



FACULTAD DE POSTGRADO

TESIS DE POSTGRADO

**OPTIMIZACIÓN DE LA CAPTURA DE AZUFRE
DURANTE LA COMBUSTION EN UNA CALDERA DE VAPOR
DE LECHO FLUIDIZADO**

SUSTENTADO POR:

JESUS JAVIER TORRES TORRES

ERIK MANUEL SIERRA SIERRA

PREVIA INVESTIDURA AL TÍTULO DE

MÁSTER EN ANALITICA DE NEGOCIOS

SAN PEDRO SULA, CORTÉS HONDURAS, C.A.

ENERO 2025

UNIVERSIDAD TECNOLÓGICA CENTROAMERICANA

UNITEC

FACULTAD DE POSTGRADO

AUTORIDADES UNIVERSITARIAS

PRESIDENTE EJECUTIVO /

RECTORA

ROSALPINA RODRÍGUEZ

SECRETARIO GENERAL /

PRORRECTOR

ROGER MARTÍNEZ MIRALDA

VICERRECTOR ACÁDEMICO NACIONAL

JAVIER ABRAHAM SALGADO LEZAMA

DECANA FACULTAD DE POSTGRADO

ANA DEL CARMEN RETTALLY

OPTIMIZACIÓN DE LA CAPTURA DE AZUFRE

DURANTE

LA COMBUSTION EN UNA CALDERA DE VAPOR DE

LECHO FLUIDIZADO

**TRABAJO PRESENTADO EN CUMPLIMIENTO DE
LOS REQUISITOS EXIGIDOS PARA OPTAR AL
TÍTULO DE
MÁSTER EN ANALITICA DE NEGOCIOS**

ASESOR METODOLÓGICO

MARVIN ROBERTO MENDOZA

MIEMBROS DE LA TERNA

JULISSA JAMILETH CORTES

ANTHONY STEVE BARAHONA

ALEJANDRO JOSE COLINDRES

DERECHOS DE AUTOR

© Copyright 2024
Jesús Javier Torres
Erik Manuel Sierra

Todos los derechos son reservados.

FACULTAD DE POSTGRADO

OPTIMIZACIÓN DE LA CAPTURA DE AZUFRE DURANTE LA COMBUSTION EN UNA CALDERA DE VAPOR DE LECHO FLUIDIZADO

JESUS JAVIER TORRES TORRES

ERIK MANUEL SIERRA SIERRA

Resumen

El presente trabajo se enfocó en reducir el consumo de carbonato de calcio en calderas de lecho fluidizado, manteniendo las emisiones de dióxido de azufre (SO_2) dentro de los límites normativos. El objetivo principal fue optimizar las condiciones operativas mediante el uso de herramientas tecnológicas y técnicas de modelado predictivo. La metodología incluyó un análisis cuantitativo que evaluó variables como el exceso de oxígeno, la presión diferencial y la temperatura, combinadas con modelos de regresión polinomial y algoritmos de machine learning como Random Forest. Los resultados destacaron que el modelo polinomial explicó el 58% de la variabilidad en las emisiones, mientras que Random Forest clasificó eficazmente escenarios óptimos y no óptimos. Se concluyó que estas herramientas permitieron reducir costos operativos y cumplir con normativas ambientales, recomendando su implementación en industrias similares.

Palabras clave: (carbonato de calcio, emisiones, machine learning, regresión, sostenibilidad)

GRADUATE SCHOOL

Optimization of Sulfur Capture During Combustion in a Fluidized Bed Steam Boiler

JESUS JAVIER TORRES TORRES

ERIK MANUEL SIERRA SIERRA

Abstract

This study focused on reducing calcium carbonate consumption in fluidized bed boilers while maintaining sulfur dioxide (SO₂) emissions within regulatory limits. The main objective was to optimize operational conditions using technological tools and predictive modeling techniques. The methodology included a quantitative analysis evaluating variables such as excess oxygen, differential pressure, and temperature, combined with polynomial regression models and machine learning algorithms like Random Forest. Results showed that the polynomial model explained 58% of the variability in emissions, while Random Forest effectively classified optimal and non-optimal scenarios. It was concluded that these tools enabled cost reductions and compliance with environmental regulations, recommending their implementation in similar industries.

Keywords: (calcium carbonate, emissions, machine learning, regression, sustainability)

DEDICATORIA

Dedicatoria...

Dedicado a Dios y a mis padres que han sido mi motor de vida y me han enseñado a no rendirme y seguir adelante, siempre con perseverancia, honestidad y esfuerzo

- **Erik Manuel Sierra**

Se lo dedico a mi mamá que no entiende estos temas, pero se alegra cuando le platico.

- **Jesús Javier Torres**

AGRADECIMIENTO

Agradecimiento...

Gracias en primer lugar a Dios por la vida, gracias a mis padres, a mi familia, a mis compañeros de maestría por todo el apoyo, a los docentes de la maestría de Analítica de Negocios y a UNITEC por su disposición y aptitud de formar grandes profesionales.

- **Erik Manuel Sierra**

Gracias a mis cuatro hermanas por cuidar de mi salud mental y física durante estos dos años de estudio y a todo el staff de docentes de la maestría en analítica de negocios que nos ayudaron a subirnos en este barco de la analítica de datos.

- **Jesús Javier Torres**

ÍNDICE DE CONTENIDO

DEDICATORIA	III
AGRADECIMIENTO	IV
CAPÍTULO I. PLANTEAMIENTO DE LA INVESTIGACIÓN	1
1.1 INTRODUCCIÓN	1
1.2 ANTECEDENTES DEL PROBLEMA	2
1.3 DEFINICIÓN DEL PROBLEMA	3
1.3.2 PREGUNTAS DE INVESTIGACION	5
1.4 OBJETIVOS DEL PROYECTO	6
1.5 JUSTIFICACIÓN	6
CAPÍTULO II. MARCO TEÓRICO	8
2.1 ANÁLISIS DE LA SITUACIÓN ACTUAL.	8
2.2 CONCEPTUALIZACIÓN	9
2.3 TEORÍAS DE SUSTENTO	15
2.3.1 BASES TEÓRICAS	17
2.3.1.2 K-Means Clustering	19
2.3.1.3 Regresion polinomial	20
2.3.2 METODOLOGÍAS DESARROLLADAS	21
2.3.3 INSTRUMENTOS UTILIZADOS	24
2.4 MARCO LEGAL	24
CAPÍTULO III. METODOLOGÍA	27
3.1 CONGRUENCIA METODOLÓGICA	27
3.1.1 MATRIZ METODOLÓGICA	28
3.1.2 ESQUEMA DE VARIABLES DE ESTUDIO	29
3.1.3 OPERACIONALIZACIÓN DE LAS VARIABLES	29

3.1.4	HIPÓTESIS	30
3.2	ENFOQUE Y MÉTODOS	30
3.3	DISEÑO DE LA INVESTIGACIÓN	31
3.3.1	POBLACIÓN	31
3.3.2	MUESTRA	31
3.3.3	TÉCNICAS DE MUESTREO	32
3.4	TÉCNICAS, INSTRUMENTOS Y PROCEDIMIENTOS APLICADOS	32
3.5	FUENTES DE INFORMACIÓN	33
3.5.1	FUENTES PRIMARIAS.....	33
3.5.2	FUENTES SECUNDARIAS	33
CAPÍTULO IV. RESULTADOS Y ANÁLISIS		34
4.1	Informe de proceso de recolección de datos	34
4.2.1	ANÁLISIS CUANTITATIVO	35
CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES.....		45
5.1	Conclusiones	45
5.2	Recomendaciones	47
CAPÍTULO VI. APLICABILIDAD		48
	Semana 1: Planificación y diseño	50
	Semana 2: Configuración del flujo en Power Automate	51
	Semana 3: Pruebas y ajustes	51
	Semana 4: Documentación y despliegue	51
Referencias Bibliograficas		58
ANEXOS		58
 ÍNDICE DE TABLAS		
Tabla 1. Matriz Metodológica		28
Tabla 2 Tabla de Operacionalización		30

Tabla 3. Modelo resultado de la regresión polinomial	40
Tabla 4 Presupuesto para implementación de la propuesta	53
Tabla 5. Matriz de concordancia	55

ÍNDICE DE FIGURAS Figura 1 Mezcla de combustible durante el 2023 ¡Error! Marcador no definido.

Figura 2. Hogar de caldera	10
Figura 3. Grado de desulfuración vrs razón Ca/S.....	14
Figura 4. Efecto de la relación aire primario/aire secundario en el grado de desulfuración	15
Figura 5. Resultados obtenidos al analizar la temperatura, flujo de vapor y emisiones de NOx	19
Figura 6. Combinación de SOM con K-Means para agrupar procesos y subprocesos ..	20
Figura 7 Razón de carbonato de calcio por tonelada de combustible en el mes de octubre	35
Figura 8 Gráfico de toneladas de Petcoke por tonelada de combustible en la mezcla ...	35
Figura 9 Matriz de correlación entre las variables	37
Figura 10 Matriz de coeficientes de correlación de Pearson	37
Figura 11 Selección de grado con el optimizador de parametros de Knime	38
Figura 12 Estadísticas de la regresión polinomial	39
Figura 13 Gráfico comparativo de los valores de SO ₂ medidos (azul) y los valores de la predicción con el modelo de la regresión polinomial.....	41
Figura 14 Selección de modelo	43
Figura 15 Selección de mejor modelo luego de reducir predictores por elevada correlación	44
Figura 16 Métricas de los modelos de clasificación aplicados.....	44
Figura 17 Diagrama de flujo de trabajo a implementar	49
Figura 18 Diagrama de Gantt de la propuesta	52

CAPÍTULO I. PLANTEAMIENTO DE LA INVESTIGACIÓN

Este capítulo presenta el planteamiento del problema de investigación, proporcionando los antecedentes que contextualizan el estudio. Asimismo, se definen los objetivos generales y específicos que guían esta investigación, destacando su relevancia tanto para la reducción de costos operativas de la compañía como para la reducción de emisiones de SO₂.

1.1 INTRODUCCIÓN

Las empresas en la región hondureña con el fin de producir al menor costo posible le apuestan a la generación de su propia energía, esto para garantizar la continuidad de sus procesos, no depender de la Red Eléctrica Nacional (no hay suficiente capacidad instalada para alimentar a la industria) y producir a menor costo.

La empresa X cuenta con calderas de vapor para suplir de energía térmica (en forma de vapor) su proceso textil y el resto de vapor para la generación de energía eléctrica con dos turbinas de vapor.

Al producir su propia energía también debe asumir los problemas derivados como ser elevados precios de importación de piezas de repuesto, combustible y como tema de esta investigación: el control de las emisiones de los gases de escape a la salida de la caldera.

Las soluciones a las mayorías de los problemas en las calderas son dadas por expertos de países asiáticos como La India y China, donde las calderas de lecho fluidizada para la generación de vapor son bastante comunes. Este fue el incentivo para comenzar esta investigación, comenzar a producir conocimiento desde Honduras sobre calderas de lecho fluidizado y que este tipo de calderas se hagan más popular en el país.

1.2 ANTECEDENTES DEL PROBLEMA

Las emisiones de dióxido de azufre han sido durante mucho tiempo un desafío ambiental en las industrias debido a su impacto negativo en la calidad del aire y el medio ambiente circundante.

Las actividades industriales que implican la combustión de combustibles fósiles, como las centrales eléctricas, las plantas de energía térmica, las fundiciones, las refinerías y la industria química, son las principales fuentes de emisiones de SO₂.

Estas industrias liberan grandes cantidades de dióxido de azufre a la atmósfera como subproducto de sus procesos de producción y generación de energía, trayendo consigo complicaciones ambientales como contaminación del aire generación de partículas de sulfato y causar daños a la vegetación. (Smith, 2019). Para el caso de Centro América, algunos autores han realizado estudios específicamente en el área volcánica, tal es el caso de Costa Rica donde se señalan que este tipo de actividades volcánicas naturales generan problemas cardiovasculares y respiratorios debido a las emisiones de SO₂, Chaves (2021) y otros autores señalan como los sectores industriales han contribuido a la emisión de gases que contienen SO₂, principalmente industrias dedicadas a la fundición de vidrio, textilera, producción de alimentos procesados, etc. (Alfaro et al, 2021, p.143)

Dada la importancia de abordar las emisiones de dióxido de azufre en las industrias, es fundamental llevar a cabo investigaciones dirigidas a comprender mejor las fuentes, los procesos y los impactos de estas emisiones. Bajo este contexto, La industria textil ha sido identificada como una de las principales fuentes antropogénicas de emisiones de dióxido de azufre (SO₂) en diversos estudios previos. (Guo et al. 2022) El proceso de producción textil, que implica el tratamiento de fibras naturales y sintéticas con productos químicos y energía térmica, libera gases contaminantes, incluido el SO₂, en la atmósfera como subproducto de la combustión de combustibles fósiles y la descomposición de compuestos azufrados presentes en los materiales textiles (Smith 2019)

La optimización de las plantas de producción textil ha surgido como una estrategia efectiva para reducir las emisiones de SO₂ sin comprometer la viabilidad económica de las operaciones. Investigaciones previas han abordado diversas técnicas de optimización, como la optimización de procesos, la gestión eficiente de la energía y el diseño de sistemas de control avanzados, para mitigar las emisiones de contaminantes atmosféricos en la industria textil. (Liu et al. 2019)

1.3 DEFINICIÓN DEL PROBLEMA

La empresa textil X dedicada a la fabricación de telas para exportación, tiene en su parque calderas de vapor con una capacidad instalada de 135 ton/h. El vapor generado en las calderas se usa en el proceso textil de teñido, secado y compactado. El vapor restante pasa a través de turbinas de vapor para la generación de la energía eléctrica necesaria para la operación, independizando el parque de la red de energía nacional. Las calderas son del tipo lecho fluidizado, en este tipo de calderas la combustión ocurre en una cama de arena-gas (aire) en movimiento.

La combustión en lecho fluidizado se exploró con el fin de disminuir las emisiones de gases nocivos al ambiente especialmente el Sox, Nox , la combustión ocurre a temperaturas entre los 800 y 1000 °C (Jimenez, 2012). Para el caso de los gases Sox incluyen principalmente dióxido de azufre SO₂ y trióxido de azufre, que repercuten en el sistema respiratorio en general y agravan problemas respiratorios preexistentes como el asma

Los gases Nox/ óxidos de nitrógeno además de generar problemas respiratorios pueden reaccionar en la atmosfera para formar ozono troposférico que es un contaminante atmosférico secundario asociado con efectos adversos en la salud humana y el medio ambiente.

La empresa textil X dedicada a la fabricación de telas para exportación, tiene en su parque calderas de vapor con una capacidad instalada de 135 ton/h. El vapor generado en las calderas se usa en el proceso textil de teñido, secado y compactado. El vapor restante pasa a través de turbinas de vapor para la generación de la energía eléctrica necesaria para la operación, independizando el parque de la red de energía nacional.

La caldera de mayor generación de vapor cambió su combustible en el 2023 de carbón mineral a coque de petróleo también conocido como Petcoke por su nombre en inglés (Petroleum Coke). En la Figura 1 Mezcla de combustible durante el 2023 se muestra el proceso de modificación de la mezcla durante los 12 meses del año 2023. El coque de petróleo es un residuo sólido de color gris oscuro o negro con un alto contenido de carbono. Se obtiene durante el proceso de conversión térmica en el procesamiento del petróleo crudo.

El contenido de azufre en el Petcoke es el doble si lo comparamos con el carbón mineral, el petcoke contiene 6% de azufre de acuerdo a la hoja de datos del combustible. La decisión de cambiarse a este tipo de combustible se debió al alto poder calorífico que posee, 7500 kcal/kg

contra un 6000 kcal/kg para el caso del carbón. Es decir, se genera más energía con la misma masa de combustible, reflejando ahorros significativos en la cuenta de materia prima.

