



UNIVERSIDAD JOSÉ ANTONIO PÁEZ

**PROPUESTA DE DISEÑO DE UN SISTEMA DE PREDICCIÓN DE FALLAS PARA UN
TAMBOR SECADOR DE NEGRO DE HUMO MEDIANTE UNA INTELIGENCIA
ARTIFICIAL.**

Autor:

Jefferson Johan Méndez Colmenares C.I.: 28.430.336

Urb. Yuma II, calle N.º 3. Municipio San Diego
Teléfono: (0241) 8714240 (master) – Fax: (0241) 8712394



REPÚBLICA BOLIVARIANA DE VENEZUELA
UNIVERSIDAD JOSÉ ANTONIO PÁEZ
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA MECÁNICA

**PROPUESTA DE DISEÑO DE UN SISTEMA DE PREDICCIÓN DE FALLAS PARA UN
TAMBOR SECADOR DE NEGRO DE HUMO MEDIANTE UNA INTELIGENCIA
ARTIFICIAL.**

Proyecto del Trabajo de Grado para optar al título de
INGENIERO MECÁNICO

Autor:

Jefferson Johan Méndez Colmenares C.I.: 28.430.336

Tutor:

Ing. Donato Romanello

San Diego, agosto de 2023



UNIVERSIDAD JOSÉ ANTONIO PÁEZ
COORDINACIÓN DE PASANTÍA Y TRABAJO DE GRADO

ACTA DE APROBACIÓN

INFORME FINAL DE PASANTÍA

TRABAJO DE GRADO

El jurado designado por la Facultad de INGENIERÍA para la evaluación del Informe Final de Pasantía o Trabajo de Grado titulado: Propuesta de diseño de un sistema de predicción de fallas para un tambor secador de negro de humo mediante inteligencia artificial.

Realizado por el (la) Br. Jefferson Méndez
C.I. N° 28430336 cursante de la carrera de MECÁNICA

hace constar después de analizar su contenido y oída la exposición oral, considera que el Informe Final o Trabajo de Grado ha obtenido la calificación de:

APROBADO

NO APROBADO

El Jurado

[Signature]
Tutor Académico (Coordinador)
Nombre: Donato Románello
C.I.: 4131977

[Signature]
Jurado
Nombre: Laura Saenz
C.I.: 4357366

[Signature]
Jurado
Nombre: Fredy Barragan Fecha: 05/09/23
C.I.: 11151678





REPÚBLICA BOLIVARIANA DE VENEZUELA
UNIVERSIDAD JOSÉ ANTONIO PÁEZ
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA

**CONSTANCIA DE APROBACIÓN PARA LA PRESENTACIÓN
PÚBLICA DEL TRABAJO DE GRADO**

Quien suscribe, Ing. Donato Romanello, portador de la cédula de identidad N° 4.131.877, en mi carácter de tutor del trabajo de grado presentado por el ciudadano Jefferson Méndez, portador de la cédula de identidad N°28.430.336, titulado "**PROPUESTA DE DISEÑO DE UN SISTEMA DE PREDICCIÓN DE FALLAS PARA UN TAMBOR SECADOR DE NEGRO DE HUMO MEDIANTE UNA INTELIGENCIA ARTIFICIAL**". presentado como requisito parcial para optar al título de Ingeniero Mecánico, considero que dicho trabajo reúne los requisitos y méritos suficientes para ser sometido a la presentación pública y evaluación por parte del jurado examinador que se designe.

En San Diego, a los 28 días del mes de agosto del año dos mil veintitrés.

Ing. Donato Romanello

C.I: 4.131.877



REPÚBLICA BOLIVARIANA DE VENEZUELA
UNIVERSIDAD JOSÉ ANTONIO PÁEZ
FACULTAD DE INGENIERÍA

FI N 010 2022-3CR TG

Valencia, 14 de abril de 2023

Ciudadano:
MENDEZ COLMENARES, JEFFERSON JOHAN
28.430.336
Presente -

Cumplo con informarle que la comisión de Trabajo de Grado y Pasantías de la Facultad de Ingeniería en su reunión N° 02-2023 de fecha 08/02/2023 aprobó el proyecto de grado titulado:

Propuesta de diseño de un sistema de predicción de fallas para un tambor secador de negro humo mediante inteligencia artificial.

Presentado por usted como requisito para optar al título de Ingeniero Mecánico.

