



**UNIVERSIDAD NACIONAL DE CHIMBORAZO
FACULTAD DE INGENIERÍA
CARRERA DE INGENIERÍA INDUSTRIAL**

**Modelado y predicción de productos en la pirólisis de biomasa y plásticos:
Enfoque cuantitativo para la valorización de residuos**

Trabajo de Titulación para optar al título de Ingeniero Industrial

**Autor:
León Borja Franklin Andrés**

**Tutor:
Ing. Fidel Vallejo, Ph.D.**

Riobamba, Ecuador. 2025

DECLARATORIA DE AUTORÍA

Yo, Franklin Andrés León Borja, con cédula de ciudadanía 0605875962, autor del trabajo de investigación titulado: Modelado y Predicción de Productos en la Pirólisis de Biomasa y Plásticos: Enfoque Cuantitativo para la Valorización de Residuos, certifico que la producción, ideas, opiniones, criterios, contenidos y conclusiones expuestas son de mi exclusiva responsabilidad.

Asimismo, cedo a la Universidad Nacional de Chimborazo, en forma no exclusiva, los derechos para su uso, comunicación pública, distribución, divulgación y/o reproducción total o parcial, por medio físico o digital; en esta cesión se entiende que el cesionario no podrá obtener beneficios económicos. La posible reclamación de terceros respecto de los derechos de autor de la obra referida, será de mi entera responsabilidad; librando a la Universidad Nacional de Chimborazo de posibles obligaciones.

En Riobamba, 17 de junio de 2026




Franklin Andrés León Borja
C.I: 0605875962

DICTAMEN FAVORABLE DEL PROFESOR TUTOR

Quien suscribe, Fidel Ernesto Vallejo Gallardo catedrático adscrito a la Facultad de Ingeniería, por medio del presente documento certifico haber asesorado y revisado el desarrollo del trabajo de investigación titulado: Modelado y Predicción de Productos en la Pirólisis de Biomasa y Plásticos: Enfoque Cuantitativo para la Valorización de Residuos, bajo la autoría de Franklin Andrés León Borja; por lo que se autoriza ejecutar los trámites legales para su sustentación.

Es todo cuanto informar en honor a la verdad; en Riobamba, a los 17 días del mes de junio de 2026



Ing. Fidel Ernesto Vallejo Gallardo, Ph.D.


C.I: 1715890644

CERTIFICADO DE LOS MIEMBROS DEL TRIBUNAL


Quienes suscribimos, catedráticos designados Miembros del Tribunal de Grado para la evaluación del trabajo de investigación “**Modelado y Predicción de Productos en la Pirólisis de Biomasa y Plásticos: Enfoque Cuantitativo para la Valorización de Residuos**”, presentado por **Franklin Andrés León Borja**, con cédula de identidad número 0605875962, bajo la tutoría del **Ing. Fidel Vallejo Gallardo, Ph.D**; certificamos que recomendamos la **APROBACIÓN** de este con fines de titulación. Previamente se ha evaluado el trabajo de investigación y escuchada la sustentación por parte de su autor; no teniendo más nada que observar.

De conformidad a la normativa aplicable firmamos, en Riobamba a los 24 días del mes de junio de 2026.


Ing. Vicente Soria Granizo, Mgs
PRESIDENTE DEL TRIBUNAL DE GRADO



Ing. Gabriela Serrano Torres, Mgs
MIEMBRO DEL TRIBUNAL DE GRADO



Ing. Darío Guamán Lozada, Mgs
MIEMBRO DEL TRIBUNAL DE GRADO





CERTIFICACIÓN

Que, **LEÓN BORJA FRANKLIN ANDRÉS** con CC: **0605875962**, estudiante de la Carrera **INGENIERÍA INDUSTRIAL**, Facultad de **INGENIERÍA**; ha trabajado bajo mi tutoría el trabajo de investigación titulado " **MODELADO Y PREDICCIÓN DE PRODUCTOS EN LA PIRÓLISIS DE BIOMASA Y PLÁSTICOS: ENFOQUE CUANTITATIVO PARA LA VALORIZACIÓN DE RESIDUOS**", cumple con el 5 %, de acuerdo al reporte del sistema Anti plagio **COMPILATIO MAGISTER**, porcentaje aceptado de acuerdo a la reglamentación institucional, por consiguiente autorizo continuar con el proceso.

Riobamba, 03 de junio de 2026



Validar únicamente en FirmsEC.
Firmado electrónicamente por:
**FIDEL ERNESTO
VALLEJO GALLARDO**

PhD. Fidel Vallejo Gallardo
TUTOR

DEDICATORIA

A Dios, por haberme dado la oportunidad de culminar esta etapa con éxito y proveerme de la fuerza necesaria para no rendirme jamás.

A mis padres, Franklin León y Patricia Borja, por ser pilares fundamentales en mi vida, por ser el motor que me ha impulsado a creer en mí mismo y por inculcarme los valores, la perseverancia y la superación constante para aspirar a un futuro mejor.

A mis hermanos, Santiago y Vanessa, por su cariño, amor incondicional y por ser los compañeros que Dios me ha otorgado para vivir gran parte de nuestras vidas.

Con cariño,
Andrés.

AGRADECIMIENTO

A Dios, por la confianza que ha puesto en mí, y a quien debo todos mis logros.

A mis padres, por el esfuerzo y sacrificio que han realizado para que yo pueda culminar esta etapa de mi vida, ustedes construyeron con amor, esfuerzo y valores el hombre en quien me he convertido. Cada sacrificio que realizaron se ve reflejado en mí y en este logro alcanzado, este logro también les pertenece.

A mis hermanos, por el acompañamiento y apoyo que me han dado durante este trayecto.

A la Universidad Nacional de Chimborazo y a los docentes de la carrera de Ingeniería Industrial, por ser quienes sentaron las experiencias y conocimientos necesarios para formar un nuevo profesional.

A mi tutor, el Ing, Fidel Vallejo Gallardo, Ph.D., por su apoyo, asesoría y conocimientos brindados para que yo pueda culminar con éxito este trabajo.

Finalmente, a mis amigos, quienes supieron ser amigos desde el comienzo de esta etapa y por las experiencias compartidas.

ÍNDICE GENERAL

DECLARATORIA DE AUTORÍA

DICTAMEN FAVORABLE DEL PROFESOR TUTOR

CERTIFICADO DE LOS MIEMBROS DEL TRIBUNAL

CERTIFICADO ANTIPLAGIO

DEDICATORIA

AGRADECIMIENTO

ÍNDICE GENERAL

ÍNDICE DE TABLAS

ÍNDICE DE FIGURAS

RESUMEN

ABSTRACT

CAPÍTULO I. INTRODUCCIÓN..... 16

1.1. ANTECEDENTES..... 16

1.2. PROBLEMA 17

1.3. JUSTIFICACIÓN..... 17

1.4. OBJETIVOS..... 19

1.4.1. Objetivo general 19

1.4.2. Objetivos específicos..... 19

CAPÍTULO II. MARCO TEÓRICO..... 20

2.1. ESTADO DEL ARTE 20

2.2. MARCO TEÓRICO 22

2.2.1. Pirólisis 22

2.2.2. Pirólisis de biomasa y plásticos 22

2.2.3. Copirólisis..... 23

2.2.4. Productos obtenidos de la copirólisis de biomasa y plásticos 23

2.2.5. Tipos de sustratos 23

2.2.6. Catalizadores 24

2.2.7. Temperaturas y tipos de pirólisis..... 26

2.2.8.	Tiempo de reacción	27
2.3.	GLOSARIO DE TÉRMINOS	28
2.3.1.	Biodiésel	28
2.3.2.	Bioenergía:.....	28
2.3.3.	Biogás	29
2.3.4.	Biomasa	29
2.3.5.	Catalizador.....	29
2.3.6.	Conversión termoquímica.....	29
2.3.7.	Gasificación.....	29
2.3.8.	Gasificador.....	29
2.3.9.	Lecho fijo.....	29
2.3.10.	Lignina.....	29
2.3.11.	Materia prima	29
2.3.12.	Pirólisis	30
2.3.13.	Pirólisis rápida	30
2.3.14.	Pirólisis lenta	30
2.3.15.	Residuos, biomasa	30
2.3.16.	Residuos orgánicos.....	30
2.3.17.	Sustrato	30
2.3.18.	Volátil	30
CAPÍTULO III. METODOLOGÍA.....		31
3.1.	Tipo de Investigación	31
3.2.	Diseño de Investigación	31
3.3.	Técnicas de recolección de Datos	32
3.4.	Análisis Exploratorio de Datos (EDA).....	32
3.4.1.	Estadísticos descriptivos.....	32

3.4.2.	Distribución de variables	33
3.4.3.	Análisis comparativo por categorías.....	33
3.5.	Población de estudio y tamaño de muestra	33
3.6.	Hipótesis.....	34
3.7.	Métodos de análisis	34
3.8.	Procesamiento de datos	36
3.9.	Procedimiento.....	36
3.9.1.	Construcción de la Base de Datos	36
3.9.2.	Análisis y Procesamiento de la Información	38
3.9.3.	Desarrollo de Modelos Predictivos.....	41
CAPÍTULO IV. RESULTADOS Y DISCUSIÓN		43
4.1.	Análisis Estadístico Exploratorio	43
4.1.1.	Estadísticos Descriptivos.....	43
4.1.2.	Distribución de Variables Respuesta.....	44
4.1.3.	Distribución de Variables Operativas.....	45
4.1.4.	Composición de Biomasa	46
4.1.5.	Histogramas de Variables Respuesta.....	47
4.1.6.	Rendimientos por Tipo de Biomasa	48
4.1.7.	Rendimientos por Tipo de Plástico.....	49
4.1.8.	Rendimientos por Tipo de Catalizador.....	50
4.2.	Análisis de Correlación y Multicolinealidad.....	51
4.2.1.	Matriz de Correlación.....	51
4.2.2.	Análisis de Multicolinealidad (VIF).....	52
4.3.	Modelos de Predicción	54
4.3.1.	Modelo de Regresión Lineal Múltiple.....	54
4.3.2.	Modelo Random Forest	57

4.4.	Evaluación del Desempeño	58
4.4.1.	Métricas de Bioaceite	58
4.4.2.	Métricas de Biocarbón.....	59
4.4.3.	Métricas de Gas	60
4.4.4.	Métricas Generales	61
CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES.		63
5.1.	Conclusiones.....	63
5.2.	Recomendaciones	64
6.	REFERENCIAS BIBLIOGRÁFICAS	65
7.	ANEXOS.....	70

ÍNDICE DE TABLAS

Tabla 1. Resumen comparativo de modelos predictivos, variables y métricas de desempeño	20
Tabla 2. Definición de las Variables de Respuesta.....	38
Tabla 3. Tabla de Estadísticos Descriptivos — Base de datos	43
Tabla 4. Valores de VIF para Variables Predictoras	53
Tabla 5. Regresión Lineal Secuencial para cada Variable	54
Tabla 6. Coeficientes de Regresión Lineal	54
Tabla 7. Estadísticos del Modelo LM Propuesto.....	57
Tabla 8. Parámetros para el Modelo de Random Forest.....	58
Tabla 9. Comparación de R^2 entre Entrenamiento y Prueba	62
Tabla 10. Métricas de Desempeño en Conjunto de Prueba	62

ÍNDICE DE FIGURAS

Figura 1. Diagrama de flujo de procesamiento de datos.	36
Figura 2. Boxplot de Variables Respuesta (Rendimientos).....	45
Figura 3. Boxplot de Variables Operativas	46
Figura 4. Rendimiento de los Distintos Tipos de Biomasa	46
Figura 5. Boxplot de Composición de Biomasa.....	47
Figura 6. Histogramas de Variables Respuesta	48
Figura 7. Boxplot de Rendimientos por Tipo de Biomasa	49
Figura 8. Boxplot de Rendimientos por Tipo de Plástico	50
Figura 9. Boxplot de Rendimientos por Tipo de Catalizador.....	51
Figura 10. Matriz de Correlación de Variables	52
Figura 11. Factor de Inflación de Varianza (VIF).....	53
Figura 12. Evolución del RMSE con la Inclusión de Nuevas Variables.....	56
Figura 13. Evolución del MAE con la Inclusión de Nuevas Variables.....	56
Figura 14. Evolución del R2 con la Inclusión de Nuevas Variables	57
Figura 15. Gráficos Observado vs Predicho modelo LM Bioaceite – Entrenamiento y Prueba	58
Figura 16. Gráficos Observado vs Predicho modelo RF Bioaceite – Entrenamiento y Prueba	59
Figura 17. Gráficos Observado vs Predicho modelo LM Biocarbón – Entrenamiento y Prueba	59
Figura 18. Gráficos Observado vs Predicho modelo RF Biocarbón – Entrenamiento y Prueba	60
Figura 19. Gráficos Observado vs Predicho modelo LM Gas – Entrenamiento y Prueba	60
Figura 20. Gráficos Observado vs Predicho modelo RF Gas – Entrenamiento y Prueba	61

RESUMEN


La pirólisis es un proceso termoquímico de descomposición de materiales orgánicos en ausencia de oxígeno. La presente investigación tiene como objetivo analizar la influencia de las variables operativas y composicionales en la pirólisis de biomasa y plásticos a través del desarrollo de modelos predictivos basados en datos experimentales. Se consolidó una base de datos con un total de 740 observaciones provenientes de diversas publicaciones científicas. Las variables predictoras fueron temperatura, tiempo de residencia, proporción de biomasa, área superficial del catalizador, composición lignocelulósica, índice de Reactividad y el índice de Polaridad. Se analizaron los datos y se evaluaron mediante VIF para generar la selección de las variables comparando los modelos de Regresión Lineal Múltiple (LM) y Random Forest (RF). Los resultados mostraron que el modelo LM alcanzó valores de R^2 en prueba de 0.34 para bioaceite, 0.34 para biocarbón y 0.23 para gas, con una mejor capacidad de generalización respecto a RF, el cual presentó sobreajuste considerable con R^2 durante el entrenamiento de 0.87 a 0.89 en relación con el R^2 de prueba que obtuvo valores entre 0.28 a 0.32. La celulosa se identificó como la variable más correlacionada con el rendimiento de bioaceite con un $r = 0.452$, mientras que la temperatura aportó la mejora con mayor significancia al incorporarse al modelo. Los índices IR e IP presentaron VIF aceptables y contribuyeron a la descripción del comportamiento térmico de la biomasa.

Palabras clave: pirólisis, modelos predictivos, Random Forest, regresión lineal

ABSTRACT

Pyrolysis is a thermochemical process for the decomposition of organic materials in the absence of oxygen. This research aims to analyze the influence of operational and compositional variables on the pyrolysis of biomass and plastics through the development of predictive models based on experimental data. A database of 740 observations from various scientific publications was compiled. The predictor variables were temperature, residence time, biomass proportion, catalyst surface area, lignocellulosic composition, Reactivity Index, and Polarity Index. The data were analyzed and evaluated using Variable Inference Factor (VIF) to select the variables by comparing Multiple Linear Regression (ML) and Random Forest (RF) models. The results showed that the LM model achieved R^2 values of 0.34 for bio-oil, 0.34 for bio-char, and 0.23 for gas, demonstrating better generalizability compared to RF. RF exhibited considerable overfitting, with R^2 values during training ranging from 0.87 to 0.89 compared to the test R^2 values of 0.28 to 0.32. Cellulose content was identified as the variable most correlated with bio-oil yield ($r = 0.452$), while temperature provided the most significant improvement when incorporated into the model. The IR and IP indices showed acceptable VIF values and contributed to describing the thermal behavior of the biomass.

Keywords: pyrolysis, predictive models, Random Forest, linear regression



Reviewed by:
Marco Antonio Aquino
ENGLISH PROFESSOR
C.C. 1753456134

CAPÍTULO I. INTRODUCCIÓN

1.1.ANTECEDENTES

La pirólisis es un proceso de descomposición térmica que busca producir gases, líquidos y sólidos. El propósito principal del proceso de pirólisis es tener como productos combustibles sólidos o líquidos con la calidad óptima, es decir, con un alto contenido energético. Uno de los desafíos que pueden tener los productos de la pirólisis de biomasa es que comúnmente presentan características inadecuadas para su uso directo como combustibles puesto que, debido al sustrato empleado suele observarse que los productos poseen una alta concentración de oxígeno y humedad (Abnisa & Wan Daud, 2014). Es por ello que se emplean procesos adicionales como el refinamiento o tratamiento para que el producto final de la pirólisis alcance la calidad que se desea. Una estrategia planteada para este desafío es la pirólisis de biomasa y plásticos, cuyas variables de proceso pueden mejorar de forma notable la composición de los productos finales.

El plástico es uno de los inventos más cruciales realizado por el ser humano; sin embargo, la cantidad excesiva de los compuestos químicos que se encuentran en los residuos plásticos ha generado uno de los desafíos a los que se enfrenta la humanidad, la descomposición de los plásticos puede tardar más de mil años hasta descomponerse en relación con otros materiales.

Una iniciativa para combatir este desafío de la degradación de plástico es mediante el proceso de pirólisis de biomasa y plástico, este método permite obtener productos de alta calidad, tal como es el combustible y su papel fundamental dentro de los procesos industriales. Se ha determinado que la combinación de biomasa y plásticos crea un efecto sinérgico en este proceso (Oh & Seo, 2016). Mediante esta combinación se logra mantener un equilibrio en relación a la baja presencia de oxígeno que se halla en los plásticos. Así también, se logra que el proceso sea el óptimo mediante una reacción más equilibrada, lo que deriva en la obtención de productos de alta calidad respecto a su composición. La pirólisis de biomasa y plásticos contribuye a la minimización de la deposición de coque, cuyo desafío va más relacionado a la pirólisis de plásticos. El coque es un restante sólido carbonoso que se genera cuando el plástico entra en el proceso de degradación térmicamente, cuando este último empieza a degradarse suele observarse que existe una acumulación de obstrucción de este residuo en los reactores, lo que significa que el proceso no se da de la manera más adecuada y que existe una falta de eficiencia en este proceso. Para combatir este problema se ha propuesto combinar este proceso de pirólisis de plástico con biomasa, la biomasa en la reacción actúa como un agente capaz de reducir el coque mediante la interacción química de los compuestos oxigenados que se encuentran en la biomasa y las partes de hidrocarburos que se liberan de los plásticos. Esta interacción permite que el proceso se lleve a cabo sin problema puesto que, se evita la polimerización y la carbonización en la pirólisis. La propuesta de realizar una pirólisis de biomasa y plásticos es una vía prometedora que permite tener un proceso sostenible y amigable con el medio ambiente, se pretende reducir la contaminación ambiental por plásticos y biomasa y se aprovecha estos recursos para poder obtener productos servibles en los procesos industriales.

La pirólisis de biomasa y plásticos posee una ventaja considerable en relación al tratamiento que se les da a estos residuos mixtos, este proceso no necesariamente ocupa separar estos residuos antes del proceso, en comparación con otros procesos que necesitan realizar esta separación de forma exhaustiva, permite minimizar considerables costos y recursos que se deberían asignar al tratamiento previo de la biomasa y plásticos (Johansson et al., 2018). La pirólisis de biomasa y plástico ofrece una gestión integral de estos residuos donde se convierten conjuntamente en productos valiosos que van desde los combustibles, carbones hasta gases sintéticos. Este proceso es viable también en sociedades y países donde el flujo de biomasa y plásticos se da de forma excesiva y necesita un tratamiento para la correcta gestión de estos residuos, es por ello que, los países en desarrollo e industrias optan por realizar este proceso para la gestión de residuos por las diversas ventajas que posee la pirólisis.

