



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

**Propuesta metodológica basada en redes
neuronales artificiales para la determinación
de la gestión óptima de residuos sólidos
urbanos: aplicación en las localidades de
Suba y Engativá de la ciudad de Bogotá
(Colombia)**

Tesis doctoral
Johanna Karina Solano Meza

Director
Dr. Javier Rodrigo Ilarri

Valencia, abril de 2021

A mi esposo, mi hijo y mi familia, que con su soporte, confianza y amor me han ayudado a alcanzar este sueño académico, profesional y personal.

Resumen

Dentro de las temáticas asociadas al campo de acción de la Ingeniería Ambiental se encuentra la referente a la gestión adecuada de los residuos sólidos que son generados por las comunidades. Los residuos sólidos urbanos (RSU) se han constituido en una de las problemáticas que debe ser atendida por los países de forma prioritaria, dadas las tendencias crecientes en su aumento y para los cuales se requiere la adopción de estrategias que permitan su aprovechamiento y disposición adecuada. Por tanto, las administraciones locales, regionales y nacionales deben tomar decisiones de forma eficiente para que se realice una gestión correcta de estos residuos que tenga presente las particularidades de su región. Dentro de estas particularidades se encuentra, entre otros elementos, la caracterización de la población, la cantidad de RSU generados, el clima, las mejores técnicas y tecnologías disponibles, las tendencias y políticas nacionales, la disponibilidad de recursos económicos, los planes de ordenamiento territorial, la legislación vigente y las características del servicio público de limpieza. Todos estos aspectos pueden influir dentro de la toma de decisiones para cada una de las etapas definidas dentro del proceso de gestión de este tipo de residuos.

En este marco de trabajo, en esta investigación se presenta una metodología para la toma de decisiones relacionada con la gestión de residuos sólidos en grandes ciudades. La investigación se ha desarrollado tomando como referencia la ciudad de Bogotá (Colombia) y, particularmente, dos zonas de esta ciudad llamadas Engativá y Suba (denominadas “localidades” según la división administrativa de la ciudad). En estos emplazamientos se han desarrollado alternativas para la selección de estrategias que permitan la gestión de RSU más adecuada.

La investigación se ha desarrollado en tres fases. En primera instancia, se han analizado las características de la generación de residuos en la ciudad mediante una ruta analítica que integra el análisis espacial junto con el tratamiento estadístico de datos, para evaluar y predecir su comportamiento en cada una de las zonas de Bogotá.

En la segunda parte de la investigación, se realizó el análisis predictivo de la generación de estos residuos a través de tres herramientas de inteligencia artificial: árboles de decisión (*Decision trees*), redes neuronales artificiales (RNA) y máquinas de soporte vectorial (*Support Vector Machines*, MSV).

Como etapa final, se realizó el planteamiento y desarrollo del modelo metodológico, incorporando tanto aspectos predictivos como variables económicas, y se analizó el comportamiento del modelo a través de redes neuronales artificiales de tipo *Long Short Term Memory* (LSTM), foco principal del presente trabajo. De igual forma, dentro de esta última fase se presenta también la revisión del comportamiento del modelo a través de la implementación de máquinas de soporte vectorial, como estrategia comparativa del rendimiento de las RNA frente a otros posibles modelos que pueden implementarse a este tipo de procesos.

Como principal resultado obtenido de la investigación realizada, se concluye que las redes neuronales artificiales constituyen una alternativa viable para el planteamiento de modelos que incluyan todas las etapas de la gestión de los RSU de una ciudad. Aunque estos modelos matemáticos requieren de gran cantidad de datos para minimizar el margen de error de los resultados, con los datos obtenidos para la modelación las RNA se adaptaron de forma apropiada, mostrando un comportamiento adecuado de acuerdo con la metodología planteada. Por otra parte, se ha comprobado que el modelo diseñado se encuentra estructurado de forma que permite la modificación, inclusión, precisión y optimización de la información de forma permanente. Todo ello constituye una gran ventaja, ya que mejora de forma continua la eficiencia de la metodología propuesta. De este modo, la metodología propuesta puede ser aplicada en zonas determinadas de ciudades con características similares, en la medida que los países vayan estableciendo y fortaleciendo sus sistemas de información de forma confiable para así obtener datos más precisos, lo cual es un proceso que Colombia tiene como meta a corto plazo.

Resum

Dins de les temàtiques associades al camp d'acció de l'Enginyeria Ambiental es troba la referent a la gestió adequada dels residus sòlids que són generats per les comunitats. Els residus sòlids urbans (RSU) s'han constituït en una de les problemàtiques que ha de ser atesa pels països de forma prioritària, donades les tendències creixents en el seu augment i per als quals es requereix l'adopció d'estratègies que permeten el seu aprofitament i disposició adequada. És així que les administracions locals, regionals i nacionals han de prendre decisions de manera eficient perquè es realitzi una gestió correcta d'aquests residus tenint present les particularitats de la seva regió, dins de les que es poden trobar la caracterització de la població, la quantitat de RSU generats, el clima, les millors tècniques i tecnologies disponibles, les tendències i polítiques nacionals, la disponibilitat de recursos econòmics, els plans d'ordenament territorial, la legislació vigent, les característiques del servei públic de neteja, entre altres elements, els quals poden influir dins de la presa de decisions per a cadascuna de les etapes definides dins el procés de gestió d'aquest tipus de residus.

És així com es presenta en aquesta investigació una metodologia per a la presa de decisions relacionada amb la gestió de residus sòlids en grans ciutats, prenent com a referència la ciutat de Bogotà (Colòmbia), i particularment dues zones d'aquesta ciutat anomenades Engativá i Suba (denominades "localitats" segons la divisió administrativa de la ciutat), com una alternativa per a la selecció de la millor estratègia que permeti l'adequada gestió de RSU d'aquesta regió.

En primera instància, s'analitza el comportament de la generació de residus de la ciutat a través d'una ruta analítica que integra l'anàlisi espacial juntament amb el tractament

estadístic de dades, per avaluar i predir el comportament de la generació dels RSU a cadascuna de les zones de Bogotá. Com a segona part de la investigació, es va realitzar l'anàlisi predictiva de la generació d'aquests residus a través de tres eines d'intel·ligència artificial, per a això es va incorporar l'aplicació d'arbres de decisió (*Decision trees*), xarxes neuronals artificials (RNA) i màquines de suport vectorial (*Support Vector Machines*, MSV).

Com a etapa final, es va realitzar el plantejament del model metodològic incorporant aspectes predictius així com variables econòmiques, i es va analitzar el comportament d'aquest a través de xarxes neuronals artificials de tipus *Long Short Term Memory* (LSTM), focus principal del present treball. De la mateixa manera, dins d'aquesta última fase es presenta el mateix model, però en aquesta ocasió es va realitzar la revisió del seu comportament a través de la implementació de màquines de suport vectorial, com a estratègia comparativa del rendiment de les RNA enfront d'altres possibles models que poden implementar-se a aquesta mena de processos.

Com a principal resultat obtingut de la investigació realitzada, es conclou que les xarxes neuronals constitueixen una alternativa viable per al plantejament de models que inclouen totes les etapes de la gestió dels RSU d'una ciutat. Encara que aquests models matemàtics requereixen de gran quantitat de dades per a minimitzar el marge d'error dels resultats, amb les dades obtingudes per a la modelació les RNA es van adaptar de manera apropiada mostrant un acompliment adequat d'acord amb la metodologia plantejada. D'altra banda, s'ha comprovat que el model dissenyat es troba estructurat de manera que permet la modificació, inclusió, precisió i optimització de la informació de forma permanent, la qual cosa constitueix en un avantatge, ja que permet de forma contínua millorar la eficiència de la metodologia proposada i aplicar-la en una zona determinada d'una ciutat amb característiques similars en la mesura que els països van establir i enfortint els seus sistemes d'informació de forma fiable per així obtenir dades més precises, la qual cosa és un procés que Colòmbia té com a meta de curt termini.

Abstract

Ensuring the proper management of solid waste generated by communities is included among the topics associated within the scope of environmental engineering. Municipal solid waste (MSW) has become one of the problems that countries must place a priority on addressing, given the trends of its increasing generation. Strategies must be adopted that facilitate MSW use and its proper disposal. Therefore, local, regional and national governments must make decisions in an efficient manner, taking into account the particularities of their region, in order to correctly manage this waste. These particularities include the characterization of their population, amount of MSW generated, climate, best available techniques and technologies, national guidelines and policies, availability of economic resources, land use plans, current legislation, characteristics of the public sanitation service, among other components. These factors can influence decision-making in each defined stage in the process of MSW management.

Accordingly, this research study presents a methodology for decision-making regarding solid waste management in large cities. The city of Bogotá (Colombia) is used as a reference, specifically, two areas of the city named Engativá and Suba Bogotá (called “localities”, which are based on the administrative division of the city). The goal of the methodology is to determine an alternative to select the best strategy to facilitate proper MSW management in the region.

First, the behavior of waste generation in the city was analyzed through an analytical approach that integrates spatial analysis with statistical data processing to evaluate and forecast the behavior of MSW generation in each area of Bogotá. The second part of the study was a predictive analysis of MSW generation which employed the following three

artificial intelligence tools: decision trees, artificial neural networks (ANN), and support-vector machines (MSV).

Lastly, the methodological model was proposed, which incorporated predictive aspects as well as economic variables. The model was analyzed by Long Short-Term Memory (LSTM) artificial neuronal networks, the primary focus of this research. Similarly, within this last phase, the same model is presented, but a review of its behavior was conducted by implementing support-vector machines, as a comparative strategy of ANN performance with respect to other possible models that can be implemented in these types of processes.

The primary conclusion of this research is that neural networks are a viable alternative to develop models that include all stages of MSW management in a city. While these mathematical models require a large amount of data to minimize the results' margin of error, with the data obtained for the modeling the ANNs were properly adapted and showed satisfactory performance according to the proposed methodology. Moreover, the study demonstrated that the designed model is structured in such a manner that it allows for continuous modification, inclusion, precision and optimization of the information. This is an advantage as it enables the proposed methodology's efficiency to be improved on an ongoing basis, in order for it to be applied to a specific area in a city with similar characteristics. The above is dependent on countries establishing and strengthening their information systems in a reliable manner, in order to obtain more precise data, which is a short-term goal for Colombia.

Agradecimientos

Al profesor Dr. Javier Rodrigo-Illari, por todo el apoyo brindado durante el desarrollo de la presente investigación, por su dedicación y acompañamiento durante todo el proceso, así como por su constante asesoría académica y profesional para lograr el presente documento de tesis.

A la Universidad Santo Tomás, por la confianza que me ha otorgado durante los años que he estado vinculada en la institución, así como por la oportunidad de hacerme partícipe de la Convocatoria 001 de estudios posgraduales de la Vicerrectoría Académica en convenio con la Universitat Politècnica de València en el Doctorado de Ingeniería del Agua y Medio ambiental y por el apoyo recibido en cuanto a la ejecución de proyectos derivados del presente trabajo investigativo.

A la Universitat Politècnica de València, por su atención permanente para la finalización de mis estudios de Doctorado de forma exitosa.

Agradecimientos a la Unidad Administrativa Especial de Servicios Públicos (UAESP), por aportar en este estudio con el suministro de la información requerida así como al Departamento Nacional de Planeación. Igualmente a la Escuela de Ingeniería de Sistemas e Informática de la Universidad Industrial de Santander por la asesoría para el planteamiento de los algoritmos, análisis y codificación.

A la Ingeniera Ana Paola Becerra Quiroz, hoy Decana de la Facultad de Ingeniería Ambiental de la Universidad Santo Tomás, por su infinita confianza en mi trabajo, por brindarme fortaleza con su amistad en los momentos difíciles y por animarme constantemente a cumplir mis logros académicos y personales.

A la Dra. Angela María Jaramillo Londoño, ya que su amistad ha sido luz y guía desde que me propuse este reto académico.

Al Magíster y Administrador Ambiental David Orjuela Yepes, a quien agradezco inmensamente el apoyo incondicional, tanto personal como profesional, brindado durante el desarrollo de la investigación.

A la Ingeniera Claudia Patricia Romero Hernández, por su apoyo en el proceso investigativo así como por las vivencias académicas y personales compartidas.

A la Dra. María Elena Rodrigo Clavero y al Dr. Eduardo Cassiraga, por el apoyo académico brindado en la presente investigación.

A mis amigos y compañeros de la Universidad Santo Tomás los Ingenieros y Magísteres Claudia Fernanda Navarrete López, Nidia Isabel Molina Gómez y Darwin Mena Rentería, quienes también emprendieron sus estudios de Doctorado bajo el convenio mencionado, por todas las experiencias personales, académicas y profesionales que vivimos a lo largo de este camino. Para ellos deseo muchos éxitos y bendiciones más en sus vidas.

A mi esposo y a mi hijo, que con su paciencia y amor han creído siempre en mí y me han apoyado para que alcance mis sueños. Gracias por estar siempre ahí, son mi fuerza y mi razón de ser.

A mi familia, que siempre me ha acompañado en el logro de mis metas académicas y profesionales.

Muchas gracias a todos.

Índice

Índice de figuras

Índice de tablas

Abreviaturas

1. Introducción y objetivos.....	1
1.1. Motivación de la investigación	1
1.2. Objetivos	4
1.3. Estructura de la tesis doctoral	4
2. Estado del arte.....	7
2.1. Aspectos generales de gestión de residuos sólidos urbanos.....	7
2.2. La gestión de residuos sólidos en Colombia	10
2.3. Gestión de RSU en la Ciudad de Bogotá y sus localidades	14
2.4. Normativa aplicable a la gestión de RSU en Colombia	16
2.5. Conceptos asociados a la inteligencia artificial.....	16
2.5.1. Aprendizaje supervisado	17
2.5.2. Aprendizaje no supervisado	18
2.5.3. Aprendizaje por refuerzo.....	19
2.6. Python como lenguaje de programación	22
2.7. Redes neuronales artificiales (RNA).....	23
2.7.1. Redes neuronales artificiales recurrentes (RNN)	28
2.7.2. Redes Long Short-Term Memory (LSTM).....	29
2.8. Máquinas de Soporte Vectorial (MSV).....	31

3. Datos disponibles	37
3.1. Caso de estudio.....	37
3.1.1. Características generales del área de estudio.....	37
3.1.2. Localidad de Suba	44
3.1.3. Localidad de Engativá.....	47
3.2. Datos utilizados en la modelación.....	49
4. Definición y análisis de escenarios.....	57
4.1. Identificación de zonas críticas en la generación de residuos sólidos en el área de estudio	57
4.2. Análisis de escenarios	63
4.2.1. Escenario 1: Cálculo de $PPC_{str,i}$ considerando fuertes restricciones en el proceso de minimización	63
4.2.2. Escenario 2: Cálculo de $PPC_{str,i}$ considerando restricciones intermedias en el proceso de minimización	65
4.2.3. Escenario 3: Cálculo de $PPC_{str,i}$ descartando los datos de la ASE 3	67
4.2.4. Escenario 4: Cálculo de $PPC_{str,i}$ descartando los datos de ASE 3 y considerando una distribución de bloques para $PPC_{str,i}$	69
5. Predicción de la generación de residuos en la ciudad de Bogotá	73
6. Propuesta metodológica	87
6.1. Propuesta metodológica para el aprovechamiento y disposición de residuos sólidos urbanos basada en redes neuronales artificiales tipo LSTM	87
6.2. Análisis del modelo propuesto	92
6.3. Análisis comparativo de la implementación de redes neuronales artificiales de tipo LSTM y máquinas de soporte vectorial en modelos asociados a la gestión de residuos sólidos urbanos en grandes ciudades.....	103
6.4. Aporte de la propuesta metodológica a la solución de problemáticas ambientales.....	108
7. Conclusiones	111
8. Líneas de futura investigación.....	115
9. Referencias	117

Anexos

- 1.- Relación de normativa colombiana vigente relacionada con la gestión de residuos sólidos
- 2.- Distribución de hogares por estrato socioeconómico por localidad
- 3.- Datos económicos. Costes de tratamiento, ingresos por venta de recursos valorizados por tratamiento e ingresos por tarifa del Servicio Público de Aseo según tratamiento
- 4.- Relación de publicaciones científicas desarrolladas en el marco de la tesis doctoral

Índice de figuras

Figura 2.1.- Esquema para la gestión de RSU.....	9
Figura 2.2.- Caracterización de RSU en las ciudades principales de Colombia	12
Figura 2.3.- Diagrama de flujo del aprendizaje supervisado.....	18
Figura 2.4.- Diagrama de flujo del aprendizaje no supervisado.....	19
Figura 2.5.- Diagrama de flujo del aprendizaje por refuerzo	20
Figura 2.6.- Modelo de neurona estándar.....	24
Figura 2.7.- Tipos de función de activación.....	25
Figura 2.8.- Esquema de una red neuronal recurrente.....	28
Figura 2.9.- Diagrama de una celda LSTM.....	30
Figura 2.10.- Definición de la frontera de decisión para MSV	32
Figura 2.11.- Ejemplo de hiperplanos posibles	33
Figura 2.12.- Definición de la frontera de decisión para MSV	34
Figura 3.1.- Generación media de RSU por departamento (t/día).....	39
Figura 3.2.- PPC de RSU por departamento (t/día).....	40
Figura 3.3.- Disposición final autorizada por departamentos.	41
Figura 3.4.- Mapa de localidades de Bogotá.....	42
Figura 3.5.- Esquema de recolección de residuos sólidos en la ciudad de Bogotá	43
Figura 3.6.- Mapa general de Bogotá con la ubicación de la localidad de Suba	45
Figura 3.7.- Mapa general de la localidad de Suba	46
Figura 3.8.- Mapa general de la localidad de Engativá.....	47
Figura 3.9.- Mapa de la localidad de Engativá.....	48
Figura 4.1.- PPC por ASE para el año 2005.....	59
Figura 4.2.- PPC por ASE para el año 2015.....	60
Figura 4.3.- PPC por ASE para el año 2020.....	62
Figura 4.4.- Generación de residuos sólidos por ASE en Bogotá (2009-2020)	62
Figura 4.5.- Generación de RSU per cápita por estrato en el escenario1	65
Figura 4.6.- Generación de RSU per cápita por estrato en el escenario 2	67
Figura 4.7.- Generación de RSU per cápita por estrato en el escenario 3	69
Figura 4.8.- Generación de RSU per cápita por estrato en el escenario 4	71

Figura 5.1.- Residuos anuales recogidos por ASE	75
Figura 5.2.- Generación mensual de residuos por año para la localidad de Suba.....	76
Figura 5.3.- Generación mensual de residuos por año para la localidad de Engativá ...	77
Figura 5.4.- Participación de las localidades de Suba y Engativá dentro de las ASE para el año 2012.....	78
Figura 5.5.- Participación de las localidades de Suba y Engativá dentro de las ASE para el año 2016.....	78
Figura 5.6.- Redes LSTM ASE 1	79
Figura 5.7.- Redes LSTM con ventana deslizante ASE 1	80
Figura 5.8.- LSTM para regresión con pasos de tiempo ASE 1	80
Figura 5.9.- Redes LSTM ASE 2	81
Figura 5.10.- Redes LSTM con ventana deslizante ASE 2	81
Figura 5.11.- LSTM para regresión con pasos de tiempo ASE 2	82
Figura 5.12.- Árboles de decisión para la ASE 1. Profundidad = 3	83
Figura 5.13.- Árboles de decisión para la ASE 1. Profundidad = 6	83
Figura 5.14.- Árboles de decisión para la ASE 2. Profundidad = 3	84
Figura 5.15.- Árboles de decisión para la ASE 2. Profundidad = 6	84
Figura 5.16.- MSV para la ASE 1	85
Figura 5.17.- MSV para la ASE 2	85
Figura 6.1.- Metodología para la formulación del modelo.....	89
Figura 6.2.- Propuesta metodológica basada en RNA como soporte para la toma de decisiones para la gestión de RSU	89
Figura 6.3.- Ajuste del Modelo de predicción.....	93
Figura 6.4.- Predicción por ASE	94
Figura 6.5.- Análisis de costos e ingresos	95
Figura 6.6.- Escenarios analizados por el modelo.....	97
Figura 6.7.- Análisis predictivo de la generación de RSU para el año 2030 para la ASE 4 (LSTM).....	98
Figura 6.8.- Análisis predictivo de la generación de RSU para el año 2030 para la ASE 5 (LSTM).....	98
Figura 6.9.- Mapa de ubicación del vertedero Doña Juana (distancia 1) y del vertedero Nuevo Mondoñedo (distancia 2).....	101

Figura 6.10.- Análisis predictivo de la generación de RSU para el año 2030 para la ASE 4 (MSV)	104
Figura 6.11.- Análisis predictivo de la generación de RSU para el año 2030 para la ASE 5 (MSV)	104
Figura 6.12.- Relación de costos proyectados para el año 2030 (promedio mensual) por ASE, modelos, escenarios y distancias.....	107

Índice de tablas

Tabla 2.1.- ASE para la recolección de residuos sólidos en Bogotá.....	14
Tabla 2.2.- Composición macroscópica de residuos Bogotá 2017.....	15
Tabla 3.1.- Capacidad de campo de residuos sólidos urbanos	50
Tabla 3.2.- Planteamiento de escenarios y definición de procesos asociados.....	53
Tabla 3.3.- Descripción de las distancias incluidas en modelo	54
Tabla 4.1.- Generación de residuos sólidos por ASE para el año 2005	59
Tabla 4.2.- Generación de residuos sólidos por ASE para el año 2015	60
Tabla 4.3.- Generación de residuos sólidos por ASE para el año 2020	61
Tabla 4.4.- Distribución de la población de 2015 por estratos económicos de cada ASE	63
Tabla 4.5.- Minimización de la función objetivo para el Escenario 1.....	64
Tabla 4.6.- Escenario 1: Residuos sólidos per cápita por estrato i ($PPC_{str,i}$)	64
Tabla 4.7.- . Escenario 2: Cálculos de minimización de la función objetivo	66
Tabla 4.8.- Escenario 2: Residuos sólidos per cápita por estrato i ($PPC_{str,i}$)	66
Tabla 4.9.- Escenario 3: Cálculos de minimización de la función objetivo	68
Tabla 4.10.- Escenario 3: Residuos sólidos per cápita por estrato i ($PPC_{str,i}$)	68
Tabla 4.11.- Escenario 4: Cálculos de minimización de la función objetivo.....	70
Tabla 4.12.- Escenario 4: Residuos sólidos per cápita por estrato i ($PPC_{str,i}$)	70
Tabla 6.1.- Estructura por ASE a partir de 2018.....	88
Tabla 6.2.- Relación de costos e ingresos (2030) para la distancia de disposición 1 (LSTM).....	99
Tabla 6.3.- Relación de costos e ingresos (2030) para la distancia de disposición 2 (LSTM).....	100
Tabla 6.4.- Relación de costos e ingresos (2030) para la distancia de disposición 1 (MSV).....	105
Tabla 6.5.- Relación de costos e ingresos (2030) para la distancia de disposición 2 (MSV).....	106
Tabla 6.6.- Errores obtenidos para cada uno de los métodos por ASE	108

Abreviaturas

ASE	Área de Servicio Especial
BAT	<i>Best Available Technology</i>
BID	Banco Interamericano de Desarrollo
CAR	Corporación Autónoma Regional
CRA	Comisión de Regulación de Agua Potable y Saneamiento Básico
DANE	Departamento Administrativo Nacional de Estadística
GIRSU	Gestión Integral de Residuos Sólidos Urbanos
IA	Inteligencia Artificial
LR	Regresión Lineal
LSTM	<i>Long Short-Term Memory</i>
OCDE	Organización para la Cooperación y el Desarrollo Económico
ORA	Organizaciones de Recicladores Autorizadas
PGIR	Plan de Gestión Integral de los Residuos sólidos
PPC	Producción Per Cápita
RCD	Residuos de Construcción y Demolición
RSDJ	Relleno Sanitario Doña Juana
RSU	Residuos Sólidos Urbanos
RNA	Redes Neuronales Artificiales
RNN	Redes Neuronales Recurrentes
MSV	<i>Support Vector Machines</i>
UAESP	Unidad Administrativa Especial de Servicios Públicos
UPZ	Unidad de Planeación Zonal

1. Introducción y objetivos

1.1. Motivación de la investigación

Una de las problemáticas que requiere acciones inmediatas, particularmente en grandes ciudades, es la asociada al aumento continuo en la generación de residuos sólidos urbanos (RSU). Si bien las administraciones locales y nacionales centran esfuerzos en implementar estrategias y analizar las diferentes alternativas existentes para la mejora de la gestión de los residuos, el aumento de la población y la complejidad propia de cada ciudad dificultan esta labor.

Los responsables de la toma de decisiones requieren de diversas herramientas de apoyo que les permitan decidir cuál es la mejor estrategia de acuerdo con las características particulares de una población determinada y las condiciones de diseño que sean coherentes con la normativa y los diferentes elementos de planificación que estén en vigor, de manera que se minimicen posibles errores en la selección de alternativas y se procure la determinación de medidas asertivas. Dicha selección debe tener presentes variables como la población, el aumento de la generación de residuos y las condiciones socioeconómicas, sin dejar de lado la utilización de las mejores técnicas que están disponibles para la región, así como la consideración de los posibles costos asociados, no sólo respecto de la inversión inicial de las infraestructuras y de sus costes de operación, sino también los posibles costos que deben asumir los usuarios del servicio de limpieza y sus implicaciones. Estos cambios en tecnologías, la introducción de mejoras y la realización

de cálculos económicos referentes a la actualización tarifaria son condiciones a tener en cuenta al momento de tomar una decisión sostenible para la ciudad.

Implementar alternativas eficientes permitirá la minimización de los impactos ambientales y así favorecer la calidad de vida de las poblaciones. De este modo, la gestión de los RSU se debe evaluar desde diversos puntos de vista para poder implementar un sistema sostenible de manera que no se realicen intentos fallidos que puedan concluir en emergencias sanitarias. Por tanto, se deben incluir dentro de los modelos todas las variables implicadas, ya sean económicas, ambientales o sociales, que incidan en este proceso de gran interés para la ciudad.

De acuerdo con la información disponible, en el año 2018 en Colombia se dispusieron 30.973 t/día de residuos sólidos (Superservicios, 2019), lo que equivale a 929.190 toneladas al mes. Específicamente en la ciudad de Bogotá, en el mes de marzo de 2020 fueron recolectadas 196.138 toneladas de residuos sólidos (UAESP, 2020a). Estos datos muestran el reto que representa gestionar los residuos sólidos del país y particularmente los residuos que se generan en la ciudad de Bogotá. Además de generar esta gran cantidad de residuos, éstos se disponen en el vertedero controlado “Doña Juana” (RSDJ) el cual ha presentado diversos problemas que han tenido como consecuencia graves emergencias ambientales. La última de estas emergencias ocurrió en mayo de 2020, por deslizamiento de residuos dentro del vertedero que afectó a la comunidad aledaña, lo que supuso la imposición de las correspondientes sanciones para el operador.

Un aspecto que debe considerarse dentro de la gestión de los RSU en Colombia es el asociado al bajo aprovechamiento de los residuos. En Colombia el 83% de los residuos sólidos que se generan son finalmente depositados en vertederos y sólo el 17% son aprovechados para incorporarlos nuevamente en el ciclo productivo a través de su comercialización (El Nuevo Siglo, 2019). Por otra parte, aún está en proceso de fortalecimiento el programa de aprovechamiento, el cual ha centrado esfuerzos en el proceso de inclusión de los recicladores de oficio al sistema de servicio de limpieza, de manera que tengan un trabajo digno y cuenten con condiciones laborales adecuadas.

Otra problemática que requiere atención es la disponibilidad de datos continuos y precisos referentes a la generación, recogida y disposición de los residuos sólidos en las ciudades, de manera que se pueda disponer de una base de datos robusta que permita poder predecir la generación de RSU en el futuro, para que se puedan plantear alternativas eficientes dentro del proceso de gestión. La mejora en los sistemas de información que permita la toma de decisiones acertada se plantea como un gran reto para el servicio público de limpieza, así como aumentar el aprovechamiento y valorización de los residuos (DNP et al., 2016).

Las herramientas de inteligencia artificial (IA) se han constituido en un apoyo para definir alternativas, criterios de diseño, modelos y rutas operativas dentro de las ciencias ambientales. De este modo, las técnicas de IA se plantean como una alternativa viable para la optimización de procesos y metodologías en diversos campos de acción a través de la búsqueda de soluciones efectivas. Las redes neuronales artificiales (RNA), como

herramienta dentro la IA, constituyen una posibilidad viable para la búsqueda de soluciones y apoyo en la toma de decisiones dentro del campo de la ingeniería ambiental relacionado con la gestión de los RSU, ya que poseen múltiples ventajas. Las herramientas de IA permiten tomar como ejemplos problemas resueltos para constituir sistemas que facilitan la toma de decisiones generando clasificaciones sin necesidad de conocer detalles matemáticos y proporcionando la solución de problemas no lineales (Ponce, 2010). Todas estas características las hacen atractivas para el diseño de modelos que brinden soluciones en esta área de investigación. Estos sistemas de IA presentan múltiples beneficios, los cuales son pertinentes para sistemas asociados a la toma de decisiones, ya que pueden obtener el conocimiento de algo en particular por medio del estudio, ejercicio o experiencia y cambian su comportamiento en función del entorno, además de ajustarse para presentar salidas coherentes si se les presenta un conjunto de datos de entrada (Basogain, s.f.).

Teniendo presente lo anterior, este trabajo tiene como motivación principal brindar una herramienta de apoyo a las administraciones municipales, y particularmente a la ciudad de Bogotá y sus localidades, en la toma de decisiones y en la búsqueda de una estrategia para la gestión de RSU. Dada la complejidad de la ciudad de Bogotá asociada a su elevada población (8.380.801 habitantes en 2020 según las proyecciones disponibles (Alcaldía de Bogotá y Secretaría de Planeación, 2014), en este trabajo se propone el estudio por zonas de la ciudad para una mejora y una gestión eficiente del actual sistema, de manera que se pueda minimizar la carga de residuos que van finalmente a ser depositadas en el vertedero de la ciudad. Como hemos dicho anteriormente, en este vertedero se han registrado emergencias sanitarias debidas, en parte, a los problemas asociados al diseño del mismo, pero también al elevado volumen de residuos que se depositan allí diariamente.

En la actualidad, no se visualizan opciones a corto plazo para disponer los residuos sólidos de la ciudad en otro vertedero controlado, pero se podría comenzar a mejorar la situación mediante la minimización de la carga que se dispone en el mismo. Una de esas alternativas está dada en la posibilidad de implementar tecnologías diferentes al simple depósito en vertedero controlado para distintas zonas de la ciudad según sus características. Por ello, este trabajo se centra en analizar posibles alternativas que incluyen dos localidades de las veinte en que se divide la megaciudad de Bogotá, denominadas Suba y Engativá.

Si bien en la ciudad se tienen tres separaciones en la fuente para los residuos (residuos aprovechables, residuos no aprovechables y residuos orgánicos, esta última con inicio de vigencia para el año 2021), el fortalecimiento paulatino de este tipo de procesos depende de diferentes aspectos sociales y de inversión, lo que proporcionaría un impulso al cumplimiento del servicio en todas las zonas de la ciudad. Sin duda, la implantación de estas estrategias representará un cambio importante en la entrada de residuos al vertedero. Sin embargo, esta gestión actual podría verse mejorada si se hiciera una planificación tecnológica zonal para la gestión de los residuos, no solo impulsando la comercialización de residuos aprovechables como se hace actualmente, sino mediante la implementación

conjunta de otras estrategias, como por ejemplo el aprovechamiento energético de diferentes tipos de residuos y el uso de modelos matemáticos de optimización para la selección de alternativas eficientes. Todo ello proporciona evidentes beneficios sobre la salud de las comunidades, junto con la mejora de la calidad ambiental y de las condiciones de las poblaciones aledañas al relleno sanitario, incentivando además la participación de los recicladores de oficio. Estas mejoras se maximizan si son optimizadas a través de herramientas avanzadas de modelación que incluyan variables particulares, tecnologías específicas y la incorporación de costes económicos para definir la apropiada gestión de los residuos generados por una población en particular.

1.2. Objetivos

La presente tesis doctoral tiene como objetivo establecer una metodología, basada en redes neuronales artificiales, para la determinación de la mejor alternativa de aprovechamiento de los residuos sólidos urbanos generados en las localidades de Suba y Engativá en Bogotá (Colombia). Para ello, la investigación a desarrollada se ha orientado de forma que responda a los siguientes objetivos específicos:

- Determinar de forma teórica y práctica la solución de problemáticas ambientales relacionadas con la gestión de residuos sólidos domiciliarios a través de redes neuronales.
- Implementar redes neuronales artificiales en cada una de las etapas de la gestión integral de residuos sólidos urbanos tomando datos reales del área de estudio seleccionada.
- Desarrollar un instrumento metodológico para la determinación de la opción más adecuada para el aprovechamiento de los residuos sólidos en las localidades establecidas para la ciudad de Bogotá.
- Validar la propuesta metodológica con métodos de cálculo tradicionales utilizados en la estimación de la generación de residuos sólidos, rutas óptimas de transporte y selección de técnicas de aprovechamiento.

1.3. Estructura de la tesis doctoral

El presente documento se estructura en nueve capítulos y anexos que describen pormenorizadamente el desarrollo de la investigación realizada. El contenido de cada uno de ellos es el siguiente:

1. **Introducción y objetivos.** Este capítulo es el inicial del documento y en él se presenta la motivación, los objetivos y la estructura general de la investigación.
2. **Estado del arte.** Este capítulo presenta los conceptos fundamentales asociados a la gestión de RSU, la normativa aplicable vigente para el área de estudio, conceptos de IA, herramientas referentes a la IA y conceptos asociados a las RNA, particularmente a las de tipo *Long Short Term Memory* (LSTM).

3. **Datos disponibles.** Se describen las características particulares de la ciudad de Bogotá y de la zona de estudio, haciendo énfasis en su estructura administrativa, factor importante dentro del proceso de gestión de RSU. De igual forma, en este capítulo se realiza una descripción de los datos utilizados para la aplicación del modelo planteado.
4. **Definición y análisis de escenarios.** Se presenta una estrategia para analizar la generación de RSU en grandes ciudades. El análisis se realiza para datos reales de la ciudad de Bogotá (Colombia), efectuando predicciones de la generación como un paso preliminar para la integración de tecnologías y costes en el modelo. Para este propósito, se realizó un análisis de los datos obtenidos y el comportamiento de la generación de los RSU como primer paso, entendiendo las relaciones entre las variables que pueden influir en la generación de estos. Además, en este capítulo se presenta una metodología analítica que utiliza una combinación de técnicas de sistemas de información geográfica (SIG) y métodos de análisis estadístico para evaluar la generación de residuos sólidos en grandes áreas urbanas.
5. **Predicción de la generación de residuos en la ciudad de Bogotá.** Se presenta en este capítulo los resultados referentes al análisis predictivo asociado a las herramientas de IA seleccionadas: los árboles de decisión, las máquinas de soporte vectorial (MSV) y redes neuronales artificiales de tipo LSTM. La investigación realizada se centró en las LSTM con las que se modelaron datos reales de la ciudad de Bogotá, utilizando Python como lenguaje de programación.
6. **Propuesta metodológica.** Una vez analizado el comportamiento predictivo, se realizó el diseño metodológico para la definición del modelo, en el cual se incluyeron todas las variables que se utilizaron para las proyecciones en la generación de los RSU con anterioridad. Se presenta, por tanto, la propuesta metodológica basada en redes neuronales artificiales. Para ello, además de las proyecciones en la generación mencionadas, se incluyó en esta etapa los costes económicos asociados a los posibles tratamientos a través del planteamiento de diferentes escenarios posibles con diferentes combinaciones tecnológicas. Así mismo, en este capítulo se incluye un análisis comparativo de la implementación de redes neuronales artificiales de tipo LSTM y MSV en modelos asociados a la gestión de residuos sólidos urbanos en grandes ciudades. Dado que en el transcurso del proceso investigativo se tuvo la posibilidad de aplicar modelos diferentes a las RNA, se decidió analizar el modelo planteado bajo máquinas de soporte vectorial en las mismas condiciones utilizadas para las redes LSTM, con el fin de realizar estudios comparativos.
7. **Conclusiones.** Se presentan en este capítulo las conclusiones de la investigación desarrollada.
8. **Líneas de futura investigación.** Se describen en esta sección las futuras líneas de investigación según los resultados obtenidos en la presente investigación.

9. **Bibliografía.** Presenta el listado bibliográfico de las referencias citadas en el documento.

Anexos. Como anexos se presentan tablas referentes a la normativa vigente en Colombia en materia de gestión de residuos sólidos así como los datos principales de costos utilizados en la investigación. Este apartado también incluye la relación de artículos de investigación y contribuciones en congresos generadas durante el desarrollo del presente trabajo.

2. Estado del arte

En este capítulo se presentan los conceptos generales acerca de la gestión de residuos sólidos urbanos en Colombia, se introducen las técnicas y herramientas de IA y los conceptos asociados a las RNA, particularmente a las de tipo *Long Short Term Memory* (LSTM). La información mostrada a continuación ha sido obtenida a partir de análisis bibliográfico y de investigación documental y ha permitido realizar las aplicaciones prácticas y el planteamiento de la propuesta metodológica que se describen en los capítulos posteriores de esta tesis.

2.1. Aspectos generales de gestión de residuos sólidos urbanos

Los residuos sólidos urbanos (RSU) se asocian a aquellos materiales desechados o descartados provenientes de la actividad humana, que pueden estar sujetos a aprovechamiento energético o transformación en materiales de valor comercial a partir de su reutilización o reciclado. Dentro del concepto de RSU se incluyen los desechos domiciliarios, generados en los hogares, los residuos provenientes de limpieza de la vía pública referentes provenientes del barrido de calles, restos de poda y jardinería, restos de obras domiciliarias en pequeños volúmenes, limpieza de áreas públicas, etc. así como los originados en actividades productivas como comercios, industrias y actividades primarias (Ubierno, 2015).

De este modo, dentro de los residuos sólidos urbanos se encuentran los generados en las viviendas, conocidos como domiciliarios o domésticos. Por lo general entre el 50% y el 55% de estos residuos son orgánicos y provienen principalmente de la manipulación de

comida y actividades de limpieza en el hogar. No obstante, esta proporción puede variar según el nivel socioeconómico de los habitantes, ya que se ha evidenciado que en familias de nivel económico superior, el consumo de productos con envases de metal, papel, plástico y vidrio es más alto que en familias con menor nivel económico (PUMA-UNAM, 1997; citado en Escamirosa et al., 2001). Es importante, por tanto, incluir dentro de los diferentes estudios asociados a la gestión de RSU la variable socioeconómica para poder definir la influencia que tiene, tanto en composición o en cantidad, en una muestra determinada o en una población definida.

La generación de residuos es una consecuencia natural de la urbanización, aumentando directamente con ella, dado que cuanto mayor es este aspecto mayor es la generación total de residuos y la generación per cápita (Kaza et al., 2018). De igual forma, el aumento en la producción de residuos viene también asociado al desarrollo económico de una región o país y al crecimiento poblacional.

La gestión de residuos sólidos puede ser considerada como una disciplina global que está relacionada tanto con la producción, control del almacenamiento, recogida, separación, procesamiento, aprovechamiento y transformación, transferencia y transporte y por último evacuación o disposición final de los residuos (figura 2.1). Estas actividades deben implementarse de forma armónica con aspectos como “*la salud pública, la economía, la ingeniería, la conservación, la estética y otras consideraciones ambientales que responden a las expectativas públicas*” (Tchobanoglous, 1994). El objetivo principal de la gestión y tratamiento de los residuos urbanos es su transformación en sustancias menos peligrosas o contaminantes así como su recuperación en forma de materias o productos útiles mediante procesos de valorización (Red Española de Compostaje, 2014), minimizando los impactos ambientales y evitando de igual forma la carga sobre los vertederos municipales.

Cuando todos los elementos del sistema hayan sido evaluados para su uso y hayan sido integrados con el fin de lograr una mayor eficiencia y rentabilidad, entonces se habrá desarrollado con éxito un sistema de gestión integral de RSU. El sistema puede ser definido como la selección e implementación de técnicas, tecnologías y programas de gestión aptos para lograr metas y objetivos específicos (Tchobanoglous, 1994). Por otra parte, un sistema de Gestión Integral de Residuos Sólidos Urbanos (GIRSU) consiste en un plan para la gestión correcta de los residuos en todas sus etapas, mediante la implementación de programas y proyectos, para lo cual se deben seleccionar e implementar tecnologías y herramientas de gestión que busquen la minimización de los impactos negativos sobre la salud de la población y el medioambiente (Ubierno, 2015).

