



CENTRO DE INVESTIGACIONES BIOLÓGICAS
DEL NOROESTE, S.C.

Programa de Estudios de Posgrado

MODELO DEL EFECTO DE LA RELACIÓN C/N DE LOS
RESIDUOS ORGÁNICOS URBANOS EN LA CALIDAD DE LA
COMPOSTA.

T E S I S

Que para obtener el grado de

Doctora en Ciencias

Uso, Manejo y Preservación de los Recursos Naturales
(Orientación en Agricultura Sustentable)

P r e s e n t a

Andrea Margarita de Anda Trasviña

La Paz, Baja California Sur, junio de 2024.

ACTA DE LIBERACIÓN DE TESIS

En la Ciudad de La Paz, B. C. S., siendo las 14:00 horas del día 12 del mes de junio del 2024, se procedió por los abajo firmantes, miembros de la Comisión Revisora de Tesis avalada por la Dirección de Estudios de Posgrado y Formación de Recursos Humanos del Centro de Investigaciones Biológicas del Noroeste, S. C., a liberar la Tesis de Grado titulada:

"Modelo del Efecto de la Relación Carbono/Nitrógeno de los Residuos Orgánicos Urbanos en la Calidad de la Composta"

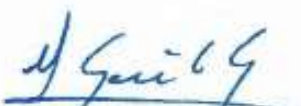
Presentada por el alumno:

Andrea Margarita de Anda Trasviña

Aspirante al Grado de DOCTOR EN CIENCIAS EN EL USO, MANEJO Y PRESERVACIÓN DE LOS RECURSOS NATURALES CON ORIENTACIÓN EN Agricultura Sustentable

Después de intercambiar opiniones los miembros de la Comisión manifestaron su **APROBACIÓN DE LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

LA COMISIÓN REVISORA



Dra. Alejandra Nieto Garibay
Co-Director



Dr. Joaquín Gutiérrez Jagüey
Co-Director



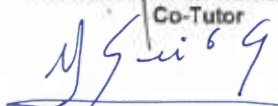
Dr. Enrique Troyo Diéguez
Co-Tutor



Dr. José Luis García Hernández
Co-Tutor



Dr. Fernando Daniel Von Borstel Luna
Co-Tutor



Dra. Alejandra Nieto Garibay,
Directora de Estudios de Posgrado y
Formación de Recursos Humanos



La Paz, Baja California Sur, a 12 de junio de 2024.

Los miembros del comité de tesis del (la) estudiante Andrea Margarita de Anda Traviña del Programa de Doctorado en ciencias en el Uso, Manejo y Preservación de los Recursos Naturales (DCUMPRN), revisamos el contenido de la tesis y otorgamos el Vo.Bo. dado que la tesis no representa un plagio de otro documento como lo muestra el reporte de similitud realizado:

- Herramienta antiplagio:
iThenticate
- Filtros utilizados:
Excluir bibliografía y citas
- Porcentajes de similitud:
15% (Se muestra captura de pantalla)

Modelo del Efecto de la Relación C/N de los Residuos
Orgánicos Urbanos en la Calidad de la Composta

INFORME DE ORIGINALIDAD

15%

Índice de Similitud

FUENTES PERMANENTES

1	hdl.handle.net	461 palabras — 2%
2	www.inifap.gob.mx	122 palabras — < 1%
3	repositorio.lamolina.edu.pe	116 palabras — < 1%
4	github.com	99 palabras — < 1%
5	tesis.ipn.mx	96 palabras — < 1%
6	www.coursehero.com	94 palabras — < 1%
7	academica-e.unavarra.es	93 palabras — < 1%
8	www.compostandociencia.com	91 palabras — < 1%
9	repositorioinstitucional.uson.mx	66 palabras — < 1%

Firmas del Comité

Dra. Alejandra Nieto Caribay

Dr. Joaquín Gutiérrez Jagüey

Dr. Enrique Troyo Diéguez

Dr. Fernando Daniel Von Borstel Luna

Dr. José Luis García Hernández

Conformación de Comités

Comité Tutorial

Dra. Alejandra Nieto Garibay
Centro de Investigaciones Biológicas del Noroeste, S.C.
Co-Directora de Tesis

Dr. Joaquín Gutiérrez Jagüey
Centro de Investigaciones Biológicas del Noroeste, S.C.
Co-Director de Tesis

Dr. Enrique Troyo Diéguez
Centro de Investigaciones Biológicas del Noroeste, S.C.
Co-Tutor de Tesis

Dr. Fernando Daniel Von Borstel Luna
Centro de Investigaciones Biológicas del Noroeste, S.C.
Co-Tutor de Tesis

Dr. José Luis García Hernández
Universidad Juárez del Estado de Durango
Co-Tutor de Tesis

Comité Revisor de Tesis

Dra. Alejandra Nieto Garibay
Dr. Joaquín Gutiérrez Jagüey
Dr. Enrique Troyo Diéguez
Dr. Fernando Daniel Von Borstel Luna
Dr. José Luis García Hernández

Jurado de Examen

Dra. Alejandra Nieto Garibay
Dr. Joaquín Gutiérrez Jagüey
Dr. Enrique Troyo Diéguez
Dr. Fernando Daniel Von Borstel Luna
Dr. José Luis García Hernández

Suplentes

Dr. Juan Francisco Villa Medina
Dr. Eduardo Romero Vivas


Resumen

Aproximadamente el 50% de los residuos sólidos urbanos que se generan en las ciudades son orgánicos (ROU) se componen principalmente de restos de alimentos y de jardinería. Estos residuos terminan en los basureros urbanos, generando impactos en el medio ambiente y en la salud de la población. El proceso de compostaje ofrece una alternativa para la disposición final de los ROU transformándolos en un producto útil llamado composta, un valioso fertilizante orgánico que beneficia el suelo y las plantas. El desarrollo de modelos del proceso de compostaje aún está limitado por la heterogeneidad de los materiales y en particular por la diversidad de los ROU. En este contexto, el objetivo del presente trabajo de investigación fue desarrollar un modelo del proceso de compostaje llamado CompostQNet basado en redes neuronales artificiales (RNA) para estimar la relación C/N de composta terminada teniendo como entrada del proceso de compostaje las características cuantitativas y cualitativas de los ROU. Se creó un conjunto de imágenes de ROU a los que se les asocio sus características cuantitativas (peso, relación C/N) y cualitativas (color y etapa de descomposición). Para clasificar los ROU se propusieron tres etapas de descomposición (inicial, media y avanzada), encontrándose diferencias estadísticas entre las etapas de descomposición para la mayoría de los ROU en el contenido de C, N, P y K. También se desarrolló un clasificador, basado en una RNA convolucional, llamado ROUNet, el cual identifica ROU en una imagen e indica a qué clase pertenece dicho residuo y cuál es su etapa de descomposición. La clasificación permite estimar el peso y la relación C/N de dicho ROU. También se realizó la medición de la evolución de las temperaturas del proceso de compostaje lo que permitió desarrollar un segundo modelo basado en lógica difusa llamado CompostTraker, el cual genera mensajes escritos para indicar el estatus de la composta durante el proceso de compostaje. Los modelos desarrollados en este trabajo son herramientas prácticas y adecuadas que simplifican el manejo del compostaje doméstico brindando información clave que permite la toma de decisiones para garantizar una composta de calidad. Los resultados alcanzados en esta investigación pueden ayudar a diseñar una gestión adecuada de los ROU para su reciclaje y uso de nutrientes como alternativa a los fertilizantes químicos.

Palabras claves: Residuos orgánicos urbanos, relación C/N, redes neuronales artificiales.

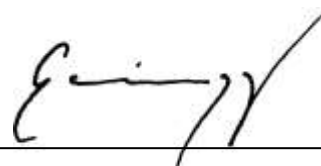
ORCID: <https://orcid.org/0000-0002-3563-3698>

Vo. Bo.



Dra. Alejandra Nieto Garibay

Co-Directora de tesis



Dr. Joaquín Gutiérrez Jagüey

Co-Director de tesis

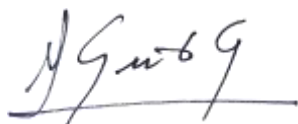
Summary

Approximately 50 % of solid waste generated in cities is organic, mainly food and garden waste. This urban organic waste (UOW) often ends up in landfills, adversely affecting the environment and public health. Composting offers an alternative disposal method, transforming UOW into compost, a valuable organic fertilizer that benefits soil and plants. However, developing composting process models is challenging due to UOW heterogeneity. In this context, this research developed a model named CompostQNet, based on artificial neural networks (ANN), to estimate the carbon-nitrogen (C/N) ratio in finished compost using quantitative and qualitative characteristics of UOW. A dataset of UOW images was created, each associated with quantitative (weight, C/N ratio) and qualitative (color and decomposition state) attributes. UOW was classified into three decomposition stages— initial, middle, and advanced—with significant statistical differences in C, N, P, and K content across stages. Additionally, a convolutional ANN classifier called ROUNet was developed to identify UOW in images, classify the residue, and determine its decomposition stage, thereby estimating the weight and C/N ratio of UOW. The temperature evolution during composting was also monitored, leading to the development of a fuzzy logic-based model called CompostTracker, which provides text status updates throughout the composting process. These models are practical tools for managing home composting, offering essential information for decision-making to ensure high-quality compost. The findings of this research contribute to effective UOW management, promoting recycling and nutrient utilization as an alternative to chemical fertilizers.

Keywords: Urban organic waste, C/N ratio, artificial neural networks.

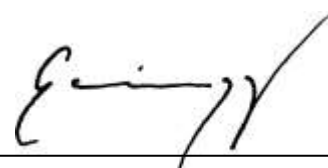
ORCID: <https://orcid.org/0000-0002-3563-3698>

Vo. Bo.



Dra. Alejandra Nieto Garibay

Co-Directora de tesis



Dr. Joaquín Gutiérrez Jagüey

Co-Director de tesis

Dedicatoria

A mis hijos Rubén, Mariana y Gabriel.

Agradecimientos

Quiero agradecer a todas las personas que participaron de diferentes formas en este trabajo de investigación y que contribuyeron a su terminación.

A mi familia por su comprensión, apoyo y amor brindados, en especial a mi esposo Rubén, por ser mi compañero en esta aventura y por motivarme a continuar superándome pese al cambio que esto significó en nuestra dinámica familiar.

A mis Co-directores, Dra. Alejandra Nieto Garibay y Dr. Joaquín Gutiérrez Jaguey por su dirección, apoyo y confianza durante todo este proyecto de investigación. A mi comité tutorial, Dr. Enrique Troyo Diéguez, Dr. Fernando Daniel Von Borstel Luna y Dr. José Luis García Hernández por su apoyo, orientación y participación en este trabajo.

Al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCyT) por la beca otorgada con número 781533. Al Centro de Investigaciones Biológicas de Noroeste, S.C. (CIBNOR) por brindar los medios para realizar el doctorado en esta institución y al proyecto de Residuos Orgánicos del COSCYT: Manejo de Residuos Orgánicos en Escuelas través del Compostaje.

Al personal de la Dirección de Estudios de Posgrado y Formación de Recursos Humanos, Mtra. Osvelia Ibarra Morales, Tania Verónica Núñez Valdez, Lic. Raquel Emilia Herrera Vega y Horacio Sandoval Gómez por su profesionalismo, paciencia y por las orientaciones brindadas en todo momento. A la Lic. Ana María Talamantes Cota, por las revisiones hechas a este documento. Mi admiración y respeto para todos ellos.

Al personal de los diferentes Laboratorios y otras áreas del CIBNOR por sus valiosas aportaciones en cada una de sus áreas: Laboratorio de Edafología, M.C. Manuel Salvador Trasviña Castro y I.B.Q. Myriam Lizzeth Hernández de Haro; Laboratorio de Espectrofotometría de Absorción Atómica, I.B.Q. F. Griselda Peña Armenta y Q.B. Emerson Carlo Zuñiga Mayoral; Laboratorio de Análisis Químico Proximal, I.B.Q. María Dolores Rondero Astorga y PGeol. Sindi Areli Juan Antúnez; Laboratorio de Fisiotécnica Vegetal, Dra. María del Carmen Mercado Guido y Lic. Magdalena López

García; Laboratorio de Diagnostico Microbiológico, Dra. Norma Angélica Ochoa Álvarez y Lic. José Manuel Melero Astorga; Laboratorio de Bioquímica Fisiológica, M. en C. Roberto Hernández Herrera; Campo Agrícola, Téc. Pedro Luna García, Ing. Saúl Edel Briseño Ruiz, Téc. José Raymundo Ceseña Núñez y Téc. Adrián Jordan Castro; Taller de Maquinado, Jorge Cobos Anaya; Grupo de Ingeniería, Dr. Juan Francisco Villa Medina. Gracias a todos por compartir sus conocimientos, por su paciencia, disposición y amabilidad en todo momento.

A mis compañeras y compañeros del doctorado que fueron un gran soporte emocional y que hicieron más agradable todo este proceso.

A pesar de la contingencia que a todos nos afectó de una u otra manera, se concluye este proyecto con el apoyo de todos ¡Muchas gracias!

Contenido

Resumen	i
Summary	ii
Dedicatoria	iii
Agradecimientos	iv
Contenido	vi
Lista de figuras	ix
Lista de tablas	xi
Abreviaturas	xii
1. INTRODUCCIÓN	1
2. ANTECEDENTES	4
2.1 Residuos orgánicos urbanos (ROU)	4
2.2 Proceso de compostaje	4
2.2.1 Parámetros del proceso de compostaje	5
2.2.1.1 Temperatura.....	6
2.2.1.2 Humedad.....	6
2.2.1.3 Aireación	7
2.2.1.4 pH	7
2.2.1.5 Tamaño de partícula	8
2.2.1.6 Relación C/N.....	8
2.2.2 Calidad de la composta	9
2.3 Modelos del proceso compostaje	10
2.4 Redes neuronales artificiales	11
2.4.1 Redes neuronales convolucionales (CNN)	14
2.4.2 Arquitectura de una CNN	16
2.5 Modelos de lógica difusa.....	18
3. JUSTIFICACIÓN	19
4. HIPÓTESIS	20
5. OBJETIVOS	21
5.1 Objetivo general	21
5.2 Objetivos particulares	21
6. MATERIAL Y MÉTODOS	22
6.1 Determinación de índices cualitativos y cuantitativos de ROU	23
6.1.1 Creación de la BD de índices de ROU.....	23
6.1.1.1 Selección y recolección de ROU	24
6.1.1.2 Determinación de color y estado de descomposición	24
6.1.1.3 Captura de imágenes y determinación del peso de ROU	25
6.1.1.4 Determinación de la relación C/N en ROU.....	25
6.1.2 Desarrollo de clasificador automático de ROU	29
6.1.2.1 Clasificación y detección de ROU	29
6.1.2.2 Estimación del peso de ROU	31
6.1.2.3 Determinación de la relación C/N de ROU.....	31
6.2 Generación del modelo del proceso de compostaje.	32
6.2.1 Sitio experimental	32
6.2.2 Materiales del experimento.....	32

6.2.3 Toma de video de ROU.....	33
6.2.4 Diseño experimental	34
6.2.5 Análisis de calidad de las compostas	35
6.2.5.1 Análisis de madurez prueba Solvita®	35
6.2.5.2 Análisis edafológicos	37
6.2.5.3 Análisis químico proximal	38
6.2.5.4 Metales pesados y micronutrientes.....	38
6.2.5.5 Análisis microbiológicos	39
6.2.5.6 Análisis de fitotoxicidad	40
6.2.6 Análisis estadístico	40
6.2.7 Modelo del proceso de compostaje.....	41
6.2.7.1 Modelo de la temperatura del proceso de compostaje	41
6.2.7.2 Modelo del proceso de compostaje.....	42
7. RESULTADOS	44
7.1 Creación de la BD de índices de ROU	44
7.1.1 Selección y recolección de ROU	44
7.1.2 Determinación de color y estado de descomposición de los ROU	44
7.1.3 Captura de imágenes y determinación del peso de ROU	46
7.1.4 Determinación de la relación C/N en ROU	48
7.2 Desarrollo del clasificador automático de ROU	54
7.2.1 Clasificación y detección de ROU	54
7.2.1.1 Preprocesamiento de imágenes.....	54
7.2.1.2 Entrenamiento de las CNN	54
7.2.1.3 Prueba de las CNN.....	54
7.2.1.4 Preprocesamiento de imágenes para los modelos CNN YOLO	58
7.2.1.5 Entrenamiento y prueba de las CNN YOLO	58
7.2.2 Estimación del peso de ROU	61
7.3 Generación de datos para el modelo a través del experimento de compostaje.....	62
7.3.1 Prueba Solvita®	62
7.3.2 Análisis de laboratorio de la calidad de la composta.....	63
7.3.2.1 Materia orgánica (MO), pH y conductividad eléctrica (CE).....	63
7.3.2.2 Carbono, Nitrógeno y relación C/N.....	64
7.3.2.3 Metales y micronutrientes	65
7.3.2.4 Diagnóstico microbiológico	65
7.3.2.5 Fitotoxicidad.....	66
7.3.3 Resumen de resultados.....	66
7.3.4 Evolución de la temperatura durante el proceso de compostaje	67
7.4 Modelo del proceso de compostaje.....	68
7.4.1 Modelo del proceso de compostaje basado en RNA.....	68
7.4.2 Modelo difuso del proceso de compostaje.....	70
8. DISCUSIÓN	73
8.1 Creación de la BD de índices de ROU	73
8.1.1 Selección y recolección de ROU	73
8.1.2 Determinación de la relación C/N en ROU.....	73
8.1.2.1 Revisión sistemática	73

8.1.2.2 Análisis de laboratorio	73
8.2 Desarrollo de clasificador automático de ROU	76
8.2.1 Clasificación y detección de ROU	76
8.2.2 Estimación del peso de ROU	78
8.3 Datos de la calidad de la composta.....	78
8.3.1 Temperatura.....	78
8.3.2 pH y Conductividad Eléctrica (CE)	79
8.3.3 Fototoxicidad.....	80
8.3.4 Relación C/N.....	81
8.4 Modelo del proceso de compostaje.....	82
8.4.1 Modelo del proceso de compostaje basado en RNA.....	82
8.4.2 Modelo difuso del proceso de compostaje.....	82
9. CONCLUSIONES	84
10. LITERATURA CITADA.....	86
11. ANEXOS	96
Anexo A.-Artículo publicado.-Carbon/nitrogen ratio estimation for urban organic waste using convolucional neural networks.	96
Anexo B.-Artículo sometido.-Macronutrient content in decomposition stages of urban organic waste.	111

Lista de figuras

Figura 1. Evolución de temperatura, pH, relación C/N y aspecto de los ROU durante las etapas del proceso de compostaje (adaptado de Bueno et al., 2008; Nieto-Garibay et al., 2021; Román et al., 2015).....	5
Figura 2. Estructura típica de una RNA compuesta por capas de neuronas representadas por círculos (elaboración propia).....	13
Figura 3. Red neuronal convolucional (CNN) con los bloques típicos de convolución y capas completamente conectadas (modificado de Lecun <i>et al.</i> , 1998).	16
Figura 4. La convolución aplica una serie de máscaras a través de filtros a una imagen para obtener mapas de características (elaboración propia).	17
Figura 5. Ejemplo de un conjunto difuso para la variable lingüística <i>Temperatura</i> y sus particiones <i>baja, media y alta</i> (creación propia).	18
Figura 6. Metodología de investigación. Cada objetivo particular consta de una serie de actividades que incluyen experimentos y análisis de laboratorio.	22
Figura 7. Actividades para la creación de la BD de índices de ROU y para la creación del clasificador automático de ROU.	23
Figura 8. Sistema de captura de imágenes de ROU (elaboración propia).	25
Figura 9. Métodos y procedimientos para la estimación de nutrientes de ROU.	29
Figura 10. Proceso de aprendizaje de las CNN: preproceso, entrenamiento y prueba (diseño propio).....	30
Figura 11. Proceso de clasificación automática de ROU.....	32
Figura 12. Contenedor de 20 L con orificios para la elaboración de composta.	33
Figura 13. Banda transportadora para la toma de video de los ROU a compostar.....	33
Figura 14. Distribución de las unidades experimentales. Tratamientos (T) y repeticiones (R).	34
Figura 15. Sensor de temperatura DS1822 equipado con un microcontrolador y panel solar.....	35
Figura 16. Medidor de CO ₂ y NH ₃ , geles reactivos y escala de color para la prueba Solvita®.....	36
Figura 17. Índice de madurez de composta para la prueba Solvita®. (Fuente: Woods End Laboratories LLC).....	36
Figura 18. Etapa de la composta de acuerdo con el índice de madurez (Fuente: Woods End Laboratories LLC).....	37
Figura 19. Variables lingüísticas Fase y Temperatura con sus respectivas etiquetas lingüísticas del modelo difuso del proceso de compostaje (Creación propia).	42
Figura 20. Modelo de RNA para el proceso de compostaje (elaboración propia).	43
Figura 21. Seguimiento fotográfico de los cambios en las características de algunos ROU.	45
Figura 22. Identificación de la etapa de descomposición de la cáscara de plátano. a) Etapa inicial, b) etapa media y c) etapa avanzada.....	46
Figura 23. Muestra de imágenes capturadas de los ROU de manzana, plátano, limón, naranja y papa.....	47
Figura 24. Variación de C en las tres etapas de descomposición. Las barras representan la desviación estándar (\pm SD) de las medias. Las etapas de descomposición con una misma letra no son estadísticamente diferentes según la prueba de Tukey en $p < 0.05$ ($n = 3$).	50
Figura 25. Valores medios (\pm SD) en N en las tres etapas de descomposición. Las barras con la misma letra no son estadísticamente diferentes según la prueba de Tukey en $p < 0.05$ ($n = 3$). .	50

Figura 26. Contenido medio de P (\pm SD) en las tres etapas de descomposición de ROU. Las mismas letras no son estadísticamente diferentes según la prueba de Tukey en $p < 0.05$ ($n = 3$).	51
Figura 27. Valores medios de K (\pm SD) en las tres etapas de descomposición de ROU. Las mismas letras no son estadísticamente diferentes según la prueba de Tukey en $p < 0.05$ ($n = 3$).	51
Figura 28. Contenidos de la relación C/N (\pm SD) determinados para las tres etapas de descomposición. Las mismas letras no son estadísticamente significativamente diferentes según la prueba de Tukey en $p < 0.05$ ($n = 3$).	53
Figura 29. Gráficas de precisión de las CNN a) ROUNet, b) MobileNet V2 y c) VGG16 para la clasificación de los ROU manzana, plátano, limón, naranja y papa. La línea azul corresponde a los datos de entrenamiento y la línea naranja a los datos de validación. Las gráficas muestran cómo la precisión mejora conforme aumenta el número de épocas (o ciclos) de entrenamiento.	56
Figura 30. Matriz de confusión normalizada de la prueba de las redes a) ROUNet, b) MobileNet V2 y c) VGG16. Los recuadros diagonales representan el número de aciertos para los que la etiqueta predicha es igual a la verdadera, mientras que los elementos fuera de la diagonal son los que el clasificador ha etiquetado erróneamente. Entre más intenso el color azul más aciertos en la predicción.	57
Figura 31. Comparación de los modelos CNN en la clasificación de ROU. Las líneas representan los modelos de CNN y los vértices de la gráfica representan las clases de ROU. Las puntuaciones bajas se sitúan en el centro de la gráfica, mientras que los valores altos se encuentran en los vértices.	58
Figura 32. Matriz de confusión normalizada de las pruebas de a) YOLOv5l y b) YOLOv8l con 100 épocas. Entre más intenso aparece el color azul en la diagonal, ello significa más aciertos en la predicción; los elementos fuera de la diagonal son los que se han clasificado erróneamente.	60
Figura 33. Relación lineal entre peso y número de píxeles para cada uno de los ROU.	61
Figura 34. Contenido de MO, CE y pH (\pm SD) para los tratamientos CN20, CN30 y CN40. Mismas letras indican que no son significativamente diferentes según la prueba de Tukey en $p < 0.05$ ($n=4$).	64
Figura 35. Contenido de N (\pm SD), C (\pm SD) y relación C/N (\pm SD) para los tratamientos CN20, CN30 y CN40. Mismas letras indican que no son estadísticamente diferentes según la prueba de Tukey con $p = 0.05$ ($n = 4$).	64
Figura 36. Comparativo del color de las compostas terminadas por tratamiento.	66
Figura 37. Evolución de las temperaturas de los tres tratamientos durante el proceso de compostaje.	68
Figura 38. Arquitectura de los modelos con dos y tres variables como entradas: a) <i>peso, CN_inicial</i> y b) <i>peso, CN_inicial</i> y <i>etapa</i>	70
Figura 39. Variables Estatus, Temperatura y Fase con sus respectivas etiquetas lingüísticas.	71
Figura 40. Reglas del modelo difuso del proceso de compostaje.	71
Figura 41. Ajuste a la variable Fase a 200 días.	71
Figura 42. Diagrama de la integración de los modelos del proceso de compostaje de ROU (elaboración propia).	72

Lista de tablas

Tabla 1. Relación C/N de algunos residuos.....	9
Tabla 2. Criterio de inclusión/exclusión.....	27
Tabla 3. Fracción no comestible de frutas y hortalizas frescas de mayor consumo en México....	44
Tabla 4. Determinación del color y estado de descomposición por ROU.	45
Tabla 5. Definición de clases para cada tipo de ROU/etapa de descomposición; en todos los casos la cantidad de imágenes capturadas por clase de ROU fue 600.....	47
Tabla 6. Relación C/N de cada ROU como resultado de la búsqueda sistemática.	48
Tabla 7. Contenido de C, N, P, and K de ROU en las etapas de descomposición.	52
Tabla 8. Relación C/N de ROU en las tres etapas de descomposición.	53
Tabla 9. Parámetros para la configuración de las CNN ROUNet, MobileNet y VGG16.	54
Tabla 10. Rendimiento de las CNN en la clasificación de ROU.	55
Tabla 11. Parámetros (en Millones) de los modelos YOLO.....	59
Tabla 12. Rendimiento los modelos YOLOv5l y YOLOv8l.....	59
Tabla 13. Materiales por tratamiento (kg).....	62
Tabla 14. Contenido de ROU (kg) por etapa de descomposición.....	62
Tabla 15. Etapa del proceso de compostaje del tratamiento T3: CN40 a los dos meses.....	63
Tabla 16. Etapa del proceso de compostaje para los tres tratamientos a los tres meses.	63
Tabla 17. Valores promedio (n=4) del contenido de MO, CE y pH por tratamiento.	64
Tabla 18. Valores promedio (n=4) del contenido de N y relación C/N de cada tratamiento.	65
Tabla 19. Contenido de sales solubles en compostas (mS/cm) de cada tratamiento con n=3.....	65
Tabla 20. Contenido de metales pesados en compostas (mg/kg) por tratamiento con n=3.....	65
Tabla 21. Resultado de análisis microbiológicos.	66
Tabla 22. Índice de germinación para los tres tratamientos a los 3 y 10 días.....	66
Tabla 23. Comparación de parámetros obtenidos en el experimento y los indicados en la norma.	67
Tabla 24. Resultado del entrenamiento de los modelos propuestos.....	70

Abreviaturas

μL	Microlitro
AOAC	(Acrónimo Association of Official Analytical Collaboration International) Asociación de Colaboración Analítica Oficial Internacional
As	Arsénico
BD	Base de datos
C	Carbono
C/N	Carbono-Nitrógeno
Ca	Calcio
Cd	Cadmio
CE	Conductividad eléctrica
CIELAB	Espacio de color de CIE (Acrónimo Commission Internationale de l'Éclairage) Comisión Internacional de la Iluminación
cm	Centímetro
CNN	(Acrónimo <i>Convolutional Neural Networks</i>) Redes neuronales convolucionales
CO₂	Dióxido de Carbono
Cu	Cobre
FAO	(Acrónimo <i>Food and Agriculture Organization of the United Nations</i>) Organización de las Naciones Unidas para la Alimentación y la Agricultura
g	Gramo
GPU	(Acrónimo <i>graphics processing unit</i>) Unidades de procesamiento gráfico
Hg	Mercurio
IG	Índice de germinación
INEGI	Instituto Nacional de Estadística y Geografía
jpg	(Acrónimo <i>Joint Photographic Experts Group</i>) Grupo Conjunto de Expertos en Fotografía
K	Potasio
kg	Kilogramo
L	Litro
LD	Lógica difusa
LGPGIR	Ley general para la prevención y gestión integral de los residuos
M	Millón
mAP^{val}	(Acrónimo <i>mean verage precision</i>) Precisión media promedio

Mg	Magnesio
mg/kg	Miligramo por kilogramo
ml	Mililitro
mm	Milímetro
MO	Materia orgánica
MS	Masa seca
mS/cm	MiliSiemens por centímetro
N	Nitrógeno
NA	Sodio
NH₃	Amoníaco
Ni	Níquel
NMP	Número más probable
ONU	Organización de las Naciones Unidas
P	Fósforo
Pb	Plomo
RNA	Redes neuronales artificiales
ROU	Residuos orgánicos urbanos
RSU	Residuos sólidos urbanos
SEMARNAT	Secretaría de Medio Ambiente y Recursos Naturales
SIAP	Servicio de Información Agroalimentaria y Pesquera
T1:CN20	Tratamiento 1 con relación C/N inicial de 20
T2:CN30	Tratamiento 2 con relación C/N inicial de 30
T3:CN40	Tratamiento 3 con relación C/N inicial de 40
VGG16	Red neuronal convolucional con 16 capas del Grupo de Geometría Visual (<i>Visual Geometry Group</i>) de la universidad de Oxford
YOLO	(Acrónimo <i>You Only Look Once</i>) Sólo miras una vez
Zn	Zinc

1. INTRODUCCIÓN

En la actualidad se generan 2010 millones de toneladas de residuos sólidos urbanos (RSU) anualmente en todo el mundo y dados los actuales índices de crecimiento de la población, desarrollo económico y urbanización, se estima que para el 2050 esta cifra aumente en un 70 %, alcanzando unos 3400 millones de toneladas (Kaza *et al.*, 2018). Los RSU se generan como producto de las actividades en los hogares, establecimientos y lugares públicos en las ciudades (LGPGIR, 2023). La ONU reporta que en América Latina y el Caribe se generan 541,000 toneladas al día de RSU que se vierten en rellenos sanitarios (ONU, 2018). De manera particular, en México se generan 44 millones de toneladas de RSU anualmente, equivalentes a 1.0 kg de RSU al día por habitante (SEMARNAT, 2020). Sin embargo, de los 2,203 sitios de disposición final de RSU en México, 2,030 carecen de infraestructura para un correcto control de las emisiones al ambiente (INEGI, 2020). En el estado de Baja California Sur, la cantidad promedio diaria de RSU recolectados en el 2018 fue 1,086.26 t (INEGI, 2019). El estudio realizado por la Cooperación Alemana al Desarrollo en el 2016 informó que la cantidad promedio de RSU, generado diariamente por habitante en la ciudad de La Paz, era de 0.495 kg (GIZ, 2016).