1.2.PROBLEMA

La pirólisis de biomasa y plásticos representa una promisorio vía para la producción sostenible de compuestos químicos y combustibles. Sin embargo, la optimización de este proceso presenta varios desafíos por la complejidad de las variables que intervienen en la pirólisis de biomasa y plásticos, tales variables pueden ser: tipo de sustrato, tipo de catalizador, temperatura, tiempo de reacción, etc.

Esta complejidad que presentan las variables puede afectar a la comprensión y predicción de los productos finales obtenidos a partir de la pirólisis de biomasa y plásticos.

Las diversas variables que intervienen en este proceso pueden afectar también a la formación de compuestos que se pretenden obtener y deriva en la dispersión de resultados y el problema principal que es la dificultad de establecer las correlaciones entre variables y productos obtenidos, parte fundamental para la predicción de productos.

Este proceso se encuentra influido por diversos factores operativos y composicionales capaces de determinar la calidad y el tipo del producto que se obtiene. Sin embargo, la gestión de los residuos como la biomasa y el plástico, y el interés que este proceso implica en cuestión de aprovechamiento para la generación de compuestos de valor, aún presentan desafíos que hay que atacarlos para la optimización de este proceso, tales desafíos incluyen la falta de comprensión de las variables operativas y su importancia en la distribución y composición de los productos.

La falta de estudios, análisis de estas variables y de resultados contribuyen a que el proceso no se realice de la manera óptima que se desea.

Esta falta de conocimiento es la principal limitante que suele impedir que el proceso pueda ser optimizado y sea comprendido en su totalidad, es así que, surge el interés de poder aportar a la optimización de este proceso mediante un análisis exhaustivo de las variables realizando un enfoque analítico y cuantitativo.

1.3. JUSTIFICACIÓN

El impacto ambiental que generan los residuos plásticos y biomasa constituye uno de los más grandes problemas a los que tiene que enfrentar el ser humano en pleno siglo XXI. La degradación lenta de los plásticos y el mal manejo de residuos es una problemática

a la que frecuentemente se enfrente la humanidad y uno de los desafíos es la valorización tanto de biomasa como de plásticos para obtener productos de alto valor.

La pirólisis se considera uno de los procesos que contribuyen al correcto manejo de residuos y plásticos, dicho proceso permite obtener productos tales como bioaceite, biocarbón y biogás. Sin embargo, la pirólisis de biomasa y plásticos es complejo en relación a sus variables y la dispersión de resultados, variables como el tipo de sustrato, catalizadores, tiempo de reacción, temperatura, entre otros., presentan una gran complejidad en relación a su análisis, interpretación y correlación entre sí mismas.

A pesar de los estudios e investigaciones que se han realizado, no se presenta con claridad modelos predictivos que permitan analizar de forma completa y sistemática este proceso, la falta de conocimiento y comprensión limita la optimización de la pirólisis de biomasa y plásticos sin el debido aprovechamiento de la tecnología que se dispone en la actualidad.

En este contexto, la presente investigación se justifica en la necesidad de realizar un enfoque analítico, cuantitativo y predictivo que permita sistematizar los diversos estudios realizados por varios autores, estudios experimentales que cuenten con base de datos confiables y completas, con la finalidad de poder establecer correlaciones significativas entre las variables operativas y así, poder definir un modelo predictivo que permita el análisis completo del proceso de pirólisis de biomasa y plásticos.

Mediante el uso de diversas herramientas como regresiones lineales, no lineales, random forest, técnicas de machine learning, se pretende construir modelos de predicción que identifiquen las principales tendencias y ofrecer un análisis de la composición de los productos obtenidos, Este estudio no solo aporta a un avance científico respecto al tema de la pirólisis, sino que también sienta bases fundamentales para posteriores optimizaciones en el diseño y control de procesos a nivel industrial, aportando así a la correcta gestión de residuos mediante el aprovechamiento de las tecnologías que disponemos hoy en día.

Este estudio busca responder preguntas fundamentales:

¿cómo varía la composición de productos según el sustrato utilizado?

¿cuál es el efecto de los catalizadores en la formación de compuestos?

¿existen patrones emergentes al analizar múltiples variables, y es posible predecir la formación de compuestos específicos mediante modelos predictivos?

En consecuencia, este trabajo de investigación se justifica no solamente por su aporte a la gestión de residuos sino también a su relevancia dentro del impacto ambiental por la contribución de alto impacto al desarrollo de estrategias de economía circular y transición hacia estrategias sostenibles y amigables con el medio ambiente.

1.4. OBJETIVOS

1.4.1. Objetivo general

Analizar la influencia de las variables operativas en la pirólisis de biomasa y plásticos, mediante la recopilación y modelado de datos experimentales, para predecir la formación de compuestos químicos y combustibles de alto valor, contribuyendo a la optimización de procesos sostenibles.

1.4.2. Objetivos específicos

Recopilar una base de datos exhaustiva que integre variables operativas (tipo de sustrato, catalizadores, temperatura, tiempo) de estudios previos, con el propósito de consolidar información dispersa para su análisis sistemático.

Aplicar modelos de regresión y técnicas de aprendizaje automático a los datos recopilados, con el propósito de identificar patrones y correlaciones que expliquen la influencia de las variables en la composición de productos de la pirólisis.

Desarrollar modelos predictivos que estimen la formación de compuestos específicos (oxigenados, hidrocarburos) en función de las variables operativas, con el propósito de facilitar la optimización de procesos de pirólisis para aplicaciones sostenibles.

CAPÍTULO II. MARCO TEÓRICO.

2.1. ESTADO DEL ARTE

Tabla 1. Resumen comparativo de modelos predictivos, variables y métricas de desempeño

Referencia	Tipo de modelo empleado	Variables independientes (entradas)	Variables dependientes (salidas / pronosticadas)	Indicadores de desempeño del modelo
(Ferrer-Romero et al., 2019)	Modelo polinomial de segundo orden basado en Metodología de Superficie de Respuesta (RSM) bajo Diseño Compuesto Central (CCD). Modelo de regresión no lineal cuadrático.	Concentración de glucosa ($\text{g}\cdot\text{L}^{-1}$); concentración de extracto de levadura ($\text{g}\cdot\text{L}^{-1}$); concentración de peptona ($\text{g}\cdot\text{L}^{-1}$).	Producción de biomasa micelial ($\text{g}\cdot\text{L}^{-1}$); concentración de compuestos fenólicos totales ($\mu\text{g}\cdot\text{mL}^{-1}$).	Modelos estadísticamente significativos según ANOVA, con coeficientes de determinación elevados ($R^2 > 0,90$), indicando buena capacidad predictiva.
(Potnuri et al., 2023)	Modelo de aprendizaje automático basado en Regresión por Máquinas de Vectores de Soporte (Support Vector Regression, SVR). Modelo no lineal.	Características fisicoquímicas de biomasa y plásticos (C, H, N, cenizas, materia volátil); condiciones operativas; tipo de catalizador.	Rendimiento de bioaceite, biocarbón y biogás (% en masa).	$R^2 = 0,96$ (bioaceite), $0,93$ (biocarbón), $0,91$ (biogás); RMSE bajo, evidenciando alta precisión predictiva.
(Dong et al., 2022)	Modelos de aprendizaje automático: Random Forest (RF), Gradient Boosting Decision Tree (GBDT), XGBoost y AdaBoost.	Características fisicoquímicas de la biomasa (humedad, C, H, O); condiciones de pirólisis (temperatura final, velocidad de calentamiento).	Rendimiento de bioaceite, biocarbón y gas pirolítico.	Mejor desempeño con RF: $R^2 > 0,90$ (bioaceite), $0,85$ (biocarbón), $0,83$ (gas); MAE y RMSE reducidos.
(Mariyam et al., 2025)	Modelo polinomial de segundo orden mediante Metodología de Superficie de Respuesta (RSM) con diseño Box–Behnken (BBD).	Contenido de volátiles (%); temperatura de pirólisis ($^{\circ}\text{C}$); velocidad de calentamiento ($^{\circ}\text{C}\cdot\text{min}^{-1}$).	Rendimiento de bioaceite, biocarbón y gas pirolítico (%).	Coefficientes de determinación entre $R^2 = 0,922$ y $0,999$, indicando excelente ajuste del modelo.

(Cahanap et al., 2023)	Modelos de inteligencia artificial: Extreme Gradient Boosting (XGB), Random Forest (RF), Support Vector Regression (SVR) y Artificial Neural Network (ANN).	Propiedades de la biomasa; condiciones operativas; parámetros geométricos del reactor (relación H/D).	Rendimiento de bioaceite, biocarbón y gas.	Mejor desempeño con XGB: $R^2 > 0,95$ (bioaceite y gas), $R^2 \approx 0,92$ (biocarbón); RMSE $< 5\%$.
(Balsora et al., 2023)	Redes Neuronales Artificiales (ANN) multivariantes con diferentes combinaciones de entradas (proximal, elemental y bioquímico).	Análisis proximal, elemental y bioquímico de la biomasa; condiciones de pirólisis.	Rendimiento de bioaceite, biocarbón y gas.	Mejor desempeño ANN-PUB: $R^2 \approx 0,97$; RMSE $< 5,6\%$; MAE $\approx 0,04$.
(Ortiz & Piloto, 2022)	Red Neuronal Artificial (ANN) tipo feedforward entrenada con algoritmo BP/LM.	Lignina, celulosa, hemicelulosa; temperatura de pirólisis; velocidad de calentamiento; tamaño de partícula; caudal de N_2 .	Rendimiento de bioaceite (%).	Coefficiente de correlación $R = 0,9739$; MAE = $1,72\%$, indicando alta precisión del modelo.
(Blanco, 2014)	Modelo fenomenológico–cinético semi–global, unidimensional y transitorio, basado en balances de masa y energía.	Tamaño de partícula; temperatura del reactor; velocidad del gas fluidizante; tiempo de residencia de gases y partículas.	Rendimiento de bioaceite, gases y carbón.	Modelo validado mediante ajuste con datos experimentales, reproduciendo rendimientos de bioaceite cercanos al 60% .

2.2. MARCO TEÓRICO

2.2.1. Pirólisis

Es una ruta para gestionar de manera adecuada los residuos, se basa en la descomposición térmica de polímeros en ausencia de oxígeno, este proceso normalmente se da en temperaturas desde los 300 °C hasta los 900 °C. A partir de la pirólisis se pueden obtener productos sólidos, líquidos y/o gaseosos, estos van a depender de las condiciones a las que esté sometida la pirólisis, dichas condiciones son temperatura, tipo de sustrato, tipo de catalizador, presión, velocidad de calentamiento y velocidad de residencia (Gil et al., 2019).

2.2.2. Pirólisis de biomasa y plásticos

La pirólisis puede emplear biomasa y residuos plásticos como sustrato, está basado en la descomposición térmica con un bajo contenido de oxígeno obteniéndose productos que pueden ser sólidos, líquidos y gaseosos (Wang et al., 2021). Esta conversión de masa en productos de alto valor está sostenida bajo varios estudios que involucran termodinámica, transferencia de calor y masa, así como catálisis heterogénea (Ansari et al., 2021).

Dentro de la caracterización de las materias primas podemos encontrar algunos aspectos importantes a considerar tales como el análisis elemental (C, H, N, S, O), el contenido de cenizas y humedad, contenido de lignocelulosa y el poder calorífico que puedan poseer las materias primas (Suriapparao & Tejasvi, 2022). Estas características juegan un papel importante en la predicción del comportamiento térmico tanto de la biomasa como de los plásticos, contribuyendo a la optimización de este sistema de conversión denominado pirólisis.

Respecto a los tipos de reactor que se emplean para el proceso de pirólisis, pueden ser de lecho fijo, lecho fluidizado, reactores de tambor rotatorio y reactores de microondas híbridos con catalizadores. La eficiencia del proceso de pirólisis y el rendimiento de los productos que se obtienen están condicionados por el tipo de reactor.

Las condiciones operativas como la temperatura, tiempo de residencia, tamaño de partícula y el tipo de sustrato son parámetros que tienen una influencia directa sobre la calidad energética de los productos y su composición (Wang et al., 2021).

Existen varias técnicas analíticas empleadas en la pirólisis que permiten obtener resultados confiables. A continuación, se detallan las técnicas más utilizadas:

- Análisis Termogravimétrico (TGA), permite realizar un análisis exhaustivo del perfil de degradación térmica y la cinética de descomposición.
- Cromatografía de Gases (GC) y Espectrometría de Masas (MS), permite definir cuáles son los compuestos orgánicos volátiles que se encuentran en el bio-oil y el gas pirolítico.
- Espectroscopía Infrarroja por Transformada de Fourier (FTIR), se emplea para identificar los principales grupos químicos que se encuentran en los productos sólidos y líquidos de la pirólisis (Suriapparao & Tejasvi, 2022).

2.2.3. Copirólisis

La copirólisis es un proceso termoquímico en el que la biomasa y los plásticos se descomponen a altas temperaturas en ausencia de oxígeno, lo que provoca la formación de combustibles líquidos denominados como bio-petróleo, junto con gases y sólidos de alta calidad y valor energético. Cuando la biomasa, que suele contener altas concentraciones de oxígeno y menor estabilidad, se mezcla con plásticos ricos en hidrógeno y carbono, se produce un efecto sinérgico que mejora la calidad del bio-petróleo resultante. Como resultado, el bio- petróleo presenta un incremento en su poder calorífico, menor acidez y niveles reducidos de oxígeno, lo que lo convierte en un combustible más eficiente y práctico para diferentes usos energéticos (Ojha & Vinu, 2018).

2.2.4. Productos obtenidos de la copirólisis de biomasa y plásticos

El proceso de conversión genera tres tipos de productos: líquidos, gases y residuos sólidos. Los líquidos incluyen bioaceites y compuestos químicos como hidrocarburos aromáticos y compuestos oxigenados. Estos líquidos son valiosos ya que pueden utilizarse tanto como combustibles alternativos o como materias primas para la producción de productos químicos de alto valor en procesos industriales.

Los gases son producto del proceso de pirólisis, podemos encontrar diversos hidrocarburos destacando los más relevantes como monóxido de carbono (CO), dióxido de carbono (CO₂), hidrógeno (H₂) y metano (CH₄). Estos gases productos de la pirólisis son empleados comúnmente como combustibles para la elaboración de productos químicos puesto que son muy eficientes cuando se trata de su aplicación en diferentes ámbitos industriales.

Así también, de la pirólisis se obtiene carbón o char. El carbón puede ser empleado en distintos ámbitos industriales pero su aplicación principal suele ser que es utilizado como combustible y también para optimizar la fertilidad del suelo. Por ello, es considerado un material con aplicaciones eficientes en prácticas agrícolas y sectores energético (Wang et al., 2021).

2.2.5. Tipos de sustratos

2.2.5.1. Biomasa

Los recursos de biomasa provienen de una amplia variedad de fuentes que pueden convertirse mediante pirólisis en energía y en otros productos útiles. Dentro de estos se encuentran los residuos provenientes de madera y de bosques, incluyendo ramas, hojas, arbustos y pastos; los residuos generados en las actividades agrícolas provenientes de cultivos de paja, tallos y mazorcas de maíz. También se consideran las semillas de *Jatropha curcas*, pasto varilla y algas. La industria alimentaria aporta otra fuente significativa a través de sus residuos y subproductos, especialmente de las cáscaras de nuez de café y otras variedades de nueces, así como de la ganadería, que proporciona biomasa en forma de estiércol, una materia orgánica, que es rica en nitrógeno y fósforo, además, de las grasas animales procedentes de la cría de animales. Adicionalmente, se consideran los residuos

humanos procedentes de plantas de tratamiento de aguas residuales y residuos orgánicos de sistemas municipales de gestión de residuos sólidos (Wang et al., 2021).

2.2.5.2.Plásticos

Los plásticos se clasifican en dos categorías principales: termoplásticos y termosets. Los termoplásticos incluyen polímeros como el polietileno (PE), polipropileno (PP), cloruro de polivinilo (PVC), poliestireno (PS), polietileno tereftalato (PETE) y nylons; estos materiales son ideales para procesos de pirólisis debido a su capacidad de fundirse y moldearse repetidamente cuando están expuestos al calor, lo que les permite recuperar energía y generar subproductos útiles, incluyendo aceites líquidos y gases combustibles. Por otro lado, los termosets incluyen poliuretanos y epoxi, que, a diferencia de los termoplásticos, cuando estos han pasado por un proceso de curado, no pueden ser remodelados, limitando así su reciclaje mediante pirólisis (Burra & Gupta, 2018).

2.2.6. Catalizadores

Un catalizador es una sustancia que acelera las reacciones químicas sin ser consumida ni alterada permanentemente en el proceso. En estudios que involucran la copirólisis de plásticos y biomasa sólida, los catalizadores basados en zeolita corresponden a la opción más utilizada. Las zeolitas son sólidos tridimensionales que presentan una estructura porosa y son valoradas por su capacidad para descomponer moléculas de hidrocarburos grandes y para facilitar procesos de deshidratación, dando como resultado moléculas ramificadas, cíclicas y compuestos aromáticos pequeños. La funcionalidad de los catalizadores de zeolita radica en su estructura y en el tamaño de los poros, debido a que esto les permiten interactuar selectivamente con moléculas específicas (Wang et al., 2021).

2.2.6.1.Copirólisis con catalizador basado en ZSM5

El ZSM5 presenta un tamaño de poro medio (~0,52 nm) y corresponde al catalizador más eficiente entre las zeolitas (Bhoi et al., 2020). Tiene una alta estabilidad térmica y puede soportar temperaturas superiores a 1100 °C sin cambiar su estructura (Hoff et al., 2016). El uso de ZSM5 en la copirólisis catalítica ayuda a mantener la actividad catalítica para producir hidrocarburos monoaromáticos y reducir la formación de compuestos poliaromáticos. El HZSM5 también tiene una baja tasa de desactivación y puede reutilizarse, lo que lo convierte en una opción importante para producir altos rendimientos de aceite de pirólisis e hidrocarburos (Bhoi et al., 2020).

2.2.6.2.Copirólisis con carbón activado

Recientemente, los catalizadores de carbón activado (AC) se han popularizado porque ofrecen beneficios importantes en la copirólisis catalítica (CFP) de residuos plásticos mezclados con materiales lignocelulósicos. En comparación con otros catalizadores como la zeolita ZSM-5, el AC resulta más económico, especialmente cuando se produce a partir de residuos agrícolas o carbón (Zhu et al., 2015).

El carbón activado ofrece una ventaja sobre otros catalizadores debido a su notable resistencia a la desactivación, producida por su estructura jerárquica de poros, que se

combina con mesóporos y microporos, además de su carácter no ácido o ligeramente ácido (Eibner et al., 2017).