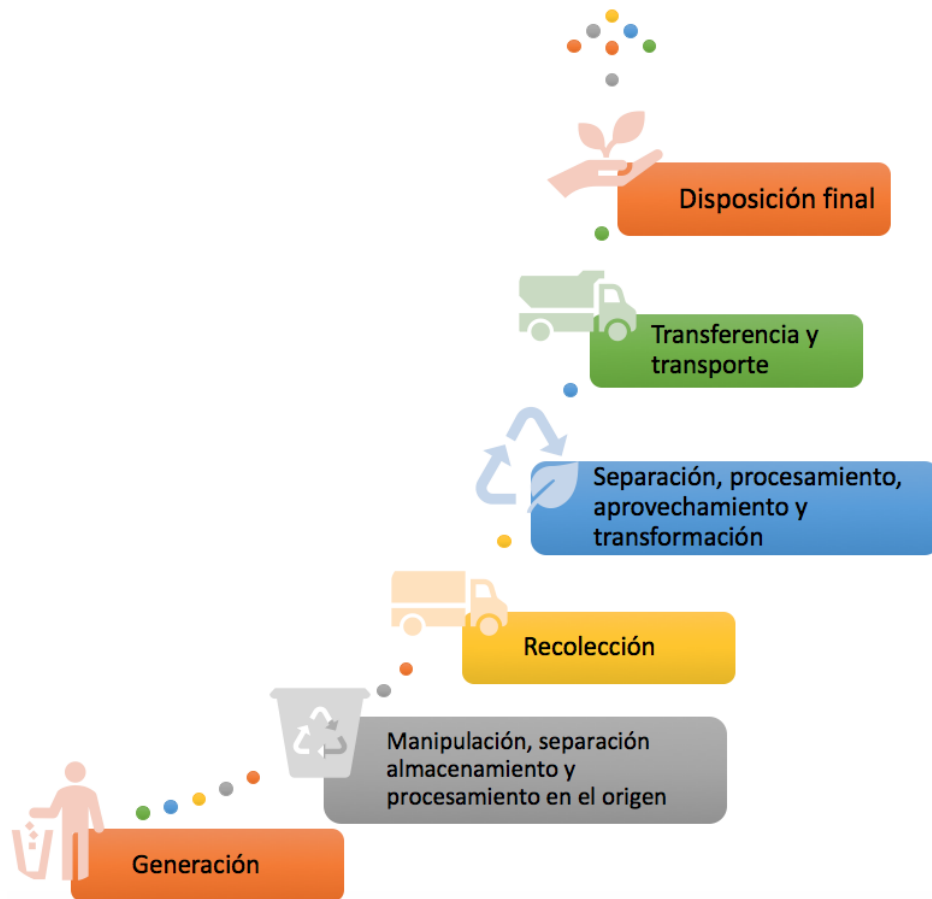


Figura 2.1.- Esquema para la gestión de RSU
(Tchobanoglous, 1994)

La inadecuada gestión de RSU es un problema que afecta a las poblaciones de forma generalizada a nivel mundial. Los residuos mal gestionados contaminan los océanos obstruyendo los desagües, generando inundaciones, transmitiendo enfermedades por reproducción de vectores, aumentando los problemas respiratorios por material particulado generado por la incineración de residuos, afectando a los animales que consumen residuos, así como al desarrollo económico a través, por ejemplo, de la disminución del turismo. Por todos estos motivos, una inadecuada gestión de residuos requiere acciones urgentes en todos los niveles de la sociedad (Kaza et al., 2018). Todo ello ratifica la necesidad de realizar esta gestión de forma ordenada y eficaz, lo cual dependerá de la disponibilidad de datos confiables referentes a los flujos de residuos, de las especificaciones del rendimiento de las tecnologías y de la información sobre los costos asociados (Tchobanoglous, 1994).

La gestión de residuos urbanos es económicamente costosa. En algunos países representa casi el 20% en promedio de los presupuestos municipales y en países de ingresos bajos puede ser la partida presupuestaria más alta. En países de ingresos medios representa más del 10% de los presupuestos municipales y en los países de ingresos altos representa alrededor del 4%, llegando incluso a ser más altos en algunos casos específicos (Kaza et al., 2018). La gestión integral de residuos sólidos urbanos en América Latina se considera un tema de responsabilidad de los gobiernos locales principalmente, quienes actúan bajo diferentes esquemas operacionales, que abarcan desde la realización de actividades directamente con recursos propios de cada municipalidad, hasta la contratación con entes privados para la ejecución de todas las tareas correspondientes a la gestión correcta de los RSU (AIDIS, 2018).

Tradicionalmente, la planificación de esta gestión se fundamenta en un plan de acción que es revisado permanentemente con el fin de ratificar su cumplimiento, denominado “Plan Municipal de Gestión Integral de Residuos” y que se ha ido apropiando gradualmente dentro de las herramientas de planificación de la gestión de los gobiernos locales (AIDIS, 2018). En Colombia, el Plan de Gestión Integral de Residuos Sólidos (conocido comúnmente como PGIR) se considera un instrumento de planeamiento para municipios y regiones, y se encuentra establecido dentro del Decreto 1077 de 2015. El plan debe ser ejecutado durante un período determinado, según los diagnósticos iniciales y sus proyecciones, basándose en un plan financiero viable dirigido a la mejora continua y a la prestación adecuada del servicio de limpieza a nivel municipal o regional (Minvivienda, 2015).

Este plan involucra la toma de decisiones para la selección de alternativas, lo que supone la necesidad de realizar un proceso de planificación laborioso. La elaboración del plan “*requiere de una gran cantidad de información y de un amplio conocimiento de las condiciones locales, culturales y económicas que considere, incluso, la idiosincrasia de la población atendida para que los resultados de esta planificación sean los apropiados*” (AIDIS, 2018). Tanto es así que conocer las particularidades regionales se hace indispensable para poder establecer estrategias, alternativas y técnicas que permitan apoyar y optimizar la toma de decisiones dentro de esta gestión de manera que se busque el beneficio ambiental y de las poblaciones dependiendo de las necesidades identificadas como prioritarias en el marco de los objetivos establecidos por las administraciones municipales para la gestión de sus RSU.

2.2. La gestión de residuos sólidos en Colombia

En Colombia, la gestión de RSU aún está acorde con modelos lineales que se centran en el desecho de bienes cuando quedan fuera de funcionamiento o no sirven para su fin inicial, representando una pérdida de recursos y un crecimiento constante en la generación de RSU. Por tanto, surge la necesidad de formular un modelo adecuado que incluya conceptos referentes a economía circular y análisis de ciclo de vida para avanzar hacia un uso eficiente de los recursos, la protección del ambiente y el desarrollo de la agenda

internacional dirigida hacia los Objetivos de Desarrollo Sostenible definidos por el COP 21 y la OCDE. Todo ello puede lograrse a través de un enfoque integral entre la gestión ambiental y las características y funcionamiento del servicio público de limpieza de una región (DNP et al., 2016), objetivo establecido de igual forma en el Plan Nacional de Desarrollo 2018-2022 “*Pacto por Colombia, pacto por la equidad*”. Este plan Nacional tiene como objetivo priorizar como estrategia nacional la economía circular para el aumento del reciclaje de residuos, la reutilización del agua y la eficiencia energética (Gobierno de Colombia, 2017).

En el año 2016 se estableció para Colombia la Política Nacional para la Gestión Integral de Residuos Sólidos (CONPES 3874), dirigida a definir alternativas para la minimización, la reutilización, el reciclaje y el aprovechamiento de residuos sólidos que lleven a procesos de economía circular. En esta política se formulan y estructuran estrategias como las siguientes (DNP et al., 2016):

- i. avanzar hacia una economía circular
- ii. promover la educación e innovación en gestión de RSU así como la cultura ciudadana para la prevención, reutilización y adecuada separación en la fuente
- iii. fortalecer la coordinación entre todas las partes interesadas que permita un aumento en la eficiencia en la gestión integral de RSU, e
- iv. implantar de acciones para mejorar los sistemas de información, el control, la verificación y la divulgación de la información del sector para el seguimiento de las políticas relacionadas con la gestión de los RSU en el país.

Es así como municipios y distritos deben asegurar la atención de las necesidades básicas de saneamiento de áreas urbanas de difícil gestión y de zonas rurales, implementando soluciones colectivas e individuales, y asegurando la óptima prestación del servicio público de aseo, de acuerdo con los esquemas diferenciales definidos por el Gobierno Nacional y la reglamentación vigente en materia de gestión de RSU (Superservicios y DNP, 2018).

Así mismo, el CONPES 3874 plantea propósitos que permiten generar impactos efectivos en el medio y largo plazo, entre los cuales se identifican los siguientes (Minvivienda, 2012):

- i. planear de forma integral los componentes del servicio de aseo, estableciendo de igual forma esquemas regionales
- ii. fortalecer la formulación, implementación y seguimiento de los PGIRS, y
- iii. fomentar el establecimiento de estrategias para la comercialización de los productos generados en los procesos de aprovechamiento que permitan la implementación de sistemas para esta actividad bajo criterios ambientalmente sostenibles y socialmente responsables.

En cuanto a la composición de los RSU en las grandes ciudades del país, de acuerdo con la información incorporada en los PGIRS, los residuos orgánicos corresponden al 61,5% (figura 2.2), siendo los más representativos los residuos correspondientes a los restos de

alimentos en sus diferentes etapas de producción, mientras que el porcentaje restante se considera que corresponde a residuos generados en la distribución, comercialización y consumo de los hogares. Los demás residuos generados, se componen fundamentalmente de materiales que pueden ser aprovechados como el papel-cartón, metales, vidrio, textiles o plásticos (DNP et al., 2016).

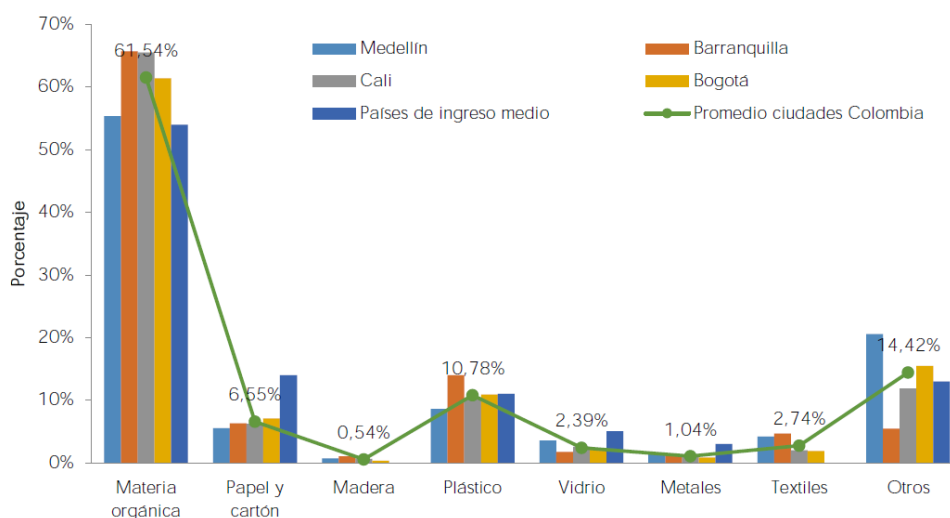


Figura 2.2.- Caracterización de RSU en las ciudades principales de Colombia (Banco Interamericano de Desarrollo (BID), 2016; citado en CONPES 3874)

Como documento base para analizar el sistema de gestión de residuos urbanos en Colombia, se dispone del Reglamento Técnico del Sector de Agua Potable y Saneamiento Básico (RAS) TÍTULO F, donde se determinan los criterios, requisitos mínimos y las buenas prácticas de ingeniería para los procesos asociados a las diferentes componentes del sistema (Minvivienda, 2012).

El servicio ordinario de limpieza constituye la prestación de servicio público domiciliario de recogida de RSU y de cualquier otro tipo de residuos que puedan ser gestionados según las posibilidades asociadas a la capacidad del prestador de este servicio y que no se incluyen dentro de los servicios definidos como especiales (UAESP, 2020b). Los componentes básicos y elementos funcionales de los sistemas de limpieza en Colombia son (Minvivienda, 2012):

- i. almacenamiento y presentación
- ii. recolección de residuos
- iii. barrido manual y mecánico de vías y limpieza de áreas públicas y, cortes y podas en estas áreas
- iv. transporte de residuos y estaciones de transferencia
- v. aprovechamiento

- vi. tratamiento, y
- vii. disposición final y procesos de tratamiento térmico.

La prestación de este servicio debe realizarse de forma eficiente y con la calidad suficiente para que se garantice su funcionamiento de forma continua e ininterrumpida, estableciendo economías de escala y estrategias que establezcan mecanismos que respondan a las necesidades de los usuarios, así como el acceso oportuno a este servicio y su intervención en la prestación (Minvivienda, 2012).

De acuerdo con la Resolución No. 2184 de 2019, en el país se tienen establecidas tres separaciones a partir del 2021:

- una separación para residuos ordinarios, identificada con color negro para separación en la fuente, que corresponden a los residuos que van a ser depositados en el vertedero controlado
- una separación de color verde, para los residuos orgánicos que van dirigidos a plantas de tratamiento según las posibilidades de cada municipio, y
- una de color blanco para los residuos aprovechables, los cuales se gestionan de acuerdo con el esquema establecido en el país para la actividad de aprovechamiento.

Este aprovechamiento incluye la recolección de estos residuos, el transporte selectivo hasta la estación de clasificación y aprovechamiento (ECA) o hasta la planta de aprovechamiento, así como su clasificación y pesaje por parte de la persona prestadora, actividad que de igual forma la pueden realizar las organizaciones de recicladores de oficio que estén en proceso de formalización (Minvivienda, 2021). El aprovechamiento es cobrado vía tarifa a los usuarios según las toneladas efectivamente aprovechadas por los prestadores en su comercialización. Este cobro debe ser regulado y vigilado ya que incide en el usuario, resaltando que las toneladas que se aprovechan dependen del número de recicladores, tipos de transporte, equipos y cantidad y características de las ECAS (Superservicios et al., 2018).

De acuerdo con lo contemplado en la legislación ambiental vigente, los sistemas de disposición final de residuos se pueden clasificar en sistemas autorizados, para los cuales la autoridad ambiental competente otorga licencia ambiental, y en sistemas no autorizados, que son aquellos que no cuentan con una evaluación previa a su ejecución por parte de la autoridad ambiental competente para operar y no cuentan con permisos ambientales. Por ello, los sistemas no autorizados no obedecen a un ejercicio de planificación previo y muy probablemente no cumplen con los requisitos técnicos mínimos de diseño, lo que suele originar impactos ambientales negativos. Los sistemas de disposición final autorizados son los rellenos sanitarios (vertederos controlados), las plantas de tratamiento y las celdas de contingencia. Dentro de los sistemas de disposición final no autorizados se encuentran las celdas transitorias, los botaderos a cielo abierto y, en general, todo aquel sistema que no cumpla con las definiciones, autorizaciones y requerimientos de la legislación medioambiental sectorial colombiana (Superservicios, 2019a).

2.3. Gestión de RSU en la Ciudad de Bogotá y sus localidades

En la ciudad de Bogotá, el proceso de gestión de RSU comienza con el almacenamiento y descarga de los residuos por parte de los generadores. Posteriormente, se continúa con la recolección, añadiendo los residuos del barrido, la limpieza de áreas públicas y el mantenimiento de parques y jardines, corte de césped y restos de poda para el caso de los residuos ordinarios que finalmente son transportados a disposición final al Relleno Sanitario Doña Juana (RSDJ) (Veeduría Distrital, 2018a). Dentro de los residuos generados en la ciudad, existen también las corrientes que van al aprovechamiento a través de los recicladores o de las Organizaciones de Recicladores Autorizadas y otros tipos de residuos, como los peligrosos hospitalarios, peligrosos, especiales y Residuos de Construcción y Demolición (RCD), que van a tratamiento y disposición final a través de un sistema diferente al del servicio de aseo (Veeduría Distrital, 2018a).

Respecto a los sistemas de recogida de RSU que van al relleno sanitario, la ciudad cuenta desde 2018 con un esquema estructurado a través de 5 ASE (Áreas de Servicio Exclusivo), las cuales agrupan varias localidades. Según la distribución administrativa de la ciudad, en Bogotá se tienen 20 localidades, cada una operada por una empresa encargada de esta actividad según la ASE correspondiente. En la tabla 2.1 se muestra el detalle de la distribución correspondiente.

Tabla 2.1.- ASE para la recolección de residuos sólidos en Bogotá

ASE	Localidad por ASE
ASE 1 PROMOAMBIENTAL	Usme, San Cristóbal, Santa Fe, La Candelaria, Chapinero, Usaquén, Sumapaz
ASE 2 LIME S.A E.S.P.	Ciudad Bolívar, Bosa, Tunjuelito, Rafael Uribe, Antonio Nariño, Puente Aranda, Teusaquillo, Los Mártires
ASE 3 CIUDAD LIMPIA	Fontibón, Kennedy
ASE 4 BOGOTÁ LIMPIA	Engativá, Barrios Unidos
ASE 5 ÁREA LIMPIA	Suba

(UAESP, 2020c)

El aprovechamiento se considera una actividad complementaria del servicio público de aseo que incluye los procesos de recolección y transporte de residuos aprovechables, separados en la fuente por los usuarios, hasta la ECA, donde serán separados y clasificados para su comercialización (MVCT, 2016; citado en Superservicios et al., 2018). Los prestadores de la actividad de aprovechamiento deben reportar mensualmente mediante la elaboración de los correspondientes informes en los cuales se detallen las toneladas recibidas en la ECA para clasificación y aprovechamiento y las toneladas de material de rechazo de la actividad de clasificación que tiene como destino final el relleno sanitario y que son recolectados por el prestador de recolección y transporte de residuos no aprovechables. Así, en 2018 se reportaron 781.776 toneladas aprovechadas en la ciudad de Bogotá, incluyendo 28 tipos de material agrupados en 6 familias: metales, papel y cartón, plásticos, vidrios, textiles y maderas (Superservicios, 2019b).

En estudios técnicos de la UAESP se estimó que en 2017 los sectores residencial y comercial de la ciudad de Bogotá generaron aproximadamente 7.000 t/día de residuos, los cuales fueron dispuestos en el relleno sanitario Doña Juana. Estos datos no tienen en cuenta el porcentaje de recuperación actual de reciclaje que se estima alrededor de un 30%. La producción per cápita de residuos (PPC) para la ciudad en este año fue de 0,855 kg/(hab·día). La tabla 2.2 muestra la composición de los residuos caracterizados en 2017 (UAESP, s.f.).

Tabla 2.2.- Composición macroscópica de residuos Bogotá 2017

Material	Porcentaje de generación
Residuos orgánicos	51,32%
Plásticos	16,88%
Celulosas	13,67%
Textiles	4,54%
Vidrios	3,67%
Otros	3,36%
Madera	1,60%
Finos	1,43%
Metales	1,13%
Complejos	0,96%
Inertes	0,84%
Peligrosos domiciliarios	0,61%

(UAESP, s.f.)

La generación de residuos en la ciudad de Bogotá y la cantidad de residuos que se recolecta a través del servicio público de aseo pueden ser evaluados a través de los siguientes indicadores (Veeduría Distrital, 2018a):

- Cantidad de residuos recogidos por el servicio público de aseo
- Cantidad de usuarios del servicio de aseo, es decir a cuántos usuarios (generadores de residuos) se les factura por la recolección
- Producción de residuos per cápita, que da cuenta de la relación entre la producción de residuos y la población
- La composición de los residuos en términos porcentuales, es decir, una comparación entre el tipo de material y la cantidad que se deposita en el RSDJ

Como se ha dicho anteriormente, para la eliminación de los residuos que no son aprovechados, el Distrito cuenta con el RSDJ. En el vertedero se realiza la disposición final a través de llenado por terrazas combinado con un método de área (llenado por niveles). El vertedero de Doña Juana cuenta con licencia ambiental única según Resolución 1351 de 2014 de la Corporación Autónoma Regional de Cundinamarca (CAR) en donde se indica que la vida útil disponible en 2014 era de 7,6 años (Veeduría Distrital, 2018a). Sin embargo, la UAESP ha realizado estudios de detalle sobre la vida útil del RSDJ que indican que ésta se puede prolongar por medio de optimizaciones y adecuaciones de las

zonas que hoy están en operación hasta un máximo de 20,4 años contados a partir del año 2011.

No obstante, el problema ambiental más crítico que presenta este vertedero corresponde a la captación y gestión posterior de sus lixiviados, pues la generación de este líquido percolado es continua y exige que estas sustancias sean depuradas adecuadamente en la Planta de Tratamiento de Lixiviados (PTL) (UAESP y JICA, 2013; citado en Veeduría Distrital, 2018a).

2.4. Normativa aplicable a la gestión de RSU en Colombia

En el Anexo 1 se presenta la normativa principal de aplicación deferente a la gestión de residuos sólidos en Colombia. Su vigencia ha sido verificada a través del Sistema único de normativa del Ministerio de Justicia y del Derecho. Dentro de esta normativa debemos destacar el Decreto 1077 de 2015 “*Por medio del cual se expide el Decreto Único Reglamentario del Sector Vivienda, Ciudad y Territorio*”. Este decreto compila normas ya existentes referentes al servicio público de gestión de residuos, desde el almacenamiento y la presentación de parte del usuario, hasta los criterios técnicos para la disposición final, así como los mecanismos para la atención de los usuarios, además de los deberes y obligaciones de los prestadores del servicio.

2.5. Conceptos asociados a la inteligencia artificial

Recientemente, se han realizado esfuerzos para revolucionar la gestión de sistemas bajo criterios de sostenibilidad y rentabilidad por medio de la implantación de tecnologías avanzadas y sistemas inteligentes (Abdallah, 2020). El reciente desarrollo en nuevas tecnologías de software e internet, junto con la introducción gradual de productos de hardware más compactos y confiables, ha supuesto la capacidad para tratar con precisión diferentes procedimientos asociados a esta área con mayor facilidad (Singh, 2019).

La Inteligencia Artificial (IA) provee sistemas que permiten proporcionar alternativas efectivas para minimizar problemáticas referentes a la toma de decisiones y la gestión de datos de una actividad o proceso determinado. La IA constituye, entonces, una disciplina nueva que ha tenido como modelo las funciones inteligentes del hombre enfocada a diferentes aspectos para proveer soluciones novedosas, más eficientes y mejor planteadas (Ponce, 2010). Al igual que la inteligencia humana, incluye procesos similares a los de percepción sensorial y sus subsiguientes procesos de reconocimiento de patrones. Las aplicaciones de esta área de conocimiento se enfocan al tratamiento de datos y la identificación de sistemas (Benítez, 2014). Solucionar problemas mediante técnicas de IA requiere establecer una secuencia de acciones o decisiones que serán ejecutadas “*por un agente con el fin de alcanzar un objetivo a partir de una situación inicial dada. (...) Según el problema establecido, la ejecución de la secuencia de acciones o decisiones tiene asociado un coste que se tratará de minimizar, o bien un beneficio que se tratará de maximizar*” (Palma, 2008).

Las técnicas de programación utilizadas para la solución de un problema requieren de un algoritmo definido como una secuencia de instrucciones que indica cómo se debe ejecutar en el sistema para lograr el objetivo propuesto, que es la resolución del planteamiento realizado (Basogain, s.f.). Se puede decir, entonces, que un algoritmo es un procedimiento para encontrar la solución a un problema mediante la reducción de este a un conjunto de reglas (Benítez et al., 2014).

Las técnicas de IA se han aplicado a diferentes campos de investigación y de desarrollo, pero también se asocian con la intención de crear entornos que hagan uso de dicha inteligencia. Los campos de estudio más importantes y comunes dentro de la IA son (Ponce, 2010):

- búsqueda de soluciones
- sistemas expertos
- procesamiento de lenguaje natural
- reconocimiento de modelos
- robótica
- aprendizaje de máquinas
- lógica
- incertidumbre y lógica difusa

Son muchos los campos de aplicación de la IA y pueden orientarse dependiendo de las necesidades, requerimientos y tipología de los datos a analizar (APD, 2020). Dentro de los campos actuales de la IA se encuentra el *Machine Learning* (aprendizaje automático), que comprende tres tipologías de algoritmos referentes a métodos que se basan en la cantidad de supervisión humana en el proceso de aprendizaje que pueden ser aplicados según las necesidades y problemáticas a resolver dentro del planteamiento de los modelos. Estas tipologías son el aprendizaje supervisado, el no supervisado y por refuerzo (Serna, 2018). Los términos “inteligencia artificial” y “aprendizaje automático” suelen utilizarse indistintamente, pero la diferencia entre ambos radica en que el aprendizaje automático es una subárea de la IA.

En general, todo aprendizaje automático es una forma de IA, pero no toda la IA es una forma de aprendizaje automático (Franklin Templeton Investments, 2019). A continuación se presentan las características fundamentales de las distintas tipologías de aprendizaje automático.

2.5.1. Aprendizaje supervisado

En el aprendizaje supervisado (*Supervised Machine Learning*), cuyo esquema se muestra en la figura 2.3 se genera un modelo predictivo, basado en datos de entrada y salida en donde se tienen datos previamente etiquetados y clasificados. Con este grupo de datos (datos de entrenamiento) se realiza el ajuste al modelo inicial planteado y el algoritmo va “aprendiendo” a clasificar las muestras de entrada comparando el resultado del

modelo con la etiqueta (respuesta) real de la muestra y realizando los ajustes respectivos según cada error en la estimación del resultado (Luna González, 2020).

Estos métodos de aprendizaje supervisado pueden ser de dos clases: de clasificación o de regresión (Serna, 2018). Algunos de los métodos y algoritmos de aprendizaje supervisado disponibles son los siguientes (Luna González, 2020):

- K vecinos más próximos (*K-nearest neighbors*)
- Redes neuronales artificiales (*Artificial Neural Networks*)
- Máquinas de soporte vectorial (*Support Vector Machines*)
- Clasificador Bayesiano ingenuo (*Naïve Bayes Classifier*)
- Árboles de decisión (*Decision trees*)
- Regresión logística (*Logistic regression*)

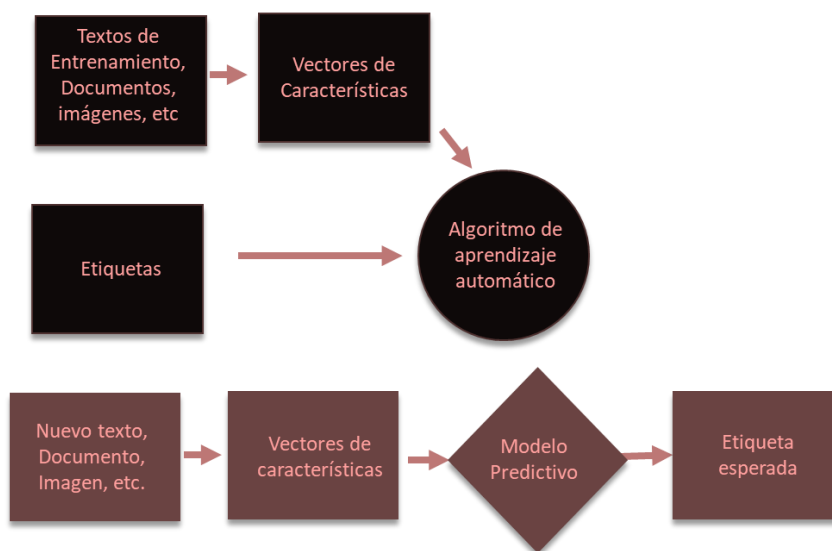


Figura 2.3.- Diagrama de flujo del aprendizaje supervisado (Luna González, 2020)

2.5.2. Aprendizaje no supervisado

La diferencia de los algoritmos de aprendizaje no supervisado (*Unsupervised Machine Learning*) con los supervisados es que sólo ajustan su modelo predictivo tomando en cuenta los datos de entrada, sin importar los de salida. Así, los datos de entrada no están clasificados ni etiquetados de forma que estas características no son necesarias para entrenar el modelo. El esquema de los aprendizajes no supervisados se muestra en la figura 2.4.

En estos modelos de aprendizaje el agrupamiento es el más utilizado, ya que divide los datos en grupos con características similares entre sí, procurando extraer información relevante de los datos en lugar de intentar predecir algún resultado (Luna González, 2020). Estos métodos pueden ser de agrupación, reducción de dimensionalidad, detección de anomalías o de asociación (Serna, 2018). Entre los principales algoritmos de tipo no supervisado destacan los siguientes (Luna González, 2020):

- K-medias (*K-means*)
- Mezcla de Gaussianas (*Gaussian mixtures*)
- Agrupamiento jerárquico (*Hierarchical clustering*)
- Mapas auto-organizados (*Self-organizing maps*)

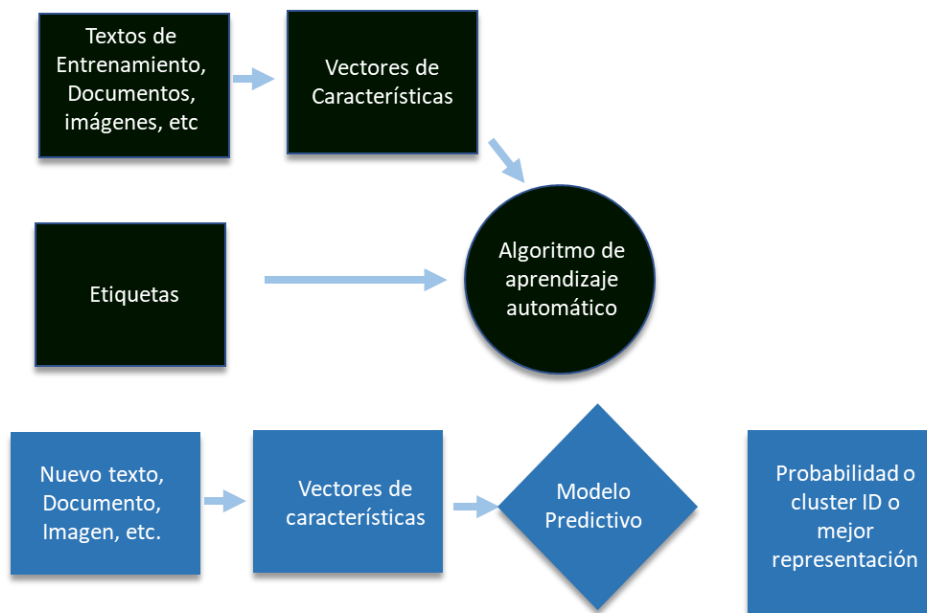


Figura 2.4.- Diagrama de flujo del aprendizaje no supervisado (Luna González, 2020)

2.5.3. Aprendizaje por refuerzo

En las técnicas de aprendizaje por refuerzo (*Reinforcement Learning*) “se tiene un agente que se quiere capacitar durante un período de tiempo para interactuar con un entorno específico” (Serna, 2018). En este aprendizaje se definen modelos y funciones enfocadas en maximizar una medida de “recompensas” basadas en “acciones” y en el ambiente en el que el agente inteligente se desempeñará (figura 2.5). Se trata, por tanto, de un modelo acción-recompensa que busca que el algoritmo se ajuste a la mejor “recompensa” dada por el ambiente y sus acciones.

Entre los algoritmos más utilizados se pueden identificar los siguientes (Luna González, 2020):

- Programación dinámica (*Dynamic programming*)
- *Q-learning*
- SARSA



Figura 2.5.- Diagrama de flujo del aprendizaje por refuerzo (Luna González, 2020)

Dentro del aprendizaje automático se encuentra el concepto de *deep learning* (o aprendizaje profundo), considerado como un subconjunto dentro del aprendizaje automático. Las técnicas de *deep learning* buscan crear modelos capaces de representar conceptos complejos y/o abstractos a partir de otros más sencillos, es decir, pueden crear de forma automática una jerarquía de conceptos, comenzando por conceptos simples, para ir creando conceptos más complejos (Casas et al., 2019). Aunque actualmente se asocia el concepto de *deep learning* con las redes neuronales, existen otros modelos de aprendizaje automático que también son capaces de componer conceptos a partir de una jerarquía de conceptos más simples (Bengio et al., 2016; citado en Casas et al., 2019).

Las aplicaciones de la IA incluyen áreas como la robótica, el análisis de imágenes o el tratamiento automático de textos, siendo la robótica un campo actual de investigación en donde un sistema robotizado explora diferentes configuraciones para realizar, generalmente, un movimiento (Benítez, 2014). En el campo de la ingeniería ambiental, la IA ha sido ampliamente implementada para resolver problemas relacionados con la contaminación atmosférica, la modelación hidráulica y del tratamiento de aguas residuales, la simulación de problemas de suelos contaminados y de contaminación de aguas subterráneas, así como en la planificación de estrategias para la gestión de residuos sólidos (Yetilmezsoy, 2011; citado en Abdallah, 2020).

Asociada directamente a la gestión de los residuos sólidos, la IA se ha utilizado para pronosticar patrones de generación de residuos, optimizar rutas de camiones de recolección, ubicar instalaciones y simular procesos de conversión de residuos, entre otros

(Abdallah, 2020). Una de las etapas clave para poder diseñar sistemas eficientes, dadas las características generales de una población, se da precisamente en la etapa de generación de RSU. La predicción precisa de las cantidades de residuos sólidos generadas tiene un rol importante en la planificación futura y en el diseño de sistemas de gestión integral de residuos, tarea crucial que en la actualidad requiere de disponer de datos precisos (Singh y Satija, 2016).

Dentro de los sistemas de IA utilizados con más frecuencia para la modelación y optimización de procesos relacionados con la gestión de RSU se encuentran:

- las redes neuronales artificiales (RNA)
- las máquinas de soporte vectorial (MSV)
- la regresión lineal (LR)
- los árboles de decisión (DT) y
- los algoritmos genéticos (GA).

En estos problemas relacionados con la gestión de residuos las herramientas más utilizadas para las RNA son las de tipo función de base radial (RBF), perceptrón multicapa (MLP), *backpropagation* o propagación hacia atrás (BP), prealimentadas, autorregresivas y recurrentes.

Además de las RNA, se han utilizado otros modelos como ANFIS, bosque aleatorio (*Random Forest* - RF), transformada *wavelette* (WT), K-medias, minería de datos, Naïve Bayes, conjuntos aproximados, árbol de modelo logístico, agrupación de tipo Q, optimización de colonias de hormigas, estimación de conjuntos no inferiores, programación de objetivos y sistemas inmunológicos artificiales (*Artificial Immune Systems* - AIS) (Abdallah, 2020).

En problemas reales, debido a las incertidumbres y a la falta de disponibilidad de datos suficientes, se necesitan métodos de modelación para la predicción de la generación de RSU, dado que su éxito depende significativamente de la selección del flujo de residuos (Kolekar et al., 2016). En muchas ocasiones, los procesos de modelación de la gestión de RSU involucran variables que pueden ser de difícil manejo debido al comportamiento no lineal que exhiben (Abdallah, 2020). Sin embargo, herramientas como las RNA y las MSV permiten obtener buenos resultados con datos limitados para variables típicamente relacionadas con la gestión de residuos.

Los modelos de predicción de generación de residuos convencionales incluyen los de correlación y regresión, que generalmente utilizan factores demográficos y socioeconómicos. De igual forma, se han utilizado métodos de análisis multivariado (variables más independientes) como análisis de entrada y salida, dinámica de sistemas y los sistemas de inteligencia artificial (Kolekar, 2016). Para poder optimizar las actividades dentro de los procesos de gestión de RSU, se requieren herramientas que permitan analizar los diferentes datos obtenidos en cada actividad de manera que se puedan realizar mejoras que tengan como resultados beneficios ambientales, sociales y económicos. Por ello, se

deben implementar herramientas de modelación y simulación que permitan establecer las relaciones entre las diversas variables involucradas.

2.6. Python como lenguaje de programación

Python es un lenguaje de programación de código abierto, sencillo de aprender, que permite realizar una programación imperativa y funcional de alto nivel. El lenguaje Python tiene como objetivo automatizar procesos con el fin de ahorrar tiempo y evitar complicaciones, por lo que es posible lograr varias soluciones con pocas líneas de código en un programa. *“Su sintaxis es simple, clara y sencilla. El tipado dinámico, el gestor de memoria, la gran cantidad de librerías disponibles y la potencia del lenguaje, entre otros, hacen que desarrollar una aplicación en Python sea sencillo y muy rápido”* (González Duque, s.f.). Este lenguaje es apropiado para trabajar con grandes volúmenes de datos y es versátil dadas sus plantillas, módulos, paquetes, bibliotecas entre otros, por lo que es el preferido para cálculos de ingeniería, cálculos científicos, desarrollo web, videojuegos y otras aplicaciones similares (Centeno, 2019).

Python se considera como un lenguaje de alto nivel y, por tanto, escribir programas en este tipo de lenguajes requiere menos tiempo, ya que los programas son más cortos, son generalmente fáciles de leer y tienen mayor probabilidad de que sean correctos (Downey et al., 2002). Las características fundamentales de Python son las siguientes, según García (2011):

- es un lenguaje interpretado por lo que no es necesaria su compilación
- es dinámico, es decir, no necesita identificar explícitamente los tipos de datos para inicializar variables, de modo que los tipos se validan durante la ejecución del programa
- es fuertemente tipado por lo que no pueden mezclarse tipos
- es un lenguaje multiplataforma (Windows, Mac, Linux, etc.)
- es multiparadigma, imperativo, orientado a objetos y, en menor medida, funcional y con gestión automática de memoria

Como principales librerías y funciones, utilizadas en el desarrollo del presente modelo en Python para las redes LSTM, se destacan:

- *NumPy*: es el paquete fundamental para la computación científica con Python (Centeno, 2019)
- *Pandas*: es una librería para el análisis de datos que cuenta con las estructuras de datos necesaria para limpiar los datos en bruto y hacerlos aptos para el análisis. Realiza alineación de datos para su comparación, fusiona conjuntos de datos, gestiona datos perdidos, etc. (Centeno, 2019), proporcionando herramientas para operar y analizar datos estructurados de forma sencilla (Bonilla, 2017).

- *Matplotlib*: es una librería de gráficos 2D en Python que produce imágenes de calidad, puede generar gráficos, histogramas, espectros de potencia, gráficos de barras, gráficos de error, diagramas de dispersión, entre otros (Centeno, 2019).
- *Scikit-learn*: con esta herramienta se puede realizar aprendizaje supervisado y no supervisado. También se puede utilizar para resolver problemas tanto de clasificación como de regresión (Centeno, 2019).
- *Keras*: es una interfaz de programación de aplicaciones de redes neuronales de alto nivel de experimentación rápida (Centeno, 2019).
- *Tensorflow*: realiza cálculos numéricos mediante diagramas de flujo para *deep learning* y otras aplicaciones de cálculo científico (Centeno, 2019). Es una plataforma de código abierto para crear y usar modelos de aprendizaje automático, la cual implementa algoritmos y patrones comunes necesarios para el aprendizaje automático, ahorrando la necesidad de aprender todas las matemáticas y la lógica subyacentes y permitiendo concentrarse en el problema a resolver (Laurance, 2020).

Como descripción general del modelo implementado en Python, antes de iniciar la programación de la red neuronal, se requiere importar las librerías necesarias, para proseguir con la carga de datos. Posteriormente, se continúa con la definición del modelo, especificando el valor de los argumentos (*tf.keras.layers.LSTM*) y del método de compilación, especificando el optimizador utilizando *model.compile()*. Tras haber definido el modelo y configurado el método de aprendizaje, se continúa con el entrenamiento ajustando dicho modelo a los datos de entrenamiento disponibles, para lo cual se invoca al método *fit()*. Una vez se ha entrenado la red neuronal, se prosigue con la evaluación de su comportamiento con datos nuevos de prueba con el método *evaluate()* (Torres, 2020).

2.7. Redes neuronales artificiales (RNA)

Las técnicas de aprendizaje automático permiten establecer modelos utilizando datos de ejemplo o experiencias pasadas, los cuales identifican patrones o regularidades en los datos para construir buenas aproximaciones a la resolución del problema a través de herramientas que se podrían clasificar como de estimación semiparamétrica, dentro de las que se encuentran las RNA (Palma, 2008).

Las RNA toman su base de las redes neuronales biológicas del cerebro humano, las cuales están conformadas por elementos similares en comportamiento a la neurona biológica, organizados de una forma equivalente a la que presenta el cerebro humano (Basogain, s.f.). Las redes neuronales artificiales (figura 2.6) se consideran una de las técnicas más usuales de aprendizaje automático, las cuales simulan el mecanismo de aprendizaje en organismos biológicos (Aggarwal, 2018). Son sistemas de mapeos no lineales que tienen a las neuronas como unidades de procesamiento y se basan en principios observados en los sistemas nerviosos de humanos y animales. Cada neurona recibe entradas de otros nodos y genera una salida simple escalar que dependen de la información

disponible (Ponce, 2010). Las RNA están compuestas por elementos de procesamiento o neuronas que trabajan uniformemente para resolver un problema (Palma, 2008).