Aproximadamente el 50% de los RSU son residuos orgánicos urbanos (ROU) y se componen principalmente de restos de alimentos y de jardinería (Colón *et al.*, 2010). La mayoría de estos residuos se depositan en algún tipo de vertedero o relleno sanitario (Kaza *et al.*, 2018). Dicha práctica genera serios riesgos a la salud para las personas que operan estos centros y para la población circundante (Abul, 2010). Al mismo tiempo, da lugar a un conjunto de impactos ambientales graves, como la contaminación de suelos y cuerpos de agua (Taheri *et al.*, 2014), la emisión de gases tóxicos y de efecto invernadero (Lu *et al.*, 2009). Además, ocasiona un impacto económico dado que puede afectar a la actividad productiva y al sector turístico (ONU, 2018). El costo de remediar estos efectos negativos es mucho mayor al que pudiera generarse si se desarrollaran soluciones sencillas y adecuadas de gestión de residuos (Kaza *et al.*, 2018).

Una alternativa para la disposición final de los ROU es transformarlos mediante el proceso de compostaje en un producto útil llamado composta (Hargreaves *et al.*, 2008), la cual es usada como abono orgánico por los beneficios que aporta al suelo y a los cultivos (Moreno y Mormeneo,

2008). En el proceso de compostaje intervienen varios factores, incluyendo la humedad, aireación, pH, relación carbono-nitrógeno (C/N), temperatura y tamaño de partícula. La relación C/N es un factor determinante para que el proceso se realice de forma adecuada y depende en gran medida de las propiedades de los materiales a compostar (Adhikari *et al.*, 2010).

Aunque el compostaje es un proceso conocido de utilización de residuos orgánicos, las características de los ROU todavía ofrecen diversos desafíos (Li *et al.*, 2013). Uno de ellos consiste en determinar cómo el proceso de descomposición de los ROU afecta sus características cualitativas y cuantitativas, y en consecuencia su composición de nutrientes, como su contenido de carbono (C) y de nitrógeno (N). Otro reto consiste en investigar la diversidad de parámetros y métodos del proceso de compostaje, toda vez que es importante acordar estrategias para la evaluación práctica de la calidad de la composta para su estandarización (Onwosi *et al.*, 2017). Debido a ello, los productores de composta enfrentan dificultades para obtener productos que mantengan las mismas propiedades, independientemente de los residuos orgánicos utilizados (Riveros *et al.*, 2006).

Por otra parte, a pesar de que existe un creciente interés en el desarrollo de modelos del proceso de compostaje, aún está limitado por la heterogeneidad de los materiales, ya que sólo consideran algunos parámetros y, en particular, no consideran la diversidad de los ROU y sus características cualitativas como su etapa de descomposición y su color.

Los modelos existentes del proceso de compostaje se clasifican en deductivos e inductivos. Los primeros se basan en los procesos físicos y bioquímicos involucrados en el compostaje como el balance de energía, biomasa, sustrato y cinética microbiana, entre otros (Hamelers, 2004). A su vez, los modelos inductivos se construyen tomando en cuenta múltiples correlaciones entre parámetros y su incidencia en un parámetro de respuesta, a partir de la experimentación, lo que permite inferir sobre ciertas condiciones iniciales, sin considerar los procesos propios del compostaje (Solé-Mauri y Díaz, 2008). Dichos modelos son usados debido al número de factores involucrados en el proceso que son difícilmente medibles. Dentro de estos modelos destacan los

que utilizan algoritmos computacionales, incluyendo los algoritmos de aprendizaje-máquina, que son capaces de aprender de los datos y predecir resultados (Hurwitz y Kirsch, 2018).

En este contexto, la presente investigación plantea la generación y sistematización de datos de las características cuantitativas (cantidad, peso, relación C/N) y cualitativas (color y estado de descomposición) de los ROU, así como los datos obtenidos de la medición de los parámetros principales del proceso de compostaje y su producto final, con el fin de desarrollar un modelo que permita adecuar el manejo de los ROU como insumos del proceso de compostaje y obtener un producto final de calidad por medio de herramientas computacionales.

2. ANTECEDENTES

2.1 Residuos orgánicos urbanos (ROU)

En el año 2018 se produjo un estimado de 868 millones de toneladas de frutas y 1,089 millones de toneladas de vegetales a nivel mundial, donde las principales frutas en orden de importancia fueron el plátano, la naranja, el limón y la manzana, entre otros (FAO, 2020). Diariamente se producen residuos de frutas, vegetales y hortalizas en los comercios y en los hogares que suelen eliminarse en los basureros urbanos (Jiang *et al.*, 2015). La fracción no comestible de frutas, vegetales y hortalizas forman parte de los ROU (Colón *et al.*, 2010).

Los restos de frutas, vegetales y hortalizas contienen altas concentraciones de sustancias orgánicas fácilmente degradables como azúcares, almidones, lípidos y proteínas, lo que los hace adecuados para ser tratados mediante el compostaje (Li *et al.*, 2013). Además, por su alto contenido de humedad, reducen la necesidad de agua durante dicho proceso (Choy *et al.*, 2015). Los restos de jardinería y de poda de árboles también forma parte de los ROU y son utilizados en el compostaje como agente de volumen para dar porosidad y estructura a la mezcla, además, absorben parte del exceso de humedad evitando la generación de lixiviados (Shilev *et al.*, 2007; Colón *et al.*, 2010). Otra función importante de dichos materiales es ser fuente de C y energía para los microorganismos que intervienen en el proceso de compostaje (Adhikari *et al.*, 2010).

2.2 Proceso de compostaje

El compostaje es un proceso de descomposición aeróbica de la materia orgánica en condiciones adecuadas (Román *et al.*, 2015). Los procesos metabólicos de los microorganismos son responsables de la descomposición y humificación de la materia orgánica (Sayara *et al.*, 2020), que finalmente se transforma en composta, la cual es un material nutritivo, homogéneo, estable, maduro, libre de contaminación y de patógenos, que aporta beneficios al suelo y a las plantas (Moreno y Mormeneo, 2008).

La composta contribuye a la mejora de las propiedades físicas, químicas y biológicas del suelo (Sánchez *et al.*, 2017). La aplicación de composta mejora la estructura del suelo y la capacidad de retención de agua evitando la pérdida de nutrientes por lixiviación, aumenta la aireación para los

microorganismos e incrementa la capacidad de función como *buffer* o amortiguador, la cual evita cambios extremos de pH del suelo (Nieto-Garibay *et al.*, 2021). Así mismo, libera nutrientes que influyen positivamente en la fertilidad del suelo (Sæbø y Ferrini, 2006) y captura C en el suelo (Pergola *et al.*, 2018), contribuyendo a reducir el calentamiento global (Tanthachoon *et al.*, 2007).

2.2.1 Parámetros del proceso de compostaje

Los estudios sobre el proceso de compostaje llevan un seguimiento de algunos de los parámetros que intervienen en el mismo, los cuales cambian continuamente durante el proceso y afectan significativamente al producto final (Li *et al.*, 2013). Antes de iniciar el proceso de compostaje, es importante establecer la proporción de los materiales que se van a utilizar y determinar su composición como la humedad, pH y la relación C/N (Ghinea y Leahu, 2020).

Durante el proceso de compostaje suceden cambios y el más evidente es la reducción del volumen de los materiales en un 40-60 %; así mismo, es evidente el cambio en el aspecto de los residuos que eventualmente se van transformando en un material homogéneo de color café oscuro similar a la tierra fértil (Nieto-Garibay *et al.*, 2021).

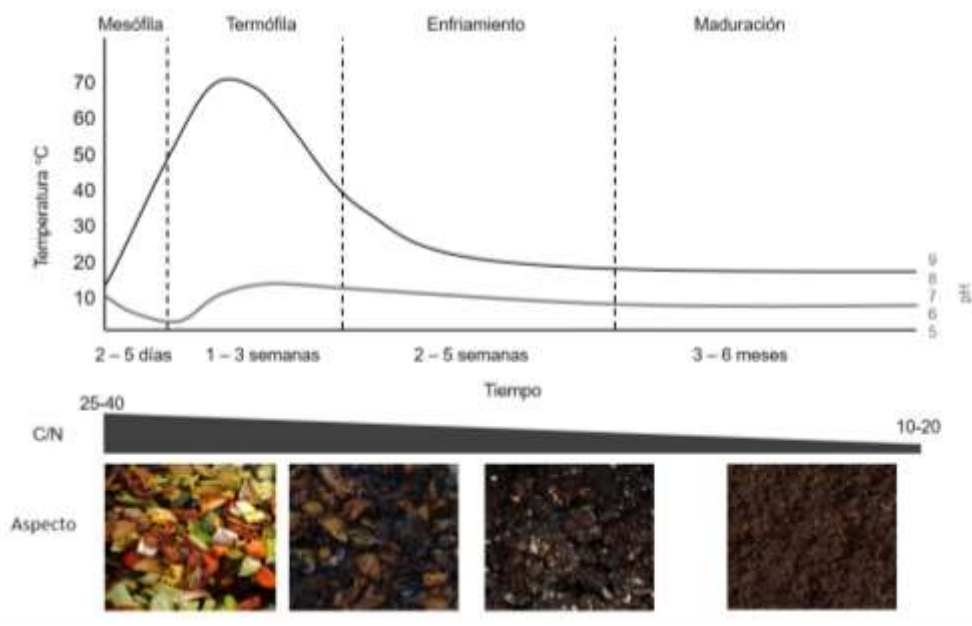


Figura 1. Evolución de temperatura, pH, relación C/N y aspecto de los ROU durante las etapas del proceso de compostaje (adaptado de Bueno *et al.*, 2008; Nieto-Garibay *et al.*, 2021; Román *et al.*, 2015).

2.2.1.1 Temperatura

Cuando los microorganismos descomponen la materia orgánica liberan agua, dióxido de carbono y energía calorífica (Moreno y Mormeneo, 2008), por lo tanto, la temperatura es un indicador adecuado del proceso de compostaje y con base en su evolución se definen las cuatro etapas del proceso (Román *et al.*, 2015): mesófila (temperatura entre 25 °C y 45 °C), termófila (temperatura mayor a 45 °C), enfriamiento (temperatura menor a 45 °C) y maduración (temperatura ambiente). La Fig. 1 muestra las etapas del proceso de compostaje y su duración aproximada con base en la evolución de la temperatura, así como los cambios en el pH y la relación C/N.

Durante la etapa mesófila, el calor es producido por los microorganismos que descomponen los compuestos más fácilmente degradables como los carbohidratos (Shilev *et al.*, 2007). Cuando la temperatura empieza a superar los 45 °C, los microorganismos presentes, llamados mesófilos porque aparecen en esta etapa, empiezan a ser reemplazados por microorganismos termófilos que toleran temperaturas mayores y así es que inicia la etapa termófila del proceso. En la etapa termófila se alcanza la temperatura mayor del proceso, que puede alcanzar entre a los 60 °C y 70 °C, la cual es consecuencia de esta actividad microbiana y es necesaria para garantizar la inocuidad de la composta (Peña *et al.*, 2020). En esta etapa se descomponen las proteínas y otros compuestos complejos (Shilev *et al.*, 2007). Posteriormente, la temperatura empieza a descender e inicia la fase de enfriamiento con la aparición de nuevos microorganismos mesófilos y finalmente se pasa a la etapa de maduración.

La duración de las etapas del proceso de compostaje puede variar, dependiendo del método de compostaje y de los materiales orgánicos a utilizar. La etapa mesófila tiene una duración de 2 a 5 días, la etapa termófila de 2 a 3 semanas, enfriamiento puede durar de 2 a 5 semanas y maduración puede tardar hasta 6 meses (Román *et al.*, 2015).

2.2.1.2 Humedad

El agua es indispensable para los microorganismos por ser el medio de transporte de sustancias solubles que sirven de alimento y de desechos de las reacciones que se realizan durante el proceso (Bueno *et al.*, 2008). La humedad óptima para el crecimiento microbiano oscila entre 50 y 60 %; cuando es menor, se presentan condiciones anaeróbicas y surgen malos olores,

disminuyendo la velocidad del proceso (Shilev *et al.*, 2007). Si existe un exceso de humedad, los microorganismos no tienen el oxígeno suficiente para poder reproducirse y desarrollarse, por lo tanto, el proceso será muy lento. En cambio, si la humedad no es suficiente en la composta, no existirán las condiciones para que los microorganismos puedan vivir, lo que se resuelve agregando agua (Nieto-Garibay *et al.*, 2021).

2.2.1.3 Aireación

El proceso de compostaje es un proceso de descomposición aeróbico, donde se necesita oxígeno para que se lleve a cabo (Román *et al.*, 2015). La aireación en el proceso de compostaje actúa directamente en la actividad microbiana, en la tasa de degradación del sustrato y en la variación de temperatura (Guo *et al.*, 2012).

La falta de oxígeno provoca que se den condiciones anaeróbicas, por lo tanto, un retardo en la descomposición, apareciendo entonces malos olores. El exceso de aireación provoca el enfriamiento y el secado de la mezcla con la disminución de la actividad microbiana (Bueno *et al.*, 2008). Una manera de aumentar la aireación es hacer volteos frecuentes del sustrato durante el proceso de compostaje (Alexander, 2007; Soto-Paz *et al.*, 2019).

2.2.1.4 pH

Hacia el final de la etapa mesófila, el pH tiende a disminuir debido a la liberación de ácido orgánico, y eventualmente tiende a subir debido a la alcalinización del medio alcanzando el valor neutro hacia el final del proceso (Bueno *et al.*, 2008).

Sí durante el proceso de compostaje hay una falta oxígeno, se dan condiciones anaeróbicas y la acumulación de ácido puede reducir el pH, limitando la actividad microbiana (Román *et al.*, 2015). En tales casos, la introducción de aire es suficiente para devolver el pH a valores aceptables (Shilev *et al.*, 2007). Por lo antes expuesto, una manera indirecta de medir la aireación es midiendo el pH (Bueno *et al.*, 2008).

2.2.1.5 Tamaño de partícula

La actividad microbiana está relacionada con el tamaño de la partícula. Si las partículas son muy grandes, la energía necesaria para que los microorganismos actúen sobre ella es mucho mayor, en cambio, si son muy pequeñas no permitirán la acción de los microorganismos debido a que no habrá espacios con aire y por lo tanto faltará el oxígeno, por lo que el tamaño ideal de los materiales es de 1 a 5 cm (Nieto-Garibay *et al.*, 2021). Además, el tamaño apropiado de los materiales permite la uniformidad en el compostaje, una mejor aireación y mantiene las condiciones adecuadas de humedad (Mishra y Yadav, 2022).

La densidad del material, la aireación y la retención de humedad, están estrechamente relacionados con el tamaño de la partícula; conforme avanza el proceso de compostaje, el tamaño disminuye y la densidad aumenta (Román *et al.*, 2015).

2.2.1.6 Relación C/N

La relación C/N inicial es determinante para que el proceso de compostaje se realice de forma adecuada y depende en gran medida de las propiedades de los materiales que se utilicen en el proceso (Adhikari *et al.*, 2010). El C es la fuente principal de energía para los microorganismos y junto con el N contribuyen a la síntesis de proteína y al crecimiento microbiano (Bueno *et al.*, 2008). Los microorganismos requieren 30 partes de C por 1 de N, por lo que una relación C/N teóricamente recomendada está en el intervalo 25-40 al inicio del proceso y hacia el final el intervalo es de 10-20 (Nieto-Garibay *et al.*, 2021). Si al inicio del proceso de compostaje la relación C/N es mayor a 40, debido al exceso de C, el proceso tiende a enfriarse y a ralentizarse, en cambio si la relación C/N es menor a 25, el proceso tiende a calentarse en exceso y se lleva a cabo con mayor rapidez lo que provoca la liberación de amoníaco (Román *et al.*, 2015).

La concentración de N y su evolución durante el compostaje depende del material que aporta el nitrógeno a la mezcla y de la tasa de degradación de la materia orgánica (Sánchez-Monedero *et al.*, 2001). El C es un elemento presente en todas las sustancias orgánicas, azúcares, proteínas y grasas, entre otras (Mirabelli, 2008). La característica del color es un indicador adecuado del contenido de C y de N: los materiales verdes y frescos contienen más nitrógeno, mientras que los materiales de tonalidades cafés o secos tienen más carbono (Nieto-Garibay *et al.*, 2021). De

manera adicional, la relación C/N se utiliza como parámetro de referencia de la capacidad de búfer del sistema (Reyna-Gómez *et al.*, 2019).

Todos los factores que intervienen en el proceso de compostaje están relacionados entre sí. De la relación C/N de los materiales a compostar dependerán las temperaturas alcanzadas (Nieto-Garibay *et al.*, 2021), por lo que es importante conocer la relación C/N de algunos materiales orgánicos (Tabla 1) para ser compostados (Shilev *et al.*, 2007; Li *et al.*, 2013; Duarte, 2018; Nieto-Garibay *et al.*, 2021).

El exceso de humedad provoca falta de oxígeno generando condiciones anaeróbicas lo que a su vez provoca cambios en el pH con el aumento de la acidez del medio (Li *et al.*, 2013).

Tabla 1. Relación C/N de algunos residuos.

Material	Relación C/N
Pasto verde (Taiwán)	12
Pasto seco (Taiwán)	70
Hojarasca	50
Restos de café	20
Pajas	120
Restos de frutas y vegetales	25
Restos de poda	25.9
Aserrín	150
Papel	100
Alfalfa fresca	10
Alfalfa seca	70

2.2.2 Calidad de la composta

Para obtener una composta de calidad es necesario comprender el proceso involucrado y evaluar las condiciones de desempeño más adecuadas (Sánchez-Monedero *et al.*, 2001). La calidad de la composta involucra dos términos: estabilidad y madurez (Goa, 2015). La primera está relacionada con el grado de descomposición de la materia orgánica y está indirectamente relacionado con la actividad biológica (Cerdeira *et al.*, 2018). La madurez describe la idoneidad de la composta para un

uso particular y comúnmente se asocia con el crecimiento de las plantas o la fitotoxicidad (Kucbel *et al.*, 2019).

La calidad de la composta depende del material que se utilice y de su composición química, así como la evolución de los parámetros del proceso (Muscolo *et al.*, 2018; Milinković *et al.*, 2019). Por otro lado, hay aspectos cualitativos que son indicadores de una composta de calidad: una composta estará lista cuando su apariencia sea completamente diferente al material de origen teniendo todas las características de la tierra fértil, olor a tierra húmeda y color café (Nieto-Garibay *et al.*, 2021).

En México, la norma NMX-AA-180-SCFI-2018 (2018) establece los métodos y procedimientos para el tratamiento aerobio de los ROU, así como las especificaciones de calidad de una composta terminada. Esta norma señala que se debe garantizar la estabilidad y la madurez de la composta de acuerdo con los parámetros cuantitativos y cualitativos que en ella se indican, incluyendo la conductividad eléctrica (CE), pH, relación C/N, color, olor, concentración de elementos traza y especificaciones microbiológicas, entre otros.

2.3 Modelos del proceso compostaje

El modelo de sistemas ha sido ampliamente usado en ciencia e ingeniería para mejorar su comprensión, establecer estrategias de control y predecir su rendimiento (Fernández *et al.*, 2016). Para el proceso de compostaje se han aplicado dos enfoques: los modelos deductivos y los modelos inductivos o empíricos.

Los modelos deductivos están basados en los procesos físicos y bioquímicos que intervienen en el proceso de compostaje y definen un conjunto de ecuaciones que describen la dependencia de la tasa de compostaje de factores como temperatura, biomasa, humedad, oxígeno, porosidad, tamaño de partícula y relación C/N (Hamelers, 2004). Dichos modelos están basados en la cinética de hidrólisis, biodegradación, el equilibrio térmico y ecuaciones de balance de masa (Vasiliadou *et al.*, 2015; Vidriales-Escobar *et al.*, 2017).

Por otro lado, los modelos inductivos buscan como dos o más factores, que intervienen en el proceso de compostaje, inciden en un parámetro de respuesta, a partir de la experimentación para hacer inferencias dada ciertas condiciones iniciales (Solé-Mauri y Díaz, 2008). Estos modelos emplean algoritmos computacionales de Inteligencia Artificial, particularmente del campo llamado aprendizaje máquina (*machine learning*), los cuales son algoritmos que aprenden iterativamente de los datos para mejorarse y para predecir resultados (Hurwitz y Kirsch, 2018). Los datos que manejan los algoritmos de aprendizaje máquina pueden ser datos numéricos, texto, imágenes, señales o sonido.

Guo y colaboradores (2021) presentan una revisión de la aplicación de diversas herramientas del aprendizaje máquina en el tratamiento de residuos orgánicos. La técnica llamada máquina de soporte de vectores ha sido usada en la digestión anaeróbica; los algoritmos genéticos se han aplicado en el tratamiento y manejo de los rellenos sanitarios; los árboles de decisión, en particular el algoritmo conocido como *random forest*, han sido aplicado en el tratamiento térmico (pirolisis e incineración) de los residuos orgánicos. Las llamadas redes neuronales artificiales (RNA) han sido aplicadas en el tratamiento aeróbico de residuo, siendo este el modelo más utilizado y que se ha aplicado con éxito en problemas relacionados con los residuos orgánicos. En este trabajo de investigación se propone un modelo basado en las RNA para clasificación de ROU y otras herramientas para la estimación de la calidad de la composta.

También se ha dado la inclusión del enfoque estocástico, con la aplicación de los algoritmos de lógica difusa, que permite abordar la incertidumbre de información incompleta o inexistente en sistemas de compostaje (Li *et al.*, 2013). Ejemplo de ello es el trabajo de Díaz y colaboradores (2012), donde se utilizó un sistema de inferencia difusa basado en una RNA sobre las variables independientes (aireación, humedad, tamaño de partícula, tiempo de compostaje) para estimar pH, temperatura y evolución de CO₂.

2.4 Redes neuronales artificiales

Las redes neuronales artificiales (RNA) son técnicas de aprendizaje máquina que emulan el mecanismo de aprendizaje en organismos biológicos. Las RNA son herramientas que permiten

identificar las relaciones dinámicas entre parámetros, así como detectar fallas experimentales y obtener modelos predictivos (Soto-Paz *et al.*, 2019). Son modelos multivariantes, no lineales que permiten manipular patrones complejos a diferencia de otros métodos matemáticos (Solé-Mauri y Díaz, 2008). Su potencial para la predicción en comparación con los métodos tradicionales, como la regresión, se ha evaluado en varias áreas de aplicación (Pulido-Calvo *et al.*, 2005; Gómez-Ossa y Botero, 2014; Támara *et al.*, 2019) y la principal razón para su uso es que no requieren del cumplimiento de supuestos teóricos (Menacho, 2014).

El poder de las RNA radica en el procesamiento paralelo realizado por unidades básicas de procesamiento llamadas neuronas (Aggarwal, 2018). Las neuronas artificiales se combinan en estructuras denominadas capas, de esta manera, la información se encuentra distribuida a lo largo de las conexiones de la red, dándole a este sistema cierta tolerancia a fallos. La Fig. 2 presenta una red neuronal artificial con 3 capas: una capa de entrada que recibe los datos de entrada y una capa de salida que devuelve la predicción realizada. La capa del medio se llama *capa oculta* (puede tener varias capas ocultas con diferente número de neuronas). Las neuronas se representan por círculos y están interconectadas entre sí. Cada conexión de la red tiene asociado un peso (w_i) lo que pondera el valor de la entrada. La entrada se multiplica por el peso de la conexión y este valor es la entrada a la neurona de la siguiente capa, y así sucesivamente hasta la capa de salida. Posteriormente se calcula el error restando el resultado obtenido con el valor esperado; si el error no es igual a cero, se actualizan los pesos y se vuelve a repetir el entrenamiento.

En un modelo de RNA una *etiqueta* es lo que se intenta predecir con el modelo y una característica es una variable de entrada. Un modelo de RNA tiene dos fases (Torres, 2020):

1. **Fase de entrenamiento** (aprendizaje), cuando se crea el modelo y aprende de forma iterativamente de las relaciones entre las características y etiquetas de ejemplos.
2. **Fase de inferencia** (predicción), se refiere al proceso de realizar predicciones aplicando el modelo ya entrenado a ejemplos sin etiquetar y que no formaron parte del conjunto de ejemplos de entrenamiento.

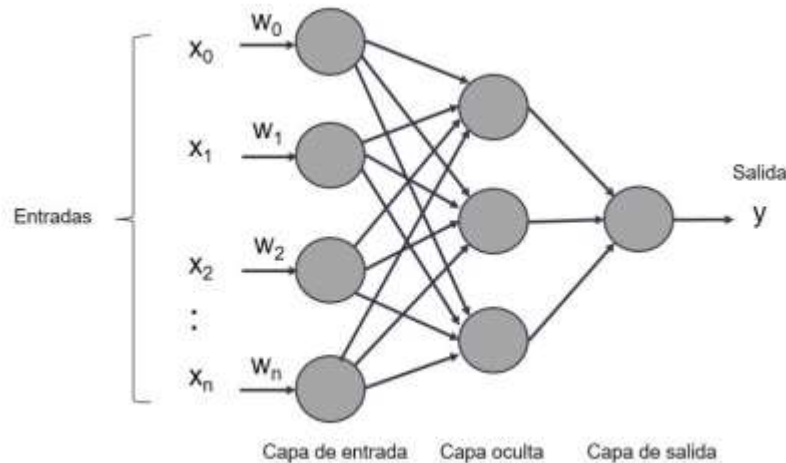


Figura 2. Estructura típica de una RNA compuesta por capas de neuronas representadas por círculos (elaboración propia).

En la fase de entrenamiento de un modelo, se aprenden los valores ideales para los parámetros del modelo (los pesos w_i). Una forma de lograrlo es examinando muchos ejemplos etiquetados e intentando determinar valores para estos parámetros del modelo minimizando el error de lo que se estima y lo que se espera.

Las capas realizan una serie de transformaciones lineales y no lineales de los datos de entrada para generar una salida cercana a la esperada. El aprendizaje supervisado consiste en obtener los parámetros de estas transformaciones (los pesos w_i) e intenta que estas transformaciones produzcan una salida que difiera lo menos posible de la salida esperada. Un modelo de RNA tiene la forma:

$$\hat{y} = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n \quad (1)$$

Con la siguiente expresión general:

$$\hat{y} = \sum_0^n w_i x_i \quad (2)$$

Donde \hat{y} es la predicción o estimación (variable dependiente o respuesta, puede ser más de una), w_i son coeficientes, llamados *pesos*, que la red debe encontrar en su etapa de aprendizaje y x_i es una de las entradas a la red (variables independientes o explicativas).

Las RNA se aplican en campos tan variados como en negocios y finanzas, medicina, seguridad informática, entretenimiento, incluso en agricultura, acuicultura y ecología, siendo sus principales tareas la clasificación y predicción (Gómez-Ossa y Botero, 2014). Ejemplos de la aplicación de estos modelos en el proceso de compostaje se encuentran los presentados por Lin y colaboradores (2016) que construyeron modelos de predicción de pH y temperatura para residuos de comida, así como el presentado por Soto-Paz y sus colaboradores (2019) que aplicaron una RNA evaluando simultáneamente factores como la relación de mezcla y la frecuencia de volteo sobre variables como temperatura, pH, carbono orgánico oxidable y nitrógeno total para los residuos de la caña de azúcar y de pasto estrella.

Los modelos basados en RNA para el proceso de compostaje predicen la tendencia de algunos de los parámetros involucrados en el mismo. Hay modelos que toman en cuenta los insumos del proceso, pero son uno o dos tipos de residuos o son considerados de forma general como residuo de comida o restos de frutas y verduras. El modelo propuesto en este trabajo pretende predecir la calidad de la composta teniendo como entrada las características cualitativas y cuantitativas de los ROU y tomando en cuenta los parámetros del proceso de compostaje.

2.4.1 Redes neuronales convolucionales (CNN)

Las redes neuronales convolucionales (CNN, *convolutional neural network*) son un tipo de RNA con la diferencia de que las CNN tienen la capacidad de reconocer patrones, lo que las hace más adecuadas para tareas de reconocimiento de patrones y clasificación de imágenes (O'Shea y Nash, 2015). El éxito que han tenido este tipo de redes se debe a la disponibilidad de grandes repositorios de imágenes como ImaginNet (Stanford Vision Lab), Kaggle (Alphabet Inc), y COCO (Lin *et al.*, 2015) y también se debe a los sistemas computacionales de alto rendimiento como los sistemas de unidades de procesamiento gráfico o *graphics processing unit* (GPU) y los *clusters* distribuidos a gran escala (Simonyan y Zisserman, 2015).

Una CNN toma como entrada una imagen representada como una matriz numérica y realiza una extracción de características que consiste en operaciones sobre la imagen para obtener una nueva matriz numérica, lo que ayuda a capturar y representar el contenido clave de ésta (Torfi *et al.*, 2020).

Las CNN se han aplicado para la clasificación de diversos residuos, a través de imágenes, en orgánico e inorgánico, o en alguna subclase como papel, vidrio o aluminio (Chu *et al.*, 2018; Desai *et al.*, 2018; Frost *et al.*, 2019). Otros trabajos emplean las CNN para la clasificación de frutas y vegetales (Hussain *et al.*, 2018; Mureşan y Oltean, 2018; Wang y Chen, 2018; Sakib *et al.*, 2019; Zhang *et al.*, 2019), para la detección de madurez de frutas (Sri *et al.*, 2020), para la identificación de ingredientes y alimentos, así como en el reconocimiento del estado de cocción de alimentos en preparación (Chen y Ngo, 2016; Jelodar *et al.*, 2018; Salekin *et al.*, 2019; Ciocca *et al.*, 2020). En este trabajo se propone una CNN para la clasificación de ROU, particularmente aplicada a imágenes de restos de frutas y vegetales, dado que las aplicaciones antes mencionadas no lo han considerado.

Para mejorar el rendimiento de los algoritmos de aprendizaje máquina, incluidas las CNN, los datos de entrada se disponen en dos o tres conjuntos, uno de entrenamiento, otro de validación, y en ocasiones puede tenerse un tercer conjunto para pruebas (Raschka y Mirjalili, 2019). Ejemplos de proporciones para cuando son dos conjuntos podría ser 60:40, 70:30 o 80:20 así como 70:15:15 o 80:10:10 para cuando se consideran tres conjuntos. Los datos de validación y los de prueba son usados para comprobar el desempeño del modelo y, si es necesario, hacer ajuste al mismo (Torres, 2020).