Cuando el ácido fosfórico actúa como agente activador, el AC puede incorporar diversos grupos funcionales con fósforo en su estructura, incluyendo -C-P-O y -C-O-P. Además, el carbón activado posee abundantes grupos funcionales que contienen oxígeno y fósforo, los cuales actúan como sitios catalíticamente activos que facilitan tanto la desoxigenación como las reacciones de craqueo.

En aplicaciones de co-pirólisis de biomasa y polímeros, los catalizadores de carbón activado que presentan estructuras microporosas y grupos funcionales activos en la superficie han mostrado un rendimiento catalítico prometedor (Zhang et al., 2018).

2.2.6.3. Copirólisis con catalizador basado en biochar

Los catalizadores presentan un enfoque más eficiente energéticamente para producir compuestos específicos en comparación con la degradación térmica directa de biomasa sólida y plásticos, que implica el uso de temperaturas muy altas y tiende a generar subproductos no selectivos. En la copirólisis, se han empleado diversos catalizadores, incluyendo zeolitas y metales como níquel (Ni), zinc (Zn), aluminio (Al) y potasio (K), para aumentar la producción de hidrógeno; no obstante, estos catalizadores se enfrentan a complicaciones como intoxicación química, sinterización y mala dispersión de los sitios activos metálicos (Gin et al., 2021).

El biochar es un material que puede provenir de diversas fuentes, su estructura suele ser ajustable y se caracteriza por tener alta porosidad. Es muy aplicado en fines industriales por sus características ya mencionadas y por su capacidad de actuar como catalizador. Como catalizador ha arrojado varios resultados positivos al ser empleado en procesos químicos contribuyendo a la formación de alquitrán, la esterificación, la hidrogenación y la reducción de oxígeno (Chi et al., 2021).

En la co-pirólisis de biomasa y plásticos, el biochar favorece la producción en conjunto de gas de síntesis y bioaceite. El biochar funciona como fuente térmica durante el proceso, facilitando la descomposición de los materiales en gases y líquidos combustibles. El syngas producido puede ser utilizado para la generación de energía, por otro lado, el bioaceite puede actuar como combustible en diversas aplicaciones. Los resultados de estudios revelan que el uso de biochar durante el procedimiento incrementa la concentración de compuestos tales como ácido acético y fenoles en el bioaceite, además de aumentar la calidad del syngas (Ren et al., 2014).

A pesar de su similitud en propiedades fisicoquímicas, desde un punto de vista económico el biochar representa una alternativa más rentable frente al carbón activado (CA) debido a que requiere menos energía y químicos durante su preparación. Aunque algunos investigadores siguen prefiriendo el carbón activado como catalizador, se ha demostrado que el biochar puede cumplir con funciones catalíticas comparables (Zoroufchi Benis et al., 2022).

Las condiciones de pirólisis utilizadas para producir biochar son factores críticos que influyen tanto en su eficiencia catalítica como en su costo. Adicionalmente, el biochar posee características superficiales distintivas que incluyen alta porosidad, gran área superficial y

elevadas concentraciones de compuestos aromáticos y minerales (Selvam S & Paramasivan, 2022).

2.2.6.4. Copirólisis con catalizador basado en metales de transición y metales alcalinos/alcalinotérreos

Los metales de transición funcionan como buenos catalizadores debido a que pueden intercambiar estados de oxidación, formar complejos coordinados con los reactivos y donar electrones. Se han aplicado como una respuesta eficiente y de bajo costo en la pirólisis catalítica de biomasa para producir biocombustibles, químicos y materiales basados en carbono (Iliopoulou et al., 2012).

Los metales de transición como Ni, Co, Fe y Mn corresponden a minerales esenciales en el crecimiento de las plantas y, por tanto, se encuentran comúnmente en la biomasa. Al someterse a copirólisis, la biomasa que contiene estos metales de transición junto con otros residuos sólidos afecta al desarrollo del proceso (Wang et al., 2020). El efecto de los metales alcalinos y alcalinotérreos (AAEM) es diferente según su descomposición en mezclas de plástico y biomasa sólida durante la copirólisis. Estos catalizadores compiten en el proceso para reducir el nivel de oxígeno en el aceite de pirólisis producido (Stefanidis et al., 2016). Un óxido de metal con características básicas soportado sobre carbono de alta superficie se utiliza para preparar un catalizador eficiente para la producción de aceite de pirólisis de alta energía desde lignina que puede utilizarse como un aditivo para combustibles (Ryu et al., 2019).

2.2.7. Temperaturas y tipos de pirólisis

La pirólisis es un proceso termoquímico bastante investigado debido a su capacidad para transformar biomasa y plásticos en productos de valor como bioaceite, biochar y gas de síntesis (syngas). La transformación se lleva a cabo en ausencia total o parcial de oxígeno para evitar la combustión y favorecer la degradación térmica de materiales orgánicos (Ogunkanmi et al., 2018). En la pirólisis, la temperatura de operación es uno de los parámetros críticos que afectan la cantidad y calidad de los productos. Dependiendo de la temperatura aplicada, se clasifica como pirólisis lenta, rápida o ultrarrápida, cada una generando diferente proporción de productos sólidos, líquidos y gases (Inayat et al., 2022).

La pirólisis lenta se caracteriza por efectuarse a temperaturas comprendidas entre 300 y 500° C, es ideal para la formación de biochar que suele ser el 45% del total de los productos de la pirólisis cuando se da en estas condiciones (Ogunkanmi et al., 2018). Cuando la pirólisis se efectúa en dichas temperaturas, el biochar suele generarse con mayor facilidad gracias a que la degradación térmica que se produce comúnmente es más controlada. El biochar bajo estas condiciones se considera muy valioso e ideal para aplicaciones con fines agrícolas, como absorbente de contaminación y así también como un catalizador muy efectivo. Si se pretende maximizar el rendimiento sólido, la pirólisis lenta es la ideal puesto que bajo sus condiciones se puede obtener un biochar con características específicas.

Mientras que, cuando se pretende obtener productos líquidos, es ideal que se emplee la pirólisis rápida, que se caracteriza por operar en temperaturas comprendidas entre 450 y 700 °C. A este nivel térmico, se favorece la formación de bioaceite, un líquido denso

compuesto por una mezcla compleja de compuestos orgánicos oxigenados, hidrocarburos y compuestos aromáticos. El rendimiento de bioaceite en este tipo de proceso puede llegar a representar hasta el 75 % de los productos obtenidos (Ogunkanmi et al., 2018). Esta eficiencia en la producción de líquidos convierte a la pirólisis rápida en una tecnología especialmente atractiva para la obtención de combustibles renovables. No obstante, el bioaceite crudo suele presentar una elevada acidez, contenido de agua y cierta inestabilidad térmica, por lo que en la mayoría de los casos requiere procesos de mejora (como hidrogenación o destilación) antes de su uso como combustible.

Por su parte, la pirólisis ultrarrápida se lleva a cabo a temperaturas superiores a los 800 °C y se enfoca principalmente en la producción de gases no condensables, conocidos como syngas. Este gas de síntesis está compuesto por una mezcla de hidrógeno (H_2), monóxido de carbono (CO), dióxido de carbono (CO_2), metano (CH_4), etano (C_2H_6) y etileno (C_2H_4) (Ghenai et al., 2019; Toscano Miranda et al., 2021). A temperaturas tan elevadas, la materia prima se descompone de forma casi instantánea, minimizando la formación de biochar y bioaceite, y maximizando la generación de gases combustibles. El syngas resultante tiene múltiples aplicaciones industriales, incluyendo su uso como fuente de energía térmica y eléctrica, así como materia prima para procesos como la síntesis de amoníaco, metanol o combustibles sintéticos mediante rutas como la Fischer–Tropsch.

El efecto de la temperatura en el proceso de pirólisis no solo incide en la proporción relativa de los productos generados, sino también en su composición química y en las propiedades energéticas de cada fracción. En líneas generales, a mayor temperatura se incrementa la fragmentación molecular, lo que favorece la liberación de compuestos volátiles y la formación de gases, mientras que a temperaturas más bajas predomina la carbonización del material (Inayat et al., 2022).

2.2.8. Tiempo de reacción

En los procesos de pirólisis, uno de los parámetros operativos más influyentes en la distribución y calidad de los productos obtenidos es el tiempo de residencia térmica, entendido como el intervalo durante el cual los materiales permanecen dentro del reactor a la temperatura objetivo del proceso. Este tiempo está estrechamente relacionado con el tipo de pirólisis que se lleve a cabo (lenta, rápida o ultrarrápida), y su efecto es determinante en la formación relativa de biochar (residuo sólido), bioaceite (fracción líquida condensable) y syngas (gases no condensables). Cuanto mayor es el tiempo de residencia, más extensa es la descomposición térmica y secundaria de los compuestos intermedios, lo que puede beneficiar o perjudicar la formación de determinados productos, dependiendo del objetivo del proceso.

En el caso de la pirólisis lenta, también conocida como carbonización o pirólisis convencional, el tiempo de residencia puede extenderse hasta 2 horas, en condiciones de temperaturas moderadas que oscilan entre 300 y 500 °C, tasas de calentamiento lentas (aproximadamente 0.1–1 °C/min), y partículas de gran tamaño, típicamente entre 5 y 50 mm (Ogunkanmi et al., 2018). El prolongado tiempo de residencia también permite una mayor carbonización y eliminación de compuestos oxigenados, aunque limita la producción de líquidos y gases (Inayat et al., 2022).

Por otro lado, en la pirólisis rápida, el enfoque cambia drásticamente. Esta modalidad opera en un rango de temperaturas más elevado, entre 450 y 700 °C, y se caracteriza por tiempos de residencia mucho más breves, del orden de 20 segundos o menos, así como tasas de calentamiento significativamente mayores, generalmente entre 10 y 200 °C/s, y partículas de menor tamaño, inferiores a 1 mm (Ogunkanmi et al., 2018). A temperaturas altas, la degradación térmica ocurre de forma inmediata, y con ello se ve favorecida la condensación de compuestos volátiles. Como resultado, el bioaceite se convierte producto dominante con capacidad de alcanzar hasta el 75 % del rendimiento total del proceso. Este tipo de pirólisis comúnmente empleada cuando se pretender obtener productos como biocombustibles líquidos (Inayat et al., 2022).

En contraste, la pirólisis ultrarrápida representa una categoría aún más extrema en términos de velocidad de reacción. Se lleva a cabo a temperaturas superiores a 800 °C, con tiempos de residencia extremadamente cortos, cercanos a 1 segundo, y tasas de calentamiento que superan los 1000 °C/s (Ghenai et al., 2019; Toscano Miranda et al., 2021). Esta modalidad está orientada a maximizar la formación de gases no condensables, conocidos como syngas, una mezcla combustible compuesta principalmente por hidrógeno (H₂), monóxido de carbono (CO), dióxido de carbono (CO₂), metano (CH₄), etano (C₂H₆) y etileno (C₂H₄). La pirólisis ultrarrápida se utiliza principalmente en aplicaciones donde se busca una conversión total de la biomasa o residuos en productos gaseosos para su uso energético inmediato (como en calderas de combustión interna, turbinas de gas o celdas de combustible), o como materia prima para procesos químicos posteriores, como la síntesis de amoníaco, metanol o combustibles sintéticos (Inayat et al., 2022).

En este contexto, la copirólisis, es decir, la pirólisis conjunta de biomasa y residuos plásticos se alinea operativamente con los parámetros característicos de la pirólisis rápida, tanto en cuanto a temperatura como en tiempos de residencia. Aunque muchos estudios centrados en la copirólisis enfatizan la variación de temperaturas (entre 300 y 500 °C) y proporciones de residuos plásticos (entre 30 % y 70 %) como variables críticas, se asume que los tiempos de residencia aplicados se mantienen en el orden de segundos a pocos minutos, similares a los de la pirólisis rápida (Raza et al., 2022). Esta duración es necesaria para garantizar la formación eficiente de bioaceite, evitando que las moléculas condensables sean sobrecalentadas o craqueadas hacia compuestos gaseosos, lo cual disminuiría el rendimiento líquido (Inayat et al., 2022).

2.3. GLOSARIO DE TÉRMINOS

2.3.1. Biodiésel

Combustible de transporte biodegradable para motores diésel, producido mediante la transesterificación de aceites o grasas de origen orgánico. Puede utilizarse como sustituto o como componente del combustible diésel (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.2. Bioenergía:

Energía generada a partir de materiales de biomasa (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.3. Biogás

Mezcla gaseosa que contiene dióxido de carbono y metano, producto de la digestión anaeróbica de materia orgánica (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.4. Biomasa

Recurso energético derivado de materia orgánica. Entre estos se incluyen la madera, los residuos agrícolas y otros materiales celulares que pueden generar energía térmica mediante la combustión. También se incluyen las algas, las aguas residuales y otras sustancias orgánicas que pueden producir energía a través de procesos químicos (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.5. Catalizador

Sustancia que aumenta la velocidad de una reacción química sin ser consumida ni producida por esta. Las enzimas son catalizadores de diversas reacciones bioquímicas (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.6. Conversión termoquímica

El empleo del calor para inducir cambios químicos en materias y así obtener productos energéticos (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.7. Gasificación

Cualquier proceso químico o térmico que convierte materia prima en gas de combustible (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.8. Gasificador

Utilizado para convertir un combustible sólido en forma gaseosa mediante un procedimiento termicoquímico (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.9. Lecho fijo

Un conjunto de partículas muy espaciadas a través de las cuales los gases se mueven hacia arriba o hacia abajo con fines de gasificación o combustión (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.10. Lignina

Polímero complejo que se encuentra en las plantas vasculares y en la madera, brindándoles firmeza y rigidez estructural. Cuando es quemado libera energía en forma de electricidad (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.11. Materia prima

Cualquier material que se usa directamente como combustible o que se convierte en otros tipos de combustibles o productos energéticos. Las materias primas bioenergéticas son las fuentes principales de biomasa, entre sus ejemplos más representativos se encuentran el maíz, residuos de cosecha y las plantas leñosas (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.12. Pirólisis

La ruptura de macromoléculas complejas mediante calentamiento en ausencia de oxígeno, que resulta en la formación de combustibles sólidos, líquidos y gaseosos (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.13. Pirólisis rápida

Proceso pirólitico que ocurre durante un período muy corto, y produce mayores cantidades de un producto combustible que incluyen aceites primarios hasta olefinas y aromáticos, dependiendo de la severidad de las condiciones (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.14. Pirólisis lenta

Conversión térmica de biomasa en combustible mediante calentamiento lento a menos de 450 °C (842 °F), en ausencia de oxígeno (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.15. Residuos, biomasa

Subproductos que se generan del procesamiento de todo tipo de biomasa, la cual tiene potencial energético significativo. Por ejemplo, la fabricación de productos de madera sólida y pulpa a partir de troncos produce corteza, virutas, aserrín y licores de pulpa usados. Estos residuos, ya recolectados en las instalaciones de procesamiento, resultan ser fuentes convenientes y rentables de biomasa para la generación de energía (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.16. Residuos orgánicos

Materiales orgánicos excedentes o de desecho derivados de la biomasa, incluyendo productos, desechos y subproductos de la producción y procesamiento, restos, fluidos corporales, excrementos o efluentes derivados de plantas, animales o microorganismos que han sido previamente utilizados, procesados, preprocesados o permanecen después de que haya ocurrido su producción o uso primario (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.17. Sustrato

La base sobre la que vive un organismo o sobre la que actúa una sustancia (como una enzima) (U.S. DEPARTMENT OF ENERGY, 2016).

2.3.18. Volátil

Material sólido o líquido que se vaporiza fácilmente (U.S. DEPARTMENT OF ENERGY, 2016).

CAPÍTULO III. METODOLOGÍA.

3.1. Tipo de Investigación

La investigación se desarrolla bajo un enfoque cuantitativo, con un alcance correlacional–predictivo y un diseño no experimental. Se trabaja con datos numéricos provenientes de estudios de pirólisis y copirólisis de biomasa y plásticos, lo que permite medir con precisión variables operativas —como la temperatura, el tiempo de residencia, la proporción biomasa/plástico, el tipo de catalizador y el área superficial— y modelar su relación con los rendimientos trifásicos (bioaceite, biocarbón y gas).

El carácter correlacional–predictivo responde a la necesidad de identificar asociaciones entre variables y construir modelos capaces de estimar resultados sin manipular directamente las condiciones experimentales. Este enfoque resulta pertinente cuando la intervención sobre las variables no es posible o no es ética, y se requiere comprender la fuerza y dirección de las relaciones para generar predicciones confiables (Gallardo, 2025). Además, Haro Sarango et al. (2024) indican la importancia de la selección de este diseño para generar modelos predictivos que puedan ser aplicados a procesos industriales sostenibles.

Por ello, el estudio realiza el análisis de patrones y relaciones estadísticas desde datos secundarios los cuales se integrarán en una base consolidada, lo que garantiza la trazabilidad, reproducibilidad y comparabilidad de las distintas fuentes. Este proceso está alineado con las buenas prácticas de investigación cuantitativa que se aplica a entornos industriales y ambientales (Hernández-Sampieri & Mendoza, 2021).

3.2. Diseño de Investigación

El diseño es no experimental, transversal y correlacional–predictivo. Se analizan registros experimentales previamente reportados, sin intervención sobre las variables independientes. Se estudian las relaciones entre condiciones operativas (tipo de biomasa, tipo de plástico, catalizador, temperatura, tiempo de residencia y área superficial) y los rendimientos observados, en un único momento de análisis.

El corte transversal permite observar el comportamiento de las variables desde un punto específico en el tiempo; por su parte, el componente correlacional – predictivo da la posibilidad de establecer relaciones y construir modelos estadísticos y de aprendizaje automático los cuales puedan estimar como se distribuyen los productos en ciertas condiciones específicas. Este diseño se aplica cuando la replicación experimental suele ser costosa o inviable y la integración de varias fuentes ayuda a mejorar la robustez del análisis (Martínez, 2020). Según la idea de Haro Sarango et al. (2024) destacan que este tipo de enfoque es esencial para la construcción de modelos predictivos aplicados a procesos industriales sostenibles.

En la práctica, el diseño contempla:

- **Caracterización:** análisis descriptivo y exploratorio (EDA).
- **Inferencia:** pruebas de correlación y diferencias de medias para asociaciones significativas.
- **Predicción:** modelado mediante regresiones lineales/polinómicas y Random Forest.

- **Validación:** evaluación con métricas de desempeño (R^2 , RMSE, MAE) y validación cruzada.

3.3. Técnicas de recolección de Datos

La recolección de datos se realizó mediante una revisión documental sistemática de literatura científica y técnica publicada en revistas indexadas, repositorios institucionales y bases de datos académicas. Se aplicaron criterios de inclusión y exclusión previamente definidos para garantizar la calidad y relevancia de la información.

Los datos obtenidos son de las variables operativas de procesos de pirólisis y copirólisis de biomasa y plásticos tales como son el tipo de sustrato, tipo de plástico, proporción biomasa/plástico, temperatura, tiempo de residencia, catalizador y área superficial. De igual manera, se registraron los rendimientos de bioaceite, biocarbón y gas obtenidos a partir de cada estudio.