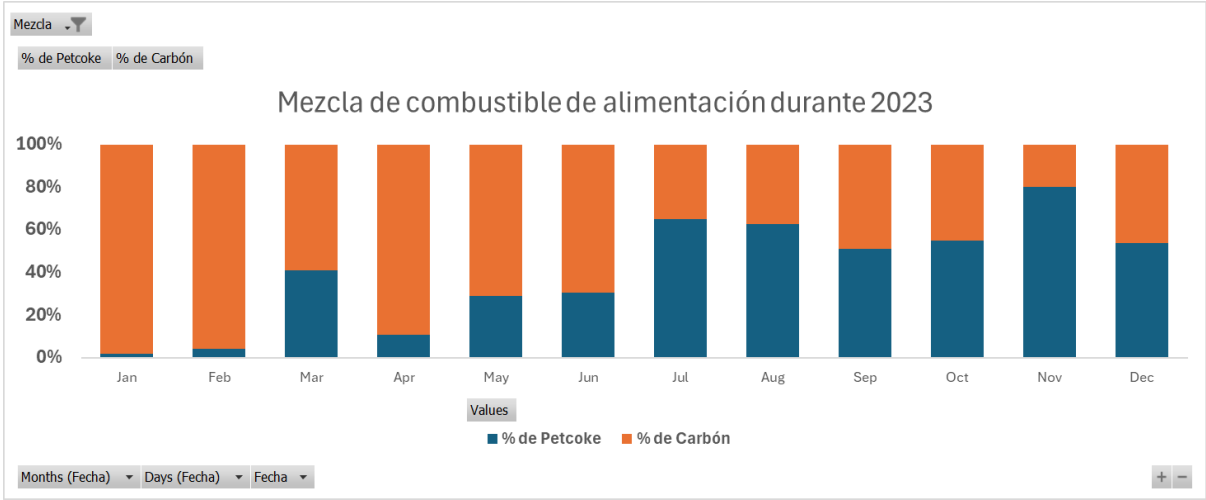


Figura 1 Mezcla de combustible durante el 2023

Fuente: Elaboración propia

El carbonato de calcio, una de las opciones más comunes para mitigar las emisiones de dióxido de azufre en calderas de lecho fluidizado, se utiliza como un agente sorbete. Cuando el carbonato de calcio se introduce en la caldera, reacciona químicamente con el dióxido de azufre presente en los gases de combustión, formando sulfato de calcio y dióxido de carbono. Esta reacción, conocida como desulfuración, es altamente eficiente para eliminar el dióxido de azufre de los gases de combustión. Además, el sulfato de calcio producido es un subproducto no tóxico que puede ser eliminado de manera segura, lo que hace que el proceso sea respetuoso con el medio ambiente. Esta estrategia de control de emisiones ha sido ampliamente adoptada en la industria textil (Smith, 2019)

Como se planteó anteriormente el combustible usado desde el ultimo semestre del 2023 es petcoke con un contenido de 6% de azufre y un bajo 0.3% de ceniza. Con una granulometría de 70% menor a 0.85mm.

Según Ballesteros (2008), para una caldera de este tipo, pero usando carbón mineral como combustible, el 20% de carbonato es necesario para controlar las emisiones de dióxido de azufre. Este porcentaje de carbonato de calcio no es suficiente para una combustión con petcoke.

Cuando decimos controlar emisiones nos referimos a mantener la concentración de dióxido de azufre por debajo de los 2000 mg por metro cubico normalizado del gas de escape de la caldera (medido en la chimenea).

En Honduras se debe cumplir con el decreto 32,448 que obliga a las empresas generadoras a partir de su quinto año de operación a mantener las emisiones por debajo de los 2000 mg/Nm³ (Secretaria de Recursos Naturales y Ambiente, 2011).

1.3.2 PREGUNTAS DE INVESTIGACION

A continuación, detallamos las preguntas de investigación:

Pregunta principal:

¿Cómo optimizar la captura de azufre en la caldera para mantener las emisiones de dióxido de azufre por debajo de los 2000 mg/Nm³ sin aumentar la cantidad de carbonato de calcio utilizado?

Preguntas secundarias:

¿Cuál es el impacto del flujo de aire de combustión en la variación de las emisiones de dióxido de azufre?

¿Cómo influye el exceso de oxígeno en la variación de las emisiones de dióxido de azufre?

¿Qué efecto tiene la temperatura en la eficiencia de captura de azufre en la caldera?

¿Cuál es la relación entre la presión diferencial en el hogar de la caldera y las emisiones de dióxido de azufre?

¿Qué modelo matemático explica mejor la variación en las emisiones de dióxido de azufre?

1.4 OBJETIVOS DEL PROYECTO

El objetivo general es optimizar la captura de azufre en la caldera que permita mantener las emisiones de dióxido de azufre bajo norma, menor a 2000 mg/Nm^3 , sin aumentar la cantidad de carbonato de calcio introducido en la caldera.

Los objetivos específicos son:

1. Determinar cómo afecta el flujo de aire de combustión en la variación de las emisiones de dióxido de azufre.
2. Revisar cómo afecta el exceso de oxígeno de combustión en la variación de las emisiones de dióxido de azufre.
3. Definir cómo afecta la temperatura de la caldera en la variación de las emisiones de dióxido de azufre.
4. Determinar cómo afecta la presión diferencial en el hogar de la caldera en la variación de las emisiones de dióxido de azufre.
5. Seleccionar un modelo matemático que explique más del 50% de la variación en las emisiones de dióxido de azufre.

1.5 JUSTIFICACIÓN

El tema de la captura de azufre en una caldera de vapor de lecho fluidizado no ha sido estudiado en nuestro país, no hay investigación científica sobre este tema y considerando que, por los altos valores comprobado de eficiencia energética en este tipo de calderas, estas calderas aumentarán su popularidad en el país, sería de gran aporte proporcionar una mezcla optimizada de carbonato de calcio para la captura de azufre.

Es necesario optimizar este proceso de captura de azufre para hacer que la operación de la caldera sea aún más rentable. Para una planta que opera este tipo de caldera la cuenta de materia prima representa el 80% de los costos operativos. Al centrarse en la cuenta de combustibles se está trabajando sobre el 80% de los costos. Así mismo se reducirían las horas de operación de las cargadoras que acarrean el combustible y las horas hombre del operador, esto al mover menos carbonato de calcio por hora. Este 2024 es un año de muchos retos para el mundo textil ya que, durante el año 2023, la industria textil enfrentó una crisis significativa, resultando en el cierre de

operaciones de varias empresas dentro de este sector. Las dificultades económicas y los desafíos operativos (Economía y Negocios, 2023).

La producción de vapor y energía a menor costo generaría un gran impacto en el escenario financiero de la empresa X, reduciendo los costos de producción podría posicionarse que mejores precios en el mercado textil y aumentar su cartera de clientes.

CAPÍTULO II. MARCO TEÓRICO

En este capítulo se desarrolla el marco teórico que fundamenta la investigación. Se analizan las bases conceptuales, teorías de sustento relacionadas con las emisiones de SO₂ en calderas de lecho fluidizado. Además, se contextualiza la relevancia de estas tecnologías en el marco legal y ambiental.

2.1 ANÁLISIS DE LA SITUACIÓN ACTUAL.

A comienzos de la década de 1960, la Junta Nacional del Carbón de Gran Bretaña, la Asociación de Investigación sobre la Utilización del Carbón Británico y la Junta Central de Generación de Electricidad iniciaron investigaciones sobre el FBC (lecho fluidizado circulante). Tras la crisis energética de 1973, los procesos de FBC de carbón se desarrollaron con rapidez, especialmente en Estados Unidos, Gran Bretaña y la República Federal Alemana, donde se implementaron en empresas de servicios, industrias manufactureras y en sectores institucionales. El FBC posee un enorme potencial para quemar de manera eficiente y limpia una amplia gama de combustibles, desde aquellos con alto contenido de azufre hasta carbones con alto contenido de cenizas de todas las categorías y grados, así como también desechos de industrias manufactureras y sedimentos municipales (Ballesteros, 2008).

En la actualidad, las emisiones industriales de dióxido de azufre (SO₂), óxidos de nitrógeno (NO_x) y otras sustancias contaminantes representan un desafío ambiental significativo a nivel global. Estas emisiones son producidas principalmente por actividades industriales, tales como la generación de energía, la producción de cemento, la industria química, entre otras, y pueden tener efectos adversos tanto en el medio ambiente como en la salud humana (Smith & Brown, 2020).

En Honduras, la situación actual respecto a las emisiones industriales es un reflejo de los desafíos ambientales y sociales que enfrenta el país. Aunque existen regulaciones ambientales y normativas para controlar las emisiones industriales, la implementación y el cumplimiento de estas regulaciones pueden ser inconsistentes debido a limitaciones en capacidad institucional, recursos financieros y tecnología adecuada (García et al., 2019).

Por un lado, la actividad industrial en Honduras ha experimentado un crecimiento considerable en las últimas décadas, impulsado por la expansión de sectores como la maquila, la agricultura y la energía. Sin embargo, este crecimiento ha estado acompañado por un aumento en las emisiones industriales y la contaminación ambiental, especialmente en áreas urbanas y zonas industriales concentradas (López & Martínez, 2018). Además, se han identificado áreas específicas en Honduras que enfrentan mayores niveles de contaminación atmosférica debido a la actividad industrial intensiva. Por ejemplo, la ciudad de San Pedro Sula, considerada el centro industrial de Honduras, ha sido catalogada como una de las ciudades más contaminadas del país debido a las emisiones de las fábricas y el tráfico vehicular (González & Herrera, 2021).

En términos de salud pública, las emisiones industriales pueden tener efectos adversos en la población, incluyendo problemas respiratorios, cardiovasculares y otros trastornos relacionados con la exposición a contaminantes atmosféricos. Los grupos vulnerables, como niños, ancianos y personas con enfermedades crónicas, son particularmente susceptibles a los efectos nocivos de la contaminación del aire (OMS, 2019). En resumen, la situación actual de las emisiones industriales en Honduras presenta desafíos significativos en términos de cumplimiento de regulaciones, control de la contaminación y protección de la salud pública. Para abordar estos desafíos de manera efectiva, es necesario fortalecer la capacidad institucional, promover la adopción de tecnologías limpias y fomentar la colaboración entre el gobierno, la industria y la sociedad civil (Gutiérrez & Díaz, 2020).

2.2 CONCEPTUALIZACIÓN

Las emisiones atmosféricas se dividen en tres grupos estos son: Emisiones de fuentes móviles, fuentes fijas y emisiones que surgen de la producción de energía eléctrica.

Las fuentes móviles son las emisiones derivadas del sector transporte mientras que las fijas provienen de la industria, agricultura y hogares. Se debe prestar principal atención al dióxido de carbono con fórmula química CO₂ y al dióxido de azufre SO₂ (Instituto Nacional de Ecología Mexico, 2017).

Los óxidos de azufre son moléculas formadas de átomos de oxígeno y azufre. Para el caso del dióxido de azufre, este se forma con dos moléculas de oxígeno y una de azufre. Su estado natural es en forma de gas incoloro, reacciona para formar ácido sulfúrico (H_2SO_4) que es tóxico para los tejidos vivos y principal componente de las lluvias ácidas (Education, UCAR Center for Science 2024).

Las lluvias ácidas se refieren a cualquier precipitación que este compuesta por componentes ácidos como el ácido sulfúrico o nítrico. No solo se refiere a lluvia de agua líquida, también puede ser nieve, niebla, granizo o incluso polvo (US EPA, 2016).

De ahora en adelante llamaremos caldera CFB a la caldera de lecho fluidizado circulante (Circulating Fluidized Bed en inglés). En la Figura 2 se muestra una sección del hogar de la caldera CFB donde se aprecian los principales componentes para su funcionamiento.




Figura 2. Hogar de caldera


Fuente: Elaboración propia

La alimentación de combustible se da por un conjunto de tornillos helicoidales (en la caldera de estudio son dos tornillos) que mueven la mezcla de combustible desde el silo de almacenamiento hasta el hogar de la caldera donde hace combustión por las elevadas temperaturas (más de $900\text{ }^{\circ}\text{C}$), este está girando de manera permanente.


El aire primario mantiene la cama en fluidización y proporciona el oxígeno para la combustión y el secundario proporciona el oxígeno restante y controla el exceso de oxígeno en los gases de escape. El exceso de oxígeno debe estar entre 5 a 7% (Changsha Boiler, 2014) , un valor por debajo es indicador de acumulación de combustible en el lecho u hogar en contraste un valor por arriba nos vuelve el proceso ineficiente pues se está usando más aire del requerido.

El combustible es una mezcla de coque de petróleo (Petcoke) y carbonato de calcio (CaCO₃). El carbonato de calcio es un aditivo para el proceso de desulfuración. La desulfuración es la captura de azufre durante la combustión en la caldera, el combustible usado contiene un 6% de azufre, la captura de azufre se de en dos pasos:

Ecuación 1 Calcificación



Ecuación 2 Sulfatación



En la Ecuación 1 el carbonato de calcio introducido en la mezcla de alimentación se descompone en Oxido de calcio y dióxido de carbono.

Oka (2004) afirma que la descomposición del CaCO₃ se producirá siempre por encima de unos 790 °C. Esta temperatura está por debajo del límite inferior del intervalo habitual de temperaturas de funcionamiento de la combustión en lecho fluidizado con captura de azufre.

En la Ecuación 2 el oxido de calcio reacciona con el dióxido de azufre (es un gas) y oxígeno, esta reacción da como resultado Sulfato de calcio (es un sólido) y dióxido de carbono.

El sulfato de calcio al ser un sólido se drena junto con la ceniza y material inerte de la caldera, de esta forma el azufre ya no se libera en forma de gas a la atmosfera si no que en forma de sólido.

Además, tiene aplicaciones como material aloplastico con un largo recorrido en la historia clínica como material sintético al no provocar reacciones de inflamación (López und Alarcón 2011).

Así un compuesto que provoca daños al medio ambiente en su forma gaseosa se hace reaccionar con otro compuesto para producir un compuesto que se encuentra naturalmente en los suelos. Esta es una de las características que hace a un caldera BFB competitivas en el mercado.

El grado de desulfuración depende de dos factores principales: los parámetros de operación y la característica de la piedra caliza. Es decir las condiciones de la caldera, el diseño, la temperatura en el lecho y la cantidad de carbonato de calcio.

Oka (2003b) explica en su libro que el rate de sulfatación está determinada por una serie de procesos interrelacionados. Estos incluyen la transferencia de masa hacia la superficie de la partícula, la difusión de SO₂ a través de la estructura porosa de la partícula, la velocidad de las reacciones químicas heterogéneas, y el proceso de bloqueo de los poros (conocido como grado de sulfatación). Diversas investigaciones y análisis indican que tanto la velocidad de sulfatación como el grado de sulfatación de una partícula de piedra caliza son influenciados por factores como la temperatura, la estructura de la piedra caliza, la porosidad de la partícula después de la calcinación, el tamaño de la partícula, el contenido de CaO y las impurezas, así como la velocidad del gas alrededor de la partícula.

La eficiencia de la sulfatación es una medida de qué tan efectivo es un proceso de sulfatación en la conversión de un reactivo en un producto deseado. Para calcular la eficiencia de la sulfatación, generalmente se compara la cantidad de reactivo que se ha convertido en el producto deseado con la cantidad total de reactivo inicialmente disponible.

Para calcular la eficiencia de la sulfatación se usa la Ecuación 3:

Ecuación 3 Eficiencia de Sulfatación

$$\text{Eficiencia} = (\text{Producto formado} / \text{Cantidad teórica máxima de producto}) \times 100\%$$

La cantidad teórica máxima de producto se calcula utilizando los datos estequiométricos de la reacción de sulfatación. Es decir, considerando la relación estequiométrica entre los reactantes y los productos en la reacción química.

Por ejemplo, si se está sulfatando CaO con SO₂ para producir CaSO₄, se puede calcular la cantidad teórica máxima de CaSO₄ que se forma basándose en la cantidad inicial de CaO y SO₂, y

la estequiometría de la reacción. Luego, comparas la cantidad real de CaSO_4 producido en tu experimento con esta cantidad teórica máxima para determinar la eficiencia de la sulfatación.