Los algoritmos de aprendizaje máquina son más efectivos si tienen acceso a más datos, incluso cuando los datos son de menor calidad, los algoritmos pueden funcionar mejor, siempre que el modelo pueda extraer datos útiles del conjunto original (Wang y Perez, 2017). Para cuando se tienen pocos datos, una técnica usada es el aumento de datos (*data augmentation*), la cual consiste en aplicar transformaciones a los datos y obtener nuevas posibilidades que se estén escapando en el conjunto de entrenamiento. Para ello se debe tener en cuenta el contexto del problema y evitar que dichas transformaciones generen datos fuera de la realidad (Torres, 2020). Para el caso de imágenes, el aumento de datos aplica transformaciones geométricas, como acercamiento, volteo, rotación y recorte, o transformaciones fotométricas como fluctuación de color y mejora de bordes (Hridayami *et al.*, 2019).

2.4.2 Arquitectura de una CNN

La Fig. 3 muestra la arquitectura básica de una CNN basada en la red LeNet-5 (Lecun *et al.*, 1998) cuyas capas básicas son convolución, agrupación (*pooling*) y capa completamente conectada (*full connected* o FC).

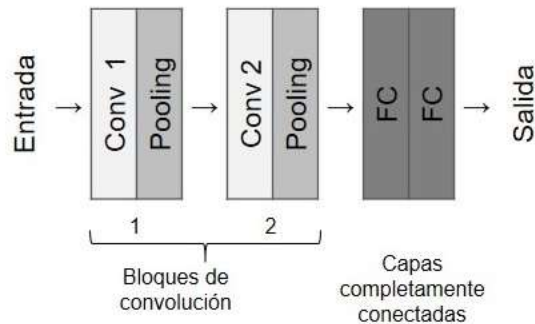


Figura 3. Red neuronal convolucional (CNN) con los bloques típicos de convolución y capas completamente conectadas (modificado de Lecun *et al.*, 1998).

La convolución es un tipo especializado de operación lineal donde se aplican filtros a la imagen para la identificación de características de los objetos (Goodfellow *et al.*, 2016; Hridayami *et al.*, 2019). Una operación de convolución se expresa de la siguiente manera:

$$s = x * k \quad (3)$$

Donde x es la entrada, k es el filtro (también llamado *kernel*) y s es la salida, conocida como llamada mapa de características.

Los filtros van generando nuevas salidas mientras que la capa de agrupamiento reduce el tamaño de la imagen (Fig. 4). Finalmente, las características obtenidas en la última capa de convolución son entrada a las capas completamente conectadas que forman una RNA tradicional en la cual se puede usar más de una capa para aumentar el poder de cálculo (Aggarwal, 2018).




Figura 4. La convolución aplica una serie de máscaras a través de filtros a una imagen para obtener mapas de características (elaboración propia).

Se han desarrollado diversas CNN, pero todas parten de la arquitectura básica de red LeNet-5. Sin embargo, no siempre es necesario empezar a construir una CNN desde cero. Lo recomendable cuando se tiene un conjunto de datos reducido, es utilizar el método llamado transferencia de aprendizaje (*transfer learning*) que permite hacer uso de una CNN de código abierto que ya ha sido entrenada previamente en un gran conjunto de datos (Torres, 2020). Las primeras capas de estas redes son útiles porque aprenden varios tipos de formas en las imágenes que pueden ser útiles para prácticamente cualquier tipo de aplicación de clasificación (Aggarwal, 2018). Ejemplos de CNN pre-entrenadas son VGG16 (Simonyan y Zisserman, 2015), MobileNet (Howard *et al.*, 2017) y GoogleLeNet (Lecun *et al.*, 2015), entre otras.

Un modelo particular de CNN son los modelos YOLO (You Only Look Once), los cuales fueron los primeros modelos de detección de objetos con una única pasada convolucional (Redmon *et al.*, 2016). Estos algoritmos son más rápidos detectando objetos, pero algunas veces con menor precisión por lo que no requieren de recursos potentes y costosos para el cálculo (Diwan *et al.*, 2023). Con una única pasada a la red convolucional detecta objetos mucho más rápido en computadoras que no tienen que ser potentes, permitiendo la detección sobre video en tiempo real de cientos de objetos en simultáneo y su ejecución en dispositivos móviles (Bagnato, 2021). Sin embargo, el gran número de parámetros e hiperparámetros que maneja hace que el tiempo de cálculo sea demasiado largo y el rendimiento en tiempo real sea limitado cuando se usa con algunos dispositivos integrados (Zheng y Ge, 2021).

2.5 Modelos de lógica difusa

Los algoritmos de lógica difusa (LD) se utilizan para crear modelos del proceso de compostaje en condiciones de incertidumbre (Qin *et al.*, 2007). Además, se han empleado como sistemas de control que permiten ahorrar tiempo, tomar decisiones y encontrar soluciones óptimas, por ejemplo, para cambiar la tasa de aireación y el consumo de calor en la materia prima (Neugebauer *et al.*, 2014) o para llevar un seguimiento de la temperatura durante el proceso.

A diferencia de los conjuntos tradicionales donde un objeto pertenece o no a un conjunto, en los conjuntos difusos los objetos tienen un grado de pertenencia a los conjuntos (valor entre el 0 y 1). El grado de pertenencia se determina por una función de membresía $\mu(x)$. Un conjunto difuso, tiene asociada una etiqueta llamada variable lingüística que son variables cuyos valores son palabras o sentencias en lenguaje natural (Zadeh, 2008), por ejemplo, en la Fig. 5, se muestra las particiones de la variable lingüística *Temperatura*, así como los valores de sus particiones: *baja*, *media* y *alta*. Cuando la temperatura es de 20 °C, esto es $x = 20$, la función de membresía $\mu(x)$ indica que la temperatura es *media*.




Figura 5. Ejemplo de un conjunto difuso para la variable lingüística *Temperatura* y sus particiones *baja*, *media* y *alta* (creación propia).

3. JUSTIFICACIÓN

Los ROU mal gestionados afectan negativamente el medio ambiente y la salud humana. El abordar estos efectos tiene un costo mayor que el costo de generar soluciones sencillas y adecuadas de gestión de residuos (Kaza, 2018). Uno de los problemas del manejo de los ROU, específicamente los restos de frutas y vegetales que resultan de la preparación de alimentos, es que se descomponen rápidamente variando su aspecto y su contenido de C y N (Soto-Paz et al. 2019). Modelos existentes del proceso de compostaje no consideran la diversidad de los ROU y sus características cualitativas como la etapa de descomposición. Así mismo, esta heterogeneidad de los ROU dificulta la estandarización de una composta de calidad.

Esta investigación realiza la generación y sistematización de datos de las características de los ROU, de los principales parámetros del proceso de compostaje y de su producto final, con el fin de desarrollar un modelo computacional que permita el manejo del proceso y además permita estimar la calidad de la composta.

4. HIPÓTESIS

La calidad de la composta está estrechamente relacionada con la relación C/N, la cual depende de las características cualitativas y cuantitativas de los ROU, en consecuencia, la calidad puede estimarse a través de un modelo basado en la relación C/N y en las características de los ROU para estandarizar el proceso de compostaje.

5. OBJETIVOS

5.1 Objetivo general

Generar un modelo de utilidad para predecir la calidad de la composta y manejo del proceso a partir de la relación C/N en función de las características cualitativas y cuantitativas de los ROU.

5.2 Objetivos particulares

1. Determinar a través de mediciones sistemáticas directas e indirectas, índices cualitativos y cuantitativos de las características de los ROU, para establecer la relación C/N.
2. Generar un modelo mediante algoritmos computacionales para estimar la calidad de la composta basado en los índices obtenidos de los ROU.
3. Evaluar el modelo en el manejo y calidad de la composta, comparando el valor estimado de la calidad con datos experimentales y análisis de laboratorio.

6. MATERIAL Y MÉTODOS

Las actividades para lograr el objetivo general y los objetivos particulares de este trabajo de investigación se resumen en la Fig. 6.

En el objetivo particular uno, la primera actividad es la creación de una base de datos (BD) de índices de los ROU seleccionados para este estudio. Como segunda actividad, se desarrollan algoritmos para la clasificación automática de los ROU a través de imágenes. El objetivo 2 consiste en la creación de un modelo del proceso de compostaje con herramientas computacionales tomando como base los datos de los índices y los algoritmos desarrollados en el objetivo 1. En el objetivo 3, se prueba el modelo y se hacen ajustes. La creación, ajuste y prueba del modelo se hizo usando los datos obtenidos de un experimento, así como de análisis de laboratorio.

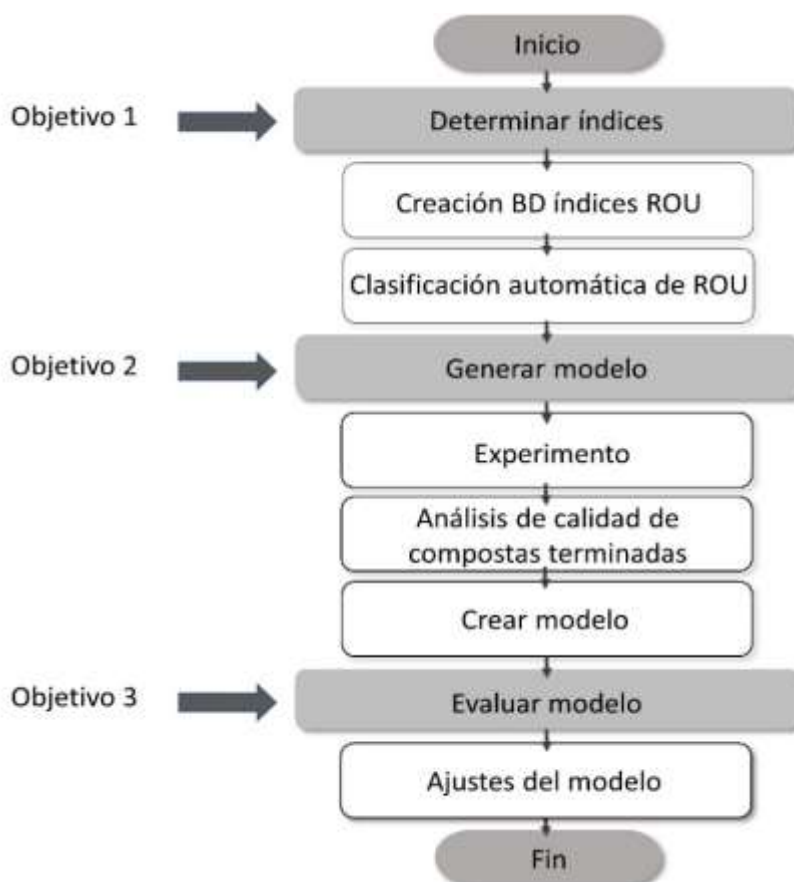


Figura 6. Metodología de investigación. Cada objetivo particular consta de una serie de actividades que incluyen experimentos y análisis de laboratorio.

6.1 Determinación de índices cualitativos y cuantitativos de ROU

Para lograr el primer objetivo, se creó una BD de índices de ROU y se desarrolló un clasificador automático de ROU. Un índice es una correlación de un ROU particular en una imagen digital con sus características cualitativas (color y etapa de descomposición) y cuantitativas (peso, expresado en gramos, y relación C/N). La Fig. 7 resume las actividades para la creación de la BD de índices. Dicha BD se utilizó para crear un clasificador automático de ROU que consiste en detectar residuos orgánicos en una imagen o video en tiempo real, determinar su estado de descomposición, estimar su peso y su relación C/N.

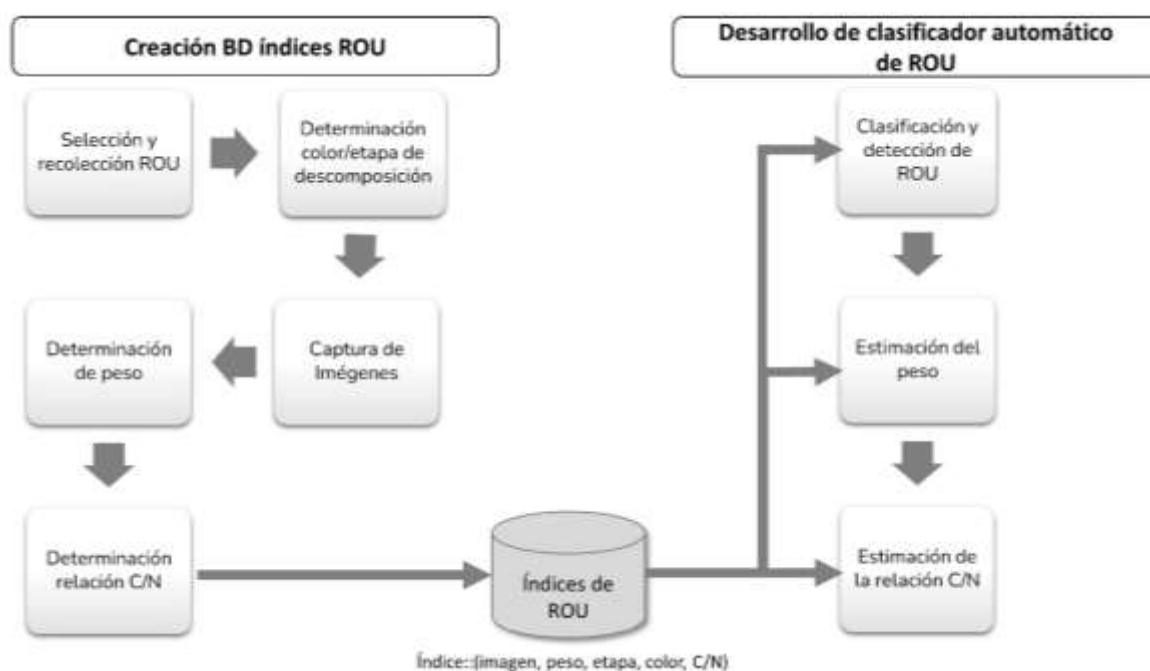


Figura 7. Actividades para la creación de la BD de índices de ROU y para la creación del clasificador automático de ROU.

6.1.1 Creación de la BD de índices de ROU

Para crear los índices de los ROU se realizaron tres actividades: selección y recolección de residuos, determinación del color/etapa de descomposición y la determinación de la relación C/N. Cada actividad se detalla en los apartados siguientes.

6.1.1.1 Selección y recolección de ROU

Para identificar y seleccionar las frutas y hortalizas más consumidas en México, se realizó una consulta al Sistema de Información Agroalimentaria y Pesquera, a través del documento Panorama Agroalimentario 2023 (SIAP, 2020), el cual presenta información estadística acerca del sector agroalimentario en México.

Para complementar la selección de frutas y vegetales, se consultó literatura publicada para determinar cuál es el residuo que generan dichas frutas y hortalizas una vez consumidas y cuál es su fracción respecto a la fruta fresca. Una vez determinados los ROU para este estudio se procedió a la recolección de estos.

6.1.1.2 Determinación de color y estado de descomposición

Para la determinación de la etapa de descomposición y del color se llevó el seguimiento fotográfico de ROU a temperatura ambiente durante 7 días para identificar cambios de color. Con dicho ejercicio se propusieron las etapas de descomposición de los ROU. La categorización generada es una adaptación de la escala de madurez y color del plátano postcosecha de Von Loesecke (Hou *et al.*, 2015) en la que los estados de madurez se establecen con base en los cambios de color.

Una vez identificado los cambios, se desarrolló un algoritmo para contabilizar los píxeles de los ROU en una imagen y se determinó el área total del residuo. A continuación, se analizó el espacio de color CIELAB inherente a las imágenes de los ROU para generar sus histogramas que representan el número de píxeles de un determinado canal del espacio de color usando el canal L de iluminación, el cual representa la intensidad de la luminosidad medida en una escala de 0 a 100, donde 0 representa el negro y 100 representa el blanco para cada píxel en la imagen. Finalmente, para determinar la etapa de descomposición se aplicó siguiente ecuación:

$$etapa_descomp = \text{área_total_ROU} - \text{píxeles_negros}_{CIELab} \quad (4)$$

6.1.1.3 Captura de imágenes y determinación del peso de ROU

Una vez seleccionadas los ROU de las frutas y hortalizas, se recolectaron y se procedió a la captura de imágenes digitales, la cual se realizó de forma sistemática en condiciones controladas, mediante un programa desarrollado en el lenguaje de programación Python™ (Python, 2020) con la librería OpenCV, *Open source Computer Vision* (Bradski, 2000). El programa se implementó para etiquetar y almacenar las imágenes de forma automática.

Se utilizó una cámara web Logitech c920, en un plano cenital a 30 cm de altura, en condiciones de iluminación controladas con una única fuente de luz blanca de una lámpara led de 5 Watts. Los ROU se colocaron extendidos sobre una base con fondo azul para crear contraste. La Fig. 8 muestra un esquema del sistema que se diseñó para la captura de las imágenes de este trabajo.



Figura 8. Sistema de captura de imágenes de ROU (elaboración propia).

Al momento de capturar la imagen de cada ROU fue pesado, registrado su peso en gramos en la BD de índices, para lo cual se utilizó una báscula digital marca Queen Sense con una resolución de 0.01 g y un intervalo de entre 0.01 a 500 g.

6.1.1.4 Determinación de la relación C/N en ROU

Para determinar el contenido de C/N de los ROU en sus etapas de descomposición, primero, se realizó una revisión sistemática de artículos publicados. Además, se realizaron análisis de laboratorio para determinar el contenido de macronutrientes de ROU en las etapas de descomposición.

a) Revisión sistemática

Para la revisión sistemática se siguió la metodología propuestos por Sánchez-Meca (Sánchez-Meca, 2010) que consiste en aplicar métodos sistemáticos para buscar, seleccionar y valorar el material científico que esté publicado sobre un tema de interés, lo que permite obtener conclusiones válidas. Dicha metodología propone los siguientes pasos: a) formulación del problema en donde se plantea una pregunta, el objetivo de la búsqueda y los constructos o palabra claves que servirán para hacer la búsqueda; b) la búsqueda de estudios se hace por medio de la formulación se ecuaciones que incluyen los constructos; c) la codificación de estudios permite descartar los artículos que no cumplen con el objetivo y los criterios de exclusión/inclusión que se hayan planteado; d) la síntesis de resultados que resume los resultados, y por último; e) la publicación de los resultados para que sean conocidos. Este paso, se omitió en este trabajo ya que los resultados obtenidos se almacenaron en la BD de índices.

Para la formulación del problema se planteó la siguiente pregunta: ¿Cuál es la relación C/N de los ROU en sus diferentes etapas de descomposición? lo que llevó al planteamiento siguiente: Si la relación C/N de los ROU depende de su composición química, entonces la relación C/N varía dependiendo de la etapa de descomposición del ROU. El objetivo de esta búsqueda fue el de conocer la relación C/N de los ROU de interés para este estudio en sus etapas de descomposición. Los constructos propuestos para la búsqueda sistemática fueron las siguientes palabras en inglés para una búsqueda más amplia: *C/N ratio*, *Carbon*, *Nitrogen*, *Ripeness* y el nombre del ROU.

La búsqueda de los estudios se llevó a cabo por medio de los motores de búsqueda siguientes:

1. Scopus, a través de una interfaz de programación de aplicaciones o API (*Application Programming Interface*), la cual consiste de un conjunto de rutinas que provee acceso a funciones de un determinado software. Para ello se creó un programa en el lenguaje de programación Python™ (Python, 2020) con la librería *elsapy* que permite interactuar con los datos de publicaciones y citas de todas las revistas académicas relevantes de Elsevier©.

2. Google scholar™, el cual es un motor de búsqueda que permite localizar documentos académicos.

Para la búsqueda con la API de Scopus se buscaron las palabras de los constructos en el título, en el resumen y en las palabras claves con la ecuación de búsqueda:

$$TITLE - ABS - KEY(ROU AND (carbon OR nitrogen) AND PUBYEAR > year) \quad (5)$$

Para la búsqueda en Google scholar™ se aplicaron las ecuaciones de búsqueda 6, 7 y 8 en el intervalo de tiempo de 1999 al 2021 donde *ROU* es el nombre de los ROU.

$$"ROU" + "carbon nitrogen" \quad (6)$$

$$"ripeness" + "ROU" + "carbon nitrogen" \quad (7)$$

$$"ROU" + "C/N ratio" \quad (8)$$

Para los pasos de codificación de estudios y síntesis de resultados se llevó a cabo la revisión de los estudios que resultaron de la búsqueda sistemática, se seleccionaron y se evaluaron para determinar si contestaban la pregunta del planteamiento del problema; si contestaba la pregunta, se incluyó ese estudio, de lo contrario no se incluyó, si había duda, se incluyó para una revisión posterior más exhaustiva. Paralelamente se aplicaron los criterios de inclusión/exclusión mostrados en la Tabla 2.

Tabla 2. Criterio de inclusión/exclusión.

	Criterio de inclusión	Criterio de Exclusión
Población	ROU de interés para este trabajo.	ROU que no sean de interés o frutas enteras.
Idioma	Inglés y español.	Cualquier otro idioma.
Método de prueba	Relación C/N o contenido de carbono y/o nitrógeno de ROU.	Relación C/N de tratamientos o de residuos en general.

b) Determinación de contenido de Carbono (C), nitrógeno (N) fósforo (P) y potasio (K) en ROU a través de análisis de laboratorio

Se seleccionó la fracción no comestible de ocho frutas y verduras más consumidas en México (SIAP 2020): manzana (*Malus domestica*), plátano (*Musa paradisiaca*), zanahoria (*Daucus carota*), limón (*Citrus aurantifolia swingle*), lechuga (*Lactuca sativa*), naranja (*Citrus sinensis*), patata (*Solanum tuberosum*) y tomate (*Lycopersicum esculentum*). Se recolectaron residuos en las tres etapas de descomposición (inicial, media y avanzada). Algunos residuos se refrigeraron a una temperatura entre 1 °C y 3 °C, dejando el resto de los ROU a temperatura ambiente.

La determinación del contenido de C, N, K y P fue en laboratorios del Centro de Investigaciones Biológicas del Noroeste, en la ciudad de La Paz, B.C.S., México. Los métodos y procedimientos que se siguieron se resumen en la Fig. 9.

Para la determinación de la concentración de C de los ROU, las muestras de ROU se calcinaron en una mufla Thermo Scientific modelo 17675 (Bernstead Thermolyne, Dubuque, Iowa, USA) a 60 °C por 5 horas, luego se determinó el contenido de ceniza (% Ash) por diferencia de peso, con lo que se calculó el porcentaje de compuestos volátiles solubles (Eq. 9) y finalmente, se determinó el contenido de carbono (Eq. 10).

$$\% VS = 100 - \% Ash \quad (9)$$

$$\% C = \% VS / 1.8 \quad (10)$$

El contenido de N se estimó a través del método Dumas (AOAC 990.03), para ello, se tomaron 3 g de muestra de ROU calcinada y se colocó en un equipo analizador de proteína/nitrógeno LECO FP-528 (LECO Instrument Corporation, St. Joseph, MI, USA). El N es convertido en N₂ a través de tubos de oxidación/reducción, y el resto de los productos volátiles de la combustión son separados. Por último, un detector mide el gas nitrógeno.

Con el propósito de conocer el contenido de los macronutrientes de los ROU, también se determinó el contenido de potasio y fósforo. El método utilizado para determinar la cantidad de potasio en los ROU fue el de flama de absorción atómica para metales pesados, que consiste en digerir en 6 ml de ácido nítrico y 2 ml de peróxido (EPA 3052), 0.5 g de muestra desecada y molida,

para después analizar el extracto resultante con un espectrofotómetro de absorción atómica GBC Avanta 12209 (GBC-Avanta E, Victoria, Australia).

El extracto resultante de la determinación de K se utilizó para determinar Fósforo usando la prueba de fosfomolibdato de acuerdo con el procedimiento AOAC 931.01, adaptado para microplaca de 96 pozos (microplaca ELISA). Se mezclaron 100 μL del extracto con 20 μL de Molibdato de Amonio en los pozos de la microplaca. Después de dejar reposar 5 minutos la mezcla, se añadieron 20 μL de hidroquinona y 20 μL de sulfito de sodio. Después, se añadieron 40 μL de agua desionizada y se dejó reposar por 30 minutos a temperatura ambiente. Pasados los 30 minutos, se leyó la absorbancia a 650 mm con un espectrofotómetro de microplaca (Termo, Multiskan Spectrum, Vantaa-Finland).

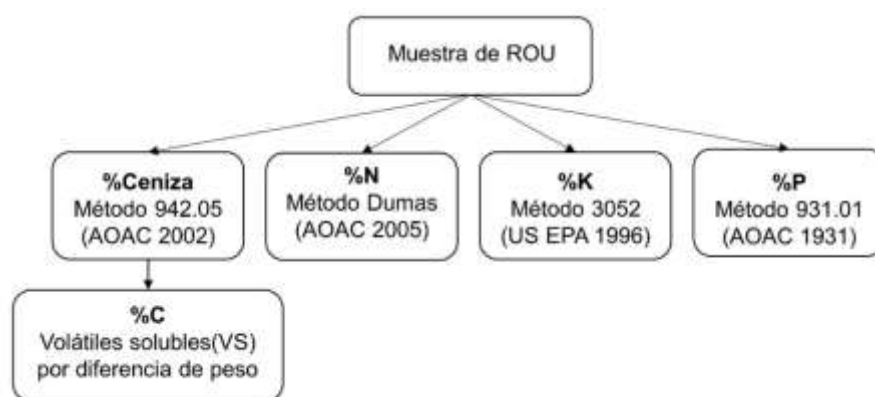


Figura 9. Métodos y procedimientos para la estimación de nutrientes de ROU.

6.1.2 Desarrollo de clasificador automático de ROU

Una vez que se creó la BD se procedió con la clasificación automática de los ROU a través de imágenes que consiste en tres pasos: 1) clasificación del ROU; 2) estimación del peso del ROU; 3) determinación de la relación C/N.

6.1.2.1 Clasificación y detección de ROU

Para clasificar un ROU y determinar su estado de descomposición y su color a través de una CNN, se probaron algunas CNN de código abierto y una de creación propia para elegir la que obtenga el mejor rendimiento en la clasificación de ROU. Las CNN seleccionadas fueron:

1. ROUNet, CNN diseño propio basado en los bloques de la red LeNet-5 (Lecun *et al.*, 1998).

2. MobileNet, de Google (Howard *et al.*, 2017).
3. VGG16 de la universidad de Oxford (Simonyan y Zisserman, 2015).
4. YOLO v5 de Ultralytics (Ultralytics inc, 2023)
5. YOLO v8 de Ultralytics (Ultralytics inc, 2023)

El proceso de aprendizaje de las CNN consistió en tres etapas: preproceso, entrenamiento y prueba (Fig. 10). Las imágenes de cada clase de ROU se dividieron en tres subconjuntos con diferentes proporciones: entrenamiento (70 %), validación (20 %) y prueba (10 %).

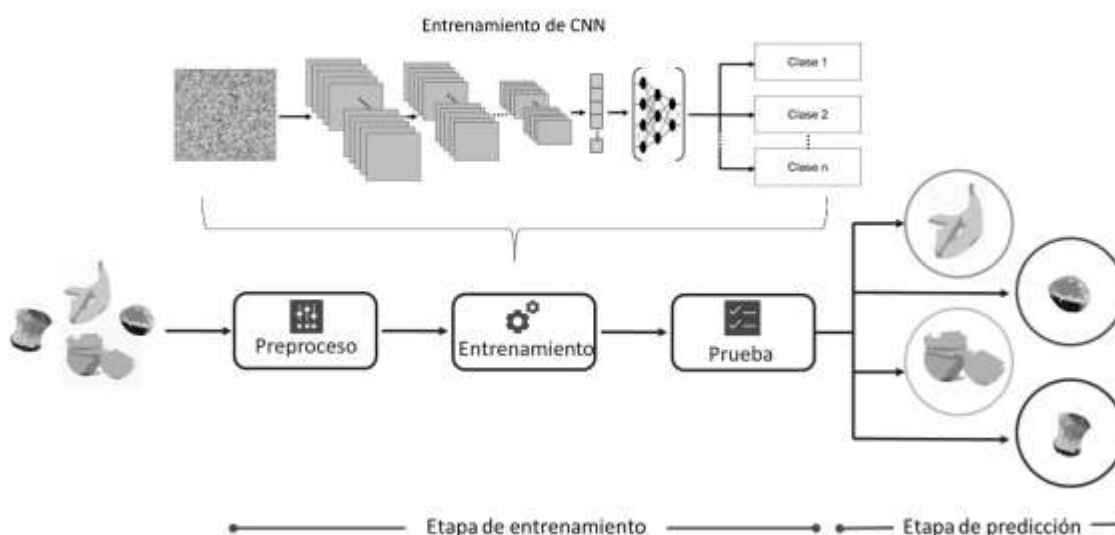


Figura 10. Proceso de aprendizaje de las CNN: preproceso, entrenamiento y prueba (diseño propio).

La etapa de preproceso consistió en la preparación de los datos y se aplicó la técnica de aumento de datos. En la etapa de entrenamiento las CNN aprenden a partir del conjunto de datos de entrenamiento ajustando sus parámetros internos para minimizar el error. Se utilizó la técnica de transferencia de aprendizaje que consiste en usar redes pre-entrenadas de código abierto (Aggarwal, 2018). Las CNN se entrenaron para que aprendan a reconocer las características de los ROU por medio las imágenes de la BD de índices.

En la última etapa se realizaron pruebas a las CNN con las imágenes reservadas para ello. Estas tres etapas (preproceso, entrenamiento y prueba) se llevaron a cabo en el entorno de Google Colaboratory (Google Colab, 2021) en el lenguaje Python™ (Python, 2020). Este entorno permite

programar desde el navegador y acceder a GPU, lo que es adecuado para analizar una gran cantidad de imágenes.

6.1.2.2 Estimación del peso de ROU

Un índice vincula una imagen de un ROU con su color, estado de descomposición, peso y relación C/N. Cada vez que se capturó una imagen de un ROU, se pesó y se registró su peso en gramos, y sus otras características, en la BD de índices.

Los datos del peso se utilizaron para estimar el peso de un nuevo ROU que no forma parte de la BD de índices mediante regresión lineal. Se buscó explicar la relación entre el número de píxeles que conforman el ROU en la imagen y el peso en gramos para cada ROU. El modelo lineal se generó en el lenguaje de programación R (R Core Team, 2020).

Para cada uno de los ROU se aplicó el método de regresión lineal obteniéndose seis modelos diferentes, los cuales explican una relación lineal entre el número de píxeles que conforman la imagen de los ROU y su peso en gramos. La ecuación 11 describe esta relación donde \hat{y} es el valor esperado del peso y x es el número de píxeles.

$$\hat{y} = \alpha + \beta x \quad (11)$$

6.1.2.3 Determinación de la relación C/N de ROU

Una vez que se identifica un ROU en una imagen y se estima su peso, se realiza una consulta directa de la relación C/N del ROU en la BD de índices. En la Fig. 11 se resume la clasificación automática de los ROU.