Figura 2.6.- Modelo de neurona estándar
(Martín del Brío y Serrano Cinca, 1995)

Podemos decir, entonces, que una RNA es un procesador distribuido en paralelo formado por unidades de proceso conectadas entre sí y con organización jerárquica, caracterizadas por (García, 2015):

- su capacidad para adquirir conocimientos de tipo dinámico muy complejos que permiten simular y predecir procesos no lineales
- pueden ser dinámicas (adaptativas), permitiendo la representación de procesos y sistemas
- tienen capacidad de aprendizaje y de generalizar casos anteriores a situaciones nuevas
- aprender a reconocer patrones con ruido
- son apropiadas para su funcionamiento en tiempo real
- pueden procesar gran cantidad de datos de forma muy rápida
- son de fácil inserción en la tecnología existente
- son de integración modular

Existe una gran diversidad de tipos de redes neuronales artificiales, pero para que sea factible el uso de una red en una asignación determinada, se pueden distinguir seis aspectos que deben ser definidos (García, 2015):

- i. unidades de proceso o nodos
- ii. regla de combinación de señales de entrada a un nodo (PSP)
- iii. regla para calcular la señal de salida o activación de un nodo (AF)
- iv. patrón de conectividad
- v. regla de propagación de las señales a través de la red
- vi. regla de entrenamiento para adaptar los pesos

La distribución de las neuronas dentro de una red neuronal artificial se organiza formando niveles de un número determinado de neuronas. Si determinadas neuronas artificiales reciben simultáneamente el mismo tipo de información se constituye entonces en una capa (Caicedo y López, 2009).

Para el diseño de una red, es necesario establecer tanto el número capas como de nodos de la red y, de igual forma, las conexiones entre ellos. En la mayoría de aplicaciones en ingeniería se emplean las RNA de conectividad completa, esto es, redes en las cuales “cada nodo oculto está conectado con la totalidad de los nodos existentes en la capa anterior y posterior, mientras que cada nodo de entrada lo está con todos los nodos de la segunda capa, y cada nodo de salida con todos los de la capa anterior” (García, 2015). De esta forma, habitualmente se tienen 3 diferentes tipos de capas (Pérez, 2012):

- la capa de entrada, que recibe información proveniente del exterior
- la capa de salida, que proporciona la salida final proporcionada por la red
- las capas ocultas ubicadas entre las capas de entrada y salida

La neurona artificial recibe entradas de estímulo que pueden provenir del sistema sensorial externo o de otras neuronas con las cuales tiene conexión. Esta información es modificada por un vector de pesos sinápticos cuyos valores se pueden considerar como una ganancia que puede atenuar o amplificar los valores que se desean propagar hacia la neurona.

Los valores que recibe la neurona, modificados por los pesos sinápticos, se suman para producir la entrada neta que va a determinar si la neurona se activa o no, activación que depende de una función denominada función de activación (Caicedo y López, 2009). Tal cual se muestra en la figura 2.7, las funciones de activación más usuales son del tipo escalón (a), lineal (b), sigmoidea (c), tangente hiperbólica (d) y gaussiana (e).




Figura 2.7.- Tipos de función de activación (Palma, 2008)

Una característica fundamental de las RNA es que, con la misma arquitectura, pueden ser capaces de ejecutar tareas diversas y simular diferentes tipos de procesos de naturaleza variada (García, 2015). Se puede decir que la arquitectura de una RNA es la forma como se organizan las neuronas en su interior y está relacionada con el algoritmo de aprendizaje usado para entrenar la red. Según el número de capas, se tienen las redes

monocapa y las redes multicapa. Si se toma como elemento de clasificación la forma como fluye la información, se tienen las redes *Feedforward* y Recurrentes (Caicedo y López, 2009).

Para que una RNA pueda realizar una tarea y sea de utilidad para propósitos de clasificación, simulación, predicción o reconocimiento de patrones, tendencias o propiedades de los datos suministrados, entre otras actividades, es necesario que la red sea entrenada, lo que constituye el proceso de “aprendizaje” de manera que ejecute la actividad asignada de forma efectiva y concreta (García, 2015). Durante este proceso los pesos se van modificando y se van adaptando según el algoritmo utilizado. El conocimiento adquirido por la red durante este entrenamiento queda recogido en la matriz de pesos (Basogain, s.f.). El objetivo del aprendizaje no es memorizar las relaciones entrada/salida que hay en el conjunto de entrenamiento, sino modelar el proceso que ha generado estos datos, lo que hace necesario disponer de un número representativo de ejemplos para el entrenamiento de la red de forma que, una vez entrenada, sea capaz de manejar no sólo los datos de entrenamiento, sino nuevos datos distintos de los primeros, sin que por ello se minimice su rendimiento (Palma, 2008).

Los algoritmos de entrenamiento de las redes pueden ser supervisados o no supervisados. Los algoritmos supervisados requieren del emparejamiento de cada vector de entrada a la red con su correspondiente vector de salida para lo cual es necesario un vector de entrada, calcular la salida y compararla con la salida deseada. El error que resulta se utiliza para realimentar la red y modificar los pesos de acuerdo con un algoritmo que tienda a minimizar el error hasta que sea un valor pequeño y aceptable (Basogain, s.f.). Se parte, entonces, de una serie de entradas y salidas deseadas que la red debería obtener, y el propósito del entrenamiento se centra en aprender la correspondencia entre ambas (Palma, 2008).

Por su parte, en el entrenamiento no supervisado no se requiere de un vector de salidas deseadas. Los vectores de entrenamiento son vectores de entrada en donde el algoritmo de entrenamiento modifica los pesos de la red para generar vectores de salida consistentes. De esta forma, el entrenamiento determina las propiedades estadísticas de los vectores de entrenamiento y agrupa en clases los vectores similares (Basogain, s.f.).

Entre las características y ventajas principales de las redes neuronales artificiales se tienen:

- Capacidad de aprendizaje: la red es capaz de aprender a partir de un conjunto de ejemplos representativos e intenta modelar el problema a solucionar. Esto le permite adaptarse a nuevas situaciones, siempre y cuando exista la información necesaria para realizar el proceso de entrenamiento (Caicedo y López, 2009).
- Asociación: “*para una entrada parcial la red elegirá la entrada más parecida en memoria y generará una salida que corresponda a la entrada completa*” (Basogain, s.f.).

- Generalización: “son capaces de extender su respuesta adecuada a datos que no han sido utilizados en la fase de aprendizaje” (Caicedo y López, 2009).
- Tolerancia a fallos: son tolerables a fallos en los datos (ruido, distorsiones, datos incompletos) dado que no almacenan el conocimiento de forma localizada, sino que este conocimiento está distribuido en toda la red (Caicedo y López, 2009). En caso de que fueran eliminados varios elementos procesadores, o si fueran alteradas las conexiones, el comportamiento de la red se vería modificado mínimamente (Basogain, s.f.).
- Otras ventajas son su capacidad para extraer características fundamentales de los datos a través de la extracción de la información relevante que hay en ciertos de ellos y rechazar aquella que no es importante. Además, tienen capacidad de agrupación, ya que pueden separar la información relevante de la irrelevante en un grupo de datos y son de aprendizaje adaptativo, siendo capaces de adaptarse a nuevas situaciones que se presenten en el sistema y que lleguen a modificar su desempeño. Finalmente, se pueden autoorganizar de acuerdo a cómo estén organizados los datos o en función del objetivo a cumplir (Caicedo y López, 2009).

Las RNA pueden resolver dos tipos básicos de problemas: los problemas de clasificación, en los cuales se trata de crear un procedimiento mediante el cual se realice un reconocimiento de patrones, y los problemas de regresión, que son problemas de ajuste de funciones en donde lo que se requiere es obtener un valor en función de las entradas a la red tratando de encontrar una función continua de ciertas variables (Palma, 2008).

Las RNA son efectivas en procesos de modelación con datos incompletos o conjuntos de datos inciertos. Así, permiten abordar problemas complicados e imprecisos que requieren de la intuición humana y se han aplicado con éxito en diferentes labores referentes a la gestión de residuos sólidos como, por ejemplo, la predicción, generación, clasificación de residuos, generación de biogás, formación de lixiviados, recuperación de energía, temperatura de fusión de residuos y diseño de rutas óptimas de recogida de residuos entre otros (Abdallah, 2020).

Las RNA son uno de los modelos no lineales más populares y se han aplicado recientemente con éxito en la predicción de valores de generación de RSU (Wu et al., 2020). Las RNA se han utilizado para modelar procesos referentes a la gestión de RSU debido a su robustez, tolerancia a fallos e idoneidad para representar las relaciones complejas entre las variables en sistemas multivariados. Además, el proceso de calibración de los sistemas RNA normalmente requiere menos parámetros que los modelos deterministas y, por tanto, son los algoritmos preferibles en tales casos (Abdallah, 2020). Las RNA han encontrado un nicho de aplicación exitoso al efectuar predicciones sobre series temporales o bien al identificar predictores dentro de éstas (Pérez, 2012).

2.7.1. Redes neuronales artificiales recurrentes (RNN)

En este tipo de redes neuronales (figura 2.8), puede haber conexiones que vayan desde una capa posterior hacia una capa anterior. Es decir, cuando la red procesa un registro concreto está utilizando, a la vez, información del propio registro e información que generó la red con el registro anterior (Casas et al., 2019). Las RNN tienen vías de retroalimentación entre todos los elementos que las conforman, “en donde una sola neurona está conectada a las neuronas posteriores en la siguiente capa, las neuronas pasadas de la capa anterior y a ella misma a través de vectores de pesos variables que sufren alteraciones en cada iteración con el fin de alcanzar los parámetros o metas de operación” (Montesdeoca, 2016). Este tipo de red neuronal puede ser monocapa o multicapa (Caicedo y López, 2009).

Las RNN realizan intercambio de información entre neuronas de una manera compleja y, dependiendo del tipo de algoritmo de entrenamiento seleccionado, pueden propagar la información hacia delante en el tiempo (Montesdeoca, 2016).




Figura 2.8.- Esquema de una red neuronal recurrente (Casas et al., 2019)

Este tipo de red se constituye en una de las arquitecturas fundamentales para construir otras arquitecturas de aprendizaje profundo. La diferencia entre una red de múltiples capas tradicional y una RNN es que esta última puede tener conexiones que se realicen en capas anteriores o en la misma capa manteniendo así la memoria de entradas pasadas y modelar problemas en tiempo real, siendo entonces el elemento diferenciador la retroalimentación dentro de la red (Centeno, 2019).

Las redes neuronales recurrentes son redes dinámicas, como la red de Hopfield, la red de Jordan y la red de Elman, o de naturaleza estática pero realimentadas de sus salidas hacia las entradas (Ponce, 2010). “Las redes de Hopfield son capaces de almacenar datos y de recuperarlos incluso cuando se les proporciona una entrada con ruido” (Centeno, 2019). Las redes de Elman son “uno de los tipos más simples de red recurrente, la cual puede ser entrenada también usando el algoritmo estándar de retropropagación”

(Elman, 1990; citado por Giraldo y Hoyos, 2004). En las redes de Jordan, “*la entrada de las neuronas de la capa de contexto se toma desde la salida de la red*” (Campos, 2020).

En general, las conexiones recurrentes en una red neuronal pueden ser de muchos tipos. Es por esto por lo que se define el concepto de “celda” que asocia a una operación con dos entradas y dos salidas que se va componiendo consigo misma a medida que se aplica la operación a los diferentes valores de la secuencia. Los puntos de entrada de la celda corresponden tanto a los valores de la secuencia para cada registro como al estado de la red neuronal en el paso anterior. Por otro lado, los puntos de salida suelen ser el estado de la red en el paso concreto en el que se ejecuta la celda y la respuesta de la red para ese paso (Casas, 2019).

2.7.2. Redes Long Short-Term Memory (LSTM)

Aunque las RNN son capaces de reconocer y predecir secuencias de datos a lo largo del tiempo, soportándose en bucles que permiten que en un momento determinado la salida de la red o de una parte de ella sirva como entrada de la propia red en el siguiente momento, tienen un problema conocido como desvanecimiento del gradiente, lo que les dificulta aprender dependencias de largo alcance. Es decir, cuando se realiza la propagación hacia atrás y se calculan los gradientes de pérdida con respecto a los pesos, los gradientes tienden a ser cada vez más pequeños, por lo que las neuronas en las capas anteriores aprenden muy lentamente en comparación con las neuronas situadas en capas posteriores en la jerarquía (Mañas, 2020).

Para intentar mitigar estos problemas, en 1997 se propuso el uso de una arquitectura de celda muy concreta llamada redes de memoria a corto/largo plazo (*Long Short Term Memory* - LSTM) (Hochreiter y Schmidhuber, 1997). Las entradas de una celda LSTM corresponden tanto al valor de la secuencia en el paso correspondiente como a la concatenación del estado y la salida de la red en el paso anterior (Casas et al., 2019). Mientras que una red neuronal recurrente puede sobrescribir su memoria en cada paso de tiempo de una manera incontrolada, una red LSTM transforma su memoria de una manera precisa, utilizando mecanismos de aprendizaje específicos para definir los datos a recordar, qué datos debe actualizar y cuáles debe tomar en cuenta (Centeno, 2019).

Las redes LSTM han obtenido resultados favorables y el diseño de su arquitectura resulta útil para explorar correlaciones temporales entre los datos. En general, los algoritmos basados en redes neuronales aprenden funciones no lineales y no paramétricas a partir de un conjunto de datos de entrenamiento. Datos tales como series temporales, texto y datos biológicos contienen dependencias secuenciales entre los atributos. En un conjunto de datos de series temporales, los valores de las marcas de tiempo sucesivas están estrechamente relacionadas unas con otras y, si no se usan los valores de estas marcas de tiempo como características independientes, entonces la información clave sobre las relaciones entre los valores de estas marcas de tiempo puede perderse. Por ello, es importante construir modelos que tengan en cuenta la información de secuenciación, por lo que, en estos casos, se usan las redes neuronales recurrentes (Aggarwal, 2018).

Las redes LSTM son capaces de recordar información durante largos períodos de tiempo. Además, igualmente tiene la capacidad de eliminar o agregar información al estado de la celda a través de compuertas que permiten que la información fluya. Estas redes se componen de una capa de red neuronal sigmoidea y una operación de multiplicación puntual (Mañas, 2020). Para evitar tener que concatenar vectores a la salida de un paso para posteriormente separarlos justo al inicio del paso siguiente, se suelen representar las celdas LSTM con tres entradas tal como se representa en la figura 2.9.

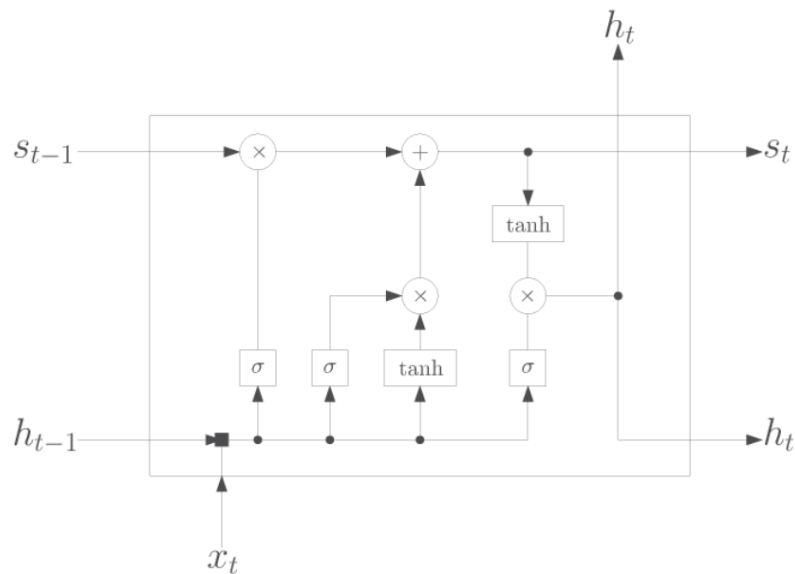


Figura 2.9.- Diagrama de una celda LSTM (Casas et al., 2019)

La primera entrada es la denominada “puerta de olvido”, que observa el valor de entrada a la celda junto con la salida de la red en el paso anterior y decide qué parte de la memoria se debe conservar. La “puerta de entrada” controla qué información se añade a la memoria de la red, y la “puerta de salida”, cuyo proceso es similar al de la puerta de entrada, observa también el valor de entrada a la celda junto con la salida anterior de la red y calcula un vector que marca qué información se emitirá como respuesta (Casas et al., 2019).

Las redes neuronales recurrentes no son capaces de modelar largas dependencias a causa de los problemas de desaparición del gradiente. Sin embargo, en el caso de las redes LSTM, la información del gradiente de la función de coste puede fluir hacia atrás sin multiplicarse consigo misma un número elevado de veces, lo que permite que los valores de entrada en los primeros pasos puedan tener un efecto importante en el entrenamiento de la red, aprendiendo así dependencias entre puntos alejados de una secuencia (Casas et al., 2019).

En múltiples ocasiones, los estudios van encaminados a realizar análisis comparativos entre herramientas, como por ejemplo el análisis de comportamientos entre RNA y árboles de decisión, incluyendo variables socioeconómicas, obteniendo mejores resultados para las RNA (Kannangara, 2018). Resultados similares se obtuvieron para análisis predictivos de residuos sólidos urbanos, comparando estas dos herramientas e incluyendo el análisis con máquinas de soporte vectorial, en donde se obtuvieron los mejores resultados para las MSV, seguido de las RNA y por último para los algoritmos de árboles de decisión (Solano et al., 2019).

Otros estudios han comparado más algoritmos, tales como sistemas inteligentes que incluyen máquinas de soporte vectorial (MSV), sistemas de inferencia neuronal difusa adaptativa (ANFIS), redes neuronales artificiales (RNA) y k-vecinos más cercanos (kNN) para determinar su capacidad de predecir la generación mensual de residuos. Los resultados mostraron que los modelos de inteligencia artificial tienen un buen rendimiento de predicción y podrían aplicarse con éxito para establecer pronósticos de producción de residuos sólidos municipales. En este caso, los modelos con mejor rendimiento fueron ANFIS y kNN (Abbasi y Hanandeh, 2016). Pero, en general, las redes neuronales funcionan mejor que otros métodos más convencionales de tratamiento y procesamiento de la información cuando el modelo a resolver es no lineal y el entorno de trabajo es muy variable (Martín del Peso, 2005), siendo el principal potencial de las RNA detectar no-linealidades en series temporales (Villada et al., 2016).

Para análisis de series temporales, la aplicación de las RNA ha demostrado un amplio potencial en el pronóstico dada su adaptabilidad, generalización, aprendizaje y la posibilidad de representar relaciones no lineales. Al contrario, los modelos de Box-Jenkins o ARIMA, suponen que las series de tiempo son generadas a partir de procesos lineales (Zhang et al., 1998; citado en Menacho, 2014). De esta forma, la tarea de crear un modelo predictivo de series temporales es compleja, ya que tienen la necesidad de analizar la información pasada en la secuencia de entrada. Las redes neuronales convencionales no son aptas para resolver este problema, pues no tienen forma de considerar la variable temporal. Las redes neuronales recurrentes, por otra parte, sí tienen la habilidad de manejar la dependencia en la secuencia (Granados, 2019).

Por ello, para tareas de predicción se emplean redes de tipo *Long Short Term Memory*, “las cuales son ampliamente utilizadas en problemas de predicción en series temporales debido a que su diseño que permite recordar la información durante largos períodos y facilita la tarea de hacer estimaciones futuras empleando registros históricos” (González et al., 2017).

2.8. Máquinas de Soporte Vectorial (MSV)

Una máquina de soporte vectorial (*Support Vector Machine* - MSV) es un algoritmo informático que aprende a asignar etiquetas a los objetos (Boser, Guyon et al., 1992;

citado en Noble, 2006). Básicamente, una MSV es un algoritmo para maximizar una función matemática particular con respecto a una variable dada una recopilación de datos (Noble, 2006). Las MSV mejoran el clasificador lineal buscando un mejor hiperplano que el que se genera con el clasificador lineal (Benitez et al., 2014). Una MSV en primera instancia mapea los puntos de entrada a un espacio de características de una dimensión mayor (figura 2.10). Por ejemplo, “si los puntos de entrada están en \mathbb{R}^2 , entonces son mapeados por la MSV a \mathbb{R}^3 , y encuentra un hiperplano que los separe y maximice el margen m entre las clases en este espacio”.




Figura 2.10.- Definición de la frontera de decisión para MSV (Betancourt, 2005)

Las MSV seleccionan el hiperplano con margen máximo de entre todos los posibles hiperplanos que separan los ejemplos positivos de los negativos (el que tiene la misma distancia entre estos dos), determinando el hiperplano a partir de los llamados vectores de soporte, que suelen ser los puntos más cercanos al hiperplano y los que lo definen (Benítez, 2014).

A manera de consideración, se presenta un ejemplo en \mathbb{R}^2 para el cual hay que construir un clasificador para separar dos tipos de puntos. En la figura 2.11, se muestran tres hiperplanos válidos que separarían los dos grupos de puntos.




Figura 2.11.- Ejemplo de hiperplanos posibles
(Benítez et al., 2014)

Se podrían encontrar infinitos hiperplanos, pero una vez escogido un hiperplano para clasificar un conjunto de puntos, se puede generar una regla de clasificación que se puede definir por la ecuación (Benítez et al., 2014):

$$h(x) = \text{signo} \left(b + \sum_{i=1}^N w_i \cdot x_i \right)$$

donde N es el número de atributos, el vector $w = \{w_1, \dots, w_N\}$ y b definen al hiperplano y $x = \{x_1, \dots, x_N\}$ al ejemplo a clasificar. Así el hiperplano seleccionado sería aquel que deja a más distancia a todos los puntos (figura 2.12). La recta que pasa más alejada de los puntos de las dos clases se denomina margen y los puntos marcados a los vectores de soporte son aquellos puntos que están rozando el margen (Benítez, 2014). De este modo, sin ningún conocimiento del mapeo, “la MSV encuentra el hiperplano óptimo utilizando el producto de cada punto con funciones en el espacio de características que son llamadas kernels” (Betancourt, 2005).




Figura 2.12.- Definición de la frontera de decisión para MSV
(Benítez et al., 2014)

Si los puntos no tienen una distribución que se pueda separar linealmente sería mejor utilizar una curva en lugar de una recta. Para ello sería necesario cambiar de kernel, es decir, la función de proyección entre espacios (Benítez et al., 2014). Por tanto, un kernel es una función de separación local de los datos. Estas funciones interponen un plano de separación entre un conjunto de datos cercanos (localmente) y su objetivo es proporcionar una solución al agregar una dimensión adicional a los datos de acuerdo con el tipo de problema (Noble, 2006). Los kernels más utilizados son los del tipo lineal, polinomial y las funciones de base radial.

Las MSV son algoritmos supervisados de aprendizaje automático útiles para análisis de datos (Dixon y Candade 2007; Hasituya et al., 2016; citados en Abdallah, 2020). Estas herramientas funcionan como clasificadores no paramétricos capaces de resolver problemas de clasificación debido a su habilidad para maximizar las separaciones mientras minimizan los errores de clasificación (Abdallah, 2020).

A pesar de que se aplicaron inicialmente para abordar problemas de clasificación, las MSV se han utilizado para resolver problemas de regresión, ya que se encontró que superaban a varias técnicas clásicas de regresión (Abdallah, 2020). Estos algoritmos son menos susceptibles al sobreajuste y son expertos simultáneamente en reducir las estimaciones de error y las dimensiones del modelo, a diferencia de procedimientos estadísticos como el análisis de componentes principales (PCA) que abordan solo la dimensionalidad del modelo (Li, 2009; citado en Abdallah, 2020).

Esta herramienta se ha utilizado en diversas áreas de ingeniería ambiental, por ejemplo para modelar el índice de contaminación del aire (Leong et al., 2019), el diseño de

sistemas de identificación de residuos sólidos plásticos basado en espectroscopía de reflectancia de infrarrojo cercano (NIR) en combinación con MSV (Zhu et al., 2019), para la predicción en la generación de energía fotovoltaica (Ling et al., 2020), para el análisis de modelos de radiación solar global diaria y su respectiva comparación (Yao et al., 2018) y para el diseño de herramientas eficaces para predecir la biodegradabilidad de los productos químicos orgánicos (Tang et al., 2020), entre otros estudios asociados a este área de conocimiento.

En el campo de los residuos sólidos, se han utilizado para la predicción de nivel de llenado de contenedores, generación de residuos, clasificación de residuos, recuperación de energía y determinación de la capacidad calorífica de los residuos (Abdallah, 2020). En muchos casos, las MSV son mejoradas para el desarrollo de modelos, en donde se pueden combinar, por ejemplo, con la técnica de análisis de componentes principales (PCA) para hacer pronósticos en la cantidad de residuos generados (Noori et al., 2009).

Para realizar las modelaciones, se han utilizado varias plataformas y bibliotecas de software de IA en donde MATLAB es la más común, particularmente en el entrenamiento y las pruebas de redes neuronales y algoritmos MLP (Chhay et al., 2018; Jahandideh et al., 2009; Jalili y Noori, 2007; Korhonen y Kaila, 2015; Elmira et al., 2011; Shu et al., 2006; You, 2017; citados en Abdallah, 2020). Otra herramienta de simulación de uso común fue SPSS, usada para correlacionar entre atributos como la densidad de población y la generación de residuos (Pan et al., 2019; Golbaz et al., 2019; Lu, 2019; citados en Abdallah, 2020). El software R es experto en eliminar los valores atípicos de los conjuntos de datos, particularmente en simulaciones de generación de residuos (Lu et al., 2015; Kumar et al., 2018; citados en Abdallah, 2020). Los lenguajes C++ y Python se utilizaron para simular modelos de IA. C++ tiene múltiples bibliotecas que incluyen OpenNN, OpenCV, BOOST, gflags, glog y Tensor Flow. De forma similar, Python contiene Tensor Flow junto con otras bibliotecas como Spyder, Matplotlib y Utils (Abdallah, 2020).

3. Datos disponibles

3.1. Caso de estudio

Se presenta en este capítulo el caso de estudio, el cual es un componente fundamental dentro de la investigación desarrollada para la identificación de las características particulares de la zona y la determinación de variables para el modelo. En el presente trabajo, se seleccionó como área de análisis dos localidades de la ciudad de Bogotá, llamadas Engativá y Suba. A continuación, se describen las características generales de estas dos localidades en el marco de la megaciudad de Bogotá (Colombia) para comprender la complejidad que presenta en la zona la gestión de los RSU. De igual forma, este capítulo describe los datos utilizados posteriormente para el planteamiento de la propuesta metodológica.

3.1.1. Características generales del área de estudio

Colombia cuenta con una extensión territorial de 1.141.748 km², a los cuales se suman la plataforma marina y submarina. Administrativamente, Colombia se divide en 32 departamentos, 1123 municipios, “*cinco entidades territoriales con una administración especial (Bogotá y las ciudades puerto de Cartagena, Barranquilla, Santa Marta y Buenaventura), (...) las entidades territoriales indígenas, y los territorios colectivos adjudicados a comunidades afrocolombianas en zonas del Pacífico*” (PNUD, 2020).

De acuerdo con la Política Nacional para Consolidar el Sistema de Ciudades en Colombia (Documento CONPES 3819), se estima que el país contará con 64 ciudades con más

de 100.000 habitantes en el año 2035, en las que habitarán el 83% de la población, por lo cual será necesario garantizar servicios públicos con calidad y continuidad, dado que se estima, de igual forma, que la generación de residuos se incrementará (DNP et al., 2016).

En 2018 en Colombia, se generaron alrededor 30.973 t/día de residuos sólidos, que corresponden a aquellos residuos recolectados y transportados a través del servicio público domiciliario de aseo, y que posteriormente son registrados en los diferentes sistemas de disposición final, los cuales son operados por prestadores de este servicio (Superservicios, 2019a). En el país aún persisten problemas asociados a la gestión de residuos sólidos urbanos, como lo son los pocos incentivos económicos, normativos y regulatorios para minimizar la generación de residuos sólidos y aumentar los niveles de aprovechamiento y tratamiento de estos (DNP et al., 2016).

Es así como una de las problemáticas actuales con mayor afección en el país y en algunas ciudades, de forma crítica, es el crecimiento año a año en la generación de RSU. Resulta, por tanto, del todo necesario adaptar los sistemas de gestión de estos residuos de forma adecuada. Actualmente, la separación en la fuente no es suficiente y, por tanto, no hay garantía para el tratamiento de estos residuos. Aunque es necesario definir los roles específicos que permitan impulsar su gestión, no existe suficiente información para sustentar la toma de decisiones y así realizar su seguimiento. Además, faltan incentivos económicos para aumentar los niveles de aprovechamiento y tratamiento de residuos, lo cual, junto con las limitadas estrategias para su prevención y minimización conlleva que la gran mayoría de los RSU generados terminen en los rellenos sanitarios (DNP et al., 2016).

De acuerdo con el informe realizado y presentado por la Superintendencia de Servicios Públicos Domiciliarios, para el año 2019 Colombia cuenta con “308 sitios de disposición final para la recepción de residuos sólidos, de los cuales 192 son autorizados y 116 no son autorizados” (Superservicios, 2019a). Los residuos dispuestos en Colombia (51,41%) se concentran en el Distrito Capital y 3 departamentos: “Bogotá, D.C. (6.366,24 t/día, 20,55%), Valle del Cauca (3.592,68 t/día, 11,60%), Antioquia (3.575,26 t/día, 11,54%) y Atlántico (2.387,50 t/día 7,71%)” (Superservicios, 2019).

En la figura 3.1, se presenta la descripción gráfica de la generación de residuos sólidos en el país. “En contraposición, los departamentos que menos reportan toneladas dispuestas son Vaupés (3,70 t/día, 0,01%), Amazonas (8,42 t/día, 0,03%), Guainía (11,84 t/día, 0,04%) y Vichada (24,12 t/día 0,08%)” (Superservicios, 2019a).

La figura 3.2 muestra gráficamente la PPC de residuos sólidos en Colombia. La población utilizada para realizar los cálculos corresponde a la proyección de la población elaborada por el Departamento Administrativo Nacional de Estadística (DANE) para el año 2018. En promedio, a nivel departamental, el hecho de contar aún con sistemas no autorizados constituye un problema que debe ser atendido para evitar riesgos a la salud humana e impactos ambientales negativos generados por esta disposición inadecuada (Superservicios, 2019a), tal cual se muestra en la figura 3.3.

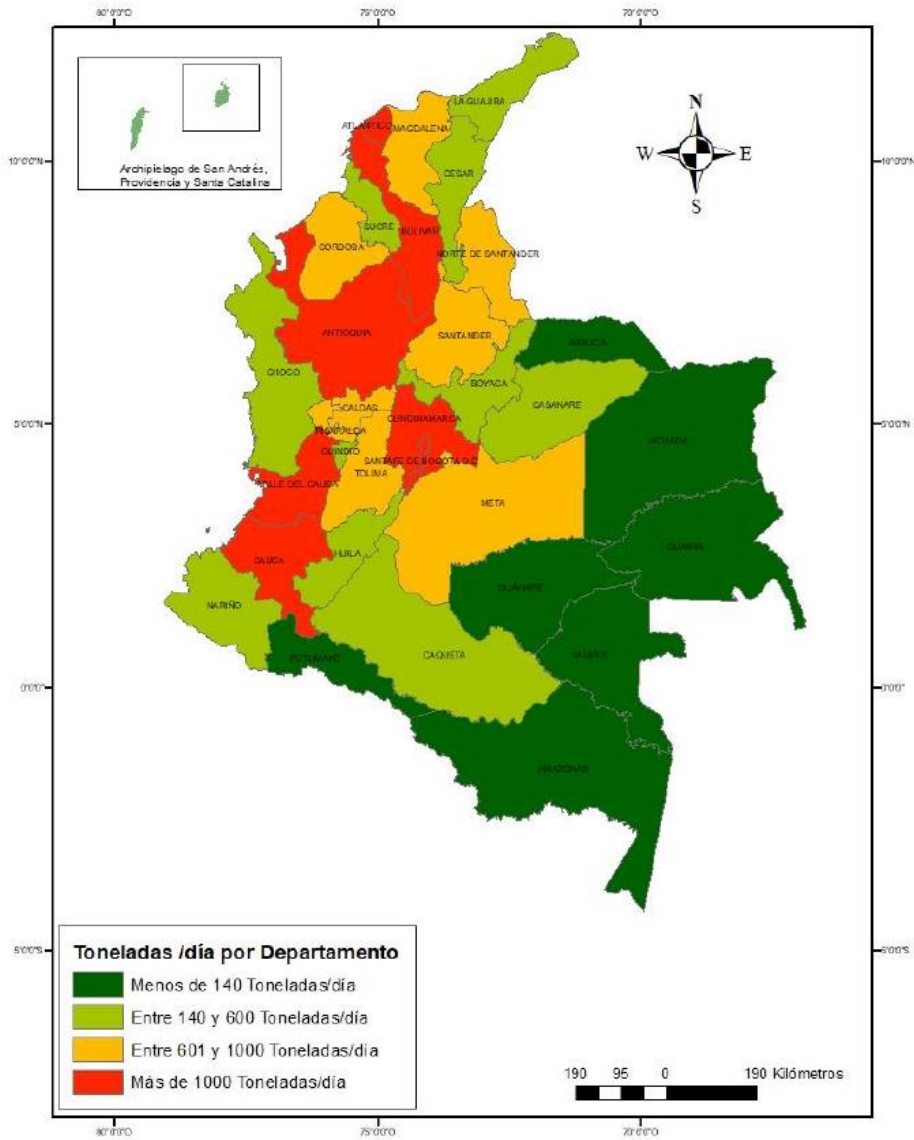


Figura 3.1.- Generación media de RSU por departamento (t/día)
(Superservicios, 2019)

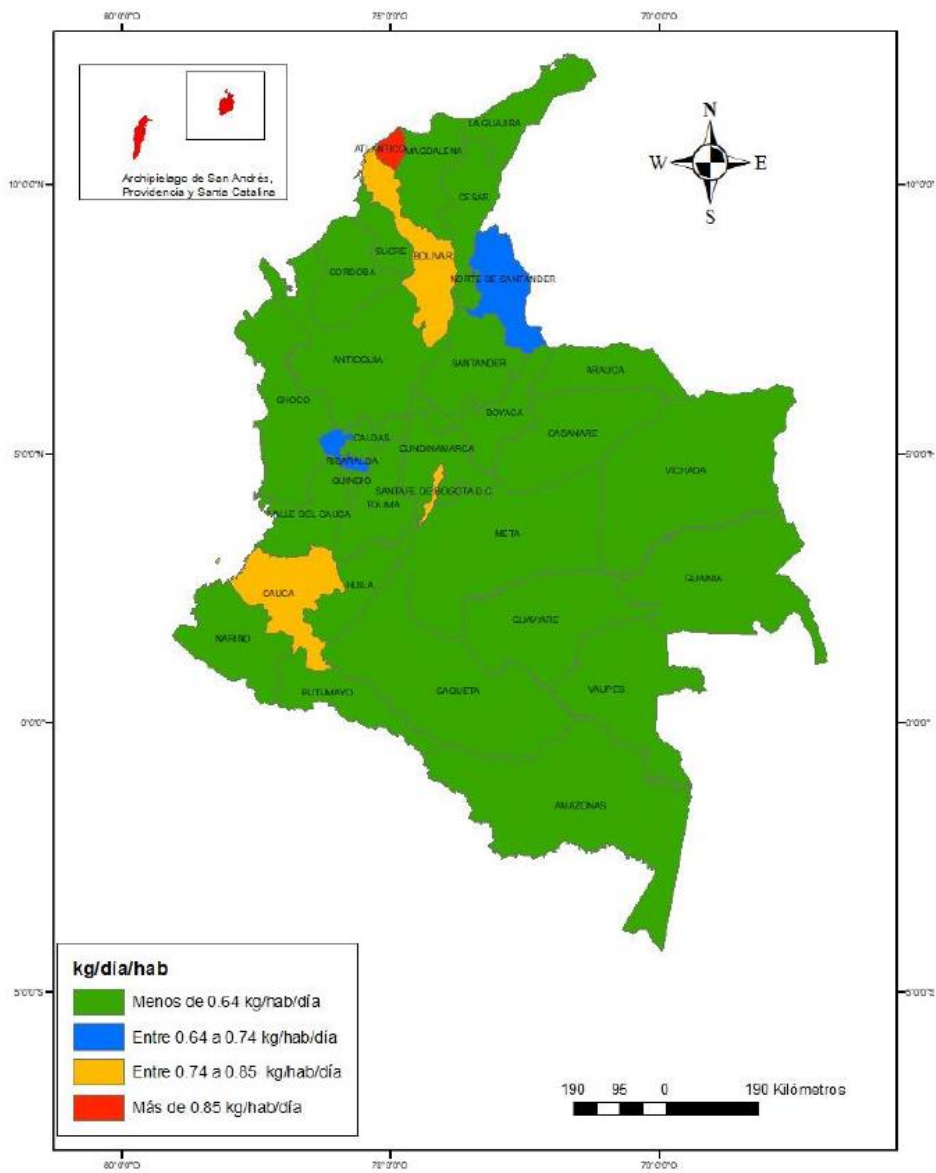


Figura 3.2.- PPC de RSU por departamento (t/día)
(Superservicios, 2019a)

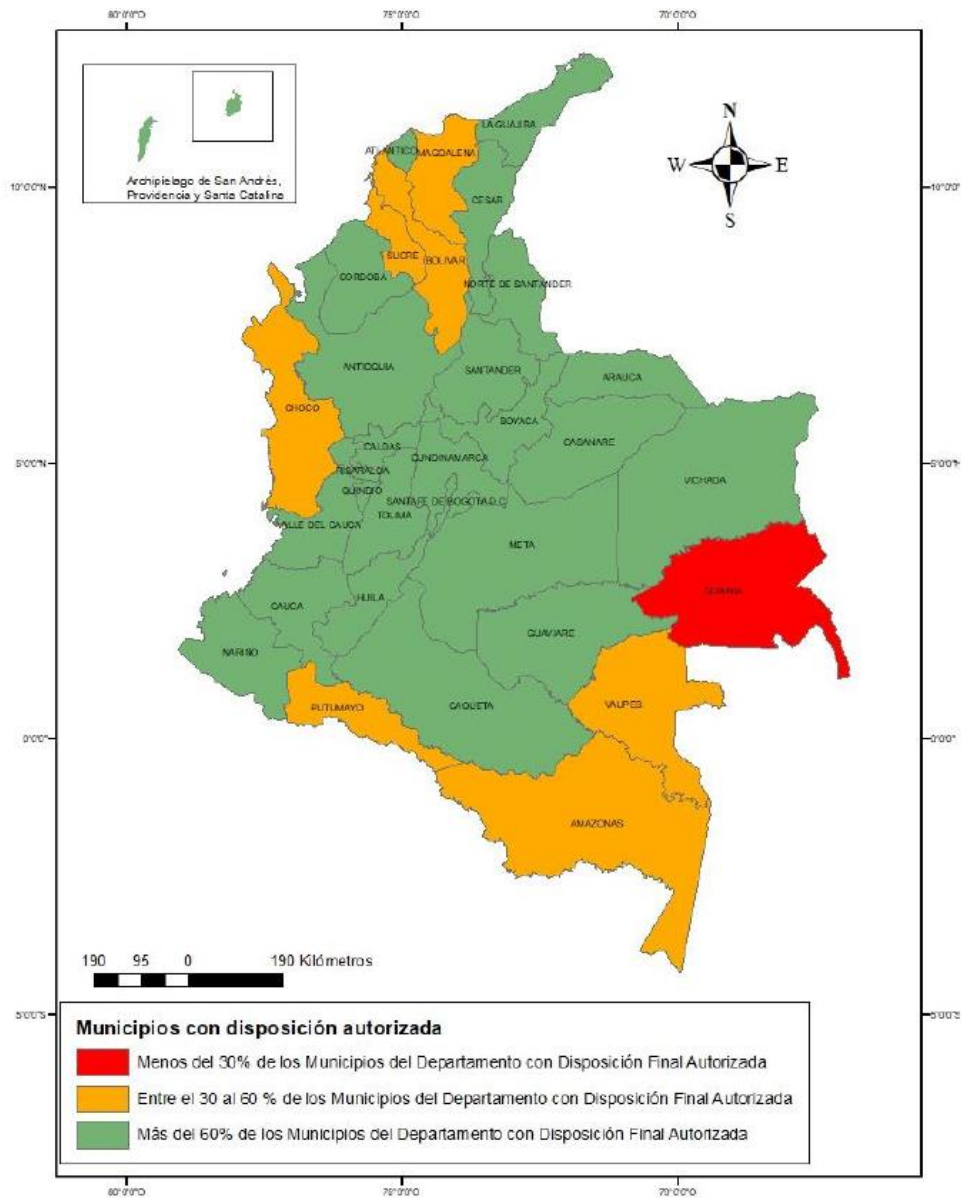


Figura 3.3.- Disposición final autorizada por departamentos.
(Superintendencia de Servicios Públicos Domiciliarios, 2019)

“Bogotá tiene una extensión de 163.635 hectáreas de territorio de las cuales 37.972 hectáreas (23,2%) son de suelo urbano, 122.687 hectáreas son de suelo rural (75%) y 2.974 hectáreas corresponden a suelo de expansión (1,8%)” (Alcaldía Local de San Cristóbal, 2019). Según la información proporcionada por el estudio “Proyecciones de población por localidades para Bogotá 2016-2020” de la Alcaldía de la ciudad, la población de Bogotá en el año 2020 es de 8.380.801 habitantes (Alcaldía de Bogotá y Secretaría de Planeación, 2014).