La técnica documental fue complementada con la elaboración de la base de datos limpia en Excel, en la cual se homogenizaron unidades, se comprobó los balances de masa y se aplicó una normalizaron de los rendimientos cuando el desbalance era menor al 5%. Para esto se utilizó la siguiente relación:

$$\text{Desbalance de masa (\%)} = \frac{\text{Masa de productor reportada} - \text{Masa de reactivos}}{\text{Masa de reactivos}} \times 100$$

Cuando el valor obtenido fue $\leq 5\%$, se procedió a ajustar proporcionalmente los rendimientos de bioaceite, biocarbón y gas, manteniendo la suma igual al 100%. Este procedimiento asegura la trazabilidad y reproducibilidad de los resultados, ya que permite validar la coherencia de los datos experimentales y garantizar comparabilidad entre estudios. Según Kitchenham et al. (2020) destacan la importancia de aplicar revisiones sistemáticas para asegurar la validez de los datos en investigaciones técnicas. De igual forma, Snyder (2021) subraya que las revisiones de literatura constituyen una metodología esencial para garantizar la calidad y consistencia de los resultados en estudios científicos.

3.4. Análisis Exploratorio de Datos (EDA)

Antes de aplicar modelos estadísticos y de aprendizaje automático para predecir los rendimientos de productos derivados de la pirólisis de biomasa y plásticos, se llevó a cabo un Análisis Exploratorio de Datos (EDA). Este procedimiento permitió comprender la estructura del conjunto de datos, identificar patrones, detectar valores atípicos y evaluar la coherencia de las variables operativas y composicionales. El EDA es un proceso que permite garantizar la validez de los modelos predictivos y sirve para interpretar de forma adecuada la influencia de las variables en los rendimientos de bioaceite, biocarbón y gas (Deng et al., 2025).

3.4.1. Estadísticos descriptivos

Estos resultados permiten caracterizar los límites de operación de la base de datos y así evaluar la variabilidad del experimento. En estudios recientes, Rajpurohit et al. (2025) indican que la sistematización de datos experimentales es indispensable para mejorar la capacidad predictiva de los modelos y garantizar de esta forma que las estimaciones tengan mayor confiabilidad en los rendimientos de bioaceite, biocarbón y gas.

La temperatura posee un rango amplio que va desde los 350 a 640 °C, lo cual indica que la base de datos integra estudios de pirólisis lenta, rápida y catalítica. El tiempo de residencia está concentrado alrededor de los 30 a 100 segundos, característica de una pirólisis rápida. La proporción biomasa/plástico obtuvo una alta variabilidad, lo cual es ideal para analizar efectos sinérgicos. Por otro lado, el área superficial tiene una mayor dispersión, lo cual se espera por la utilización de catalizadores como ZSM-5, Ni/Al₂O₃ y biochar activado. Finalmente, los rendimientos tienen coherencia, en donde el bioaceite y biocarbón tienden a reducirse cuando incrementa la fracción gaseosa, lo que refleja el craqueo secundario (Al-Maadeed, 2023).

3.4.2. Distribución de variables

Los histogramas muestran que la temperatura presenta una distribución bimodal, lo que refleja dos grupos experimentales: pirólisis moderada (380–450 °C) y catalítica/rápida (520–620 °C). El rendimiento de bioaceite se concentra en 35–45 %, mientras que el gas alcanza valores superiores a los 55%, asociados al uso de catalizadores ácidos como ZSM-5. La distribución del área superficial se observa sesgada hacia la derecha, característica típica de materiales porosos (Baranitharan et al.,(2024).

3.4.3. Análisis comparativo por categorías

- **Biomasa:** la cáscara de coco (alta lignina) produce más biocarbón; el aserrín (alta celulosa) más bioaceite; la cáscara de arroz (altas cenizas) menos bioaceite.
- **Plásticos:** PE (alto H/C) favorece bioaceite; PS (aromático) favorece gas; PVC (cloro) afecta catalizadores.
- **Catalizadores:** ZSM-5 aumenta gas y aromáticos; Ni/Al₂O₃ favorece bioaceite; biochar tiene efecto moderado (Al-Maadeed, 2023).

El EDA permite caracterizar como varía el conjunto de datos, identificando relaciones y validando la coherencia del Dataset. Este proceso es importante para asegurar la calidad de los modelos predictivos, y que se alinean con estudios recientes en donde se destaca la importancia de integrar análisis exploratorios previo a aplicar técnicas de modelado (Deng et al., 2025). También, Rajpurohit et al. (2025) indican que la sistematización de datos experimentales puede fortalecer la capacidad de predicción y mejora la confiabilidad de los resultados finales.

3.5.Población de estudio y tamaño de muestra

La población de estudio estuvo constituida por un total de 62 publicaciones científicas y técnicas que reportan resultados experimentales de pirólisis y copirólisis de biomasa y plásticos. De ellas, se incluyeron 45 artículos de revistas indexadas, 10 tesis de posgrado y 7 reportes técnicos publicados entre 2010 y 2025, seleccionados bajo criterios de relevancia, rigor metodológico y disponibilidad de datos completos.

A partir de esta población extraída de estudios previos, se construyó una base de datos limpia que integró un total de 740 observaciones experimentales. Cada observación está asignada a un registro único de condiciones operativas con su respectivo tipo de biomasa,

tipo de plástico, catalizador, temperatura, tiempo de residencia y área superficial) y sus rendimientos asociados (bioaceite, biocarbón y gas).

Ahmad y Wilkins (Ahmad & Wilkins, 2024) indican que la correcta selección de fuentes es primordial para asegurar la validez de los análisis comparativos. Por otro lado, Haro et al. (2024) destacan la importancia de contar con bases de datos sistematizadas para la aplicación de modelos predictivos en procesos industriales.

3.6. Hipótesis

Hipótesis general

La variación de las condiciones operativas (tipo de biomasa, tipo de plástico, proporción biomasa/plástico, temperatura, tiempo de residencia, catalizador y área superficial) permite explicar los rendimientos de bioaceite, biocarbón y gas. Asimismo, estas relaciones permiten construir modelos predictivos capaces de estimar la formación de compuestos químicos y combustibles de alto valor, contribuyendo a la optimización de procesos sostenibles de pirólisis y copirólisis.

Hipótesis específicas:

1. El tipo de biomasa y plástico determina diferencias significativas en la composición de productos, lo que posibilita predecir la formación de compuestos oxigenados e hidrocarburos de interés industrial.
2. La presencia y el tipo de catalizador incrementan la selectividad hacia bioaceite y reducen la formación de coque, favoreciendo la predicción de combustibles líquidos de alto valor.
3. La temperatura y el tiempo de residencia mantienen relaciones no lineales con los rendimientos, y su modelado permite anticipar la producción de gas y biocarbón con aplicaciones energéticas.

Los autores Dong et al. (2022) implementaron modelos de aprendizaje automático para predecir los rendimientos de productos pirolíticos de biomasa lignocelulósica, en donde se demostró la importancia de las características fisicoquímicas y las condiciones operativas en la composición final. Por otro lado, Potnuri (2023) aplicó SVM en la copirólisis catalítica asistida por microondas de biomasa y plásticos, lo que afirma la capacidad de los modelos predictivos para estimar el bioaceite, biocarbón y biogás con una precisión elevada.

3.7. Métodos de análisis

El análisis de datos se desarrolló en cuatro fases:

1. Análisis descriptivo y exploratorio (EDA):
 - Estadística descriptiva (media, mediana, desviación estándar, rango intercuartílico).
 - Visualizaciones (histogramas, boxplots, curvas suavizadas LOESS, barras apiladas).
 - Matriz de correlación de Pearson.
2. Pruebas estadísticas:
 - ANOVA y pruebas no paramétricas (Kruskal–Wallis) para comparar rendimientos por tipo de catalizador y plástico.

- Evaluación de multicolinealidad mediante VIF.
- 3. Modelado predictivo:
 - Regresión lineal múltiple para establecer relaciones básicas.
 - Random Forest para capturar relaciones no lineales y complejas.
 - Evaluación de importancia de variables y gráficos de dependencia parcial (PDP).
- 4. Validación y métricas:
 - Partición de datos (70% entrenamiento, 30% prueba).
 - Validación cruzada k-fold ($k=5$).
 - Métricas: coeficiente de determinación (R^2), error cuadrático medio (RMSE) y error absoluto medio (MAE).

Esta propuesta metodológica permite asegurar que se obtenga un análisis robusto y reproducible, lo que está alineado con las mejores prácticas actuales de investigación aplicadas al modelado predictivo. James et al. (2021) indican que es importante aplicar técnicas estadísticas para mejorar la precisión de los modelos. De igual forma, Kuhn y Johson (2020) indican que es importante integrar métodos de aprendizaje automático para fortalecer la capacidad predictiva y la confiabilidad de los resultados.

3.8. Procesamiento de datos

La presente investigación utiliza un protocolo estructurado de procesamiento de datos que permite convertir la información bruta en variables adecuadas para el modelado computacional. Este flujo metodológico asegura la integridad técnica del estudio a través de una secuencia lógica de depuración y ajuste, lo cual se detalla a continuación en la Figura 1.

Figura 1.

Diagrama de flujo de procesamiento de datos.



Fuente: Elaborado por el autor.

3.9. Procedimiento

3.9.1. Construcción de la Base de Datos

La recopilación de las fuentes de información para elaborar la base de datos es la etapa principal del presente estudio, ya que la consistencia, trazabilidad y homogeneidad de la información permitirá que los modelos de regresión y aprendizaje automático desarrollados sean válidos. Para esto se diseñó una base de datos cuantitativa en donde se integra información operativa, composicional y de rendimiento de procesos de pirólisis de

biomasa, plásticos y mezclas biomasa-plástico, la cual se recopiló mediante estudios experimentales extraídos de la literatura científica.

3.9.1.1. Fuentes de información y criterios de selección

Se recopilaron un total de 740 registros experimentales los cuales se obtuvieron de artículos científicos indexados, reportes técnicos y archivos experimentales de otros estudios. Las fuentes se seleccionaron considerando los siguientes criterios:

- Estudios experimentales de pirólisis térmica o catalítica.
- Reportes de condiciones operativas del proceso (temperatura, tiempo de residencia, catalizador).
- Información cuantitativa sobre la distribución de productos (bioaceite, biocarbón y gas).
- Identificación del tipo de biomasa, plástico o mezcla empleada.

3.9.1.2. Estructura y variables de la base de datos

La base de datos se estructuró en forma de tabla, en donde cada fila representa una condición experimental independiente, y las columnas corresponden a variables de entrada y variables de salida del proceso. Las variables incluidas se describen a continuación:

- **Variables de caracterización del sustrato**
 - **Biomasa:** tipo de residuo lignocelulósico (por ejemplo, cáscara de coco, residuos agrícolas).
 - **Plástico:** tipo de polímero (por ejemplo, PE).
 - **Proporción de biomasa (%):** fracción másica de biomasa en la mezcla biomasa-plástico.
- **Variables del proceso**
 - **Temperatura (°C):** temperatura de operación del reactor de pirólisis.
 - **Tiempo de residencia (s):** tiempo de permanencia de los vapores o sólidos en el reactor.
 - **Catalizador:** tipo de catalizador utilizado.
 - **Área superficial (m²/g):** área específica del catalizador.
- **Variables de rendimiento de productos**
 - Rendimiento de bioaceite (%)
 - Rendimiento de biocarbón (%)
 - Rendimiento de gas (%)
- **Variables de composición de la biomasa**
 - Celulosa (%)
 - Hemicelulosa (%)
 - Lignina (%)
 - Cenizas (%)
- **Variables de análisis elemental**
 - %C, %H, %O, %N
 - Relación C/H eff

3.9.2. Análisis y Procesamiento de la Información

3.9.2.1. Definición de Variables de Estudio

Una vez obtenida la base de datos, se realizó un análisis de las variables obtenidas para definir los rangos, unidades y aspectos principales de la información recopilada. En primer lugar, se define las variables de respuesta, las cuales indican los rendimientos de los tres productos principales del proceso de pirólisis, los cuales se expresan en porcentaje de la masa inicial de sustrato. Estas variables son mutuamente excluyentes y su suma tiene una aproximación del 100%, tomando en cuenta las pérdidas mínimas que se presentan durante el proceso. En la **Tabla 2** se aprecian las principales variables de respuesta de la base de datos obtenida las cuales se expresan en porcentaje.

Tabla 2.

Definición de las Variables de Respuesta

Variable	Descripción	Unidad
Rendimiento de bioaceite	Fracción líquida condensable obtenida	%
Rendimiento de biocarbón	Fracción sólida residual carbonizada	%
Rendimiento de gas	Fracción gaseosa no condensable	%

Fuente: Elaborado por el autor.

Por otro lado, se consideran las variables predictoras las cuales se clasifican en cuatro categorías principales, cada una proporcionando información específica sobre el proceso y las características del sustrato. A continuación se detalla cada una de las variables establecidas dentro del proceso de recolección de información.

a) Variables Operativas del Proceso

Estas variables indican las condiciones bajo las que se lleva a cabo la pirólisis y son directamente controlables por el operador del proceso. Entre estas variables se destacan:

- **Proporción de biomasa (%):** Corresponde a la relación másica entre biomasa y plástico en la mezcla de alimentación. Los valores que se acercan al 100% indican pirólisis exclusiva de biomasa.
- **Temperatura (°C):** Temperatura máxima que se alcanza durante el proceso. Este parámetro afecta la cinética de las reacciones de descomposición térmica y afecta de manera significativa la distribución de productos.
- **Tiempo de residencia (min):** Duración en la cual el material se mantiene a la temperatura de pirólisis. Esta variable define el grado de conversión y las reacciones secundarias.
- **Área superficial del catalizador (m²/g):** Es la propiedad textural del material catalítico utilizado. Un área superficial mayor indica más sitios activos para las reacciones catalíticas.

b) Composición Lignocelulósica

Los componentes estructurales de la biomasa lignocelulósica indican comportamientos térmicos diferenciados durante la pirólisis, los cuales se detallan de la siguiente forma:

- **Celulosa (%):** Polisacárido de cadena lineal, se descompone principalmente en temperaturas entre 315 a 400 °C, lo que genera principalmente compuestos volátiles.
- **Hemicelulosa (%):** Polisacárido ramificado de estructura amorfa, tiene una menor estabilidad térmica entre 220 a 315 °C lo que ayuda a la producción de gases y ácidos orgánicos.
- **Lignina (%):** Polímero aromático tridimensional, que trabaja en un amplio rango de descomposición entre 160 a 900 °C y contribuye en gran parte a la formación de biocarbón y compuestos aromáticos.
- **Cenizas (%):** Contenido mineral inorgánico el cual se genera como residuo. Actúa como catalizador afectando las reacciones de pirólisis.

c) Análisis Elemental

La composición elemental del proceso presenta información sobre el contenido energético y el comportamiento durante la pirólisis. En esto se incluye %C, %H, %O y %N (en cantidades muy bajas) y la relación C/H la cual indica el grado de aromaticidad y madurez térmica del material.

d) Variables Categóricas

Estas variables son:

- **Tipo de biomasa:** Clasificación de la materia prima vegetal como madera, residuos agrícolas, etc.
- **Tipo de plástico:** Categoría del residuo plástico utilizado en co-pirólisis tal como PE, PP, PS, PET, etc.
- **Tipo de catalizador:** Material catalítico utilizado como zeolitas, óxidos metálicos, catalizadores naturales, etc.

3.9.2.2. Análisis Estadístico Exploratorio

El análisis estadístico exploratorio es la fase inicial del proceso de modelado, ya que permite comprender de manera profunda la naturaleza y estructura de los datos. Esta etapa permite detectar anomalías, identificar patrones y validar supuestos que ayudarán a sustentar las técnicas de modelado posteriores.

En primer lugar, se analizaron los estadísticos descriptivos los cuales permiten proporcionar medidas de tendencia central y dispersión que son caracterizando de forma cuantitativa la distribución de cada variable. Estos valores permitieron realizar comparaciones entre variables y evaluar la homogeneidad de los datos obtenidos.

De igual forma se analizarán los histogramas de las variables, los cuales dividen el rango de valores en intervalos y representan la frecuencia de observaciones en cada uno de ellos. Permiten identificar la forma de la distribución, valores atípicos y el rango de datos.

Posteriormente se realiza el análisis por categorías, el cual segmenta las variables categóricas para poder identificar diferencias sistemáticas en los rendimientos atribuibles a la naturaleza del sustrato o del catalizador. Este análisis se realizó mediante el análisis por tipo de biomasa, por tipo de plástico y por tipo de catalizador.

3.9.2.3. Análisis de Correlación

El análisis de correlación es una herramienta que permite identificar relaciones lineales entre pares de variables, lo cual sirve como información valiosa sobre la estructura de dependencias en el conjunto de datos y el cual se orienta a la selección de variables predictores para los modelos respectivos. Esto se lo realiza a través del software R, herramienta que permite procesar todos los datos recopilados a partir de estudios previos y de esta forma obtener las variables más representativas para el estudio.

Se identificaron pares de variables con correlaciones muy altas ($|r| > 0.9$) como indicadores potenciales de colinealidad problemática. En los datos registrados, se pueden encontrar los siguientes casos:

- **Componentes del análisis elemental (%C, %H, %O, %N):** Estos cuatro componentes suman aproximadamente 100%. Esta restricción matemática genera correlaciones muy altas.
- **Variables derivadas y sus componentes:** La relación C/H se encuentra matemáticamente establecida mediante el C% y H%, lo cual genera correlaciones perfectas o casi perfectas.
- **Componentes lignocelulósicos:** Celulosa y hemicelulosa habitualmente tienen correlaciones negativas moderadas o altas con lignina, ya que son los tres componentes estructurales principales.

3.9.2.4. Análisis de Multicolinealidad

La multicolinealidad es la existencia de relaciones lineales aproximadas o exactas entre dos o más variables predictoras en un modelo de regresión múltiple. Esta característica representa uno de los problemas más comunes dentro del modelado estadístico, ya que incumple con el supuesto de independencia entre predictores y genera consecuencias como:

- Inestabilidad paramétrica: Los coeficientes se hacen sensibles a pequeñas perturbaciones en los datos.
- Inflación de errores estándar: La varianza de los estimadores de mínimos cuadrados aumenta de forma considerable, incrementando los intervalos de confianza.
- Ambigüedad interpretativa: No permite aislar el efecto individual de cada predictor sobre la variable respuesta.
- Inversión de signos: Los coeficientes puede presentar signos opuestos a los esperados.

De igual forma se realizó el análisis del Factor de Inflación de Varianza (VIF) el cual es una métrica cuantitativa para diagnosticar multicolinealidad. En el presente estudio se consideró un criterio conservador de $VIF < 5$ para todas las variables, lo que garantiza que la varianza inflada no exceda 5 veces la varianza teórica bajo independencia.

El procedimiento para poder definir la colinealidad esta descrito de la siguiente forma:

- Análisis preliminar de correlaciones bivariadas ($|r| > 0.9$)
- Identificación de colinealidad perfecta mediante ajuste preliminar
- Exclusión de variables con dependencia perfecta
- Cálculo de VIF con manejo de errores
- Exclusión iterativa de variables con $VIF \geq 5$
- Verificación final de ausencia de aliasing y $VIF < 5$

3.9.2.5. Selección de Variables Predictoras

La selección de variables permite equilibrar la inclusión de información importante con la parsimonia del modelo. Un modelo parsimonioso con menos variables tiende a generalizar mejor y es más fácil de interpretar. La selección final de predictores se consideró en base a los siguientes criterios:

- **Relevancia Teórica**

Variables con significado fisicoquímico claro en la pirólisis se dieron prioridad. Un ejemplo de ello es la temperatura, la cual es el parámetro operativo más influyente, mientras que la composición lignocelulósica determina las rutas de descomposición térmica.