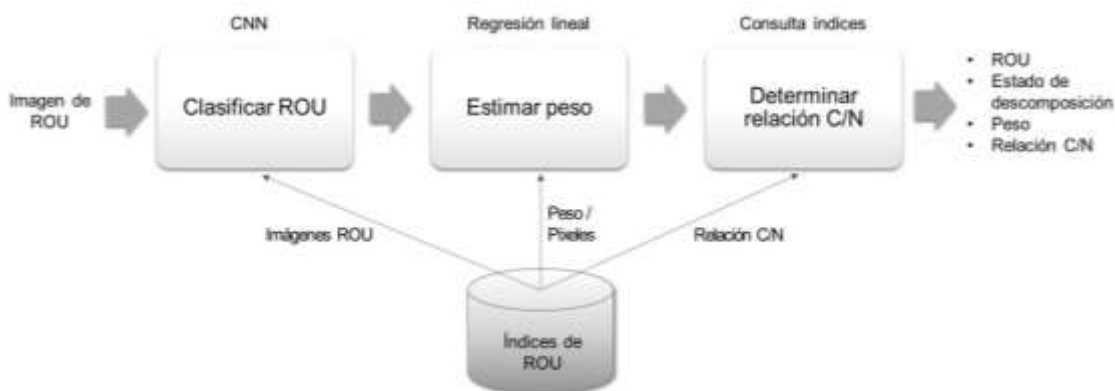


Figura 11. Proceso de clasificación automática de ROU.

6.2 Generación del modelo del proceso de compostaje.

El clasificador automático de ROU desarrollado en el objetivo uno, permite identificar cada ROU y su estado de descomposición, además estima el peso y la relación C/N. Tanto el peso de los residuos como la relación C/N son la entrada al modelo que permitir estimar la calidad de la composta resultante. Para crear este modelo, se llevó a cabo un experimento con el propósito de obtener datos. El experimento consistió en la elaboración de compostas con los ROU seleccionados para este proyecto de investigación y el análisis de calidad de las compostas terminadas. Los resultados de los análisis se compararon con lo establecido por la norma NMX-AA-180-SCFI-2018.

6.2.1 Sitio experimental

6.2.2 Materiales del experimento

Los ROU seleccionados para el experimento fueron centros de manzana y cáscaras de plátano, naranja, limón y papa. Para la obtención de los ROU se realizó una colecta en hogares y en comercios de preparación de jugos y alimentos en la ciudad de La Paz, Baja California Sur, México. Las colectas fueron realizadas durante un mes. En el caso de las obtenidas en hogares la colecta fue diaria y en el caso de los comercios la colecta fue una o dos veces por semana. Esto con el fin de obtener ROU en diferentes etapas de descomposición. Para dar porosidad a la mezcla a compostar se utilizó alfalfa fresca, la cual se molió en partículas de aproximadamente 5-10 cm de longitud.

Para la elaboración de compostas se utilizaron contenedores de plástico reciclado con capacidad de 20 L (Fig. 12). A los contenedor y a sus tapas, se les hicieron orificios de 3 mm con una distancia promedio entre orificios de 6 cm vertical y 1.3 cm horizontal con el fin de asegurar una buena aireación de los ROU. Además, se le hizo un orificio mayor (3-5 cm) en la parte inferior para permitir el paso de los lixiviados.



Figura 12. Contenedor de 20 L con orificios para la elaboración de composta.

6.2.3 Toma de video de ROU

Previo al proceso de compostaje se pesaron los ROU por clase, 15 clases en total (manzana, plátano, limón, naranja y papa en sus tres etapas, inicial, medio y avanzado) y se tomó vídeo de los ROU. Los ROU se colocaron en una banda transportadora y se tomó video con una cámara web Logitech c920 (Fig. 13), en un plano cenital a 30 cm de altura para posteriormente identificarlos a través de los algoritmos CNN. Esta actividad se llevó a cabo un día previo a la elaboración de las compostas. La banda fue elaborada en el taller de maquinado en las instalaciones del CIBNOR.



Figura 13. Banda transportadora para la toma de video de los ROU a compostar.

6.2.4 Diseño experimental

El diseño experimental fue completamente al azar con 3 tratamientos y 4 repeticiones. Las unidades experimentales fueron los contenedores de composta (Fig. 14) y el factor de variación fue la relación C/N inicial de las mezclas a compostar (ROU/alfalfa): (T1) 20, (T2) 30 y (T3) 40. Se llevó a cabo la siguiente distribución en proporciones para cada tratamiento:

- T1:CN20 → 50 % ROU – 50 % alfalfa
- T2:CN30 → 70 % ROU – 30 % alfalfa
- T3:CN40 → 80 % ROU – 20 % alfalfa

Se dio seguimiento a la temperatura, a la humedad y al pH de las unidades experimentales durante tres meses. La lectura de la temperatura de cada unidad experimental se llevó a cabo mediante sensores de temperatura registrándose las temperaturas cada 15 minutos durante las 24 horas con un sensor DS1822 (Maxim Integrated, San José, CA), instalados en cada contenedor equipado con un microcontrolador ESP 32 con LoRa (Microchip Technologies, Chandler, AZ) y un panel solar (Fig. 15). Con los datos recopilados se generó un reporte del estado del proceso al instante y se mostrará su evolución una vez al día.




Figura 14. Distribución de las unidades experimentales. Tratamientos (T) y repeticiones (R).

La humedad se midió por observación directa una vez por semana. Se realizó volteo a las compostas de forma manual de acuerdo con la observación de la transformación de los materiales con el fin de ayudar a la homogenización y aireación del medio de todas las unidades experimentales. Se registró el pH de cada unidad experimental usando tiras reactivas. Las

mediciones se hicieron diariamente los primeros 7 días y posteriormente se registraron una vez por semana.



Figura 15. Sensor de temperatura DS1822 equipado con un microcontrolador y panel solar.

6.2.5 Análisis de calidad de las compostas

Para determinar en qué etapa se encuentra el proceso de compostaje se aplicó la prueba de madurez Solvita® a cada unidad experimental a los dos y tres meses de iniciado el proceso de compostaje. Después de tres meses se realizó un muestreo de cada unidad experimental y se les aplicaron diversos análisis para determinar la calidad de las compostas terminadas.

6.2.5.1 Análisis de madurez prueba Solvita®

La prueba Solvita® (Woods End Laboratories LLC, Augusta, ME, USA) consiste en la medición por colorimetría del Dióxido de Carbono (CO_2) y Amoníaco (NH_3) que una muestra húmeda de composta emite a través de gas, estando en un recipiente cerrado. Para lo cual se colocan unas paletas con geles reactivos para cada uno de los gases a medir en cada recipiente con la muestra de composta, se tapan durante 4 horas en un lugar fresco. Al cabo de este tiempo se realiza la comparación del color de los geles de cada elemento con la escala de colores numerada correspondiente para encontrar con el que mejor coincida. La escala de color de CO_2 consta de 8 colores y NH_3 el consta de 5. Para obtener un valor cuantitativo se colocan una a una las paletas en el medidor seleccionando el gas correspondiente a leer (Fig. 16).

Los resultados de la colorimetría permiten obtener el índice de madurez el cual se calcula usando las tablas de la Fig. 17. Por ejemplo, si el CO_2 resultó 6 y NH_3 resultó 2, entonces el índice de madures es 4. Este índice se utiliza para identificar en la tabla mostrada en la Fig. 18, la etapa en el que se encuentra el proceso de compostaje. Si el índice de madures calculado es 4, entonces

la composta está activa. En cambio, si el índice es 8, el proceso de compostaje está en la etapa final.



Figura 16. Medidor de CO₂ y NH₃, geles reactivos y escala de color para la prueba Solvita®.

		Dióxido de Carbono (CO ₂)								
		1	2	3	4	5	6	7	8	
Amoníaco (NH ₃)	5	Nada	1	2	3	4	5	6	7	8
	4	Bajo	1	2	3	4	5	6	7	8
	3	Medio	1	1	2	3	4	5	6	7
	2	Alto	1	1	1	2	3	4	5	6
	1	Muy	1	1	1	1	1	2	3	4

Figura 17. Índice de madurez de composta para la prueba prueba Solvita®. (Fuente: Woods End Laboratories LLC).

8	Composta inactiva, altamente madura. Posiblemente sobre madura como tierra; no hay limitantes para su uso	COMPOSTA TERMINADA
7	Composta bien madura; curada; pocas limitaciones para su uso.	
6	Composta curada; reducir aeración y mantenimiento. 6 o más se reconoce como madurez adecuada	Curada
5	Composta pasando de la etapa de descomposición activa a la de lista para curar; se reduce el manejo intensivo.	COMPOSTA ACTIVA
4	Composta media o moderadamente en etapa de descomposición activa; requiere manejo continuo	
3	Composta activa; ingredientes frescos; Se necesita vigilancia y manejo intensivo	
2	Composta muy activa y aún en estado de descomposición; alto respiración; necesita volteo y/o aireación intensiva	COMPOSTA INMADURA
1	Composta cruda y fresca; muy alto estado de descomposición; materiales muy olorosos	

Figura 18. Etapa de la composta de acuerdo con el índice de madurez (Fuente: Woods End Laboratories LLC).

6.2.5.2 Análisis edafológicos

A los tres meses del proceso de compostaje y una vez realizada la prueba Solvita®, se dio por terminado el experimento y se procedió a determinar la calidad de las compostas a través de análisis en laboratorios del CIBNOR. Para este fin, se colectaron las compostas, se etiquetaron y se resguardaron en el laboratorio de Edafología. De cada una de las 12 unidades experimentales se tomaron 300 g de composta molida y se prepararon diferentes cantidades para realizar los diferentes análisis.

Se tomaron 200 g de muestra por unidad experimental y en el laboratorio de Edafología se determinaron los siguientes parámetros por triplicado:

- **El pH** por medio de un potenciómetro marca Hanna© modelo HI221 (Hanna Instruments, Inc. Woonsocket, RI, USA). La evaluación de pH se basa en la determinación de la actividad del ion H mediante un electrodo (método AS-02, NOM-021).

- **La conductividad eléctrica (CE)** con el método AS-18 (NOM-021), con un potenciómetro Hanna® modelo HI221 (Hanna Instruments, Inc. Woonsocket, RI, USA), esto es por medición electrolítica a través de una celda de conductividad en extracto de saturación.
- **Materia orgánica (MO)** a través del método Walkley and Black (AS-07, NOM-021), el cual se basa en la oxidación del C orgánico por medio de una disolución de dicromato de potasio y el calor al mezclarse con ácido sulfúrico concentrado. La mezcla se diluye y se agrega ácido fosfórico y el dicromato de potasio residual es valorado con sulfato ferroso. Para obtener el porcentaje de carbono orgánico total (CoT) se aplica la Eq. 12.

$$\%CoT = \frac{\%MO}{1.724} \quad (12)$$

6.2.5.3 Análisis químico proximal

El contenido de nitrógeno de las muestras se determinó en el laboratorio de Análisis Químico Proximal por el método Dumas (AOAC 990.03) el cual consiste en tomar 3 g de muestra calcinada previamente en una mufla *Thermo Scientific* modelo 17675 (Bernstead Thermolyne, Dubuque, Iowa, USA) a 60 °C por 5 horas, se envolvió en papel estaño y se colocó en un equipo analizador de proteína/nitrógeno LECO FP-528 (LECO Instrument Corporation, St. Joseph, MI, USA). El N es convertido en N₂ a través de tubos de oxidación/reducción, el resto de los productos volátiles de la combustión son separados y el N resultante es contabilizado.

6.2.5.4 Metales pesados y micronutrientes

La determinación de algunos metales se realizó en el laboratorio de Espectrofotometría de Absorción Atómica a través del método de medición de metales pesados por absorción atómica en tejido vegetal. Después de secar y moler las muestras de ROU, se tomaron 0.5 g de cada una y se digirieron en 6 ml de ácido nítrico concentrado y 2 ml de peróxido mediante el método EPA 3052 (1996). El extracto resultante se analizó en un espectrofotómetro de absorción atómica GBC Avanta 12209 (GBC-Avanta E, Victoria, Australia). Los elementos que se determinaron en las muestras de composta fueron: Sodio (Na), Calcio (Ca), Potasio (K), Magnesio (Mg), Cobre (Cu), Zinc (Zn), Cadmio (Cd), Níquel (Ni), Plomo (Pb), Mercurio (Hg) y Arsénico (As).

6.2.5.5 Análisis microbiológicos

Para determinar la inocuidad de las compostas de acuerdo con la NOM-AA-180-SCFI-2018 se llevaron a cabo análisis microbiológicos de muestras de las compostas de los tres tratamientos con la siguiente metodología:

- ***Salmonella*** con el procedimiento para la determinación de *Salmonella* en alimentos con modificaciones (NOM-114-SSA1-1994) basado en el análisis de 25 g de la muestra de composta en una proporción de 1:9 de muestra/caldo. Primeramente, se pesaron 25 g de la muestra y se colocaron en una bolsa estéril adicionando 225 ml de caldo lactosado. Posteriormente se colocó la mezcla en un recipiente estéril de boca ancha con tapón de rosca y se dejó reposar por 60 minutos a temperatura ambiente con la tapa bien enroscada. Se ajustó el pH a 7 con hidróxido de sodio y se colocaron los recipientes en una incubadora microbiológica SHEL LAB SMI12 (Sheldon Manufacturing, Inc., Cornelius, OR, USA) por 24 a 35° C. Después de ese tiempo se procedió a estriar en agar entérico Hektoen y se incubaron las placas por 48 h a 35° C. Pasadas las 48 horas, se examinaron las placas para identificar si había presencia de colonias típicas de *Salmonella* (colonias verdes o azulverdes con o sin centro negro o colonias completamente negras).
- ***Coliformes totales, C. fecales y Escherichia coli (presuntiva)*** por el procedimiento para la determinación de Coliformes totales, Coliformes fecales y *Escherichia coli* (presuntiva) en superficies de contacto por el método del hisopo y producto terminado basado en el método del número más probable (NMP) en tubos múltiples de análisis de agua (NMX-AA-042-SCFI-2015). Primero se tomó 1 g de muestra por unidad experimental y se utilizaron diluciones de 10 ml, 1.0 ml y 0.1 ml en medio caldo lactosado con 3 tubos por cada disolución y se incubaron en una incubadora microbiológica SHEL LAB S14 (Sheldon Manufacturing, Inc., Cornelius, OR, USA) por 24 h a 35° C. Pasado este tiempo se examinaron los tubos de cultivo y se registraron como reacción positiva aquellos que mostraron turbidez y formación de gas en el interior del tubo invertido (tubo de Durham). Se continuó con la incubación por 24 h a 35° C de aquellos tubos que no presentaron estos cambios y se examinaron nuevamente. A los tubos que presentaron formación de gas y turbidez se les realizaron pruebas confirmativas por lo que se incubaron los tubos con

caldo lactosa bilis verde brillante y nuevamente encubados a 35° C por otras 24 h y se examinó la producción de gas. Se calculó NMP de organismos coliformes, organismos coliformes termotolerantes y *E. coli* a partir del número de tubos positivos en los resultados confirmativos.

6.2.5.6 Análisis de fitotoxicidad

Se realizó una prueba en el laboratorio de Fisiotecnia Vegetal del CIBNOR para determinar el índice de germinación (IG) y conocer el nivel de fototoxicidad de las compostas. Para esta prueba se preparó un té de composta. Primero se tomaron 25 g de muestra de los tres tratamientos (T1:CN20, T2:CN30 y T2:CN40) y se colocaron en una gasa formando una bolsa. Las bolsas se sumergieron en recipientes con 100 ml agua destilada y se dejaron reposar por dos horas. Trascurridas las dos horas se filtró la infusión obtenida. En 12 cajas Petri se colocó papel filtro en la base, se etiquetaron y se colocaron 10 semillas de rábano (*Raphanus sativus* var. Champion) en cada caja. Posteriormente se agregaron 4 ml de agua destilada a tres de las cajas (grupo control). Así mismo, se agregó 4 ml de la infusión de composta en tres cajas por tratamiento (repeticiones). Finalmente, se colocaron las cajas en una cámara de germinación a de 25°C. La contabilización de semillas germinadas se hizo a los 3 y 10 días. El IG se calculó por tratamiento con la Eq. 13 (donde *PG* es porcentaje de germinación).

$$IG = \frac{(PG * 100)}{PG \text{ control}} \quad (13)$$

$$PG = \left[\frac{\text{semillas germinadas}}{\text{semillas sembradas}} \right] x 100$$

6.2.6 Análisis estadístico

Se llevó a cabo el análisis de varianza (ANOVA de una vía) entre tratamientos con respecto al pH, CE, MO y relación C/N. Se aplicó la prueba de Tukey en caso de observar diferencia entre los tratamientos con niveles de significancia de $p < 0.05$. El análisis estadístico se realizó utilizando el lenguaje de programación R (R Core Team, 2020).

6.2.7 Modelo del proceso de compostaje

Se propusieron dos modelos del proceso de compostaje, uno basado en la temperatura durante el proceso de compostaje y otro tomando como entrada los insumos a compostar y sus características cualitativas y cuantitativas.

6.2.7.1 Modelo de la temperatura del proceso de compostaje

Durante el proceso de compostaje se llevó el seguimiento de la temperatura. Los datos recolectados se usaron para desarrollar un modelo difuso, esto es, basado en LD. Este modelo estima el estatus del proceso de compostaje tomando como entrada la temperatura y el tiempo del proceso. Para crear el modelo difuso se utilizó el lenguaje de programación R (R Core Team, 2020) y el paquete *sets* (Meyer et al. 2023).

El modelo difuso utilizó el dato de la temperatura y de los días transcurridos del proceso de compostaje para determinar cuál es el estatus de la composta: "inmadura", "activa" o "madura". Para definir el estatus se tomó como referencia la clasificación de las etapas de la composta de la prueba Solvita®: cruda, activa y terminada.

Se definieron las variables lingüísticas del sistema difuso. La variable lingüística "Estatus" de la composta ("inmadura", "activa" o "madura"), se determinó en función de las variables "Temperatura" y "Fase". Para la variable "Temperatura" se definieron tres etiquetas: "baja", "media" y "alta" la cual describe la temperatura leída por los sensores en un momento determinado. Para la variable "Fase" se definieron cuatro etiquetas lingüísticas basadas en las etapas del proceso de compostaje: "mesófila", "termófila", "enfriamiento", "maduración" y se establecen tomando en cuenta los días transcurridos del proceso de compostaje (Fig. 19). Para Los intervalos de valores de cada etiqueta se establecieron con base a en la evolución de la temperatura en el transcurso de los tres meses del proceso de compostaje del experimento.




Figura 19. Variables lingüísticas Fase y Temperatura con sus respectivas etiquetas lingüísticas del modelo difuso del proceso de compostaje (Creación propia).

Una vez definidas las variables, se definieron las reglas difusas del modelo. Las reglas difusas son los vínculos entre las variables "Temperatura" y "Fase" con la variable "Estatus" que es la variable de respuesta del modelo. Por último, se creó el modelo con la instrucción: *fuzzy_system(variables, rules)* con las variables y las reglas definidas para el proceso de compostaje.

6.2.7.2 Modelo del proceso de compostaje

Para desarrollar el modelo del proceso de compostaje se entrenó una RNA que recibe como entrada las características cualitativas y cuantitativas de los ROU identificadas por el clasificador automático (objetivo 1). El modelo de RNA se describe en la Eq. 14 y se esquematiza en la Fig. 20.

$$CN = w_0 + w_1x_1 + w_2x_1 + \dots + w_nx_n \quad (14)$$

donde:

- CN es la relación C/N estimada.
- w_i son los coeficientes, llamados pesos, que el modelo debe encontrar durante la etapa de entrenamiento.
- x_i son características cuantitativas de los ROU (peso, relación C/N) y cualitativas (etapa de descomposición).

El modelo de RNA tiene como entradas los datos de la relación C/N, la etapa de descomposición y el peso de los ROU. El modelo se entrena para poder estimar la relación C/N final. La etapa de entrenamiento del modelo consiste encontrar los coeficientes w_i que multiplican cada una de las conexiones de la RNA que relacionan las entradas con la salida. Los datos de entrada son datos obtenidos con el experimento, y los datos de salida son datos de los parámetros obtenidos en los análisis de laboratorio.




Figura 20. Modelo de RNA para el proceso de compostaje (elaboración propia).

Para crear el modelo de RNA se utilizó el lenguaje de programación R (R Core Team, 2020) y el paquete *neuralnet* (Fritsch et al. 2019) y se llevaron a cabo las tres etapas presentadas en la Fig. 10:

1. **Preproceso.** Se creó un conjunto de datos con las variables de entrada relación C/N inicial, peso, etapa descomposición de los ROU y como variable de salida la relación C/N final. Este conjunto de datos se dividió en dos: datos de entrenamiento y datos de prueba. Los datos son los resultados del experimento y los análisis de laboratorio de las compostas terminadas.
2. **Entrenamiento.** Se propuso una arquitectura de RNA (Número de capas intermedias y de neuronas en las capas intermedias. También se definieron el número de épocas (ciclos de entrenamiento).
3. **Prueba.** Se hicieron pruebas con los datos del experimento reservados para ello. Esta etapa permitió hacer ajustes al modelo.

7. RESULTADOS

7.1 Creación de la BD de índices de ROU

Se construyó una BD con las características cuantitativas (peso, relación C/N) y cualitativas (color y estado de descomposición) de los ROU seleccionados. Para la creación de la BD de los ROU se realizaron las actividades presentadas en la Fig. 7 de la metodología; a continuación, se presentan los resultados por actividad.

7.1.1 Selección y recolección de ROU

De acuerdo con el análisis de selección presentado en la metodología se seleccionaron ocho frutas y vegetales de mayor consumo en México: plátano (*Musa paradisiaca*), manzana (*Malus domestica*), naranja (*Citrus sinensis*), limón (*Citrus aurantifolia*), papa (*Solanum tuberosum*), lechuga (*Lactuca Sativa*), tomate (*Lycopersicon esculentum*) y zanahoria (*Daucus carota*). En la Tabla 3 se muestra el consumo anual per capita, el tipo residuo resultante de la parte no consumida y la fracción no comestible expresada en porcentaje.

Tabla 3. Fracción no comestible de frutas y hortalizas frescas de mayor consumo en México.

Nombre	Consumo anual per cápita (kg)	Residuo	Fracción
Limón	18.6	Cáscara, pulpa, semillas	34%
Manzana	8.2	Cáscara, pulpa, centro	12%
Naranja	36.9	Cáscara, pulpa, semillas	30%
Papa	15.3	Cáscara	16%
Plátano	15.9	Cáscara	35%
Zanahoria	6*	Cáscara	19%
Lechuga	12.7	Centro, hojas	8%
Tomate	13.4	Cáscara, centro, semillas	20%

*A nivel mundial (Fuente: USDA, 2010).

7.1.2 Determinación de color y estado de descomposición de los ROU

En el ejercicio de seguimiento de la evolución de ROU mediante la captura de imágenes se observó que en las primeras horas el residuo de manzana y la cáscara de zanahoria empezaron a cambiar a color café y la cáscara de zanahoria cambió su tamaño. A las de 24 horas se hicieron

más evidente los cambios en las cáscaras de plátano y papa, por último, en las cáscaras de limón y de naranja (Fig. 21). Este ejercicio permitió hacer una clasificación inicial de los ROU en tres etapas de descomposición, para con ello proponer la escala de colores para cada ROU y sus etapas de descomposición (Tabla 4).

Tabla 4. Determinación del color y estado de descomposición por ROU.

Etapas	Limón	Manzana	Naranja	Papa	Plátano	Zanahoria
Inicial	Verde- Amarillo	Blanco- Amarillo	Naranja	Amarillo- café	Amarillo	Naranja
Media	Verde- Amarillo- Café	Blanco- Amarillo- Café	Naranja- Café	Café	Amarillo- Café	Naranja- Café
Avanzada	Café	Café	Café	Café	Café- Negro	Café- Negro

Para robustecer la clasificación propuesta, se aplicó la Eq. (4) para contabilizar los píxeles negros en la imagen del ROU después de pasar la imagen original a tono de grises. En la Fig. 22 se observa que conforme avanza la etapa de descomposición va aumentando el número de píxeles negros en el histograma del canal de luminosidad del espacio de color CIELAB. Se establecieron umbrales de las etapas de descomposición en el canal de luminosidad para contar los píxeles oscuros, estableciendo si el número de píxeles es menor a 30 para la etapa inicial, entre 30 y 50 para la etapa intermedia y mayor a 50 para la etapa avanzada. Finalmente, se generó el histograma de la imagen en el canal L y se aplicaron los umbrales para determinar las etapas de descomposición. El algoritmo de la etapa de descomposición permitió categorizar un conjunto de imágenes de ROU en 15 clases, con precisiones de 52 a 55 %.

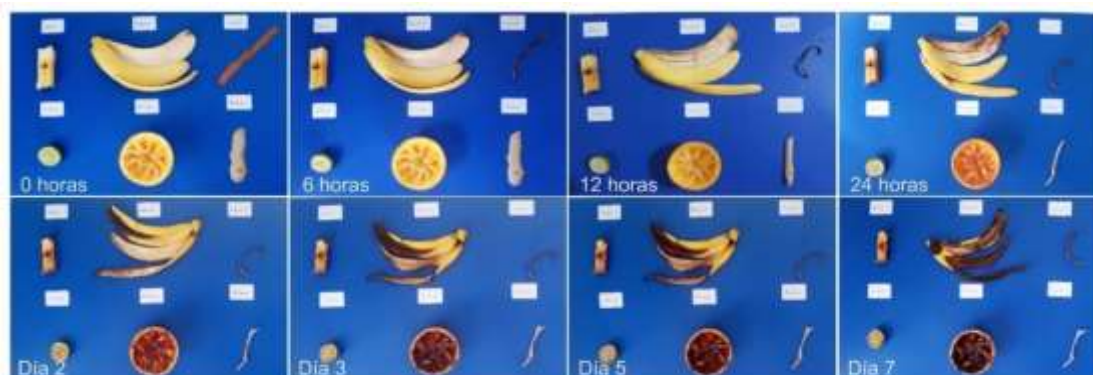


Figura 21. Seguimiento fotográfico de los cambios en las características de algunos ROU.




Figura 22. Identificación de la etapa de descomposición de la cáscara de plátano. a) Etapa inicial, b) etapa media y c) etapa avanzada.

7.1.3 Captura de imágenes y determinación del peso de ROU

El conjunto de imágenes de ROU quedó conformado por imágenes de cinco de los residuos seleccionados (Fig. 23). El conjunto quedó dividido en clases por tipo de ROU y etapa de descomposición. Se generaron 9,000 imágenes con 600 imágenes por clase (Tabla 5). Las imágenes del repositorio tienen una dimensión de 960 píxeles de altura por 720 píxeles de ancho en formato jpg (*Joint Photographic Experts Group*). Cada imagen fue etiquetada con el nombre del residuo y una numeración consecutiva. Después de tomar la foto del ROU se pesó y se agregó el dato del peso a la BD de índices.



Figura 23. Muestra de imágenes capturadas de los ROU de manzana, plátano, limón, naranja y papa.

Tabla 5. Definición de clases para cada tipo de ROU/etapa de descomposición; en todos los casos la cantidad de imágenes capturadas por clase de ROU fue 600.

Clases (ROU/etapa de descomposición)	
1	Manzana inicial
2	Manzana media
3	Manzana avanzada
4	Plátano inicial
5	Plátano media
6	Plátano avanzada
7	Limón inicial
8	Limón media
9	Limón avanzada
10	Naranja inicial
11	Naranja media
12	Naranja avanzada
13	Papa inicial
14	Papa media
15	Papa avanzada

7.1.4 Determinación de la relación C/N en ROU

a) Revisión sistemática

Como resultado de la búsqueda sistemática de la relación C/N de los ROU de interés para este estudio, se obtuvieron 2,988 artículos, de los cuales 971 fueron documentos completos y 2,017 fueron resúmenes. Después de una revisión exhaustiva, de aplicar los criterios de exclusión, de eliminar los documentos repetidos y de comprobar si respondían o no a la pregunta formulada se obtuvieron finalmente 20 artículos con los datos de la relación C/N de los cinco ROU. Los datos por cada ROU se promediaron para obtener la relación C/N promedio por tipo de ROU, los cuales se muestran en la Tabla 6. Los artículos revisados no indicaron la etapa de descomposición de los residuos.

Tabla 6. Relación C/N de cada ROU como resultado de la búsqueda sistemática.

ROU	Relación C/N	Fuente	Relación C/N promedio
Naranja	47.78	(Fernandez <i>et al.</i> , 2014)	48.67
	34.00	(Idris <i>et al.</i> , 2019)	
	33.83	(Pathak <i>et al.</i> , 2017)	
	49.92	(Pinzón-Bedoya y Cardona, 2008)	
	60.06	(Tejeda <i>et al.</i> , 2014)	
	60.03	(Tejada-Tovar <i>et al.</i> , 2018)	
	54.81	(Tejada-Tovar <i>et al.</i> , 2020)	
	48.89	(Jiménez-Castro, 2020)	
Limón	31.76	(Pathak <i>et al.</i> , 2017)	28.38
	25	(Thomas <i>et al.</i> , 2019)	
Papa	14.40	(Omar <i>et al.</i> , 2020)	14.94
	10.78	(Liang y McDonald, 2014)	
	16.6	(Gautam <i>et al.</i> , 2015)	
	18	(Rynk <i>et al.</i> , 1992)	
Plátano	31	(Sial <i>et al.</i> , 2019)	34.34
	28.00	(Gautam <i>et al.</i> , 2015)	
	30.95	(Pathak <i>et al.</i> , 2017)	
	35.59	(Rojas <i>et al.</i> , 2019)	
	39.82	(Rojas-González <i>et al.</i> , 2018)	
Manzana	48	(Rynk <i>et al.</i> , 1992)	48

b) Análisis de laboratorio para la determinación de contenido de Carbono (C), nitrógeno (N) fósforo (P) y potasio (K) de los ROU.

Los resultados revelaron que el C fue el nutriente con mayor concentración en todos los ROU (Fig. 24). La manzana tuvo el mayor contenido de C, seguida de la naranja y el limón. El mayor contenido de N fue para la lechuga, seguida de la papa y el tomate, mientras que la manzana presentó la menor concentración (Fig. 25). El nutriente encontrado en menor concentración fue P (Fig. 26), siendo la lechuga el tipo de ROU que presentó los valores más altos para dicho macronutriente, mientras que la cáscara de naranja reflejó concentraciones bajas e incluso no se encontró en la cáscara de naranja en la etapa inicial. Las cáscaras de plátano reflejaron la mayor concentración de K, seguidos por la zanahoria, la lechuga, la papa y el tomate (Fig. 27). Los ROU con menores concentraciones de K fueron los cítricos y las manzanas y el residuo con mayor contenido fue la cáscara de plátano, seguida de la lechuga. En la Tabla 7 se muestran los resultados del contenido de C, N, P, and K de ROU en las etapas de descomposición.

