equilibrada.

El estudio de caso de la ciudad de Sincelejo implicó la necesidad de múltiples habilidades por parte del investigador, desde las empleadas para superar las etapas de recolección de datos, limpieza, filtros de datos atípicos, entre otras, hasta la correcta visualización e interpretación de los resultados, con lo cual se logró establecer estructurar análisis con la calidad requerida por el alcance del estudio. No obstante, los resultados demuestran la aplicabilidad de la herramienta desarrollada para evaluar y seleccionar alternativas de valorización energética de RSM. Los resultados revelan que el RSCB es la opción más equilibrada para esta ciudad, considerando su potencial técnico, ambiental y económico. Sin embargo, la elección final debe adaptarse a las condiciones específicas de cada localidad, así como a la inclusión de otros posibles criterios relevantes (e.g., sociales) en función de la capacidad con la que se cuente para la obtención de datos primarios y/o secundarios.

La herramienta metodológica desarrollada permite realizar análisis de sensibilidad que facilitan la toma de decisiones en función de las condiciones de operación de un municipio, localidad o población objetivo. Lo anterior, funge como un recurso clave no solamente para la evaluación científica del desempeño de rutas tecnológicas de valorización de RSM, sino que posibilita la identificación de horizontes de inversión promisorios para iniciativas empresariales público-privadas y/o actores gubernamentales.

Declaraciones

Financiación Esta investigación contó con financiamiento de la Asignación para la Ciencia, Tecnología e Innovación - ACTEI (antiguo Fondo de Ciencia, Tecnología e Innovación - FCTeI) del Sistema General de Regalías (SGR) de Colombia, a través de los siguientes proyectos:

- “*Formación de Capital Humano de Alto Nivel – Corporación Universidad de la Costa, CUC Nacional*” [BPIN 2019000100034].
- “*Aprovechamiento y Valorización Sostenible de Residuos Sólidos Orgánicos y su Posible Aplicación en Biorrefinerías y Tecnologías de Residuos-a-Energía en el Departamento de Sucre*” [BPIN 2020000100189].

Conflictos de Interés Los autores declaran que no presentan conflictos de interés que sean relevantes para el contenido de este estudio.

Aprobación Ética Este estudio no involucró investigación primaria con participantes humanos o animales, por lo que no requirió aprobación ética.