Efecto de los parámetros de la caldera en la eficiencia de sulfatación:

a) Efecto de la Temperatura de combustión

Hay evidencia científica que sustenta la existencia de una temperatura optima en la cual la eficiencia de sulfatación es máxima. La temperatura optima es entre 800 y 900 °C.

b) Efecto de la razón molar Ca/S

Varios experimentos se han realizado en calderas experimentales y plantas pilotos, en los resultados se determinó que el grado de desulfuración incrementa al aumentar la razón molar Ca/S. En la Figura 3; **Error! No se encuentra el origen de la referencia.** OKA (2003b) muestra los resultados del grado de desulfuración contra la razón molar Calcio/Azufre, se hizo el experimento en 4 calderas diferentes variando el tamaño del carbonato de calcio y la velocidad de fluidización:

1. Queen's Univ., BFBC, 0.49–0.78 mm, 1.6–1.9 m/s,
2. Queen's Univ., BFBC, 0.49–0.78 mm, 2.0–2.3 m/s,
3. Queen's Univ., BFBC, 0.49–0.78 mm, 2.7–2.8 m/s,
4. Queen's Univ., BFBC, 0.49–0.78 mm, 1.72–1.98 m/s,
5. Caldera Experimental MARK1, BFBC, 1.1 mm,
6. District heating boiler Summerside, BFBC, 0.85–2.36 mm,
7. UBC caldera CFBC , 0.21–0.45 mm




Figura 3. Grado de desulfuración vrs razón Ca/S

Fuente: (Kolehmainen et al. 2009)

c) Efecto de la altura de la cama:

El aumento del tiempo de residencia de las partículas de piedra caliza en el lecho fluidizado y el contacto prolongado con el SO₂ aumentan el grado de desulfuración. El aumento de la altura del lecho afecta a las dos magnitudes mencionadas, y por eso se puede aumentar la altura del lecho cuando sea necesario conseguir emisiones de SO₂ muy bajas (OKA 2003b).

d) Efecto del exceso de aire:

Un aumento del exceso de aire debería significar un aumento de la eficacia de la desulfuración. Debería disminuir la probabilidad de existencia de zonas con condiciones de reducción, en las que puede producirse la descomposición del CaSO₄. Los resultados que se vieron en la conferencia dada por WVZ Khan (1991a) muestran que un aumento del exceso de aire de 1.3 a 1.4 reduce la emisión de SO₂ en aproximadamente un 5-10%.

e) Efecto de la relación entre el aire primario y el secundario

La introducción de la combustión en dos etapas es común en las calderas de lecho fluidizado para conseguir reducir las emisiones de NO_x. Existen numerosas investigaciones sobre

los efectos de la combustión en dos etapas y la relación entre aire primario y secundario en la emisión de SO₂ y NO_x. La introducción de aire secundario afecta desfavorablemente a la desulfuración. La Figura 4 muestra los resultados de una investigación realizada en una caldera de 4 MWth, en la que la reducción de la razón de aire primario/aire secundario de 1,2 a 0,87, debido a la reducción del oxígeno disponible, hizo que la retención de SO₂ se redujera del 90% al 80%. Por lo tanto, se recomienda la adopción de un exceso de aire total más elevado cuando se emplee la combustión en dos etapas.




Figura 4. Efecto de la relación aire primario/aire secundario en el grado de desulfuración

Fuente: (Kolehmainen et al. 2009)

2.3 TEORÍAS DE SUSTENTO

La investigación se fundamenta en las teorías relacionadas con la combustión en calderas de tipo lecho fluidizado. Según (Smith 2015) , estas teorías explican cómo la granulometría del combustible, la presión y la temperatura en el hogar de la caldera pueden influir en las emisiones de gases contaminantes.

Además, estudios previos como el de (García und Pérez 2018) han demostrado la efectividad de ciertas estrategias, como el uso de carbonato de calcio, para reducir las emisiones de dióxido de

azufre en este tipo de calderas. Estas teorías proporcionan el marco conceptual necesario para diseñar y llevar a cabo análisis cuantitativos que permitan alcanzar los objetivos de la investigación.

La investigación se basa en teorías que explican cómo las variables operativas en procesos de combustión afectan directamente las emisiones de contaminantes y el consumo de aditivos como el carbonato de calcio. Según la teoría de la combustión controlada, mantener condiciones óptimas de temperatura, flujo de aire y presión permite reducir la formación de gases contaminantes como el dióxido de azufre (SO_2) y los óxidos de nitrógeno (NO_x), ya que estas condiciones facilitan una combustión más completa y eficiente (Smith, 2015). En el caso específico de las calderas de lecho fluidizado, la combustión ocurre en una cama de material granular que mejora la transferencia de calor y facilita la captura de contaminantes a través de reacciones químicas entre el carbonato de calcio y el SO_2 , formando sulfato de calcio como subproducto (Oka, 2004).

Además, la teoría del modelado estadístico y predictivo sustenta el uso de herramientas como la regresión polinomial y los algoritmos de machine learning para predecir y optimizar procesos industriales. Estas técnicas permiten identificar relaciones complejas entre las variables operativas y los resultados del proceso, como las emisiones de contaminantes. Estudios como los de García y Pérez (2018) han demostrado que los modelos polinomiales son particularmente útiles para capturar las relaciones no lineales entre variables como la temperatura, la presión y la granulometría del carbonato de calcio. Por su parte, los algoritmos de machine learning, como Random Forest y Naive Bayes, complementan este enfoque al identificar patrones en grandes conjuntos de datos, proporcionando una capacidad predictiva superior en escenarios de alta variabilidad y ruido en los datos (Breiman, 2001).

Otra teoría relevante es la teoría de la integración tecnológica en procesos industriales, que respalda el uso de herramientas como Power BI y Power Automate para el análisis y la automatización de datos en tiempo real. Estas herramientas, al integrarse con modelos matemáticos y algoritmos predictivos, permiten un monitoreo continuo y la implementación de acciones correctivas automáticas, optimizando la operación de la caldera y reduciendo los costos operativos

(Pérez & García, 2021). En este sentido, se crea un sistema proactivo que no solo identifica las desviaciones en los parámetros operativos, sino que también proporciona soluciones rápidas y efectivas para mantener el proceso bajo control.

Por último, el sustento legal también es fundamental en esta investigación. Las normativas internacionales y nacionales, como las emitidas por la Secretaría de Recursos Naturales y Ambiente en Honduras, establecen límites estrictos para las emisiones de SO₂, lo que refuerza la importancia de implementar tecnologías avanzadas que garanticen el cumplimiento normativo sin comprometer la viabilidad económica del proceso. Este marco legal guía el diseño de la propuesta y asegura su alineación con los objetivos ambientales y operativos de la empresa (García et al., 2019).

2.3.1 BASES TEÓRICAS

2.3.1.1 Mapa Auto-organizado (Self-organizing map)

El uso de un mapa auto-organizado (SOM), desarrollado por Kohonen a principios de la década de 1980, en el análisis de estados de proceso ha generado una variedad de aplicaciones en los últimos años. El concepto de estados de proceso se introdujo en 1992 utilizando un SOM para monitorear el estado de un transformador de energía.

En varios de sus estudios Kolehmainen et al. (2009) afirma que diferentes estados del proceso de combustión en lecho fluidizado pueden ser descubiertos en los datos del proceso mediante el uso del SOM. Estos estados pueden ser, por ejemplo, arranques, paros, tiempos de inactividad y diferentes estados del proceso normal. Pueden existir diferencias importantes en el rendimiento del proceso entre estas condiciones, por ejemplo, las emisiones pueden variar considerablemente.

Conocer como los diferentes atributos (variables del proceso) afectan el proceso y clasificarlos para predecir en que grado afectaran la operación, genera un impacto positivo en la administración de la compañía hablando de potenciales ahorros como evitar multas por sobrepasar los límites de emisiones fijados por los entes reguladores.

Las aplicaciones que utilizan el algoritmo del mapa auto-organizado son muy variadas y abarcan una amplia gama de áreas en el campo de las redes neuronales artificiales. Tradicionalmente, el SOM se ha utilizado en diversas aplicaciones prácticas, como el análisis exploratorio de datos, el reconocimiento de patrones, el análisis del habla, diagnósticos industriales y médicos, robótica, instrumentación e incluso control (Kohonen 2001).

La función principal del SOM es facilitar el análisis de datos al asignar vectores de entrada de n dimensiones a clases o neuronas, generalmente en una retícula bidimensional (mapa). Este mapa de neuronas refleja las diferencias en las estadísticas de los datos y selecciona características que se asemejan a la distribución de las muestras de datos. Además, conserva la organización topológica de los datos de entrada al asociar los vectores de entrada con características comunes con las mismas o con neuronas vecinas. Se pueden representar las propiedades generalizadas de una neurona mediante un vector de prototipo específico de la neurona, o vector de referencia, de n dimensiones. El tamaño del mapa puede ajustarse según el propósito cambiando el número de neuronas; cuanto mayor sea el mapa, más detalles se mostrarán (Kolehmainen et al. 2009).

En la Figura 5 se observa los resultados que se obtuvieron en los estudios de (Kolehmainen et al, 2009). para el caso de una caldera de lecho fluidizado circulante y las emisiones de óxidos de nitrógeno. Aunque las emisiones que se deben controlar son las de óxidos de azufre, este modelo sigue siendo válido pues el entrenamiento del modelo se hará con la base de datos de operación de la caldera, considerando las variables mencionadas en la conceptualización del marco teórico.

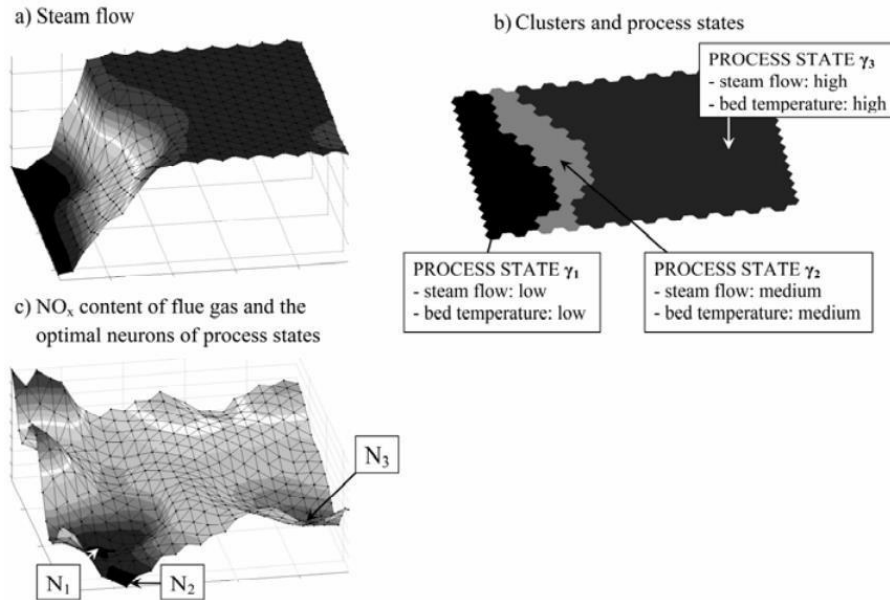


Figura 5. Resultados obtenidos al analizar la temperatura, flujo de vapor y emisiones de NOx

Fuente: (Kolehmainen et al, 2009)

Uno de los métodos más ilustrativos es utilizar la visualización 3 dimensiones del mapa de componentes. En este enfoque, las dos primeras dimensiones están definidas por la disposición de las neuronas, mientras que la tercera dimensión ilustra la característica o atributo estudiado. Este tipo de mapa es más informativo y más comprensible que el mapa de 2 dimensiones convencional.

2.3.1.2 K-MEANS CLUSTERING

El algoritmo k-means es un método de agrupamiento de datos muy utilizado que no sigue una estructura jerárquica. Su funcionamiento básico consiste en seleccionar k centros de clúster al azar y luego asignar cada punto de datos al clúster cuyo centro sea el más cercano en términos de distancia euclidiana. Posteriormente, se calculan los vectores medios de los puntos de datos asignados a cada clúster y se utilizan iterativamente como nuevos centros de clúster. Para determinar el número óptimo de clústeres, se puede emplear el índice de Davies-Bouldin. Valores bajos de este índice indican clústeres compactos cuyos centros están bien separados entre sí. Por lo tanto, el número óptimo de clústeres es aquel donde el índice de Davies-Bouldin alcanza su valor mínimo. De esta manera, se puede evitar la necesidad de conocer de antemano la cantidad de clústeres (MacQueen,1967).

Este algoritmo se puede usar en combinación con SOM para subdividir el proceso en estados secundarios. La Figura 6 refleja este método.




Figura 6. Combinación de SOM con K-Means para agrupar procesos y subprocessos

Fuente: (Mika Liukkonen, Eero Hälikkä, Reijo Kuivalainen, Yrjö Hiltunen 2010)

2.3.1.3 REGRESION POLINOMIAL

El uso de técnicas de modelado estadístico y machine learning ha demostrado ser eficaz en la optimización de procesos industriales, como en la mejora del rendimiento de calderas de lecho fluidizado. En particular, la regresión polinomial ha sido utilizada en diversas investigaciones para modelar relaciones no lineales entre variables operativas y emisiones contaminantes. En un estudio realizado por García y Pérez (2018), se aplicó regresión polinomial para analizar la relación entre la temperatura, el flujo de aire y las emisiones de dióxido de azufre en calderas industriales. Los autores demostraron que un modelo polinomial de segundo grado fue capaz de predecir las emisiones de manera más precisa que modelos lineales, lo que destacó la importancia de considerar las interacciones no lineales entre las variables del proceso.

Esta técnica permitió optimizar el uso de los aditivos en las calderas, como el carbonato de calcio, reduciendo la cantidad necesaria para mantener las emisiones dentro de los límites permitidos.

Por otro lado, los algoritmos de machine learning se han utilizado con éxito en la predicción de emisiones en sistemas industriales, como las calderas de lecho fluidizado. En el trabajo de Chaves et al. (2021), se implementaron algoritmos como Random Forest y Árboles de Decisión para predecir las emisiones de óxidos de nitrógeno (NOx) en calderas de biomasa. Los resultados mostraron que Random Forest proporcionaba una mayor precisión en las predicciones al manejar una gran cantidad de variables operativas, como la temperatura y la humedad del aire, y su capacidad para identificar patrones complejos que no podrían ser capturados por métodos tradicionales. De manera similar, Li et al. (2020) utilizaron Naive Bayes y Regresión Logística para clasificar las emisiones de SO₂ en diversas categorías basadas en parámetros como el tipo de combustible y la velocidad del aire. Estos modelos fueron fundamentales para identificar los factores que influían más en las emisiones, permitiendo ajustar las condiciones operativas de manera que se minimizara la contaminación sin afectar la eficiencia del proceso.

La combinación de técnicas de regresión polinomial y machine learning en el análisis de emisiones de calderas ha sido ampliamente documentada. Según Zhang et al. (2019), el uso de estos enfoques ha permitido a las industrias no solo predecir las emisiones con una mayor precisión, sino también desarrollar sistemas de control predictivos que ajustan en tiempo real las variables operativas, garantizando el cumplimiento de las normativas ambientales y mejorando la eficiencia operativa. En este sentido, se observa que tanto los modelos estadísticos como los algoritmos de machine learning se complementan en la optimización de procesos industriales, proporcionando una base sólida para el diseño de sistemas de control más eficientes y sostenibles.

2.3.2 METODOLOGÍAS DESARROLLADAS

Basado en las variables identificadas y los efectos documentados en la literatura, se desarrollará una metodología integral para abordar el problema de reducción del consumo de carbonato de calcio en la caldera 1 de la Empresa Textil X.

En esta investigación, se utilizó regresión polinomial como una herramienta clave para modelar la relación no lineal entre diversas variables operativas de la caldera (como la temperatura, presión y granulometría del carbonato de calcio) y las emisiones de dióxido de azufre (SO₂). La regresión polinomial es un enfoque estadístico robusto que extiende la regresión lineal al incorporar términos polinomiales que permiten capturar patrones más complejos en los datos. Esta técnica es particularmente útil cuando se enfrenta a fenómenos no lineales, como los que ocurren en procesos industriales donde las interacciones entre variables no son simples y pueden tener efectos de curvatura significativos. Al ajustar un polinomio de grado adecuado, es posible predecir de manera precisa cómo las variaciones en las condiciones operativas afectan las emisiones de gases contaminantes, lo que es crucial para la optimización del proceso de combustión en las calderas de lecho fluidizado (Montgomery et al., 2012).