- **Ausencia de Multicolinealidad**

Solo variables con $VIF < 5$ fueron seleccionadas. Este criterio asegura que las estimaciones sean estables y los coeficientes de regresión confiables.

- **Correlación con Variables Respuesta**

Variables con correlación absoluta mayor a 0.10 con al menos una de las tres variables respuesta fueron consideradas potencialmente informativas. Correlaciones menores pueden indicar predictores de utilidad marginal.

Una vez aplicados los criterios sistemáticos, se obtiene un conjunto reducido y robusto de variables predictoras el cual permite equilibrar la capacidad predictiva con estabilidad numérica y facilita la interpretación de resultados.

3.9.3. Desarrollo de Modelos Predictivos

Se implementaron y compararon seis algoritmos distintos que representan diferentes modelos de aprendizaje automático, que parte desde modelos lineales hasta métodos basados en conjuntos. A continuación, se detalla cada uno de los modelos planteados.

3.9.3.1. Regresión Lineal Múltiple (LM)

La regresión lineal múltiple es el modelo fundamental y más interpretable. Este asume una relación lineal aditiva entre predictores y respuesta de la siguiente forma:

$$\hat{y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p \quad (1)$$

Los coeficientes se estiman por mínimos cuadrados ordinarios (OLS).

3.9.3.2. Random Forest (RF)

Random Forest es un método de ensemble el cual está basado en árboles de decisión. Realiza la construcción de múltiples árboles entre 500 a 1000 de manera general, los cuales son entrenados sobre submuestras Bootstrap y subconjuntos aleatorios de variables. La predicción final es el promedio de todos los árboles de la siguiente forma:

$$\hat{y} = (1/B) \sum T_b(x) \quad \text{para } b = 1 \text{ hasta } B \text{ árboles} \quad (2)$$

Entre las principales ventajas es que maneja no linealidades e interacciones automáticamente, robusto a valores atípicos y proporciona importancia de las variables.

3.9.3.3. Protocolo de Entrenamiento

El conjunto de datos fue dividido de forma aleatoria en dos subconjuntos:

- **Conjunto de entrenamiento (70%):** Utilizado para ajustar los parámetros de los modelos, incluyendo selección de hiperparámetros.
- **Conjunto de prueba (30%):** Reservado para evaluar el desempeño final de los modelos. No se los utiliza en ninguna etapa del entrenamiento.

La proporción 70/30 es estándar, balanceando datos suficientes para entrenamiento con estimaciones de error confiables en test.

3.9.3.4. Métricas de Evaluación

Las métricas de evaluación permiten cuantificar de forma objetiva el desempeño predictivo de los modelos. Se utilizaron tres métricas complementarias que evalúan diferentes aspectos del error de predicción. A continuación, se detalla cada una de las métricas planteadas en el estudio.

- **Coefficiente de Determinación (R^2)**

R^2 representa la proporción de varianza de la variable dependiente explicada por el modelo de la siguiente forma:

$$R^2 = 1 - [\sum (y_i - \hat{y}_i)^2 / \sum (y_i - \bar{y})^2] \quad (3)$$

Esta métrica permite comparar el modelo con el modelo nulo (predicción constante igual a la media). En entrenamiento, R^2 está entre 0 y 1, pero en test puede ser negativo si el modelo generaliza de manera incorrecta.

- **Raíz del Error Cuadrático Medio (RMSE)**

RMSE permite cuantificar la magnitud promedio del error en las mismas unidades que Y:

$$RMSE = \sqrt{[(1/n) \sum (y_i - \hat{y}_i)^2]} \quad (4)$$

Esta medida penaliza con mayor severidad a los errores grandes. Valores más bajos indican mejor ajuste, lo cual lo hace útil para comparar modelos sobre la misma variable.

- **Error Absoluto Medio (MAE)**

MAE es la magnitud promedio del error sin penalización cuadrática la cual se representa por:

$$MAE = (1/n) \sum |y_i - \hat{y}_i| \quad (5)$$

Esta métrica es más robusta en valores atípicos que RMSE.

CAPÍTULO IV. RESULTADOS Y DISCUSIÓN

En la presente sección se analizan los resultados estadísticos y del modelado predictivo en base a los datos experimentales de pirólisis de biomasa y plásticos. El objetivo es desarrollar dos modelos que tengan la capacidad de predecir los rendimientos de los tres productos principales del proceso: bioaceite, biocarbón y gas. Se realizó la comparación de dos enfoques, un modelo paramétrico (Regresión Lineal Múltiple) y un modelo no paramétrico basado en aprendizaje automático (Random Forest).

La regresión lineal ayuda a determinar las relaciones matemáticas directas entre variables independientes y dependientes, lo cual facilita la interpretación física de los resultados. Por otro lado, Random Forest permite capturar las relaciones no lineales complejas y posibles relaciones entre variables que no se pueden describir mediante modelos lineales simples.

3.10. Análisis Estadístico Exploratorio

3.10.1. Estadísticos Descriptivos

Se analizaron los datos obtenidos de experimentos de pirólisis de mezclas biomasa-plástico a partir de 25 tipos de biomasa. Dentro de los estadísticos descriptivos se observa en la **Tabla 3** que la temperatura de pirólisis tiene una distribución casi simétrica con una media = 501 °C, mediana = 500 °C, CV = 14.8 %, la cual está centrada en el rango óptimo visualizado dentro de los estudios previos. El tiempo de residencia por su parte presenta una media = 63 s, CV = 44.1 % y el área superficial del catalizador tiene media = 490 m²/g, CV = 46.3 % lo cual indica que se presenta mayor dispersión, lo cual indica la variedad de condiciones catalíticas y regímenes encontrados.

Tabla 3.

Tabla de Estadísticos Descriptivos — Base de datos

Variable	Mín.	Media	Mediana	Máx.	DE	CV (%)
Proporción biomasa (%)	20.00	50.96	52.00	79.00	15.25	29.9
Temperatura (°C)	353.00	501.41	500.00	641.00	74.08	14.8
Tiempo de residencia (s)	10.00	63.21	65.00	119.00	27.91	44.1
Área superficial (m ² /g)	65.39	489.63	488.53	891.47	226.60	46.3
Rendimiento bioaceite (%)	19.90	39.16	39.37	64.86	8.35	21.3
Rendimiento biocarbón (%)	10.54	24.07	23.48	39.94	5.68	23.6
Rendimiento gas (%)	1.02	36.85	36.60	65.51	8.74	23.7
Celulosa (%)	10.00	35.86	39.35	51.40	9.59	26.8
Hemicelulosa (%)	8.30	26.27	26.30	45.90	7.02	26.7
Lignina (%)	1.00	21.19	20.60	51.90	10.59	50.0
Cenizas (%)	0.30	7.88	5.00	44.80	8.41	106.6

Carbono — C (%)	30.00	47.69	47.60	56.20	4.69	9.8
Hidrógeno — H (%)	4.80	6.05	6.00	7.40	0.42	6.9
Oxígeno — O (%)	36.00	45.56	45.60	64.30	4.92	10.8
Relación C/H	5.65	7.89	7.72	10.04	0.67	8.5

Fuente: Elaborado por el autor.

Por otro lado, con respecto a los rendimientos, el bioaceite es el producto que tiene dominancia con una media de 39.2, seguido por el gas con media de 36.9 % y el biocarbón con media de 24.1 %, y con coeficientes de variación similares que están entre 21 a 24 %, lo cual indica una variabilidad que puede ser comparable entre cada uno de los tres productos. Por su parte, con respecto a la composición lignocelulósica, la celulosa tiene una media de 35.9 % y la hemicelulosa una media de 26.3 %, mostrando valores típicos de biomasa herbácea-forestal, mientras que la lignina tiene una alta variabilidad con un CV de 50.0 % y valores que van del 1 % para la mazorca de maíz, hasta el 51.9 % para el caso del cuesco de palma; las cenizas tienen la mayor dispersión relativa con un CV de 106.6 %, lo que evidencia la heterogeneidad mineralógica entre especies y siendo esta la variable que tiene mayor potencial de sesgo para la implementación de los modelos predictivos. Finalmente, el análisis elemental es más homogéneo del conjunto de variables con un CV < 11 %, en contenidos de carbono de aproximadamente el 47.7 %, hidrógeno el 6.1 % y oxígeno del 45.6 % característicos de estas biomásas lignocelulósicas.


3.10.2. Distribución de Variables Respuesta

Los rendimientos de bioaceite, biocarbón y gas presentan comportamientos diferenciados en términos de dispersión y variabilidad. Como se muestra en la **Figura 2**, el bioaceite posee una dispersión amplia con valores entre 20% a 65%, lo que indica alta sensibilidad a las condiciones operativas y composición del sustrato obteniendo una mediana cerca del 40% y con ligeros valores atípicos.

Por su parte, el biocarbón presenta una distribución más concentrada, con valores que están entre el 15% al 45% lo que indica que la formación de este compuesto depende de forma más directa de la composición estructural de la biomasa, considerando especialmente el contenido de lignina y minerales. Con respecto a la mediana, esta se encuentra ubicada en un valor cercano al 30%, mostrando una distribución ligeramente asimétrica hacia valores superiores. Finalmente, con respecto al gas, se observa una mayor variabilidad entre las tres variables respuesta con valores que van desde aproximadamente 5% a 55%, lo que refleja la naturaleza secundaria de las reacciones de craqueo térmico y reformado, que son altamente dependientes de temperatura y catalizadores. La mediana para esta variable se encuentra alrededor del 25%.

Figura 2.

Boxplot de Variables Respuesta (Rendimientos)



Fuente: Elaborado por el autor.


3.10.3. Distribución de Variables Operativas

Las variables operativas, como se muestra en la **Figura 3** poseen rangos nominales considerando procesos típicos de pirólisis rápida y lenta. La temperatura se mantiene dentro del rango óptimo donde ocurren procesos de despolimerización y craqueo térmico el cual va desde los 400 °C a 600 °C.

Por su parte, el tiempo de residencia muestra cierta variabilidad que puede influir en la extensión de reacciones secundarias. Se muestra una elevada variabilidad en el área superficial lo cual indica representa el uso de diferentes catalizadores con distintas propiedades texturales.

Finalmente, la proporción de biomasa permite analizar efectos sinérgicos entre biomasa y plásticos, observando que está distribuida de manera uniforme entre los valores experimentales evaluados.

Figura 3.
Boxplot de Variables Operativas




Fuente: Elaborado por el autor.

3.10.4. Composición de Biomasa

Se analizaron 25 tipos de biomasa distintos como se muestra en la **Figura 4**, las cuales poseen rendimientos en bioaceite que van desde el 25% al 55%, siendo las menores el alga marina, cuesco de palma y lodos de depuradora. Para el caso del biocarbón los rendimientos se encuentran entre el 18% al 30%, y para el gas se tiene una distribución con mayor uniformidad que va del 35% al 42%.

Figura 4.
Rendimiento de los Distintos Tipos de Biomasa




Fuente: Elaborado por el autor.

Como se muestra en la **Figura 5**, la composición lignocelulósica permite determinar el comportamiento térmico de la biomasa. La celulosa contribuye principalmente a la formación de compuestos volátiles condensables y la cual se muestra como componente mayoritario con valores típicos que van desde el 30% al 50%. La hemicelulosa se descompone a menores temperaturas, generando compuestos oxigenados ligeros, siendo este el segundo componente estructural con valores entre que vane entre el 15% al 35%.

Por otro lado, la lignina favorece la formación de estructuras aromáticas y residuos carbonosos estables, cuyo contenido se presenta con mayor variabilidad con valores entre 10 al 30% dependiendo del tipo de biomasa. Finalmente, el contenido de cenizas actúa como catalizador mineral natural, lo que afecta la cinética de descomposición, y cuyos valores son bajos pero alta variabilidad relativa oscilando entre el 2% al 15%.

Figura 5.

Boxplot de Composición de Biomasa




Fuente: Elaborado por el autor.

3.10.5. Histogramas de Variables Respuesta

Los histogramas permiten visualizar la forma de las distribuciones de cada una de las variables de respuesta como se muestra en la **Figura 6**, con respecto al Bioaceite se aprecia una distribución aproximadamente normal, concentrada entre el 35% al 50%. Por su parte, el biocarbón, tiene una tendencia hacia valores de medios a bajos, lo que representa una forma ligeramente bimodal. Finalmente, el gas se presenta como una distribución con mayor dispersión y con una forma que no se puede determinar el tipo de distribución típica.

Figura 6.

Histogramas de Variables Respuesta




Fuente: Elaborado por el autor.

3.10.6. Rendimientos por Tipo de Biomasa

Como se muestra en la **Figura 7**, el análisis segmentado por tipo de biomasa permite identificar patrones diferenciados. Las diferentes biomásas tienen rendimientos variables, con algunas categorías generando de forma consistente una mayor cantidad de fracción líquida. El rendimiento de biocarbón se correlaciona típicamente con el contenido de lignina.

Figura 7.
Boxplot de Rendimientos por Tipo de Biomasa



Fuente: Elaborado por el autor.


3.10.7. Rendimientos por Tipo de Plástico

Como se aprecia en la **Figura 8**, cada tipo de polímero tiene diferentes rutas de degradación térmica. En cuanto al polietileno, este favorece a la producción de hidrocarburos líquidos como lo es el bioaceite debido a su estructura de cadena lineal, mientras que el PET puede generar mayor fracción sólida debido a su estructura aromática lo cual produce mayor biocarbón.

El Polipropileno posee rendimientos intermedios para las tres fracciones, mientras que el Poliestireno contribuye a la formación de compuestos aromáticos en el bioaceite. Finalmente, el PVC introduce efectos químicos adicionales debido al contenido de cloro, lo que puede afectando las rutas de reacción y la calidad del bioaceite.

Figura 8.

Boxplot de Rendimientos por Tipo de Plástico




Fuente: Elaborado por el autor.

3.10.8. Rendimientos por Tipo de Catalizador

Con respecto a los rendimientos por tipo de catalizador, como se muestra en la **Figura 9** estos modifican las rutas de reacción termoquímica. Las zeolitas como el ZSM-5, ayudan a la formación de compuestos aromáticos por medio de reacciones de craqueo y ciclización. Por su parte, los catalizadores metálicos como el $\text{Ni}/\text{Al}_2\text{O}_3$ promueven reacciones de reformado y eliminación de oxígeno, mientras que materiales como el Carbón activado pueden actuar como soportes reactivos y absorbentes.

Figura 9.

Boxplot de Rendimientos por Tipo de Catalizador



Fuente: Elaborado por el autor.

3.11. Análisis de Correlación y Multicolinealidad


El análisis de correlación permite identificar relaciones lineales entre variables, lo cual ayuda a la identificación de patrones que no permitan generar un modelo confiable. De igual manera, la multicolinealidad afecta la estabilidad estadística de los modelos lineales, en donde sistemas con variables de composición porcentual, muestran una dependencia lineal estructural. A continuación, se detalla en proceso de análisis de las variables.

3.11.1. Matriz de Correlación

Como se muestra en la **Figura 10** se presenta una alta correlación entre componentes lignocelulósicos lo cual es coherente debido a su naturaleza estructural. De igual forma, las variables elementales muestra cierta dependencia matemática, ya que %C, %H, %O y %N

poseen un análisis elemental que suma aproximadamente el 100%. Esto implica que los modelos lineales pueden presentar coeficientes inestables por lo que se debe aplicar técnicas de reducción dimensional.

Figura 10.
Matriz de Correlación de Variables




Fuente: Elaborado por el autor.

3.11.2. Análisis de Multicolinealidad (VIF)

Como se muestra en la **Figura 11**, la inflación de la varianza permite identificar redundancia informativa entre variables predictoras, evitando de esta manera que exista un sobreajuste estadístico y pérdida de interpretabilidad física durante la implementación del modelo. La causa principal de la exclusión de las variables de composición es la restricción matemática de sumas porcentuales constantes resultante de ser una composición química.

Figura 11.

Factor de Inflación de Varianza (VIF)



Fuente: Elaborado por el autor.

De acuerdo con lo que se aprecia a detalle en la **Tabla 4**, las variables Lignina, Celulosa, Cenizas y presentan VIF dentro del rango aceptable (<5), lo cual representa que no existe una multicolinealidad que pueda afectar al modelo. Las variables operativas como la temperatura, tiempo de residencia, área superficial y proporción de biomasa, de igual forma tienen VIF aceptables.

Tabla 4.

Valores de VIF para Variables Predictoras

Variable	VIF	Interpretación
Proporción_biomasa	1.004	Aceptable
Temperatura	1.013	Aceptable
Tiempo_residencia	1.008	Aceptable
Area_superficial	1.008	Aceptable
Celulosa	3.054	Aceptable
Hemicelulosa	4.312	Aceptable
Lignina	2.656	Aceptable
Cenizas	4.562	Aceptable
IR (Ind. Reactividad)	3.941	Aceptable
IP (Ind. Polaridad)	2.438	Aceptable

Fuente: Elaborado por el autor.

3.12. Modelos de Predicción

3.12.1. Modelo de Regresión Lineal Múltiple

Para el caso de la regresión lineal, el modelo considera para el entrenamiento el 70% del total de las 740 observaciones, y se reserva un 30% para pruebas el cual equivale a 220 muestras. Mediante este modelo se pueden generar ecuaciones matemáticas interpretables, las cuales se evaluaron mediante la medición de R², AIC, RSME y MAE principalmente. 2. Para determinar la influencia de cada una de las variables de predictoras, se las ordenó de acuerdo con el nivel de la correlación $|r|$ de mayor a menor, siendo este el orden de incorporación al modelo. Posteriormente se realizó el ajuste de los modelos de regresión de forma sucesiva de tal forma que:

$$M_1 (k = 1 \text{ variable}), M_2 (k = 2 \text{ variables}), \dots, M_{10} (k = 10 \text{ variables}). \quad (6)$$

Como se observa en la **Tabla 5**, la mayor correlación individual que corresponde a Celulosa la variable de la celulosa equivalente a 0.452 entrega un R² de 0.2783. Posteriormente, la incorporación de Temperatura como tercera variable de agregación genera el mayor incremento de R² con un incremento de 0.047 entregando un modelo con R² en pruebas de 0.3247, un RMSE de 6.6512 y MAE de 4.0938.

Tabla 5.

Regresión Lineal Secuencial para cada Variable

k	Variable agregada	$ r $	R ² Test	RMSE	MAE
1	Celulosa	0.452	0.2783	6.8759	4.6603
2	Cenizas	0.349	0.2784	6.8754	4.6598
3	Temperatura	0.280	0.3247	6.6512	4.0938
4	Hemicelulosa	0.225	0.3247	6.6510	4.0910
5	Tiempo_residencia	0.065	0.3332	6.6094	4.0737
6	Lignina	0.037	0.3307	6.6218	4.0892
7	Area_superficial	0.028	0.3303	6.6235	4.0845
8	Proporcion_biomasa	0.026	0.3336	6.6070	4.0526

Fuente: Elaborado por el autor.