El análisis estadístico mostró que la concentración de C fue significativamente diferente ($p < 0,05$) en las tres etapas de descomposición, excepto en las etapas media y avanzada en los desechos de manzana, en la etapa inicial y media en la cáscara de limón y en las etapas inicial y avanzada de la cáscara de plátano. No hubo diferencia significativa ($p < 0.05$) en el contenido de N en las etapas media y avanzada de la cáscara de naranja. Por otro lado, la cáscara de papa y tomate mostraron un aumento significativo en el contenido de N a medida que avanzaban las etapas de descomposición.

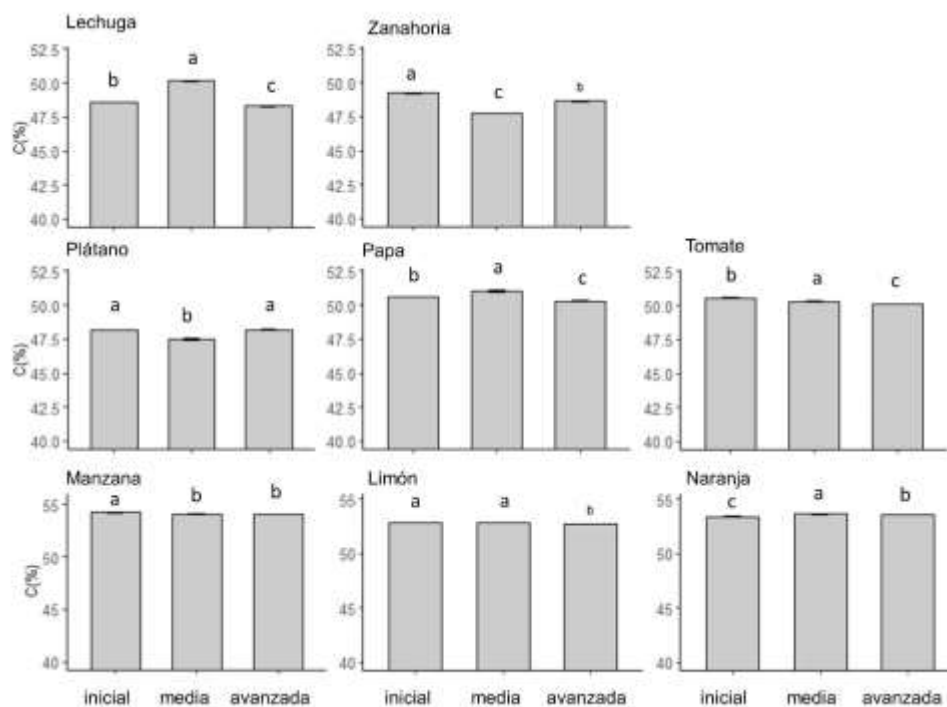


Figura 24. Variación de C en las tres etapas de descomposición. Las barras representan la desviación estándar (\pm SD) de las medias. Las etapas de descomposición con una misma letra no son estadísticamente diferentes según la prueba de Tukey en $p < 0.05$ ($n = 3$).

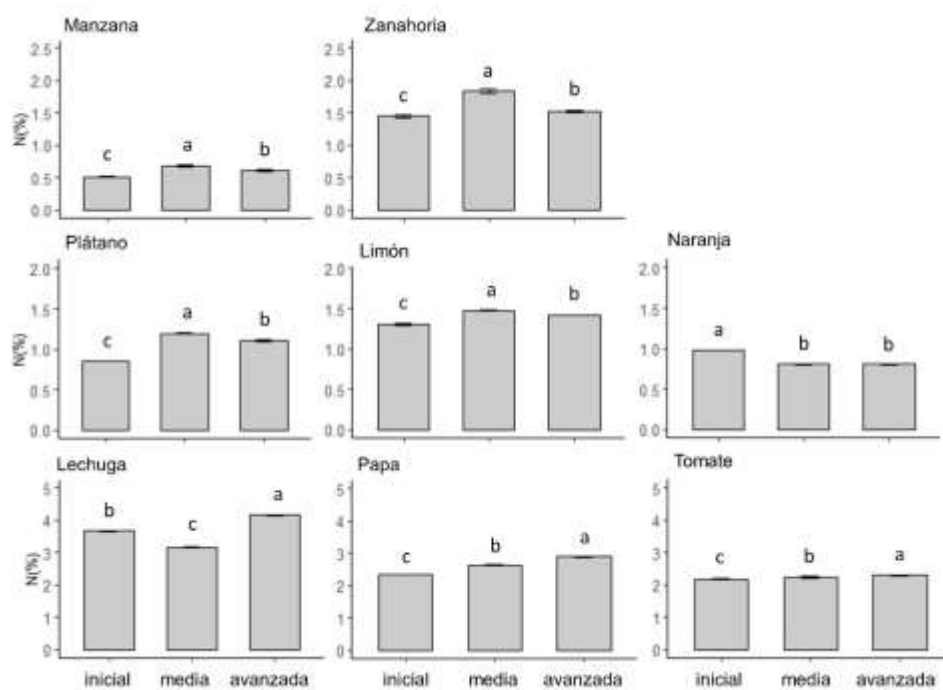


Figura 25. Valores medios (\pm SD) en N en las tres etapas de descomposición. Las barras con la misma letra no son estadísticamente diferentes según la prueba de Tukey en $p < 0.05$ ($n = 3$).

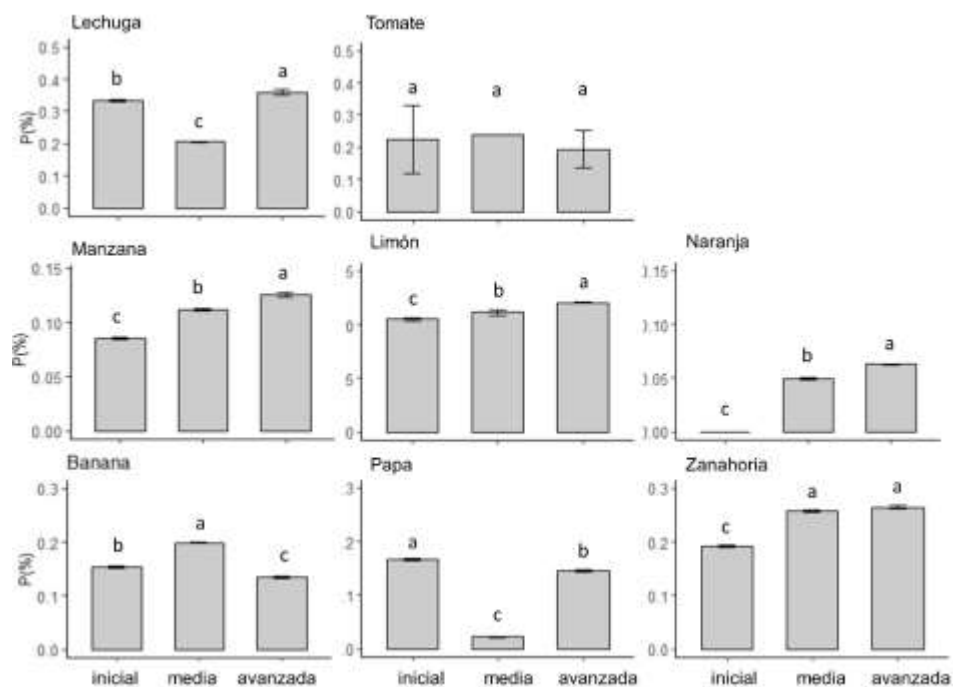


Figura 26. Contenido medio de P (\pm SD) en las tres etapas de descomposición de ROU. Las mismas letras no son estadísticamente diferentes según la prueba de Tukey en $p < 0.05$ ($n = 3$).

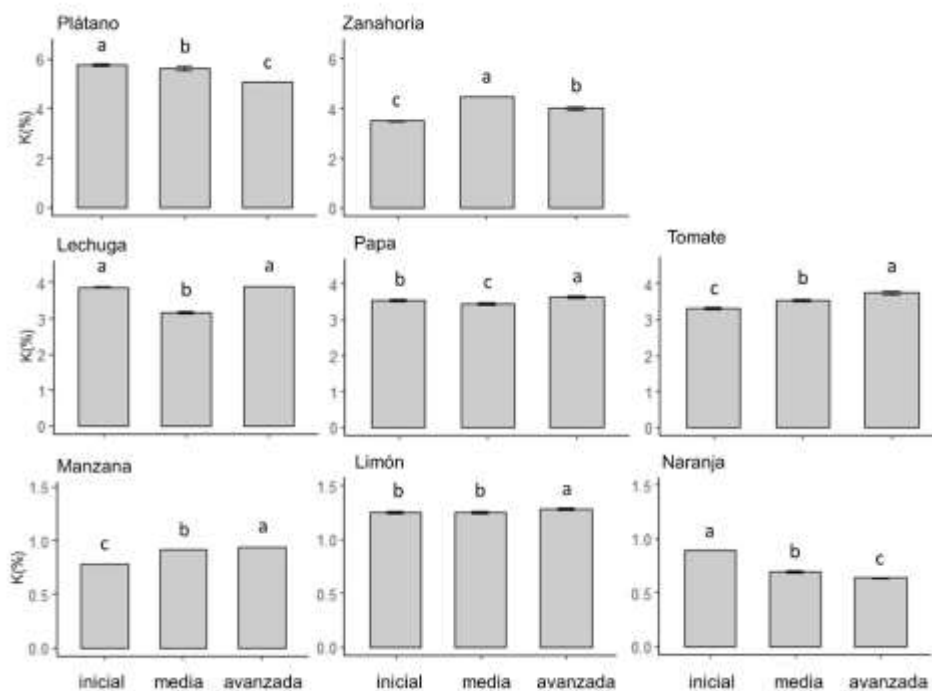


Figura 27. Valores medios de K (\pm SD) en las tres etapas de descomposición de ROU. Las mismas letras no son estadísticamente diferentes según la prueba de Tukey en $p < 0.05$ ($n = 3$).

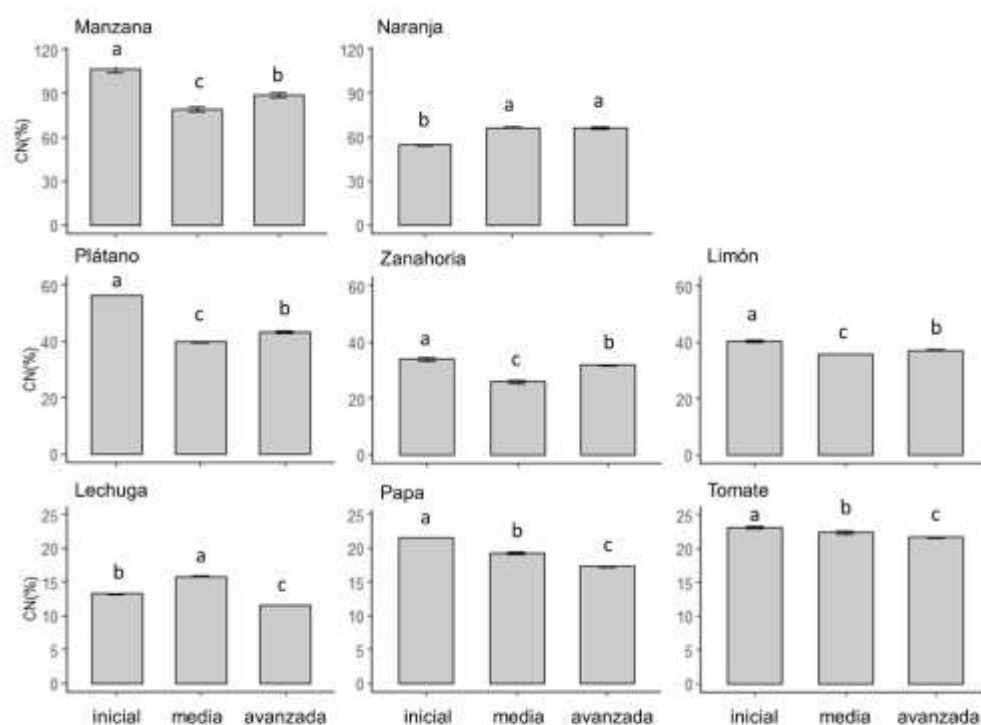
Tabla 7. Contenido de C, N, P, and K de ROU en las etapas de descomposición.

ROU	Etapas	C (%)	N (%)	P (%)	K (%)
Manzana	Initial	54.19±0.05	0.51±0.01	0.09±0.01	0.78±0.00
	Middle	54.06±0.06	0.69±0.01	0.11±0.01	0.91±0.00
	Advanced	54.02±0.05	0.61±0.01	0.13±0.02	0.94±0.00
Plátano	Initial	48.17±0.03	0.85±0.00	0.15±0.02	5.74±0.04
	Middle	47.49±0.04	1.19±0.01	0.20±0.02	5.62±0.07
	Advanced	48.20±0.07	1.11±0.01	0.14±0.02	5.06±0.02
Zanahoria	Initial	49.24±0.03	1.45±0.03	0.19±0.02	3.49±0.01
	Middle	47.76±0.01	1.84±0.04	0.26±0.02	4.45±0.00
	Advanced	48.63±0.03	1.53±0.01	0.26±0.03	3.99±0.08
Limón	Initial	52.87±0.02	1.31±0.01	0.10±0.02	1.25±0.01
	Middle	52.84±0.02	1.48±0.01	0.11±0.02	1.25±0.01
	Advanced	52.72±0.02	1.42±0.01	0.12±0.01	1.28±0.01
Lechuga	Initial	48.58±0.02	3.67±0.01	0.33±0.04	3.86±0.02
	Middle	50.15±0.02	3.17±0.02	0.21±0.02	4.07±0.04
	Advanced	48.30±0.02	4.16±0.01	0.36±0.09	3.90±0.00
Naranja	Initial	53.41±0.02	0.98±0.00	0.00±0.00	0.89±0.00
	Middle	53.64±0.03	0.81±0.01	0.05±0.01	0.70±0.01
	Advanced	53.57±0.02	0.81±0.01	0.06±0.01	0.64±0.01
Papa	Initial	50.60±0.02	2.35±0.01	0.17±0.02	3.54±0.03
	Middle	51.01±0.06	2.64±0.02	0.02±0.00	3.44±0.02
	Advanced	50.31±0.05	2.90±0.01	0.14±0.02	3.64±0.03
Tomate	Initial	50.55±0.01	2.18±0.01	0.22±1.06	3.35±0.03
	Middle	50.30±0.03	2.25±0.03	0.24±0.01	3.53±0.04
	Advanced	50.09±0.03	2.31±0.01	0.19±0.58	3.75±0.05

Los restos de manzana presentaron la relación C/N mayor, mientras que los restos de lechuga presentaron la relación C/N menor. Los resultados sugieren diferencias estadísticamente significativas en la relación C/N en todas las etapas de descomposición (Tabla 8), excepto en la etapa media y avanzadas en la cáscara de naranja. Los resultados de la prueba de Tukey muestran diferencias estadísticamente significativas ($p < 0.05$) en cada comparación pareada (Fig. 28).

Tabla 8. Relación C/N de ROU en las tres etapas de descomposición.

ROU	Inicial	Media	Avanzada	Promedio
Manzana	106.09±2.41	78.75±1.70	88.68±1.77	91.17
Plátano	56.45±0.02	39.79±0.20	43.43±0.38	46.56
Zanahoria	33.97±0.63	25.92±0.49	31.86±0.25	30.58
Limón	40.46±0.34	35.79±0.13	37.21±0.16	37.82
Lechuga	13.25±0.04	15.82±0.08	11.62±0.02	13.56
Naranja	54.50±0.11	66.28±0.53	66.30±0.71	62.36
Papa	21.56±0.06	19.30±0.11	17.33±0.07	19.40
Tomate	23.15±0.12	22.36±0.25	21.71±0.10	22.41

**Figura 28.** Contenidos de la relación C/N (\pm SD) determinados para las tres etapas de descomposición. Las mismas letras no son estadísticamente significativamente diferentes según la prueba de Tukey en $p < 0.05$ ($n = 3$).

7.2 Desarrollo del clasificador automático de ROU

El propósito de la actividad de clasificación automática de ROU a través de CNN, fue la elección de la red que obtuvo el mejor rendimiento en la clasificación de ROU.

7.2.1 Clasificación y detección de ROU

7.2.1.1 Preprocesamiento de imágenes

Como resultado del conjunto de las imágenes capturadas de los ROU se obtuvieron tres conjuntos, uno de entrenamiento con el 70 % de las imágenes, el conjunto de validación con el 20% y el conjunto de prueba con el 10% restante.

7.2.1.2 Entrenamiento de las CNN

El resultado de las pruebas para las CNN ROUNet, MobileNet y VGG16 para determinar los parámetros se muestra en la Tabla 9.

Tabla 9. Parámetros para la configuración de las CNN ROUNet, MobileNet y VGG16.

Parámetro	Valor
Función de pérdida	Categorical_crossentropy
Ancho, alto y canales de imagen	224, 224, 3
Número de clases	14
Tamaño de lote de imágenes	32
Número de épocas	100
Desactivación de neuronas (<i>dropout</i>)	0.5
Razón de aprendizaje	0.0001
Función de optimización	Adam

7.2.1.3 Prueba de las CNN

Se realizaron pruebas de rendimiento de las tres CNN para la clasificación de cada clase de ROU en sus tres estados de descomposición. La Tabla 10 muestra los resultados en las etapas de entrenamiento, validación y prueba. La Fig. 29 muestra las gráficas de precisión resultantes de la etapa de entrenamiento y validación. La precisión (*accuracy*) es una métrica que indica qué tan

bien clasifica la red y se calcula como la proporción de muestras clasificadas correctamente frente al total de las muestras del conjunto de datos (Santos-Romero *et al.*, 2022). Por ejemplo, si una CNN clasifica correctamente 90 de cada 100 imágenes, su precisión sería del 90%.

La Fig. 30 presenta las matrices de confusión normalizadas (%) obtenidas en la etapa de prueba de las tres CNN, donde se observa una mejor clasificación para los modelos MobileNet y UOWNet. El modelo completado para residuo de manzana logró una precisión media del 85.62%. Se generan matrices de confusión para los datos de prueba y la cáscara de plátano reflejó una precisión promedio del 86.64%. La cáscara de limón presentó la menor precisión promedio (67.11%) con los porcentajes más bajos en la clasificación de la prueba. Los modelos presentaron precisiones del 78.76% y 80.72% para cáscaras de naranja y papa, respectivamente.

Los resultados también mostraron que los modelos MobileNet y ROUNet tienen mayor precisión que el modelo VGG16. En el caso de manzana, limón y naranja, VGG16 tiende a sobreajustarse.

Tabla 10. Rendimiento de las CNN en la clasificación de ROU.

ROU	MobileNet	VGG16	ROUNet	Promedio
Manzana	85.24%	82.10%	89.52%	85.62%
Plátano	90.67%	82.48%	86.76%	86.64%
Limón	68.57%	59.52%	73.23%	67.11%
Naranja	80.86%	72.95%	82.48%	78.76%
Papa	82.66%	73.04%	86.47%	80.72%
Promedio	81.60%	74.02%	83.69%	

La Fig. 31 muestra el rendimiento de los modelos considerando las estadísticas Kappa (κ) que van de 0 a 1 (Cohen, 1960). Esta métrica mide la confiabilidad entre la verdad p_o (para datos etiquetados que son los valores de cada ROU) y los resultados de los modelos CNN que se esperan p_e , expresado por:

$$\kappa = \frac{p_o - p_e}{1 - p_e} \quad (14)$$

Los valores Kappa están asociados con una etiqueta de concordancia entre la clasificación calculada (resultados del modelo) y la clasificación esperada (por predicción aleatoria) para los modelos CNN: muy malo (<0.00), malo ($0.00-0.20$), regular ($0.21-0.40$), moderada ($0.41-0.60$), buena ($0.61-0.80$) y muy buena ($0.81-1.00$). Según la estadística Kappa, los modelos ROUNet presentaron una buena concordancia, mientras que los modelos MobileNet y VGG16 presentaron una concordancia moderada para la clase limón.

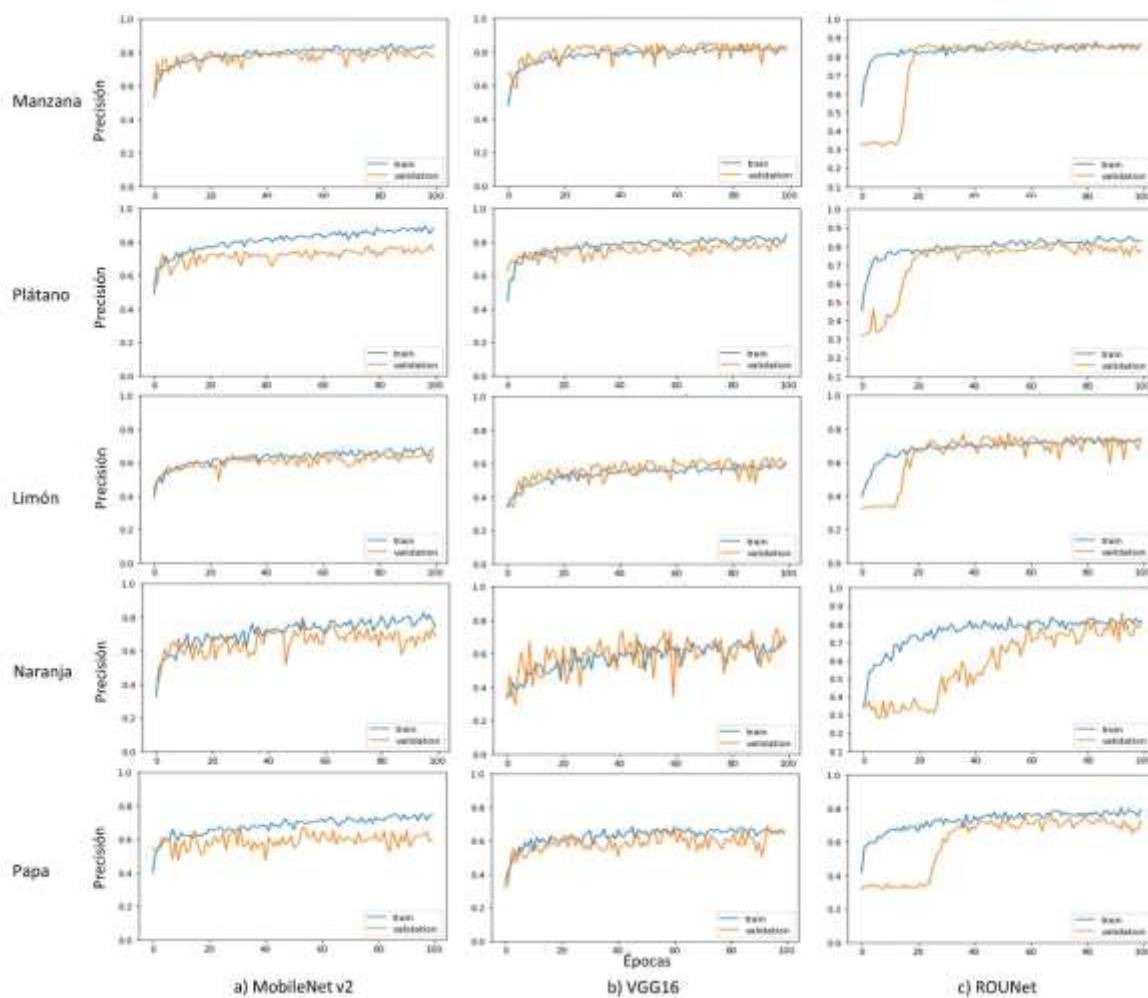


Figura 29. Gráficas de precisión de las CNN a) ROUNet, b) MobileNet V2 y c) VGG16 para la clasificación de los ROU manzana, plátano, limón, naranja y papa. La línea azul corresponde a los datos de entrenamiento y la línea naranja a los datos de validación. Las gráficas muestran cómo la precisión mejora conforme aumenta el número de épocas (o ciclos) de entrenamiento.




Figura 30. Matriz de confusión normalizada de la prueba de las redes a) ROUNet, b) MobileNet V2 y c) VGG16. Los recuadros diagonales representan el número de aciertos para los que la etiqueta predicha es igual a la verdadera, mientras que los elementos fuera de la diagonal son los que el clasificador ha etiquetado erróneamente. Entre más intenso el color azul más aciertos en la predicción.

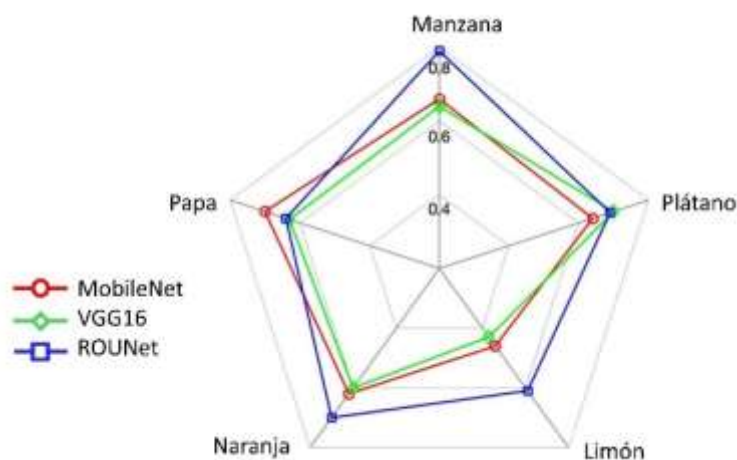


Figura 31. Comparación de los modelos CNN en la clasificación de ROU. Las líneas representan los modelos de CNN y los vértices de la gráfica representan las clases de ROU. Las puntuaciones bajas se sitúan en el centro de la gráfica, mientras que los valores altos se encuentran en los vértices.

7.2.1.4 Preprocesamiento de imágenes para los modelos CNN YOLO

Del conjunto de las imágenes de los ROU el 90% de las se utilizaron para el entrenamiento de los modelos YOLO y el 10% para la validación. A cada imagen se le asignó una etiqueta, la cual consiste en un archivo de texto que contiene la clase a la que pertenece el ROU en esa imagen y su posición exacta en ella.

7.2.1.5 Entrenamiento y prueba de las CNN YOLO

Las versiones seleccionadas de los modelos YOLO fueron la 5 y la 8 en sus tamaños *medium* y *large* (Yolov5m, Yolov5l, Yolov8m y Yolov8l). La selección fue por el tamaño de los modelos (Tabla 11) y el rendimiento en las etapas de entrenamiento para cada modelo con 100 y 200 épocas. La Tabla 12 muestra las métricas Precisión Media Promedio o *Mean Average Precision* (mAp) la cual es una métrica utilizada para evaluar la precisión de los modelos de detección de objetos donde mAP 0.5 indica que el modelo detecto correctamente en un 50 % y mAP 0.5:0.95 evalúa la precisión entre el 50 % y el 90 % (Diwan *et al.*, 2023). La Fig. 32 muestra la matriz de confusión normalizada de los algoritmos YOLO.

Tabla 11. Parámetros (en Millones) de los modelos YOLO.

Modelo	Parámetros (M)
Yolov5m	21.2
Yolov5l	46.5
Yolov8m	25.9
Yolov8l	43.7

Tabla 12. Rendimiento los modelos YOLOv5l y YOLOv8l.

Modelo	Épocas	mAP^{val} 0.5	mAP^{val} 0.5:0.95
YOLOv5l	100	0.88	0.77
	200	0.89	0.76
YOLOv8l	100	0.89	0.86
	200	0.88	0.86

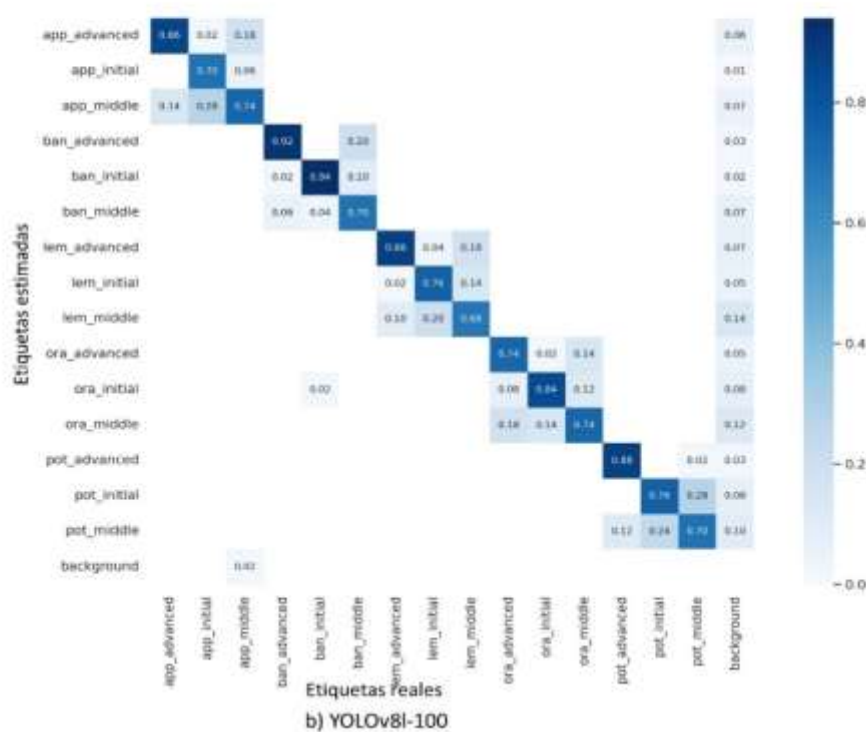



Figura 32. Matriz de confusión normalizada de las pruebas de a) YOLOv5l y b) YOLOv8l con 100 épocas. Entre más intenso aparece el color azul en la diagonal, ello significa más aciertos en la predicción; los elementos fuera de la diagonal son los que se han clasificado erróneamente.

7.2.2 Estimación del peso de ROU

La Fig. 33 muestra las gráficas de dispersión y la aplicación de la Eq. (11) para cada uno de los cinco ROU. En el caso del residuo de la manzana, el valor de probabilidad fue significativo ($F_{1,995} = 9148$, $p < 0.01$) y el modelo explica el 90 % de la variación de los datos ($R^2 = 0.90$). Para el caso de la cáscara de plátano $F_{1,972} = 2511$ y con 70 % de la variación de los datos ($R^2 = 0.72$). La cáscara de limón y la cáscara de naranja mostraron similitudes con el 60 % de la variación de los datos: limón con $F_{1,1079} = 1629$ y $R^2 = 0.60$ y naranja con $F_{1,1209} = 2028$ con $R^2 = 0.62$. Por último, la cáscara de papa obtuvo un $F_{1,1313} = 18430$ y $R^2 = 0.93$, esto es, obtuvo un 90% de la variación de los datos.