Se ratifica la designación del Tutor Académico que lo asesorará en el desarrollo de este proyecto a:
Ing. Donato Romanello Lombardi, titular de la cédula de identidad V-4.131.877

Atentamente

Dra. Laura Aurora Sáenz Palencia
Decana de la Facultad de Ingeniería



c.c. Coordinación de Pasantías y Trabajo de Grado de la Facultad de Ingeniería

RECONOCIMIENTOS:

De primera instancia a mis padres y familia, por su gran apoyo incondicional, comprensión, esfuerzo y amor para conmigo, por acompañarme y estar presentes en todos y cada uno de los momentos de mi vida, además de ser mis primeros guías brindándome enseñanzas y valores que me hicieron la persona que soy ahora. Gracias por apoyarme de todas las formas posibles, estar pendiente y luchar a mi lado en todo este recorrido tanto dentro como fuera de lo académico.

A la Universidad José Antonio Páez, siendo la casa de estudio y el lugar donde aprendí y desarrollé habilidades a lo largo de mi estadía, principalmente de la mano de excelentes profesores y sus profundos conocimientos, sin los cuales no sería posible este trabajo de grado, gracias también a los compañeros con los cuales conviví durante todo este proceso, siendo parte importante de mi experiencia en la universidad y brindando apoyo tanto directa como indirectamente en este recorrido académico y la realización de este proyecto.

Con mucho respeto, gratitud y cariño...

Att. Jefferson Johan Méndez Colmenares

DEDICATORIA:

Con la más grade gratitud, dedico este trabajo principalmente a mis padres, por prestarme apoyo de forma incondicional, formarme como persona y estar siempre presentes en mi vida, además de en todo este camino académico y personal, dándome palabras de aliento y soporte para seguir adelante en todo momento, les debo a ellos todos mis logros y la persona que soy ahora, fueron y son la base fundamental en mi vida por lo cual me encontrare en deuda siempre con ellos.

A mi pareja, la cual tomándome de la mano con cariño, amor y ternura me alentaba a seguir adelante, dándome apoyo emocional y estando presente en todo momento en este camino, creyendo en mí y motivándome a dar lo mejor en cada paso que doy tanto en mi vida académica y personal.

De igual modo a los profesores que me acompañaron durante toda la carrera, gracias por el crecimiento profesional que significó este recorrido académico, siendo mis guías en todo momento, impartiendo sus conocimientos con excelencia, brindándome incontables aprendizajes y una formación sólida, bases para un crecimiento profesional y personal permitiéndome cumplir con esta meta.

Este trabajo es dedicado a ustedes, por el gran apoyo que significaron en mi vida tanto académica como personal, siendo parte fundamental del cumplimiento de esta meta, con todo el agradecimiento y admiración del mundo...

Att. Jefferson Johan Méndez Colmenares

ÍNDICE GENERAL

CONTENIDO	PP.
LISTA DE CUADROS.....	IX
LISTA DE FIGURAS.....	X
LISTA DE TABLAS.....	XII
LISTA DE GRÁFICOS.....	XIII
RESUMEN INFORMATIVO.....	XV
INTRODUCCIÓN.....	1
CAPÍTULO	
I EL PROBLEMA	
1.1 Planteamiento del Problema.....	2
1.2 Formulación del Problema.....	6
1.3 Objetivos de la Investigación.....	6
1.3.1 Objetivo General.....	6
1.3.2 Objetivos Específicos.....	6
1.4 Justificación.....	6
1.5 Alcance y Limitaciones.....	7
II MARCO TEÓRICO	
2.1 Antecedentes.....	8
2.2 Bases Teóricas.....	11
2.2.1. Manteamiento en la industria.....	11
2.2.2. Tipos de mantenimiento.....	11
2.2.3. Técnicas de mantenimiento predictivo aplicadas a la industria.....	12
2.2.4. Inteligencia artificial.....	13
2.2.4.1 Redes neuronales artificiales.....	13
2.2.4.2 Neurona artificial.....	14
2.2.4.3 Elementos y características importantes de una red neuronal artificial.....	15
2.2.4.4 Arquitectura de las redes neuronales artificiales.....	19
2.2.5. Tambor rotativo.....	20
2.2.6. Ambiente corrosivo (negro de humo).....	21
2.3 Bases Legales.....	23
2.4 Definición de Términos.....	24
III MARCO METODOLÓGICO	
3.1 Tipo de Investigación.....	26
3.2 Diseño de la Investigación.....	26
3.3 Nivel de la investigación.....	27
3.4. Población y muestra.....	27
3.5. Técnicas e instrumentos de recolección de datos.....	28
3.6. Técnicas de análisis de resultados.....	29