Una vez observada la influencia de cada una de las variables con respecto al modelo, se obtienen los coeficientes de regresión que se muestran en la **Tabla 6** considerando cada tipo de variable.

Tabla 6.

Coeficientes de Regresión Lineal

Coeficiente	Bioaceite	Biocarbón	Gas
(Intercept)	44,2605968	27,9300846	25,9053338
Proporcion_biomasa	0,02107415	-0,0201008	-0,0008312
Temperatura	-0,0284625	-0,0112623	0,03692037
Tiempo_residencia	0,02322182	0,00038729	-0,0235963
Area_superficial	-0,0008945	-0,0010401	0,00134667
Tipo_biomasa Aserrín	13,2504701	-1,6020356	-12,299228
Tipo_biomasa Bagazo	13,9616976	-0,5908127	-14,198979


Tipo_biomasa Bambu	11,5985235	-2,5226359	-9,5019097
Tipo_biomasa Cana de azucar	11,8108359	-4,2963147	-8,670215
Tipo_biomasa Cana gigante	11,8274866	-3,343052	-10,081094
Tipo_biomasa Cáscara de arroz	10,3760883	-0,4445294	-12,503242
Tipo_biomasa Cáscara de coco	7,88189103	-2,907311	-5,779613
Tipo_biomasa Cascaras citricos	10,1108671	-7,2016013	-2,5540928
Tipo_biomasa Corteza de eucalipto	9,31060628	-1,4047898	-8,9024607
Tipo_biomasa Cuesco de palma	0,72436441	4,98573657	-5,2592999
Tipo_biomasa Hueso de aceituna	5,32655938	-0,1217758	-5,1675743
Tipo_biomasa Lodo de depuradora	-4,2532147	2,64134246	0,69414906
Tipo_biomasaMadera de caucho	14,3361951	-4,9514431	-9,7669982
Tipo_biomasaMadera de pino	12,1664232	-2,3825244	-10,044497
Tipo_biomasaMazorca de maiz	14,0899502	-10,236189	-5,1659284
Tipo_biomasaMicroalga Chlorella	5,33450735	-4,5874302	1,70853028
Tipo_biomasaOrujo de oliva	4,17661599	4,83710788	-8,9830087
Tipo_biomasaPaja de arroz	7,96746582	-3,3319684	-5,2450401
Tipo_biomasaPaja de trigo	11,0115873	-4,7457327	-6,7348158
Tipo_biomasaPalma aceitera	10,1532209	-2,1875906	-7,9068437
Tipo_biomasaRastrojo de soya	11,3574134	-5,3953959	-6,2065893
Tipo_biomasaResiduos agrícolas	7,37850358	-2,4127953	-5,8460035
Tipo_biomasaResiduos de cafe	8,16095914	-3,6938405	-4,8151823
Tipo_biomasaTallos de maiz	10,0342767	-5,2599869	-6,4460353
Tipo_plastico PET	-5,6821502	3,83165076	1,95710029
Tipo_plastico PP	-0,1487828	0,29201471	-0,2740524
Tipo_plastico PS	-1,1813207	1,99715486	-0,9110745
Tipo_plastico PVC	-3,9422668	2,74308101	1,36640299
Tipo_catalizador Carbón activado	0,97341049	-1,0455022	0,19543703
Tipo_catalizador Ni/Al ₂ O ₃	1,45649507	-0,7855208	-1,0297872
Tipo_catalizador Sin catalizador	-2,9625893	0,32759853	2,56896631
Tipo_catalizador ZSM-5	3,41337514	-1,0661792	-2,6028587
Celulosa		0,05388344	
Hemicelulosa		0,06312084	
Lignina		0,01076958	
Cenizas		0,06054495	

Fuente: Elaborado por el autor.

Como se muestra en la **Figura 12**, el RMSE disminuye de manera significativa al incluir la temperatura dentro del modelo de predicción y manteniéndose igual hasta la inclusión del tiempo de residencia y la proporción de la biomasa.

Figura 12.

Evolución del RMSE con la Inclusión de Nuevas Variables




Fuente: Elaborado por el autor.

Con respecto al MAE, se observa en la **Figura 13** se aprecia que este indicador tiene una mejor respuesta para el caso del biocarbón las 4 primeras variables son suficientes para obtener el modelo adecuado, mientras que, en el caso del gas, la influencia de nuevas variables después de la temperatura no tiene influencia relevante sobre esta métrica.

Figura 13.

Evolución del MAE con la Inclusión de Nuevas Variables




Fuente: Elaborado por el autor.

Finalmente, como se muestra en la **Figura 14** el R^2 para el caso del bioaceite mejora de forma significativa al incorporar a la temperatura, permitiendo que durante el entrenamiento y las pruebas las métricas incrementen con una tendencia superior a 0.3 para el bioaceite y biocarbón, mientras que para gas alcanza únicamente el 0.2327.

Figura 14.

Evolución del R² con la Inclusión de Nuevas Variables



Fuente: Elaborado por el autor.

Como se muestra en la **Tabla 7**, el modelo para el caso del Biocarbón obtienen un R² en las pruebas de 0.3396, un RMSE de 6.57, un MAE de 4.02 y un AIC de 3432.26; para el biocarbón se obtiene un R² de 0.3361, un RMSE de 4.56, MAE de 2.9572 y AIC de 3098.48; y el modelo del Gas obtuvo un R² de 0.2327, RMSE de 7.68, MAE de 4.7576 y AIC de 3567.94.

Tabla 7.

Estadísticos del Modelo LM Propuesto

Variable	Tipo Modelo	R2 Train	R2 Test	RMSE Test	MAE Test	AIC
Bioaceite	LM	0,4779	0,3396	6,5774	4,0203	3432,26
Biocarbón	LM	0,4073	0,3361	4,563	2,9572	3098,48
Gas	LM	0,3634	0,2327	7,6838	4,7576	3567,94

Fuente: Elaborado por el autor.

3.12.2. Modelo Random Forest

Por su parte, se consideró el modelo Random Forest el cual permite capturar interacciones complejas, sin embargo, en ciertas ocasiones requiere un mayor volumen de datos de entrenamiento para poder generalizar de manera correcta. Al igual que el caso de la regresión lineal múltiple, se considera un 70% de los datos totales para el entrenamiento y un 30% para pruebas.

Como se muestra en la **Tabla 8**, el modelo se plantea con un número de árboles óptimo de árboles que el modelo estableció para el bioaceite de 169, biocarbón de 547, y el gas de 316. Por otro lado, el parámetro mtry representa el número de variables consideradas en cada división del árbol, tomando en cuenta un valor óptimo definido por el algoritmo de 5 debido al dominio amplio de las variables predicciones.

Tabla 8.

Parámetros para el Modelo de Random Forest

Variable Respuesta	Número de Árboles	mtry óptimo
Bioaceite	169	5
Biocarbón	547	5
Gas	316	5

Fuente: Elaborado por el autor.


3.13. Evaluación del Desempeño

3.13.1. Métricas de Bioaceite

Para el modelo de Regresión Lineal, se observa un R^2 durante el entrenamiento de apenas 0.478 lo que indica que el modelo está generalizando de forma correcta con ciertos puntos fuera de los valores observados como se muestra en la **Figura 15**. De igual manera pasa con los datos de prueba, se observa un R^2 de 0.34 lo cual indica que el modelo está prediciendo de manera correcta en base a la cantidad de información proporcionada pero únicamente en ciertos puntos.

Figura 15.

Gráficos Observado vs Predicho modelo LM Bioaceite – Entrenamiento y Prueba




Fuente: Elaborado por el autor.

Con respecto al modelo Random Forest, se observa un R^2 durante el entrenamiento de 0.894 lo que indica resulta con mayor precisión que el planteado por LM, pudiendo generalizar de mejor manera las condiciones para obtener esta variable como se muestra en la **Figura 15**. Por su parte, en los datos de prueba, se observa un R^2 de apenas 0.317 lo cual indica que el modelo pudo predecir correctamente varios de los datos de prueba, esto se traduce en que el modelo tiene cierto sobreajuste con respecto a ciertas condiciones específicas.

Figura 16.

Gráficos Observado vs Predicho modelo RF Bioaceite – Entrenamiento y Prueba




Fuente: Elaborado por el autor.

3.13.2. Métricas de Biocarbón

Para el caso del Biocarbón, el modelo de Regresión Lineal presenta un R^2 durante el entrenamiento de 0.407, que al igual que en el bioaceite indica que modelo no está generalizando de forma correcta las condiciones esperadas, tal y como se muestra en la **Figura 17**. De igual manera pasa con los datos de prueba, se observa un R^2 de 0.336 lo que indica que el modelo ha podido aprender ciertos patrones de acuerdo con la información proporcionada.

Figura 17.

Gráficos Observado vs Predicho modelo LM Biocarbón – Entrenamiento y Prueba




Fuente: Elaborado por el autor.

Con respecto al modelo Random Forest, se observa un R^2 durante el entrenamiento 0.872 lo cual se puede considerar un modelo aceptable con ligeras desviaciones en los extremos, obteniendo mejores resultados que lo planteado por LM como se muestra en la **Figura 18**. Por su parte, en los datos de prueba, se observa un R^2 de 0.314 lo que indica que el modelo no pudo predecir correctamente todos los datos de prueba, por lo que se verifica un sobreajuste de ciertas condiciones específicas del modelo.

Figura 18.

Gráficos Observado vs Predicho modelo RF Biocarbón – Entrenamiento y Prueba




Fuente: Elaborado por el autor.

3.13.3. Métricas de Gas

Para el caso del Gas, el modelo de Regresión Lineal presenta un R^2 durante el entrenamiento de apenas 0.363, que al igual que en los casos anteriores indica que modelo no ha podido detectar patrones de forma correcta con respecto a las variables analizadas como se muestra en la **Figura 19**. De igual manera pasa con los datos de prueba, se observa un R^2 de 0.233 mostrando igual valores que no corresponden a los esperados durante el proceso de predicción.

Figura 19.

Gráficos Observado vs Predicho modelo LM Gas – Entrenamiento y Prueba




Fuente: Elaborado por el autor.

Con respecto al modelo Random Forest, se observa un R^2 durante el entrenamiento 0.856 lo obteniendo un modelo aceptable con ligeras desviaciones en los extremos, demostrando al igual que en los casos anteriores una mejora significativa con respecto a LM, tal y como se muestra en la **Figura 20**. Por su parte, en los datos de prueba, se observa un R^2 de 0.278 lo que indica que el modelo no pudo predecir correctamente la totalidad de datos de prueba evaluados, comprobando cierto sobreajuste en condiciones específicas del modelo.

Figura 20.

Gráficos Observado vs Predicho modelo RF Gas – Entrenamiento y Prueba



Fuente: Elaborado por el autor.

El sobreajuste que se observó en el modelo de Random Forest indica que el modelo logró aprender con gran precisión los patrones específicos y particularidades presentes en los datos de entrenamiento, incluyendo ruido y relaciones no generalizables, pero presentó dificultades para adaptarse correctamente a datos nuevos no observados. Aunque se realizó un ajuste automático de hiperparámetros, este proceso no pudo garantizar la capacidad adecuada de generalización, esto se debe principalmente al tamaño del conjunto de datos que, posee algunas configuraciones de variables correlacionadas, presencia de ruido o una elevada complejidad para describir el modelo. En estos casos, el algoritmo realiza la selección de las configuraciones en donde se optimiza el rendimiento interno del entrenamiento, pero que no pueden representar de forma correcta el comportamiento real del sistema bajo situaciones externas. Debido a estas discrepancias entre las métricas se identifica que el modelo posee una alta varianza y una limitada capacidad predictiva fuera del conjunto de entrenamiento, por lo que se requiere aplicar estrategias adicionales como reducción de variables, incremento de datos, validación cruzada más robusta o restricciones adicionales en la profundidad y complejidad de los árboles.

3.13.4. Métricas Generales

Como se muestra en la **Tabla 9**, el modelo Random Forest muestra un aprendizaje adecuado, debido a que durante el entrenamiento alcanza valores de R^2 mayores a 0.85 en las distintas variables, pero en las pruebas decae a valores mayores a 0.27, obteniendo diferencias entre 0.57 lo que indica que el modelo memoriza los datos de entrenamiento.

Por su parte, el modelo de Regresión Lineal tiene mayor estabilidad, pero con bajo desempeño ya que posee un R^2 durante el entrenamiento de 0.23 a 0.34, lo que indica menos sobreajuste, pero capacidad predictiva limitada.

Técnicamente, el bajo desempeño del modelo puede atribuirse a la limitada cantidad y variabilidad de los datos experimentales, así como a una insuficiente optimización de hiperparámetros. En el caso del Random Forest, el modelo aprendió patrones específicos y ruido del conjunto de entrenamiento, generando sobreajuste y una baja capacidad de

generalización. Por otro lado, la Regresión Lineal presentó bajos valores de R^2 debido a que las relaciones entre variables no son completamente lineales. Además, la posible existencia de variables no consideradas y variabilidad experimental afectó la capacidad predictiva de ambos modelos.

Tabla 9.

Comparación de R^2 entre Entrenamiento y Prueba

Variable	Modelo	R^2 Train	R^2 Test
Bioaceite	Regresión Lineal	0,478	0,34
Bioaceite	Random Forest	0,894	0,317
Biocarbón	Regresión Lineal	0,407	0,336
Biocarbón	Random Forest	0,872	0,314
Gas	Regresión Lineal	0,363	0,233
Gas	Random Forest	0,856	0,278

Fuente: Elaborado por el autor.

Finalmente, como se observa en la **Tabla 10**, se aprecia que ambos modelos presentan una capacidad predictiva para estimar los rendimientos de bioaceite, biocarbón y gas durante la etapa de pruebas, evidenciada por los valores mayores a 0.2 de R^2 . Con respecto al bioaceite, Regresión Lineal es mejor que Random Forest con un $R^2 = 0.3396$ vs 0.3169, y presentando menores errores tanto para RMSE como MAE, lo cual indica una ligera mejor capacidad de ajuste.

Con respecto al biocarbón, ambos modelos tienen desempeño correcto durante la etapa de pruebas, siendo la regresión lineal ligeramente mejor que Random Forest, encontrándose en valores cercanos. En el caso del gas, Random Forest obtiene el mejor desempeño relativo con un $R^2 = 0.2784$, aunque considerándose bajo, mientras que Regresión Lineal muestra menor capacidad predictiva y mayor error.

Tabla 10.

Métricas de Desempeño en Conjunto de Prueba

Variable	Modelo	R^2	RMSE	MAE
Bioaceite	Regresión Lineal	0,3396	6,5774	4,0203
	Random Forest	0,3169	6,6893	4,2508
Biocarbón	Regresión Lineal	0,3361	4,563	2,9572
	Random Forest	0,3142	4,6377	2,9626
Gas	Regresión Lineal	0,2327	7,6838	4,7576
	Random Forest	0,2784	7,4514	4,4704

Fuente: Elaborado por el autor.

CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES.

4.1. Conclusiones

- Se consolidó la base de datos que se encuentra compuesta por 740 observaciones experimentales, en donde se consideró la inclusión de variables operativas del proceso tal como temperatura, tiempo de residencia, proporción biomasa/plástico, área superficial del catalizador, así como variables de composición lignocelulósica como la celulosa, hemicelulosa, lignina y cenizas, el análisis elemental (%C, %H, %O) y diversas variables categóricas, obteniendo un total de 25 tipos de biomasa con rendimientos en bioaceite que van desde el 25% al 55%, siendo las menores el alga marina, cuesco de palma y lodos de depuradora. Para el caso del biocarbón los rendimientos se encuentran entre el 18% al 30%, y para el gas se tiene una distribución con mayor uniformidad que va del 35% al 42%. Con ello se pudo realizar la verificación del balance de masa tomando en cuenta un criterio de desbalance inferior al 5% y la respectiva normalización proporcional de rendimientos lo que permitió garantizar la coherencia del conjunto de datos obtenidos, generando de esta forma el Dataset para el entrenamiento y validación de cada uno de los modelos.
- El análisis exploratorio de datos permitió identificar patrones y correlaciones significativas entre las diferentes variables operativas y la composición de los productos de pirólisis. El análisis de correlación mostró que la celulosa posee la mayor correlación individual con los rendimientos equivalente a $|r| = 0.452$, seguida por las cenizas con $|r| = 0.349$ y la temperatura con $|r| = 0.280$, demostrando que la composición del sustrato y las condiciones térmicas tienen influencia determinante con respecto a la distribución de productos. El análisis secuencial de regresión demostró que la incorporación de la temperatura como tercera variable puede generar el mayor incremento en el coeficiente de determinación, elevando el R^2 en pruebas de 0.2784 a 0.3247 disminuyendo el RMSE a 6.6512 para el bioaceite. El análisis de multicolinealidad mediante VIF mostró que todas las variables predictoras seleccionadas mantuvieron valores menores a 5 validando de esta manera la estabilidad numérica de los coeficientes estimados. De igual forma, el análisis por categorías mostró patrones diferenciados como en el caso del polietileno en donde mejoró la producción de bioaceite debido a la estructura de cadena lineal, mientras que la cáscara de coco promovió una mayor formación de biocarbón, y el catalizador ZSM-5 aumentó la fracción gaseosa a través de las respectivas reacciones, lo que confirma que la interacción entre el tipo de sustrato y catalizador modifica las rutas termoquímicas del proceso.
- Finalmente, se desarrollaron y compararon dos modelos predictivos, la Regresión Lineal Múltiple (LM) y Random Forest para estimar los rendimientos de bioaceite, biocarbón y gas en función de las variables operativas. El modelo de regresión lineal demostró mayor estabilidad en generalización, llegando a tener en el conjunto de prueba un R^2 de 0.3396, RMSE de 6.58 y MAE de 4.02 para bioaceite; un R^2 de 0.3361, RMSE de 4.56 y MAE de 2.96 para biocarbón; y un R^2 de 0.2327, RMSE de 7.68 y MAE de 4.76 para gas. Por otro lado, Random Forest obtuvo un ajuste mayor

durante el entrenamiento con un $R^2 > 0.85$ para las tres variables, pero mostrando un sobreajuste en la etapa de pruebas con valores de R^2 de 0.3169, 0.3142 y 0.2784 para bioaceite, biocarbón y gas respectivamente. Estos resultados indican que ambos modelos tienen una capacidad predictiva moderada, pero que regresión lineal es ligeramente superior a bioaceite y biocarbón en pruebas, mientras que Random Forest mostró mejor desempeño para la componente gaseosa. Los valores de R^2 obtenidos, pese a que muestran la complejidad inherente del fenómeno termoquímico y la variabilidad multifactorial del proceso, comprueban la necesidad de construir modelos cuantitativos que se encarguen de capturar las tendencias generales en la formación de productos basados en la pirólisis.