Además de la regresión polinomial, esta investigación también incorporó el uso de algoritmos de machine learning como Random Forest, Naive Bayes, Regresión Logística y Árboles de Decisión para mejorar la predicción y clasificación de las emisiones de dióxido de azufre en función de los diferentes parámetros operativos de la caldera. Estos algoritmos fueron elegidos debido a su capacidad para manejar grandes volúmenes de datos y su habilidad para identificar patrones complejos que otros métodos estadísticos tradicionales podrían pasar por alto. El Random Forest, por ejemplo, es un algoritmo basado en un conjunto de árboles de decisión, que permite mejorar la precisión y robustez de las predicciones al reducir el riesgo de sobreajuste, lo que es particularmente útil en un entorno industrial con datos ruidosos y variables correlacionadas (Breiman, 2001). Por otro lado, Naive Bayes y Regresión Logística son modelos probabilísticos que, a pesar de sus suposiciones simplificadoras, han demostrado ser muy eficientes para clasificar datos en escenarios con relaciones lineales entre variables, lo cual es común en muchos procesos industriales (Hosmer et al., 2013; Rish, 2001).

Por otra parte y en el contexto de la optimización de procesos industriales, las herramientas de análisis de datos y automatización han cobrado relevancia, permitiendo gestionar grandes volúmenes de información en tiempo real. En esta investigación, se propone el uso de Power BI y Power Automate como herramientas principales para implementar un sistema de monitoreo y alertas en la operación de calderas de lecho fluidizado.

Power BI, desarrollado por Microsoft, es una herramienta de inteligencia empresarial que permite transformar datos en visualizaciones interactivas y paneles personalizados. Su capacidad para conectar múltiples fuentes de datos, procesar información en tiempo real y generar análisis predictivos lo hace ideal para monitorear variables operativas como el flujo de aire, la temperatura del hogar de la caldera y las emisiones de dióxido de azufre (SO₂). Estudios previos han demostrado que el uso de Power BI en la industria mejora significativamente la toma de decisiones al proporcionar una visión integral del rendimiento operativo (Smith & Brown, 2020).

Por otro lado, Power Automate, también de Microsoft, es una plataforma de automatización de flujos de trabajo que permite conectar aplicaciones y servicios para automatizar procesos repetitivos. En esta propuesta, Power Automate se utiliza para generar alertas en tiempo real cuando las variables operativas de la caldera se desvían de los valores óptimos. Al integrarse con Power BI, permite que las alertas se disparen automáticamente basándose en los datos analizados, enviando notificaciones por correo electrónico o mensajes a los operadores y supervisores. Según estudios, la implementación de Power Automate en sistemas industriales ha reducido significativamente los tiempos de respuesta ante eventos críticos, mejorando la eficiencia y garantizando el cumplimiento normativo (Pérez & García, 2021).

El uso de estos algoritmos y software permite la posibilidad de una clasificación más precisa de las emisiones en categorías "óptimas" y "no óptimas" y también ofrece una herramienta para la toma de decisiones en tiempo real, lo que permite ajustar las condiciones operativas de la caldera para maximizar la eficiencia y reducir el consumo de recursos como el carbonato de calcio. Al integrar estos modelos y software en un sistema de control automatizado, se puede garantizar que las emisiones se mantengan dentro de los límites normativos sin comprometer la eficiencia operativa, lo que es fundamental para cumplir con los objetivos económicos y ambientales de la empresa.

Asimismo, se evaluará el impacto del exceso de aire en la eficacia de la desulfuración, tomando en cuenta los resultados presentados por (WVZ Khan, 1991b), que indican una reducción en la emisión de SO₂ con un aumento del exceso de aire.

Finalmente, se analizará el efecto de la relación entre el aire primario y secundario en la combustión en dos etapas, considerando los resultados de investigaciones anteriores que sugieren una relación inversa entre la retención de SO₂ y la reducción de la razón de aire primario/aire secundario (OKA 2003a). Estas metodologías integradas permitieron explorar de manera exhaustiva los diferentes factores que influyen en el consumo de carbonato de calcio y las emisiones de SO₂ en la caldera 1, proporcionando una base sólida para la optimización del proceso de combustión.

2.3.3 INSTRUMENTOS UTILIZADOS

En primer lugar, se empleará un analizador de emisiones para medir la concentración de dióxido de azufre (SO₂) y óxidos de nitrógeno (NO_x) en los gases de escape de la caldera. Este analizador proporcionó datos precisos sobre las emisiones generadas durante el proceso de combustión.

Además, se utilizará un termómetro de alta precisión para monitorear la temperatura en el hogar de la caldera y asegurar que se mantenga dentro del rango óptimo para la eficiencia de sulfatación. Asimismo, se implementaron instrumentos para medir la altura de la cama en el lecho fluidizado y controlar el flujo de aire primario y secundario durante la combustión en dos etapas.

Estos instrumentos permitirán obtener datos detallados sobre las variables clave que influyen en el consumo de carbonato de calcio y las emisiones de SO₂ y NO_x, facilitando así la evaluación y optimización del proceso de combustión.

2.4 MARCO LEGAL

A nivel internacional y en un panorama general las regulaciones de emisiones se fundamentan en tratados y convenciones internacionales, así como en acuerdos regionales, que establecen estándares y directrices para la protección del medio ambiente y la salud humana.

El Protocolo de Montreal, uno de los tratados ambientales más exitosos, fue adoptado en 1987 con el objetivo de eliminar gradualmente la producción y el consumo de sustancias que agotan la capa de ozono, incluidos los clorofluorocarbonos (CFC) y los hidroclorofluorocarbonos (HCFC).

La implementación exitosa de este protocolo ha contribuido significativamente a la recuperación de la capa de ozono y ha demostrado la efectividad de la cooperación internacional en la protección del medio ambiente (Smith 2018)

El Acuerdo de París, firmado en 2015, representa otro hito importante en la lucha contra el cambio climático. Este acuerdo tiene como objetivo limitar el aumento de la temperatura global a menos de 2°C con respecto a los niveles preindustriales, y se basa en contribuciones voluntarias de los países para reducir las emisiones de gases de efecto invernadero (GEI) (García und López 2020) .

A nivel regional, diversos acuerdos y tratados establecen estándares y mecanismos de cooperación para abordar problemas ambientales transfronterizos. Por ejemplo, la Comisión para la Cooperación Ambiental de América del Norte (CCAAN) facilita la colaboración entre Canadá, Estados Unidos y México en áreas como la calidad del aire y la gestión de residuos peligrosos (Johnson 2021).

Panorama en Honduras

En Honduras, el marco legal relacionado con las emisiones industriales se basa en una serie de leyes y regulaciones nacionales que buscan proteger el medio ambiente y la salud pública. La Ley General del Ambiente, promulgada en 1998, establece los principios y normas para la conservación, protección y restauración del ambiente en Honduras. Esta ley establece los lineamientos para la evaluación y control de la contaminación atmosférica, incluyendo la regulación de las emisiones industriales de SO₂, NO_x y otros contaminantes (Secretaría de Recursos Naturales y Ambiente 1998)

Además de la legislación general, Honduras cuenta con normativas específicas para sectores industriales clave. Por ejemplo, la Ley del Sector Eléctrico, aprobada en 2005, establece los requisitos para la generación, transmisión, distribución y comercialización de energía eléctrica en el país. Esta ley incluye disposiciones relacionadas con la calidad del aire y la reducción de emisiones en el sector energético (Congreso Nacional de Honduras) .

En términos de cumplimiento, la Secretaría de Energía, Recursos Naturales, Ambiente y Minas (MiAmbiente+) es la autoridad responsable de supervisar y regular las emisiones industriales en Honduras. Esta institución lleva a cabo inspecciones regulares para garantizar el cumplimiento de las leyes y regulaciones ambientales y puede imponer sanciones a las empresas que no cumplan con los estándares de emisión establecidos (MiAmbiente+ 2021).

Este marco legal nacional e internacional proporciona una estructura sólida para regular las emisiones industriales de dióxido de azufre, óxidos de nitrógeno y otras sustancias contaminantes, tanto a nivel global como en el contexto específico de Honduras.

Esta información se basa en las regulaciones y prácticas actuales en Honduras y puede estar sujeta a cambios según las actualizaciones legales y normativas del país.

CAPÍTULO III. METODOLOGÍA

Este capítulo describe el enfoque metodológico empleado para alcanzar los objetivos de la investigación. Se incluye la matriz de congruencia, la operacionalización de las variables y las técnicas utilizadas para recolectar y analizar los datos, con el fin de llegar a conclusiones y recomendaciones planteadas, logrando así los objetivos planteados.

3.1 CONGRUENCIA METODOLÓGICA

La metodología empleada en este estudio demostró congruencia al vincular de manera coherente los objetivos de la investigación con el diseño del estudio, las técnicas analíticas utilizadas y los resultados obtenidos. Se estableció un enfoque basado en el análisis de datos que permitió estudiar las variables clave del proceso de combustión en una caldera de lecho fluidizado, como temperatura en la salida de la caldera, el exceso de oxígeno y la presión diferencial. Estas variables fueron seleccionadas cuidadosamente en función de su relevancia directa para la optimización de la captura de azufre y el control de las emisiones de SO₂.

Los instrumentos y herramientas utilizados, como analizadores de gases, sensores de presión y temperatura, y los modelos de machine learning (Naive Bayes, Random Forest y regresión polinomial), garantizaron que las mediciones fueran precisas y relevantes para los objetivos del estudio. La consistencia en la recolección de datos y el diseño del modelo de análisis permitió interpretar los resultados en relación con las hipótesis planteadas, asegurando que cada paso metodológico contribuyera de manera directa a los hallazgos finales.

Esta congruencia metodológica se reflejó en la integración de técnicas avanzadas, como la visualización de datos en tiempo real mediante Power BI y la automatización de alertas mediante Power Automate, que complementaron el análisis y optimización del proceso. En conclusión, la metodología aplicada permitió mantener una alineación clara entre las etapas del diseño del estudio, el análisis de datos y la generación de conclusiones, garantizando así la validez y la fiabilidad de los resultados obtenidos.

3.1.1 MATRIZ METODOLÓGICA

Tabla 1. Matriz Metodológica

Título de la investigación	Objetivos de Investigación	Objetivos Específicos	Variables Respuesta	Variables independientes	Unidad
Optimización de la captura de azufre durante la combustión en una caldera de vapor de lecho fluidizado	Optimizar la captura de azufre en la caldera que permita mantener las emisiones de dióxido de azufre bajo norma sin aumentar la cantidad de carbonato de calcio introducido en la caldera.	1. Determinar cómo afecta el flujo de aire de combustión en la variación de las emisiones de dióxido de azufre.	Emisiones de dióxido de azufre	Flujo de aire primario	m ³ /h
		2. Revisar cómo afecta el exceso de oxígeno de combustión en la variación de las emisiones de dióxido de azufre.		Flujo de aire secundario	m ³ /h
		3. Definir cómo afecta la temperatura de la caldera en la variación de las emisiones de dióxido de azufre.		Exceso de oxígeno de combustión	%
		4. Determinar cómo afecta la presión diferencial en el hogar de la caldera en la variación de las emisiones de dióxido de azufre.		Temperatura del Lecho	°C
		5. Seleccionar un modelo matemático que explique más del 50% de la variación en las emisiones de dióxido de azufre.		Temperaturas en la salida del hogar	°C
				Presión diferencial superior	KPa
				Presión diferencial inferior	KPa

3.1.2 ESQUEMA DE VARIABLES DE ESTUDIO

1. Variable Independiente:

- Flujo de aire primario
- Flujo de aire secundario
- Temperatura del lecho de la caldera
- Temperatura a la salida del hogar de la caldera
- Presión diferencial superior
- Presión diferencial inferior -Exceso
de aire de combustión

3. Variable Dependiente:

- Emisiones de dióxido de azufre (SO₂)

Este esquema presenta las variables de estudio, indicando las variables independientes (aquellas que se manipulan) y la variable dependiente (aquella que se mide para observar su respuesta a las manipulaciones). Las variables adicionales pueden influir en la variable dependiente y, por lo tanto, también se deben considerar en el estudio.

3.1.3 OPERACIONALIZACIÓN DE LAS VARIABLES

Las emisiones de óxidos de azufre son moléculas formadas de átomos de oxígeno y azufre. Para el caso del dióxido de azufre, este se forma con dos moléculas de oxígeno y una de azufre. Su estado natural es en forma de gas incoloro, reacciona para formar ácido sulfúrico (H₂SO₄) que es tóxico para los tejidos vivos y principal componente de las lluvias ácidas.

Operacionalmente se define como la masa de dióxido de azufre que se libera al ambiente por cada metro cubico normalizado de gas de escape de la caldera. El volumen normalizado es el volumen del gas referenciado a presión de 1 atmosfera y temperatura 0 °C. La unidad de medida de las emisiones es mg/Nm³.

Tabla 2 Tabla de Operacionalización

Variables	Definición	Operacional	Dimensiones	Indicadores
Emisiones de SO ₂	Concentración de SO ₂ en los gases de escape.	Masa de SO ₂ emitida por unidad de volumen de gas de escape normalizado.	Contaminación	mg/Nm ³
Temperatura del lecho	Nivel de calor en la cama del lecho fluidizado.	Medición directa con sensor de temperatura.	Operación	°C
Flujo de aire primario	Cantidad de aire suministrado al lecho.	Volumen de aire medido con medidores de flujo.	Operación	m ³ /h
Exceso de oxígeno	Porcentaje de oxígeno residual después de la combustión.	Lectura directa del analizador de gases.	Combustión	%
Presión diferencial	Diferencia de presión medida en la cama del lecho fluidizado.	Sensor de presión diferencial instalado en la caldera.	Operación	kPa

3.1.4 HIPÓTESIS

Los principales predictores de las emisiones de dióxido de azufre son los flujos de aire de combustión y la temperatura en lecho del hogar de la caldera.

3.2 ENFOQUE Y MÉTODOS

El enfoque de la investigación se centrará en analizar cómo diferentes variables, como la temperatura de combustión, la razón molar Ca/S, la altura de la cama en el lecho fluidizado, el exceso de aire y la relación entre el aire primario y secundario, afectan el consumo de carbonato de

calcio y las emisiones de dióxido de azufre (SO₂) y óxidos de nitrógeno (NO_x) en la caldera 1 de la Empresa Textil X.

Para alcanzar este objetivo, se realizarán mediciones utilizando instrumentos especializados, como analizadores de emisiones y termómetros de alta precisión para recopilar datos sobre las emisiones de gases y la temperatura en el hogar de la caldera. Como método principal se implementará el algoritmo de regresión polinomial para obtener un modelo matemático que mejor explique la variación en la variable respuesta, las emisiones de dióxido de azufre. Los procesos en la caldera están influenciados por fenómenos físico químicos que pueden ser aproximados mediante una regresión polinomial del grado adecuado.

Además, se transformará la variable respuesta numérica continua en una variable categórica binaria, implementando otras técnicas avanzadas de análisis estadístico y modelos de machine learning como **Random Forest**, **Naive Bayes**, **Regresión Logística** y **Árboles de Decisión** para evaluar la relación entre las variables manipuladas y la variable dependiente. Estos modelos permiten identificar patrones complejos y determinar los factores que tienen un impacto significativo en el consumo de carbonato de calcio y las emisiones de SO₂ y NO_x (Breiman, 2001). Este enfoque metodológico no solo facilitará la comprensión de los procesos de combustión en la caldera, sino que también proporcionará información valiosa para optimizar su funcionamiento y reducir su impacto ambiental.

3.3 DISEÑO DE LA INVESTIGACIÓN

3.3.1 POBLACIÓN

La población son todas las emisiones de dióxido de azufre en los gases de escape de la caldera de lecho fluidizado de la empresa X.

3.3.2 MUESTRA

Con un nivel de confianza del 95%, el valor crítico Z es aproximadamente 1.96

Aplicamos la siguiente formula

$$n = \frac{Z^2 * S^2}{d^2}$$

Donde:

Z: 1.96

S: 554 d:

20

Entonces, para estimar la media poblacional con un nivel de confianza del 95% y un margen de error del 5%, necesitaríamos una muestra de aproximadamente 2,947 observaciones.

3.3.3 TÉCNICAS DE MUESTREO

Se usará un muestreo sistemático, los datos son tomados en tiempo real por analizador de gases. La data se puede recolectar por diferentes periodos de tiempo: minutos, horas, días y meses.

3.4 TÉCNICAS, INSTRUMENTOS Y PROCEDIMIENTOS APLICADOS

Técnica: recolección de datos históricos de la operación de la caldera durante un mes, descartando los modos de operación anormales para cuidar la pureza del modelo final.