Bogotá cuenta con un clima subtropical serrano, con temperatura promedio de 14,5 °C. En días claros y soleados, la temperatura varía desde 4 a 19°C, y entre 10 a 18°C cuando llueve (JICA y UAESP, 2013). Se espera que la población para Bogotá crezca año a año. Sin embargo, de acuerdo con las proyecciones del DANE, la magnitud del crecimiento será menor para los próximos años. Este comportamiento se justifica por el descenso de la natalidad en la ciudad. Para los años entre 2010 y 2015 este crecimiento fue de 1,5% (Alcaldía de Bogotá y Secretaría de Planeación, 2014).

Bogotá está subdividida administrativamente en 20 localidades (figura 3.4): Usaquén, Chapinero, Santa Fe, San Cristóbal, Usme, Tunjuelito, Bosa, Kennedy, Fontibón, Engativá, Suba, Barrios Unidos, Teusaquillo, Los Mártires, Antonio Nariño, Puente Aranda, La Candelaria, Rafael Uribe, Ciudad Bolívar y Sumapaz (Secretaría Distrital de Gobierno, 2020).



Figura 3.4.- Mapa de localidades de Bogotá
(Secretaría Distrital de Gobierno, 2020)

Sumapaz, completamente rural, es la localidad con mayor extensión (78.096 hectáreas). Por otra parte, la menos extensa es La Candelaria con 206 hectáreas (Alcaldía Local de San Cristóbal, 2019). Respecto al grado de eficiencia de los servicios públicos, según el censo de 2018, el 99,8% de los hogares de Bogotá manifiesta tener cobertura de abastecimiento de agua, el 99,9% tiene alcantarillado, el 99,7% tiene cobertura de recolección de basuras, el 99,9% cuenta con energía eléctrica y el 74,1% de las viviendas de Bogotá

tienen servicio de internet (fijo o móvil) (Alcaldía Local de San Cristóbal, 2019). Asociado a estos servicios públicos, se tiene la estratificación socioeconómica que define como “la clasificación en estratos de los inmuebles residenciales que deben recibir servicios públicos se realiza principalmente para cobrar de manera diferencial por estratos los servicios públicos domiciliarios permitiendo asignar subsidios y cobrar contribuciones en esta área” (DANE, 2020).

En el campo de la gestión de residuos sólidos, han sido establecidas estrategias como los programas “Basura Cero” y el “Plan de Inclusión de la Población Recicladora en la Gestión Pública de los Residuos” (JICA y UAESP, 2013), ambos de gran importancia para la ciudad. En el mes de marzo del año 2020 fueron recolectados alrededor de 196.138 t/mes de RSU (UAESP, 2020a).

La ciudad cuenta actualmente con un esquema de recolección de RSU dividida en 5 ASE (Áreas de Servicio Exclusivo) cada una de ellas operada por una empresa prestadora del servicio como ha sido mencionado anteriormente (tabla 2.1 y figura 3.5) (UAESP, 2020b).

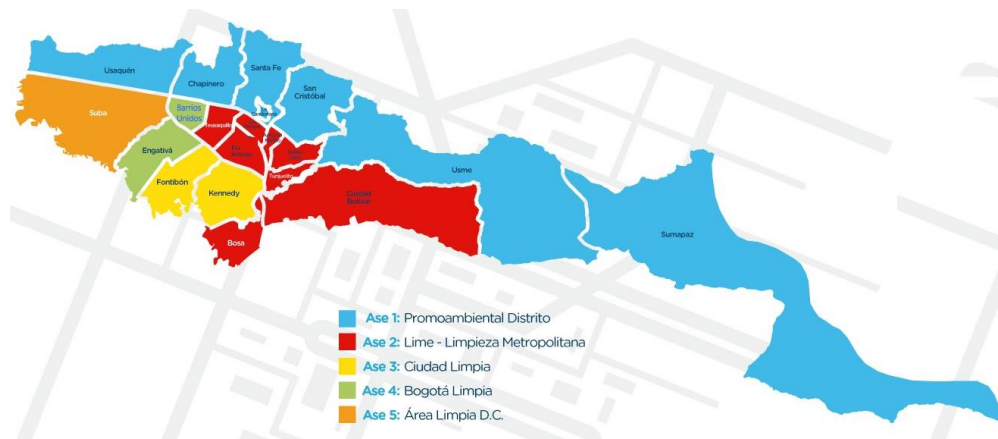


Figura 3.5.- Esquema de recolección de residuos sólidos en la ciudad de Bogotá (UAESP, 2020b)

Como entidades asociadas a la gestión de residuos sólidos, los prestadores del servicio de aseo se encargan de la recolección y transporte de los residuos domiciliarios presentados por los usuarios, para su correspondiente disposición en vertederos controlados. El Ministerio de Vivienda, Ciudad y Territorio formula las políticas y reglamentaciones relacionadas con el servicio público de aseo. El Ministerio de Ambiente y Desarrollo Sostenible se encarga de emitir las directrices para la gestión de los residuos. Las Corporaciones Ambientales ejercen control ambiental en su jurisdicción. La Comisión de Regulación de Agua Potable y Saneamiento Básico-CRA regula la prestación del servicio público de aseo y la Superintendencia de Servicios Públicos es la encargada de vigilar y controlar la prestación de este servicio (DNP, 2016).

Además de los prestadores del servicio, se encuentra la Unidad Administrativa Especial de Servicios Públicos (UAESP) la cual *“tiene por objeto garantizar la prestación, coordinación, supervisión y control de los servicios de recolección, transporte, disposición final, reciclaje y aprovechamiento de residuos sólidos, la limpieza de vías y áreas públicas; los servicios funerarios en la infraestructura del Distrito así como el servicio de alumbrado público”* (Secretaría Distrital del Hábitat, 2020). Bogotá cuenta con un Plan de Gestión Integral de Residuos Sólidos (PGIRS), el cual es una herramienta fundamental y se convierte en la hoja de ruta dentro del establecimiento de un esquema de prestación del servicio de aseo (Alcaldía de Bogotá, 2016).

El documento elaborado por la JICA para la UAESP en el 2013 indica que la vida útil del RSDJ se puede prolongar por medio de optimizaciones y adecuaciones a las zonas que hoy están en operación, extendiéndose la vida útil a 20,4 años contados a partir del año 2011 (Veeduría Distrital, 2018a). Sin embargo *“el 2 de octubre de 2015 ocurrió un deslizamiento de aproximadamente 370.000 toneladas de residuos en la zona operativa del relleno. Como consecuencia de este evento, se han evidenciado afloramientos de lixiviados en el área afectada, deficiencia en la cobertura de residuos, aumento en el indicador de vectores y afectación en la vida útil efectiva”* (Superservicios, 2018).

El último incidente ocurrido en el vertedero de Doña Juana se dio en 2020 cuando se presentó un deslizamiento de 60.000 toneladas de basura, según la UAESP (Revista Semana, 2020). Es así como, además de realizar operaciones de optimización en este sitio de disposición, se hace necesario identificar nuevas zonas de disposición final para Bogotá, así como la búsqueda de alternativas para disminuir el impacto sobre el vertedero a través de actividades como la disminución en la generación de residuos, la maximización del aprovechamiento de los residuos o el tratamiento de la materia orgánica (Veeduría Distrital, 2018a), entre otras estrategias.

3.1.2. Localidad de Suba

El presente estudio se ha realizado tomando como base de análisis las localidades de Suba y Engativá. Suba está situada en el norte de Bogotá, posee zonas verdes y humedales, cuenta con zonas residenciales, industriales y comerciales y se caracteriza por ser la más poblada, con más de un millón de habitantes (Alcaldía de Bogotá, 2020a). Suba cuenta con una extensión total de 10.055,98 ha, de las cuales 6.033,67 ha se clasifican como suelo urbano, 880 ha como suelo de expansión y 3.141,31 ha corresponden a suelo rural. Dentro de estas áreas se localizan 1.754,66 ha de suelo protegido. Esta localidad cuenta con la mayor área urbana del Distrito, con el 15,7% de dicha superficie (Alcaldía de Bogotá et al., 2004).

La figura 3.6 muestra el mapa general de la ciudad de Bogotá, la ubicación de la localidad de Suba en la misma y la ficha de caracterización para Suba, que describe aspectos como extensión, población y tipo de suelo de la localidad. En cuanto a generación de residuos sólidos, en marzo del año 2020 se reportó una recolección de residuos sólidos de 26.715,12 toneladas (UAESP, 2020a).

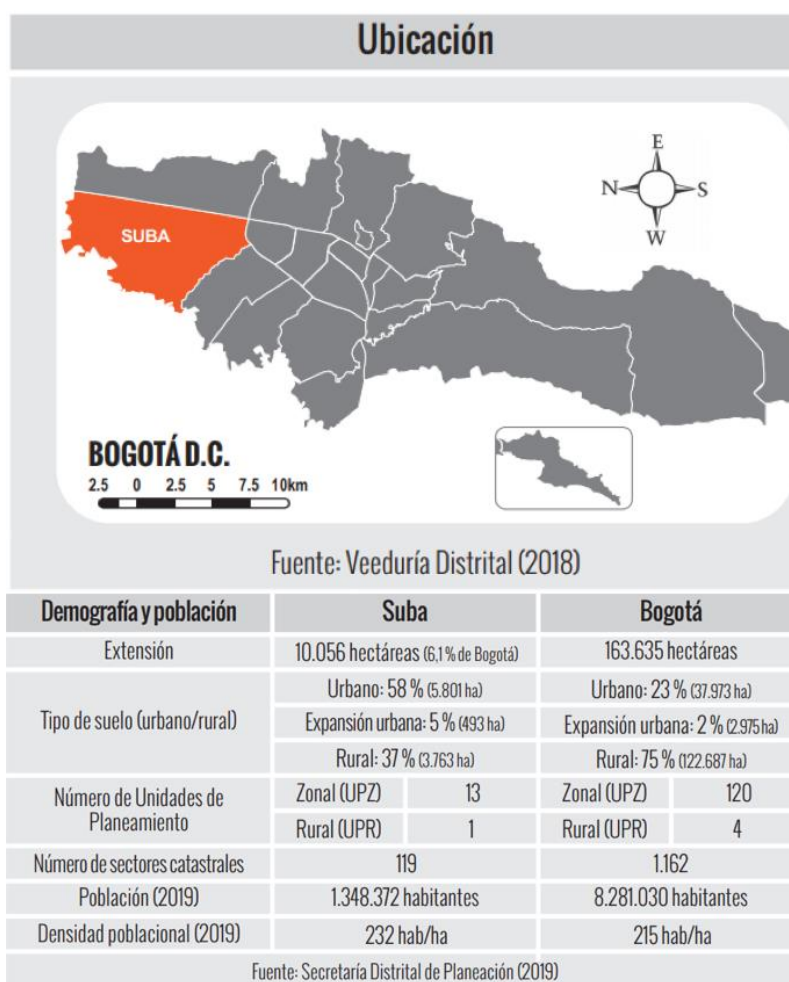


Figura 3.6.- Mapa general de Bogotá con la ubicación de la localidad de Suba (Veeduría Distrital, 2019)

Según el Plan de Ordenamiento Territorial (POT), la localidad de Suba está dividida en 12 Unidades de Planeación Zonal (UPZ) (figura 3.7) y una Unidad de Planeación Rural (UPR) (Alcaldía Local de Suba, 2017).

Suba se encuentra ubicada geográficamente en una zona privilegiada desde el punto de vista ambiental, paisajístico y ecológico, compuesta por los Cerros de Suba, las cuencas de los ríos Bogotá y Juan Amarillo, los humedales denominados Juan Amarillo, la Conejera, Córdoba y 27 Quebradas, ecosistemas intermedios entre el medio acuático y el terrestre, que sirven de albergue transitorio de las aves que recorren países y continentes (SDP, 2011). Al igual que en el resto de problemáticas de la ciudad, “la deficiencia en

el tratamiento de aguas residuales domésticas y la disposición de residuos sólidos domésticos e industriales, entre otros, son los aspectos de mayor relevancia en esta localidad” (Alcaldía Local de Suba, 2017).

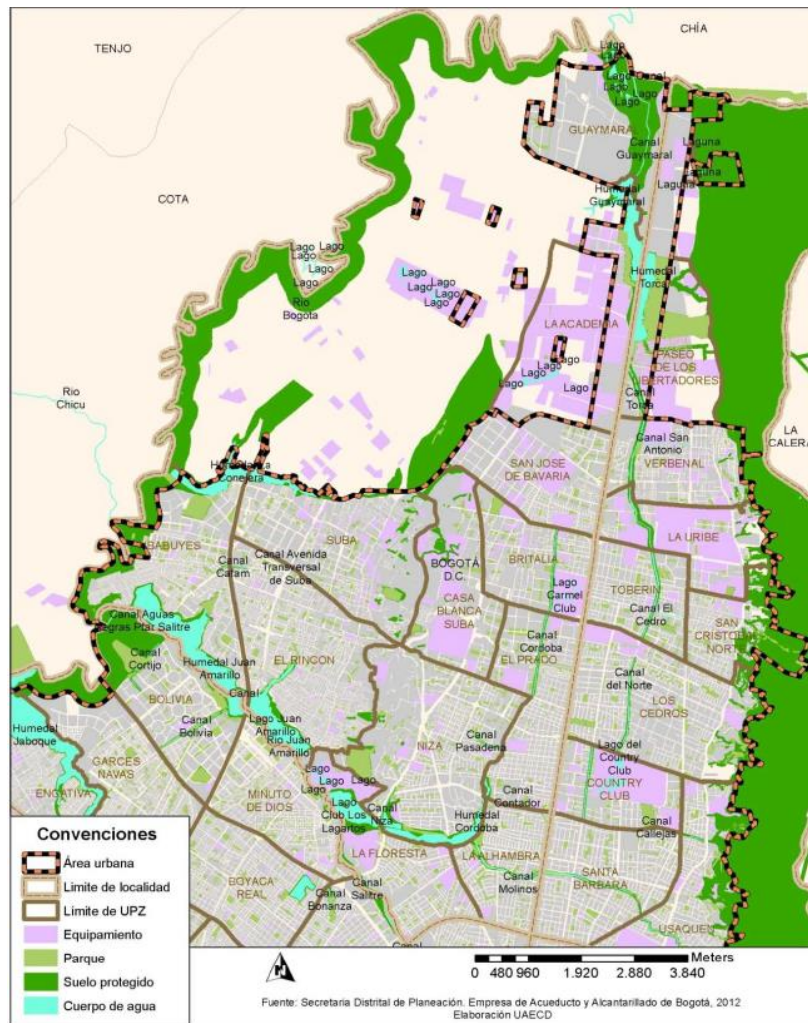


Figura 3.7.- Mapa general de la localidad de Suba (Mejía, 2017)

3.1.3. Localidad de Engativá

Engativá se encuentra en el occidente de la ciudad de Bogotá y cuenta con una población de 878.434 habitantes en el año 2017. En ella se encuentra “*el sector de Las Ferias (principal eje económico) y el eje vehicular de la Avenida El Dorado con varias industrias aledañas al Aeropuerto el Dorado*” (Alcaldía de Bogotá, 2020b). La figura 3.8 muestra el mapa general de la ciudad de Bogotá y la ubicación de la localidad de Engativá en el mismo. La ficha de caracterización de Engativá describe aspectos como extensión, población y tipo de suelo. En cuanto a generación de residuos sólidos, para marzo del año 2020 la localidad de Engativá junto con la localidad de Barrios Unidos reportó una recolección de residuos sólidos de 24.967,06 toneladas (ASE 4) (UAESP, 2020a).

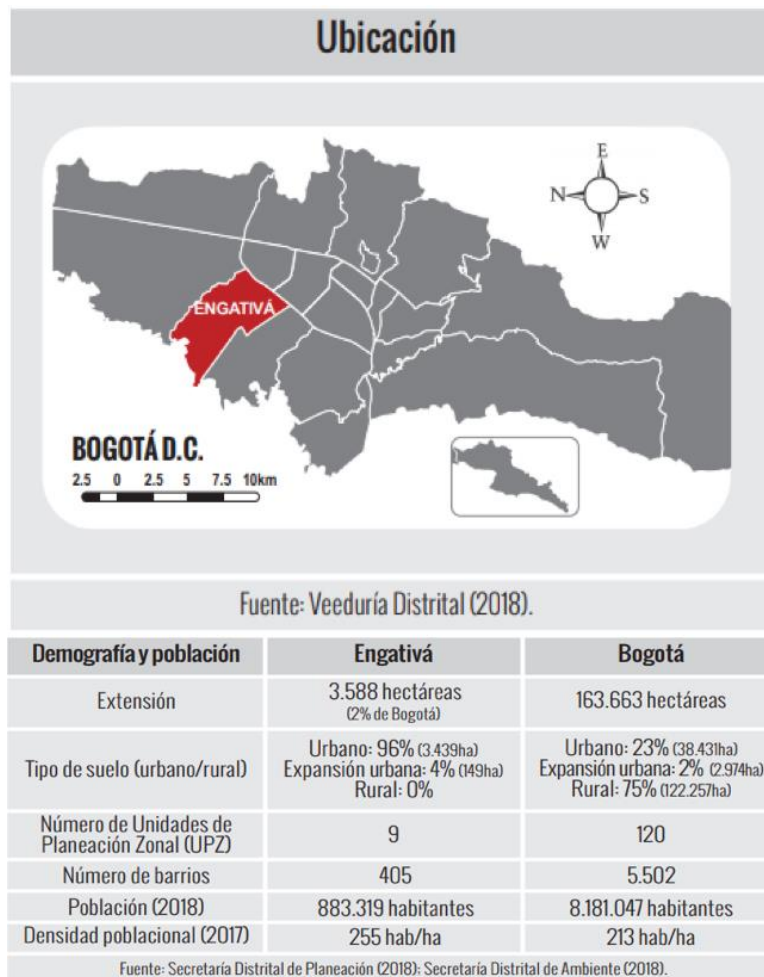


Figura 3.8.- Mapa general de la localidad de Engativá (Veeduría Distrital, 2018b)

Engativá cuenta con una extensión de 3.588,10 hectáreas, que constituyen el 9,1% de la superficie urbana de la ciudad. De esta superficie, 148,90 hectáreas constituyen suelo de expansión y 3.439,20 suelo urbano (SDP, 2018a). Asimismo, tiene las siguientes nueve Unidades de Planeamiento Zonal (UPZ): Las Ferias, Minuto de Dios, Boyacá Real, Santa Cecilia, Bolivia, Garcés Navas, Engativá, Jardín Botánico y Álamos (figura 3.9). “En cuanto al uso del suelo predomina el residencial (52,6%), seguido por el de servicios (16,1%), el comercial (13,6%) y el dotacional (12,8%)” (SDP, 2018b citado en Alcaldía Local de Engativá, 2020).

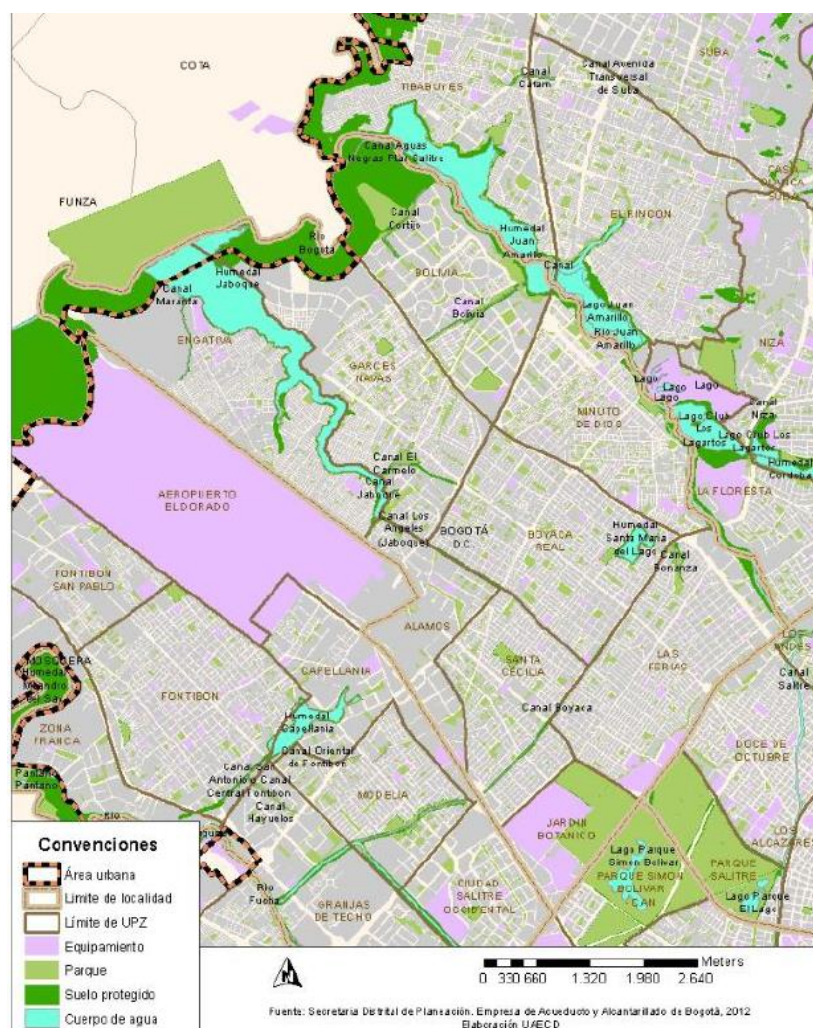


Figura 3.9.- Mapa de la localidad de Engativá (Cogua, 2013)

La localidad de Engativá es la tercera localidad con mayor concentración de población después de Kennedy y Suba. El Sistema Único de Información de Servicios Públicos estima que Engativá genera “*alrededor de 19.278,48 toneladas de residuos al mes y presenta una producción per cápita de 0,5 kg por habitante y día*” (Sistema Único de Información de Servicios Públicos, 2017; citado en Alcaldía Local de Engativá, 2020).

Dentro de las acciones propuestas para mitigar la problemática asociada a la gestión de RSU, se encuentran el cambio de hábitos de consumo, la separación en la fuente y la implantación de técnicas de reciclaje. En 2016, fueron identificados 65 puntos críticos de depósito de basuras, para los cuales se plantearon acciones de limpieza y recolección (Alcaldía Local de Engativá, 2016; citado en Alcaldía Local de Engativá, 2020). La UAESP señala como logros alcanzados en el 2018 en la localidad “*la consolidación de operativos para la recolección de neumáticos fuera de uso, recolectando en Engativá 2.262 de 38.996 neumáticos en total recolectados en la ciudad de Bogotá*” (UAESP, 2018; citado en Alcaldía Local de Engativá, 2020). La administración actual, en el marco de la gestión de los residuos sólidos generados en la localidad, tiene previsto fomentar la apropiación de valores, hábitos y habilidades que se dirijan a decisiones de consumo responsable orientadas hacia la autogestión de los residuos en el hogar, desde su correcta separación para aumentar la posibilidad de aprovechamiento y así contribuir en la disminución de los residuos dispuestos en el relleno sanitario (Alcaldía Local de Engativá, 2020).

3.2. Datos utilizados en la modelación

Para la realización de la presente investigación, se han utilizado datos referentes a la generación de RSU en las localidades, su población y sus proyecciones, las características de estratificación socioeconómica y los costos económicos asociados a las principales tecnologías planteadas para los distintos escenarios.

La primera parte del trabajo realizado se orientó a la identificación de zonas críticas de la generación de residuos sólidos en el área de estudio. Para ello, se utilizaron datos suministrados por la UAESP, del área de Disposición final de esta entidad (UAESP, 2017), en donde los valores de referencia de generación de RSU se toman de información asociada a los residuos transportados al RSDJ. A partir de ellos se organizó un archivo de datos en el que se registró la cantidad de residuos sólidos mensual por año para cada una de las ASES, desde el año 2009 al 2016.

Los datos de crecimiento poblacional y estratificación socioeconómica fueron obtenidos para ambas localidades en base a los datos del DANE y la Secretaría de Planeación Distrital (SDP, 2020). Los estratos 1, 2 y 3 corresponden a estratos bajos, es decir, a usuarios con menores recursos, y los estratos 5 y 6 corresponden a estratos altos, que se refieren a los usuarios con mayores recursos económicos (DANE, s.f.). La estratificación socioeconómica (SDP, 2011) incluida en este análisis se muestra en el anexo 2.

En el momento de la realización del análisis en esta etapa de investigación, el sistema de recolección se encontraba dividido en 6 ASE de la forma mostrada en la tabla 3.1.

Tabla 3.1.- Capacidad de campo de residuos sólidos urbanos

Zona	Localidad
ASE 1	Usaquén Suba
ASE 2	Fontibón Engativá
ASE 3	Chapinero Santa Fe Barrios Unidos La Candelaria Los Mártires Teusaquillo
ASE 4	Ciudad Bolívar Puente Aranda Tunjuelito
ASE 5	San Cristóbal Usme Antonio Nariño Rafael Uribe
ASE 6	Bosa Kennedy

(UAESP, 2017)

Así pues, el análisis se realizó teniendo en cuenta esta estructura organizativa dentro de la gestión de RSU en la ciudad. Aunque la investigación está centrada en dos localidades de la ciudad, los datos obtenidos no fueron suficientes para generar resultados en el modelo predictivo debido a que los registros suministrados por la UAESP por localidad no son continuos, la organización de la información variaba año a año y existían datos faltantes de forma considerable. Por ello, se decidió trabajar el modelo por ASE, identificando el comportamiento de las ASE en donde se encuentran las localidades de estudio. A pesar de que la estructuración de datos y la cantidad de estos se constituye en el aspecto limitante dentro de este tipo de planteamientos, finalmente se logró la estructuración de un modelo adecuado con los datos suministrados, como se va a mostrar a continuación.

La siguiente etapa de la investigación consistió en el establecimiento de un modelo que permitiera realizar la predicción de la generación de RSU mediante la implementación de aprendizaje automático basado en RNA. Sin embargo, también se incluyeron dentro del análisis los árboles de decisión y las MSV. Para ello, fue necesario realizar una reestructuración de la base de datos obtenida para facilitar el trabajo y así poder realizar un procesamiento del algoritmo de forma adecuada.

Los datos fueron reestructurados en tres archivos csv para este análisis:

- un primer archivo organizado por ASE, con datos asociados a los residuos dispuestos por la ciudad para los años 2012 al 2016, años para los cuales se tenían datos completos y continuos por tanto de utilidad para el modelo
- un segundo archivo por localidades, con la generación de RSU para los años mencionados
- un tercer archivo con los datos asociados a la estratificación socioeconómica.

Al igual que en la primera etapa, el archivo referente a datos por localidades no incluía una cantidad suficiente de datos para poder realizar la modelación, pues faltaba un número considerable de datos. Por ello, se decidió igualmente trabajar con el modelo por ASE. Para los datos de población y estratificación socioeconómica se utilizaron los mismos datos considerados en la primera etapa de la investigación.

El análisis de datos y la implementación de modelos de predicción fueron desarrollados en Python, utilizando diferentes librerías para la visualización y despliegue de los datos. De esta forma, la codificación de archivos digitales interactivos que envuelven tanto el código, la descripción de los modelos y la visualización de los resultados facilita el análisis de los resultados obtenidos. Las herramientas de IA seleccionadas se utilizaron para predecir la generación de RSU en la ciudad de Bogotá en el año 2030.

Continuando con la investigación, en una tercera fase se procedió a estructurar una propuesta de modelo metodológico basado en RNA. Para ello, se establecieron como las más apropiadas para esta modelación las redes recurrentes de tipo LSTM y simultáneamente se realizó el análisis comparativo con las máquinas de soporte vectorial para el mismo modelo. En esta etapa fue necesaria una nueva reestructuración de los datos, dado el cambio en la organización de ASE implementada para la ciudad desde el año 2018, a partir del cual ya no se tienen las seis zonas anteriormente comentadas sino únicamente cinco, como se muestra en la tabla 2.1. En caso de datos faltantes, se realizó una proyección al alza del 2% sobre el año anterior o a la baja sobre los valores del año posterior, según la disponibilidad de las observaciones.

En cuanto a las bases de datos alimentadas al modelo se organizaron de la siguiente forma:

- Residuos por zona: se organizaron los datos por cada ASE del 2012 al 2020 en t/mes, siendo los datos del 2017-2020 los utilizados para la validación del modelo, esta base también incluye la población por ASE por año.
- Escenarios: se incluyen los porcentajes de cada una de las corrientes de RSU, según el porcentaje distribuido en el escenario y según el tratamiento definido.
- Costos generales: se incluyen los datos de costo medio del tratamiento por tonelada, ingresos venta de recursos valorizados y los ingresos por tarifas del servicio público de aseo según lo establecido en cada escenario. Estos valores se presentan en el anexo 3.

- Distancias: describe las distancias desde el centro de gravedad de la localidad hacia los posibles sitios de aprovechamiento o disposición final.
- Costos de transporte: se organizan los datos de costo de transporte de RSU (t/mes), según la distancia de transporte.
- IPC: valores del IPC mensual desde 2003 para el ajuste de los costos asociados al proceso.

Los datos de costos fueron estructurados teniendo en cuenta el planteamiento de los escenarios, identificando el porcentaje para cada proceso dentro del mismo (tabla 3.2). Para este planteamiento, se utilizó como base el documento “*Estudio de técnicas alternativas de tratamiento, disposición final y/o aprovechamiento de residuos sólidos – Propuesta de ajuste Decreto 838 de 2005 (compilado en el Decreto 1077 de 2015)*” del Banco Interamericano de Desarrollo (BID, 2016), proporcionado directamente por el Departamento de Planeación Nacional, por lo que esta información no se ha analizado con anticipación de la forma realizada en la presente investigación ni se han integrado los mismos a modelos que proyecten en el tiempo posibles panoramas económicos teniendo presente el aumento de la población y los RSU. En este documento se presenta los costos generales por proceso para el año 2015 asociando costo medio por tonelada de RSU. De igual forma, presenta los ingresos por venta de recursos valorizados por tonelada e ingresos por tarifa del servicio de aseo. Dada la información presentada en el documento suministrado, cada función tiene tres puntos referentes asociados a tres tamaños de planta, para lo cual se hizo necesario realizar el cálculo de los valores correspondientes según la cantidad de residuos sólidos a evaluar, lo cual se realizó a través de interpolación lineal. Cabe resaltar que para los valores fuera del dominio de la función se tomaron los valores de los extremos.

En cuanto al planteamiento de tratamientos, el estudio mencionado analizó los potencialmente viables en el país asociados a las mejores tecnologías disponibles, que fueron tomados como base para los escenarios planteados. Estos tratamientos fueron determinados de conformidad con las etapas de la gestión integral de RSU, el análisis de los indicadores de viabilidad asociados con los requisitos técnicos, la complejidad de la técnica planteada, la relación costo/beneficio (C/B), el impacto en la tarifa del servicio público de aseo, la participación de los recicladores en la actividad de recolección, transporte o tratamiento y los requerimientos de participación de los generadores de residuos. Por tanto, dentro de los escenarios se plantean los siguientes tratamientos (BID, 2016):

- Generación de energía a partir del gas generado en rellenos sanitarios
- Tratamiento térmico por combustión en parrilla, por combustión de lecho fluidizado, o por gasificación en dos etapas
- Tratamiento mecánico con mayor intensidad mecánica para la recuperación de materiales
- Tratamiento biológico: digestión anaerobia, compostaje al aire libre, compostaje en contenedor
- Tratamiento mecánico biológico con baja/alta intensidad

Tabla 3.2.- Planteamiento de escenarios y definición de procesos asociados

	Escenario	Porcentaje de residuos sólidos para cada proceso
E1	Incineración	78%
	Relleno Sanitario	22%
E2	Gasificación	78%
	Relleno Sanitario	22%
E3	Mecánico + Digestión Anaerobia con generación de energía	68%
	Relleno Sanitario	32%
E4	Mecánico + Compostaje al Aire Libre	52%
	Relleno Sanitario	48%
E5	Mecánico + Compostaje Cerrado	68%
	Relleno Sanitario	32%
E6	Compostaje de residuos separados en la fuente	60%
	Relleno Sanitario	40%
E7	Relleno Sanitario con captura y quema	100%
E8	Relleno Sanitario con Captura y Generación de Energía	100%
E9	Relleno Sanitario con Captura y Venta directa de Gas	100%

(BID, 2016)

Otro aspecto que se tuvo en cuenta para el establecimiento de los costos es el asociado al transporte de los residuos sólidos. Se referenciaron dos distancias en el modelo (en km). La primera distancia que se estableció (distancia de disposición final 1) fue la distancia de transporte hasta el relleno sanitario actual Doña Juana, asumiendo que la situación de la ciudad en cuanto a la disposición de los RSU no sufrirá cambios desde hoy a 2030, ya que en este momento el relleno sanitario se encuentra en etapa de acondicionamiento para un aumento de su vida útil y por tanto de la licencia ambiental. También se definió una segunda distancia de transporte (distancia de disposición final 2), referente a un posible nuevo lugar de disposición final en el cual, actualmente, se realizan procesos de aprovechamiento y disposición final de residuos sólidos (tabla 3.3).

Para estas estimaciones de distancias se hizo necesario incluir el centro de gravedad para cada una de las ASE, para lo cual se utilizaron los datos presentados en el Decreto 652 de 2018 de la Alcaldía Mayor de Bogotá que define estos centros (Alcaldía de Bogotá, 2018).

Tabla 3.3.- Descripción de las distancias incluidas en modelo

	Escenario	Distancia de disposición final 1 (km)		Distancia de disposición final 2 (km)	
		ASE 4	ASE 5	ASE 4	ASE 5
E1	Incineración	27,3	36,9	27,3	36,9
	Relleno Sanitario	21,5	32,589	35,8	51,6
E2	Gasificación	27,3	36,9	27,3	36,9
	Relleno Sanitario	21,5	32,589	35,8	51,6
E3	Mecánico + Digestión Anaerobia con generación de energía	35,6	45,1	35,6	45,1
	Relleno Sanitario	21,5	32,589	35,8	51,6
E4	Mecánico + Compostaje al Aire Libre	35,6	45,1	35,6	45,1
	Relleno Sanitario	21,5	32,589	35,8	51,6
E5	Mecánico + Compostaje Cerrado	35,6	45,1	35,6	45,1
	Relleno Sanitario	21,5	31	35,8	51,6
E6	Compostaje de residuos separados en la fuente	35,6	45,1	35,6	45,1
	Relleno Sanitario	21,5	32,589	35,8	51,6
E7	Relleno Sanitario con captura y quema	21,5	32,589	35,8	51,6
E8	Relleno Sanitario con Captura y Generación de Energía	21,5	32,589	35,8	51,6
E9	Relleno Sanitario con Captura y Venta directa de Gas	21,5	32,589	35,8	51,6

Nota: Los centros de gravedad se establecieron tomando como referencia el Decreto 652 de 2018 de la Alcaldía Mayor de Bogotá (Alcaldía de Bogotá, 2018)

Para la estructuración de costos de transporte incluidos dentro del modelo se tomó como referencia la Resolución CRA 853 de 2018 de la Comisión de Regulación de Agua Potable y Saneamiento Básico, la cual presenta los precios máximos de transporte de RSU. Estos precios corresponden a los valores que se establecieron para el año 2018 “dependiendo del promedio mensual de toneladas recolectadas y transportadas en el año fiscal

inmediatamente anterior (toneladas/mes) y la distancia al sitio de disposición final, estación de transferencia o tratamiento (km), tomando como base para la actualización de costos el factor de aumento asociado a la relación del índice de precios al consumo (IPC) en el mes seleccionado por la persona prestadora para efectos de realizar la actualización y el correspondiente al último mes en el cual se realizó la actualización por concepto de IPC” (Minvivienda y CRA, 2018). De este modo, los datos referentes a costos para todos los procesos involucrados fueron ajustados al 2020 a través de los valores disponibles de IPC y se hicieron las proyecciones de estos, considerando como variable las predicciones en la cantidad de RSU generados por año.

Todo el trabajo anteriormente descrito permitió obtener un conjunto de datos estructurado que fueron utilizados conforme a la propuesta metodológica, objetivo principal del presente trabajo, que se describe en el capítulo 6, la cual fue implementado en redes de tipo LSTM para su modelación. Se usó como lenguaje de programación Python, a través del uso de Jupyter *notebooks* en el entorno de Google Colab, como una alternativa integradora para la utilización de este tipo de lenguaje y la gestión de las bases datos generadas y organizadas para la programación.

Este trabajo fue implementado para todas las ASE de Bogotá dada la dificultad de la adquisición de datos completos y continuos por localidad. Sin embargo, se mantuvo el enfoque en las áreas de estudio de interés, el cual presentó como resultados la viabilidad del diseño de modelos basado en este tipo de redes dado su funcionamiento apropiado. Sin embargo, la escasa cantidad de datos que se pueden llegar a obtener de este tipo de procesos se mantiene como un factor para tener en cuenta para poder minimizar el error obtenido. Para cuantificar el error asociado a cada una de las predicciones realizadas por este método, en este trabajo se utilizó el error cuadrático medio (MSE) y el error absoluto promedio (MAE).

4. Definición y análisis de escenarios

Identificar las zonas críticas que requieren atención inmediata se constituye en un primer paso para determinar las necesidades de las áreas de una gran ciudad. Por tanto, el estudio de la generación per cápita de residuos sólidos en cada área de recolección, integrando sistemas de información geográfica, da como resultado un diagnóstico más específico de las zonas de generación con el fin de identificar y analizar sus características a través de un enfoque estadístico. Al identificar las áreas de la ciudad que requieren mayor atención para la implementación de programas, planes y proyectos, se pueden diseñar y priorizar acciones preventivas y correctivas de acuerdo con las características específicas de cada zona.

4.1. Identificación de zonas críticas en la generación de residuos sólidos en el área de estudio

En este apartado se presentan los resultados obtenidos para la identificación de zonas críticas de generación de residuos sólidos urbanos en la ciudad de Bogotá. En este primer análisis se utilizó la distribución en 6 ASE establecidas hasta el año 2018. Para el análisis espacial se utilizó el software ARGIS y la información se basó en mapas generales de la Unidad Administrativa Especial del Catastral Distrital de Bogotá, así como datos estadísticos del Departamento Administrativo Nacional de Estadística (DANE) y del Departamento de Planeación Distrital. Para los datos poblacionales se utilizó el Censo 2005, así como las proyecciones del DANE para el año 2020 y las de la Secretaría Distrital de Planeación (SDP, 2018).

Las variables consideradas fueron las siguientes:

- i. población
- ii. cantidad de residuos sólidos recolectados, y
- iii. estratificación socioeconómica del área urbana de la ciudad por localidad.

Además, se compararon los resultados de la generación anual de residuos sólidos per cápita de cada ASE para considerar la variabilidad de este indicador, de acuerdo con la información de estratificación de cada una de ellas. Se supuso que la generación de residuos sólidos per cápita del estrato i ($PPC_{str.i}$) permanece constante, independientemente de la ASE, ya que en principio no se producen cambios en el comportamiento de consumo de la población de los diferentes estratos con respecto a la ASE donde viven. Por lo tanto, los valores de $PPC_{str.i}$ se pueden calcular a través de una función objetivo de la forma mostrada en las ecuaciones 4.1, 4.2 y 4.3:

$$Función\ Objetivo = \sum_{j=1}^{num\ ASEs} \gamma_j \cdot Err_j \quad (4.1)$$

$$\gamma_j = \frac{Población\ de\ la\ ASE_j}{Total\ de\ la\ población} \quad (4.2)$$

$$Err_j = abs(RSU_{medidos_{ASE\ j}} - RSU_{estimados_{ASE\ j}}) \quad (4.3)$$

La función objetivo (ecuación 4.1) se define en términos de la diferencia entre la generación de residuos sólidos medida y la estimada en cada ASE, ponderada por la proporción de la población de la ASE con respecto a la población total. Una vez calculada la $PPC_{str.i}$ para cada estrato, se obtiene la generación total de residuos sólidos de cada ASE utilizando la ecuación 4.4:

$$RSU_{estimados_{ASE\ j}} = \sum_{i=0}^{strata} (PPC_{estrato\ i} \cdot Población\ estrato\ i_{ASE\ j}) \quad (4.4)$$

En el año 2005 fueron generados un total de residuos sólidos de 2.746 t/día (UAESP y Universidad de los Andes, 2005) para la ciudad de Bogotá, como se menciona en el Proyecto de Estudio del Plan Maestro de Gestión Integral de Residuos Sólidos en Bogotá, D.C. (JICA y UAESP, 2013), del cual fueron obtenidos los datos para el análisis como se presenta en la tabla 4.1. De igual forma, se realizó a través de ARGIS la identificación de las zonas críticas de generación de RSU en la ciudad, identificando que la ASE 3 tuvo la PPC más alta para ese año (figura 4.1).