4.2. Recomendaciones

- Se recomienda que se amplíe la base de datos integrando una mayor cantidad de variables operativas adicionales que no fueron incluidas en el presente estudio, tales como la velocidad de calentamiento, la presión del reactor, el tamaño de partícula del sustrato y la relación catalizador/sustrato, observando que estas condiciones ejercen influencia sobre la selectividad de productos.
- Considerando que los modelos implementados consiguieron valores de R^2 moderados en pruebas que van desde 0.23 a 0.34 y que Random Forest mostró sobreajuste entre entrenamiento y prueba, se sugiere explorar algoritmos de mayor capacidad representacional tales como Gradient Boosting (XGBoost, LightGBM), Redes Neuronales Artificiales (ANN) y Support Vector Regression (SVR), los cuales pueden llegar a obtener valores de R^2 superiores a 0.90 para la predicción de los rendimientos pirolíticos.
- Finalmente, se recomienda que los modelos predictivos implementados se validen a través de ensayos experimentales controlados dentro de un laboratorio, seleccionando combinaciones específicas de sustrato, catalizador y condiciones operativas los cuales se pueda identificar como óptimas para la maximización del rendimiento de bioaceite o gas de síntesis. Esta validación mediante experimentación puede permitir realizar validaciones de la capacidad de los modelos para anticipar resultados reales y ajustar los coeficientes de acuerdo con los datos primarios.

5. REFERENCIAS BIBLIOGRÁFICAS

- Abnisa, F., & Wan Daud, W. M. A. (2014). A review on co-pyrolysis of biomass: An optional technique to obtain a high-grade pyrolysis oil. *Energy Conversion and Management*, 87, 71–85. <https://doi.org/10.1016/J.ENCONMAN.2014.07.007>
- Ahmad, M., & Wilkins, S. (2024). Purposive sampling in qualitative research: a framework for the entire journey. *Quality & Quantity*, 59, 1461–1479. <https://doi.org/10.1007/s11135-024-02022-5>
- Al-Maadeed, M. (2023). Catalytic pyrolysis of plastic waste: Advances and challenges. *Journal of Cleaner Production*, 403, 136789. <https://doi.org/https://doi.org/10.1016/j.jclepro.2023.136789>
- Ansari, K. B., Hassan, S. Z., Bhoi, R., & Ahmad, E. (2021). Co-pyrolysis of biomass and plastic wastes: A review on reactants synergy, catalyst impact, process parameter, hydrocarbon fuel potential, COVID-19. *Journal of Environmental Chemical Engineering*, 9(6), 106436. <https://doi.org/10.1016/J.JECE.2021.106436>
- Balsora, H., S, K., Joshi, J., Sharma, A., & Chakinala, A. (2023). Artificial Neural Network-Based Models for the Prediction of Biomass Pyrolysis Products from Preliminary Analysis. *Industrial & Engineering Chemistry Research*. <https://doi.org/10.1021/acs.iecr.3c01662>
- Baranitharan, B., Elaiyaran, S., Sakthivel, R., Sriariyanun, M., & Tamilarasan, K. (2024). Production and characterization of bio-oil and bio-char from microwave-assisted pyrolysis of waste biomass: A review. *Fuel*, 357, 128956. <https://doi.org/10.1016/j.fuel.2023.128956>
- Bhoi, P. R., Ouedraogo, A. S., Soloiu, V., & Quirino, R. (2020). Recent advances on catalysts for improving hydrocarbon compounds in bio-oil of biomass catalytic pyrolysis. *Renewable and Sustainable Energy Reviews*, 121, 109676. <https://doi.org/https://doi.org/10.1016/j.rser.2019.109676>
- Blanco, L. (2014). *Modelado y simulación del proceso de pirolisis rápida de biomasa en un reactor de lecho fluidizado*. <https://repositorio.unal.edu.co/handle/unal/51313>
- Burra, K. G., & Gupta, A. K. (2018). Kinetics of synergistic effects in co-pyrolysis of biomass with plastic wastes. *Applied Energy*, 220, 408–418. <https://doi.org/https://doi.org/10.1016/j.apenergy.2018.03.117>
- Cahanap, D. R., Mohammadpour, J., Jalalifar, S., Mehrjoo, H., Norouzi-Apourvari, S., & Salehi, F. (2023). Prediction of three-phase product yield of biomass pyrolysis using artificial intelligence-based models. *Journal of Analytical and Applied Pyrolysis*. <https://doi.org/10.1016/j.jaap.2023.106015>
- Chi, N. T. L., Anto, S., Ahamed, T. S., Kumar, S. S., Shanmugam, S., Samuel, M. S., Mathimani, T., Brindhadevi, K., & Pugazhendhi, A. (2021). A review on biochar production techniques and biochar based catalyst for biofuel production from algae. *Fuel*, 287, 119411. <https://doi.org/10.1016/J.FUEL.2020.119411>
- Deng, J. Y., Masek, O., Yuan, X., Hwang, S. Y., Ong, H. C., Hua, Z., & Ok, Y. S. (2025). Co-pyrolysis of biomass and plastic waste into carbon materials with environmental

- applications: A critical review. *Green Chemistry*, 27(15), 6320–6341. <https://doi.org/10.1039/D4GC02901G>
- Dong, Z., Bai, X., Xu, D., & Li, W. (2022). Machine learning prediction of pyrolytic products of lignocellulosic biomass based on physicochemical characteristics and pyrolysis conditions. *Bioresource Technology*, 128182. <https://doi.org/10.2139/ssrn.4191315>
- Eibner, S., Margeriat, A., Broust, F., Laurenti, D., Geantet, C., Julbe, A., & Blin, J. (2017). Catalytic deoxygenation of model compounds from flash pyrolysis of lignocellulosic biomass over activated charcoal-based catalysts. *Applied Catalysis B: Environmental*, 219, 517–525. <https://doi.org/10.1016/J.APCATB.2017.07.071>
- Ferrer-Romero, J. C., Mas-Diego, S. M., Beltrán-Delgado, Y., Rodríguez-Quiala, Y., & Morris-Quevedo, H. J. (2019). Optimización del medio de cultivo para la producción de biomasa y compuestos fenólicos por *Pleurotus ostreatus* en fase sumergida utilizando la metodología de superficie de respuesta. *Tecnología Química*, 39(1), 1–16. <https://www.redalyc.org/articulo.oa?id=445558836001>
- Gallardo, M. (2025). *Investigación cuantitativa: fundamentos teóricos y prácticos*. Universidad Juárez del Estado de Durango.
- Ghenai, C., Alamara, K., & Inayat, A. (2019). Solar Assisted Pyrolysis of Plastic Waste: Pyrolysis oil Characterization and Grid-Tied Solar PV Power System Design. *Energy Procedia*, 159, 123–129. <https://doi.org/10.1016/J.EGYPRO.2018.12.029>
- Gil, S. A., Arias, A. N. A., & Zapata, R. B. (2019). *Simulación y obtención de combustibles sintéticos a partir de la pirólisis de residuos plásticos*. <https://api.semanticscholar.org/CorpusID:210276321>
- Gin, A. W., Hassan, H., Ahmad, M. A., Hameed, B. H., Din, A. T. M., Gin, A. W., Hassan, H., Ahmad, M. A., Hameed, B. H., & Din, A. T. M. (2021). Recent progress on catalytic co-pyrolysis of plastic waste and lignocellulosic biomass to liquid fuel: The influence of technical and reaction kinetic parameters. *Arabian Journal of Chemistry*, 14(4). <https://doi.org/10.1016/J.ARABJC.2021.103035>
- Haro Sarango, J., Chisag Pallmay, J., Ruiz Sarzosa, J., & Caicedo Pozo, J. (2024). Systematization of experimental databases for predictive modeling in industrial processes. *Journal of Industrial Engineering Research*, 12(3), 145–160. <https://doi.org/10.5281/zenodo.10821435>
- Hernández-Sampieri, R., & Mendoza, C. (2021). *Metodología de la investigación: las rutas cuantitativa, cualitativa y mixta* (2nd ed.). McGraw-Hill.
- Hoff, T. C., Thilakaratne, R., Gardner, D. W., Brown, R. C., & Tessonier, J.-P. (2016). Thermal Stability of Aluminum-Rich ZSM-5 Zeolites and Consequences on Aromatization Reactions. *The Journal of Physical Chemistry C*, 120(36), 20103–20113. <https://doi.org/10.1021/acs.jpcc.6b04671>
- Iliopoulou, E. F., Stefanidis, S. D., Kalogiannis, K. G., Delimitis, A., Lappas, A. A., & Triantafyllidis, K. S. (2012). Catalytic upgrading of biomass pyrolysis vapors using transition metal-modified ZSM-5 zeolite. *Applied Catalysis B: Environmental*, 127, 281–290. <https://doi.org/https://doi.org/10.1016/j.apcatb.2012.08.030>

- Inayat, A., Rocha-Meneses, L., Ghenai, C., Abdallah, M., Shanableh, A., Al-Ali, K., Alghfeli, A., & Alsuwaidi, R. (2022). Co-pyrolysis for bio-oil production via fixed bed reactor using date seeds and plastic waste as biomass. *Case Studies in Thermal Engineering*, 31, 101841. <https://doi.org/10.1016/J.CSITE.2022.101841>
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An Introduction to Statistical Learning: with Applications in R* (2nd ed.). Springer. <https://doi.org/10.1007/978-1-0716-1418-1>
- Johansson, A. C., Sandström, L., Öhrman, O. G. W., & Jilvero, H. (2018). Co-pyrolysis of woody biomass and plastic waste in both analytical and pilot scale. *Journal of Analytical and Applied Pyrolysis*, 134, 102–113. <https://doi.org/10.1016/J.JAAP.2018.05.015>
- Kitchenham, B., Budgen, D., & Brereton, P. (2020). *Evidence-Based Software Engineering and Systematic Reviews*. CRC Press. <https://doi.org/10.1201/9780429400902>
- Kuhn, M., & Johnson, K. (2020). *Feature Engineering and Selection: A Practical Approach for Predictive Models*. Chapman & Hall/CRC. <https://doi.org/10.1201/9781315108230>
- Mariyam, S., Alherbawi, M., McKay, G., & Al-Ansari, T. (2025). A predictive model for biomass waste pyrolysis yield: Exploring the correlation of proximate analysis and product composition. *Energy Conversion and Management: X*. <https://doi.org/10.1016/j.ecmx.2024.100831>
- Martínez, C. (2020). El diseño correlacional–predictivo en la investigación científica. *Revista de Investigación Educativa*, 38(1), 227–247. <https://doi.org/10.6018/rie.38.1.341141>
- Ogunkanmi, J. O., Kulla, D. M., Omisanya, N. O., Sumaila, M., Obada, D. O., & Doodoo-Arhin, D. (2018). Extraction of bio-oil during pyrolysis of locally sourced palm kernel shells: Effect of process parameters. *Case Studies in Thermal Engineering*, 12, 711–716. <https://doi.org/10.1016/J.CSITE.2018.09.003>
- Oh, S. Y., & Seo, Y. D. (2016). Polymer/biomass-derived biochar for use as a sorbent and electron transfer mediator in environmental applications. *Bioresource Technology*, 218, 77–83. <https://doi.org/10.1016/J.BIORTECH.2016.06.073>
- Ojha, D. K., & Vinu, R. (2018). Chapter 12 - Copyrolysis of Lignocellulosic Biomass With Waste Plastics for Resource Recovery. In T. Bhaskar, A. Pandey, S. V. Mohan, D.-J. Lee, & S. K. Khanal (Eds.), *Waste Biorefinery* (pp. 349–391). Elsevier. <https://doi.org/https://doi.org/10.1016/B978-0-444-63992-9.00012-4>
- Ortiz, M., & Piloto, R. (2022). *Predicción mediante redes neuronales artificiales del rendimiento de bioaceite obtenido a partir de pirólisis de biomasa lignocelulósica*.
- Potnuri, R., Rao, C. S., Surya, D. V., Kumar, A., & Basak, T. (2023). Utilizing support vector regression modeling to predict pyro product yields from microwave-assisted catalytic co-pyrolysis of biomass and waste plastics. *Energy Conversion and Management*, 292, 117387. <https://doi.org/https://doi.org/10.1016/j.enconman.2023.117387>
- Rajpurohit, R., Kamani, P., & Rao, S. (2025). Statistical modeling of pyrolysis variables for sustainable energy. *Renewable Energy*, 210, 112–124. <https://doi.org/10.1016/j.renene.2024.121345>

- Raza, M., Abu-Jdayil, B., Al-Marzouqi, A. H., & Inayat, A. (2022). Kinetic and thermodynamic analyses of date palm surface fibers pyrolysis using Coats-Redfern method. *Renewable Energy*, 183, 67–77. <https://doi.org/10.1016/J.RENENE.2021.10.065>
- Ren, S., Lei, H., Wang, L., Bu, Q., Chen, S., & Wu, J. (2014). Hydrocarbon and hydrogen-rich syngas production by biomass catalytic pyrolysis and bio-oil upgrading over biochar catalysts. *RSC Advances*, 4(21), 10731–10737. <https://doi.org/10.1039/C4RA00122B>
- Ryu, H. W., Lee, H. W., Jae, J., & Park, Y.-K. (2019). Catalytic pyrolysis of lignin for the production of aromatic hydrocarbons: Effect of magnesium oxide catalyst. *Energy*, 179, 669–675. <https://doi.org/https://doi.org/10.1016/j.energy.2019.05.015>
- Selvam S, M., & Paramasivan, B. (2022). Microwave assisted carbonization and activation of biochar for energy-environment nexus: A review. *Chemosphere*, 286, 131631. <https://doi.org/10.1016/J.CHEMOSPHERE.2021.131631>
- Snyder, H. (2021). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104, 333–339. <https://doi.org/10.1016/j.jbusres.2019.07.039>
- Stefanidis, S. D., Karakoulia, S. A., Kalogiannis, K. G., Iliopoulou, E. F., Delimitis, A., Yiannoulakis, H., Zampetakis, T., Lappas, A. A., & Triantafyllidis, K. S. (2016). Natural magnesium oxide (MgO) catalysts: A cost-effective sustainable alternative to acid zeolites for the in situ upgrading of biomass fast pyrolysis oil. *Applied Catalysis B: Environmental*, 196, 155–173. <https://doi.org/https://doi.org/10.1016/j.apcatb.2016.05.031>
- Suriapparao, D. V., & Tejasvi, R. (2022). A review on role of process parameters on pyrolysis of biomass and plastics: Present scope and future opportunities in conventional and microwave-assisted pyrolysis technologies. *Process Safety and Environmental Protection*, 162, 435–462. <https://doi.org/10.1016/J.PSEP.2022.04.024>
- Toscano Miranda, N., Lopes Motta, I., Maciel Filho, R., & Wolf Maciel, M. R. (2021). Sugarcane bagasse pyrolysis: A review of operating conditions and products properties. *Renewable and Sustainable Energy Reviews*, 149, 111394. <https://doi.org/10.1016/J.RSER.2021.111394>
- U.S. DEPARTMENT OF ENERGY. (2016). *Full - Text Glossary - Bioenergy Technologies Office*. https://www.energy.gov/eere/bioenergy/full-text-glossary?utm_source=chatgpt.com#P
- Wang, Z., Burra, K. G., Lei, T., & Gupta, A. K. (2021). Co-pyrolysis of waste plastic and solid biomass for synergistic production of biofuels and chemicals-A review. *Progress in Energy and Combustion Science*, 84, 100899. <https://doi.org/https://doi.org/10.1016/j.pecs.2020.100899>
- Wang, Z., Liu, G., Shen, D., Wu, C., & Gu, S. (2020). Co-pyrolysis of lignin and polyethylene with the addition of transition metals - Part I: Thermal behavior and kinetics analysis. *Journal of the Energy Institute*, 93(1), 281–291. <https://doi.org/https://doi.org/10.1016/j.joei.2019.03.003>

- Zhang, Y., Lei, H., Yang, Z., Duan, D., Villota, E., & Ruan, R. (2018). From glucose-based carbohydrates to phenol-rich bio-oils integrated with syngas production via catalytic pyrolysis over an activated carbon catalyst. *Green Chemistry*, 20(14), 3346–3358. <https://doi.org/10.1039/C8GC00593A>
- Zhu, L., Lei, H., Wang, L., Yadavalli, G., Zhang, X., Wei, Y., Liu, Y., Yan, D., Chen, S., & Ahring, B. (2015). Biochar of corn stover: Microwave-assisted pyrolysis condition induced changes in surface functional groups and characteristics. *Journal of Analytical and Applied Pyrolysis*, 115, 149–156. <https://doi.org/10.1016/J.JAAP.2015.07.012>
- Zoroufchi Benis, K., Minaei, S., Soltan, J., & McPhedran, K. N. (2022). Adsorption of lincomycin on microwave activated biochar: Batch and dynamic adsorption. *Chemical Engineering Research and Design*, 187, 140–150. <https://doi.org/10.1016/J.CHERD.2022.08.058>

6. ANEXOS

Biomasa	Plástico	Prop. Biomasa (%)	Temp. (°C)	T. Resid (s)	Cataliza.	Área (m ² /g)	Bioaceite (%)	Biocarbón (%)
Cáscara de coco	PE	56	596	99	ZSM-5	251,64	61,44	21,68
Residuos agrícolas	PE	43	425	28	ZSM-5	136,52	59,15	18,66
Aserrín	PE	48	503	48	Ni/Al ₂ O ₃	179,93	43,35	20,67
Residuos agrícolas	PE	68	493	76	Carbón activado	259,06	46,61	31,57
Residuos agrícolas	PS	65	435	54	Ni/Al ₂ O ₃	186,58	37,96	18,91
Cáscara de arroz	PE	72	534	22	Ni/Al ₂ O ₃	208,58	22,46	26,99
Aserrín	PET	50	634	101	Ni/Al ₂ O ₃	292,33	35,08	24,28
Aserrín	PVC	54	569	67	Biochar	197,37	56,13	29,91
Aserrín	PE	79	418	29	Biochar	812,25	20,21	38,1
Residuos agrícolas	PS	52	396	101	Ni/Al ₂ O ₃	118,2	35,01	31,98
Cáscara de coco	PS	71	443	81	Carbón activado	495,83	37,92	16,45
Aserrín	PE	40	587	70	ZSM-5	398,84	44,18	10,94
Residuos agrícolas	PVC	51	553	114	Carbón activado	885,02	61,39	17,87
Cáscara de arroz	PE	42	567	48	Sin catalizador	145,23	35,59	27,85
Cáscara de coco	PS	52	388	10	Biochar	388,18	35,61	11,54
Cáscara de arroz	PP	22	449	12	ZSM-5	874,05	53,19	24,89
Cáscara de coco	PET	37	638	86	ZSM-5	785,68	40,35	27,91
Residuos agrícolas	PS	44	603	101	Sin catalizador	744,51	30,11	20,03
Bagazo	PE	61	571	71	Sin catalizador	269,22	40,36	33,13
Cáscara de coco	PET	50	372	72	Ni/Al ₂ O ₃	195,25	26,34	13,2
Cáscara de arroz	PE	73	599	34	Biochar	618,35	27,94	12,25
Residuos agrícolas	PE	77	359	65	Biochar	839,97	42,43	31,85
Cáscara de coco	PP	22	595	42	Carbón activado	523,25	38,85	24,86
Bagazo	PET	59	449	47	Ni/Al ₂ O ₃	535,87	61,17	30,65
Bagazo	PET	65	639	15	Ni/Al ₂ O ₃	287,98	36,31	23,04
Aserrín	PP	43	529	67	Ni/Al ₂ O ₃	704,07	46,13	17,39
Aserrín	PS	69	572	53	Ni/Al ₂ O ₃	208,99	48,45	34,57
Cáscara de arroz	PE	51	599	54	Biochar	325,13	20,59	33,98
Cáscara de coco	PVC	66	496	41	Biochar	411,62	49,86	30,84