Instrumentos: Como instrumentos tendremos el analizador de gases instalado en línea y otro analizador de gases portátil para tomar mediciones en otros puntos de la caldera. También se usará un agitador de tamices para determinar la granulometría de los combustibles.

Procedimiento: Primero se recolectará la información técnica de los combustibles, como ser el contenido de azufre, densidad, y granulometría. Luego generar diferentes escenarios como la alimentación de carbonato de calcio de diferente tamaño o granulometría, modificar la frecuencia de operación de los motores de los tornillos de alimentación y aires. Al final se recolectará la

información de los resultados de las emisiones y se usará el campo de fecha para relacionar los eventos.

3.5 FUENTES DE INFORMACIÓN

3.5.1 FUENTES PRIMARIAS

Las fuentes de información son las distintas bases de dato de los sistemas conectados a los controladores lógicos programables (PLC). Se cuenta con la base de datos de las mediciones del analizador de gases y las variables de operación de la caldera guardados por segundo o cualquier otra unidad de tiempo mayor.

3.5.2 FUENTES SECUNDARIAS

Datos de las distintas fuentes que se revisaron a lo largo de la investigación, como información de calderas piloto y experimentales. Asimismo, las fichas de información técnica de los combustibles importados.

CAPÍTULO IV. RESULTADOS Y ANÁLISIS

En este capítulo se explora el proceso de recolección de datos, limpieza y procesamiento, comenzando con la declaración de las fuentes de datos utilizadas luego la limpieza y revisión de correlación, el análisis de datos tiene dos vías, se comienza analizando la variable respuesta como una variable numérica continua en la que el objetivo es encontrar el grado o exponente de un modelo de regresión polinomial que mejor explique la variación en las emisiones de dióxido de azufre. El otro enfoque es tratando la variable respuesta como una variable categórica binaria en la que se transformó la variable respuesta en dos categorías: Optimo y No optimo, siendo Optimo cuando los valores de emisiones están por debajo de los 2000 miligramos por metro cubico normalizado (mg/Nm^3) y No optimo en caso contrario. Para este enfoque el objetivo será que algoritmo de clasificación dentro de sus métricas presenta el mejor valor de presión.

4.1 INFORME DE PROCESO DE RECOLECCIÓN DE DATOS

Las fuentes de datos principales son dos: la base de datos de operación de la caldera y la base de datos de las emisiones de dióxido de azufre en la chimenea de la caldera. La data extraída de ambas fuentes corresponde al periodo del 1 al 27 de octubre del 2024, la data fue recolectada en intervalos de 1 minuto.

Se excluyeron de la data los días 14,16,17,24 y 25 de octubre ya que esos días la caldera operó en una configuración especial. También se excluyó de los predictores la razón de carbonato de calcio por tonelada de combustible, en la Figura 7 se muestra que dicha razón tuvo un valor promedio de 0.24 toneladas de carbonato de calcio por cada tonelada de combustible consumido. El combustible consumido fue en algunos días una mezcla de carbón y Petcoke, en la Figura 8 los días con valores de 1 son de 100% carbón y en los demás días el complemento es carbón mineral, sin embargo, el mayor periodo de tiempo estudiado fue 100% Petcoke que es el escenario normal de operación de la caldera.

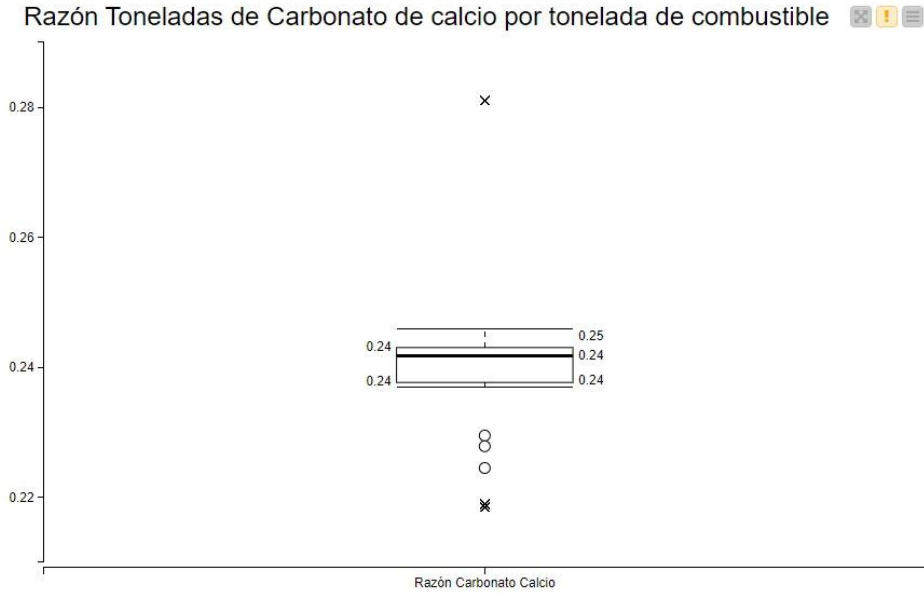


Figura 7 Razón de carbonato de calcio por tonelada de combustible en el mes de octubre

Fuente: Elaboración propia




Figura 8 Gráfico de toneladas de Petcoke por tonelada de combustible en la mezcla

Fuente: Elaboración propia

4.2 RESULTADOS Y ANÁLISIS DE LAS TÉCNICAS APLICADAS SEAN CUANTITATIVAS O CUALITATIVAS.

4.2.1 ANÁLISIS CUANTITATIVO

Revisando la matriz de correlación lineal de las variables que se muestra en la Figura 9, se encontró una fuerte correlación entre el flujo de aire secundario y todas las temperaturas del hogar

de la caldera. Esto sugiere que podría existir un problema de multicolinealidad entre las variables, lo cual afectará los resultados de cualquier análisis de regresión que utilice estas variables como predictores. El coeficiente de correlación que se calculó es el coeficiente de correlación de Pearson (PCC), Asuero et al. (2006) reporta que los coeficientes entre 0.9 y 1 representan una correlación muy alta entre las dos variables en estudio mientras que los valores entre 0.7 y 0.89 indican una alta correlación.

La multicolinealidad se presenta cuando dos o más variables independientes están altamente correlacionadas entre sí, lo que puede generar problemas en la estimación de los coeficientes de regresión, dificultando la interpretación de los efectos individuales de cada predictor. Según O'Brien (2007), la multicolinealidad puede inflar los errores estándar de los coeficientes, lo que lleva a la obtención de intervalos de confianza más amplios y a pruebas de hipótesis menos fiables. Además, este problema puede reducir la capacidad del modelo para identificar las relaciones verdaderas entre las variables, comprometiendo la validez de las conclusiones (Kennedy, 2008).

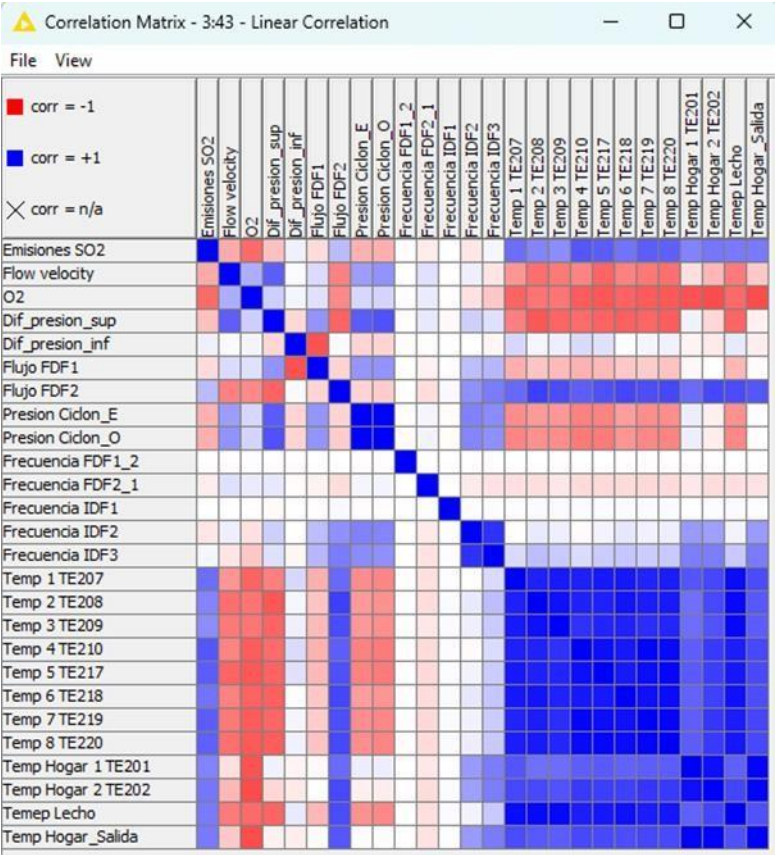
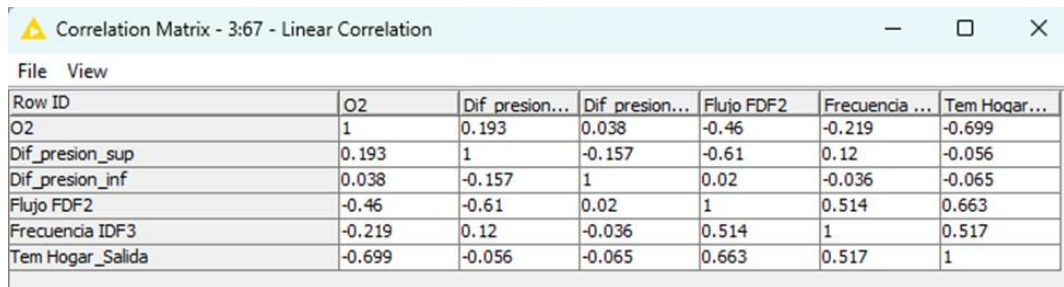


Figura 9 Matriz de correlación entre las variables

Fuente: Elaboración propia

Para solucionar este problema de multicolinealidad se ha eliminado estratégicamente todas las variables con un PCC mayor a 0.7, dejando únicamente las variables que se muestran en la Figura 10.



Row ID	O2	Dif_presion...	Dif_presion...	Flujo FDF2	Frecuencia ...	Tem Hogar...
O2	1	0.193	0.038	-0.46	-0.219	-0.699
Dif_presion_sup	0.193	1	-0.157	-0.61	0.12	-0.056
Dif_presion_inf	0.038	-0.157	1	0.02	-0.036	-0.065
Flujo FDF2	-0.46	-0.61	0.02	1	0.514	0.663
Frecuencia IDF3	-0.219	0.12	-0.036	0.514	1	0.517
Tem Hogar_Salida	-0.699	-0.056	-0.065	0.663	0.517	1

Figura 10 Matriz de coeficientes de correlación de Pearson

Fuente: Elaboración propia

De un total de 25 predictores de acuerdo a la Figura 9 se redujo a 6 luego de revisar el coeficiente de correlación de Pearson. Los predictores para entrenar el modelo serán los que quedaron en la Figura 10.

Se encontrará la relación que existe entre las variables seleccionadas en la Figura 10 y el valor de las emisiones de dióxido de azufre en la salida de la caldera, como primer método se ha seleccionado un algoritmo de regresión polinomial y la selección del grado de la ecuación polinomial se ha obtenido con un optimizador de parámetros de knime. La data data se ha particionado en dos conjuntos, se ha seleccionado aleatoriamente el 70% de los datos para entrenamiento del algoritmo de regresión polinomial y el 30% para verificación del método.

<input type="checkbox"/> Row...	Grado <small>Number (integer)</small>	Objective value ↓ <small>Number (double)</small>
<input type="checkbox"/> Row6	7	0.579
<input type="checkbox"/> Row3	4	0.57
<input type="checkbox"/> Row5	6	0.568
<input type="checkbox"/> Row7	8	0.566
<input type="checkbox"/> Row8	9	0.563
<input type="checkbox"/> Row4	5	0.561
<input type="checkbox"/> Row2	3	0.556
<input type="checkbox"/> Row1	2	0.534
<input type="checkbox"/> Row0	1	0.513
<input type="checkbox"/> Row9	10	-1.643

Figura 11 Selección de grado con el optimizador de parametros de Knime

Fuente: Elaboración propia

De la tabla en la Figura 11 se muestra el grado versus el valor de R cuadrado ordenado de mayor a menor y se concluye que el grado del polinomio con el que se obtiene mayor valor de R es 7 por lo tanto se procede a ejecutar el algoritmo de nuevo con el valor de 7 para obtener la ecuación y las demás métricas para la evaluación del modelo.

Statistics on Polynomial Regression

Variable	Coeff.	Std. Err.	t-value	P> t
O2	-5.449,9175	709,2878	-7,6836	1,62E-14
Dif_presion_sup	-4.930,2154	48.885,6584	-0,1009	0,9197
Dif_presion_inf	-1,56E9	1,33E10	-0,1172	0,9067
Flujo FDF2	-1,5686	0,5804	-2,7027	0,0069
Frecuencia IDF3	-3,50E8	52.718.715,4317	-6,645	3,10E-11
Temp Hogar_Salida	5.541.142,4607	1.329.821,9542	4,1668	3,10E-5
O2^2	3.810,6101	444,7562	8,5679	0.0
Dif_presion_sup^2	-79.435,1875	442.063,986	-0,1797	0,8574
Dif_presion_inf^2	4,99E8	4,80E9	0,1039	0,9173
Flujo FDF2^2	0,0005	0,0002	3,3686	0,0008
Frecuencia IDF3^2	35.190.974,6118	5.268.161,4436	6,6799	2,45E-11
Temp Hogar_Salida^2	-26.809,3299	6.366,7363	-4,2108	2,55E-5
O2^3	-885,9617	117,0623	-7,5683	3,93E-14
Dif_presion_sup^3	463.564,5031	2.134.978,78	0,2171	0,8281
Dif_presion_inf^3	-87.338.717,1755	9,62E8	-0,0908	0,9276
Flujo FDF2^3	-6,46E-8	1,64E-8	-3,9348	8,35E-5
Frecuencia IDF3^3	-1.957.701,4633	291.628,9275	-6,713	1,95E-11
Temp Hogar_Salida^3	71,7532	16,8725	4,2527	2,12E-5
O2^4	96,0558	15,9107	6,0372	1,59E-9
Dif_presion_sup^4	-751.540,1854	5.944.845,3415	-0,1264	0,8994
Dif_presion_inf^4	9.017.988,1315	1,16E8	0,078	0,9378
Flujo FDF2^4	4,09E-12	9,26E-13	4,4195	9,94E-6
Frecuencia IDF3^4	65.143,7776	9.659,3509	6,7441	1,58E-11
Temp Hogar_Salida^4	-0,1148	0,0267	-4,2924	1,78E-5
O2^5	-5,2232	1,1731	-4,4524	8,53E-6
Dif_presion_sup^5	-579.681,0191	9.551.249,9831	-0,0607	0,9516
Dif_presion_inf^5	-545.760,5955	8.327.131,1119	-0,0655	0,9477
Flujo FDF2^5	-1,39E-16	2,88E-17	-4,8328	1,36E-6
Frecuencia IDF3^5	-1.296,7463	191,4493	-6,7733	1,29E-11
Temp Hogar_Salida^5	0,0001	2,53E-5	4,33	1,50E-5
O2^6	0,1331	0,0446	2,9853	0,0028
Dif_presion_sup^6	2.488.746,6999	8.211.544,3	0,3031	0,7618
Dif_presion_inf^6	17.768,355	333.249,6314	0,0533	0,9575
Flujo FDF2^6	2,42E-21	4,67E-22	5,1688	2,38E-7

Figura 12 Estadísticas de la regresión polinomial

Fuente: Elaboración propia

Luego de ejecutar el modelo se obtuvo los resultados de la Figura 12, queda evaluar el valor P de cada coeficiente. En su blog oficial Minitab (2013) define que el valor p de cada término de la ecuación polinomial encontrada pone a prueba la hipótesis nula de que el coeficiente es igual a cero (ningún efecto). Es así que un valor p bajo (< 0.05) indica que se puede rechazar la hipótesis

nula. En otras palabras, un predictor que tiene un valor p bajo es probable que sea una adición significativa al modelo porque los cambios en el valor del predictor están relacionados con los cambios en la variable de respuesta. Filtrando los términos con un valor p menor que 0.05 se obtiene el modelo de Tabla 3.