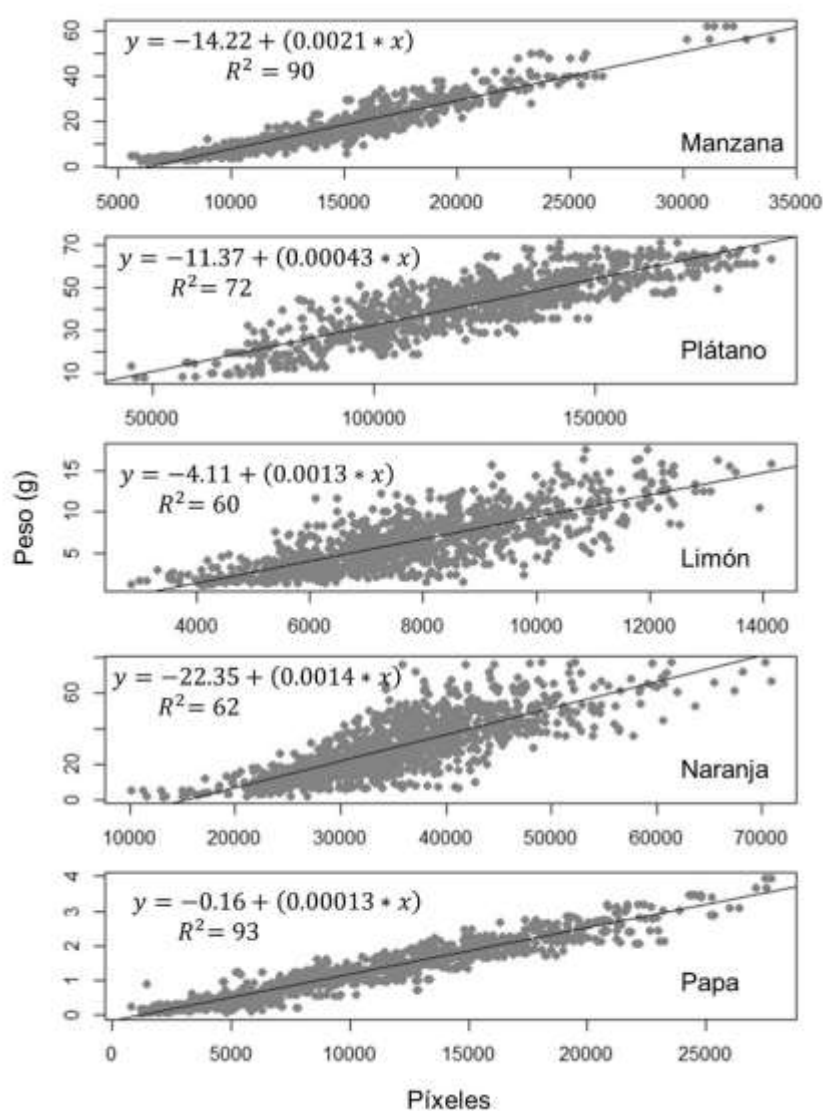


Figura 33. Relación lineal entre peso y número de píxeles para cada uno de los ROU.

7.3 Generación de datos para el modelo a través del experimento de compostaje

Cada tratamiento contenía una mezcla de ROU en diferentes etapas de descomposición para obtener una relación C/N lo más próxima a lo establecido (Tabla 13). En la Tabla 14 se muestra el contenido de ROU por etapa de descomposición. Las proporciones para cada tratamiento del experimento quedaron de la siguiente manera:

- T1:CN20 → 3.05 kg ROU – 3.6 kg alfalfa (proporción aproximada 50 % - 50 %).
- T2:CN30 → 8.60 kg ROU – 3.6 kg alfalfa (proporción aproximada 70 % - 30 %).
- T3:CN40 → 14.80 kg ROU – 3.6 kg alfalfa (proporción aproximada 80 % - 20 %).

Tabla 13. Materiales por tratamiento (kg)

ROU	T1:CN20	T2:CN30	T3:CN40
Manzana	0.1	0.2	1.8
Plátano	0.4	3.2	2.45
Limón	1.2	3.6	6.9
Naranja	0.2	0.8	2.5
Papa	1.15	0.8	1.15
Alfalfa	0.9	0.9	0.9
Relación C/N	22.24	31.06	40.75

Tabla 14. Contenido de ROU (kg) por etapa de descomposición

Etapa	T1:CN20	T2:CN30	T3:CN40
Inicial	0.50	0.20	1.20
Media	2.25	1.75	10.80
Avanzada	0.30	0.20	2.80

7.3.1 Prueba Solvita®

De acuerdo con los resultados obtenidos de la prueba Solvita®, se observaron compostas activas a los dos meses de haberse establecido; en la tabla 15 se muestran los resultados de la medición de NH₃ y CO₂ que, de acuerdo con la escala colorimétrica de la prueba, arrojó un índice de madurez que se traduce en una etapa del proceso de compostaje como ACTIVA. A los tres meses se volvió a aplicar la prueba a todas las unidades experimentales y los resultados mostraron que las compostas estaban en etapa terminada (Tabla 16).

Tabla 15. Etapa del proceso de compostaje del tratamiento T3: CN40 a los dos meses.

	NH ₃	CO ₂	Índice de madurez	Etapa del proceso de compostaje
T3R1	4	5	5	Activa
T3R2	4	4	4	Activa
T3R3	4	5	5	Activa
T3R4	4	5	5	Activa

Tabla 16. Etapa del proceso de compostaje para los tres tratamientos a los tres meses.

Unidad experimental	NH ₃	CO ₂	Índice de madurez	Etapa del proceso de compostaje
T1:CN20				
T1R1	4	8	7	Terminada
T1R2	5	6	6	Activa
T1R3	5	7	7	Terminada
T1R4	5	7	7	Terminada
T2:CN30				
T2R1	4	7	7	Terminada
T2R2	5	7	7	Terminada
T2R3	5	7	8	Terminada
T2R4	4	7	7	Terminada
T2:CN40				
T3R1	5	8	8	Terminada
T3R2	4	7	7	Terminada
T3R3	4	6	6	Activa
T3R4	4	7	7	Terminada

7.3.2 Análisis de laboratorio de la calidad de la composta

7.3.2.1 Materia orgánica (MO), pH y conductividad eléctrica (CE)

Los resultados del análisis estadístico de MO mostraron que no hay diferencia significativa entre los tratamientos T1:CN20 y T2:CN30. De igual manera los resultados mostraron que no existe diferencia estadísticamente significativa entre los tratamientos T2:CN30 y T3:CN40 en la medición de pH. En cambio, los resultados del análisis estadístico de CE mostraron que no hay diferencia

significativa entre los tres tratamientos (Fig. 34). El tratamiento T3:CN40 mostró el mayor valor en las mediciones de CE y pH, pero el más bajo en contenido de MO (Tabla 17).




Figura 34. Contenido de MO, CE y pH (\pm SD) para los tratamientos CN20, CN30 y CN40. Mismas letras indican que no son significativamente diferentes según la prueba de Tukey en $p < 0.05$ ($n=4$).

Tabla 17. Valores promedio ($n=4$) del contenido de MO, CE y pH por tratamiento.

	CN20	CN30	CN40
MO (%)	58.78	58.72	54.09
CE (mS/cm)	23.96	23.25	25.92
pH	8.96	9.57	9.68

7.3.2.2 Carbono, Nitrógeno y relación C/N

En el contenido de C, obtenido al aplicar la Eq. 12, el análisis estadístico no encontró diferencias significativas entre los tratamientos T1:CN20 y T2:CN30. Al igual que con el contenido de N. Respecto a la relación C/N, se encontró que no hay diferencia significativa entre los tratamientos T1:CN20 y T2:CN30 y entre los tratamientos T2:CN30 y T3:CN40 (Fig. 35). El tratamiento T3:CN40 presentó el porcentaje más bajo contenido de C y N, pero el más alto en la relación C/N (Tabla 18).




Figura 35. Contenido de N (\pm SD), C (\pm SD) y relación C/N (\pm SD) para los tratamientos CN20, CN30 y CN40. Mismas letras indican que no son estadísticamente diferentes según la prueba de Tukey con $p = 0.05$ ($n = 4$).

Tabla 18. Valores promedio (n=4) del contenido de N y relación C/N de cada tratamiento.

	CN20	CN30	CN40
C (%)	34.10	34.06	31.38
N (%)	3.48	3.28	2.74
Relación C/N	9.8	10.4	11.5

7.3.2.3 Metales y micronutrientes

Los resultados de la caracterización del contenido de sales solubles se muestran en la Tabla 19. Los datos obtenidos de la concentración de metales pesados muestran que no se rebasan los límites permitidos señalados en la norma NMX-AA-180-SCFI-2018 (Tabla 20).

Tabla 19. Contenido de sales solubles en compostas (mS/cm) de cada tratamiento con n=3.

	CN20	CN30	CN40
Na	17.11	15.80	15.31
Ca	90.11	88.33	88.36
K	66.43	80.80	95.75
Mg	22.08	21.36	19.36

Tabla 20. Contenido de metales pesados en compostas (mg/kg) por tratamiento con n=3.

	CN20	CN30	CN40	NMX-AA-180-SCFI-2018 (máximo permitido)
Cu	20.21	18.60	18.92	70
Ni	15.46	16.45	15.34	25
Pb	9.43	9.17	9.80	45
Zn	50.59	45.17	47.91	200
Hg	0.04	0.05	0.05	0.4
As	0.20	0.19	0.16	0.2

7.3.2.4 Diagnóstico microbiológico

Los resultados del análisis microbiológico se muestran en la Tabla 21, presentando ausencia de *Salmonella* y en el caso de *E. coli* y coliformes fecales no se rebasaron los límites permisibles.

Tabla 21. Resultado de análisis microbiológicos.

Parámetro	Resultado
Salmonella	Ausencia
Escherichia coli (NMP/g)	No rebasa los límites permisibles
Coliformes fecales (NMP/g)	No rebasa los límites permisibles

7.3.2.5 Fitotoxicidad

Los resultados de la prueba de germinación para el día 3 mostraron, un IG del 69 %, 31 % y 38 % en los tratamientos T1:CN20, T2:CN30 y T3:CN40, respectivamente. Sin embargo, al día 10 se obtuvo para el T1 un IG del 95 %, para T2 un 63 % y para el T3 un 47 % (Tabla 22).

Tabla 22. Índice de germinación para los tres tratamientos a los 3 y 10 días.

Tratamiento	R1	R2	R3	Total	Promedio	% IG	Fitotoxicidad
Día 3							
Control	5	6	5	16	53	100	No existe
T1:CN20	6	3	2	11	37	69	Moderada
T2:CN30	1	5	4	10	33	63	Moderada
T3:CN40	2	1	2	5	17	31	Severa
Día 10							
Control	6	7	6	19	63	100	No existe
T1:CN20	7	6	5	18	60	95	No existe
T2:CN30	3	5	4	12	40	63	Moderada
T3:CN40	3	3	3	9	30	47	Severa

7.3.3 Resumen de resultados

Los resultados de los análisis se resumen en la Tabla 23 para cada uno de los tratamientos. La característica cualitativa del color se presenta en la Fig. 36.

**Figura 36.** Comparativo del color de las compostas terminadas por tratamiento.

Tabla 23. Comparación de parámetros obtenidos en el experimento y los indicados en la norma.

Parámetro	CN20	CN30	CN40	NMX-AA-180-SCFI-2018	Referencias
pH	8.96	9.57	9.68	6.7-8.5	6.7-9 Rich y Bharti, 2015
CE (mS/cm)	23.96	23.25	25.92	0.5-12	19.6 Tazeh <i>et al</i> , 201
MO (% MS)	58.78	58.72	54.09	≥20	≥25 Rivas, 2015
C orgánico total (%)	34.10	34.06	31.38	Mínimo 10	28.6-41.2 Khater, 2015
N total (% MS)	3.48	3.28	2.74	1-3	0.99-2.01 Benito, 2006
Relación C/N	9.81	10.38	11.46	15-25	Cercano a 10 Moreno, 2018
Fitotoxicidad (% IG)	95	63	47	≥ 80	≥ 80 Luo, 2018
Color	Café claro	Café oscuro medio	Café oscuro	Marrón o pardo oscuro. Similar al café o chocolate oscuro	Café oscuro – Negro Nieto-Garibay et al. 2021
Olor	Yerba	Yerba leve	Tierra mojada	Agradable a tierra húmeda de bosque (monte)	Libre de malos olores Nieto-Garibay et al. 2021

7.3.4 Evolución de la temperatura durante el proceso de compostaje

Las temperaturas de los tratamientos CN20 y CN30 mostraron curvas similares pero diferentes a la evolución de la temperatura del tratamiento CN40 (Fig. 37).

Se observó que las temperaturas comenzaron a aumentar rápidamente después de iniciado el proceso de compostaje en los tres tratamientos. Una vez alcanzados los 45 °C, inicia la etapa termófila, donde el tratamiento CN20 alcanzó su máximo valor (51 °C) a los 3 días, el tratamiento CN30 tuvo un máximo de 56 °C a los 5 días y el tratamiento CN40 alcanzó los 49 °C a los 7 días. La etapa de enfriamiento comenzó cuando las temperaturas comenzaron a disminuir y al superar los 45 °C se dio paso a la fase de enfriamiento, a los días 7, 9 y 10 para CN20, CN30 y CN40, respectivamente. El día 14 se llevó a cabo volteo de los materiales de las unidades experimentales y se observó un aumento en las temperaturas, pero ya no se alcanzaron los máximos observados en la etapa termófila. Al final de la etapa de enfriamiento y durante la etapa de maduración, las

fluctuaciones de temperatura coincidieron con los cambios de temperatura ambiental y esto se mantuvo constante hasta el final del experimento.

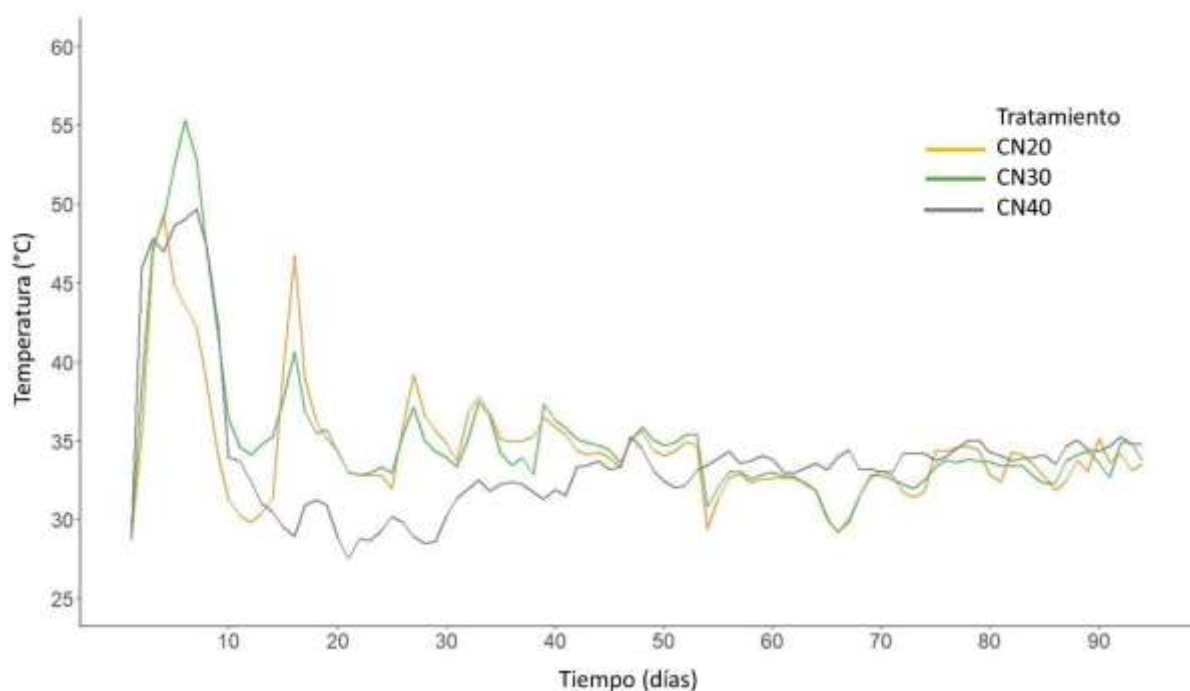


Figura 37. Evolución de las temperaturas de los tres tratamientos durante el proceso de compostaje.

7.4 Modelo del proceso de compostaje

Se propusieron dos modelos del proceso de compostaje, uno de RNA que toma como entradas las características cualitativas y cuantitativas de los ROU y estima la relación C/N. El segundo se basó en los datos de la temperatura que se recolectaron durante el proceso de compostaje mediante sensores. Para crear el segundo modelo se utilizó lógica difusa.

7.4.1 Modelo del proceso de compostaje basado en RNA

En la Fig. 38 se presenta la arquitectura de los modelos obtenidos con dos y tres entradas con sus respectivas gráficas de variables relevantes. La configuración de los modelos, el error resultante del entrenamiento y la variable más relevante se muestran en la Tabla 24. Las variables relevantes son el resultado de aplicar la función *olden* (Olden *et al.* 2004). Los parámetros que variaron en el entrenamiento de cada modelo fueron el número de capas ocultas (*hidden*) en la red y el

número de neuronas en cada capa. El valor del umbral (*threshold*) se fijó en 0.01, el número de épocas (*rep*) en 50, la función de activación (*act.fct.*) se fijó en *logistic*.

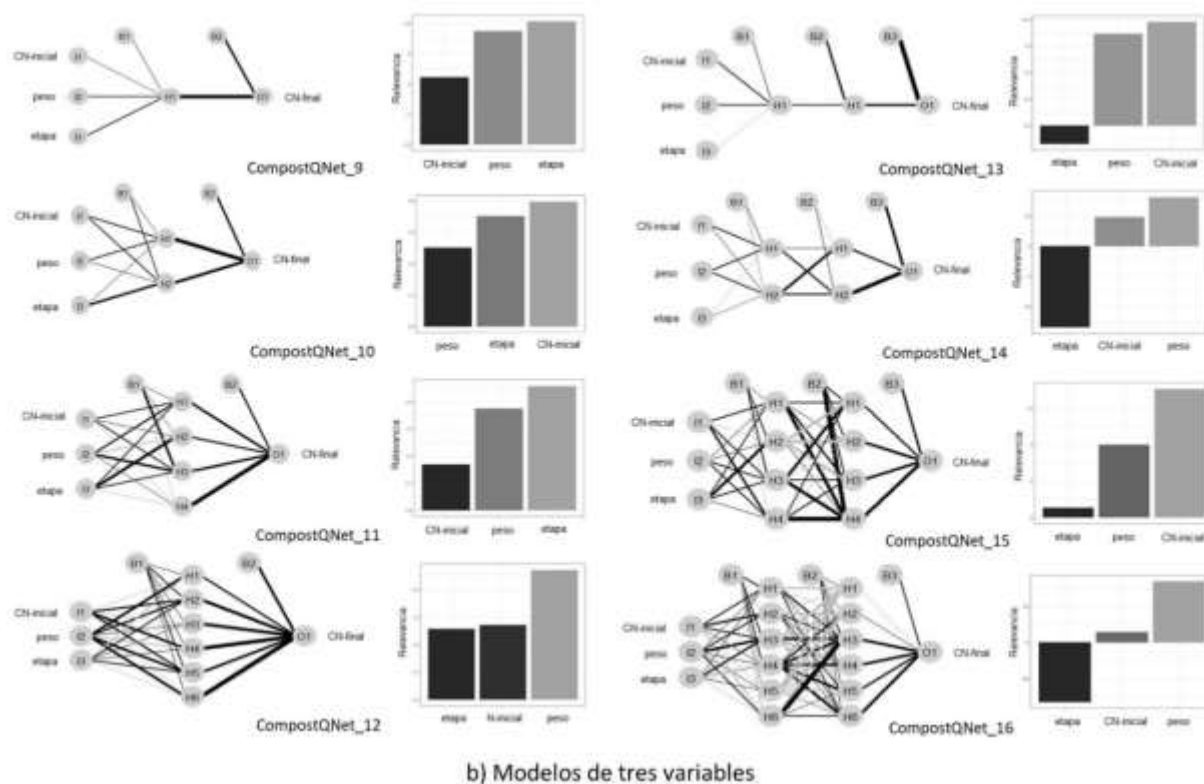
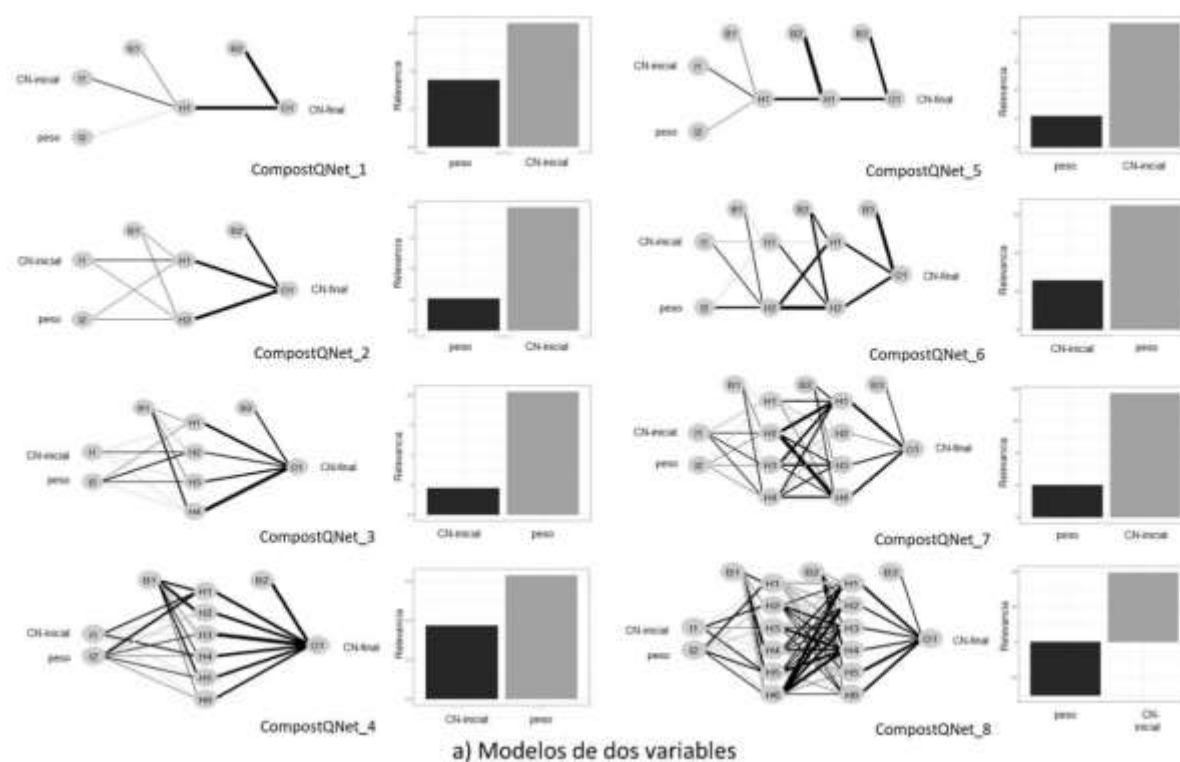


Figura 38. Arquitectura de los modelos con dos y tres variables como entradas: a) *peso, CN_inicial* y b) *peso, CN_inicial* y *etapa*.

Tabla 24. Resultado del entrenamiento de los modelos propuestos.

Modelo	Capas ocultas	Neuronas (por capa)	Error	Variable más relevante
CompostQNet_1	1	1	0.72438	CN_inicial
CompostQNet_2	1	2	0.001443	CN_inicial
CompostQNet_3	1	4	7.00E-06	peso
CompostQNet_4	1	6	0	peso
CompostQNet_5	2	1	1.20E-05	CN_inicial
CompostQNet_6	2	2	6.00E-06	peso
CompostQNet_7	2	4	5.00E-06	CN_inicial
CompostQNet_8	2	6	0	CN_inicial
CompostQNet_9	1	1	6.78E-04	etapa
CompostQNet_10	1	2	1.10E-05	etapa
CompostQNet_11	1	4	0.00E+00	etapa
CompostQNet_12	1	6	0	peso
CompostQNet_13	2	1	8.00E-06	CN_inicial
CompostQNet_14	2	2	1.00E-06	etapa
CompostQNet_15	2	4	0	CN_inicial
CompostQNet_16	2	6	0	etapa

7.4.2 Modelo difuso del proceso de compostaje

El modelo difuso desarrollado (Fig. 39) estima el estatus del proceso de compostaje tomando como entrada la temperatura y el tiempo (medido en días) en el que se encuentra el proceso. Las variables lingüísticas de entrada que se definieron fueron "temperatura" y "fase". La variable "estatus" es la variable de respuesta del modelo. Las reglas definidas fueron 15 las cuales se presentan en la Fig. 40. El modelo genera mensajes escritos para indicar el estatus de la composta como "La composta está inmadura", "La composta está activa" o "La composta está madura".

A la variable lingüística Fase del modelo difuso propuesto se le dio inicialmente 90 días. El seguimiento de temperaturas durante el experimento mostró que la fase de maduración es la que tiene la mayor duración iniciando alrededor del día 20, por lo que se realizó un ajuste a los días para esta variable, aumentando de 90 a 180 días para un tiempo de total de 6 meses para el proceso de compostaje (Fig. 41).

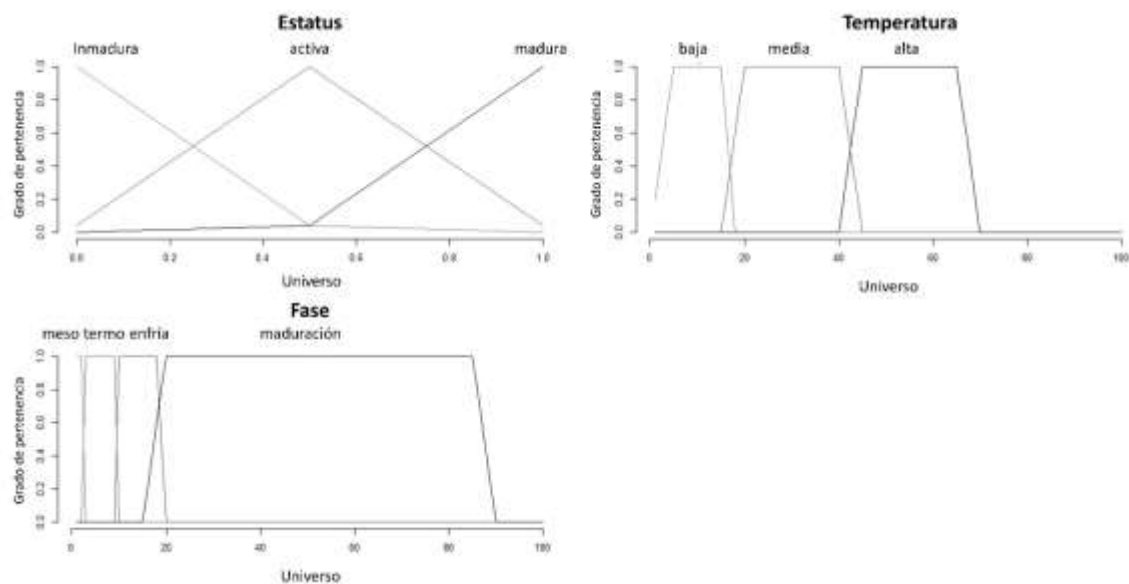


Figura 39. Variables Estatus, Temperatura y Fase con sus respectivas etiquetas lingüísticas.

```

rules <- set(
  fuzzy_rule(temperature %is% high && phase %is% meso,status %is% active),
  fuzzy_rule(temperature %is% high && phase %is% ther,status %is% active),
  fuzzy_rule(temperature %is% high && phase %is% cool,status %is% active),
  fuzzy_rule(temperature %is% high && phase %is% matu,status %is% active),
  fuzzy_rule(temperature %is% high && phase %is% end, status %is% active),

  fuzzy_rule(temperature %is% med && phase %is% meso,status %is% raw),
  fuzzy_rule(temperature %is% med && phase %is% ther,status %is% raw),
  fuzzy_rule(temperature %is% med && phase %is% cool,status %is% active),
  fuzzy_rule(temperature %is% med && phase %is% matu,status %is% active),
  fuzzy_rule(temperature %is% med && phase %is% end,status %is% finish),

  fuzzy_rule(temperature %is% low && phase %is% meso,status %is% raw),
  fuzzy_rule(temperature %is% low && phase %is% ther,status %is% raw),
  fuzzy_rule(temperature %is% low && phase %is% cool,status %is% raw),
  fuzzy_rule(temperature %is% low && phase %is% matu,status %is% active),
  fuzzy_rule(temperature %is% low && phase %is% end, status %is% finish)
)

```

Figura 40. Reglas del modelo difuso del proceso de compostaje.




Figura 41. Ajuste a la variable Fase a 200 días.

En Fig. 42 se describe la integración de los modelos obtenidos del proceso de compostaje de ROU. Primero, las imágenes de ROU entran al clasificador ROUNet, el cual identifica los ROU y la etapa de descomposición. Posterior a ello se determina el peso y la relación C/N del total de los ROU. Estos tres datos (etapa, peso y relación C/N) son la entrada al modelo CompostQNet, modelo basado en RNA, que estima la relación C/N final de la composta. Si la relación C/N no es la adecuada se ajustan los valores hasta encontrar los adecuados para el proceso de compostaje. Una vez iniciado el proceso de compostaje el modelo difuso, CompostTraker, lleva un seguimiento de la evolución de la temperatura indicando el grado de madurez de la composta.




Figura 42. Diagrama de la integración de los modelos del proceso de compostaje de ROU (elaboración propia).

8. DISCUSIÓN

8.1 Creación de la BD de índices de ROU

8.1.1 Selección y recolección de ROU

Los residuos de los frutos y hortalizas seleccionados en esta investigación son adecuados para ser tratados por el proceso de compostaje, como lo señalan algunos autores (Colón *et al.*, 2010; Li *et al.*, 2013; Choy *et al.*, 2015). Si bien existen otros frutos, hortalizas y vegetales que se consumen comúnmente en México como el aguacate y el mango, los resultados obtenidos en la búsqueda para la selección de ROU para este estudio encontró que el residuo de estos frutos lo conforman semillas de gran tamaño las cuales tardan más tiempo en descomponerse, como lo mencionan González-Fernández y colaboradores (2013) y Wadhwa y Bakshi (2013).

8.1.2 Determinación de la relación C/N en ROU

8.1.2.1 Revisión sistemática

Los resultados de la búsqueda sistemática mostraron que hay escasez de estudios que realicen el análisis de los cambios que sufren las características de los ROU a través del tiempo. Estudios como los publicados por Idris y colaboradores (2019); Gautam, Pareek, y Sharma (2015), presentan una relación C/N de residuos de algunas frutas y hortalizas en estado fresco y seco. Richardson y colaboradores (2011) reportaron en su trabajo comparaciones de peso, firmeza, color y producción de etileno endógeno en Kiwis (*actinidia chinensis*) como características importantes en diferentes etapas durante el desarrollo desde la flor abierta hasta la madurez e inicio de la senescencia; sin embargo, a diferencia del presente estudio no hace una comparación en el contenido de C y N en ellas.