Cáscara de coco	PE	41	445	54	Ni/Al ₂ O ₃	481,47	28,01	18,16
Aserrín	PE	42	606	70	Carbón activado	256,05	63,25	27,71
Cáscara de coco	PS	21	353	56	ZSM-5	147,61	26,69	20,83
Cáscara de coco	PE	46	365	30	ZSM-5	569,03	38,66	12,75
Bagazo	PP	61	629	89	Carbón activado	295,34	23,84	37,52
Aserrín	PP	21	596	94	Ni/Al ₂ O ₃	544,05	64,86	14,1
Residuos agrícolas	PET	45	607	84	Biochar	181,21	42,6	38,51
Aserrín	PVC	36	509	110	ZSM-5	458,97	46,79	23,38
Residuos agrícolas	PE	59	501	45	Sin catalizador	502,7	23,02	15,55
Bagazo	PE	52	527	108	Sin catalizador	94,05	53,75	26,26
Cáscara de arroz	PS	28	512	28	Carbón activado	336,11	29,45	36,19
Cáscara de coco	PP	62	382	29	Ni/Al ₂ O ₃	164,25	60,41	31,97
Bagazo	PVC	73	528	66	ZSM-5	103,87	29,23	34,2
Cáscara de coco	PET	67	450	27	Ni/Al ₂ O ₃	891,47	28,58	29,76
Cáscara de arroz	PP	58	617	56	ZSM-5	324	21,64	30,77
Cáscara de arroz	PET	48	414	114	Carbón activado	738,39	41,24	35,48
Bagazo	PS	61	517	58	Carbón activado	266,44	45,42	17,49
Cáscara de arroz	PS	74	392	23	Sin catalizador	629,28	22,96	24,68
Residuos agrícolas	PE	45	393	24	Ni/Al ₂ O ₃	696,19	54,9	16,64
Cáscara de arroz	PVC	54	634	40	Sin catalizador	556,29	40,4	39,63
Cáscara de coco	PET	69	361	10	Ni/Al ₂ O ₃	450,84	43,6	38,32
Cáscara de coco	PP	44	444	63	Sin catalizador	400,06	39,83	11,18
Cáscara de coco	PS	43	602	12	Biochar	346,54	38,03	31,17
Cáscara de coco	PE	32	591	25	Biochar	840,1	45,18	37,76
Residuos agrícolas	PE	79	384	96	Biochar	756,03	26,99	15,42
Aserrín	PET	77	564	66	Biochar	870,27	28,19	27,04
Bagazo	PS	26	439	84	ZSM-5	155,65	58,78	37,46
Cáscara de coco	PVC	76	613	21	Biochar	671,24	62,58	11,02
Cáscara de arroz	PS	55	442	83	Carbón activado	847,59	36,8	30,92
Cáscara de coco	PET	64	439	105	Carbón activado	204,05	32,18	18,92
Cáscara de arroz	PET	39	464	25	ZSM-5	106,52	48,98	37,73

Cáscara de arroz	PS	20	454	81	Biochar	679,95	38,39	39,13
Cáscara de coco	PET	27	545	111	Biochar	538,3	21,14	38,33
Residuos agrícolas	PS	65	463	85	Biochar	765,55	27,03	24,23
Cáscara de arroz	PP	35	424	33	Sin catalizador	168,81	52,22	35,86
Cáscara de arroz	PS	33	566	37	Ni/Al ₂ O ₃	725,98	49,65	35,34
Cáscara de coco	PS	31	626	17	Sin catalizador	221,38	21,22	19,57
Cáscara de arroz	PET	70	598	101	Ni/Al ₂ O ₃	189,11	29,99	34,87
Cáscara de arroz	PET	42	513	45	Biochar	189,63	30,4	11,11
Cáscara de coco	PE	34	541	99	Biochar	742,39	50,24	27,89
Cáscara de coco	PE	47	576	17	Sin catalizador	615,42	20,89	16,9
Bagazo	PP	53	526	67	Sin catalizador	494,61	24,68	13,62
Residuos agrícolas	PE	21	448	69	Ni/Al ₂ O ₃	355,01	56	12,31
Residuos agrícolas	PS	51	385	59	Carbón activado	795,62	28,03	30,89
Cáscara de arroz	PET	42	445	37	Ni/Al ₂ O ₃	383,58	49,37	20,2
Residuos agrícolas	PE	41	501	101	Sin catalizador	744,11	30,72	31,74
Cáscara de arroz	PE	70	500	110	Sin catalizador	423,26	24,47	11,96
Bagazo	PP	44	539	50	ZSM-5	370,4	30,94	19,46
Cáscara de coco	PP	77	573	109	Sin catalizador	443,28	52,5	26,18
Cáscara de coco	PS	41	386	73	ZSM-5	306,17	58,51	33,72
Cáscara de coco	PET	77	617	36	Carbón activado	685,47	57,36	19,56
Residuos agrícolas	PP	77	532	72	Ni/Al ₂ O ₃	477,31	37,87	28,78
Bagazo	PE	41	362	26	Ni/Al ₂ O ₃	247,38	50,06	36,58
Residuos agrícolas	PET	68	628	82	ZSM-5	814,64	29,22	28,48
Residuos agrícolas	PET	71	566	42	Ni/Al ₂ O ₃	376,31	33,19	16,99
Bagazo	PE	61	635	93	Sin catalizador	512,02	60,34	10,73
Bagazo	PP	25	622	86	Biochar	820,5	20,59	36,1
Bagazo	PE	34	411	101	ZSM-5	580,6	23,85	10,64
Bagazo	PET	73	433	38	Ni/Al ₂ O ₃	149,36	29,35	36,24
Cáscara de coco	PVC	62	566	22	ZSM-5	848,86	21,19	25,87
Aserrín	PVC	79	536	55	ZSM-5	583,55	28,16	38,17
Aserrín	PS	56	368	44	Biochar	334,67	46,24	33,96
Bagazo	PE	52	526	15	Sin catalizador	168,38	38,96	39,94

Aserrín	PE	27	449	91	ZSM-5	724,92	60,17	20,52
Aserrín	PS	72	582	78	Ni/Al ₂ O ₃	577,06	56,78	33,02
Bagazo	PS	79	425	56	Carbón activado	503,44	35,38	22,06
Aserrín	PS	63	614	34	ZSM-5	809,81	31,67	24,4
Residuos agrícolas	PET	63	633	75	ZSM-5	720,31	37,09	28,83
Cáscara de arroz	PE	24	555	19	Biochar	178,92	46,56	36,21
Cáscara de arroz	PET	58	572	65	Sin catalizador	314,96	32,06	39,52
Bagazo	PS	23	401	39	Carbón activado	261,22	48,09	33,05
Cáscara de coco	PE	25	493	118	Ni/Al ₂ O ₃	682,35	38,42	22,53
Bagazo	PET	64	418	14	Carbón activado	78,5	44,84	22,64
Cáscara de coco	PET	51	448	42	Ni/Al ₂ O ₃	534,41	39,63	32,13
Cáscara de arroz	PS	71	374	74	Sin catalizador	698,09	33,25	17,16
Bagazo	PE	49	402	27	Ni/Al ₂ O ₃	795,25	62,68	13,31
Residuos agrícolas	PS	66	500	105	Biochar	340,77	54,36	20,64
Aserrín	PE	54	493	58	Biochar	748,07	26,31	18,62
Cáscara de coco	PVC	74	406	20	Biochar	144,04	59,08	18,89
Aserrín	PP	59	388	94	Biochar	769,48	41,93	17,01
Aserrín	PP	71	458	35	Carbón activado	158,37	60,25	11,26
Bagazo	PP	35	530	72	Sin catalizador	387,69	55,99	10,54
Aserrín	PS	32	391	98	Ni/Al ₂ O ₃	727,7	39,13	39,63
Residuos agrícolas	PVC	69	535	95	Ni/Al ₂ O ₃	177,43	21,01	22,83
Aserrín	PE	79	572	68	Biochar	244,86	32,09	21,53
Bagazo	PET	61	471	36	Biochar	663,91	44,37	30,39
Residuos agrícolas	PE	49	482	58	ZSM-5	662,03	48,51	16,55
Cáscara de arroz	PET	38	512	86	Sin catalizador	594,98	31,6	38,5
Aserrín	PE	36	564	42	Carbón activado	639,86	26,27	33,59
Bagazo	PVC	75	570	107	Ni/Al ₂ O ₃	511,32	57,57	12,68
Cáscara de arroz	PET	38	584	114	ZSM-5	264,03	64,3	22,53
Cáscara de arroz	PS	47	495	108	ZSM-5	343,84	43,66	36,37
Cáscara de coco	PE	77	588	10	Ni/Al ₂ O ₃	204,36	27,73	38,34
Residuos agrícolas	PE	74	425	30	Carbón activado	822,18	32,25	24,02
Aserrín	PET	45	358	64	ZSM-5	545,88	20,83	28,4
Bagazo	PS	56	423	15	ZSM-5	390,72	61,14	15,01

Cáscara de coco	PS	45	602	101	Sin catalizador	442,7	25,3	39,74
Residuos agrícolas	PVC	72	579	90	Carbón activado	855,19	45,94	16,95
Cáscara de coco	PS	42	356	78	ZSM-5	180,35	32,33	38,28
Residuos agrícolas	PS	28	523	104	Carbón activado	548,3	44,94	29,49
Residuos agrícolas	PS	31	490	14	Ni/Al ₂ O ₃	480,01	49,31	28,23
Aserrín	PP	72	517	111	Biochar	569,74	57,34	25,38
Residuos agrícolas	PVC	20	519	12	ZSM-5	65,39	29,29	16,92
Cáscara de coco	PE	77	632	62	Sin catalizador	791,31	20,49	15,3
Residuos agrícolas	PET	77	471	32	Ni/Al ₂ O ₃	842,3	26,16	16,61
Aserrín	PE	20	543	110	Carbón activado	530,36	60,5	15,59
Aserrín	PVC	66	354	62	Ni/Al ₂ O ₃	642,15	59,33	33,39
Cáscara de coco	PET	53	378	46	ZSM-5	834,12	46,88	20,5
Cáscara de arroz	PVC	51	514	83	Carbón activado	651,15	47,02	11,74
Cáscara de arroz	PS	73	485	83	Biochar	179,66	49,93	39,07
Residuos agrícolas	PET	67	494	92	Ni/Al ₂ O ₃	539,85	27,89	36,51
Bagazo	PS	44	566	26	ZSM-5	565,71	61,15	37,83
Residuos agrícolas	PE	59	481	94	Sin catalizador	410,51	38,84	39,85
Cáscara de coco	PE	64	641	87	Carbón activado	675,98	37,24	15,22
Cáscara de coco	PET	72	419	82	Ni/Al ₂ O ₃	844,21	43,35	21,89
Cáscara de coco	PET	20	601	119	Ni/Al ₂ O ₃	836,73	22,11	32,75
Cáscara de coco	PVC	35	624	10	Biochar	433,21	27,48	30,88
Cáscara de coco	PVC	58	531	60	Biochar	146,25	53,21	14,62
Aserrín	PS	24	516	54	Sin catalizador	887,12	23,73	34,47
Cáscara de arroz	PET	41	440	86	Sin catalizador	763,06	47,14	16,73
Cáscara de coco	PE	48	551	13	ZSM-5	155,96	31,04	16,71

Gas (%)	Celulosa (%)	Hemicelulosa (%)	Lignina (%)	Cenizas (%)	C (%)	H (%)	O (%)	Relación C/H
17,25	30	25	35	10	55	5,8	39,2	9,48
23,12	40	30	20	10	46	6	48	7,67
36,78	45	30	25	1	50	6	43	8,33
17,74	40	30	20	10	46	6	48	7,67
46,91	40	30	20	10	46	6	48	7,67
48,2	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
36,93	45	30	25	1	50	6	43	8,33
17,85	45	30	25	1	50	6	43	8,33
46,24	45	30	25	1	50	6	43	8,33
36,64	40	30	20	10	46	6	48	7,67
48,73	30	25	35	10	55	5,8	39,2	9,48
46,43	45	30	25	1	50	6	43	8,33
21,25	40	30	20	10	46	6	48	7,67
32,43	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
51,93	30	25	35	10	55	5,8	39,2	9,48
20,65	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
29,34	30	25	35	10	55	5,8	39,2	9,48
52,1	40	30	20	10	46	6	48	7,67
26,47	45	30	20	5	46	6	47	7,67
56,27	30	25	35	10	55	5,8	39,2	9,48
57,01	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
27,56	40	30	20	10	46	6	48	7,67
32,04	30	25	35	10	55	5,8	39,2	9,48
11,69	45	30	20	5	46	6	47	7,67
40,6	45	30	20	5	46	6	47	7,67
36,29	45	30	25	1	50	6	43	8,33
17,9	45	30	25	1	50	6	43	8,33
48,68	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
17,78	30	25	35	10	55	5,8	39,2	9,48
55,6	30	25	35	10	55	5,8	39,2	9,48
9,7	45	30	25	1	50	6	43	8,33
50,15	30	25	35	10	55	5,8	39,2	9,48
52,38	30	25	35	10	55	5,8	39,2	9,48
41,61	45	30	20	5	46	6	47	7,67
22,62	45	30	25	1	50	6	43	8,33
22,4	40	30	20	10	46	6	48	7,67
33,5	45	30	25	1	50	6	43	8,33
63,51	40	30	20	10	46	6	48	7,67
23,36	45	30	20	5	46	6	47	7,67
36,34	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
9,42	30	25	35	10	55	5,8	39,2	9,48
37,76	45	30	20	5	46	6	47	7,67
44,18	30	25	35	10	55	5,8	39,2	9,48

44,17	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
27,09	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
40,81	45	30	20	5	46	6	47	7,67
47,65	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
31,72	40	30	20	10	46	6	48	7,67
16,26	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
16,43	30	25	35	10	55	5,8	39,2	9,48
51,42	30	25	35	10	55	5,8	39,2	9,48
27,41	30	25	35	10	55	5,8	39,2	9,48
20,24	30	25	35	10	55	5,8	39,2	9,48
60,92	40	30	20	10	46	6	48	7,67
44,85	45	30	25	1	50	6	43	8,33
3,76	45	30	20	5	46	6	47	7,67
26,4	30	25	35	10	55	5,8	39,2	9,48
32,28	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
48,9	30	25	35	10	55	5,8	39,2	9,48
13,29	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
22,48	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
40,53	30	25	35	10	55	5,8	39,2	9,48
48,74	40	30	20	10	46	6	48	7,67
11,92	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
15,01	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
59,21	30	25	35	10	55	5,8	39,2	9,48
35,14	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
58,49	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
21,87	30	25	35	10	55	5,8	39,2	9,48
62,21	30	25	35	10	55	5,8	39,2	9,48
61,7	45	30	20	5	46	6	47	7,67
31,69	40	30	20	10	46	6	48	7,67
41,08	40	30	20	10	46	6	48	7,67
30,43	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
37,54	40	30	20	10	46	6	48	7,67
63,57	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
49,6	45	30	20	5	46	6	47	7,67
21,32	30	25	35	10	55	5,8	39,2	9,48
7,77	30	25	35	10	55	5,8	39,2	9,48
23,08	30	25	35	10	55	5,8	39,2	9,48
33,35	40	30	20	10	46	6	48	7,67
13,36	45	30	20	5	46	6	47	7,67
42,3	40	30	20	10	46	6	48	7,67
49,82	40	30	20	10	46	6	48	7,67
28,93	45	30	20	5	46	6	47	7,67
43,31	45	30	20	5	46	6	47	7,67
65,51	45	30	20	5	46	6	47	7,67
34,41	45	30	20	5	46	6	47	7,67

52,94	30	25	35	10	55	5,8	39,2	9,48
33,67	45	30	25	1	50	6	43	8,33
19,8	45	30	25	1	50	6	43	8,33
21,1	45	30	20	5	46	6	47	7,67
19,31	45	30	25	1	50	6	43	8,33
10,2	45	30	25	1	50	6	43	8,33
42,56	45	30	20	5	46	6	47	7,67
43,93	45	30	25	1	50	6	43	8,33
34,08	40	30	20	10	46	6	48	7,67
17,23	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
28,42	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
18,86	45	30	20	5	46	6	47	7,67
39,05	30	25	35	10	55	5,8	39,2	9,48
32,52	45	30	20	5	46	6	47	7,67
28,24	30	25	35	10	55	5,8	39,2	9,48
49,59	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
24,01	45	30	20	5	46	6	47	7,67
25	40	30	20	10	46	6	48	7,67
55,07	45	30	25	1	50	6	43	8,33
22,03	30	25	35	10	55	5,8	39,2	9,48
41,06	45	30	25	1	50	6	43	8,33
28,49	45	30	25	1	50	6	43	8,33
33,47	45	30	20	5	46	6	47	7,67
21,24	45	30	25	1	50	6	43	8,33
56,16	40	30	20	10	46	6	48	7,67
46,38	45	30	25	1	50	6	43	8,33
25,24	45	30	20	5	46	6	47	7,67
34,94	40	30	20	10	46	6	48	7,67
29,9	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
40,14	45	30	25	1	50	6	43	8,33
29,75	45	30	20	5	46	6	47	7,67
13,17	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
19,97	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
33,93	30	25	35	10	55	5,8	39,2	9,48
43,73	40	30	20	10	46	6	48	7,67
50,77	45	30	25	1	50	6	43	8,33
23,85	45	30	20	5	46	6	47	7,67
34,96	30	25	35	10	55	5,8	39,2	9,48
37,11	40	30	20	10	46	6	48	7,67
29,39	30	25	35	10	55	5,8	39,2	9,48
25,57	40	30	20	10	46	6	48	7,67
22,46	40	30	20	10	46	6	48	7,67
17,28	45	30	25	1	50	6	43	8,33
53,79	40	30	20	10	46	6	48	7,67
64,21	30	25	35	10	55	5,8	39,2	9,48

57,23	40	30	20	10	46	6	48	7,67
23,91	45	30	25	1	50	6	43	8,33
7,28	45	30	25	1	50	6	43	8,33
32,62	30	25	35	10	55	5,8	39,2	9,48
41,24	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
11	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
35,6	40	30	20	10	46	6	48	7,67
1,02	45	30	20	5	46	6	47	7,67
21,31	40	30	20	10	46	6	48	7,67
47,54	30	25	35	10	55	5,8	39,2	9,48
34,76	30	25	35	10	55	5,8	39,2	9,48
45,14	30	25	35	10	55	5,8	39,2	9,48
41,64	30	25	35	10	55	5,8	39,2	9,48
32,17	30	25	35	10	55	5,8	39,2	9,48
41,8	45	30	25	1	50	6	43	8,33
36,13	46,2	42,4	7,1	18,8	46,5	6,1	46,7	7,62
52,25	30	25	35	10	55	5,8	39,2	9,48