3.7. Fases metodológicas.....	29
3.8. Confiabilidad de la investigación.....	31
IV RESULTADOS	
4.1. Diagnóstico de las condiciones de trabajo del secador de negro de humo y la variabilidad de esta a través del tiempo	32
4.1.1 Definición de las constantes y dimensionado del tambor secador	33
4.1.2 Propiedades del negro de humo y del proceso de secado.....	36
4.2. Análisis de la data mediante modelos matemáticos y procesos de simulación implementando software CAD	38
4.2.1 Flujo de negro de humo en el tambor secador.....	38
4.2.2 Análisis térmico del tambor secador mediante software CAD.	39
4.2.3 Velocidad de transferencia de calor, balances de masa y energía	66
4.2.4 Calculo del tiempo de residencia del negro de humo dentro del tambor.	72
4.2.5 Análisis documental del medio corrosivo, corrosión a altas temperaturas con ambiente contaminado de CO ₂ .	73
4.2.6 Análisis de esfuerzos en el tambor secador mediante software CAD.	78
4.2.7 Criterio de falla (fatiga).....	81
4.3 Definición de los hiperparámetros óptimos en relación a las condiciones de trabajo del tambor, implementando lenguaje de programación Python.	86
4.3.1 Creación del conjunto de datos para el entrenamiento de la red (DataSet)	86
4.3.2 Diseño de la red neuronal y definición de hiperparámetros.....	97
4.4 Comparación las predicciones realizadas por la inteligencia artificial con valores guías para cuantificar su progreso.	103
4.4.1 Selección del mejor modelo de red neuronal entrenado.....	118
4.5 Evaluación de la viabilidad técnica y ambiental, para una posible aplicación en la industria.	119
4.5.1 Viabilidad técnica.....	119
4.5.2 Viabilidad ambiental.....	120
CONCLUSIONES.....	122
RECOMENDACIONES.....	123
REFERENCIAS.....	124
ANEXOS.....	126
APENDICES.....	129

LISTA DE CUADROS

DESCRIPCIÓN

CUADRO		pp.
1	Indicadores, tipos de mantenimiento aplicado en la industria petrolera en al occidente del país.	4
2	Dimensiones del tambor secador de negro de humo.....	33
3	Dimensiones de engranaje conducido del tambor secador.....	35
4	Valores iniciales para las simulaciones térmicas con flujo de aire.....	38
5	Resolución de ecuación del calor trasferido por unidad de masa.....	68
6	Segunda resolución de ecuación del calor trasferido por unidad de masa.	71
7	Variables dependientes e independientes principales en el DataSet.....	85
8	Ejemplo de agrupación de clases de acuerdo al valor de “% de vida transcurrido” en el valor más cercano múltiplo de 5	98
9	hiperparametros utilizados en el entrenamiento del grupo de modelos N°1	104
10	hiperparametros utilizados en el entrenamiento del grupo de modelos N° 2	106
11	hiperparametros utilizados en el entrenamiento del grupo de modelos N° 3	109
12	hiperparametros utilizados en el entrenamiento del grupo de modelos N° 4	112
13	hiperparametros utilizados en el entrenamiento del grupo de modelos N° 5	115