Tabla 3. Modelo resultado de la regresión polinomial

Variable	Exponent	Coeff.	Std. Err.	t-value	P> t
O2	1	-5.450E+03	7.093E+02	-7.684	1.621E-14
Flujo FDF2	1	-1.569E+00	5.804E-01	-2.703	6.884E-03
Frecuencia IDF3	1	-3.503E+08	5.272E+07	-6.645	3.103E-11
Temp Hogar_Salida	1	5.541E+06	1.330E+06	4.167	3.100E-05
O2	2	3.811E+03	4.448E+02	8.568	0.000E+00
Flujo FDF2	2	5.115E-04	1.519E-04	3.369	7.567E-04
Frecuencia IDF3	2	3.519E+07	5.268E+06	6.680	2.447E-11
Temp Hogar_Salida	2	-2.681E+04	6.367E+03	-4.211	2.554E-05
O2	3	-8.860E+02	1.171E+02	-7.568	3.930E-14
Flujo FDF2	3	-6.465E-08	1.643E-08	-3.935	8.352E-05
Frecuencia IDF3	3	-1.958E+06	2.916E+05	-6.713	1.953E-11
Temp Hogar_Salida	3	7.175E+01	1.687E+01	4.253	2.121E-05
O2	4	9.606E+01	1.591E+01	6.037	1.593E-09
Flujo FDF2	4	4.095E-12	9.265E-13	4.419	9.942E-06
Frecuencia IDF3	4	6.514E+04	9.659E+03	6.744	1.578E-11
Temp Hogar_Salida	4	-1.148E-01	2.674E-02	-4.292	1.775E-05
O2	5	-5.223E+00	1.173E+00	-4.452	8.533E-06
Flujo FDF2	5	-1.390E-16	2.876E-17	-4.833	1.356E-06
Frecuencia IDF3	5	-1.297E+03	1.914E+02	-6.773	1.290E-11
Temp Hogar_Salida	5	1.097E-04	2.534E-05	4.330	1.498E-05
O2	6	1.331E-01	4.459E-02	2.985	2.836E-03
Flujo FDF2	6	2.415E-21	4.673E-22	5.169	2.376E-07
Frecuencia IDF3	6	1.430E+01	2.103E+00	6.801	1.068E-11
Temp Hogar_Salida	6	-5.805E-08	1.330E-08	-4.366	1.274E-05
Flujo FDF2	7	-1.687E-26	3.109E-27	-5.426	5.832E-08
Frecuencia IDF3	7	-6.739E-02	9.872E-03	-6.826	8.954E-12
Temp Hogar_Salida	7	1.312E-11	2.982E-12	4.399	1.091E-05

Fuente: Elaboración propia

Es interesante comprobar con la data de prueba que tan bien se ajusta el modelo polinomial de grado 7 con los datos reales medidos para el dióxido de azufre.

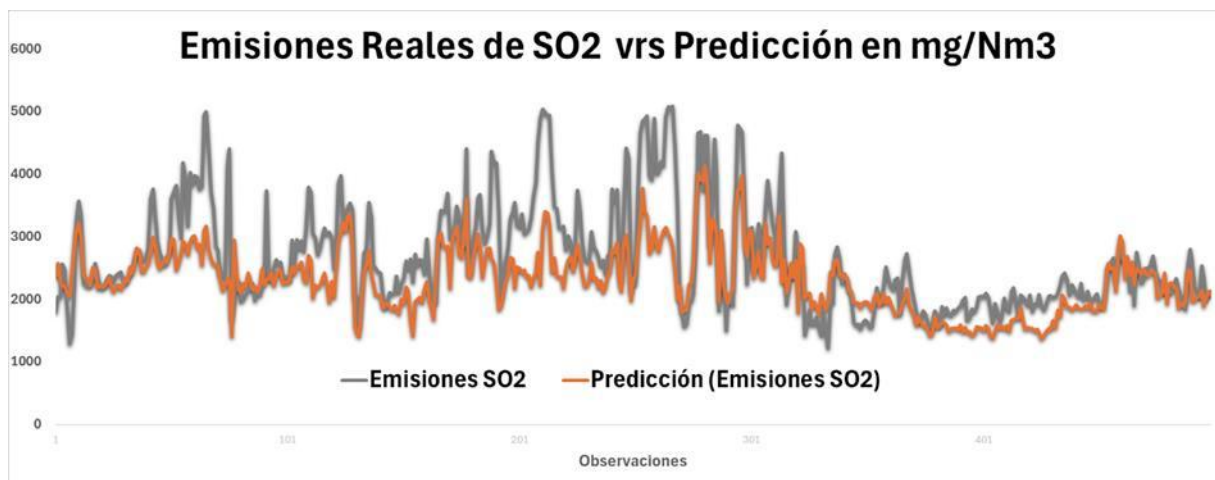


Figura 13 Gráfico comparativo de los valores de SO2 medidos (azul) y los valores de la predicción con el modelo de la regresión polinomial

Fuente: Elaboración propia

En la Figura 13 se muestra el comparativo de la predicción hecha por el modelo y el valor real, el grafico se hizo con una muestra de 500 observaciones del conjunto de datos de prueba. Las unidades de medida para las emisiones de SO2 son miligramos por metro cubico normalizado (mg/Nm³). El modelo se ajusta a los datos reales.

La gráfica de los valores calculados por el modelo en la Figura 13 se ajustan a los valores reales medidos con un valor de R cuadrado de 0.58 de acuerdo a la tabla de la Figura 11. Existe evidencia estadística para pensar que el 58% de la variación en los valores de las emisiones son explicadas por el modelo de regresión polinomial.

No existe una regla universal sobre cómo incorporar la medida estadística a la evaluación de un modelo. El contexto del experimento o la previsión es extremadamente importante y, en diferentes escenarios, las percepciones de la métrica pueden variar.

4.2 RESULTADOS Y ANÁLISIS DE LOS DATOS ENCONTRADOS CON OTRAS TÉCNICAS

Para el caso de analizar los resultados con otras técnicas y transformando la variable respuesta en binaria se han utilizado 4 algoritmos de clasificación, cuyo objetivo principal es determinar que una emisión de SO₂ será “Optima” y “No Optima” considerando que una emisión optima se encuentra por debajo de 2,000 y una No Optima por arriba de 2000.

Para la resolución del problema de clasificación, se emplearon cuatro algoritmos de machine learning: Random Forest, Naive Bayes, Regresión Logística y Árbol de Decisión. El Random Forest es un algoritmo basado en ensamblajes que construye múltiples árboles de decisión durante el entrenamiento y luego realiza una predicción combinando los resultados de todos los árboles. Este enfoque reduce el riesgo de sobreajuste y mejora la precisión al capturar interacciones complejas entre las variables (Breiman, 2001).

El Naive Bayes es un clasificador probabilístico que utiliza el teorema de Bayes con la suposición de independencia entre las variables predictoras. A pesar de esta suposición simplificadora, este algoritmo es altamente eficiente y funciona bien en situaciones con grandes volúmenes de datos y relaciones lineales (Rish, 2001). La Regresión Logística es un modelo estadístico utilizado para predecir la probabilidad de pertenecer a una clase binaria, utilizando una función logística para mapear las predicciones a un rango entre 0 y 1 (Hosmer et al., 2013).

Optimo: SO2 menor o igual a 2000
No Optimo: SO2 mayor a 2000

Random Forest

Scorer View

Confusion Matrix:

	No Optimo (Predicted)	Optimo (Predicted)	
No Optimo (Actual)	5825	332	94.61%
Optimo (Actual)	636	2687	80.86%
	90.16%	89.00%	

Overall Statistics

Overall Accuracy	Overall Error	Cohen's kappa (κ)	Correctly Classified	Incorrectly Classified
89.79%	10.21%	0.771	8512	968

Bayes

Scorer View

Confusion Matrix:

	No Optimo (Predicted)	Optimo (Predicted)	
No Optimo (Actual)	5640	517	91.60%
Optimo (Actual)	1884	1439	43.30%
	74.96%	73.57%	

Overall Statistics

Overall Accuracy	Overall Error	Cohen's kappa (κ)	Correctly Classified	Incorrectly Classified
74.67%	25.33%	0.386	7079	2401

Regresión Logística

Scorer View

Confusion Matrix:

	No Optimo (Predicted)	Optimo (Predicted)	
No Optimo (Actual)	4419	1738	71.77%
Optimo (Actual)	2104	1219	36.68%
	67.74%	41.22%	

Overall Statistics

Overall Accuracy	Overall Error	Cohen's kappa (κ)	Correctly Classified	Incorrectly Classified
59.47%	40.53%	0.087	5638	3842

Árbol de decisión

Scorer View

Confusion Matrix:

	No Optimo (Predicted)	Optimo (Predicted)	
No Optimo (Actual)	5500	657	89.33%
Optimo (Actual)	744	2579	77.61%
	88.08%	79.70%	

Overall Statistics

Overall Accuracy	Overall Error	Cohen's kappa (κ)	Correctly Classified	Incorrectly Classified
85.22%	14.78%	0.673	8079	1401

Figura 14 Selección de modelo

Fuente: Elaboración propia

Finalmente, el Árbol de Decisión es un modelo de aprendizaje supervisado que divide el espacio de características en segmentos basados en decisiones sucesivas. Este modelo es fácil de interpretar, pero puede ser propenso al sobreajuste si no se ajusta adecuadamente (Quinlan, 1986). De los algoritmos probados, Random Forest mostró el mejor desempeño, alcanzando una mayor precisión y robustez en comparación con los demás modelos, especialmente en contextos con datos ruidosos y variables correlacionadas.

Optimo: SO2 menor o igual a 2000
No Optimo: SO2 mayor a 2000

Random Forest

Scorer View
Confusion Matrix

	No Optimo (Predicted)	Optimo (Predicted)	
No Optimo (Actual)	5694	494	92.02%
Optimo (Actual)	740	2552	77.52%
	88.50%	83.78%	

Overall Statistics

Overall Accuracy	Overall Error	Cohen's kappa (κ)	Correctly Classified	Incorrectly Classified
86.98%	13.02%	0.708	8246	1234

Bayes

Scorer View
Confusion Matrix

	No Optimo (Predicted)	Optimo (Predicted)	
No Optimo (Actual)	5844	344	94.44%
Optimo (Actual)	2293	999	30.35%
	71.82%	74.39%	

Overall Statistics

Overall Accuracy	Overall Error	Cohen's kappa (κ)	Correctly Classified	Incorrectly Classified
72.18%	27.82%	0.288	6843	2637

Regresión Logística

Scorer View
Confusion Matrix

	No Optimo (Predicted)	Optimo (Predicted)	
No Optimo (Actual)	89	6099	1.44%
Optimo (Actual)	395	2897	88.00%
	18.39%	32.20%	

Overall Statistics

Overall Accuracy	Overall Error	Cohen's kappa (κ)	Correctly Classified	Incorrectly Classified
31.50%	68.50%	-0.075	2986	6494

Árbol de decisión

Scorer View
Confusion Matrix

	No Optimo (Predicted)	Optimo (Predicted)	
No Optimo (Actual)	5438	750	87.86%
Optimo (Actual)	974	2318	70.41%
	84.81%	75.55%	

Overall Statistics

Overall Accuracy	Overall Error	Cohen's kappa (κ)	Correctly Classified	Incorrectly Classified
81.81%	18.19%	0.592	7756	1724

Figura 15 Selección de mejor modelo luego de reducir predictores por elevada correlación

Fuente: Elaboración propia

Modelo	Overall Accuracy	Cohen's kappa
Random Forest	0.87	0.71
Decision Tree	0.82	0.59
Naive Bayes	0.72	0.29
Logistic Regression	0.31	-0.08

Figura 16 Métricas de los modelos de clasificación aplicados

Fuente: Elaboración propia

CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES

Luego de los resultados obtenidos en el capítulo anterior, en este capítulo se resumen las conclusiones que se pueden plantear basadas en los resultados obtenidos durante el proceso de análisis de datos, asegurando contestar todas las preguntas planteadas a lo largo de esta investigación y con la suficiente evidencia estadística.

5.1 CONCLUSIONES

1. La investigación destacó que el exceso de oxígeno (O_2), el flujo de aire y la temperatura en la caldera son predictores claves para el control de las emisiones de SO_2 .
2. La exclusión de días con configuraciones especiales y de variables altamente correlacionadas permitió mejorar la precisión de los análisis y desarrollar modelos predictivos más confiables. Esto evidencia la necesidad de monitorear y ajustar constantemente los parámetros operativos para mantener las emisiones dentro de los límites normativos.
3. El exceso de oxígeno aportó los términos más significativos para el modelo polinomial con valores P tan pequeños que se aproximaron a cero.
4. La temperatura que mayor afecta el resultado de las emisiones es la temperatura en la salida de la caldera, las temperaturas en el lecho se eliminaron del modelo al presentar fuerte correlación lineal con las demás variables, con coeficientes de correlación de Pearson mayores a 0.7.
5. Los valores de presión diferencial superior e inferior no aportaron términos significativos al modelo polinomial.
6. Se observó que el modelo de regresión polinomial de grado 6 puede explicar el 58% de la variabilidad en las emisiones de SO_2 , lo cual, aunque moderado, proporciona información valiosa para optimizar el proceso de combustión. Por otro lado, el algoritmo Random Forest demostró ser altamente efectivo en la clasificación de emisiones "Óptimas" (<2000 ppm) y "No Óptimas" (>2000 ppm), siendo una herramienta robusta para escenarios con datos ruidosos y variables correlacionadas. Estas herramientas representan un avance significativo para el monitoreo y control en tiempo real de las emisiones.
7. La reducción del consumo de carbonato de calcio sin exceder los límites normativos de emisiones no solo contribuye al cumplimiento de regulaciones ambientales, sino que también mejora la sostenibilidad operativa de la empresa. Esto se traduce en una disminución de los costos operativos y una mejor gestión de los recursos, fortaleciendo la competitividad de la empresa en el mercado textil. Además, los resultados de esta investigación aportan un marco técnico y metodológico que puede

ser replicado en otras industrias con procesos similares, promoviendo el desarrollo de tecnologías más limpias y eficientes.

5.2 RECOMENDACIONES

1. Implementar estrategias de monitoreo y ajuste continuo de parámetros como el flujo de aire, la temperatura de combustión a la salida del hogar de la caldera. Estos ajustes deben basarse en datos históricos y en modelos predictivos para asegurar una combustión eficiente y una captura óptima de azufre.
2. Diseñar protocolos que permitan identificar rápidamente desviaciones operativas y aplicar correcciones antes de que las emisiones superen los límites normativos. Esto incluye la instalación de sensores más precisos para monitorear en tiempo real variables como el exceso de oxígeno y la temperatura del hogar.
3. Integrar el algoritmo Random Forest y otros modelos desarrollados durante la investigación en el sistema de gestión operativa de la caldera. Esto permitiría predecir de manera temprana situaciones de emisiones no óptimas, facilitando la implementación de acciones correctivas inmediatas.
4. Desarrollar una interfaz de usuario que permita al personal visualizar las predicciones y recibir alertas en tiempo real, simplificando la toma de decisiones y mejorando la eficiencia operativa.
5. Brindar formación continua al personal técnico sobre el uso de modelos predictivos y la interpretación de los datos generados por los sistemas de monitoreo. Esto asegura que las herramientas desarrolladas se utilicen de manera efectiva y que los operadores estén capacitados para implementar mejoras en tiempo real.
6. Sensibilizar a los empleados sobre la importancia del cumplimiento normativo en emisiones y su relación con la sostenibilidad operativa y ambiental. Esto refuerza el compromiso de todos los niveles de la organización con los objetivos ambientales y de eficiencia.

CAPÍTULO VI. APLICABILIDAD

En este capítulo se plantea la propuesta alineada con el cumplimiento del objetivo principal de reducir el consumo de carbonato de calcio sin afectar las emisiones de dióxido de azufre, la propuesta comienza con la lectura de la data hasta la generación de un correo electrónico alertando una operación no óptima de caldera. Esta propuesta se desarrolla en la plataforma de Office 365.

6.1 NOMBRE DE LA PROPUESTA

Sistema de alertas para optimizar captura de azufre en la caldera implementando un flujo de trabajo en Microsoft 365 mediante Power Automate.