8.1.2.2 Análisis de laboratorio

Los ROU utilizados en este estudio son restos de frutas y verduras, como cáscaras, semillas o parte de ellas que siguen el proceso de maduración y senescencia que ocurre comúnmente en las frutas (Kubo, 2015), procesos que se hacen evidente al cortarse, partirse o romperse, donde liberan ciertas enzimas que reaccionan en contacto con el oxígeno, provocando oxidación y aparición de manchas cafés (Nguyen *et al.*, 2003). Lo anterior se reflejó en los resultados del seguimiento de

la evolución de ROU mediante la captura de imágenes (Fig. 21); los resultados mostraron que a medida que avanza el tiempo hay una pérdida de agua iniciando el marchitamiento, el oscurecimiento, la pérdida de peso y textura, por lo tanto, la aceleración de la senescencia, como mencionaron Lufu et al. (2020).

En cuanto a la disminución en el contenido de C en la etapa media de descomposición de manzanas, plátanos y tomates encontrada en este estudio, se infiere que podría deberse a que estos frutos son climatéricos, es decir, continúan madurando después de ser cosechados y tienen un patrón vinculado a la actividad respiratoria y de la producción de etileno (hormona vegetal gaseosa) como lo menciona Kubo (2015). De acuerdo con Richardson y colaboradores (2011) hay una degradación de los carbohidratos a medida que maduran y utilizan parte de su contenido de C para formar compuestos como azúcares y almidones lo que contribuye al ablandamiento de la fruta. Los resultados del presente estudio coinciden con evidencia de ello en el ablandamiento de los residuos y en la aparición de manchas cafés (que aparecen, según los resultados, en la etapa media de descomposición). El etileno además influye en el oscurecimiento de la fruta de acuerdo con lo indicado por Jung y Choi (2020). En los residuos de limón y naranja se observó un patrón diferente, esto puede deberse a que los cítricos son frutos no climatéricos, como menciona Trainotti y colaboradores (2007), estos frutos no maduran después de la cosecha y la respiración disminuye sin producción de etileno. Por otro lado, los residuos en etapa avanzada con alto contenido de carbono tienen baja densidad y bajo contenido de humedad, y de acuerdo con Guo y colaboradores (2012) esta característica los hace adecuados para su uso como agente de carga durante el compostaje.

Los resultados mostraron que la papa es uno de los residuos que contienen mayor porcentaje de N en la etapa avanzada, que de acuerdo con lo descrito en Javed et al. (2019), la cáscara de papa contiene cantidades elevadas de proteínas y almidón, las cuales cuando se degradan generan fertilizantes con alto contenido de N. La lechuga mostró la mayor concentración de N de 3.67 %, 3.17 % y 4.16 % para las etapas media, avanzada e inicial respectivamente, lo que concuerda con lo encontrado en Petek y colaboradores (2020) quienes indican que el contenido de N en las hojas de lechuga oscila entre 1.13 % y 5.02 %.

La generación de nuevo conocimiento sobre el contenido de macronutrientes según las etapas de descomposición de los ROU ayuda a obtener un adecuado equilibrio de la relación C/N al inicio del proceso de compostaje, permitiendo una adecuada evolución del mismo, y por tanto, que dichos nutrientes estén presentes en la composta final.

Estudios previos han presentado el contenido de C/N de algunos restos de fruta, pero pocos consideran las diferentes etapas de descomposición. En Idris y colaboradores (2019) se estimó la relación C/N de cáscaras de naranja dulce y amarga en los días 1, 7 y 15, lo que coincide con los tiempos observados para las etapas de descomposición propuestas en este trabajo. Sin embargo, la relación C/N presentada en dicho trabajo (entre 34 % y 27 %) es inferior a los resultados encontrados en este estudio (alrededor de 66 % y 54 %). En Gautam, Pareek, y Sharma (2015) se presenta una relación C/N de 28 % y 26 % para cáscaras de plátano frescas y secas, mientras que, para cáscaras de papa frescas y secas, 16.6 % y 17.1 %, respectivamente. Las condiciones frescas y secas se pueden comparar con las etapas inicial y avanzada propuestas en este estudio, aunque los valores encontrados son mayores para ambas ROU: la relación C/N de la cáscara de plátano fue de 9.79 %, 43.43 % y 56.45 % para las etapas media, avanzada e inicial respectivamente, y 17.33 %, 19.30 % y 2.56 % para las cáscaras de papa en las etapas avanzada, media e inicial, respectivamente. En Anjum y Sundaram (2022) se determinaron los componentes nutricionales y antinutritivos de la cáscara de plátano en tres etapas: inmaduro, maduro y demasiado maduro que pueden compararse con las etapas de descomposición propuestas en este trabajo.

Las características de la lechuga y la cáscara de la papa los convierte en buenas opciones para equilibrar la relación C/N inicial de la mezcla a compostar. Además, la cáscara de papa, también en etapa avanzada podría aportar porosidad a la mezcla. Esto es importante para el tratamiento de los ROU mediante compostaje donde es común mezclarlos con estiércol animal o rastrojos de algunos cultivos (Vasiliadou *et al.*, 2015; Gao *et al.*, 2015; Thomas *et al.*, 2019; Alavi *et al.*, 2019) lo que a nivel doméstico no es práctico.

Otro nutriente que debe estar presente en cantidades mínimas en el material a compostar para que el proceso se realice correctamente es P (Bueno *et al.*, 2008), lo que permite la proliferación

microbiana y eventualmente la unión de P reactivo disuelto a los ácidos húmicos (USDA, 2010). El resultado de la determinación de P muestra que la lechuga tiene la mayor cantidad con 3.33 %, 2.06 % y 3.59 % en estados avanzado, medio e inicial, respectivamente. Estos valores se encuentran por arriba de lo encontrado por Petek y colaboradores (2020). Los restos de naranja presentaron la menor concentración de P lo que concuerda con Soceanu y sus colaboradores (2009), donde encontraron una pequeña cantidad de P en la cáscara de los cítricos a diferencia del encontrado en su jugo. Respecto al contenido de K, se encontró que la cáscara de plátano contiene la mayor cantidad con 5.74 % en la etapa inicial, 5.62 % en la etapa media y 5.06 % en la etapa avanzada. Estos valores se aproximan a lo encontrado por Anjum y Sundaram (2022), que observaron que la cáscara de plátano maduro contiene un 7.28 % de K. La cáscara de zanahoria y los restos de lechuga también mostraron altos contenidos de K lo que, junto con la cáscara de plátano, los convierte en buenos materiales para el compostaje debido a que durante el proceso de compostaje se libera K lo que genera ácidos orgánicos debido a la actividad microbiana (Bhattacharyya *et al.*, 2007).

8.2 Desarrollo de clasificador automático de ROU

8.2.1 Clasificación y detección de ROU

Los resultados en la etapa de validación mostraron que la red VGG16 obtuvo el mayor rendimiento (89%), lo que significa que la red VGG16 aprendió mejor las características de los ROU en comparación de las redes MobileNet y ROUNet que obtuvieron 86% y 79% respectivamente. Después de haber entrenado las tres redes, se efectuó una etapa de prueba donde las redes deben clasificar imágenes que no formaron parte de la etapa de aprendizaje. La red que obtuvo un mejor resultado en la etapa de prueba fue la VGG16 con el 94% de precisión en comparación del 73% de la red MobileNet y el 84% de la red ROUNet. Esto se explica porque la red VGG16 es más precisa y logran un rendimiento mejor en tareas de clasificación debido a las 16 capas convolucionales que tiene y al uso de filtros convolucionales pequeños de acuerdo con lo citado en Simonyan y Zisserman (2015). En cambio, la red MobileNet tiene 13 capas porque se desarrolló para aplicaciones de visión para dispositivos móviles lo que reduce el cálculo, pero a su vez reduce la precisión en la clasificación como lo menciona Howard y sus colaboradores (2017).

Es importante resaltar que los resultados alcanzados se deben principalmente a que VGG16 y MobileNet fueron previamente entrenadas en el conjunto de datos de ImageNet (Stanford Vision Lab), que tiene 14 millones de imágenes y más de 20,000 categorías (no incluyen categorías de ROU). En cambio, la red ROUNet se entrenó con las 9,000 imágenes de ROU que conforman la BD de índices que se desarrolló en durante este proyecto de investigación. Los resultados sugieren que la mejor opción para la clasificación de ROU con el número de imágenes de la BD de índices de este trabajo de investigación, fue la red VGG16.

Sin embargo, aun cuando la red ROUNet mostró un rendimiento menor, obtuvo un mayor porcentaje (84%) en la etapa de prueba en comparación con la red MobileNet (73%), lo que sugiere que, con el aumento indicado del número de capas, el ajuste correcto de los hiperparámetros y el aumento del número de imágenes de la BD de índices, se puede obtener un mejor rendimiento y ser más apropiada para la clasificación de ROU en este proyecto de investigación. Lo anterior implicaría un menor costo computacional en comparación con las otras dos CNN.

Entonces, como la CNN de creación propia ROUNet utiliza un menor número de capas representa una ventaja por tener que realizar un número menor de cálculos, lo que permite que el modelo pueda ejecutarse en microcontroladores o en dispositivos móviles como lo señalado por Frost y sus colaboradores (2019) que propusieron un modelo de clasificación de residuos para dispositivos móviles con buenos resultados.

Los resultados del entrenamiento y prueba de los modelos YOLO muestra resultados muy similares entre ellos. Sin embargo, el modelo YOLOv8l tuvo un mejor rendimiento observando la métrica $mAP^{val}_{0.5:0.95}$ que, de acuerdo con Diwan y colaboradores (2023), su evaluación es más precisa. Es importante observar que la ventaja de los modelos YOLOv8 es su velocidad en el reconocimiento de objetos (Wang *et al.*, 2022), mientras que los modelos YOLOv5 tienen un mejor rendimiento en aplicaciones en tiempo real según lo mencionado por Elmessery y colaboradores (2023). Estas características pueden ser un factor decisivo en la elección del modelo. Otro factor importante para elegir un modelo es el número de parámetros de cada

modelo. Los modelos YOLO tienen millones de parámetros (Tabla 11), que de acuerdo con Wang y colaboradores (2022), podría limitar su uso en algunos dispositivos.

8.2.2 Estimación del peso de ROU

Los resultados de la estimación del peso de los ROU a través de la regresión lineal mostraron que el modelo que mejor explica la variación de los datos es el de la manzana. Esto debido a que el residuo de manzana, que lo conforma el centro, considerada para este trabajo, tiene pocas variaciones en su forma y, por ende, la imagen tiene pocas variaciones en el número de píxeles. En cambio, en algunas imágenes del residuo del plátano la cáscara puede no estar completamente extendida, lo que provoca que se calcule un número menor de píxeles y por lo tanto el peso estimado por regresión no concuerde con el peso real del ROU. La condición de colocar los ROU de forma completamente extendida al momento de capturar la imagen, aumentaría el porcentaje explicativo entre la relación de las variables del peso y del número de píxeles para todas las clases de ROU. Otro aspecto por considerar es que algunos de los residuos de limón y naranja pueden contener aún jugo, y presentar variaciones en el peso. Para mejorar esto, se podría considerar tomar en cuenta otra variable como el estado de descomposición del ROU para aumentar la correlación.

8.3 Datos de la calidad de la composta

8.3.1 Temperatura

Los resultados del seguimiento de las temperaturas durante el proceso de compostaje permitieron observar un rápido aumento en ellas una vez iniciado el proceso lo que se puede explicar por lo señalado en Rashwan *et al.* (2021) donde se menciona que la rápida descomposición de la MO y los compuestos nitrogenados disponible en un proceso de compostaje es debido a la acción de microorganismos. Pese a que se alcanzaron temperaturas alrededor de los 50 °C en todas las repeticiones, en los tres tratamientos, estos no fueron por más de un día. Si bien la curva de la evolución de las temperaturas sigue el patrón de las temperaturas presentadas en la Fig. 1, se observó que, en las tres primeras fases, mesófila, termófila y enfriamiento duran menos tiempo comparada con el patrón de temperatura para otras metodologías, por ejemplo, en el compostaje en pilas como lo indica Román y sus colaboradores

(2015). Durante la fase de maduración, las fluctuaciones de temperatura coincidieron con los cambios de temperatura ambiental y esta última fase debería durar mucho más tiempo para obtener humus estable, de acuerdo con Rashwan *et al.* (2021).

Es importante señalar que para la elaboración de las compostas del experimento de este proyecto de investigación se utilizaron contenedores de 20 L para un compostaje a nivel doméstico. El compostaje a pequeña escala difícilmente alcanza las temperaturas arriba de los 60 °C necesarias para garantizar la inocuidad de la composta como lo señala Peña y sus colaboradores (2020) y temperaturas menores a 50 °C tienden a ralentizar el proceso de compostaje según Nieto-Garibay *et al.* (2021), por lo que fue necesario realizar análisis microbiológicos de las compostas terminadas cuyos resultados dieron compostas dentro de los límites permisibles. Además, es importante tener en cuenta que cuanto más pequeño sea el contenedor de la composta o pila, mayor será la relación superficie-volumen, y por tanto, mayor será el grado de pérdida de calor por conducción y radiación (Cornell Waste Management Institute, 2024).

Los restos de frutas, como los usados para los tratamientos, se caracterizan por contener pectina que se descompone rápidamente en ácidos orgánicos que eventualmente ralentizan el proceso de descomposición (Chanakya *et al.*, 2007). Además se observó que la alfalfa, al igual que los restos de jardinería tienen una lenta descomposición según Colón *et al.* (2010), dando una textura porosa a las compostas.

8.3.2 pH y Conductividad Eléctrica (CE)

Los parámetros de pH y CE son indicadores de la estabilidad de la composta (Bazrafshan *et al.*, 2016). El análisis de pH de las compostas resultantes del experimento de este trabajo fue alcalino lo cual puede ser un indicador de que el proceso de compostaje aún se encontraba en la fase de maduración. Además, el pH observado en los tratamientos podría ser debido al consumo de protones de los ácidos grasos volátiles durante la descomposición como lo señala Rashwan *et al.* (2021). El pH de T1:CN20 estaba ligeramente más bajo (8.96) que el pH de los otros dos tratamientos. Este resultado, de acuerdo con Bazrafshan y sus colaboradores (2016) pudiera ser debido a la mineralización del N orgánico que conduce a la emisión y el agotamiento del NH₃ y según el resultado de prueba Solvita® no se midieron emisiones de amoníaco (nivel 5) en el T1 en

comparación con los otros dos tratamientos que marcaron baja concentración de NH_3 (nivel 4). Por otro lado, los resultados del análisis de CE no mostraron diferencia estadísticamente significativa entre los tres tratamientos dado valores altos, que se explican por el alto contenido de sales solubles de acuerdo con Gondek *et al.* (2020). Así mismo, según Rashwan y colaboradores (2021), el aumento de CE en la fase de maduración puede deberse a la pérdida de peso de las compostas y a la liberación de sales solubles por la descomposición y degradación de la MO. Si, por un lado, los altos niveles de sales en una composta pueden resultar perjudicial para las plantas, por otro lado, las sales más solubles son nutrientes, por lo que una composta con alta concentración de sales puede ser una buena fuente de nutrientes cuando se aplica en dosis bajas (Gondek *et al.*, 2020). Además, compostas con alta CE son adecuadas para la remediación de suelos al facilitar la floculación de partículas, ayudar a lixiviar sodio y aumentar la capacidad de intercambio catiónico para favorecer la fertilidad del suelo (Gondek *et al.*, 2020).

También se debe tomar en cuenta las propiedades de los residuos usados para el proceso de compostaje. Los resultados de los análisis de nutrientes de los ROU utilizados en este estudio mostraron que el carbono es el nutriente mayormente presente en ellos y los materiales carbonosos son materiales conductores y responsables del color oscuro en una composta según lo mencionado en Rashwan *et al.* (2021) lo que coincide con el resultado del color oscuro de T3:CN40 (Fig. 36). En Kucbel y colaboradores (2019), se encontró que manzanas, plátanos, papas y cítricos contienen 100-200 mg/100 g de fruta y según Gamarra (2014) la cáscara de plátano tiene una gran cantidad de compuestos salinos solubles relacionados con el Na y K. La cáscara de naranja y limón tienen una descomposición lenta y esto puede deberse a que los residuos de cítricos son fuente de compuestos fenólicos que suelen presentar baja actividad biológica (Aguirre-Forero *et al.*, 2022).

8.3.3 Fototoxicidad

Como se mencionó anteriormente, altos valores de CE podrían revelar el grado de salinidad de la composta indicando su posible fitotoxicidad, y además indica que la composta aún no está madura. Al hacer pruebas de germinación con té de composta si se presentan índices de germinación (IG) por debajo de 50 % existe una fitotoxicidad severa, de 50 % a 80 % se le considera fitotoxicidad moderada, y por arriba de 80 % no existe fitotoxicidad de acuerdo con Nieto-Garibay

et al. (2021). En este trabajo los resultados de la prueba de germinación mostraron un IG para el T1:CN20 de 95 %, para T2:CN30 de 63 % y el T3:CN40 se obtuvo un 47 %. Estos resultados muestran que en el T1:CN20 no existe fitotoxicidad aún con sus valores de CE y de pH.

De acuerdo con lo indicado por Rashwan y sus colaboradores (2021) puede existir fitotoxicidad en compostas estables o maduras debido a la presencia de metales pesados, sin embargo, los resultados del análisis de metales pesados realizados a los tres tratamientos de este estudio indicaron que se encuentran dentro de los valores permisibles de acuerdo con la NMX-AA-180-SCFI-2018 como se puede observar en la Tabla 20.

8.3.4 Relación C/N

La relación C/N está asociada con la descomposición de los residuos orgánicos y la madurez de la composta con respecto al ciclo de MO y N: en una composta con una relación C/N alta (mayor a 40) los residuos orgánicos tardan mucho en descomponerse por la escasez de N, mientras que en una composta con una relación C/N baja causa toxicidad por amonio (Rashwan *et al.*, 2021). La prueba Solvita® para el T3:CN40 indicó bajas concentraciones de NH₃, se presentaron los valores de CE, pH y la relación C/N más altos y además presentó una fitotoxicidad severa, por lo tanto, se puede inferir que los residuos orgánicos aún requieren más tiempo para su descomposición. Esto se confirma al observar las proporciones de ROU y en la etapa de descomposición en el que se encontraban a la hora de iniciar el proceso de compostaje para los tratamientos. La Tabla 14 muestra las cantidades y se puede observar que el T3:CN40 contenía más ROU en etapa de descomposición inicial y media que los otros dos tratamientos. Por otro lado, estudios sugieren una cantidad mayor de los agentes que dan volumen para reducir la salinidad en compostas domésticas de acuerdo con diferentes estudios (Li *et al.*, 2013; Vázquez *et al.*, 2015). En el presente estudio el tratamiento CN20 contenía una relación aproximada de 50 % - 50 % de ROU-alfalfa. También se obtuvieron relaciones C/N de 9.81, 10.38 y 11.46 para T1, T2 y T3 respectivamente siendo T1 el que obtuvo un mayor IG y de acuerdo con Moreno y Mormeneo (2008), una relación C/N final cercana a 10 es aceptable.

8.4 Modelo del proceso de compostaje

8.4.1 Modelo del proceso de compostaje basado en RNA

Los modelos de RNA del proceso de compostaje permiten estudiar dos o más factores involucrados en el proceso y su incidencia sobre un parámetro de respuesta a partir de datos lo que permite hacer inferencias sobre ciertas condiciones iniciales (Soto-Paz *et al.*, 2019). Los modelos de RNA propuestos para este estudio se dividieron en dos grupos: los que tienen dos entradas (*peso* y *CN_inicial*) y los que tienen tres entradas (*peso*, *CN_inicial* y *etapa*). Los modelos que presentaron un mejor rendimiento fueron los modelos con un mayor número de neuronas en las capas ocultas los cuales presentaron un error igual a cero al clasificar la calidad de la composta resultante del proceso (CompostQNet_4, CompostQNet_8, ComposQtNet_12, CompostQNet_15 y CompostQNet_16).

Es importante señalar que la confiabilidad de los datos siempre ha sido una de las principales prioridades de los modelos basados en RNA (Yang *et al.*, 2021). Si bien, en los modelos de RNA en este proyecto se entrenaron con un número reducido de datos, lo que resalta de los modelos de tres variables es tener una entrada que no se había considerado hasta ahora en otros modelos del proceso de compostaje. Los resultados del análisis de calidad de las compostas demuestran la importancia de involucrar en modelos del proceso de compostaje de ROU las características cualitativas de éstos. Además, se observa que en los modelos que tienen como entrada la etapa de descomposición, el error convergió más rápidamente a cero en comparación con los modelos de dos entradas. Esto refleja la importancia de utilizar un número óptimo de variables de entrada para evitar el sobreajuste de los datos de entrenamiento y hacer estimaciones deficientes como lo indican Sarkar y Pandey (2015).

8.4.2 Modelo difuso del proceso de compostaje

La aplicación de tecnología de seguimiento en el proceso de compostaje provee a los modelos de parámetros de insumos adicionales, los cuales están involucrados durante el proceso, previniendo sobre los posibles errores en el mismo. Es así como el segundo modelo basado en LD lleva un seguimiento de la evolución de la temperatura durante el proceso de compostaje lo que es importante porque según Temel y sus colaboradores (2023) los cambios inconsistentes en el

patrón de temperatura en cualquier etapa del proceso de compostaje indican que hay un problema en el proceso ya sea debido a una mala aireación, un bajo contenido de humedad o una pérdida de nutrientes.

Inicialmente a la variable lingüística Fase del modelo difuso propuesto se le dio un espacio de 90 días, y la fase de maduración es la que se le asignó el mayor tiempo iniciando alrededor del día 20 y terminando el día 90. Sin embargo, dado los resultados en los análisis en la calidad de las compostas se hizo un ajuste al espacio de esta variable lingüística a 180 días para un tiempo total de 200 días del proceso de compostaje.

9. CONCLUSIONES

En la presente investigación se estudió el impacto de la relación carbono/nitrógeno en la calidad de la composta mediante la clasificación de las características cualitativas y cuantitativas de residuos orgánicos urbanos, la predicción de calidad y el seguimiento del proceso de compostaje. Los resultados obtenidos proporcionan una comprensión profunda de cómo estas características influyen en la calidad de la composta y el tiempo del proceso de compostaje. Este entendimiento es fundamental para mejorar el proceso de compostaje desde la gestión de residuos.

Se definieron tres etapas de descomposición: inicial, media y avanzada, asociadas a las características cualitativas de los ROU, como su cambio de color al degradarse. Estas etapas de descomposición son pertinentes mostrando diferencias significativas en su relación C/N y contenido de otros nutrientes, valores comprobados mediante análisis de laboratorio. Esta clasificación contribuye al manejo efectivo de residuos con el estudio de las características de los residuos orgánicos urbanos en distintas etapas de descomposición.

Se formuló un clasificador de residuos orgánicos, configurado en una red neuronal convolucional denominado ROUNet, para estimar la relación C/N a partir imágenes digitales. El clasificador ROUNet identifica con alta precisión el tipo de residuo y su etapa de descomposición, lo cual permite estimar su relación C/N y peso correspondiente. Como resultado complementario, se creó un conjunto de imágenes de residuos orgánicos urbanos en sus tres etapas de descomposición.

La red neuronal artificial CompostQNet se implementó para predecir la calidad de la composta. La predicción fue a partir de los datos estimados por el clasificador ROUNet con la tripleta integrada por la etapa de descomposición, el peso y la relación C/N, los cuales sintetizan las características cualitativas y cuantitativas de cada ROU. A diferencia de otros modelos de predicción del proceso de compostaje, se observó que CompostQNet es un modelo fiable que involucra diversos tipos de residuos y sus etapas de descomposición, mejorando así la precisión de las predicciones.

La medición de la evolución de las temperaturas del proceso de compostaje de ROU permitió desarrollar un modelo de seguimiento del proceso de compostaje basado en LD llamado CompostTraker. Este modelo es una herramienta práctica y adecuada que simplifica el manejo del proceso de compostaje brindando información clave que permite la toma de decisiones para garantizar una composta de calidad.

Los resultados de la presente investigación demostraron que la etapa de descomposición y las proporciones de los ROU a compostar tienen un efecto directo y significativo en el tiempo del proceso de compostaje y en la calidad de la composta resultante, particularmente calificada por su relación C/N, así como en el contenido de materia orgánica, pH, contenido de sales solubles y otros nutrientes. Asimismo, los modelos implementados contribuyen a mejorar la gestión de los ROU, a la estandarización del proceso de compostaje y a promover prácticas sostenibles en entornos urbanos.

Un trabajo futuro será la implementación del clasificador ROUNet y del modelo de RNA CompostQNet como una aplicación para dispositivos móviles. Así como utilizar el modelo CompostTraker para la obtención de datos que permitan ampliar el conocimiento sobre el compostaje doméstico.

Además, se propone como estudio innovador, evaluar el uso de ROU en etapa de descomposición avanzada como agentes de volumen y evaluar a mayor profundidad el efecto de las diferentes etapas de descomposición como factor de variabilidad. Al implementar esta metodología se espera lograr una mayor eficiencia en la gestión de residuos, así como obtener una composta de calidad que pueda ser utilizada en actividades agrícolas y de jardinería. Los resultados de este estudio contribuirán a mejorar la sostenibilidad de los procesos de compostaje a nivel local.

10. LITERATURA CITADA

- Abul, S. (2010). Environmental and health impact of solid waste disposal at Mangwaneni dumpsite in Manzini: Swaziland. *Journal of Sustainable Development in Africa*, 12(7): 64-78.
- Adhikari, B. K., Trémier, A., Martínez, J. y Barrington, S. (2010). Home and community composting for on-site treatment of urban organic waste: perspective for Europe and Canada. *Waste Management and Research*, 28(11): 1039-1053. doi: 10.1177/0734242X10373801.
- Aggarwal, C. C. (2018). *Neural networks and deep learning*. Springer Nature, Cham.
- Aguirre-Forero, S. E., Piraneque-Gambasica, N. V. y Cabarcas-Saumeth, D. E. (2022). Compost de cáscara de naranja: una alternativa de aprovechamiento y ciclaje de materia orgánica en la Región Caribe de Colombia. *Entramado*, 18(1): 1-11. doi: 10.18041/1900-3803/entramado.1.8063.
- Alavi, N., Sarmadi, K., Goudarzi, G., Babaei, A. A., Bakhshoodeh, R. y Paydary, P. (2019). Attenuation of tetracyclines during chicken manure and bagasse co-composting: degradation, kinetics, and artificial neural network modeling. *Journal of Environmental Management*, 231: 1203-1210. doi: 10.1016/j.jenvman.2018.11.003.
- Alexander, P. D. (2007). Effect of turning and vessel type on compost temperature and composition in backyard (amateur) composting. *Compost Science & Utilization*, 15(3): 167-175. doi: 10.1080/1065657X.2007.10702329.
- Anjum, S. y Sundaram, S. (2022). Comparative study on nutrient composition and functional characteristics of tropical fruits with emphasis on banana fruit peel. *International Journal of Pharmacy and Pharmaceutical Sciences*, 14(5): 25-35. doi: 10.22159/ijpps.2022v14i5.44144.
- Aprende Machine Learning (2021). Modelos de Detección de Objetos. Disponible en: <https://www.aprendemachinlearning.com/modelos-de-deteccion-de-objetos/> [consulta: 12 marzo 2021].
- Bazrafshan, E., Zarei, A., Kord Mostafapour, F., Poormollae, N., Mahmoodi, S. y Zazouli, MA. (2016). Maturity and stability evaluation of composted municipal solid wastes. *Health Scope*, 5(1): 1-9. doi: 10.17795/jhealthscope-33202.
- Bhattacharyya, P., Chakrabarti, K., Chakraborty, A., Nayak, D. C., Tripathy, S. y Powell, M. A. (2007). Municipal waste compost as an alternative to cattle manure for supplying potassium to lowland rice. *Chemosphere*, 66(9): 1789-1793. doi: 10.1016/j.chemosphere.2006.07.062.
- Bradski, G. (2000). The OpenCV Library (Versión 4.7.0). Palo Alto. OpenCV team.
- Bueno, P., Díaz, M. J., Cabrera, F. (2008). Factores que afectan al proceso de compostaje. En: *Compostaje*. Mundi-Prensa, Madrid, España, pp. 95-109.
- Cerda, A., Artola, A., Font, X., Barrena, R., Gea, T. y Sánchez, A. (2018). Composting of food wastes: status and challenges. *Bioresource technology*, 248(Pt A): 57-67. doi: 10.1016/j.biortech.2017.06.133.
- Chanakya, H.N., Ramachandra, T.V., Guruprasad, M. y Devi, V. (2007). Micro-treatment options for components of organic fraction of MSW in residential areas. *Environmental Monitoring and Assessment*, 135: 129-139. doi: 10.1007/s10661-007-9711-5.
- Chen, J. y Ngo, C.W. (2016). Deep-based ingredient recognition for cooking recipe retrieval. En: *24th ACM International conference on Multimedia*. Amsterdam, The Netherlands, pp. 32-41.