LISTA DE FIGURAS

DESCRIPCIÓN

FIGURA		pp.
1	Tipos de neurona artificial.....	19
2	Modelo genérico de neurona artificial con los elementos que la conforman.	19
3	Principales tipos de función de activación o transferencia.....	21
4	Arquitecturas típicas de RNAs.....	23
5	Esquema de tambor secador rotativo.....	24
6	Modelo 3D del tambor secador hecho en SolidWorks.	34
7	Valores de temperatura en el plano medio del tambor secador en la simulación 1.	40
8	Valores de temperatura en el plano medio del tambor secador en la simulación 2.	41
9	Valores de temperatura en el plano medio del tambor secador en la simulación 3.	42
10	Valores de temperatura en el plano medio del tambor secador en la simulación 4	43
12	Valores de temperatura en el plano medio del tambor secador en la simulación 5	44
13	Valores de temperatura en el plano medio del tambor secador en la simulación 6	45
14	Valores de temperatura en el plano medio del tambor secador en la simulación 7	46
15	Valores de temperatura en el plano medio del tambor secador en la simulación 8	47
16	Valores de temperatura en el plano medio del tambor secador en la simulación 9	48
17	Valores de temperatura en el plano medio del tambor secador en la simulación 10	49
18	Valores de temperatura en el plano medio del tambor secador en la simulación 11	50
19	Valores de temperatura en el plano medio del tambor secador en la simulación 12	51
20	Valores de temperatura en el plano medio del tambor secador en la simulación 13	52
21	Valores de temperatura en el plano medio del tambor secador en la simulación 14	53
22	Valores de temperatura en el plano medio del tambor secador en la simulación 15	54
23	Valores de temperatura en el plano medio del tambor secador en la simulación 16	55
24	Valores de temperatura en el plano medio del tambor secador en la simulación 17	56

25	Valores de temperatura en el plano medio del tambor secador en la simulación 18	57
26	Carta psicrométrica web para la obtención de bulbo húmedo.....	66
27	Diagrama de temperaturas del tambor. (la parte de arriba representa el aire y la de abajo representa el sólido)	70
28	Distribución de masa a lo largo del tambor secador.....	79
29	Simulación, análisis de esfuerzos en el tambor secador sin carga.....	80
30	Relación entre el espacio, tamaño y profundidad ocupado por picaduras.	82
31	Esfuerzos axiales máximos presentes en el tambor secador.....	84
32	Arreglo inicial del set de datos.....	90
33	Segmento de data set del ciclo de vida de un tambor se secador simulado.	97
34	Tiempo de entrenamiento utilizando todos los datos del dataset y 10000 clases.	100
35	Estructura del modelo de red neuronal de clasificación, grupo de modelos N°1.	104
36	Estructura del modelo de red neuronal de clasificación, grupo de modelos N°2.	106
37	Estructura del modelo de red neuronal de clasificación, grupo de modelos N°3.	109
38	Estructura del modelo de red neuronal de clasificación, grupo de modelos N°4.	112
39	Estructura del modelo de red neuronal de clasificación, grupo de modelos N°5.	115

LISTA DE TABLAS

TABLA	DESCRIPCIÓN	pp.
1	Propiedades mecánicas del Acero inoxidable AISI 304.....	33
2	Propiedades físicas del negro de humo.....	37
3	Propiedades del proceso de secado de negro de humo.....	37
4	Valores de la temperatura para 1 k/s de flujo de aire.....	60
5	Valores de la temperatura para 0,5 k/s de flujo de aire.....	62
6	Valores de la temperatura para 1,5 k/s de flujo de aire.....	64
7	Ecuación empírica resultante (Corrosión por CO ₂ a 750°C).....	76
8	Ecuación empírica resultante (Corrosión por CO ₂ a 850°C).....	77