6.2 JUSTIFICACION DE LA PROPUESTA

Con el modelo matemático entrenado a partir de la regresión polinomial en el análisis de resultados se definieron los principales predictores que ocasionan cerca del 60% de la variación de las emisiones de dióxido de azufre. Con el mismo modelo se definirán los valores para los cuales la captura de azufre en la caldera es óptima y con esta propuesta del sistema de alarmas mantendrá en control la operación alertando oportunamente a los tomadores de decisiones cuando variable se salga de control.

Para evitar incurrir en costos extras y problemas de integración, la propuesta se diseñará dentro de Microsoft 365 debido a que la compañía cuenta con suscripción permanente en esta plataforma. Las herramientas para usarse no agregan costo extra a esta suscripción, las funciones requeridas están dentro del paquete pagado por la compañía.

6.3 ALCANCE DE LA PROPUESTA

Reducir el consumo de carbonato de calcio mediante la implementación de un sistema de alertas para evitar que la caldera entre en un estado de operación donde la captura de azufre no es eficiente. Los operadores de las calderas serán informados de los valores máximos y mínimos que debe tener cada variable independiente, su trabajo será mantener esas condiciones en la caldera y cuando se incumpla el jefe inmediato será notificado vía correo para reforzar esta instrucción.

La salida o producto final de esta propuesta es la generación automática de un correo de alerta para los tomadores de decisiones del departamento.

6.4 DESCRIPCIÓN Y DESARROLLO A DETALLE DE LA PROPUESTA.

6.4.1 DESCRIPCIÓN

Esta implementación se hará mediante la creación de un flujo de trabajo en el ambiente de Microsoft 365 en el que se conectará la base de datos de operación de la caldera con un Dashboard de PowerBI en el que se hará la evaluación del promedio de cada variable en un periodo de tiempo de 6 horas, el resultado de la evaluación pasará a un módulo predefinido en Power Automate y al violar el conjunto de restricciones se generará un correo hacia el jefe de turno para reforzar la instrucción y fijar los parámetros operativos en los valores óptimos.

6.4.2 DESARROLLO

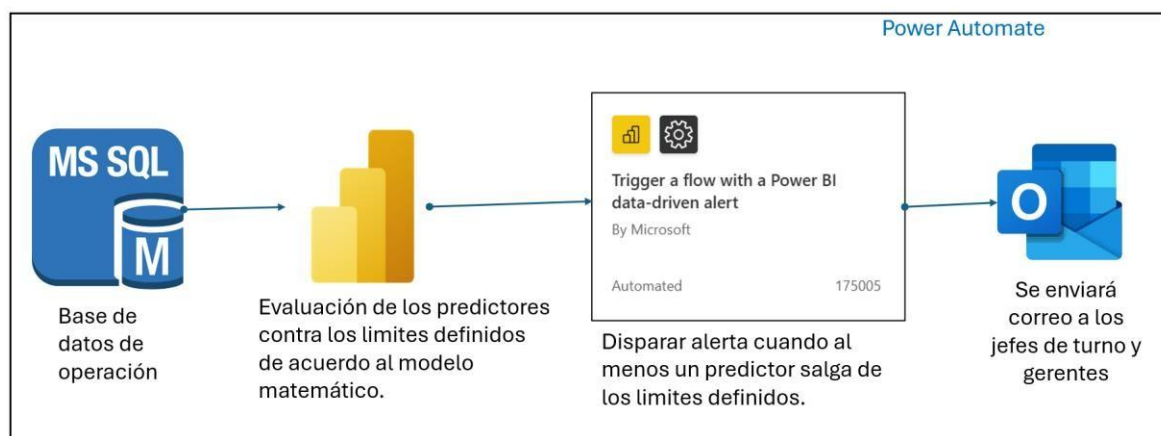


Figura 17 Diagrama de flujo de trabajo a implementar

Fuente: Elaboración propia

En la Figura 17 se ilustra el flujo de trabajo para la implementación de la propuesta, comenzando con la configuración de acceso a la base de datos, esta es la base de datos de la operación de la caldera la cual contiene datos en intervalos de 1 segundo. La limpieza y transformación de la data se hará en Power BI el cual estará publicado en el entorno de Microsoft 365 y será consultado por un módulo predefinido en Power Automate al cual se le configura la dirección del archivo publicado que debe consultar.

La salida del módulo de Power Automate será un correo dirigido a los jefes de turno, ingeniero de procesos y gerentes.

6.5 MEDIDAS DE CONTROL

Como medida de control se definirán 6 métricas para cada turno de 12 horas, las métricas de cada turno serán visualizadas gráficamente como un Boxplot por cada variable en un dashboard de Power Bi y serán las siguientes:

- a) Porcentaje de oxígeno a la salida de la caldera
- b) Presión diferencial superior de la caldera
- c) Temperatura superior en la salida de la caldera
- d) Frecuencia de ventilador inducido
- e) Frecuencia del ventilador forzado secundario
- f) Flujo de aire del ventilador forzado secundario

Cada jefe de turno será responsable de mantener estas métricas dentro de los parámetros establecidos y la revisión será semanal mediante una reunión de equipo.

6.6 CRONOGRAMA DE IMPLEMENTACIÓN Y PRESUPUESTO

El programa de trabajo para implementar un flujo de trabajo en Power Automate que envíe correos cuando las variables superen los límites establecidos requiere dividir el proyecto en etapas clave en lapso de 4 semanas.

SEMANA 1: PLANIFICACIÓN Y DISEÑO

Día 1-2: Identificación de variables y límites

- Reunir información sobre las 6 variables y sus límites aceptables.
- Definir los eventos que disparan el flujo de trabajo.
- Establecer las reglas de negocio para las alertas.

Día 3-4: Especificaciones del flujo

- Diseñar un esquema básico del workflow en Power Automate.
- Definir los tipos de notificación (e.g., email) y destinatarios.

Día 5: Configuración de recursos

- Crear o identificar las fuentes de datos (e.g., Excel, SQL Server, SharePoint).

- Garantizar permisos y accesos a los sistemas requeridos.

SEMANA 2: CONFIGURACIÓN DEL FLUJO EN POWER AUTOMATE

Día 1-2: Conexión a datos

- Configurar conectores (e.g., SharePoint, OneDrive, SQL, o API) para obtener datos.
- Validar que Power Automate acceda correctamente a las variables.

Día 3-4: Configuración de disparadores

- Definir los disparadores:
 - Automático (cuando cambien los datos).
 - Basado en un cronograma (revisión periódica).
- Probar la captura de eventos que superan los límites.

Día 5: Diseño del flujo

- Configurar condiciones y ramificaciones basadas en los valores de las variables.
- Añadir acciones como el envío de correos electrónicos.

SEMANA 3: PRUEBAS Y AJUSTES

Día 1-2: Pruebas unitarias

- Simular datos que cumplan y no cumplan los límites.
- Validar que los correos electrónicos se envíen correctamente.

Día 3: Ajustes de mensajes

- Personalizar los correos electrónicos con datos relevantes (variables, límites, recomendaciones).

Día 4-5: Validación con el equipo

- Revisar el flujo con las partes interesadas.
- Incorporar cambios según el feedback.

SEMANA 4: DOCUMENTACIÓN Y DESPLIEGUE

Día 1-2: Documentación

- Crear una guía de usuario y un manual técnico para el flujo. Incluir ejemplos y posibles errores.

Día 3-4: Capacitación

- Capacitar al equipo en la operación y mantenimiento del flujo.
- Hacer pruebas en un entorno controlado con datos reales.

Día 5: Despliegue

- Activar el flujo en el entorno de producción.
- Monitorear el funcionamiento inicial y solucionar problemas.

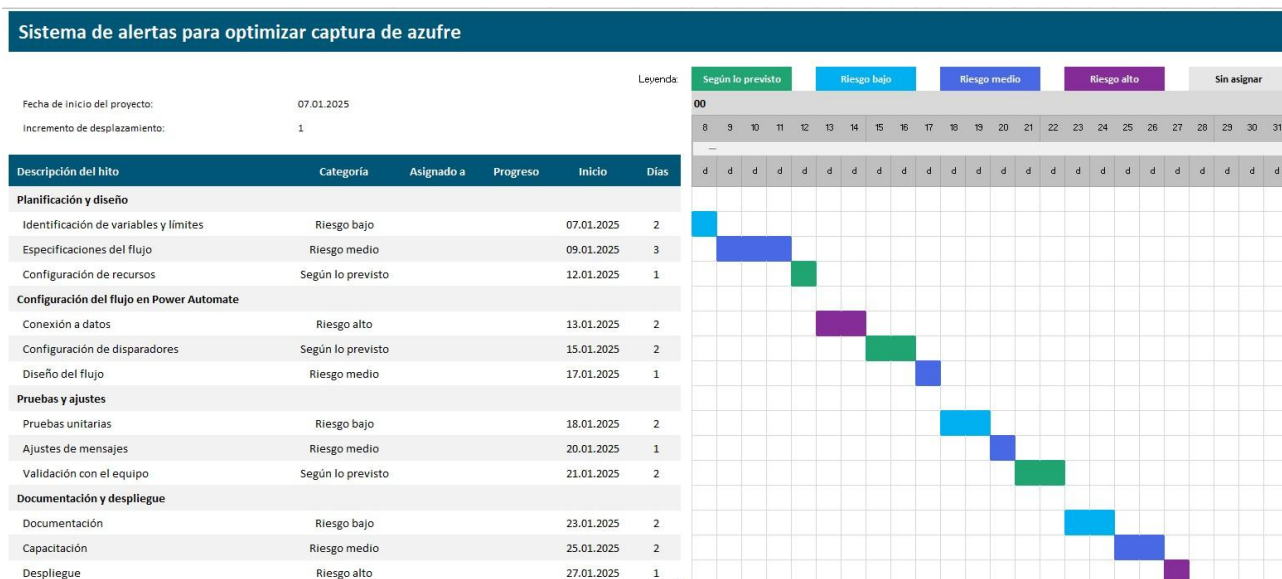


Figura 18 Diagrama de Gantt de la propuesta

Fuente: Elaboración propia

En la Tabla 4 se muestra el presupuesto para la implementación de la propuesta en una compañía donde no se cuente con la suscripción de Office 365, este presupuesto es anual y suma un total de L. 39,708.00. En la compañía donde se implementará esta propuesta ya se cuenta con la suscripción anual a la plataforma Office 365 evitando incurrir en este costo.

Tabla 4 Presupuesto para implementación de la propuesta

Herramienta	Cantidad	Costo Unitario	Total
Mensualidad de Power BI Pro	12	L. 253.00	L. 3,036.00
Mensualidad Microsoft 365 Business Premium	12	L.556.00	L. 6,672.00
Computadora 32 de Ram y 512 GB de disco	1	L.30,000.00	L.30,000.00
Total General			L.39,708.00

6.7 CONCORDANCIA DE LOS SEGMENTOS DE LA TESIS CON LA PROPUESTA

La propuesta presentada en este trabajo, que busca optimizar el consumo de carbonato de calcio mediante un sistema de monitoreo y alertas, está directamente fundamentada en los objetivos, análisis y resultados desarrollados en la investigación. Desde el planteamiento inicial del problema, se identificó que la cantidad de carbonato de calcio utilizada en la caldera representa un costo significativo para la operación de la empresa, lo cual está alineado con el objetivo general de reducir dicho consumo sin comprometer las emisiones normativas de dióxido de azufre (SO₂).

El marco teórico proporciona la base conceptual para la propuesta, explorando técnicas como la regresión polinomial y algoritmos de machine learning, que se utilizan para modelar y predecir las emisiones. Estas herramientas no solo demostraron ser relevantes en investigaciones previas, sino que también fueron validadas en los resultados obtenidos en esta tesis. Por ejemplo, los algoritmos de machine learning, como Random Forest y Naive Bayes, han mostrado una precisión notable en la predicción de emisiones y en la clasificación de escenarios operativos como "óptimos" y "no óptimos". Esto respalda la factibilidad técnica de integrar estos modelos en la propuesta de un sistema de monitoreo automatizado.

En el capítulo de metodología, se planteó el listado de variables que afectaban la variable dependiente, como la temperatura, el oxígeno, el flujo de aire y la presión en el hogar de la caldera. Este planteamiento prepara el terreno no solo para validar las hipótesis planteadas, sino que también

identificar las combinaciones óptimas de estas variables, las cuales se traducen directamente en las restricciones que serán implementadas en el sistema de alertas de la propuesta.

Este sistema será capaz de identificar en tiempo real las desviaciones de los valores óptimos y notificar a los operadores para realizar los ajustes necesarios.

Finalmente, las conclusiones y recomendaciones del trabajo refuerzan la viabilidad de la propuesta al destacar la importancia de monitorear continuamente las variables operativas y aprovechar las herramientas predictivas para mantener las emisiones bajo norma. La implementación de un sistema basado en modelos matemáticos y algoritmos de machine learning, como el propuesto, no solo garantiza el cumplimiento normativo, sino que también reduce los costos operativos al minimizar el consumo de carbonato de calcio. Esto se alinea con las necesidades operativas de la empresa y con los objetivos planteados desde el inicio de la investigación

Tabla 5. Matriz de concordancia

Capítulo I			Capítulo II	Capítulo III			Capítulo IV	Capítulo VI	
Título Investigación	Objetivo General	Objetivos Específicos	Teorías/Methodologías de sustento	Variables	Población	Técnicas	Conclusiones	Nombre de la Propuesta	Objetivos Propuesta

Reducción del consumo de carbonato de calcio manteniendo emisiones bajo norma en calderas de lecho fluidizado	optimizar la captura de azufre en la caldera que permita mantener las emisiones de dióxido de azufre bajo norma sin aumentar la cantidad de carbonato de calcio introducido en la caldera	Determinar cómo afecta el flujo de aire de combustión en la variación de las emisiones de dióxido de azufre. Revisar cómo afecta el exceso de oxígeno de combustión en la variación de las emisiones	Combustión controlada, modelado estadístico, machine learning, Power BI y Power Automate como herramientas predictivas.	Emisiones de dióxido de azufre, Flujo de aire primario Flujo de aire secundario Exceso de oxígeno de combustión Temperatura del Lecho Temperaturas en la salida del hogar Presión diferencial superior Presión diferencial inferior	VARIABLES OPERATIVAS DE CALDERAS INDUSTRIALES DE LECHO FLUIDIZADO	Regresión polinomial, Random Forest, Power BI para visualización, Power Automate para alertas.	La investigación destacó que el exceso de oxígeno (O ₂), el flujo de aire y la temperatura en la caldera son predictores claves para el control de las emisiones de SO ₂ , El exceso de oxígeno aportó los términos más significativos para el modelo polinomial con valores P tan pequeños que se aproximaron a cero. La temperatura que mayor afecta el resultado de las	Sistema de alertas para optimizar la captura de azufre en la caldera implementando un flujo de trabajo en Microsoft 365 mediante Power Automate.	Implementar un sistema predictivo que ajuste automáticamente las condiciones operativas de la caldera para optimizar el consumo de aditivos.
---	---	---	---	---	---	--	---	--	--

de dióxido de

--	--	--	--	--	--

azufre.

Definir cómo
afecta la
temperatura
de la caldera
en la
variación de
las emisiones
de dióxido de
azufre.

Determinar
cómo afecta
la presión
diferencial en
el hogar de la
caldera en la
variación de
las emisiones
de dióxido de
azufre.
emisiones es

la temperatura en la
salida de la cadera, las
temperaturas en el
lecho se eliminaron
del modelo al
presentar fuerte
correlación lineal con
las demás variables,
con coeficientes de
correlación de Pearson
mayores a 0.7.

Los valores de presión
diferencial superior e
inferior no aportaron
términos significativos
al modelo polinomial.

Se observó
que el
modelo de
regresión
polinomial de
grado 6
puede
explicar el
58% de la

variabilidad
en las
emisiones de
SO₂
Seleccionar
un modelo
matemático
que explique
más del 50%
de la variación
en las
emisiones de
dióxido de
azufre.

REFERENCIAS BIBLIOGRAFICAS

Alfaro-Alfaro, Daniel; Salas-Morelli, Luis; Sánchez-Mejías, Bryan; Mora-Barrantes, José; Sibaja-Brenes, José Pablo; Borbón-Alpizar, Henry (2021): Preliminary inventory of atmospheric emissions (SO₂, NO_x and TSP) from different industrial sectors in Costa Rica. In: *Uniciencia* 35 (2), S. 1–13. DOI: 10.15359/ru.35-2.5.

chaves, Kevin David; Sibaja, José Pablo; Perez, Esteban (2021): Monitoreo de la concentración de SO₂ en el aire y características físicoquímicas del agua de lluvia en el Volcán Irazú.