Tabla 4.1.- Generación de residuos sólidos por ASE para el año 2005

ASE	Generación de residuos sólidos (t/año)	Población 2005	PPC (kg/persona /año)
ASE 1	235.201,40	1.363.504	173
ASE 2	158.763,73	1.091.877	145
ASE 3	160.571,69	718.797	223
ASE 4	121.561,06	1.027.293	118
ASE 5	155.205,83	1.192.633	130
ASE 6	170.779,33	1.440.060	119

(UAESP y Universidad de los Andes, 2005; JICA y UAESP, 2013)

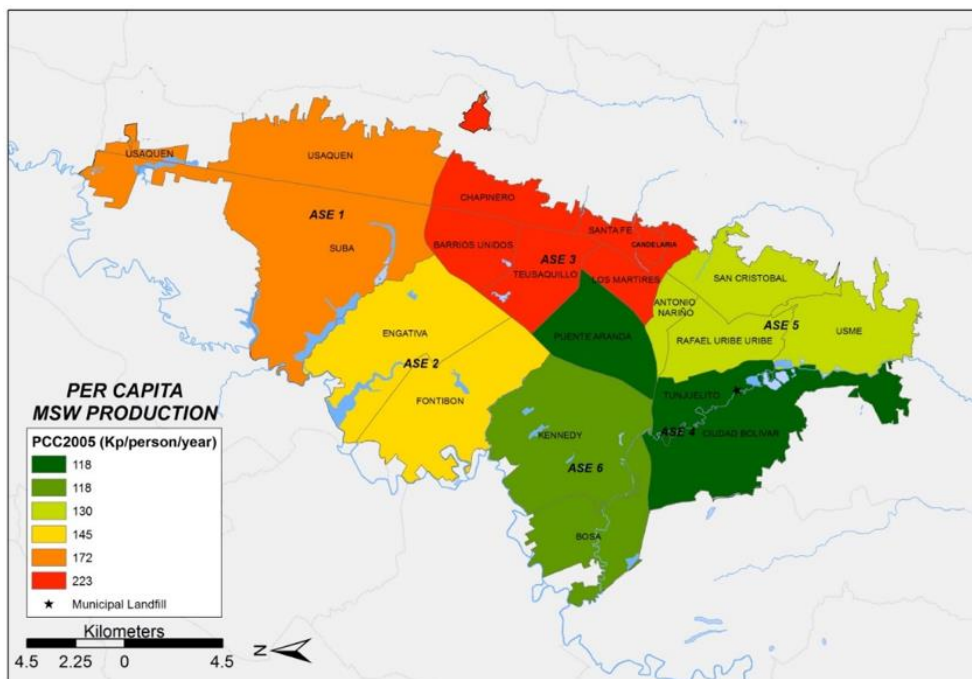


Figura 4.1.- PPC por ASE para el año 2005

Los datos correspondientes al año 2015 fueron los proporcionados directamente por la UAESP (tabla 4.2) por el Área de Disposición Final de esa entidad, los cuales fueron analizados para la identificación de zonas críticas para ese año (figura 4.2). La ASE 3 nuevamente representa la zona con mayor generación de residuos sólidos en la ciudad.

Tabla 4.2.- Generación de residuos sólidos por ASE para el año 2015

ASE	Generación de residuos sólidos (t/año)	Población 2015	PPC (kg/persona /año)
ASE 1	447.188,72	1.668.802	268
ASE 2	354.295,06	1.255.208	282
ASE 3	338.561,67	762.829	444
ASE 4	323.844,30	1.146.385	282
ASE 5	321.634,07	1.322.797	243
ASE 6	484.009,26	1.716.302	282

(Registros de la Unidad Administrativa Especial de Servicios Públicos)

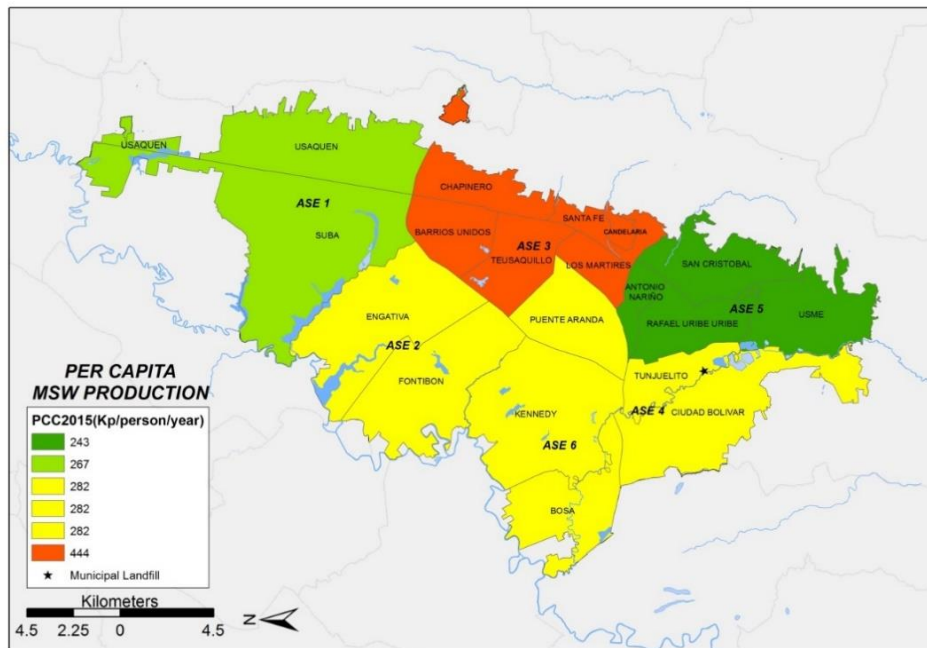


Figura 4.2.- PPC por ASE para el año 2015

Para el año 2020 se realizaron las estimaciones correspondientes (tabla 4.3), para lo cual se contó con datos desde el año 2009 al 2016 para realizar proyecciones. Estos datos fueron suministrados igualmente de forma directa por la UAESP.

Tabla 4.3.- Generación de residuos sólidos por ASE para el año 2020

ASE	Generación de residuos sólidos (t/año)	Población 2020	PPC (kg/persona /año)
ASE 1	507.542,87	1.858.528	273
ASE 2	396.484,94	1.337.120	296
ASE 3	366.090,73	746.291	490
ASE 4	332.914,65	1.171.220	284
ASE 5	362.623,87	1.186.754	305
ASE 6	576.760,04	2.073.050	278

En general, se mantiene el comportamiento de las ASE, por lo cual se identifica como área crítica la ASE 3 (figura 4.3) de acuerdo con el PPC generado, la cual requiere de atención prioritaria. Esta zona se caracteriza por tener actividades empresariales, institucionales y domiciliarias lo que podría influir en la cantidad de residuos generados.

La ASE 2, donde se localiza la localidad de Engativá, presenta un PPC que no se encuentra dentro de los valores críticos, mientras que la ASE 1, donde se encuentra la localidad de Suba, presenta valores bajos de PPC para el año 2015 y según las proyecciones del 2020. Sin embargo, es necesario tener en cuenta que todas estas ASE se identificaron con valores críticos para el año 2005.

La figura 4.4 muestra la evolución de la generación total de RSU de cada ASE en Bogotá a lo largo del tiempo. En resumen, para este análisis se trabajaron los datos de generación de residuos sólidos para los años 2005 y 2015 según lo reportado, y para el año 2020 se realizó una regresión lineal para su estimación.

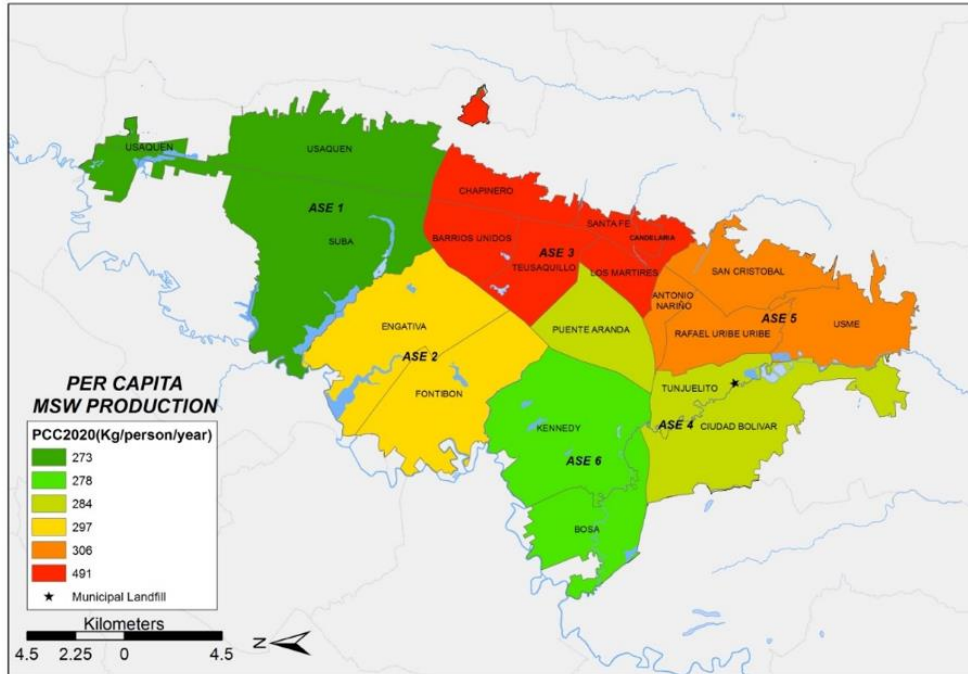


Figura 4.3.- PPC por ASE para el año 2020




Figura 4.4.- Generación de residuos sólidos por ASE en Bogotá (2009-2020)

La tabla 4.4 muestra la distribución de la población de 2015 por estratos económicos de cada ASE. La gran mayoría de la población pertenece al estrato 2 y al estrato 3 en la ciudad de Bogotá.

Tabla 4.4.- Distribución de la población de 2015 por estratos económicos de cada ASE

ASE	Población (hab) (%)	Pob Str 0	Pob Str 1	Pob Str 2	Pob Str 3	Pob Str 4	Pob Str 5	Pob Str 6
1	1.723.691 (22)	24.582	23.246	411.639	543.835	378.983	236.359	105.047
2	1.276.634 (16)	16.91	6.462	281.611	796.983	171.117	3.551	0
3	724.902 (9)	2.702	11.623	85.831	284.921	262.626	29.646	47.553
4	1.134.511 (14)	12.002	431.964	356.491	334.054	0	0	0
5	1.196.612 (15)	14.881	219.654	651.424	310.613	0	0	40
6	1.896.355 (24)	40.883	41.133	1.204.318	580.338	29.683	0	0
TOTAL		111.960	734.082	2.991.314	2.850.744	842.409	269.556	152.64
Población (%)		1,4	9,2	37,6	35,8	10,6	3,4	1,9

(SDP, 2011)

4.2. Análisis de escenarios

A partir de los resultados anteriores, se plantearon varios escenarios para realizar el análisis de los datos obtenidos y así visualizar un panorama de generación de residuos sólidos per cápita agrupados por estratos económicos.

4.2.1. Escenario 1: Cálculo de $PPC_{str.i}$ considerando fuertes restricciones en el proceso de minimización

En el proceso de minimización, se impusieron dos restricciones (estrictas) adicionales:

- El valor de $PPC_{str.i}$ debe ser superior a 200 kg/persona/año
- El error absoluto máximo de la diferencia entre el valor estimado de generación de RSU y el valor real de RSU generado para un ASE particular debe ser menor al 20%

La tabla 4.5 presenta los resultados del proceso de minimización de la función objetivo para el escenario 1. El valor de la función objetivo es igual a 38.034 t/año, mientras que la suma de los errores absolutos asociados a las diferencias entre el valor estimado de la generación de RSU y el valor real de los RSU generados es igual a 231.737 t/año.

La generación de residuos sólidos per cápita del estrato i ($PPC_{str.i}$) se muestra en la tabla 4.6.

Tabla 4.5.- Minimización de la función objetivo para el Escenario 1

ASE	Generación estimada	Generación real	Dif.	Error	Abs. Dif.	Abs. error
ASE 1	540.544	450.453	90.091	20%	90.091	20,0%
ASE 2	418.445	348.704	69.741	20%	69.741	20,0%
ASE 3	264.944	324.087	-59.143	-18%	59.143	18,2%
ASE 4	317.633	317.633	0	0%	0	0,0%
ASE 5	311.384	324.146	-12.762	-4%	12.762	3,9%
ASE 6	487.897	487.9	-3	0%	3	0,0%
					$\Sigma = 231.737$	Func. Obj.= 38.034 t/año

Tabla 4.6.- Escenario 1: Residuos sólidos per cápita por estrato i (PPC_{str.i})

PPC _{str i}	PPC Str 0	PPC Str 1	PPC Str 2	PPC Str 3	PPC Str 4	PPC Str 5	PPC Str 6
t/persona/año	200	294	215	334	503	200	200
kg/persona/día	0,55	0,81	0,59	0,91	1,38	0,55	0,55

La figura 4.5 muestra la generación de RSU per cápita para los siete estratos en las condiciones consideradas en el escenario 1, en donde los valores más altos de generación de residuos sólidos per cápita obtenidos corresponden al estrato 4.




Figura 4.5.- Generación de RSU per cápita por estrato en el escenario 1

4.2.2. Escenario 2: Cálculo de $PPC_{str.i}$ considerando restricciones intermedias en el proceso de minimización

Los valores de PPC en el estrato 4 según el escenario 1 pueden considerarse anormalmente altos en comparación con los resultados obtenidos para los otros estratos. Por esto se planteó el escenario 2, de igual forma, para analizar el comportamiento de $PPC_{str.i}$ y mejorar el proceso de minimización. En este escenario, se impusieron las siguientes condiciones adicionales para la minimización de la función objetivo:

- El valor de $PPC_{str.i}$ debe ser superior a 200 kg/persona/año.
- El error absoluto máximo asociado a la diferencia entre el valor estimado de generación de RSU y el valor real de RSU generado para un ASE particular debe ser menor al 20%.
- El error absoluto máximo de la diferencia entre el valor estimado de generación de RSU y el valor real de RSU generado para ASE 3 puede ser superior al 20% si es necesario.

La tabla 4.7 presenta los cálculos para la función objetivo manteniendo estas condiciones. La generación de residuos sólidos per cápita del estrato i ($PPC_{str.i}$) se muestra en la tabla 4.8. En este caso particular, el valor de la función objetivo es igual a 12.238 t/año,

mientras que la suma de los errores absolutos de las diferencias entre el valor estimado de la generación de RSU y el valor real de los RSU generados es igual a 130.054 t/año.

Tabla 4.7.- Escenario 2: Cálculos de minimización de la función objetivo

ASE	Generación estimada	Generación real	Dif.	Error	Abs. Dif.	Abs. error
ASE 1	450.454	450.453	1	0%	1	0,0%
ASE 2	348.612	348.704	-92	0%	92	0,0%
ASE 3	200.484	324.087	-123.603	-38%	123.603	38,1%
ASE 4	317.634	317.633	1	0%	1	0,0%
ASE 5	317.789	324.146	-6.357	-2%	6.357	2,0%
ASE 6	487.9	487.9	0	0%	0	0,0%
					$\Sigma = 130.054$	Func. Obj.= 12.238 t/año

Tabla 4.8.- Escenario 2: Residuos sólidos per cápita por estrato i (PPC_{str.i})

PPC _{str.i}	PPC Str 0	PPC Str 1	PPC Str 2	PPC Str 3	PPC Str 4	PPC Str 5	PPC Str 6
t/persona/año	272	312	245	276	306	200	213
kg/persona/día	0,75	0,86	0,67	0,76	0,84	0,55	0,58

La figura 4.6 muestra la generación de RSU per cápita para los siete estratos en el escenario 2. Los resultados son considerablemente diferentes a los obtenidos en el escenario 1. En el escenario 2, los valores más altos de generación de residuos sólidos per cápita corresponden al estrato 1 y estrato 4. Como se muestra, el valor de PPC para el estrato 4 disminuyó considerablemente en comparación con la estimación realizada para el escenario 1.




Figura 4.6.- Generación de RSU per cápita por estrato en el escenario 2

4.2.3. Escenario 3: Cálculo de $PPC_{str,i}$ descartando los datos de la ASE 3

Los resultados obtenidos en el escenario 2 indican que el comportamiento de la ASE 3 no es coherente con el del resto de las ASE. Es por esto por lo que se ha propuesto el escenario 3, que excluye los datos del ASE 3. En este escenario, se impusieron las mismas condiciones que las consideradas en el escenario 1 para la minimización de la función objetivo. Como resultado, el escenario 3 se diseña bajo las siguientes hipótesis:

- El valor de $PPC_{str,i}$ debe ser superior a 200 kg/persona/año
- El error absoluto máximo de la diferencia entre el valor estimado de generación de RSU y el valor real de RSU generado para un ASE particular debe ser menor al 20%
- Se descartan los datos de ASE 3

La tabla 4.9 muestra los resultados del proceso de minimización de la función objetivo para el escenario 3. La generación de residuos sólidos per cápita del estrato i ($PPC_{str,i}$) se muestra en la tabla 4.10. En este caso particular, el valor de la función objetivo es igual a 1.147 t/año, mientras que la suma de los errores absolutos de la diferencia entre la generación estimada de RSU y la generación real de RSU es igual a 6.927 t/año. Hay que tener en cuenta que estos valores son muy inferiores a los obtenidos para los escenarios 1 y 2, lo que significa que los errores en el proceso de minimización han disminuido y que la estimación es mucho más precisa.

Tabla 4.9.- Escenario 3: Cálculos de minimización de la función objetivo

ASE	Generación estimada	Generación real	Dif.	Error	Abs. Dif.	Abs. error
ASE 1	450.452	450.453	-1	0%	1	0,0%
ASE 2	348.713	348.704	9	0%	9	0,0%
ASE 3	317.632	317.633	-1	0%	1	0,0%
ASE 4	317.23	324.146	-6.916	-2%	6.916	2,1%
ASE 5	487.9	487.9	0	0%	0	0,0%
ASE 6	450.452	450.453	-1	0%	1	0,0%
					$\Sigma = 6.927$	Func. Obj.= 1.147 t/año

Tabla 4.10.- Escenario 3: Residuos sólidos per cápita por estrato i ($PPC_{str.i}$)

$PPC_{str.i}$	PPC Str 0	PPC Str 1	PPC Str 2	PPC Str 3	PPC Str 4	PPC Str 5	PPC Str 6
t/persona/año	288	305	239	291	246	245	288
kg/persona/día	0,79	0,84	0,65	0,80	0,67	0,67	0,79

La figura 4.7 muestra la generación de RSU per cápita para los siete estratos en las condiciones consideradas para el escenario 3. Los resultados obtenidos son bastante similares a los obtenidos en el escenario 2, en términos de los valores máximos de generación de residuos sólidos per cápita, que se obtuvieron en ambos escenarios para el estrato 1 ($PPC_{str.1} = 312$ kg/persona/año para el escenario 2 y $PPC_{str.1} = 305$ kg/persona/año para el escenario 3). Sin embargo, los escenarios 2 y 3 difieren mucho de los valores mínimos de PPC, la forma de la función de distribución de PPC y el valor final de la función objetivo, que es mayor que el orden de magnitud para el escenario 3 (Func. Obj.= 12.238 t/año para el escenario 2, mientras que Func. Obj. = 1.147 t/año para el escenario 3).

Por lo tanto, los resultados obtenidos para el escenario 3 son consistentes con los datos y proporcionan una estimación muy precisa de los valores de $PPC_{str.i}$.

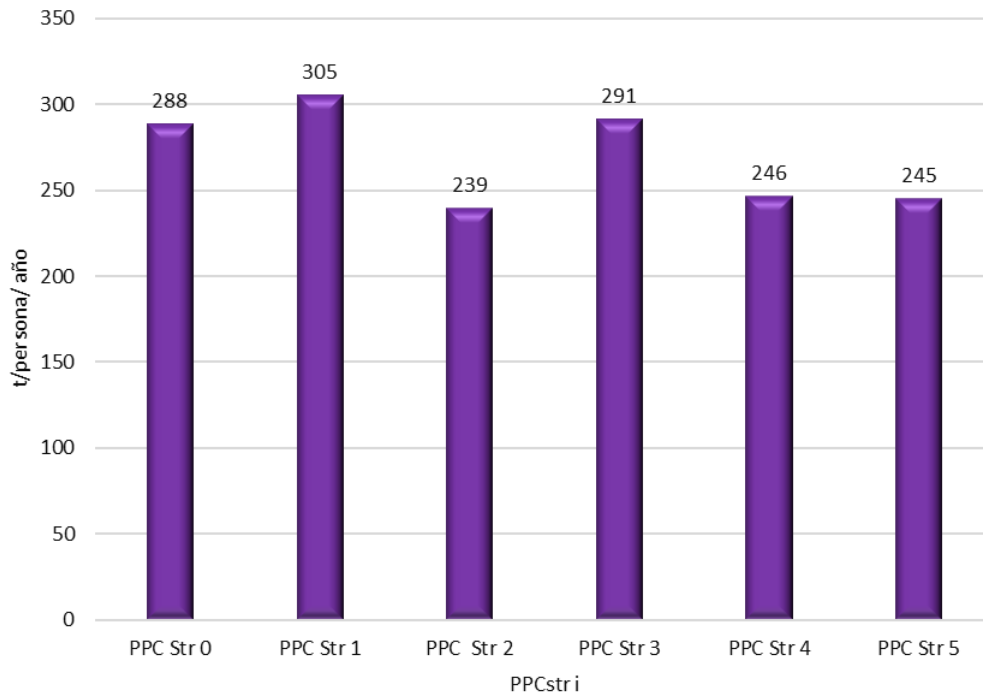


Figura 4.7.- Generación de RSU per cápita por estrato en el escenario 3

4.2.4. Escenario 4: Cálculo de $PPC_{str,i}$ descartando los datos de ASE 3 y considerando una distribución de bloques para $PPC_{str,i}$

El escenario 4 está diseñado para explorar los resultados obtenidos al descartar los datos de la ASE 3 y además considerar que los valores de $PPC_{str,i}$ se distribuyen en 3 bloques. De esta manera, existe un bloque $PPC_{str,i}$ para los estratos 0, 1 y 2, otro para los estratos 3 y 4, y un tercero para los estratos 5 y 6.

En el escenario 4, las mismas condiciones adicionales que las consideradas en el Escenario 1 fueron impuesta para la minimización de la función objetivo. Por lo tanto, en el escenario 4 se consideran las siguientes hipótesis:

- El valor de $PPC_{str,i}$ debe ser superior a 200 kg/persona/año.
- El error absoluto máximo de la diferencia entre el valor estimado de la generación de RSU y el valor real de RSU generado para un ASE en particular debe ser menor al 20%.
- Los valores de $PPC_{str,i}$ se distribuyen en 3 bloques, que agrupan los estratos 0-1-2, los estratos 3-4 y los estratos 5-6.
- Se descartan los datos de ASE 3.

La tabla 4.11 muestra los resultados del proceso de minimización de la función objetivo para el escenario 4. En este caso particular, el valor de la función objetivo es igual a 8.285 t/año, mientras que la suma de los errores absolutos de la diferencia entre la generación estimada de RSU y la generación real de RSU es de 50.871 t/año. Tengamos en cuenta que estos valores son mayores que los obtenidos para el escenario 3, pero menores que los obtenidos para los escenarios 1 y 2.

Tabla 4.11.- Escenario 4: Cálculos de minimización de la función objetivo

ASE	Generación estimada	Generación real	Dif.	Error	Abs. Dif.	Abs. error
ASE 1	450.836	450.453	383	0%	383	0,1%
ASE 2	342.983	348.704	-5.721	-2%	5.721	1,6%
ASE 3	291.084	317.633	-26.549	-8%	26.549	8,4%
ASE 4	305.928	324.146	-18.218	-6%	18.218	5,6%
ASE 5	487.9	487.9	0	0%	0	0,0%
ASE 6	450.836	450.453	383	0%	383	0,1%
$\Sigma = 50.871$						Func. Obj.= 8.285 t/año

La tabla 4.12 y la figura 4.8 muestran la generación de RSU per cápita para los siete estratos en las condiciones consideradas en el escenario 4. Los resultados obtenidos muestran que la máxima generación de RSU PPC es de los estratos ubicados en el centro de la distribución (estratos 3 y 4), para los cuales, $PPC_{str\ 3-4} = 275$ kg/persona/año. Sin embargo, a pesar de brindar una sólida explicación del proceso de generación de RSU, la precisión de los resultados obtenidos en el escenario 4 es menor que la obtenida para el escenario 3, en términos del valor de la función objetivo (Func. Obj.= 1.147 t/año para el escenario 3, mientras que Func. Obj. = 8.285 t/año para el escenario 4).

Tabla 4.12.- Escenario 4: Residuos sólidos per cápita por estrato i ($PPC_{str.i}$)

$PPC_{str\ i}$	PPC Str 0	PPC Str 1	PPC Str 2	PPC Str 3	PPC Str 4	PPC Str 5	PPC Str 6
t/persona/año	249	249	249	275	275	242	242
kg/persona/día	0,68	0,68	0,68	0,75	0,75	0,66	0,66




Figura 4.8.- Generación de RSU per cápita por estrato en el escenario 4

Los resultados obtenidos para los cuatro escenarios planteados dejan de manifiesto que el uso de técnicas SIG facilita el desarrollo de cálculos preliminares que evalúan la generación de residuos sólidos urbanos dentro de áreas específicas de un entorno urbano complejo. La utilización de técnicas SIG combinadas con técnicas estadísticas han permitido obtener resultados que serán utilizados posteriormente en el análisis apropiado de las proyecciones en la generación de RSU, de manera que se hace interesante que este tipo de análisis se tenga en cuenta para el sistema urbano de gestión de estos residuos, especialmente con respecto a la disposición en relleno sanitario, dado que en este momento es la única opción para la eliminación de residuos en Bogotá a corto y medio plazo. Esta metodología permite visualizar la distribución de los RSU de cada ASE, y se constituye de gran interés ya que integra la estratificación económica de la población de la ciudad.

5. Predicción de la generación de residuos en la ciudad de Bogotá

Conocer las cantidades de residuos sólidos urbanos que son generados en un periodo de tiempo determinado permite estructurar un sistema completo de acuerdo con las particularidades de una población o ciudad, de manera que se soporte con mayor robustez la toma de decisiones para el planteamiento y formulación del diseño de tecnologías en todas las etapas de este proceso. Estas etapas incluyen la recogida, transporte, aprovechamiento y disposición final de los residuos en las ciudades. Integrar modelos matemáticos a la gestión de residuos sólidos urbanos se constituye en un desafío, principalmente por la falta de datos reales en todas las etapas de gestión.

En el marco de este trabajo, la segunda etapa de la investigación consistió en la realización de la predicción de la producción de residuos sólidos de la ciudad utilizando herramientas de inteligencia artificial. Aunque el enfoque principal se centró en la utilización de redes RNA de tipo LSTM, se realizó también la predicción a través de árboles de decisión y de MSV para poder visualizar mejor la eficiencia del comportamiento de las redes. Todas estas herramientas fueron seleccionadas teniendo en cuenta la cantidad de datos disponibles así como su relación temporal disponibles para la modelación.

En esta etapa de la investigación, se implementaron tres herramientas para la predicción de la generación de RSU: los árboles de decisión como algoritmo no paramétrico, el cual se adapta para la modelación de fronteras de separación de datos basados en reglas de decisión aprendidos sobre las características de entrada del modelo; las MSV, que tienen como principal ventaja su apropiado ajuste a los datos, a pesar de la naturaleza variable de éstos o frente a problemas que contienen pocos datos de entrenamiento; y las redes

neuronales artificiales, que cuentan con un diseño dentro de su arquitectura que es útil para explorar correlaciones temporales.

En cuanto a la base de datos inicial, se realizaron mejoras para lograr una lectura automatizada de los mismos y poder evidenciar la calidad de éstos en cuanto a elementos faltantes. Los datos faltantes fueron estimados a partir de observaciones con características similares (por ejemplo, valores en años precedentes o valores vecinos). Una vez organizados y estructurados los datos, se procedió al desarrollo de una herramienta que permitiera su análisis visual.

Para la modelación de las alternativas se utilizó el programa Phyton, en el cual se realizó el análisis de datos para el cálculo de las proyecciones en todas las herramientas. Se emplearon notebooks para visualizar y mostrar los datos, que codifican archivos digitales interactivos que integran tanto el código como la descripción de los modelos, mientras visualizan los resultados obtenidos, lo que facilita el análisis y la manipulación de la información contenida en ellos.

Inicialmente, se realizó un análisis general para determinar relaciones y patrones de las cifras almacenadas, ya que la mejor manera para visualizar y entender los datos es transformar los valores almacenados a series de tiempo, lo que permitió observar cuáles son las zonas en Bogotá que generan más residuos y cuáles generan menos. Como resultado se obtuvo que las ASE que generan más residuos son la 1 y la 6, y las ASE que generan menos residuos son la 3 y 4, lo cual es coherente con los resultados obtenidos durante la primera etapa de la investigación, teniendo presente que, entonces, se analizaron los datos proporcionados por la UAESP del Área de Disposición Final, pero ahora los datos proceden del Área de Recolección, Barrido y Limpieza (figura 5.1).

Aunque los datos obtenidos para esta etapa del análisis tenían una mayor organización y cantidad, no se consideraron suficientes para trabajar el modelo por localidades, dado el número de datos faltantes en la base de datos. Por ello, se decidió realizar las proyecciones por ASES para obtener mejores resultados de los modelos, logrando de esta forma una mejor visualización del comportamiento de la generación de residuos sólidos por localidades. A partir de estos datos, se analizaron las series de tiempo de las localidades para cada uno de los meses a través de un modelo dinámico de visualización. En la figura 5.2 se muestra el comportamiento de la generación de residuos en los meses de cada año para la localidad de Suba y en la figura 5.3 para la localidad de Engativá.

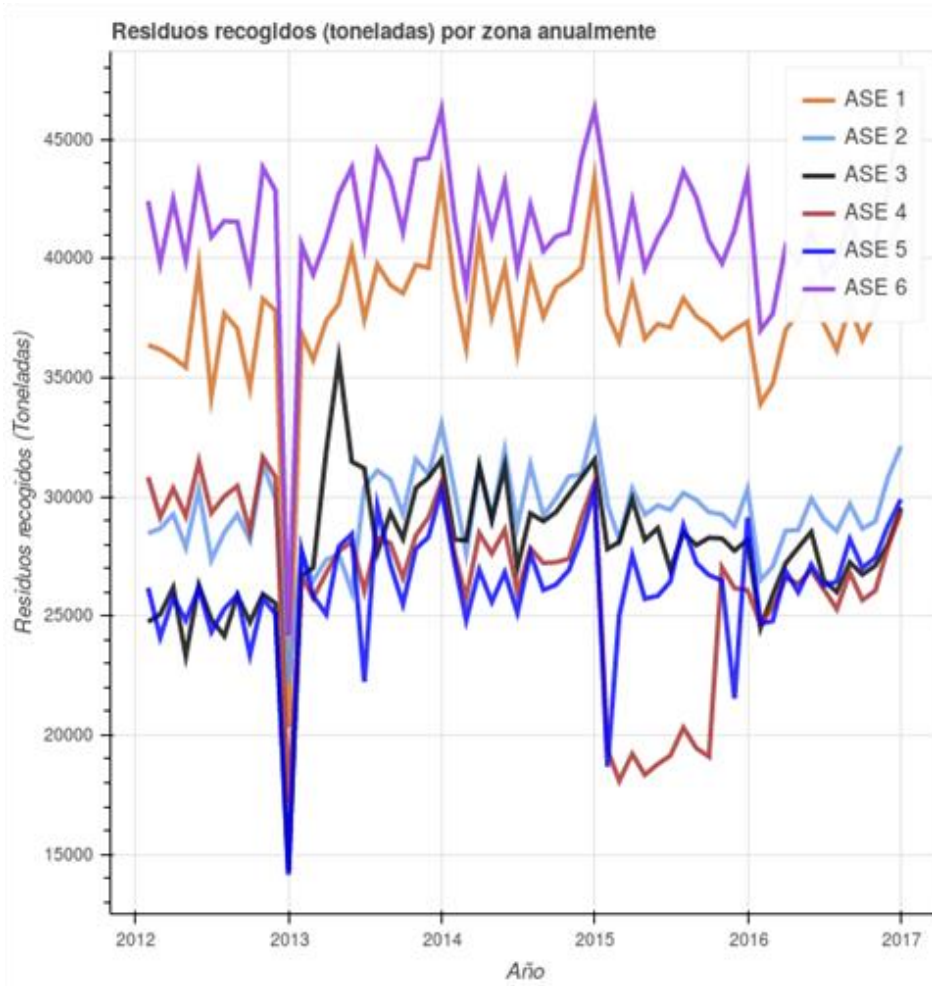


Figura 5.1.- Residuos anuales recogidos por ASE

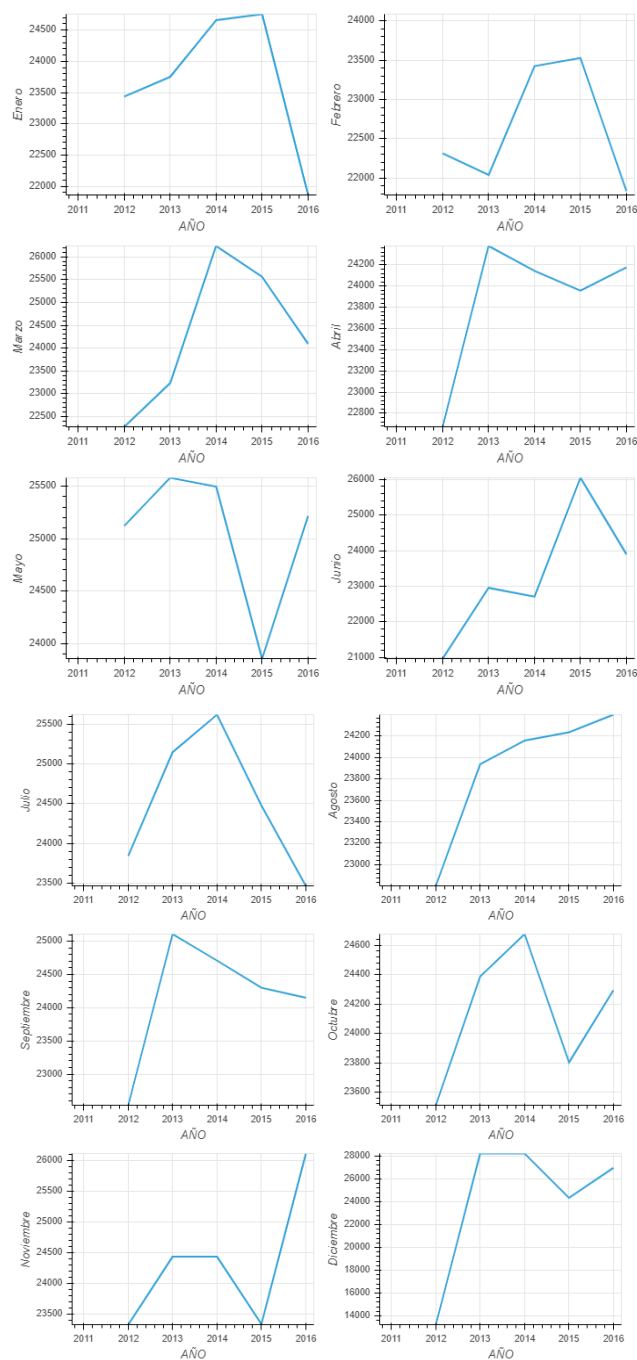


Figura 5.2.- Generación mensual de residuos por año para la localidad de Suba

Predicción de la generación de residuos en la ciudad de Bogotá

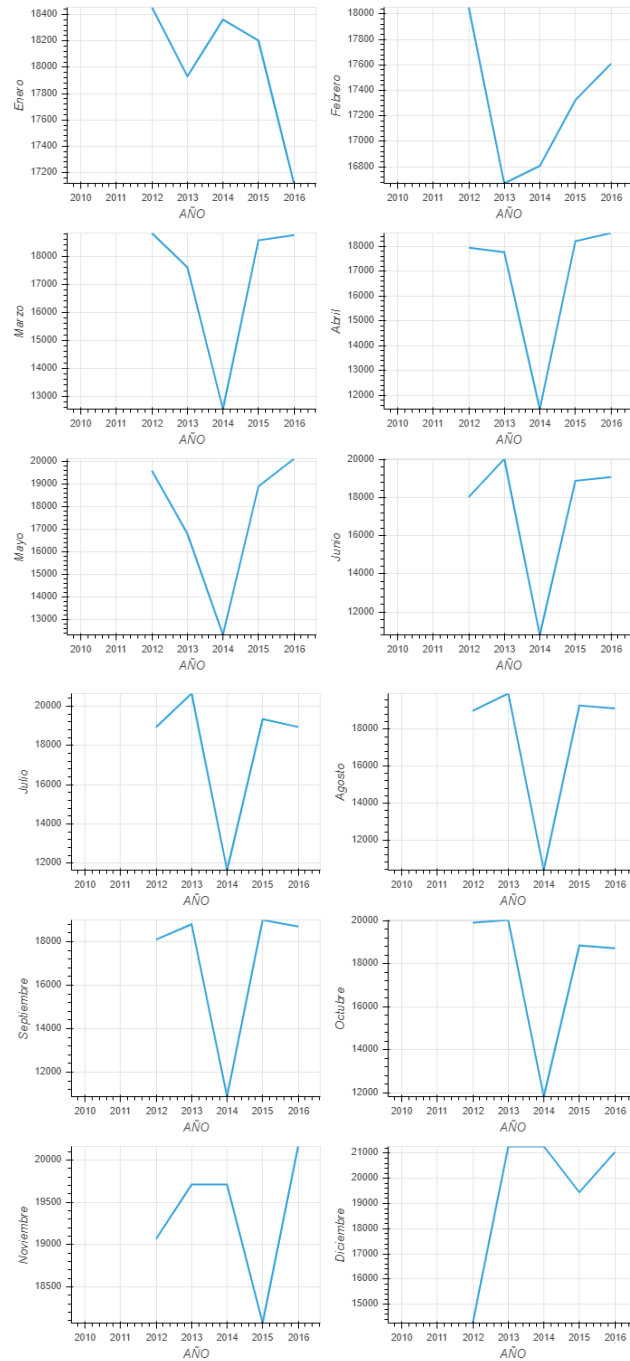


Figura 5.3.- Generación mensual de residuos por año para la localidad de Engativá

Además, se obtuvo el porcentaje de participación que tienen las localidades de Suba y Engativá dentro de cada una de sus ASE por cada mes en todos los años registrados. Se presentan como ejemplos los resultados obtenidos para los años 2012 (figura 5.4) y 2016 (figura 5.5).




Figura 5.4.- Participación de las localidades de Suba y Engativá dentro de las ASE para el año 2012




Figura 5.5.- Participación de las localidades de Suba y Engativá dentro de las ASE para el año 2016

Una vez realizado el análisis general, se prosiguió con las predicciones de la gestión de RSU utilizando herramientas de aprendizaje de máquina, para cuantificar el error asociado a cada una de las predicciones realizadas por este método, en este trabajo se utilizó la raíz del error medio cuadrático (ecuación 5.1):

$$e = \sqrt{\frac{1}{M} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (5.1)$$

donde \hat{y}_i es el valor predicho por el método implementado e y_i es el valor real. Este error mide las diferencias locales y da una estimación en términos de la variable cuantificada, es decir, cantidad de residuos.

En este trabajo, se decidió utilizar redes LSTM, como se ha mencionado con anterioridad, ya que una de las principales ventajas de estas redes es la capacidad para ajustar comportamientos no lineales de los datos y mantener estados de memoria y olvido que tienen en cuenta información temporal pasada. En este caso, las neuronas son denominadas bloques de memoria, conectados a través de diferentes capas. Los algoritmos basados en redes neuronales profundas utilizan un método de gradiente descendente para aprender los pesos entre capas y conexiones de las neuronas, en este caso los bloques de memoria. Debido a que su uso es normalmente en conjunto con grandes volúmenes de datos, existen nuevos algoritmos de aprendizaje que intentan aprender estos parámetros de forma recursiva sobre pequeños conjuntos de datos.

A continuación, se presentan los resultados de la modelación para las redes de tipo LSTM para las ASE 1 y 2, por ser las áreas en donde se encuentran las localidades de estudio (figura 5.6 y figura 5.9), en la ASE 1, la localidad de Suba y en la ASE 2, la localidad de Engativá. Para mejorar el comportamiento de estos métodos, se implementó previamente una ventana deslizante que permite filtrar temporalmente los datos y así tratar de obtener un suavizado secuencial según sus vecinos locales (figura 5.7 y figura 5.10). También se muestra la predicción por pasos de tiempo como alternativa de presentación de la modelación de la serie temporal (figura 5.8 y figura 5.11).

Los resultados obtenidos muestran que estas predicciones tienden a seguir un promedio. Esto se debe principalmente a que se realizan de manera recursiva, es decir se realizan predicciones en base a predicciones anteriores. Por lo general, estos modelos mejoran y se fortalecen en la medida que se obtiene mayor cantidad de datos para así mantener un histórico y obtener patrones más finos, por lo que es importante alimentar la red con observaciones reales a medida que se vayan obteniendo.