- Choy, S. Y., Wang, K., Qi, W., Wang, B., Chen, C.L. y Wang, J.Y. (2015). Co-composting of horticultural waste with fruit peels, food waste, and soybean residues. *Environmental Technology (United Kingdom)*, 36(11): 1448-1456. doi: 10.1080/09593330.2014.993728.
- Chu, Y., Huang, C., Xie, X., Tan, B., Kamal, S. y Xiong, X. (2018). Multilayer hybrid deep-learning method for waste classification and recycling. *Computational Intelligence and Neuroscience*, 2018: 1-9. doi: 10.1155/2018/5060857.
- Ciocca, G., Micali, G. y Napoletano, P. (2020). State recognition of food images using deep features. *IEEE Access*, 8: 32003-32017. doi: 10.1109/ACCESS.2020.2973704.
- Colón, J., Martínez-Blanco, J., Gabarrell, X., Artola, A., Sánchez, A., Rieradevall, J. y Font, X. (2010). Environmental assessment of home composting. *Resources, Conservation and Recycling*, 54(11): 893-904. doi: 10.1016/j.resconrec.2010.01.008.
- Cornell Waste Management Institute (1996). *Cornell composting. Science and engineering*. Disponible en: <https://compost.css.cornell.edu/physics.html> [consulta: 20 marzo 2024].
- Desai, Y., Dalvi, A., Jadhav, P. y Baphna, A. (2018). Waste segregation using machine learning. *International Journal for Research in Applied Science & Engineering Technology*, 6(III): 537-541. doi: 10.22214/ijraset.2018.3086.
- Díaz, M.J., Eugenio, M.E., López, F., García, J.C. y Yañez, R. (2012). Neural models for optimizing lignocellulosic residues composting process. *Waste and Biomass Valorization*, 3(3): 319-331. doi: 10.1007/s12649-012-9121-y.
- Diwan, T., Anirudh, G. y Tembhurne, J V. (2023). Object detection using YOLO: challenges, architectural successors, datasets and applications. *Multimedia Tools and Applications*, 82(6): 9243-9275. doi: 10.1007/s11042-022-13644-y.
- Duarte, D.G. (2018). *Estrategias para el aprovechamiento económico de residuos orgánicos generados por granjas avícolas del valle de La Paz, B.C.S. Tesis de Licenciatura*. Universidad Autónoma de Baja California Sur, Departamento Académico de Economía, La Paz.
- Elmessery, W.M., Gutiérrez, J., Abd El-Wahhab, G.G., Elkhayat, I.A., El-Soaly, I.S., Alhag, S.K., Al-Shuraym, L.A., Akela, M.A., Moghanm, F.S. y Abdelshafie, M.F. (2023). YOLO-based model for automatic detection of broiler pathological phenomena through visual and thermal images in intensive poultry houses. *Agriculture (Switzerland)*, 13(8). doi: 10.3390/agriculture13081527.
- FAO. (2020). *Frutas y verduras - esenciales en tu dieta*. FAO. Roma. Disponible en: <https://doi.org/10.4060/cb2395es> [consulta: 16 abril 2021].
- Fernández, C., Mateu, C., Moral, R. y Sole-Mauri, F. (2016). A predictor model for the composting process on an industrial scale based on Markov processes. *Environmental Modelling and Software*, 79: 156-166. doi: 10.1016/j.envsoft.2016.02.007.
- Fernandez, M.E., Nunell, G.V., Bonelli, P.R. y Cukierman, A.L. (2014). Activated carbon developed from orange peels: batch and dynamic competitive adsorption of basic dyes. *Industrial Crops and Products*, 62: 437-445. doi: <https://doi.org/10.1016/j.indcrop.2014.09.015>.
- Frost, S., Tor, B., Agrawal, R. y Forbes, A.G. (2019). CompostNet: An image classifier for meal waste. En: *2019 IEEE Global Humanitarian Technology Conference, GHTC 2019*. Seattle, WA, USA, pp. 31-34.
- Gamarra, F. (2014). Evaluación del uso de cáscaras de banano (*musa paradisiaca* sp.) para la descontaminación del agua con metales pesados de la cuenca de Milluni-La Paz. *Tesis de Licenciatura*. Universidad Mayor de San Andrés, Facultad de agronomía, La Paz.

- Gao, H., Zhou, C., Wang, R. y Li, X. (2015). Comparison and evaluation of co-composting corn stalk or rice husk with swine waste in China. *Waste and Biomass Valorization*, 6(5): 699-710. doi: 10.1007/s12649-015-9419-7.
- Gautam, K., Pareek, A. y Sharma, D.K. (2015). A method to utilize waste nutrient sources in aqueous extracts for enhancement of biomass and lipid content in potential green algal species for biodiesel production. *Journal of Bioprocessing & Biotechniques*, 5(10). doi: 10.4172/2155-9821.1000259.
- Ghinea, C. y Leahu, A. (2020). Monitoring of fruit and vegetable waste composting process: relationship between microorganisms and physico-chemical parameters. *Processes*, 8(3): 303. doi: 10.3390/pr8030302.
- GIZ. (2016). Diagnóstico de la gestión integral de los residuos sólidos urbanos para el municipio de La Paz, Baja California Sur, México. Cooperación Alemana al Desarrollo. Ciudad de México.
- Google Colab. (2021). *Google Colaboratory*. <https://colab.research.google.com/>
- Gómez-Ossa, L. y Botero, V. (2014). Análisis comparativo de dos modelos de deforestación: redes neuronales artificiales y regresión logística. En: *XVI Simposio Internacional SELPER 2014. La Geoinformación al Servicio de la sociedad*. Sociedad Latinoamericana de Especialistas en Percepción Remota y Sistemas de Información Espacial. Medellín, Colombia, pp. 1-22.
- Gondek, M., Weindorf, D.C., Thiel, C. y Kleinheinz, G. (2020). Soluble salts in compost and their effects on soil and plants: a review. *Compost Science & Utilization*, 28(2): 59-75. doi: 10.1080/1065657X.2020.1772906.
- González-Fernández, J.J., Alvarez, J.M., Galea, Z., Guirado, E., Hermoso, J.M., Hormaza, I. y López, R. (2013). Reciclaje de residuos de la producción de guacamole mediante compostaje. En: *VII Congreso Iberico de Agroingeniería y Ciencias Hortícolas: innovar y producir para el futuro*. Madrid, España, pp. 1529-1533.
- Goodfellow, I., Bengio, Y. y Courville, A. (2016). *Deep Learning*. MIT Press. Disponible en: <http://www.deeplearningbook.org>. [consulta: 20 noviembre 2020].
- Guo, H. N., Wu, S. B., Tian, Y. J., Zhang, J., y Liu, H. T. (2021). Application of machine learning 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.
- Guo, R., Li, G., Jiang, T., Schuchardt, F., Chen, T., Zhao, Y. y Shen, Y. (2012). Effect of aeration rate, C/N ratio and moisture content on the stability and maturity of compost. *Bioresource Technology*, 112: 171-178. doi: 10.1016/j.biortech.2012.02.099.
- Hamelers, H.V. (2004). Modeling composting kinetics: a review of approaches. *Reviews in Environmental Science and Biotechnology*, 3(4): 331-342. doi: 10.1007/s11157-004-2335-0.
- Hargreaves, J.C., Adl, M.S. y Warman, P.R. (2008). A review of the use of composted municipal solid waste in agriculture. *Agriculture, Ecosystems and Environment*, 123(1-3): 1-14. doi: 10.1016/j.agee.2007.07.004.
- Hou, J.C., Hu, Y.H., Hou, L.X., Guo, K.Q. y Satake, T. (2015). Classification of ripening stages of bananas based on support vector machine. *International Journal of Agricultural and Biological Engineering*, 8(6): 99-103. doi: 10.3965/j.ijabe.20150806.1275.
- Howard, A.G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M. y Adam, H. (2017). MobileNets: efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*. doi: 10.48550/arXiv.1704.04861.

- Hridayami, P., Putra, I.K.G.D. y Wibawa, K.S. (2019). Fish species recognition using VGG16 deep convolutional neural network. *Journal of Computing Science and Engineering*, 13(3): 124-130. doi: 10.5626/JCSE.2019.13.3.124.
- Hurwitz, J. y Kirsch, D. (2018). *Machine learning*. John Wiley & Sons, Inc., Hoboken, New Jersey.
- Hussain, I., He, Q. y Chen, Z. (2018). Automatic fruit recognition based on DCNN for commercial source trace system. *International Journal on Computational Science & Applications*, 8(2/3): 01-14. doi: 10.5121/ijcsa.2018.8301.
- Idris, I., Dan-musa, A., Musa, A., Ilu, B.M. y Sada, I. (2019). Evaluation of the influence of size reduction on methane production of orange peel waste samples at ambient temperature. *Journal of Applied Chemistry*, 12(3): 14-21. doi: 10.9790/5736-1203011421.
- INEGI. (2020). *Comunicado de prensa núm. 266/2020*. Disponible en: https://www.inegi.org.mx/contenidos/saladeprensa/aproposito/2020/ambiente2020_Nal.pdf [consulta: 16 febrero 2021].
- INEGI. (2019). *Censo Nacional de Gobiernos Municipales y Delegacionales 2019. Módulo 6: Residuos sólidos urbanos*. Disponible en: <https://www.inegi.org.mx/programas/cngmd/2019/> [consulta: 21 abril 2021].
- Javed, A., Ahmad, A., Tahir, A., Shabbir, U., Nouman, M. y Hameed, A. (2019). Potato peel waste—its nutraceutical, industrial and biotechnological applications. *AIMS Agriculture and Food*, 4(3): 807-823. doi: 10.3934/agrfood.2019.3.807.
- Jelodar, A.B., Salekin, M.S. y Sun, Y. (2018). Identifying object States in cooking-related images. *arXiv preprint arXiv:1805.06956*. doi: 10.48550/arXiv.1805.06956.
- Jiang, R., Sun, S., Xu, Y., Qiu, X., Yang, J. y Li, X. (2015). Leaching behavior of total organic carbon, nitrogen, and phosphorus from banana peel. *Water Science and Technology*, 71(10): 1458-1462. doi: 10.2166/wst.2015.117.
- Jiménez-Castro, M. P., Buller, L.S., Zoffreo, A., Timko, M.T., y Forster-Carneiro, T. (2020). Two-stage anaerobic digestion of orange peel without pre-treatment: Experimental evaluation and application to São Paulo state. *Journal of Environmental Chemical Engineering*, 8(4): 104035. doi: 10.1016/j.jece.2020.104035.
- Jung, S.K. y Choi, H.S. (2020). Browning of 'empire' and 'fuji' apples as affected by antioxidant activities. *Agronomy*, 10(12): 1883. doi: 10.3390/agronomy10121883.
- Kaza, S., Yao, L., Bhada-Tata, P. y Van Woerden, F. (2018). *What a waste 2.0: a global snapshot of solid waste management to 2050*. The World Bank, Washington, DC.
- Kubo, Y. (2015). Ethylene, oxygen, carbon dioxide, and temperature in postharvest physiology. En: *Abiotic stress biology in horticultural plants*. Springer, Japan, pp. 13-33.
- Kucbel, M., Raclavská, H., Růžičková, J., Švédová, B., Sassmanová, V., Drozdová, J., Raclavský, K. y Juchelková, D. (2019). Properties of composts from household food waste produced in automatic composters. *Journal of Environmental Management*, 236: 657-666. doi: 10.1016/j.jenvman.2019.02.018.
- Lecun, Y., Bengio, Y. y Hinton, G. (2015). Deep learning. *Nature*, 521(7553): 436-444. doi: 10.1038/nature14539.
- Lecun, Y., Bottou, L., Bengio, Y. y Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11): 2278-2324. doi: 10.1109/5.726791.
- LPGIR (2023). *Ley General para la Prevención y Gestión Integral de los Residuos Sólidos*. Cámara de Diputados. Ciudad de México.

- Li, Z., Lu, H., Ren, L. y He, L. (2013). Experimental and modeling approaches for food waste composting: a review. *Chemosphere*, 93(7): 1247-1257. doi: 10.1016/j.chemosphere.2013.06.064.
- Liang, S. y McDonald, A.G. (2014). Chemical and thermal characterization of potato peel waste and its fermentation residue as potential resources for biofuel and bioproducts production. *Journal of Agricultural and Food Chemistry*, 62(33): 8421-8429. doi: 10.1021/jf5019406.
- Lin, C., Wei, C.C. y Tsai, C.C. (2016). Prediction of influential operational compost parameters for monitoring composting process. *Environmental Engineering Science*, 33(7): 494-506. doi: 10.1089/ees.2015.0259.
- Lin, T.Y., Maire, M., Belongie, S., Bourdev, L., Girshick, R., Hays, J., Perona, P., Ramanan, D., Zitnick, C.L. y Dollár, P. (2014). Microsoft COCO: common objects in context. En: *Computer Vision–ECCV 2014: 13th European Conference*. Zurich, Switzerland, pp. 740-755.
- Lu, H.W., Huang, G.H., He, L. y Zeng, G.M. (2009). An inexact dynamic optimization model for municipal solid waste management in association with greenhouse gas emission control. *Journal of Environmental Management*, 90(1): 396-409. doi: 10.1016/j.jenvman.2007.10.011.
- Lufu, R., Ambaw, A. y Opara, U.L. (2020). Water loss of fresh fruit: influencing pre-harvest, harvest and postharvest factors. *Scientia Horticulturae*, 272: 109519. doi: 10.1016/j.scienta.2020.109519.
- Menacho, C. (2014). Lineal regression models with neural networks. *Anales Científicos*, 75(2): 253-260. doi: 10.21704/ac.v75i2.961.
- Milinković, M., Lalević, B., Jovičić-Petrović, J., Golubović-Ćurguz, V., Kljujev, I. y Raičević, V. (2019). Biopotential of compost and compost products derived from horticultural waste - effect on plant growth and plant pathogens' suppression. *Process Safety and Environmental Protection*, 121: 299-306. doi: 10.1016/j.psep.2018.09.024.
- Mirabelli, E. (2008). *Compostaje proyectado a la lombricultura*. Hemisferio Sur S.A., Buenos Aires.
- Mishra, S.K. y Yadav, K.D. (2022). Assessment of the effect of particle size and selected physico-chemical and biological parameters on the efficiency and quality of composting of garden waste. *Journal of Environmental Chemical Engineering*, 10(3): 107925. doi: <https://doi.org/10.1016/j.jece.2022.107925>.
- Moreno, J. y Mormeneo, S. (2008). Microbiología y bioquímica del proceso de compostaje. En: *Compostaje*. Mundi-Prensa, Madrid, pp 110-140.
- Mureşan, H. y Oltean, M. (2018). Fruit recognition from images using deep learning. *Acta Universitatis Sapientiae, Informatica*, 10(1): 26-42. doi: 10.2478/ausi-2018-0002.
- Muscolo, A., Papalia, T., Settineri, G., Mallamaci, C. y Jeske-Kaczanowska, A. (2018). Are raw materials or composting conditions and time that most influence the maturity and/or quality of composts? Comparison of obtained composts on soil properties. *Journal of Cleaner Production*, 195: 93-101. doi: 10.1016/j.jclepro.2018.05.204.
- Neugebauer, M., Sołowiej, P. y Piechocki, J. (2014). Fuzzy control for the process of heat removal during the composting of agricultural waste. *Journal of Material Cycles and Waste Management*, 16(2): 291-297. doi: 10.1007/s10163-013-0188-8.
- Nguyen, T.B.T., Ketsa, S. y Van Doorn, W.G. (2003). Relationship between browning and the activities of polyphenol oxidase and phenylalanine ammonia lyase in banana peel during low temperature storage. *Postharvest Biology and Technology*, 30(2): 187-193. doi: 10.1016/S0925-5214(03)00103-0.

- Nieto-Garibay, A., Murillo-Amador, B., Luna, P., Troyo-Diéguez, E., García-Hernández, J.L., Aguilar, M.G., Holguín-Peña, R.J. y Larrinaga-Mayoral, J.A. (2021). *La composta. Importancia, elaboración y uso agrícola*. 2ª ed. Trillas, Ciudad de México.
- NMX-AA-180-SCFI-2018. (2018). Que establece los métodos y procedimientos para el tratamiento aerobio de la fracción orgánica de los residuos sólidos urbanos y de manejo especial, así como la información comercial y de sus parámetros de calidad de los productos finales. Dirección General Mexicana de Normas, Ciudad de México.
- Omar, S.Z., Hasan, A.H. y Lalov, I. (2020). Potato peels and mixed grasses as raw materials for biofuel production. *Aro-the Scientific Journal of Koya University*, 8(1): 31-37. doi: 10.14500/aro.10568.
- ONU (2018). *Perspectiva de la gestión de residuos en América Latina y el Caribe*. Programa de las Naciones Unidas para el Medio Ambiente. Oficina para América Latina y el Caribe. Ciudad de Panamá, Panamá.
- Onwosi, C.O., Igbokwe, V.C., Odimba, J.N., Eke, I.E., Nwankwoala, M.O., Iroh, I.N. y Ezeogu, L.I. (2017). Composting technology in waste stabilization: on the methods, challenges and future prospects. *Journal of Environmental Management*, 190: 140-157. doi: 10.1016/j.jenvman.2016.12.051.
- O'Shea, K. y Nash, R. (2015). An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*. 1-11. doi: 10.48550/arXiv.1511.08458.
- Pathak, P.D., Mandavgane, S.A. y Kulkarni, B.D. (2017). Fruit peel waste: characterization and its potential uses. *Current Science*, 113(3): 444-454. doi: 10.18520/cs/v113/i03/444-454.
- Peña, H., Mendoza, H., Diánez, F. y Santos, M. (2020). Parameter selection for the evaluation of compost quality. *Agronomy*, 10(10): 1567. doi: 10.3390/agronomy10101567.
- Pergola, M., Persiani, A., Palese, A-M., Di Meo, V., Pastore, V., D'Adamo, C. y Celano, G. (2018). Composting: the way for a sustainable agriculture. *Applied Soil Ecology*, 123: 744-750. doi: 10.1016/j.apsoil.2017.10.016.
- Petek, M., Krvavica, L., Karažija, T., Žlabur, J.Š. y Ćustić, M.H. (2020). Macroelements status in lettuce affected by different forms of phosphorus fertilization. *Scientific Papers. Series B, Horticulture*, LXIV (2): 227-234.
- Pinzón-Bedoya, M.L. y Cardona, A.M. (2008). Caracterización de la cáscara de naranja para su uso como material bioadsorbente. *Bistua: Revista de la Facultad de Ciencias Básicas*, 6(1): 1-23.
- Pulido-Calvo, I., Montesinos, P., Roldán, J. y Ruiz-Navarro, F.J. (2005). Estimación de la demanda de agua para riego: regresiones lineales versus aproximaciones neuronales. *Avances en Recursos Hidráulicos*, (12): 7-20.
- Python. (2020). *Python* (versión 3.10.12). Python Software Foundation.
- Qin, X., Huang, G., Zeng, G., Chakma, A. y Xi, B. (2007). A fuzzy composting process model. *Journal of the Air and Waste Management Association*, 57(5): 535-550. doi: 10.3155/1047-3289.57.5.535.
- R Core Team. (2020). R: A language and environment for statistical computing (versión 4.3.0.). R Core Team.
- Raschka, S. y Mirjalili, V. (2019). *Python machine learning: machine learning and deep learning with python, scikit-learn, and TensorFlow*. 3rd ed. Packt, Birmingham.
- Rashwan, M.A., Naser Alkoaik, F., Abdel-Razzak Saleh, H., Blanqueza Fulleros, R. y Nagy Ibrahim, M. (2021). Maturity and stability assessment of composted tomato residues and chicken

- manure using a rotary drum bioreactor. *Journal of the Air and Waste Management Association*, 71(5): 529-539. doi: 10.1080/10962247.2020.1859416.
- Redmon, J., Divvala, S., Girshick, R. y Farhadi, A. (2016). You only look once: unified, real-time object detection. En: IEEE conference on computer vision and pattern recognition. Long Beach, Los Ángeles, California, USA, pp. 779-788.
- Reyna-Gómez, L.M., Molina-Guerrero, C.E., Alfaro, J.M., Vázquez, S.I.S., Robledo-Olivo, A. y Cruz-López, A. (2019). Effect of carbon/nitrogen ratio, temperature, and inoculum source on hydrogen production from dark codigestion of fruit peels and sewage sludge. *Sustainability (Switzerland)*, 11(7): 1-13. doi: 10.3390/SU11072139.
- Richardson, A.C., Boldingh, H.L., McAtee, P.A., Gunaseelan, K., Luo, Z., Atkinson, R.G., David, K.M., Burdon, J.N. y Schaffer, R.J. (2011). Fruit development of the diploid kiwifruit, *Actinidia chinensis* "Hort16A". *BMC Plant Biology*, 11: 1-14. doi: 10.1186/1471-2229-11-182.
- Riveros, A.S., Rosales, F.E., Romero, J., Romero, C., Jiménez, M.I., Jiménez, R, Acuña, O., Tabora, P., Segura, R., Pocasangre, L.E. y Villalobos, M. (2006). Estandarización de enmiendas orgánicas para banano en América Latina. En: *XVII reunión Internacional de Asociaciones para la Cooperación e Investigación Sobre Banana en el Caribe y América Tropical*. Joinville, Santa Catarina, Brasil, pp. 234-240.
- Rojas, A.F., Rodríguez-Barona, S. y Montoya, J. (2019). Evaluación de alternativas de aprovechamiento energético y bioactivo de la cáscara de plátano. *Información Tecnológica*, 30(5): 11-24. doi: 10.4067/s0718-07642019000500011.
- Rojas-González, A.F., Flórez-Montes, C. y López-Rodríguez, D.F. (2018). Use prospects of some agroindustrial waste. *Revista Cubana de Química*, 31(1): 31-52.
- Román, P., Martínez, M.M. y Pantoja, A. (2015). *Farmer's compost handbook. Experiences in Latin America*. 1st ed. FAO, Santiago de Chile.
- Rynk, R., Van De Kamp, M., Willson, G.B., Singley, M.E., Richard, T.L., Kolega, J.J., Gouin, F.R., Laliberty, L., Kay, D., Murphy, D.W., Hoitink, H.A.J. y Brinton, W.F. (1992). *On-farm composting handbook*. Northeast Regional Agricultural Engineering Service (NRAES), Ithaca.
- Sæbø, A. y Ferrini, F. (2006). The use of compost in urban green areas – A review for practical application. *Urban Forestry & Urban Greening*, 4(3): 159-169. doi: <https://doi.org/10.1016/j.ufug.2006.01.003>.
- Sakib, S., Ashrafi, Z. y Siddique, M.A.B. (2019). Implementation of fruits recognition classifier using convolutional neural network algorithm for observation of accuracies for various hidden layers. *arXiv preprint arXiv:1904.00783*, 10-14. doi: 10.48550/arXiv.1904.00783.
- Salekin, M.S., Babaeian Jelodar, A. y Kushol, R. (2019). Cooking state recognition from images using inception architecture. *Proceedings of the 1st International Conference on Robotics, Electrical and Signal Processing Techniques, ICREST 2019*, pp. 163-168. doi: 10.1109/ICREST.2019.8644262.
- Sánchez, Ó.J., Ospina, D.A. y Montoya, S. (2017). Compost supplementation with nutrients and microorganisms in composting process. *Waste Management*, 69(26): 136-153. doi: 10.1016/j.wasman.2017.08.012.
- Sánchez-Meca, J. (2010). Cómo hacer una revisión sistemática y un meta-análisis. *Aula Abierta*, 38(2): 53-64.
- Sánchez-Monedero, M.A., Roig, A., Paredes, C. y Bernal, M.P. (2001). Nitrogen transformation during organic waste composting by the Rutgers system and its effects on pH, EC and

- maturity of the composting mixtures. *Bioresource Technology*, 78(3): 301-308. doi: 10.1016/S0960-8524(01)00031-1.
- Santos-Romero, M., Arellano-Verdejo, J., Lazcano-Hernández, H.E. y Reyes, P.D. (2022). Automatic classification of images with beach linear perspective using convolutional neural networks; Automatic classification of images with beach linear perspective using convolutional neural networks. En: *IEEE Mexican International Conference on Computer Science (ENC)*. Xalapa, Veracruz, Mexico, pp. 1-8.
- Sarkar, A. y Pandey, P. (2015). River water quality modelling using artificial neural network technique. *Aquatic Procedia*, 4: 1070-1077. doi: 10.1016/j.aqpro.2015.02.135.
- Sayara, T., Basheer-Salimia, R., Hawamde, F. y Sánchez, A. (2020). Recycling of organic wastes through composting: process performance and compost application in agriculture. *Agronomy*, 10(11): 1838. doi: 10.3390/agronomy10111838.
- SEMARNAT. (2020). *Diagnóstico básico para la gestión integral de los residuos*. 1ª. ed. Secretaría de Medio Ambiente y Recursos Naturales, Ciudad de México.
- Shilev, S., Naydenov, M., Vancheva, V. y Aladjadjyan, A. (2007). Composting of food and agricultural wastes. En: *Utilization of by-products and treatment of waste in the food industry*. Springer, Boston, MA, pp. 283-301.
- Sial, T-A., Khan, M-N., Lan, Z., Kumbhar, F., Ying, Z., Zhang, J., Sun, D. y Li, X. (2019). Contrasting effects of banana peels waste and its biochar on greenhouse gas emissions and soil biochemical properties. *Process Safety and Environmental Protection*, 122: 366-377. doi: 10.1016/j.psep.2018.10.030.
- SIAP. (2023). *Panorama Agroalimentario 2023*. Servicio de Información Agroalimentaria y Pesquera. Secretaria de Agricultura y Desarrollo Rural. Ciudad de México.
- Simonyan, K. y Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv preprint arXiv: 1409.1556*. doi: 10.48550/arXiv.1409.1556.
- Soceanu, A., Dobrinas, S., Birghila, S., Popescu, V., Birghila, S. y Magearu, V. (2009). Levels of phosphorus in citrus fruits. *Ovidius University Annals of Chemistry*, 20(1): 87-90.
- Solé-Mauri, F. y Díaz, M.J. (2008). Modelización matemática del proceso de compostaje: estado de la cuestión. En: *Compostaje*. Mundi-Prensa, Madrid, pp 209-228.
- Soto-Paz, J., Manyoma-Velásquez, P., Oviedo-Ocaña, R., Alfonso, W., Caicedo, E. y Torres-Lozada, P. (2019). Neuronal network modeling to support an experimental study of the composting process of biowaste with filter cake and star grass. En: *Waste management and the environment*. WIT Press, pp 225-236.
- Sri, M.K., Saikrishna, K. y Kumar, V.V. (2020). Classification of ripening of banana fruit using convolutional neural networks. En: *4th International Conference: Innovative Advancement in Engineering & Technology (IAET)*. Jaipur, Rajasthan, India, pp. 1-6.
- Taheri, M., Gholamalifard, M., Ghazizade, M.J. y Rahimoghli, S. (2014). Environmental impact assessment of municipal solid waste disposal site in Tabriz, Iran using rapid impact assessment matrix. *Impact Assessment and Project Appraisal*, 32(2): 162-169. doi: 10.1080/14615517.2014.896082.
- Támara, A.L., Vargas, H., Cuartas, J.J. y Chica, I.E. (2019). Regresión logística y redes neuronales como herramientas para realizar un modelo scoring. *Revista Lasallista de Investigación*, 16(1): 187-200. doi: <https://doi.org/10.22507/rli.v16n1a5>.
- Tanthachoon, N., Chiemchaisri, C. y Chiemchaisri, W. (2007). Utilisation of municipal solid waste compost as landfill cover soil for reducing greenhouse gas emission. *International Journal*

- of *Environmental Technology and Management*, 7(3/4): 286-297. doi: 10.1504/IJETM.2007.015146.
- Tejada-Tovar, C., González-Delgado, A. y Villabona-Ortíz, A. (2018). Adsorption kinetics of orange peel biosorbents for Cr (VI) uptake from water. *Contemporary Engineering Sciences*, 11(24): 1185-1193. doi: 10.12988/ces.2018.83105.
- Tejada-Tovar, C., Herrera-Barros, A. y Villabona-Ortíz, A. (2020). Assessment of chemically modified lignocellulose waste for the adsorption of Cr (VI). *Revista Facultad de Ingeniería*, 29(54). doi: 10.19053/01211129.v29.n54.2020.10298.
- Tejada, L., Tejada-Tovar, C., Marimón, W. y Villabona-Ortíz, Á.V. (2014). Estudio de modificación química y física de biomasa (*Citrus sinensis* y *Musa paradisiaca*) para la adsorción de metales pesados en solución. *Revista Luna Azul*, 39: 124-142.
- Temel, A.F., Yolcu, C.O. y Turan, N.G. (2023). Artificial intelligence and machine learning approaches in composting process: a review. *Bioresource Technology*, 370. doi: 10.1016/j.biortech.2022.128539.
- Thomas, E.Y., Adiku, S.G.K., Atkinson, C.J., Omueti, J.A.I. y Marcarthy, D.S. (2019). Evaluation of CO₂ emission from rice husk biochar and cowdung manure co-compost preparation. *Journal of Agricultural Science*, 11(17): 158. doi: 10.5539/jas.v11n17p158.
- Torfi, A., Shirvani, R.A., Keneshloo, Y., Tavaf, N. y Fox, E.A. (2020). Natural language processing advancements by deep learning: A survey. *arXiv preprint arXiv:2003.01200*.
- Torres, J. (2020). Python deep learning: Introducción práctica con Keras y TensorFlow 2. Alpha Editorial, Bogotá.
- Trainotti, L., Tadiello, A. y Casadoro, G. (2007). The involvement of auxin in the ripening of climacteric fruits comes of age: The hormone plays a role of its own and has an intense interplay with ethylene in ripening peaches. *Journal of Experimental Botany*, 58(12): 3299-3308. doi: 10.1093/jxb/erm178.
- Ultralytics Inc. (2023). *Ultralytics*. Disponible en: <https://www.ultralytics.com/es>
- USDA. (2010). Composting. En: *Environmental Engineering National Engineering Handbook*. United States Department of Agriculture. Washington, DC.
- Vasiliadou, I.A., Chowdhury, M.B.A.K.M., Akratos, C.S., Tekerlekopoulou, A.G., Pavlou, S. y Vayenas, D.V. (2015). Mathematical modeling of olive mill waste composting process. *Waste Management*, 43: 61-71. doi: 10.1016/j.wasman.2015.06.038.
- Vázquez, M.A., Sen, R. y Soto, M. (2015). Physico-chemical and biological characteristics of compost from decentralised composting programmes. *Bioresource Technology*, 198: 520-532. doi: 10.1016/j.biortech.2015.09.034.
- Vidriales-Escobar, G., Rentería-Tamayo, R., Alatraste-Mondragón, F. y González-Ortega, O. (2017). Mathematical modeling of a composting process in a small-scale tubular bioreactor. *Chemical Engineering Research and Design*, 120: 360-371. doi: 10.1016/j.cherd.2017.02.006.
- Wadhwa, M. y Bakshi, S.P.M. (2013). Utilization of fruit and vegetable wastes as livestock feed and as substrates for generation of other value-added products. RAP publication, 2013/04. Rome 67 p.
- Wang, C.Y., Bochkovskiy, A. y Liao, H.Y.M. (2022). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. En: *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver, Canada, pp. 7464-7475.

- Perez, L. y Wang, J. (2017). The effectiveness of data augmentation in image classification using deep learning. *arXiv preprint arXiv:1712.04621*. doi: 10.48550/arXiv.1712.04621.
- Wang, S.H. y Chen, Y. (2018). Fruit category classification via an eight-layer convolutional neural network with parametric rectified linear unit and dropout technique. *Multimedia Tools and Applications*, 79(21-22): 15117-15133. doi: 10.1007/s11042-018-6661-6.
- Yang, Z., Muhayodin, F., Larsen, O.C., Miao, H., Xue, B. y Rotter, V.S. (2021). A review of composting process models of organic solid waste with a focus on the fates of C, N, P, and K. *Processes*, 9(3): 473. doi: 10.3390/pr9030473.
- Zadeh, L.A. (2008). Is there a need for fuzzy logic? *Information Sciences*, 178(13): 2751-2779. doi: 10.1016/j.ins.2008.02.012.
- Zhang, Y.D., Dong, Z., Chen, X., Jia, W., Du, S., Muhammad, K. y Wang, S.H. (2019). Image based fruit category classification by 13-layer deep convolutional neural network and data augmentation. *Multimedia Tools and Applications*, 78(3): 3613-3632. doi: 10.1007/s11042-017-5243-3.
- Zheng, Y. y Ge, J. (2021). Binocular intelligent following robot based on YOLO-LITE. En *MATEC Web of Conferences vol. 336*. Sanya, China, pp. 1-10. doi: 10.1051/matecconf/202133603002.