Economía y Negocios (2023): Cierre de empresas aumenta el desempleo y la migración.

Education, UCAR Center for Science (2024): Sulfur Oxides | Center for Science Education. Online verfügbar unter <https://scied.ucar.edu/learning-zone/air-quality/sulfur-oxides>, zuletzt aktualisiert am 19.03.2024, zuletzt geprüft am 19.03.2024. aría, A.; Pérez, D. (2018): Estrategias de control de emisiones en calderas de lecho fluidizado:

Un enfoque experimental. *Revista de Ingeniería Ambiental*.

Guo, Yiqi; Zhu, Lisha; Wang, Xiaopeng; Qiu, Xiaoxiao; Qian, Weiran; Wang, Laili (2022): Assessing environmental impact of NO_x and SO₂ emissions in textiles production with chemical footprint. In: *The Science of the total environment* 831, S. 154961. DOI: 10.1016/j.scitotenv.2022.154961.

Instituto Nacional de Ecología Mexico (2017): Tipos de emisiones de contaminantes atmosféricos. Online verfügbar unter https://paot.org.mx/centro/ine-semarnat/informe02/estadisticas_2000/compendio_2000/03dim_ambiental/03_01_Atmosfera/data_atmosfera/RecuadroIII.1.1.2.htm, zuletzt aktualisiert am 04.02.2017, zuletzt geprüft am 19.03.2024.

Ballesteros (2008): COMBUSTIÓN DEL PETCOKE CON ADICIÓN DE COMBUSTIÓN DEL PETCOKE CON ADICIÓN DE CALIZA EN UN HOGAR DE LECHO FLUIDIZADO

CIRCULANTE. Universidad del Bio Bio.

Jones, Anne (2019): Grate firing has been the most commonly used firing method for combusting solid fuels in small and medium-sized furnaces since the beginning of the industrialization. Coal, waste and biomass fuels are usually burned in grate boiler, 15.03.2019. Online verfügbar unter <https://www.linkedin.com/pulse/what-chain-grate-boiler-anne-jones>, zuletzt geprüft am 06.03.2024.

Kohonen, T. (2001): *Self-Organizing Maps*. Springer.

Kolehmainen, Mikko; Toivanen, Pekka; Beliczynski, Bartlomiej (2009): *Adaptive and Natural Computing Algorithms*. Berlin, Heidelberg: Springer Nature (5495).

Liu, Jian; Yang, Qingshan; Zhang, Yu; Sun, Wen; Xu, Yiming (2019): Analysis of CO₂ Emissions in China's Manufacturing Industry Based on Extended Logarithmic Mean Division Index Decomposition. In: *Sustainability* 11 (1), S. 226. DOI: 10.3390/su11010226.

López, J.; Alarcón, M. (2011): Sulfato de calcio: propiedades y aplicaciones clínicas. In: *Rev. Clin. Periodoncia Implantol. Rehabil. Oral* 4 (3), S. 138–143. DOI: 10.4067/S071901072011000300012.

MacQueen, J. (Hg.) (1967): Some methods for classification and analysis of multivariate observations. Fifth Berkeley Symposium on Mathematical Statistics and Probability. Statistics. University of California Press,

Mika Liukkonen, Eero Hälikkä, Reijo Kuivalainen, Yrjö Hiltunen (2010): Modeling of nitrogen oxide emissions in fluidized bed combustion using artificial neural networks.

OKA, H. (2003a): Experimental investigation of SO₂ emissions and limestone consumption in a bubbling fluidized bed combustor.

OKA, SIMEON (2003b): FLUIDIZED BED COMBUSTION. [Place of publication not identified]: CRC Press.

S. Jimenez (2012): Combustion de carbon. Online verfügbar unter http://www.energia2012.es/sites/default/files/Combustion_de_carbon.pdf, zuletzt geprüft am 03.06.2024.

Secretaria de Recursos Naturales y Ambiente (2011): Reglamento para el control de emisiones generadas por fuentes fijas. In: *Diario Oficial de la Republica de Honduras La Gaceta*, 21.02.2011. Online verfügbar unter <https://www.tsc.gob.hn/web/leyes/Reglamento%20para%20el%20control%20de%20emisiones%20generadas%20por%20fuentes%20fijas.pdf>, zuletzt geprüft am 03.05.2024.

Smith, J. (2015): Combustion processes in fluidized bed boilers: A theoretical overview. *Journal of Energy Engineering*.

Smith, J. K. (2019): Understanding the Impact of Sulfur Dioxide Emissions from Industrial Processes. *Environmental Science and Technology*.

US EPA (2016): What is Acid Rain? | US EPA. Online verfügbar unter <https://www.epa.gov/acidrain/what-acid-rain>, zuletzt aktualisiert am 01.06.2023, zuletzt geprüft am 19.03.2024.

WVZ Khan, B. GibbsM (Hg.) (1991a): Simultaneous Removal of NO_x and SO₂ by limestone and ammonia during unstaged and staged FBC. Montreal.

WVZ Khan. (1991b): Sulfur retention and sulfur dioxide emissions from fluidized-bed combustion. *Progress in Energy and Combustion Science*.

Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.

Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression* (3rd ed.). Wiley.

Montgomery, D. C., Peck, E. A., & Vining, G. G. (2012). *Introduction to linear regression analysis* (5th ed.). Wiley.

Quinlan, J. R. (1986). Induction of decision trees. *Machine Learning*, 1(1), 81–106.

Chaves, F., Hernández, M., & López, P. (2021). Predicting NO_x emissions from biomass combustion in fluidized bed boilers using machine learning techniques. *Journal of Environmental Engineering and Technology*, 15(4), 562–574.

García, A., & Pérez, L. (2018). Non-linear regression models for optimizing sulfur emissions in industrial boilers. *Industrial Process Optimization*, 10(2), 132–145.

Li, J., Wang, Z., & Liu, S. (2020). Machine learning methods for predicting sulfur dioxide emissions in industrial boilers. *Environmental Science & Technology*, 54(7), 4200–4207.

Zhang, Y., Chen, W., & Li, X. (2019). Machine learning approaches for real-time emission control in industrial processes. *Energy & Environmental Science*, 12(6), 1550–1563.

Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.

García, A., & Pérez, L. (2018). Non-linear regression models for optimizing sulfur emissions in industrial boilers. *Industrial Process Optimization*, 10(2), 132–145.

Oka, S. (2004). Fluidized bed combustion. *Marcel Dekker Inc.*

Pérez, J., & García, L. (2021). Implementación de plataformas de automatización en procesos industriales. *Journal of Industrial Technology*, 28(3), 123-135.

Smith, T. (2015). Controlled combustion processes for emission reduction. *Energy and Environment Journal*, 12(4), 230-245.

Smith, T., & Brown, H. (2020). The impact of business intelligence tools on industrial decisionmaking. *International Journal of Operations Research*, 45(2), 87-102.

ANEXOS

Anexo 1

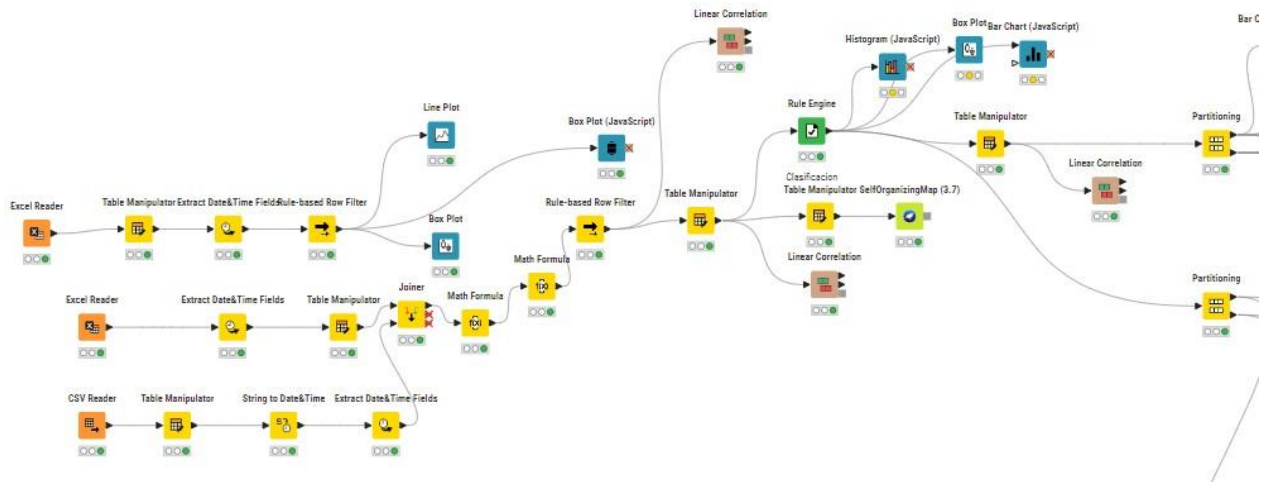


Figura 19 Workflow de Knime para lectura y limpieza de datos Fuente:

Elaboración propia

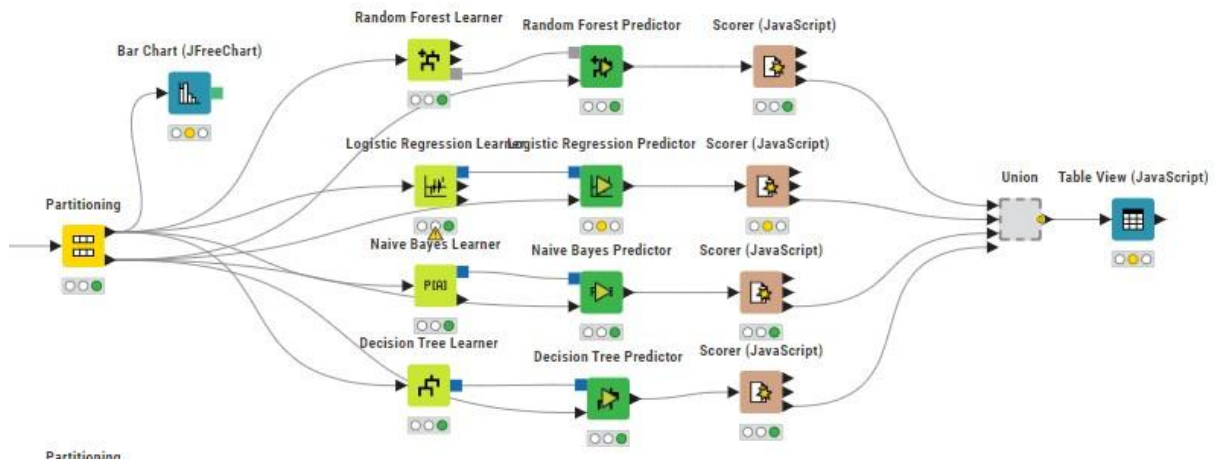


Figura 20 Partición para modelos de clasificación

Fuente: Elaboración propia

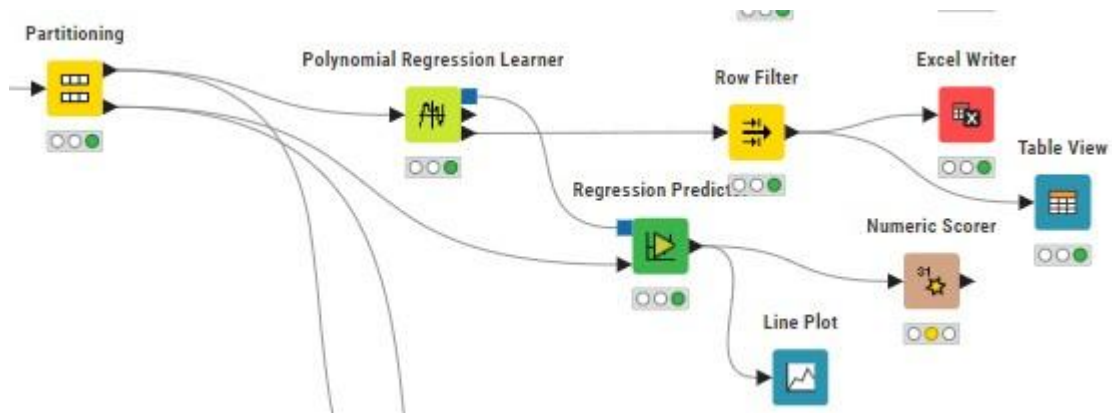


Figura 21 Partición para modelo de regresión

Fuente: Elaboración propia

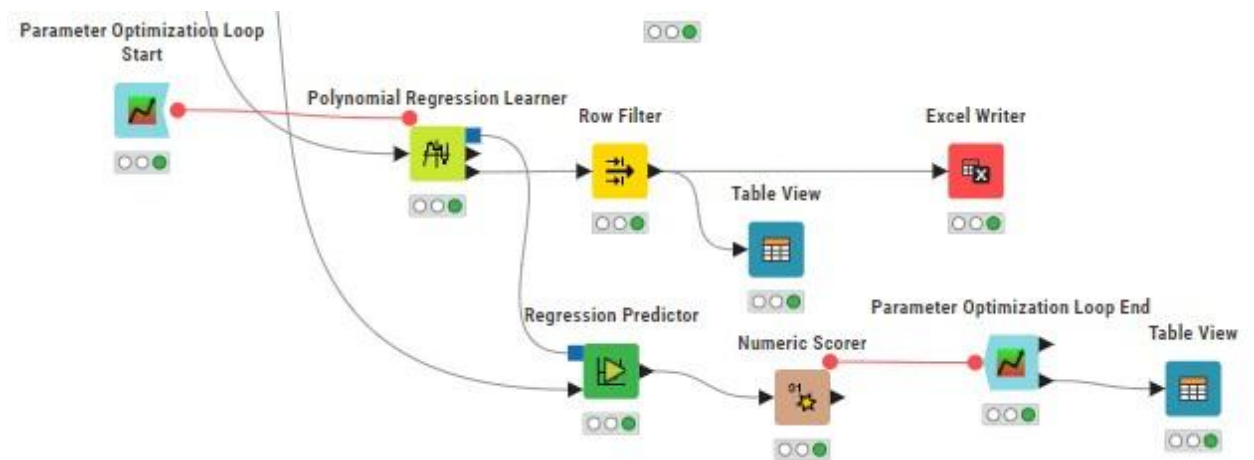


Figura 22 Loop para seleccionar el grado del modelo polinomial

Fuente: Elaboración propia

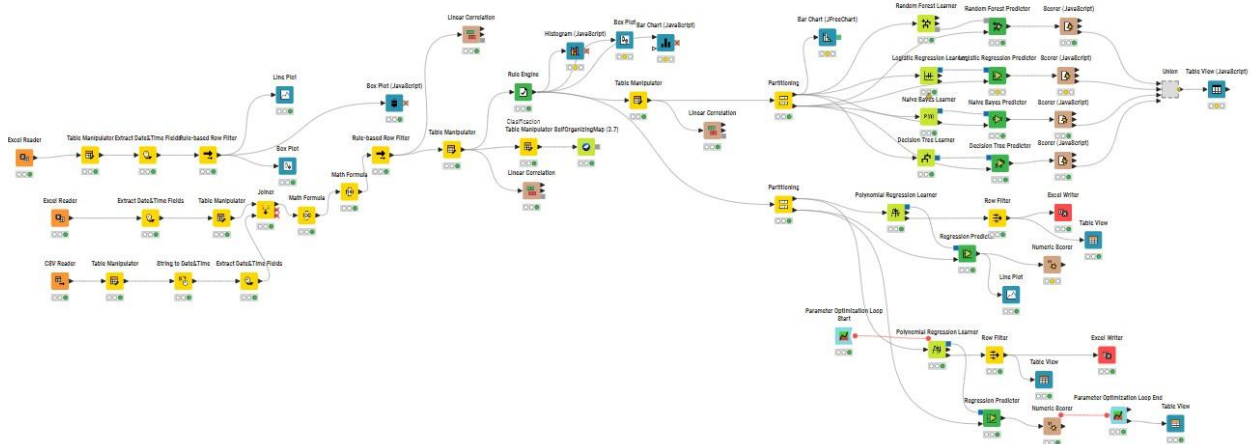


Figura 23 Workflow completo en Knime

Fuente: Elaboración propia