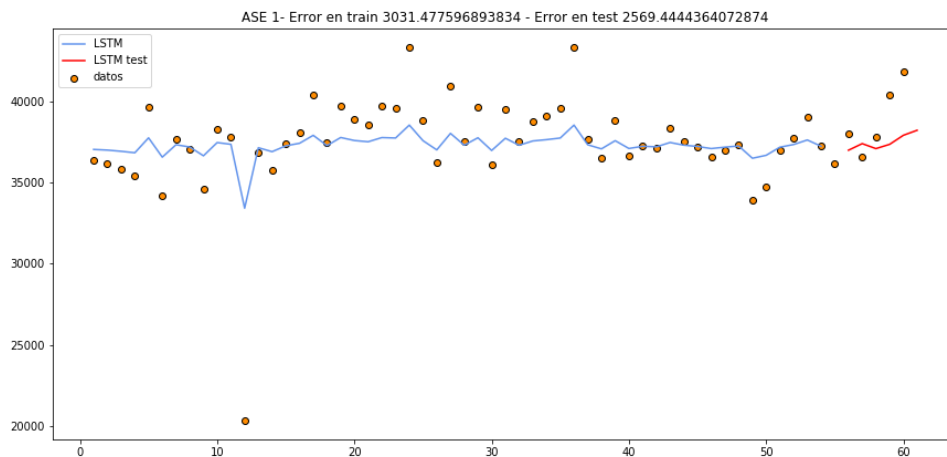


Figura 5.6.- Redes LSTM ASE 1




Figura 5.7.- Redes LSTM con ventana deslizando ASE 1



Figura 5.8.- LSTM para regresión con pasos de tiempo ASE 1

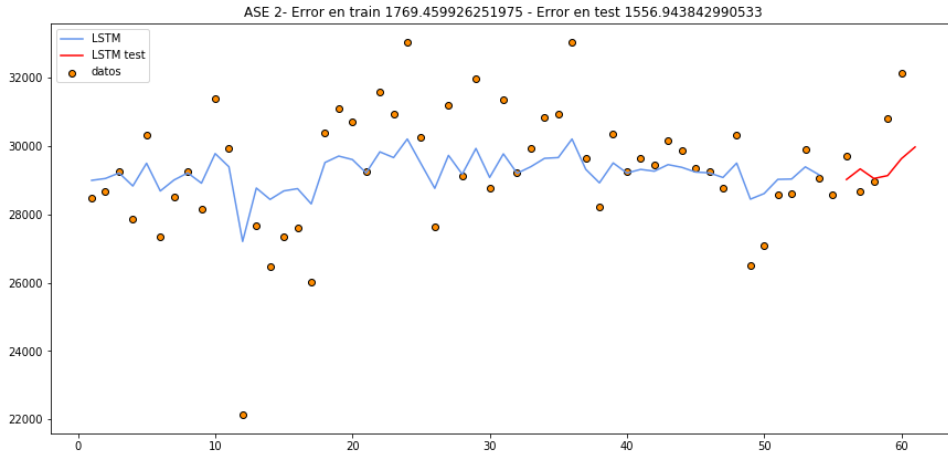


Figura 5.9.- Redes LSTM ASE 2

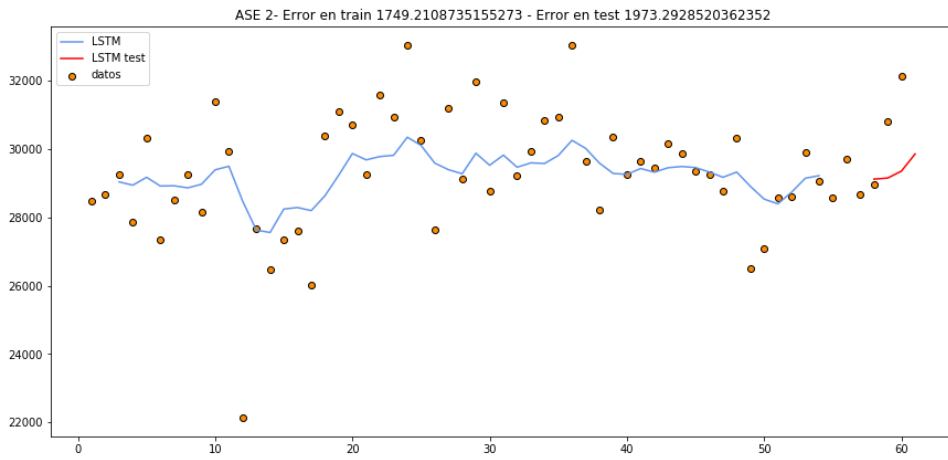


Figura 5.10.- Redes LSTM con ventana deslizante ASE 2




Figura 5.11.- LSTM para regresión con pasos de tiempo ASE 2

Como se mencionó con anterioridad, esta etapa predictiva incluyó también un análisis con otros modelos con el objetivo de realizar un análisis comparativo del funcionamiento de las redes LSTM. Como metodología alternativa, se utilizó los árboles de decisión. Según requiera la sensibilidad del modelo, se define la profundidad del árbol aprendido, que contiene un conjunto de umbrales de decisión que separan los datos contenidos en cada característica. Para este caso, la característica de entrada es la producción anual de residuos. Si se define un árbol de decisión con número de profundidad igual a dos, el algoritmo de aprendizaje intentará separar los residuos en dos subgrupos y solo existirá un valor de separación. A medida que se considera un mayor número de profundidad, la separación se vuelve más fina y se pueden separar los datos de una mejor forma. Sin embargo, un valor muy alto en el árbol de profundidad hace líneas de separación sobre ajuste lo que limitan la generalidad del modelo para nuevos valores. Esto quiere decir que el modelo aprendió incluso datos ruidosos de la entrada y no podrá predecir valores coherentes para valores con cierta varianza con respecto a los datos de entrenamiento.

En nuestro caso, la implementación utilizó una versión optimizada del algoritmo CART, utilizando árboles de profundidad de 3 y 6. La principal ventaja de este método es la rapidez en el cálculo de del árbol representativo y la posibilidad de visualizar y entender los cortes realizados por el modelo. Sin embargo, si los datos tienen una alta variabilidad, este método puede ser restringido en dar unos apropiados resultados. De esta forma, se presentan los resultados asociados a la modelación referente a árboles de decisión para las ASE 1 con profundidad de 3 y de 6 (figura 5.12 y figura 5.13) y para la ASE 2 manejando las mismas profundidades (figura 5.14 y figura 5.15).

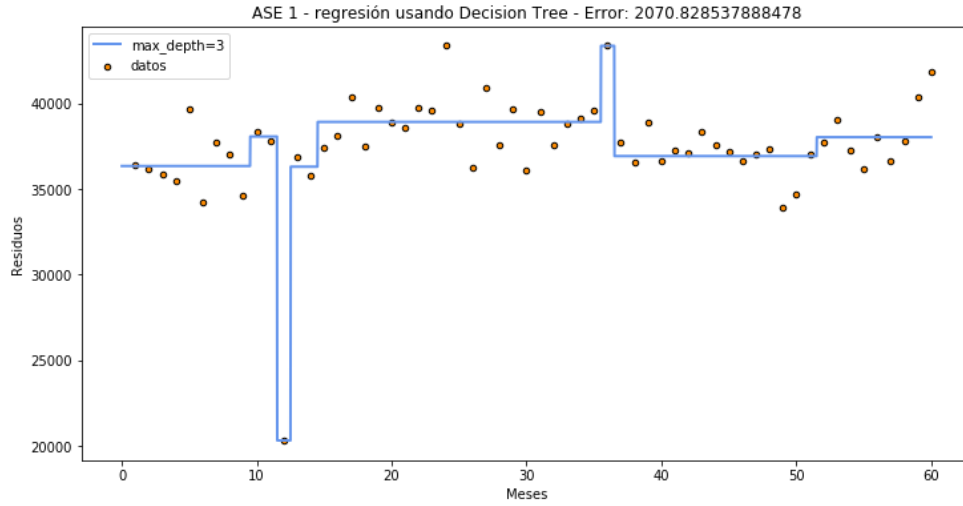


Figura 5.12.- Árboles de decisión para la ASE 1. Profundidad = 3




Figura 5.13.- Árboles de decisión para la ASE 1. Profundidad = 6




Figura 5.14.- Árboles de decisión para la ASE 2. Profundidad = 3

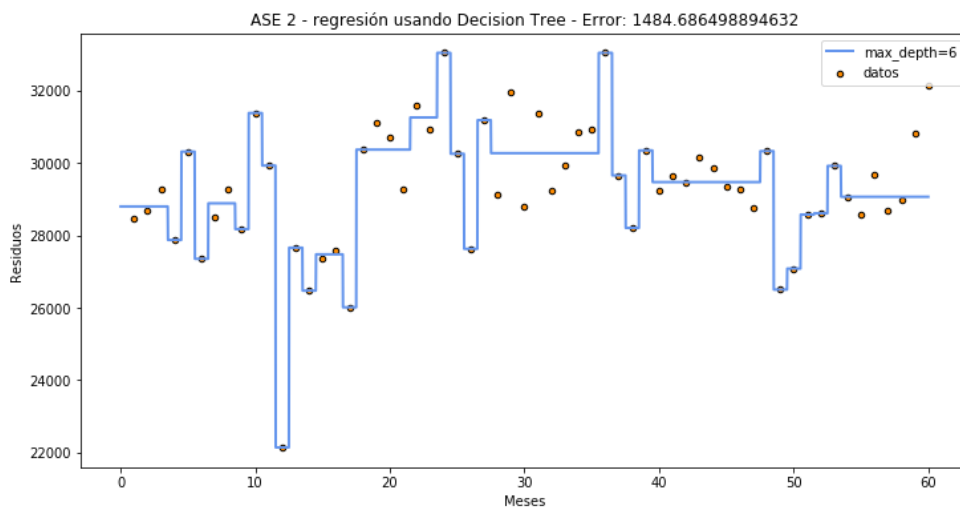


Figura 5.15.- Árboles de decisión para la ASE 2. Profundidad = 6

Un tercer método analizado como modelo de predicción fueron las máquinas de soporte vectorial (MSV). En el notebook implementado, se calculó un modelo de regresión utilizando como kernel una función de base radial. El comportamiento se ilustra en las

figuras 5.16 y 5.17, utilizando diferentes kernels que pueden interpretar mejor los datos de entrenamiento para efectuar una mejor predicción.




Figura 5.16.- MSV para la ASE 1




Figura 5.17.- MSV para la ASE 2

Los resultados obtenidos demuestran que este método el método MSV ajusta apropiadamente a los datos seleccionados y logra curvas coherentes de regresión pese a que los datos de entrenamiento son muy limitados.

6. Propuesta metodológica

En este capítulo se presenta la propuesta metodológica basada en redes neuronales artificiales de tipo LSTM, el cual se constituye en una apuesta por la integración de todas las etapas de gestión de residuos incluyendo aspectos de predicción en la generación y costos en un modelo asociado a la IA, de manera que se busque la optimización de todo el proceso y se pueda definir para una zona o área de estudio la mejor alternativa para la gestión y tratamiento de los residuos que allí se generan. La metodología y el modelo propuesto representan una oportunidad para que las administraciones municipales cuenten con herramientas que permitan incluir múltiples variables según las particularidades regionales, de manera que den resultados precisos y así poder tomar una decisión acertada en cuanto a la gestión de sus RSU.

6.1. Propuesta metodológica para el aprovechamiento y disposición de residuos sólidos urbanos basada en redes neuronales artificiales tipo LSTM

Para facilitar el trabajo computacional y teniendo en cuenta el objetivo de esta fase, fue necesario realizar nuevamente una reestructuración de los datos ya que, como se mencionó, en el año 2018 comenzó un nuevo esquema de recogida de residuos en la ciudad de Bogotá por lo que cambió la estructura de la base de información con la que se había trabajado hasta el momento.

Hay que destacar que Suba, una de las áreas de investigación de este estudio corresponde ahora a la ASE 5 únicamente, lo que hace más detallado el análisis para esta localidad.

La relación de las localidades incluidas en cada ASE y la identificación de los operadores de servicio correspondientes se muestran en la tabla 6.1.

Tabla 6.1.- Estructura por ASE a partir de 2018

ASE	Nombre del operador de servicio en cada ASE	Localidad por ASE
ASE 1	PROMOAMBIENTAL	Usme, San Cristóbal, Santa Fe, La Candelaria, Chapinero, Usaquén, Sumapaz
ASE 2	LIME S.A E.S.P.	Ciudad Bolívar, Bosa, Tunjuelito, Rafael Uribe, Antonio Nariño, Puente Aranda, Teusaquillo, Los Mártires
ASE 3	CIUDAD LIMPIA	Fontibón, Kennedy
ASE 4	BOGOTÁ LIMPIA	Engativá, Barrios Unidos
ASE 5	ÁREA LIMPIA	Suba

(UAESP, 2020c)

Para el planteamiento de la propuesta metodológica se requieren como etapas previas la definición de las principales variables involucradas en el proceso en cada una de las etapas de la gestión y un análisis preliminar para la identificación de áreas críticas en cuanto a generación de RSU.

Una vez se cuenta con la definición de variables, se procede al establecimiento de la herramienta para la modelación de los datos según la información que puede ser obtenida. En este caso, tras la realización del estudio teórico de la mejor alternativa dentro de esta área de conocimiento según la calidad y cantidad de los datos obtenidos, fueron seleccionadas las RNA de tipo LSTM como herramienta estratégica dentro de las técnicas de IA. A su vez, Python fue seleccionado como software para el planteamiento del algoritmo del modelo, dados los beneficios y facilidades del mismo, los cuales fueron descritos en la sección 2.1.6. Una vez establecidos estos parámetros, se procedió a realizar el planteamiento de la propuesta metodológica, la cual finaliza con una validación y análisis comparativo para la determinación de su rendimiento (figura 6.1).

La figura 6.2 representa el diagrama de flujo asociado a la propuesta metodológica en sí, la cual se realizó para RNA como centro de la investigación. Se optó por realizar la modelación de igual forma para MSV en la última fase dados los resultados previos obtenidos en la presente investigación y como estrategia comparativa del comportamiento de este tipo de herramientas.

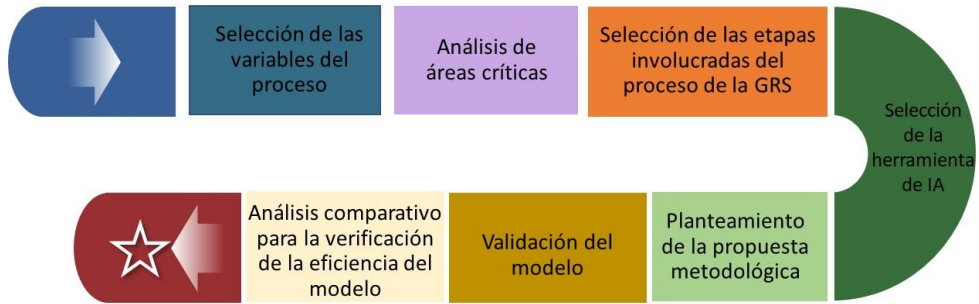


Figura 6.1.- Metodología para la formulación del modelo

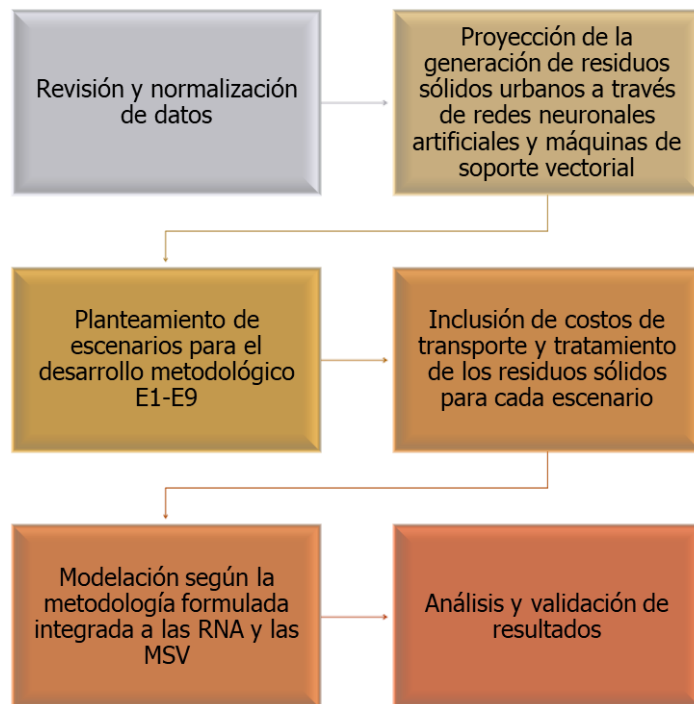


Figura 6.2.- Propuesta metodológica basada en RNA como soporte para la toma de decisiones para la gestión de RSU

Esta propuesta metodológica define la ruta a seguir para la obtención de un modelo que permita definir las posibilidades de implementación de tecnologías para una población determinada según sus particularidades. Aunque la propuesta se centró en el caso de estudio de dos localidades de la ciudad de Bogotá, esta podría ser aplicada a cualquier población que cuente con la información referente a las variables analizadas.

La primera etapa de la metodología propuesta se refiere a la obtención de datos para su posterior revisión, organización, análisis y normalización. Los datos que es necesario recopilar para la aplicación metodológica son los siguientes:

- histórico de generación de RSU de la población,
- histórico del crecimiento poblacional y sus predicciones,
- costos de transporte y
- costos tecnológicos para los posibles tratamientos de estos residuos.

Una vez se tienen las bases de datos organizadas, se realizan las proyecciones de la generación de los RSU con la herramienta de IA seleccionada. Para esta investigación, como se ha mencionado, fueron utilizadas las RNA de tipo LSTM.

Para la ejecución de este modelo es necesario precisar posibles escenarios de tratamiento, aprovechamiento y disposición de los RSU. Debido a las particularidades, necesidades y posibilidades para la implementación tecnológica en la zona, en este caso se definieron nueve escenarios posibles, obtenidos a partir de diversos estudios previos que involucran costos tecnológicos para cada tratamiento. Estos estudios previos están sustentados de forma detallada en los llamados documentos de referencia de las mejores técnicas disponibles en tratamiento e incineración de residuos (*Best Available Techniques* - BAT - *Reference Documents* – BREFs). Los documentos BREF fueron tomados como referencia para los análisis en el estudio de técnicas alternativas de tratamiento, disposición final y/o aprovechamiento de residuos sólidos del BID (2016), preparados dentro del marco de referencia del control integrado de prevención y control de la contaminación.

En la elección de las alternativas tecnológicas se analizaron previamente criterios técnicos, legales, financieros, económicos y ambientales, dentro de los que se encuentran los siguientes (BID, 2016):

- *Técnicas probadas*: nivel de desarrollo del tipo de tratamiento, la cantidad de años de su utilización y el número de instalaciones que funciona a nivel internacional, así como la disponibilidad esperada de cada técnica y la confiabilidad de su operación.
- *Porcentaje de desviación de residuos*: de acuerdo con experiencias internacionales, se estableció un porcentaje de desviación de residuos sólidos que se evitaría disponer en los rellenos sanitarios.
- *Impacto ambiental*: especialmente, en lo que respecta a la salida de cada proceso (emisiones), el uso del suelo y los requerimientos de área para emplazamiento de cada tratamiento.

- *Complejidad*: personal requerido, la complejidad técnica de la maquinaria a usar, los requerimientos de monitoreo y análisis de laboratorio. También, se muestran algunas condiciones especiales para la implementación exitosa del tratamiento y se presenta si hay o no proveedores en Colombia.
- *Costos*: costos tentativos de implementación, la cantidad aproximada de inversión, los costos anuales de operación y mantenimiento, así como la vida útil proyectada del tratamiento y los costos de tratamiento por tonelada de residuo.
- *Escala*: se muestra la capacidad de operación de cada tratamiento en términos de toneladas a tratar por día, mes o año.
- *Balance de masas y energía*
- *Evaluación ambiental, económica y social*: beneficios y costos ambientales, económicos y sociales y los costos del no uso del relleno sanitario.
- *Participación de recicladores*: se precisa si la técnica usa o no mano de obra de recicladores de oficio.
- *Condiciones para la introducción exitosa del tratamiento*: requerimientos de legislación y regulación de soporte, necesarios para que el tratamiento analizado pueda funcionar en el país, analiza el mercado de subproductos y las necesidades de capacitación de personal y de inversiones en investigación y desarrollo.

Definidos los escenarios, se integran al modelo los costos asociados a transporte. Se tomó como base para el cálculo la normativa nacional en Colombia, el coste por km recorrido, el centro de gravedad de la zona y el IPC para la actualización anual de dichos valores.

Se integran de igual forma al modelo los costes de las tecnologías definidas en los escenarios. Estos costos fueron definidos considerando los costos de pre-inversión, inversión, operación, mantenimiento, administración, gravamen a los movimientos financieros, el costo del capital de trabajo y el costo promedio ponderado de capital. De igual forma, se consideraron los ingresos por comercialización de subproductos (BID, 2016), según el tamaño de planta. Los valores finales de costos para el modelo planteado fueron ajustados al año 2020, por lo que se requiere el ajuste según las variables económicas correspondientes según el año al cual se desea realizar la predicción.

Como resultado del análisis se determinó el mejor escenario de implementación técnico-económico para las zonas de estudio, desde un modelo que integra las etapas principales de un sistema de gestión de residuos y que permite a los tomadores de decisiones soportar la determinación de una estrategia para la gestión de los RSU de su región. Para ello, también se deberá tener presente los PGIRS, las políticas nacionales asociadas a los RSU, los planes de ordenamiento territorial, los planes de desarrollo y la normativa particular regional y nacional.

De esta forma, se ha comprobado que la aplicación del modelo es viable para el área de estudio así como para poblaciones con características similares que cuenten con los datos requeridos para su implementación.

Una vez planteado el modelo mediante la utilización de RNA de tipo LSTM, se logró como etapa final de la metodología la realización de un análisis comparativo de su rendimiento, a través de la utilización de MSV. Los resultados obtenidos también fueron adecuados, lo que permitió evidenciar que la metodología propuesta es flexible, adaptativa y dinámica, no sólo respecto a los datos alimentados al modelo sino también respecto a su arquitectura, lo que permite que se pueda optimizar constantemente, en la medida que se mejoran los sistemas de información regionales de manera que se tengan bases de datos robustas de la generación de RSU principalmente.

6.2. Análisis del modelo propuesto

Aunque existe una amplia variedad de redes neuronales, con diversas arquitecturas según la tarea de predicción establecida, en el caso de series temporales, las redes neuronales recurrentes han mostrado resultados favorables. Por tanto, para el modelo se implementaron redes LSTM utilizando Python como lenguaje de programación a través del uso de Jupyter *notebooks* en el entorno de Google Colab, el cual permite el desarrollo de códigos abiertos y que, para este caso, se constituye en una herramienta adecuada para el desarrollo del modelo.

En general, los algoritmos basados en redes neuronales aprenden funciones no lineales y no paramétricas, a partir de un conjunto de datos de entrenamiento. Existen aproximaciones que permiten ser eficientes en el entrenamiento, utilizando un subconjunto de datos (*batch*) y realizando este proceso un número determinado de interacciones (*epochs*). Para mejorar el comportamiento de estos métodos, se implementó previamente una ventana deslizante que permite filtrar temporalmente los datos para obtener un suavizado secuencial según sus vecinos locales. Teniendo en cuenta que estas redes LSTM fueron diseñadas para problemas de predicción temporal, existen parámetros propios que pueden ser adaptados para un mejor comportamiento de la predicción, en señales escalonadas que tienen periodos propios de frecuencia y ajustando el tiempo de paso.

En este caso, la señal es por meses y se tienen varios años registrados por lo que se esperaría que un año fuera el periodo ideal de la modelación y, por tanto, se podría ajustar a un paso de 12 meses. Es entonces que una vez se establece el modelo y configurado su método de aprendizaje, se procede al entrenamiento para lo cual se utilizó la función *fit*, con *epochs* de 30. El conjunto de datos de validación está compuesto por los datos correspondientes al periodo 2017 al 2020.

Con los resultados obtenidos, se realizó una verificación referente a la proyección en la generación de RSU con datos reales, presentando resultados favorables. La arquitectura de la red está estructurada en doscientas cincuenta y seis neuronas, la función de tangente hiperbólica se utilizó como función de activación por defecto y se utilizó una función lineal para la capa densa. Aunque el modelo permite realizar el análisis para todas las ASE, se enfocaron los resultados a las ASE en donde se encuentran Suba y Engativá, como localidades de estudio.

El notebook está dividido en secciones y es necesario ejecutarlas secuencialmente en el mismo orden:

- Ajuste de modelos de predicción (entrenamiento)
- Predicción de la producción de residuos sólidos
- Análisis financiero de la disposición

En la sección de ajuste de modelos de predicción se entrena el algoritmo sobre los datos organizados en archivo Excel para entrenamiento y, una vez seleccionada la configuración deseada, se ejecuta la celda y ésta automáticamente habilita la opción para subir el archivo requerido, para lo cual se utilizó una sola serie temporal (figura 6.3).



Figura 6.3.- Ajuste del Modelo de predicción

Una vez ejecutado el entrenamiento, se debe escoger la zona y el año hasta donde se desea realizar las predicciones lo que corresponde a la segunda sección en el diseño del modelo (figura 6.4).

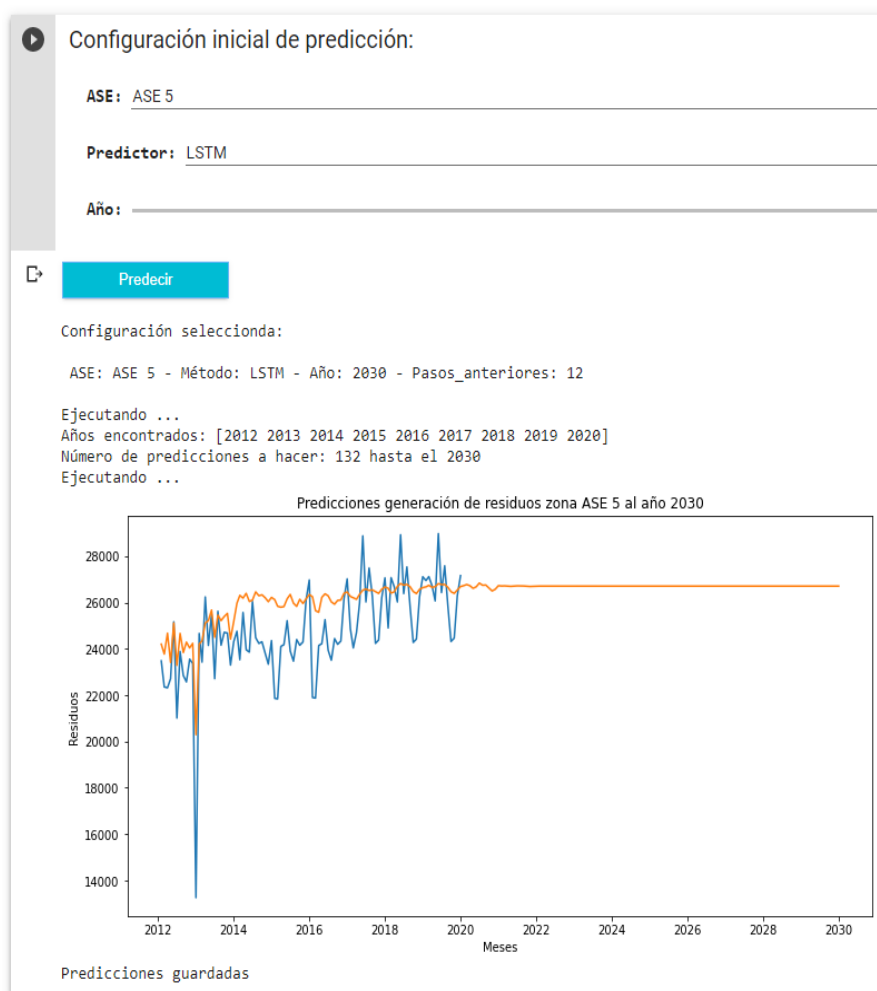


Figura 6.4.- Predicción por ASE

Finalmente, la sección de análisis realiza los cálculos de costos, ingresos y totales mensuales en cada escenario a lo largo de las predicciones realizadas en el paso anterior para lo cual es necesario cargar los datos de manera similar a la sección de entrenamiento. Los resultados calculados son: ingresos medios mensuales, costos medios mensuales y promedio total mensual de costos (costos - ingresos) para el año seleccionado y para cada uno de los escenarios seleccionados. El modelo presenta las predicciones de producción de residuos por mes en ese mismo año y las respectivas gráficas de costos, ingresos y totales en ese año (figura 6.5).

+ Código + Texto Copiar en Drive
Meses

Predicciones guardadas

▼ Análisis financiero de la disposición

- ▶ Cargar información de costos:
 - ▶ Subir Excel de DATOS (Formato: Excel)

Elegir archivos: Ningún archivo seleccionado Upload widget is only available when the cell has been executed in the current browser session. Please return this cell to enable. Saving datos.xlsx to Datos.xlsx
- ▶ Análisis financiero:

Escenario: E2
E3
E4
E5
E6

Relleno: Doña Juana

Año: 2030

Ejecutar

Cálculos con valores del mes Marzo del año 2028

Zona	Escenario	Año	Proceso 1	% proceso 1	Proceso 2	% proceso 2	Promedio total/mes	Promedio Ingresos/mes	Promedio Costos/mes		
ASE 5	E6	2030	Compostaje de residuos separados en la fuente	0,6	Relleno Sanitario	0,4	7184.306 M	2313.641 M	9497.947 M		
Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
25877.1	25877.9	25876.7	25876.6	25876.4	25876.3	25876.2	25876.1	25876	25875.9	25875.8	25875.8

Figura 6.5.- Análisis de costos e ingresos

Con respecto a los datos de costos, se estructuró un único archivo Excel con múltiples pestañas para integrarlo con mayor facilidad dentro del modelo:

- Una pestaña corresponde a los escenarios, en donde se describe la información general de los mismos, el nombre, el porcentaje de cada proceso y la complejidad.
- La pestaña de costos generales 2015 almacena los puntos referentes para calcular las funciones de costes medio por tonelada, ingresos por venta de residuos valorizados por tonelada e ingresos por tarifa del servicio de aseo, en donde cada función tiene tres puntos referentes para calcular las funciones a través de interpolación. Para dichas funciones se utilizó `scipy.interpolate.interp1d` como interpolador. Cabe resaltar que para los valores fuera del dominio de la función se toman los valores de los extremos.
- La siguiente pestaña contiene las distancias (en km) de cada lugar de disposición a cada zona. Se ha organizado por cada proceso en cada escenario, lo que define las variantes de disposición de cada proceso.
- La pestaña costos vs distancias 2018 almacena los costes de transporte por tonelada en función de la distancia y el total de toneladas a transportar.
- Finalmente una pestaña denominada IPC almacena los valores respectivos del IPC mensual y anual, para los ajustes económicos correspondientes de todos los datos al año 2020.

Las variables incluidas dentro del modelo fueron:

- La generación de RSU y sus proyecciones al año 2030
- La población de la ciudad y sus proyecciones
- Los nueve escenarios establecidos (figura 6.6) los cuales identifican las Mejores Tecnologías Disponibles, costes de proceso y los ingresos posibles por comercialización de subproductos generados¹
- Las distancias posibles a los dos lugares de disposición final, la primera asociada al vertedero Doña Juana y la segunda a una zona alternativa, para realizar un comparativo de costos²

¹ Como base de esta información tanto de escenarios como de costos e ingresos, se tomó como referente el estudio denominado “Estudio de técnicas alternativas de tratamiento, disposición final y/o aprovechamiento de residuos sólidos – Propuesta de ajuste Decreto 838 de 2005” (Compilado en el Decreto 1077 de 2015) del Banco Interamericano de Desarrollo (BID, 2016)

² Para lo asociado a costos de transporte se tuvo en cuenta para los cálculos lo establecido en la Resolución CRA 853 de 2018 de la Comisión de Regulación de Agua Potable y Saneamiento Básico (Minvivienda, 2018). Es importante destacar en este trabajo la inclusión de esta información, ya que el estudio suministrado no es público; no se han realizado análisis de la información contenida en él que incluyan proyecciones RSU y costos; y no se han desarrollado modelos de análisis incorporando herramientas de IA.




Figura 6.6.- Escenarios analizados por el modelo (BID, 2016)

A continuación se muestran los resultados obtenidos para el año 2030, tanto para la ASE 4, dentro de la cual se encuentra la localidad de Engativá (figura 6.7) como para la ASE 5 que actualmente se constituye en la localidad de Suba únicamente (figura 6.8). Ambas se constituyen como como las zonas de interés para la presente investigación.

Debemos dejar constancia de que el modelo diseñado ha sido aplicado para la obtención de resultados en todas las ASE de Bogotá por lo que la investigación permitió la visualización del comportamiento de las redes LSTM para todas las zonas de recolección de la ciudad. Para los cálculos del error asociado a cada una de las predicciones realizadas con las redes LSTM se utilizó el MSE y el MAE el cual fue de 0,2284 para la ASE 4 y 0,1894 en la ASE 5.




Figura 6.7.- Análisis predictivo de la generación de RSU para el año 2030 para la ASE 4 (LSTM)




Figura 6.8.- Análisis predictivo de la generación de RSU para el año 2030 para la ASE 5 (LSTM)

A continuación se muestran los resultados obtenidos para los costos referentes a la distancia de trabajo 1 para las ASE 4 y 5 (tabla 6.2), así como para la distancia de trabajo 2 (tabla 6.3), para los cuales se trabajó como parámetro de cálculo al valor presente para el año 2020. En ellas se presentan los resultados del tratamiento y los costos de transporte para el año 2030.

Tabla 6.2.- Relación de costos e ingresos (2030) para la distancia de disposición 1 (LSTM)

ASE	Escenario	Promedio mensual de generación de residuos (2030) (t/mes)	Costes medios mensuales (\$)	Ingresos medios mensuales (\$)
ASE 4	E1	25.310	4.216.565	1.154.529
	E2		4.352.313	1.091.825
	E3		2.874.381	502.129
	E4		2.417.796	237.887
	E5		2.641.632	385.473
	E6		2.281.202	602.177
	E7		2.119.451	3.315
	E8		2.194.040	82.047
	E9		2.128.568	38.952
ASE 5	E1	26.074	4.650.092	1.218.098
	E2		4.793.317	1.151.941
	E3		3.234.006	529.777
	E4		2.752.281	250.985
	E5		2.988.442	406.697
	E6		2.608.166	633.737
	E7		2.437.510	3.498
	E8		2.516.205	86.565
	E9		2.447.128	41.096

Para el primer escenario, los residuos se disponen en el relleno sanitario de Doña Juana como se realiza actualmente (distancia 1). También se incluyeron y calcularon los ingresos potenciales por la venta de subproductos del proceso de tratamiento primario para los diferentes escenarios. Ante la problemática del relleno sanitario actual de la ciudad, se muestra un segundo análisis, en el que se presenta una segunda distancia aproximada (distancia 2), que hace referencia a la zona donde se ubica el relleno sanitario de Mondoñedo (figura 6.9), como alternativa para la disposición de desechos sólidos en áreas cercanas o en ese vertedero.

Tabla 6.3.- Relación de costos e ingresos (2030) para la distancia de disposición 2 (LSTM)

ASE	Escenario	Promedio mensual de generación de residuos (2030) (t/mes)	Costes medios mensuales (\$)	Ingresos medios mensuales (\$)
ASE 4	E1	25.310	4.258.553	1.154.529
	E2		4.394.304	1.091.825
	E3		2.935.454	502.129
	E4		2.509.405	237.887
	E5		2.702.705	385.473
	E6		2.357.543	602.177
	E7		2.310.303	3.315
	E8		2.384.892	82.047
	E9		2.319.420	38.952
ASE 5	E1	26.074	4.738.690	1.218.098
	E2		4.881.916	1.151.941
	E3		3.362.877	529.777
	E4		2.945.587	250.985
	E5		3.117.313	406.697
	E6		2.769.255	633.737
	E7		2.840.231	3.498
	E8		2.918.926	86.565
	E9		2.849.849	41.096

La decisión de utilizar los emplazamientos de Doña Juana o Mondoñedo depende de los estudios de viabilidad y lo establecido en los POT sobre esta opción, para poder realizar un análisis comparativo de costos. Sin embargo, al haber formulado un modelo dinámico, las distancias podrían ajustarse. Asimismo, este ejercicio de analizar dos distancias se realiza para mostrar que el modelo permite ajustar distancias a los emplazamientos de tratamiento de manera que se puedan realizar análisis comparativos y brindar a los tomadores de decisiones alternativas sobre diferentes estrategias en función de las variables asociadas al modelo.




Figura 6.9.- Mapa de ubicación del vertedero Doña Juana (distancia 1) y del vertedero Nuevo Mondoñedo (distancia 2) (Catastro Distrital Bogotá, 2020)

De acuerdo con los resultados del análisis económico, para cada escenario en las ASE 4 y 5, el escenario con los costos más bajos es E7. Sin embargo, la mejor alternativa es la proporcionada por el escenario E6, no sólo porque representa uno de los escenarios con los costos más bajos, sino también porque la cantidad de ingresos es representativamente alta dentro de los enfoques propuestos. Su relación costos-ingresos lo convierte en el escenario más adecuado según los resultados obtenidos en el modelo (tablas 6.2 y 6.3). Los datos asociados a costos se ajustaron al año 2020 de acuerdo con el IPC, por lo que a los valores obtenidos se dan en función del cambio en la generación de residuos año a año, debiendo realizar el ajuste económico correspondiente.

De acuerdo con los resultados obtenidos para el modelo propuesto, se concluye que el comportamiento de las redes de tipo LSTM es adecuada para los primeros cinco años de predicción. Sin embargo, al intentar considerar predicciones a un futuro lejano (mayores 5 años) los costos tienden a un promedio histórico, lo que puede estar asociado a patrones débiles aprendidos debido a los errores propagados en las predicciones a futuro. Por ello, se decidió no realizar predicciones de variables económicas y manejar los datos de costo ajustados al año 2020.

Por todo ello, el escenario E6 se plantea como la mejor alternativa para la gestión de los RSU, el cual propone un 60% de los residuos para compostaje y un 40% para relleno sanitario, siendo el escenario que presenta una mejor relación costos-ingresos.

Es de tener en cuenta el hecho de que las operaciones de gestión de RSU están en su mayoría desactualizadas con registros confiables limitados y datos sensoriales escasos, especialmente en países en desarrollo (Abdallah et al., 2020), como ocurre con los datos obtenidos para la modelación. Sin embargo, el modelo planteado en esta investigación es flexible y posibilita la actualización de datos de forma permanente, lo que hace posible minimizar el error obtenido y permite obtener mejores resultados para un periodo de tiempo determinado.

El aumento de la generación de residuos sólidos requiere de medidas prioritarias para su adecuada gestión. Generalmente se selecciona opciones de tratamiento de RSU basado en el juicio y la experiencia de individuos con autoridad y experiencia, mientras se subestima el papel de las técnicas que se derivan del conocimiento científico (Kazuva y Zhang, 2019). Es así que, con el desarrollo de la inteligencia artificial, los algoritmos de alto rendimiento hacen posibles predicciones confiables desde la perspectiva de los datos (Song, 2020), por lo que las administraciones municipales deben tener en cuenta este tipo de modelos que podrían representar un respaldo confiable para una determinada decisión. En los últimos años, las herramientas como las redes neuronales y el aprendizaje profundo están aplicándose al análisis de series temporales, explorando entonces las redes neuronales artificiales y las redes neuronales recurrentes (RNN), las cuales han demostrado que en cuanto a pronósticos son mucho mejores en comparación con los métodos tradicionales, en donde las redes LSTM son un tipo de RNN que tienen la capacidad de aprender las dependencias a largo plazo (Yadav et al., 2020). Las redes LSTM son uno de los modelos de aprendizaje profundo más populares actualmente, los cuales se han aplicado a la predicción de series temporales, un problema de gran dificultad debido a la presencia de tendencias a largo plazo, fluctuaciones estacionales y cíclicas y ruido aleatorio (Muzaffar y Afshari, 2019).

Las redes neuronales recurrentes utilizadas en este trabajo han logrado una descripción de los datos de forma coherente. Sin embargo, en algunos casos, son muy sensibles y las dificultades para lograr una correcta predicción están básicamente en el requerimiento de una gran cantidad de datos para lograr predicciones robustas y apropiadas. En el caso de la gestión de residuos sólidos urbanos puede ser difícil obtener información histórica acerca de la producción de residuos. Sin embargo, es precisamente éste uno de los

objetivos propuestos para la zona de estudio y la metodología propuesta se presenta como estrategia a considerar frente a la utilización de modelos lineales, contando con sistemas de información que permitan tomar decisiones acertadas, incidiendo así en criterios de economía circular a través de la gestión de residuos sólidos y su relación con el servicio público de aseo (DNP et al., 2016).

6.3. Análisis comparativo de la implementación de redes neuronales artificiales de tipo LSTM y máquinas de soporte vectorial en modelos asociados a la gestión de residuos sólidos urbanos en grandes ciudades

Como estrategia comparativa y de análisis de rendimiento de herramientas, se implementaron las MSV para el mismo modelo y los resultados se compararon con los obtenidos al aplicar RNA de tipo LSTM. Las máquinas de soporte vectorial utilizan funciones paramétricas locales para estimar las fronteras de separación entre clases, o estimar la función que mejor se ajusta a los datos. Por otra parte, existe la posibilidad de usar diferentes kernels que pueden interpretar mejor los datos de entrenamiento para efectuar una mejor predicción.

A continuación, se presentan los resultados obtenidos al utilizar esta herramienta sobre los datos disponibles (figuras 6.10 y 6.11) para realizar predicciones sobre el horizonte 2030 para cada una de las áreas de recolección de residuos sólidos de la ciudad (ASE). Los resultados muestran que las MSV se ajustan mejor a los datos de entrenamiento e intentan replicar dicho patrón en las predicciones, mientras que las LSTM aprenden un patrón más general y resulta en predicciones periódicas notorias.

Es importante mencionar que las MSV capturan tanto el patrón de crecimiento en los datos de entrenamiento como el comportamiento predominante en los datos para luego replicarlo en las predicciones realizadas. En las tablas siguientes (tablas 6.4 y 6.5) se muestran los resultados de costos obtenidos de este modelo implementando las MSV para las dos distancias de trabajo anteriormente planteadas.




Figura 6.10.- Análisis predictivo de la generación de RSU para el año 2030 para la ASE 4 (MSV)




Figura 6.11.- Análisis predictivo de la generación de RSU para el año 2030 para la ASE 5 (MSV)

Tabla 6.4.- Relación de costos e ingresos (2030) para la distancia de disposición 1 (MSV)

ASE	Escenario	Promedio mensual de generación de residuos (2030) (t/mes)	Costes medios mensuales (\$)	Ingresos medios mensuales (\$)
ASE 4	E1	24.817	4.134.337	1.132.014
	E2		4.267.441	1.070.533
	E3		2.818.327	492.337
	E4		2.370.646	233.248
	E5		2.590.117	377.956
	E6		2.236.716	590.434
	E7		2.078.120	3.250
	E8		2.151.253	80.447
	E9		2.087.058	38.192
ASE 5	E1	25.877	4.506.023	1.180.359
	E2		4.644.811	1.116.252
	E3		3.133.811	513.363
	E4		2.667.010	243.209
	E5		2.895.854	394.097
	E6		2.527.360	615.649
	E7		2.361.991	3.389
	E8		2.438.248	83.883
	E9		2.371.311	39.823

Tabla 6.5.- Relación de costos e ingresos (2030) para la distancia de disposición 2 (MSV)

ASE	Escenario	Promedio mensual de generación de residuos (2030) (t/mes)	Costes medios mensuales (\$)	Ingresos medios mensuales (\$)
ASE 4	E1	24.817	4.175.506	1.132.014
	E2		4.308.610	1.070.533
	E3		2.878.209	492.337
	E4		2.460.464	233.248
	E5		2.642.016	377.956
	E6		2.311.568	590.434
	E7		2.265.250	3.250
	E8		2.338.384	80.447
	E9		2.274.188	38.192
ASE 5	E1	25.877	4.591.876	1.218.098
	E2		4.730.664	1.151.941
	E3		3.258.689	529.777
	E4		2.854.327	250.985
	E5		3.020.733	406.697
	E6		2.683.458	633.737
	E7		2.752.235	3.498
	E8		2.828.492	86.565
	E9		2.761.556	41.096

En la figura 6.12, se puede analizar de forma gráfica el análisis comparativo de costos para cada ASE, por distancia y herramienta de IA utilizado. Se puede observar que los costos más bajos por escenario y modelo corresponde a las ASE 4 y 5. Al utilizar las distintas técnicas de IA sobre los datos disponibles, se han obtenido resultados consistentes en todos los casos.




Figura 6.12.- Relación de costos proyectados para el año 2030 (promedio mensual) por ASE, modelos, escenarios y distancias

Algunos resultados significativos son los siguientes:

- La ASE 2 presenta los mayores valores en cuanto al análisis de costos, dado que es la localidad que genera mayor cantidad de residuos sólidos de la ciudad, la cual es proporcional a la densidad de población en esa zona. Los valores más bajos se dan en las ASES 4 y 5 por ser las zonas con menor densidad de población en la ciudad.
- Para la ASE 4, con los costos más bajos, el promedio mensual aproximado de menor costo fue el correspondiente al escenario E7 con un valor de 2.326.874 dólares.
- Sin embargo, si se tienen en cuenta los posibles ingresos generados en el proceso, el escenario óptimo sería el escenario E6 con un valor de 16.435.044 dólares como promedio mensual aproximado usando como lugar de disposición final el relleno Doña Juana, el cual plantea tratamiento de residuos sólidos en un 60% para compostaje y un 40% para relleno sanitario. Las máquinas de soporte vectorial se han mostrado como el modelo de mejor comportamiento.
- Para la ASE 2, con los costos más altos, el escenario más favorable es el E7, para el cual los costos ascienden a 6.446.908 dólares. Si se incluyen en los cálculos los ingresos proyectados para los distintos escenarios, el escenario E6 es el mejor con un valor promedio mensual 4.628.449 dólares. Este comportamiento se repite para todas las ASE.

Para cuantificar el error asociado a cada una de las predicciones realizadas por estos métodos, en este trabajo se utilizó el MSE y el MAE. La tabla 6.6 presenta los resultados obtenidos para cada modelo por ASE.

Tabla 6.6- Errores obtenidos para cada uno de los métodos por ASE

Método Zona	ASE 1		ASE 2		ASE 3		ASE 4		ASE 5	
	MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE
SVR	0,0108	0,0820	0,0419	0,1341	0,0110	0,0845	0,0946	0,1996	0,0300	0,1204
LSTM	0,0383	0,1524	0,0530	0,1800	0,0893	0,2436	0,0886	0,2204	0,0448	0,1797

Se ha observado que el método MSV presenta los errores más bajos en entrenamiento. Además, las ASE 2,4 y 5 presentan los errores absolutos más elevados en entrenamiento por este método. Para las redes LSTM los valores mayores para el error absoluto se ha encontrado en las ASE 3 y 4. El valor menor corresponde a la ASE 1 tanto para SVR como para las redes LSTM.

6.4. Aporte de la propuesta metodológica a la solución de problemáticas ambientales

Uno de los ejes estratégicos asociados a las políticas colombianas en materia de residuos sólidos busca establecer estrategias que permitan la prevención de la generación de residuos, la minimización de la llegada de éstos a los rellenos sanitarios, promoviendo su reutilización, aprovechamiento y tratamiento y evitando así la generación de gases efecto invernadero. De igual forma, buscan establecer que todas las entidades participantes del proceso de gestión lideren actividades referentes al tratamiento de los residuos y el fortalecimiento de los sistemas urbanos de reciclaje (DNP et al., 2016). La optimización de las etapas dentro de la gestión de residuos sólidos es una alternativa de apoyo a estas directrices, dirigida a la minimización de impactos ambientales como fin prioritario, sin dejar de lado los beneficios económicos que pueden reflejarse dentro de todo el proceso y los posibles beneficios sociales de la población involucrada en dicha gestión.

Determinar con certeza la generación de residuos sólidos de una región, como una de las etapas de mayor importancia dentro del proceso de diseño tecnológico, permite determinar su gestión adecuada minimizando así el depósito de los mismos en vertedero, lo cual, para el caso de estudio particular analizado en esta investigación supone minimizar la presión sobre el mismo y la afectación a las comunidades vecinas al sector en donde se encuentra ubicado. Determinar con mayor precisión las estrategias y tecnologías a implementar de manera que se determinen otras alternativas al relleno sanitario, conlleva directamente una disminución de lixiviados y menores áreas requeridas para los sitios de disposición final. Igualmente, determinar las mejores técnicas disponibles asegura que los residuos sean gestionados de manera ambientalmente responsable, que se minimice

la emisión de contaminantes al agua y al aire y, de igual forma, que se disminuya el consumo de energía (BID, 2016).

Esta implementación tecnológica, determinada a través de modelos de optimización, permite establecer su viabilidad económica, lo que también implica que se tenga un control más preciso de su funcionamiento y, en consecuencia, un funcionamiento más adecuado desde el punto de vista medioambiental. Contar con modelos que permitan determinar las mejores técnicas de aprovechamiento de residuos según las particularidades de una población determinada tiene como fin último minimizar los impactos ambientales y fomentar el aprovechamiento de material recuperable. Todo ello es particularmente relevante en Colombia, cuyos RSU según su caracterización cuentan con un alto contenido de materia orgánica, lo que tiene como consecuencia un impacto significativo por emisiones a la atmósfera de gases de efecto invernadero y la generación de mayor cantidad de lixiviados en sitios de disposición final (BID, 2016).

Por tanto, la metodología propuesta permite contribuir a los objetivos establecidos en las políticas nacionales en cuanto a la optimización de escenarios que permitan determinar la estrategia más adecuada según las variables principales de decisión. El modelo propuesto considera el uso de diferentes herramientas que logran obtener resultados más precisos que los alcanzados con técnicas de cálculo convencionales. Además, los SIG se integran a los modelos para la mejora de la visualización de la generación de RSU en una zona determinada y así definir áreas críticas que requieren atención prioritaria tomando como referente la posición geográfica. De igual forma, la integración de las RNA a los modelos para dar soluciones a problemáticas ambientales que tienen como referentes datos de comportamiento no lineal, se constituyen en un aporte al avance de la modelación y simulación ambiental.

En esta investigación, la arquitectura de las redes de tipo LSTM permitió el planteamiento de un modelo que integra aspectos técnicos, tecnológicos y ambientales que tiene como consecuencia directa la obtención de evidentes beneficios sociales. Las RNA se han aplicado en muchos estudios de gestión de residuos por su fuerte capacidad de tolerancia a fallos e idoneidad para representar las complejas relaciones entre variables en sistemas multivariados (Abdallah et al., 2020; citado en Nguyen et al., 2021). A pesar de las limitaciones de datos, lo cual constituye el principal reto para la formulación de modelos, así como la baja interpretabilidad, las técnicas de *Machine Learning* tienen un gran potencial de aplicación en varios campos, incluida la toma de decisiones de gestión de residuos, reducción del ciclo de tratamiento, mejoras en la utilización de recursos y mitigación del riesgo de contaminación por residuos sólidos. En la mayoría de los estudios relevantes consultados, se han adoptado técnicas basadas en RNA para modelado y predicción, seguido de MSV, algoritmos genéticos y árboles de decisión (Guo et al., 2021).

Con todo ello, las RNA se consignan significativamente en el campo del diseño de modelos y la simulación ambiental como una estrategia avanzada para la optimización de procesos, convirtiéndose en un campo atractivo para la gestión de RSU. Esto ha quedado

de manifiesto en la presente investigación, que ha logrado integrar las variables más representativas del problema para la determinación del mejor escenario tecnológico, teniendo en cuenta todas las fases del proceso. Todo ello tiene como consecuencia proporcionar información que permita avanzar hacia una adecuada gestión de los residuos, lo que induce impactos ambientales positivos mientras determina el tratamiento más apropiado de los RSU según las posibilidades de una región.

Por otra parte, la predicción de la generación de residuos, la inclusión de costos asociados a su transporte, así como los costos asociados a posibles alternativas de tratamiento, permite minimizar la posibilidad de toma de decisiones poco acertadas reduciendo el riesgo de fallos dentro de las etapas de la gestión. Todo ello tiene como consecuencia no solo la minimización de posibles consecuencias ambientales y sobre la salud de las personas expuestas, sino que también supone la optimización de recursos económicos y beneficios sociales para las partes involucradas. Buscar a través de diferentes propuestas y modelos el uso de técnicas alternativas a las que tradicionalmente se implementan en el país, permitirán a Colombia cumplir con estándares ambientales internacionales. Aunque se están logrando avances importantes para la transformación tecnológica en este sector, es necesario que algunas instalaciones se enfoquen hacia mecanismos más favorables para el ambiente y la sociedad (BID, 2016).

7. Conclusiones

Como resultado de la aplicación práctica presentada en las localidades de Suba y Engativá, se ha obtenido un modelo integrador de las diferentes etapas del proceso de gestión de una ciudad basado en redes neuronales de tipo LSTM. La propuesta metodológica planteada tiene en cuenta variables referentes a cantidad de población, cantidad de residuos sólidos generados por ASE, costos de transporte, costos de disposición y posibles ingresos por comercialización de subproductos obtenidos en los procesos de tratamiento. Según los escenarios modelados, el escenario más favorable, tanto para la ciudad de Bogotá como para las localidades de estudio, es el que presenta como alternativas tecnológicas el compostaje de residuos separados en la fuente junto con la disposición final de los rechazos en relleno sanitario.

El resultado anterior ha sido obtenido tras la aplicación de la propuesta metodológica presentada y desarrollada en la presente tesis doctoral. Los resultados obtenidos demuestran la utilidad de las técnicas SIG como una valiosa herramienta complementaria para analizar y diseñar sistemas robustos de gestión de residuos sólidos ya que permiten la elaboración de mapas de generación de RSU con respecto a la posición geográfica, la identificación de zonas críticas de atención prioritaria y la identificación de la evolución de esta generación a lo largo del tiempo. De esta forma, se ha demostrado que se puede aplicar una ruta analítica que integre el análisis espacial junto con el tratamiento estadístico de datos para comprender la distribución de la generación de residuos sólidos en las diferentes localidades, y de igual forma realizar un análisis de acuerdo a las características socioeconómicas de la población, para así evaluar la generación actual y futura de los RSU. Todo ello se ha podido realizar sin la necesidad de disponer de datos

preliminares complejos, ya que para esta área de estudio la adquisición de datos es uno de los factores que limitan la implementación de herramientas de predicción y modelación en general, dando cumplimiento al objetivo de esta investigación relacionado con la validación de la generación de RSU con métodos de cálculo tradicionales.

La aplicación de estas técnicas de análisis estadístico con herramientas SIG ha permitido estimar la generación de residuos municipales per cápita por estrato socioeconómico (PPC_{str}) a través del análisis de cuatro escenarios diferentes. En esta primera etapa de la investigación se consideraron diferentes hipótesis sobre las propiedades del PPC_{str} , en donde se identificó que los datos de la ASE 3 no son consistentes con los datos de las demás ASE. Por lo tanto, los escenarios 3 y 4 planteados para esa fase de la investigación no consideran los datos de ASE 3 con fines de minimizar los errores de estimación, obteniendo así resultados mucho más precisos. Es importante reiterar que la estrategia de análisis propuesta se puede aplicar a cualquier gran área urbana para realizar una evaluación de la generación actual y futura de RSU, sin necesidad de datos preliminares complejos no disponibles.

En la segunda fase de la investigación, se implementaron tres métodos diferentes de predicción de valores de producción de RSU. Primeramente se utilizaron métodos basados en redes neuronales artificiales LSTM para la estimación de trayectorias de puntos. En la implementación de las redes LSTM se tuvo en cuenta diferentes configuraciones, filtros temporales y cálculo de periodos anuales de los residuos. Teniendo en cuenta el número limitado de datos disponibles, se realizó una exploración de éstos utilizando árboles de decisión con diferentes profundidades. También se logró la implementación de MSV para el cálculo de modelos de regresión basados en funciones radiales locales, calculadas a partir de puntos (vectores de soporte) en un vecindario específico. Como herramienta de cálculo del error, se implementó la raíz del error medio cuadrático. De esta segunda fase se puede concluir que las RNA tipo LSTM presentan un buen rendimiento para la proyección de RSU en grandes ciudades, considerando y revisando el comportamiento y la proyección de los RSU por zonas y teniendo presente la baja disponibilidad de datos que son requeridos para este tipo de modelos.

En la tercera fase del proceso de investigación se presenta la propuesta metodológica basada en redes neuronales artificiales, la cual integra la realización del análisis predictivo y una proyección en el cálculo de costos de tratamiento de RSU, así como los posibles ingresos por comercialización de los subproductos obtenidos tras los procesos de pretratamiento realizados en la planta de clasificación o valorización correspondiente. Se decidió usar redes de tipo LSTM debido a su capacidad de aplicación directa a la predicción de series temporales. En esta etapa de la investigación se dio cumplimiento a los objetivos establecidos referentes a implementar técnicas de modelación mediante RNA para la gestión integral de residuos sólidos urbanos tomando datos reales del área de estudio seleccionada y su articulación en el desarrollo de un instrumento metodológico para la determinación de la opción más adecuada para el aprovechamiento de los residuos sólidos en las localidades establecidas para la ciudad de Bogotá.

Igualmente, en esta tercera fase de la investigación se realizó un análisis comparativo de la propuesta metodológica, modelando primero mediante RNA tipo LSTM y en segunda instancia utilizando técnicas MSV. Se ha tenido presente que la principal ventaja de las máquinas de soporte vectorial es su apropiado ajuste a los datos a pesar de la naturaleza variable de estos o frente a problemas que contienen pocos datos de entrenamiento.

Como resultado del análisis realizado, se obtuvieron los costos calculados en los nueve escenarios planteados para las zonas ASE 4 y ASE 5 y para todos los años. En estos análisis, Engativá se encuentra en la ASE 4 y Suba corresponde a la totalidad de la ASE 5. Del proceso de modelación se concluye que en la zona ASE 4, el escenario E6 (compostaje de residuos separados en la fuente y relleno sanitario), presentó los mejores resultados asociados a la relación costo-ingreso para las dos herramientas utilizadas (LSTM y MSV), considerando como lugar de disposición final el relleno Doña Juana. Es de asumir que a una mayor distancia se incrementaría el valor de los costes pero se requería evaluar si este aumento de costes se considera significativo o por el contrario serían costes que se podrían asumir en caso de que se decida optar por otro emplazamiento para la disposición final de los rechazos de planta. También habría que considerar la existencia de otros impactos positivos económicos, ambientales y sociales.

Para la zona ASE 5 se ha observado el mismo comportamiento en cuanto a la determinación del escenario, pero se tiene como resultado un valor menor de los costes, usando las máquinas de soporte vectorial. Desde otro punto de vista, los escenarios que presentan mayores ingresos son el E1 (incineración y relleno sanitario) y E2 (gasificación y relleno sanitario). Sin embargo, a estos escenarios corresponden también los mayores costos.

Los resultados obtenidos en esta investigación presentan la posibilidad de implementar modelos asociados a redes neuronales artificiales tipo LSTM, y adicionalmente a MSV, para la predicción de la generación de residuos sólidos urbanos así como para el cálculo de posibles costos a largo plazo. Dadas las características reales de los procesos asociados a la gestión de los RSU, la posibilidad de disponer de datos en grandes cantidades es una tarea compleja e improbable, lo que limita la modelación en este tipo de herramientas a medio y largo plazo. La insuficiencia de datos es un obstáculo importante que afecta la implementación de sistemas de IA, dado que estos modelos de IA se basan precisamente en la disponibilidad de amplios conjuntos de datos para fines de entrenamiento y calibración. Esto es precisamente lo que ocurre a menudo en gestión de RSU por la falta o la incompletitud de las series de datos de residuos.

Por tanto, a partir del análisis realizado, se podría concluir que la herramienta que mejores rendimientos proporcionó fueron las MSV. Sin embargo, esta herramienta no presenta comportamientos adecuados en todas las zonas de Bogotá al realizar un análisis del modelo global para la ciudad. Es así como las ASE 1 y 3 las MSV aparentemente presentan patrones de predicción acordes con la serie vista en entrenamiento. Sin embargo, en las ASE 2, 4 y 5 (de acuerdo con la distribución de localidades a partir del 2018), el rendimiento se evidencia alejado de los datos reales, mientras que para las redes

recurrentes los mejores comportamientos de predicción se presentan precisamente en estas zonas, por lo que es necesario una mayor cantidad de datos para mejorar las proyecciones.

Como resultado final de la aplicación práctica planteada en las localidades de Suba y Engativá, teniendo presentes las variables establecidas para las zonas objeto de este estudio y considerando los diferentes planteamientos realizados en la última etapa de la investigación, la opción más favorecedora es la que considera la gestión de los RSU en dos corrientes: una que destina un 60% de los residuos para compostaje y la otra en donde el 40% restante es depositado en vertedero controlado. Este escenario proporciona la mejor relación costos-ingresos, ya sea utilizando las máquinas de soporte vectorial o las redes neuronales LST. Sin embargo, el menor error se asocia a las MSV en las zonas de estudio.

Se puede concluir entonces, según lo determinado en las últimas etapas de la investigación, que es posible el planteamiento de metodologías que permitan mejorar y apoyar el proceso de toma de decisiones dentro de la gestión de los RSU que integren las redes neuronales artificiales para este caso de tipo LSTM. Dada la estructura y el diseño del modelo es posible incorporar datos, a la medida que son obtenidos, para robustecer la base de información y minimizar el error obtenido. De igual forma, es posible implementar el modelo para regiones con características similares, para las cuales se disponga de datos confiables que puedan ser proporcionados al modelo, dada la flexibilidad que éste tiene para incorporar procesos de mejora y actualización de la información. La propuesta metodológica planteada, así como la arquitectura general del modelo, es adaptativa y actualizable, facilitando así la mejora continua de su rendimiento.

Es de destacar que, hasta el desarrollo de esta investigación, en Colombia aún no se había implementado este tipo de estrategias o modelos matemáticos avanzados que permitieran ratificar las decisiones que se toman respecto a la implantación de alternativas tecnológicas en una región en cuanto a la gestión de sus RSU se refiere. Por ello, esta investigación aporta contribuciones significativas para el avance de planteamientos que permitan determinar la mejor opción de gestión de los RSU de una población, fomentando el uso de modelos matemáticos dentro de este proceso. Generalmente las herramientas de IA se han utilizado en procesos de optimización de las diferentes etapas de la gestión de RSU por separado. En este trabajo se ha demostrado que es posible plantear propuestas metodológicas que integren las principales etapas de esta gestión para la adecuada gestión de los residuos generados por una población en particular.

8. Líneas de futura investigación

Tras la realización de la investigación desarrollada se han identificado diversas líneas de futura investigación que la complementan y amplían. Una de ellas se refiere a la inclusión dentro de estos modelos del análisis de ciclo de vida de cada una de las tecnologías, lo cual puede ser analizado mediante diferentes softwares para este fin. Tal es el caso del software Sima-Pro, el cual es una herramienta confiable para este tipo de procesos. Para este análisis se requieren datos reales tanto de entrada como de salida de cada una de las tecnologías planteadas, y por tanto de los escenarios, de manera que los resultados obtenidos puedan enlazarse con las redes neuronales artificiales del modelo y así disponer de un panorama completo que involucre todas las posibles variables. De igual forma, en la medida que se cuente con una base de datos robusta y con datos históricos confiables en cada una de las etapas del proceso de la gestión de los residuos se podrá mejorar la precisión en los cálculos y disminuir los porcentajes de error dentro de los modelos asociados al desarrollo metodológico. Esta línea de investigación debe relacionarse directamente con los propósitos establecidos para el país en materia de gestión de RSU, la adopción de políticas referentes a la economía circular y el cumplimiento de los Objetivos de Desarrollo Sostenible (ODS), según las metas propuestas a 2030, las cuales involucran en esta gestión directamente la meta asociada a la reducción del impacto ambiental negativo per cápita de las ciudades prestando atención a la gestión de residuos municipales enmarcada al objetivo 11 Ciudades y comunidades sostenibles (Departamento Nacional de Planeación et al., 2016).

Otra posible línea de investigación que se desprende de este trabajo se refiere a las diferentes herramientas de inteligencia artificial para la optimización de planteamientos

metodológicos. Actualmente, los conocimientos científicos en esta área de la ingeniería buscan la optimización de las herramientas tradicionales con principios más robustos que permitan minimizar los errores y ajustarse a las variables o limitaciones en los datos para un determinado proceso. El análisis comparativo entre diferentes herramientas permitirá el planteamiento de modelos eficientes para la toma de decisiones más cercanas a la realidad de una ciudad en la medida que las bases de datos se fortalezcan y se pueda obtener información histórica continua para que los modelos se ajusten a las particularidades de cada análisis realizado y mejoren los procesos en todas sus etapas y, particularmente, en las etapas de predicción, las cuales se convierten en determinantes para una planificación a futuro de la implementación de estrategias o tecnologías para una ciudad con características determinadas.

9. Referencias

Agencia de Cooperación Internacional del Japón (JICA) y Unidad Administrativa Especial De Servicios Públicos (UAESP) (2013). Proyecto de Estudio del Plan Maestro para el Manejo Integral de Residuos Sólidos en Bogotá, D.C. Informe Final Volumen II, Informe Principal (1).

Abdallah, M.; Abu Talib, M.; Feroz, S.; Nasir, Q.; Abdalla, H. y Mahfood, B. (2020). Artificial intelligence applications in solid waste management: A systematic research review. *Waste Management*, 109, 231-246, doi: 10.1016/j.wasman.2020.04.057

Abbasi, M. y El Hanandeh, A. (2016). Forecasting municipal solid waste generation using artificial intelligence modelling approaches. *Waste Management (Elmsford)*, 56, 13-22, doi: 10.1016/j.wasman.2016.05.018

Aggarwal, C. C. (2018). *Neural Networks and Deep Learning*. Springer International Publishing AG, doi: 10.1007/978-3-319-94463-0

Alcaldía de Bogotá, D.C., Secretaría de Hacienda y Departamento Administrativo de Planeación (2004). *Recorriendo Suba. Diagnóstico físico y socioeconómico de las localidades de Bogotá, D.C.* Consultado el 13 de mayo de 2020. Recuperado de: www.shd.gov.co/shd/sites/default/files/documentos/RECORRIENDO%20SUBA.pdf

Alcaldía De Bogotá y Secretaría De Planeación (2014) *Proyecciones de población por localidades para Bogotá 2016-2020*. Dirección De Estudios Macro. Consultado el 18 de abril de 2020. Recuperado de: www.sdp.gov.co/sites/default/files/boletin69.pdf

Alcaldía de Bogotá (2016). Plan de Gestión Integral de Residuos Sólidos -PGIRS. PGIRS actualización octubre de 2016. Consultado el 1 de diciembre de 2020. Recuperado de: www.uaesp.gov.co/images/Actualizacion_PGIRS_20161018_Completo.pdf

Alcaldía de Bogotá (2018). Decreto 652 de 2018 de la Alcaldía Mayor de Bogotá. Recuperado: Consultado el 13 de mayo de 2020. Recuperado de: www.uaesp.gov.co/sites/default/files/documentos/Decreto%20652%20de%202018.pdf

Alcaldía de Bogotá (2020a). Localidad de Suba | Bogota.gov.co. Consultado el 10 de mayo de 2020. Recuperado de: bogota.gov.co/mi-ciudad/localidades/suba

Alcaldía de Bogotá (2020b). Localidad de Engativá | Bogota.gov.co. Consultado el 10 de mayo de 2020. Recuperado de: bogota.gov.co/mi-ciudad/localidades/engativa

Alcaldía Local de Engativá (2016). Plan de Desarrollo Local "Engativá Mejor para todos - Engativá renace contigo 2016-2020". Consultado el 1 de diciembre de 2020.

Recuperado de:

www.engativa.gov.co/sites/engativa.gov.co/files/planeacion/plande_desarrollo_2017-2020.pdf

Alcaldía Local de Engativá (2020). Diagnóstico Local Alcaldía Local De Engativá. Documento Técnico Base Para La Construcción Del Plan De Desarrollo Local. Versión borrador 3. Consultado el 1 de diciembre de 2020, Recuperado de: www.sdp.gov.co/sites/default/files/documento_tecnico_pdl-engativa.pdf Consultado: 30 de noviembre de 2020

Alcaldía local de San Cristóbal (2019). Todo lo que debes saber sobre Bogotá en 2019. Consultado el 15 de enero de 2021. Recuperado de: www.sancristobal.gov.co/noticias/todo-lo-debes-saber-sobre-bogota-2019

Alcaldía Local de Suba (2017). Diagnóstico local sectorial y documento de priorización. Gobierno seguridad y Convivencia. Registro Distrital, Bogotá Distrito Capital (Colombia). Consultado el 1 de diciembre de 2020. Recuperado de: www.alcaldiabogota.gov.co/sisjur/adminverblobawa?tabla=T_NORMA_ARCHIVO&p_NORMFIL_ID=11092&f_NORMFIL_FILE=X&inputfileext=NORMFIL_FILENAME Consultado:30 de noviembre de 2020

Asociación Interamericana de Ingeniería Sanitaria y Ambiental – AIDIS (2018). Gestión Integral de Residuos Sólidos Urbanos. Consultado el 1 de diciembre de 2020.

Recuperado de: aidisnet.org/wp-content/uploads/2019/08/GESTION-INTEGRAL-DE-RESIDUOS-SOLIDOS-URBANOS-LIBRO-AIDIS.pdf

Asociación para el Progreso de la Dirección, APD (2020). Técnicas de la inteligencia artificial: ¿Cuáles son y para qué se utilizan? APD España. Consultado el 1 de diciembre de 2020. Recuperado de: www.apd.es/tecnicas-de-la-inteligencia-artificial-cuales-son-y-para-que-se-utilizan/.

Banco Interamericano de Desarrollo, BID (2016). Estudio de técnicas alternativas de tratamiento, disposición final y/o aprovechamiento de residuos sólidos – propuesta de ajuste decreto 838 de 2005 (compilado en el decreto 1077 de 2015), Departamento de Planeación Nacional.

Basogain, (s.f.). Redes neuronales artificiales y sus aplicaciones. Escuela Superior de Ingeniería de Bilbao, EHU -UPV. Consultado el 17 de mayo de 2020. Recuperado de: ocw.ehu.eus/pluginfile.php/9047/mod_resource/content/1/redes_neuro/contenidos/pdf/libro-del-curso.pdf

Bengio, Y.; Goodfellow, I. y Courville, A. (2016). Deep Learning. Cambridge, MA: MIT Press.

Benítez, R.; Escudero G.; Kanaan S. y Masip Rodó, D. (2014). Inteligencia artificial avanzada. Barcelona, España: Editorial UOC. Consultado el 5 de diciembre de 2020, Recuperado de: elibro.net/es/ereader/usta/57582?page=13.

Betancourt, G. (2005). Las máquinas de soporte vectorial (MSVs). *Scientia et technica*, 1(27), 67-72. Consultado el 4 de diciembre de 2020. Recuperado de: dialnet.unirioja.es/servlet/oaiart?codigo=4838384

Boser, B.E.; Guyon, I.M. y Vapnik, V.N. (1992). A training algorithm for optimal margin classifiers. in 5th Annual ACM Workshop on COLT (ed. Haussler, D.) 144–152 (ACM Press, Pittsburgh, PA, 1992).

Bonilla, V. (2017). Machine Learning con tensorflow. Univesidad Politécnica de Madrid, Escuela Técnica superior de Ingenieros Informáticos. Trabajo fin de grado

Caicedo Bravo, E. F. y López Sotelo, J. A. (2009). Una aproximación práctica a las redes neuronales artificiales. Programa Editorial Universidad del Valle. Consultado el 4 de diciembre de 2020. Recuperado de: elibro.net/es/ereader/usta/129183?page=22.

Campos, F. (2020). Redes Neuronales Recurrentes. Predicción de una serie temporal. *Diegocalvo.es*. Consultado el 6 de diciembre de 2020. Recuperado de: www.diegocalvo.es/redes-neuronales-recurrentes-prediccion-de-una-serie-temporal/.

Casas Roma, J.; Bosch Rué, A. y Lozano Bagén, T. (2019). Deep leRNAing: principios y fundamentos. Editorial UOC. Consultado el 4 de diciembre de 2020, elibro.net/es/ereader/usta/126167?page=179.

Catastro Distrital Bogotá (2020). Mapas Bogotá. Consultado el 10 de octubre de 2020. Recuperado de: mapas.bogota.gov.co/#

Centeno Franco, A. (2019). DEEP LERNAING. Universidad de Sevilla, Trabajo de fin de grado Consultado el 4 de diciembre de 2020. Recuperado de: idus.us.es/bitstream/handle/11441/90004/Centeno%20Franco%20Alba%20TFG.pdf?sequence=1&isAllowed=y.

- Cogua (2013). Dinámica de las construcciones por usos de la localidad de Engativá en los años 2002 y 2012. Alcaldía Mayor de Bogotá, Unidad Administrativa Especial De Catastro Distrital, Observatorio Técnico Catastral. Consultado el 15 de enero de 2021. Recuperado de: www.catastrobogota.gov.co/sites/default/files/archivos/engativa.pdf
- Chhay, L.; Reyad, M. A. H.; Suy, R.; Islam, M. R. y Mian, M. 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, doi: 10.1007/s10163-018-0743-4
- Departamento Administrativo Nacional de Estadística (DANE) (s.f.). Preguntas frecuentes estratificación. Consultado el 15 de enero de 2020. Recuperado de: www.dane.gov.co/files/geoestadistica/Preguntas_frecuentes_estratificacion.pdf
- Departamento Administrativo Nacional de Estadística (DANE) (2020). Información para todos. Consultado el 13 de mayo de 2020. Recuperado de: www.dane.gov.co/index.php/69-espanol/geoestadistica/estratificacion/468-estratificacion-socioeconomica
- Departamento Nacional de Planeación, Ministerio de Ambiente y Desarrollo Sostenible, Ministerio de Vivienda, Ciudad y Territorio, Ministerio de Educación, Nacional, Ministerio de Minas y Energía, Comisión de Regulación de Agua Potable y Saneamiento Básico, Departamento Administrativo Nacional de Estadísticas, Superintendencia de Servicios Públicos Domiciliarios, Unidad de Planeación Minero-Energética (2016). Documento CONPES 3874, Política nacional para la gestión integral de residuos sólidos. Consultado el 10 de mayo de 2020. Recuperado de: colaboracion.dnp.gov.co/CDT/Conpes/Econ%20C3%B3micos/3874.pdf
- Dixon, B. y Candade, N. (2007). Multispectral land use classification using neural networks and support vector machines: one or the other, or both? *International Journal of Remote Sensing*, 29(4), 1185-1206, doi: 10.1080/01431160701294661
- Downey, A.; Elkner, J. y Meyers, C. (2002). *Aprenda a Pensar Como un Programador con Python*. Argentinaenpython.com. Consultado el 9 de diciembre de 2020. Recuperado de: argentinaenpython.com/quiero-aprender-python/aprenda-a-pensar-como-un-programador-con-python.pdf.
- El Nuevo Siglo (2019). 8 puntos claves del 'negocio' del reciclaje. Consultado el 17 de mayo de 2020. Recuperado de: www.elnuevosiglo.com.co/articulos/03-2019-8-puntos-claves-del-negocio-del-reciclaje
- Elman J.L. (1990). Finding Structure in Time, *Cognitive science*, no. 14.
- Shamshiry, E.; Nadi, B.; Bin Mokhtar, M.; Komoo, I.; Saadiah Hashim, H. y Yahya, N. (2011). Forecasting Generation Waste Using Artificial Neural Networks, search.proquest.com/docview/1272281114
- Escamirosa Montalvo, L. F.; Uriel del Carpio Penagos, C. y Castañeda Nodasco, G. (2001). Manejo de los residuos sólidos domiciliarios en la ciudad de Tuxtla Gutiérrez

Chiapas. México D.F., México: Plaza y Valdés, S.A. de C.V. Consultado el 5 de diciembre de 2020. Recuperado de: elibro.net/es/ereader/usta/73323?page=18.

Franklin Templeton Investments (2019). Inteligencia artificial: una oportunidad real. Consultado el 24 de marzo de 2021 Recuperado de: www.franklintempleton.com.es/content-common/marketperspective/es_ES/localOS/Inteligencia%20artificial_una%20oportunidad%20real.pdf

García Bartual, R. (2015). Redes Neuronales Artificiales en Ingeniería Hidráulica y Medioambiental: FUNDAMENTOS

García García, A. (2011). INTRODUCCIÓN A PYTHON. Sites.google.com. Consultado el 9 de diciembre de 2020. Recuperado de: sites.google.com/site/pythoncolombia/documentos/56131068-Introduccion-a-Python.pdf?attredirects=0yd=1.

Gobierno de Colombia, (2017). Plan Nacional de Desarrollo. 2018-2022. Pacto por Colombia, pacto por la equidad. Colaboracion.dnp.gov.co. Consultado el 8 de diciembre de 2020. Recuperado de: colaboracion.dnp.gov.co/CDT/Prensa/Resumen-PND2018-2022-final.pdf.

Golbaz, S.; Nabizadeh, R. y Sajadi, H. S. (2019). Comparative study of predicting hospital solid waste generation using multiple linear regression and artificial intelligence. *Journal of Environmental Health Science and Engineering*, 17(1), 41-51, doi: 10.1007/s40201-018-00324-z

González-Avella, J. C.; Tudurí J. M. y Rul-lan G. (2017). Análisis de Series Temporales Usando Redes Neuronales Recurrentes APSL

González Duque, R (s.f.). Python para todos. Consultado el 6 de diciembre de 2020. Recuperado de: www.utic.edu.py/citil/images/Manuales/Python_para_todos.pdf

Granados Núñez, P. (2019). Pronóstico de series temporales utilizando Deep Learning con aplicación en fusión nuclear, Pontificia Universidad Católica de Valparaíso, tesis de grado

Guo, H.; Wu, S.; Tian, Y.; Zhang, J. y Liu, H. (2021). Application of machine leRNAing methods for the prediction of organic solid waste treatment and recycling processes: A review. *Bioresource Technology*, 319, 124114 doi: 10.1016/j.biortech.2020.124114

Hasituya; Chen, Z.; Wang, L.; Wu, W.; Jiang, Z. y Li, H. (2016). Monitoring Plastic-Mulched Farmland by Landsat-8 OLI Imagery Using Spectral and Textural Features. *Remote Sensing*, 8(4), 353, doi: 10.3390/rs8040353

Hochreiter, S. y Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation* 9 (8). MIT Press: 1735–80.

Jahandideh, S.; Jahandideh, S.; Asadabadi, E. B.; Askarian, M.; Movahedi, M. M.; Hosseini, S. y Jahandideh, M. (2009). The use of artificial neural networks and multiple

linear regression to predict rate of medical waste generation. *Waste Management*, 29(11), 2874-2879, doi: 10.1016/j.wasman.2009.06.027

Jalili Ghazi Zade, M. y Noori, R. (2007). Prediction of Municipal Solid Waste Generation by Use of Artificial Neural Network: A Case Study of Mashhad. *International Journal of Environmental Research*, 2(1), www.bioline.org.br/abstract?id=er08002

Kannangara, M.; Dua, R.; Ahmadi, L. y Bensebaa, F. (2018). Modeling and prediction of regional municipal solid waste generation and diversion in Canada using machine learning approaches. *Waste Management*, 74, 3-15, doi: 10.1016/j.wasman.2017.11.057

Kaza, S.; Yao, L. C.; Bhada-Tata, P.; Van Woerden, F. (2018). *What a Waste 2.0: A Global Snapshot of Solid Waste Management to 2050*. Urban Development. Washington, DC: World Bank. Consultado el 5 de diciembre de 2020, openknowledge.worldbank.org/handle/10986/30317 License: CC BY 3.0 IGO."2018

Kazuva, E. y Zhang, J. (2019). Analyzing Municipal Solid Waste Treatment Scenarios in Rapidly Urbanizing Cities in Developing Countries: The Case of Dar es Salaam, Tanzania. *International Journal of Environmental Research and Public Health*, 16(11), 2035, doi: 10.3390/ijerph1611203

Kolekar, K. A.; Hazra, T. y Chakrabarty, S. N. (2016). A Review on Prediction of Municipal Solid Waste Generation Models. *Procedia Environmental Sciences*, 35, 238-244, doi: 10.1016/j.proenv.2016.07.087

Korhonen, P. y Kaila, J. (2015). Waste container weighing data processing to create reliable information of household waste generation. *Waste Management*, 39, 15-25, doi: 10.1016/j.wasman.2015.02.021

Leong, W. C.; Kelani, R. O. y Ahmad, Z. (2019). Prediction of air pollution index (API) using support vector machine (MSV). *Journal of Environmental Chemical Engineering*, 8(3), 103208, doi: 10.1016/j.jece.2019.103208

Kumar, A.; Samadder, S. R.; Kumar, N. y Singh, C. (2018). Estimation of the generation rate of different types of plastic wastes and possible revenue recovery from informal recycling. *Waste Management*, 79, 781-790, doi: 10.1016/j.wasman.2018.08.045

Li, P.; Kwon, H.; Sun, L.; Lall, U. y Kao, J. (2009). A modified support vector machine-based prediction model on streamflow at the Shihmen Reservoir, Taiwan. *International Journal of Climatology*, 30(8), 1256-1268, doi: 10.1002/joc.1954

Lin, G.; Li, L.; Tseng, M.; Liu, H.; Yuan, D. y Tan, R. R. (2020). An improved moth-flame optimization algorithm for support vector machine prediction of photovoltaic power generation. *Journal of Cleaner Production*, 253, 119966, doi: 10.1016/j.jclepro.2020.119966

- Lu, W. (2019). Big data analytics to identify illegal construction waste dumping: A Hong Kong study. *Resources, Conservation and Recycling*, 141, 264-272. 10.1016/j.resconrec.2018.10.039
- Lu, W., Chen, X., Peng, Y., y Shen, L. (2015). Benchmarking construction waste management performance using big data. *Resources, Conservation and Recycling*, 105, 49-58, doi: 10.1016/j.resconrec.2015.10.013
- Lu, W.; Chen, X.; Peng, Y. y Shen, L. (2015). Benchmarking construction waste management performance using big data. *Resources, Conservation and Recycling*, 105, 49-58, doi: 10.1016/j.resconrec.2015.10.013
- Luna González, J. (2020). Tipos de aprendizaje automático (SOLDAI). Consultado el 4 de diciembre de 2020. Recuperado de: medium.com/soldai/tipos-de-aprendizaje-automatico-6413e3c615e2.
- Mañas, A. (2020). Capítulo 8 Métodos basados en Deep Learning | Notas sobre pronóstico del flujo de tráfico en la ciudad de Madrid. Bookdown.org. Consultado el 4 de diciembre de 2020. Recuperado de: bookdown.org/amanas/traficomadrid/m%C3%A9todos-basados-en-deep-leRNAing.html#lstm-univariado.
- Martín del Brío, B. y Serrano Cinca, C. (1995). Fundamentos de redes neuronales artificiales: hardware y software. Scire: Representación Y Organización Del Conocimiento, 1(1), 103-125. Consultado el 5 de diciembre de 2020. Recuperado de: www.iber-sid.eu/ojs/index.php/scire/article/view/1036
- Martín del Peso, M. (2005). Aplicaciones de las redes neuronales artificiales a problemas de predicción y clasificación financiera. Madrid, España: Universidad Rey Juan Carlos. Recuperado de: elibro.net/es/ereader/usta/34664?page=27.
- Mejía, A.M. (2013). Dinámica de las construcciones por usos de la localidad de SUBA en los años 2002 y 2012. Alcaldía Mayor de Bogotá, Unidad Administrativa Especial De Catastro Distrital, Observatorio Técnico Catastral. Consultado el 15 de enero de 2021. Recuperado de: www.catastrobogota.gov.co/sites/default/files/archivos/suba.pdf
- Menacho, C. (2014). Comparación de los métodos de series de tiempo y redes neuronales. *Anales Científicos*, 75 (2): 245-252
- Ministerio de Vivienda, Ciudad y Territorio, Minvivienda (2012). Reglamento Técnico del Sector de Agua Potable y Saneamiento Básico, TÍTULO F. Sistemas de Aseo Urbano / Viceministerio de Agua y Saneamiento Básico. Bogotá, D.C. Colombia, Ministerio de Vivienda, Ciudad y Territorio. ISBN: 978-958-57464-0-4
- Ministerio de Vivienda, Ciudad y Territorio, Minvivienda (2015). Decreto 1077 de 2015. Consultado el 7 de diciembre de 2020. Recuperado de: www.alcaldiabogota.gov.co/sisjur/normas/Norma1.jsp?i=62512
- Ministerio de Vivienda, Ciudad y Territorio, Minvivienda y Comisión de Regulación de Agua Potable y Saneamiento Básico, CRA (2018). Resolución CRA 853 de 2018.

Recuperado: 28 mayo 2020. Disponible en: www.cra.gov.co/documents/RESOLUCION_CRA_853_DE_2018.pdf

Ministerio de Vivienda, Ciudad y Territorio, Minvivienda (2021). Aprovechamiento. Consultado el 25 de marzo de 2021. Disponible en:

www.minvivienda.gov.co/viceministerio-de-agua-y-saneamiento-basico/gestion-institucional/gestion-de-residuos-solidos/aprovechamiento

Montesdeoca Santana, B. (2016). Estudios de predicción en series temporales de datos meteorológicos utilizando redes neuronales recurrentes. Universidad de las Palmas de gran canaria Accedacris.ulpgc.es Consultado el 4 de diciembre de 2020. Recuperado de: accedacris.ulpgc.es/bitstream/10553/18829/1/0728348_00000_0000.pdf

Noble, W. S. (2006). What is a support vector machine? *Nature Biotechnology*, 24(12), 1565-1567, doi:10.1038/nbt1206-1565

Moroney, L. (2020). *AI and Machine Learning for Coders*. O'Reilly Media, Inc. ISBN: 9781492078197

Muzaffar, S. y Afshari, A. (2019). Short-Term Load Forecasts Using LSTM Networks. *Energy Procedia* 158, 2922-2927.

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. y Nguyen, V. K. (2021). Development of machine leRNAing - based models to forecast solid waste generation in residential areas: A case study from Vietnam. *Resources, Conservation and Recycling*, 167, 105381, doi: 10.1016/j.resconrec.2020.105381

Noori, R.; Abdoli, M. A.; Ghasrodashti, A. A. y Jalili Ghazizade, M. (2009). Prediction of municipal solid waste generation with combination of support vector machine and principal component analysis: A case study of Mashhad. *Environmental Progress y Sustainable Energy*, 28(2), 249-258, doi: 10.1002/ep.10317

Palma Méndez, J. T. (2008). *Inteligencia artificial: métodos, técnicas y aplicaciones*. Madrid, España: McGraw-Hill España. Consultado el 5 de diciembre de 2020. Recuperado de: elibro.net/es/ereader/usta/50116?page=336.

Pan, A.; Yu, L. y Yang, Q. (2019). Characteristics and Forecasting of Municipal Solid Waste Generation in China. *Sustainability* 11(5), 1433, doi: 10.3390/su11051433

Pérez Águila, R. (2012). *Una introducción al cómputo neuronal artificial*. Santa Fe, Argentina, Argentina: El Cid Editor. Consultado el 4 de diciembre de 2020. Recuperado de: elibro.net/es/ereader/usta/34865?page=60.

PUMA-UNAM (1997). *Guía práctica de residuos sólidos*, México, Universidad Nacional Autónoma de México.

Ponce, Pedro (2010). Inteligencia artificial con aplicaciones a la ingeniería. Primera Edición. Alfaomega Grupo Editor, S.A. de C.V. ISBN:978-607-7854-83-8, México.

Programa de las Naciones Unidas para el Desarrollo PNUD, P (2020). Colombia en breve. El PNUD en Colombia. Consultado el 24 de noviembre de 2020 www.co.undp.org/content/colombia/es/home/countryinfo.html#:~:text=Colombia%2C%20al%20noroeste%20de%20Am%C3%A9rica,las%20m%C3%A1s%20progresistas%20del%20mundo.

Red Española de Compostaje, R. E. (2014). Residuos urbanos I.4. Madrid, España: Mundi-Prensa. Consultado el 5 de diciembre de 2020. Recuperado de: elibro.net/es/ereader/usta/55265?page=115.

Revista Semana (2020). Consultado el 12 de mayo de diciembre de 2020. Recuperado de: www.semana.com/nacion/articulo/deslizamiento-en-dona-juana-fue-de-60000-toneladas-de-basura-segun-la-uaesp/666826

Secretaría Distrital de Gobierno (2020). Mapa de localidades de Bogotá. Consultado el 10 de mayo de 2020. Recuperado de: www.gobiernobogota.gov.co/sgdapp/sites/default/files/localidades/mapa/basic/localidadesmapa.html

Secretaría Distrital de Planeación, SDP, (2011). 21 monografías de las Localidades, Distrito Capital. Consultado el 20 de noviembre de 2018. Recuperado de: www.sdp.gov.co/portal/page/portal/PortalSDP/InformacionTomaDecisiones/Estadisticas/Documentos/An%Elisis/DICE062-MonografiaBogota-31122011.pdf

Secretaría Distrital de Planeación, SDP (2018a). Estadísticas, Información para la toma de decisiones Proyecciones por localidades 2005 – 2030. Consultado el 18 de octubre de 2018. Recuperado de: www.sdp.gov.co/portal/page/portal/PortalSDP/InformacionTomaDecisiones/Estadisticas/ProyeccionPoblacion:Proyecciones%20de%20Poblacion

Secretaría Distrital de Planeación, SDP. (2018b). Monografía Engativá "Diagnóstico de los principales aspectos territoriales, de infraestructura, demográficos y socioeconómicos". Bogotá D.C. Consultado el 28 de noviembre de 2020. Recuperado de: www.sdp.gov.co/gestion-estudios-estrategicos/informacion-cartografia-y-estadistica/repositorio-estadistico/monografia-de-bogota-2017%5D

Secretaría de Planeación Distrital, SDP, (2020). Estadísticas, información para la toma de decisiones; Proyecciones por distritos 2005–2030. Consultado el 28 de abril de 2020. Recuperado de: www.sdp.gov.co/portal/page/portal/PortalSDP/InformacionTomaDecisiones/Estadisticas/ProyeccionPoblacion:Proyecciones%20de%20Poblacion

Secretaría Distrital del Hábitat (2020). Unidad Administrativa Especial de Servicios Públicos | Secretaría Distrital del Hábitat. Consultado el 10 de mayo de 2020. Recuperado de: www.habitatbogota.gov.co/node/229

- Serna, C. (2018). Una Pequeña Introducción a Machine Learning, Universidad Central. Consultado el 4 de diciembre de 2020. Recuperado de: hplab.uccentral.edu.co/~hfranco/data_analysis/SessionV/VSession.pdf
- Singh, A. (2019). Solid waste management through the applications of mathematical models. *Resources, Conservation & Recycling*, 151, 104503, doi: 10.1016/j.resconrec.2019.104503
- Sistema Único de Información de Servicios Públicos. (2017). Informe de Gestión SUI 2017. Bogotá D.C: Alcaldía de Bogotá.
- Singh, D. y Satija, A. (2016). Prediction of municipal solid waste generation for optimum planning and management with artificial neural network—case study: Faridabad City in Haryana State (India). *International Journal of System Assurance Engineering and Management*, 9(1), 91-97, doi: 10.1007/s13198-016-0484-5
- Shu, H.; Lu, H.; Fan, H.; Chang, M. y Chen, J. (2006). Prediction for Energy Content of Taiwan Municipal Solid Waste Using Multilayer Perceptron Neural Networks. *Journal of the Air and Waste Management Association*, 56(6), 852-858, doi: 10.1080/10473289.2006.10464497
- Solano Meza, J. K., Orjuela Yepes, D., Rodrigo-Illari, J., y Cassiraga, E. (2019). Predictive analysis of urban waste generation for the city of Bogotá, Colombia, through the implementation of decision trees-based machine learning, support vector machines and artificial neural networks. *Heliyon*, 5(11), e02810, doi: 10.1016/j.heliyon.2019.e02810
- Song, X.; Liu, Y.; Xue, L.; Wang, J.; Zhang, J.; Wang, J.; Jiang, L. y Cheng, Z. (2020). Time-series well performance prediction based on Long Short-Term Memory (LSTM) neural network model. *Journal of Petroleum Science and Engineering*, 186, 106682, doi: 10.1016/j.petrol.2019.106682
- Superintendencia de Servicios Públicos Domiciliarios, Superservicios; Departamento de Planeación Nacional, DNP (2018). Informe de Disposición Final de Residuos Sólidos – 2017. Consultado el 10 May 2020. Recuperado de: www.superservicios.gov.co/sites/default/archivos/Publicaciones/Publicaciones/2018/Dic/2._disposicion_final_de_residuos_solidos_-_informe_2017.pdf
- Superintendencia de Servicios Públicos Domiciliarios, Superservicios; Departamento de Planeación Nacional, DNP, Gobierno de Colombia (2018). Informe Nacional De Aprovechamiento 2017. Consultado el 1 de diciembre de 2020. Recuperado de: www.superservicios.gov.co/sites/default/archivos/Publicaciones/Publicaciones/2018/Dic/3._informe_nacional_de_aprovechamiento_2017.pdf
- Superintendencia de Servicios Públicos Domiciliarios, Superservicios (2019a). Informe de Disposición Final de Residuos Sólidos – 2018. Consultado el 10 May 2020. Recuperado de: www.superservicios.gov.co/sites/default/archivos/Publicaciones/Publicaciones/2020/Ene/informe_nacional_disposicion_final_2019_1.pdf

Superintendencia de Servicios Públicos Domiciliarios, Superservicios (2019b). Informe Sectorial de la Actividad de Aprovechamiento 2018. Consultado el 25 de marzo de 2021. Recuperado de: www.superservicios.gov.co/sites/default/archivos/Publicaciones/Publicaciones/2020/Ene/informe_sectorial_aprovechamiento_2018.pdf

Tang, W.; Li, Y.; Yu, Y.; Wang, Z.; Xu, T.; Chen, J.; Lin, J. y Li, X. (2020). Development of models predicting biodegradation rate rating with multiple linear regression and support vector machine algorithms. *Chemosphere*, 253, 126666, doi: 10.1016/j.chemosphere.2020.126666

Tchobanoglous, G.; Theisen, H. y Vigil, S. (1994). *Gestión integral de residuos sólidos, Volumen I*, McGraw-Hill. ISBN84-481-1778-6

Torres, J. (2020), *Python Deep Learning, Introducción práctica con Keras y Tensorflow 2*. Marcombo, España, ISBN 978-84-267-2828-9.

Ubierno, A. (2015). *La gestión integral de residuos sólidos urbanos en la ciudad de Santa Fe*. Santa Fe, Argentina: Ediciones UNL. Consultado el 5 de diciembre de 2020. Recuperado de: elibro.net/es/ereader/usta/78504?page=82.

Unidad Administrativa Especial de Servicios Públicos, UAESP (s.f.). *Proyecto De Reciclaje y Aprovechamiento Sostenible -PRAS-* Consultado el 5 de diciembre de 2020. Recuperado de: www.uaesp.gov.co/sites/default/files/Documento%20Soporte%20PRAS%20Versio%CC%81n%20definitiva.pdf

Unidad Administrativa Especial de Servicios Públicos, UAESP y Universidad de los Andes (2005). “Estudio de Caracterización y Cuantificación de los Materiales Potencialmente Reciclables presentes en los Residuos Sólidos Municipales Generados en Bogotá, D.C”.

Unidad Administrativa Especial de Servicios Públicos, UAESP (2017). *Informe de disposición final de residuos sólidos urbanos. Área de disposición final*.

Unidad Administrativa Especial de Servicios Públicos, UAESP (2018). *Informe de Gestión 2018*. Bogotá D.C: Alcaldía de Bogotá. Consultado el 10 diciembre de 2020. Recuperado de: www.gobiernobogota.gov.co/transparencia/planeacion/planes/informe-gestion-2018

Unidad Administrativa Especial de Servicios Públicos, UAESP (2020a). *Datos Abiertos Bogotá. Subdirección Recolección Barrido Limpieza*. Consultado el 10 Mayo 2020. Recuperado de: datosabiertos.bogota.gov.co/dataset/data_set_subdireccion_recoleccion_barrido_limpieza

Unidad Administrativa Especial De Servicios Públicos, UAESP (2020b). *Servicio ordinario de aseo*. Consultado el 8 de noviembre de 2020. Recuperado de: <http://www.uaesp.gov.co/transparencia/informacion-interes/glosario/servicio-ordinario-aseo>.

- Unidad Administrativa Especial de Servicios Públicos, UAESP (2020c). Conoce los días y horarios de recolección de basuras. Consultado el 10 de mayo de 2020. Recuperado de: www.uaesp.gov.co/content/conoce-los-dias-y-horarios-recoleccion-basuras
- Veeduría Distrital (2018a). Diagnóstico Del Modelo De Aseo En Bogotá: El Nuevo PGIRS. Consultado el 12 mayo 2020. Recuperado de: [veeduriadistrital.gov.co/sites/default/files/files/Publicaciones%202018/Diagnostico%20del%20Modelo%20de%20Aseo%20en%20Bogota%20El%20nuevo%20PGIRS%20VF%20\(13%20feb%202018\)](http://veeduriadistrital.gov.co/sites/default/files/files/Publicaciones%202018/Diagnostico%20del%20Modelo%20de%20Aseo%20en%20Bogota%20El%20nuevo%20PGIRS%20VF%20(13%20feb%202018))
- Veeduría Distrital (2018b). Engativá: Ficha Local. Consultado el 12 mayo 2020. Recuperado de: www.veeduriadistrital.gov.co/sites/default/files/files/NotasLocales/Ficha%20Localidad%20Engativa.pdf
- Veeduría Distrital (2019). Suba: Ficha Local. Consultado el 12 mayo 2020. Recuperado de: www.veeduriadistrital.gov.co/sites/default/files/files/Ficha%20Local%20Suba.pdf
- Villada, F.; Muñoz, N. y García-Quintero, E. (2016). Redes Neuronales Artificiales aplicadas a la Predicción del Precio del Oro. *Información tecnológica*, 27(5), 143-150, doi: 10.4067/S0718-07642016000500016
- Wu, F.; Niu, D.; Dai, S. y Wu, B. (2020). New insights into regional differences of the predictions of municipal solid waste generation rates using artificial neural networks. *Waste Management*, 107, 182-190, doi: 10.1016/j.wasman.2020.04.015
- Yao, W.; Zhang, C.; Hao, H.; Wang, X. y Li, X. (2018). A support vector machine approach to estimate global solar radiation with the influence of fog and haze. *Renewable Energy*, 128, 155-162, doi: 10.1016/j.renene.2018.05.069
- Yadav, A.; Jha, C. K. y Sharan, A. (2020). Optimizing LSTM for time series prediction in Indian stock market. *Procedia Computer Science*, 167, 2091-2100, doi: 10.1016/j.procs.2020.03.257
- Yetilmezsoy, K.; Ozkaya, B. y Cakmakci, M. (2011). ARTIFICIAL intelligence-based prediction models for environmental engineering. *Neural Network World*, 21(3), 193-218, doi: 10.14311/mnw.2011.21.012.
- You, H.; Ma, Z.; Tang, Y.; Wang, Y.; Yan, J.; Ni, M.; Cen, K. y Huang, Q. (2017). Comparison of ANN (MLP), ANFIS, MSV, and RF models for the online classification of heating value of burning municipal solid waste in circulating fluidized bed incinerators. *Waste Management*, 68, 186-197, doi: 10.1016/j.wasman.2017.03.044
- Zhang, G.; Patuwo, B. E. y Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14:35-62
- Zhu, S.; Chen, H.; Wang, M.; Guo, X.; Lei, Y. y Jin, G. (2019). Plastic solid waste identification system based on near infrared spectroscopy in combination with support vector machine. *Advanced Industrial and Engineering Polymer Research*, 2(2), 77-81, doi: 10.1016/j.aiepr.2019.04.001

ANEXO 1

Relación de normativa colombiana vigente relacionada con la gestión de residuos sólidos

Disposición	Carácter	Descripción
Constitución Política de Colombia.1991	Nacional	<i>“Derechos fundamentales en Colombia”</i>
Decreto-Ley 2811 de 1974	Nacional	<i>“Código nacional de los recursos naturales renovables RNR y no renovables y de protección al medio ambiente”</i>
Ley 99 de 1993	Nacional	<i>“Por la cual se crea el Ministerio del Medio Ambiente, se reordena el Sector Público encargado de la gestión y conservación del medio ambiente y los recursos naturales renovables, se organiza el Sistema Nacional Ambiental, SINA, y se dictan otras disposiciones”</i>
Ley 1672 de 2013	Nacional	<i>“Por la cual se establecen los lineamientos para la adopción de una política pública de gestión integral de residuos de aparatos eléctricos y electrónicos (RAEE), y se dictan otras disposiciones”</i>
Ley 1252 de 2008	Nacional	<i>“Por la cual se dictan normas prohibitivas en materia ambiental, referentes a los residuos y desechos peligrosos y se dictan otras disposiciones”</i>
Ley 511 de 1999	Nacional	<i>“Por la cual se establece el Día Nacional del Reciclador y del Reciclaje”</i>
Ley 9 de 1979	Nacional	<i>“Medidas sanitarias sobre Residuos sólidos”</i>
Ley 142 de 1994	Nacional	<i>“Por la cual se establece el régimen de los servicios públicos domiciliarios y se dictan otras disposiciones”</i>

Disposición	Carácter	Descripción
Ley 769 de 2002	Nacional	<i>“Por la cual se expide el Código Nacional de Tránsito Terrestre y se dictan otras disposiciones”</i>
Decreto No. 1077 de 2015	Nacional	<i>“Por medio del cual se expide el Decreto Único Reglamentario del Sector Vivienda, Ciudad y Territorio”</i>
Decreto 1609 de 2002	Nacional	<i>“Manejo y transporte terrestre de mercancías peligrosas”</i>
Decreto 0351 de 2014	Nacional	<i>“Por el cual se reglamenta la gestión integral de los residuos generados en la atención en salud y otras actividades”</i>
Decreto 2981 de 2013	Nacional	<i>“Por el cual se reglamenta la prestación del servicio público de Aseo”</i>
Decreto 838 de 2005	Nacional	<i>“Por el cual se modifica el Decreto 1713 de 2002 sobre disposición final de residuos sólidos y se dictan otras disposiciones”</i>
Decreto 2041 de 2014	Nacional	<i>“Por el cual se reglamenta el Título VIII de la Ley 99 de 1993 sobre licencias ambientales”</i>
Decreto No. 596 de 2016	Nacional	<i>“Por el cual se modifica y adiciona el Decreto 1077 de 2015 en lo relativo con el esquema de la actividad de aprovechamiento del servicio público de aseo y el régimen transitorio para la formalización de los recicladores de oficio, y se dictan otras disposiciones”</i>
Decreto 1736 de 2015	Nacional	<i>“Modifica el artículo 2.3.2.3.2.2.5 del Decreto 1077 de 2015, Por medio del cual se expide el Decreto Único Reglamentario del Sector Vivienda, Ciudad y Territorio, referente a las prohibiciones y restricciones en la localización de áreas para disposición final de residuos sólidos”</i>

Disposición	Carácter	Descripción
Resolución CRA 351 de 2015	Nacional	<i>“Por la cual se establecen los regímenes de regulación tarifaria a los que deben someterse las personas prestadoras del servicio público de aseo y la metodología que deben utilizar para el cálculo de las tarifas del servicio de aseo de residuos ordinarios y se dictan otras disposiciones”</i>
Resolución CRA 352 de 2015	Nacional	<i>“Por la cual se definen los parámetros para la estimación del consumo en el marco de la prestación del servicio público domiciliario de aseo y se dictan otras disposiciones”</i>
Resolución CRA 720 de 2015	Nacional	<i>“Por la cual se establece el régimen de regulación tarifaria al que deben someterse las personas prestadoras del servicio público de aseo que atiendan en municipios de más de 5.000 suscriptores en áreas urbanas, la metodología a utilizar para el cálculo de tarifas del servicio público de aseo y se dictan otras disposiciones”</i>
Resolución 2184 de 2009	Nacional	<i>“Por el cual se modifica la resolución 668 de 2016 sobre el uso racional de bolsas plásticas y se adoptan otras disposiciones”</i>
Resolución 754 de 2014	Nacional	<i>“Por la cual se adopta la metodología para la formulación, implementación, evaluación, seguimiento, control y actualización de los Planes de Gestión Integral de Residuos Sólidos”</i>
Resolución 276 de 2016 del Ministerio de Vivienda, Ciudad y Territorio	Nacional	<i>“Por la cual se reglamentan los lineamientos del esquema operativo de la actividad de aprovechamiento del servicio público de aseo y del régimen transitorio para la formalización de los recicladores de oficio acorde con lo establecido en el Capítulo 5 el Título 2 de la parte 3 del Decreto 1077 de 2015 adicionado por el Decreto 596 del 11 de abril de 2016”</i>

Disposición	Carácter	Descripción
Resolución 330 del 8 de junio de 2017, expedida por el Ministerio de Vivienda, Ciudad y Territorio	Nacional	<i>“Por la cual se adopta el “Reglamento Técnico para el sector de Agua Potable y Saneamiento Básico (RAS) y se derogan las Resoluciones números 1096 de 2000, 0424 de 2001, 0668 de 2003, 1459 de 2005, 1447 de 2005 y 2320 de 2009”</i>
Resolución 1045 de 2003	Nacional	<i>“Metodología para la elaboración de los PGIRS y otras disposiciones”</i>
Resolución 541 de 1994	Nacional	<i>“Cargue, descargue, transporte, almacenamiento y disposición final de escombros y materiales de construcción”</i>
Resolución 1362 de 2007	Nacional	<i>“Por la cual se establecen los requisitos y el procedimiento para el Registro de Generadores de Residuos Peligrosos, a que hacen referencia los artículos 27 y 28 del Decreto 4741 del 30 de diciembre de 2005”</i>
Resolución 2309 de 1986	Nacional	<i>“Por la cual se dictan normas para el cumplimiento en cuanto a Residuos Especiales”</i>
Resolución 1511 de 2010	Nacional	<i>“Por la cual se establecen los Sistemas de Recolección Selectiva y Gestión Ambiental de Residuos de Bombillas y se adoptan otras disposiciones”</i>
Resolución 1512 de 2010	Nacional	<i>“Por la cual se establecen los Sistemas de Recolección Selectiva y Gestión Ambiental de Residuos de Computadores y/o Periféricos y se adoptan otras disposiciones”</i>
Resolución 0222 de 2011	Nacional	<i>“Por la cual se establecen requisitos para la gestión ambiental integral de equipos y desechos que consisten, contienen o están contaminados con Bifenilos Policlorados (PCB)”</i>
Resolución 415 de 1998	Nacional	<i>“Por la cual se establecen los casos en los cuales se permite la combustión de los aceites de desecho y las condiciones técnicas para realizar la misma”</i>

Disposición	Carácter	Descripción
Resolución 371 de 2009	Nacional	<i>“Por la cual se establecen los elementos que deben ser considerados en los planes de gestión de devolución de productos posconsumo de fármacos o medicamentos vencidos”</i>
Resolución 1297 de 2010	Nacional	<i>“Sistema de recolección selectiva y Gestión ambiental de residuos de pilas y/o acumuladores”</i>
Resolución 1675 de 2013	Nacional	<i>“Por la cual se establecen los elementos que deben contener los planes de gestión de devolución de productos posconsumo de plaguicidas”</i>
Resolución 372 de 2009	Nacional	<i>“Por la cual se establecen los elementos que deben contener los Planes de Gestión de Devolución de Productos Posconsumo de Baterías Usadas Plomo Acido, y se adoptan otras disposiciones”</i>
Resolución 693 de 2007	Nacional	<i>“Por la cual se establecen criterios y requisitos que deben ser considerados para los Planes de Gestión de Devolución de Productos Posconsumo de Plaguicidas”</i>
Resolución 1326 de 2007	Nacional	<i>“Por la cual se establecen los Sistemas de Recolección Selectiva y Gestión Ambiental de Llantas Usadas y se dictan otras disposiciones”</i>
Acuerdo 565 de 2014	Concejo de Bogotá D.C.	<i>“Promueve la instalación de puntos de entrega y recolección de residuos o desechos peligrosos provenientes del consumo de productos o sustancias peligrosas en Bogotá, D.C. La Secretaría Distrital de Ambiente ejercerá la coordinación del cumplimiento del presente Acuerdo”</i>

Disposición	Carácter	Descripción
Resolución 940 de 1997	Alcaldía Mayor de Bogotá, D.C.	<i>“Ordena a los directores del Instituto Distrital de Cultura y Turismo, de la Unidad Ejecutiva de Servicios Públicos, del Departamento Técnico Administrativo del Medio Ambiente y del Departamento Técnico Administrativo de Acción Comunal, iniciar acciones tendientes a definir una estrategia, con legitimidad social, para la organización de un sistema de manejo de residuos sólidos de origen doméstico que incentive su separación y clasificación en la fuente y su reciclaje o reutilización”</i>
Resolución 701 de 2013 Unidad Administrativa Especial de Servicios Públicos - UAESP	Distrital	<i>“Todo usuario y/o generador de residuos sólidos en el territorio del Distrito Capital, está obligado a presentar, en espacio público, para la recolección y transporte por parte de la población recicladora de oficio, los residuos sólidos que correspondan a materiales potencialmente reciclables y aprovechables en una bolsa blanca, con el contenido previsto en el artículo primero (1°) de la Resolución UAESP No. 799 de 2012, o la que modifique o sustituya, con una antelación no mayor a tres (3) horas ni inferior a una (1) hora, respecto del rango de horario y frecuencia establecida por el operador y/o prestador del servicio público de aseo en su componente de recolección de residuos sólidos ordinarios. La población recicladora de oficio será la responsable de la recolección y transporte de los residuos conservando en todo momento el área limpia, evitando la rotura de bolsas y la dispersión de residuos sólidos; y, en general, absteniéndose de incurrir en cualquiera de las conductas establecidas en el numeral 6° del artículo 4° del Acuerdo Distrital 417 de 2009”</i>

Disposición	Carácter	Descripción
Concepto 2010 de 2014 Unidad Administrativa Especial de Servicios Públicos - UAESP	Distrital	<i>“Responde a la solicitud de información del marco normativo vigente para el aprovechamiento de residuos sólidos, en este sentido presenta el panorama de normas del nivel nacional y distrital que regulan la materia”</i>
Decreto 495 de 2016 Alcaldía Mayor de Bogotá, D.C.	Distrital	<i>“Adopta el Plan de Gestión Integral de Residuos Sólidos - PGIRS - del Distrito Capital como el instrumento de planeación distrital contenido de los objetivos, metas, programas, proyectos, actividades y recursos para la gestión de los residuos sólidos, basado en la política de gestión integral de los mismos. La coordinación general del PGIRS está a cargo de la UAESP”</i>
Decreto 859 de 1998 Alcaldía Mayor de Bogotá, D.C.	Distrital	<i>“Por el cual se expiden normas para la adopción de un tratamiento de lixiviados en el relleno sanitario doña Juana”</i>

ANEXO 2

Distribución de hogares por estrato socioeconómico por localidad

Localidad	Número de hogares	Estrato						
		0 (%)	1 (%)	2 (%)	3 (%)	4 (%)	5 (%)	6 (%)
Antonio Nariño	27.774	1,79	0,00	4,49	93,72	0,00	0,00	0,00
Barrios Unidos	57.196	0,16	0,00	0,00	54,60	41,89	3,35	0,00
Bosa	133.097	4,51	4,83	87,18	3,48	0,00	0,00	0,00
Chapinero	55.919	0,21	3,38	9,41	6,30	33,18	10,45	37,07
Ciudad Bolívar	152.266	1,21	60,02	34,56	4,22	0,00	0,00	0,00
Engativá	232.205	1,04	0,74	23,58	70,63	4,00	0,00	0,00
Fontibón	116.233	1,94	0,00	18,76	44,66	33,75	0,88	0,00
Kennedy	269.028	0,75	0,58	49,37	46,80	2,50	0,00	0,00
La Candelaria	7.857	0,71	0,45	53,30	45,54	0,00	0,00	0,00
Los Mártires	27.497	0,18	0,00	8,79	83,29	0,00	0,00	0,00
Puente Aranda	70.682	1,05	0,00	0,32	98,62	0,00	0,00	0,00
Rafael Uribe	104.433	1,12	8,53	47,72	42,63	0,00	0,00	0,00
San Cristóbal	112.721	0,39	7,74	77,40	14,47	0,00	0,00	0,01
Santa Fe	36.163	1,51	7,49	55,47	25,13	9,39	0,49	0,51
Suba	288.568	1,61	0,21	30,56	33,59	18,78	13,71	1,54
Sumapaz	1.743	0,00	54,91	28,06	9,70	3,61	1,61	2,12
Teusaquillo	57.972	0,16	0,00	0,00	14,12	80,71	5,02	0,00
Tunjuelito	49.168	0,49	0,00	56,48	43,04	0,00	0,00	0,00
Usaquén	162.641	0,94	4,36	6,22	26,16	30,47	13,72	18,14
Usme	99.114	2,20	47,10	50,69	0,01	0,00	0,00	0,00

DANE-SDP (SPD, 2011)

ANEXO 3

Datos económicos. Costes de tratamiento, ingresos por venta de recursos valorizados por tratamiento e ingresos por tarifa del Servicio Público de Aseo según tratamiento

Fuente: Banco Interamericano de Desarrollo, BID (2016). Estudio de técnicas alternativas de tratamiento, disposición final y/o aprovechamiento de residuos sólidos – propuesta de ajuste decreto 838 de 2005 (compilado en el decreto 1077 de 2015), Departamento de Planeación Nacional.

Costo Medio por Tipo de Tratamiento (\$/t), en Pesos Colombianos

Tratamiento	Costo Medio (\$/t)		
Tratamiento Térmico con Generación de Energía			
<i>Tamaño (t/mes)</i>	38.933	9.125	4.000
Incineración	254.300	343.900	445.400
Gasificación	268.800	364.900	472.900
Tratamiento Mecánico Biológico			
<i>Tamaño (t/mes)</i>	38.933	9.125	2.000
Mecánico + Digestión Anaerobia con generación de energía	100.900	143.400	223.400
<i>Tamaño (t/mes)</i>	38.933	9.125	304
Mecánico + Compostaje al Aire Libre	55.800	82.200	149.100
Mecánico + Compostaje Cerrado (en contenedores)	75.700	102.100	280.500
Tratamiento Biológico			
<i>Tamaño (t/mes)</i>	3.898	2.000	304
Compostaje de residuos separados en la fuente (v.gr. corte de césped)	35.400	43.500	78.300
Extracción y Aprovechamiento de Biogás en Relleno Sanitario			
<i>Tamaño (t/mes)</i>	22.204	9.125	304
Captura y Quema	7.800	16.900	395.900
Captura y Generación de Energía	16.800	25.900	No evaluado
Captura y Venta directa de Gas	8.900	15.700	No evaluado

(BID,2016)

Ingresos por Venta de Recursos Valorizados por Tratamiento (\$/t), en Pesos Colombianos

Tratamiento	Ingreso Venta Recursos Valorizados (\$/t)		
Tratamiento Térmico con Generación de Energía			
<i>Tamaño (t/mes)</i>	38.933	9.125	4.000
Incineración	92,400	82,800	75,900
Gasificación	82,800	73,100	70,300
Tratamiento Mecánico Biológico			
<i>Tamaño (t/mes)</i>	38.933	9.125	2.000
Mecánico + Digestión Anaerobia con generación de energía	25,700	25,700	25,700
<i>Tamaño (t/mes)</i>	38.933	9.125	304
Mecánico + Compostaje al Aire Libre	5,000	5,000	5,000
Mecánico + Compostaje Cerrado (en contenedores)	5,000	5,000	5,000
Tratamiento Biológico			
<i>Tamaño (t/mes)</i>	3.898	2.000	304
Compostaje de residuos separados en la fuente (v.gr. corte de césped)	90.000	90.000	90.000
Extracción y Aprovechamiento de Biogás en Relleno Sanitario			
<i>Tamaño (t/mes)</i>	22.204	9.125	304
Captura y Quema	400	400	400
Captura y Generación de Energía	9,900	9,900	No Evaluado
Captura y Venta directa de Gas	4,700	4,700	No Evaluado

(BID,2016)

Ingresos por Tarifa del Servicio Público de Aseos según tratamiento (\$/t), en Pesos Colombianos

Tratamiento	Ingreso Tarifa (\$/t)		
Tratamiento Térmico con Generación de Energía			
<i>Tamaño (t/mes)</i>	38.933	9.125	4.000
Incineración	40,700	95,800	150,900
Gasificación	40,700	95,800	150,900
Tratamiento Mecánico Biológico			
<i>Tamaño (t/mes)</i>	38.933	9.125	2.000
Mecánico + Digestión Anaerobia con generación de energía	33,100	63,400	150,900
<i>Tamaño (t/mes)</i>	38.933	9.125	304
Mecánico + Compostaje al Aire Libre	30,000	50,200	150,900
Mecánico + Compostaje Cerrado (en contenedores)	33,100	63,400	150,900
Tratamiento Biológico			
<i>Tamaño (t/mes)</i>	3.898	2.000	304
Compostaje de residuos separados en la fuente (v.gr. corte de césped)	26,700	31,100	71,800
Extracción y Aprovechamiento de Biogás en Relleno Sanitario			
<i>Tamaño (t/mes)</i>	22.204	9.125	304
Captura y Quema	0	0	0
Captura y Generación de Energía	0	0	No Evaluado
Captura y Venta directa de Gas	0	0	No Evaluado

(BID,2016)

Propuesta metodológica basada en RNA para la determinación de la gestión óptima de RSU

Recursos Valorizados por cada técnica, en Pesos Colombianos

Técnica	Recurso Valorizado	Valor Unitario	Unidad	Tamaño 1	Tamaño 2	Tamaño 3
Incineración	Energía (generación)*	\$138.086/MWh	MWh/t	0,56	0,49	0,44
	Reciclables (Ferrosos y No Ferrosos)**	\$450.000/t	t/t	0,02	0,02	0,02
Gasificación	Energía (generación)*	\$138.086,5/MWh	MWh/t	0,49	0,42	0,40
	Reciclables (Ferrosos y no Ferrosos)**	\$450.000/t	t/t	0,02	0,02	0,02
Tratamiento Mecánico	Vidrio**	\$65.753/t	t/t	0,02	0,02	0,02
	RDF (Combustible derivado de residuos)****	\$4,3/MBTU	MBTU/t	2.338,52	2.338,52	2.338,52
	Metales**	\$450.000/t	t/t	0,01	0,01	0,01
Digestión Anaerobia con generación de energía	Energía*	\$138.086/MWh	MWh/t	0,15	0,15	0,15
Compostaje al Aire Libre	Compost Enmienda Orgánica	-	t/t	-	-	-
Compostaje Cerrado	Compost	-	t/t	-	-	-
Compostaje de corte de césped	Compost Enmienda Orgánica*****	\$150.000/t	t/t	0,60	0,60	0,60
Captura y generación de Energía	Energía*	\$138.086/MWh	MWh/t	0,07	0,07	
	Certificados de emisión reducida CER***	\$1.345/tCO ₂ eq	t CO ₂ eq/t	0,29	0,29	
Captura y venta directa de Gas	Gas****	\$8,6/MBTU	MBTU/t	498,90	498,90	
	Certificados de reducción de emisiones***	\$1.345/MBTU	t CO ₂ eq/t	0,29	0,29	

Fuente: (BID,2016)

* Acolgen (septiembre, 2015)

** Información secundaria y entrevistas realizadas a rutas de recicladores en varias ciudades del país (Asociación en Participación MAG Consultoria de año 2014)

*** Entrevista a operador de instalación para el tratamiento de biogás (cifra aproximada a partir del precio en Euro y tasa de cambio vigente a septiembre, 2015)

**** www.gasyenergia.com (septiembre, 2015)

***** Entrevista a operador de instalación para el procesamiento de compost (2015), (BID,2016).

ANEXO 4

Relación de publicaciones científicas desarrolladas en el marco de la tesis doctoral

Artículos publicados en revistas indexadas:

Solano-Meza, J. K.; Orjuela-Yepes, D.; Rodrigo-Ilarri, J. y Cassiraga, E. (2019). Predictive analysis of urban waste generation for the city of Bogotá, Colombia, through the implementation of decision trees-based machine learning, support vector machines and artificial neural networks. *Heliyon*, 5; doi: 10.1016/j.heliyon.2019.e02810

Solano-Meza, J. K.; Rodrigo-Ilarri, J.; Romero-Hernández, C. P. y Rodrigo-Clavero, M. E. (2020). Analytical Methodology for the Identification of Critical Zones on the Generation of Solid Waste in Large Urban Areas. *International Journal of Environmental Research and Public Health*, 17, 1196; doi: 10.3390/ijerph17041196

Contribuciones en congresos internacionales

Solano, J. K.; Orjuela-Yepes, D. y Rodrigo-Ilarri, J. (2020). Methodological analysis for decision-making regarding solid waste management in megacities. EGU2020.10745. EGU 2020 General Assembly, Viena. doi: 10.5194/egusphere-egu2020-10745

Solano-Meza, J. K., Orjuela-Yepes, D.; Rodrigo-Clavero, M. E. y Rodrigo-Ilarri, J. (2019). Comparative analysis on the application of artificial intelligence techniques to forecast solid waste generation in the city of Bogotá. EGU 2019-3167 EGU 2019 General Assembly, Viena. doi: 10.13140/RG.2.2.17538.94405

Solano-Meza, J. K.; Orjuela-Yepes, D.; Rodrigo-Clavero, M.E. y Rodrigo-Ilarri, J. (2018). Determination of the solid urban waste generation in megacities using artificial neural networks. EGU2018-5585 EGU 2018 General Assembly, Viena. doi: 10.13140/RG.2.2.24682.82888

Solano, J. K.; Romero C.P. y Rodrigo-Ilarri, J. (2017). Application of geographic information systems to the analysis of the solid waste production on the city of Bogotá. EGU 2017 General Assembly, Viena. doi: 10.13140/RG.2.2.12743.29602