LISTA DE GRÁFICOS

GRÁFICO	DESCRIPCIÓN	pp.
1	Curva de temperatura en relación a la distancia (Simulación 1)	40
2	Curva de temperatura en relación a la distancia (Simulación 2):	41
3	Curva de temperatura en relación a la distancia (Simulación 3):	42
4	Curva de temperatura en relación a la distancia (Simulación 4):	43
5	Curva de temperatura en relación a la distancia (Simulación 5):	44
6	Curva de temperatura en relación a la distancia (Simulación 6):	45
7	Curva de temperatura en relación a la distancia (Simulación 7):	46
8	Curva de temperatura en relación a la distancia (Simulación 8):	47
9	Curva de temperatura en relación a la distancia (Simulación 9):	48
10	Curva de temperatura en relación a la distancia (Simulación 10):	49
11	Curva de temperatura en relación a la distancia (Simulación 11):	50
12	Curva de temperatura en relación a la distancia (Simulación 12):	51
13	Curva de temperatura en relación a la distancia (Simulación 13):	52
14	Curva de temperatura en relación a la distancia (Simulación 14):	53
15	Curva de temperatura en relación a la distancia (Simulación 15):	54
16	Curva de temperatura en relación a la distancia (Simulación 16):	55
17	Curva de temperatura en relación a la distancia (Simulación 17):	56
18	Curva de temperatura en relación a la distancia (Simulación 18):	57
19	Curvas de temperatura vs distancia, con relación a la temperatura inicial, con 0,5 kh/s de flujo de aire constante.	58
20	Curvas de temperatura vs distancia, con relación al flujo de aire inicial, con 1600 °C de temperatura del quemador constante.	59
21	Pérdida de masa debido a corrosión por CO ₂ a 750°C.	76
22	Pérdida de masa debido a corrosión por CO ₂ a 850°C.	77
23	Tensiones de Von Mises a lo largo del tambor secador.	80
24	Comparación de tensiones de Von Mises para diferentes cargas.	81
25	Crecimiento de la grieta desde la superficie.	94
26	Aumento de la profundidad de la picadura.	94
27	Distribución de datos, modelo N° 1, grupo N°1.	105
28	Distribución de datos, modelo N° 2, grupo N°1.	105
29	Distribución de datos, modelo N° 1, grupo N°2.	107
30	Distribución de datos, modelo N° 2, grupo N°2.	107
31	Distribución de datos, modelo N° 3, grupo N°2.	108
32	Distribución de datos, modelo N° 4, grupo N°2.	108
33	Distribución de datos, modelo N° 1, grupo N°3.	110
34	Distribución de datos, modelo N° 2, grupo N°3.	110
35	Distribución de datos, modelo N° 3, grupo N°3.	111
36	Distribución de datos, modelo N° 4, grupo N°3.	111
37	Distribución de datos, modelo N° 1, grupo N°4.	113
38	Distribución de datos, modelo N° 2, grupo N°4.	113
39	Distribución de datos, modelo N° 3, grupo N°4.	114

40	Distribución de datos, modelo N° 4, grupo N°4.	114
41	Distribución de datos, modelo N° 1, grupo N°5.	116
42	Distribución de datos, modelo N° 2, grupo N°5.	116
43	Descenso del gradiente de un punto en una función de error a un mínimo local.	117
44	Descenso del gradiente de un punto en una función de error a un mínimo global.	118
45	Distribución de datos, evaluación N°2, modelo N°2, grupo N°5.	119



**REPÚBLICA BOLIVARIANA DE VENEZUELA
UNIVERSIDAD JOSÉ ANTONIO PÁEZ
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA MECÁNICA**

**PROPUESTA DE DISEÑO DE UN SISTEMA DE PREDICCIÓN DE FALLAS PARA UN
TAMBOR SECADOR DE NEGRO DE HUMO MEDIANTE UNA INTELIGENCIA
ARTIFICIAL.**

Autor: Jefferson Johan Méndez Colmenares C.I.: 28.430.336

Tutor: Ing. Donato Romanello

Fecha: agosto 2023

RESUMEN INFORMATIVO

La presente investigación tiene como finalidad, relacionar el machine learning con el mantenimiento predictivo de modo que pueda ser medible que tan eficientes puede ser estas nuevas tecnologías en la industria, tomando como caso estudio de un procedimiento de secado de negro de humo mediante un tambor secador rotativo, de manera que se pueda predecir con antelación posibles fallas, funcionamientos irregulares en el mismo y sus respectivos orígenes, implementando para ello redes neuronales artificiales que den vida a una inteligencia artificial dedicada al cumplimiento de la tarea de predecir averías. Para esto se implementaron teorías como el machine learning referente a las redes neuronales artificiales, al manteniendo predictivo y el ambiente corrosivo existente en el tambor debido a la presencia de negro de humo, humedad y las altas temperaturas. La investigación desde un punto de vista metodológico se cataloga como, proyecto factible, investigación descriptiva y documental, tomándose como mayor apoyo revisiones bibliográficas referentes al tema. Siguiendo de este modo con la línea de investigación “desarrollo de nuevas tecnologías de la información y comunicación” de la Universidad José Antonio Páez. La investigación concluye en un correcto proceso de entrenamiento de las redes neuronales que conforman a la inteligencia artificial, resultando en predicciones con más de 80% de acierto respecto al tiempo de falla del tambor secador de negro de humo.

Descriptor: Machine learning, Inteligencia artificial, Mantenimiento predictivo, tambor secador rotativo.

INTRODUCCIÓN

En la actualidad la industria en uno de los pináculos de la mejora continua, siempre se está buscando ser más eficiente y gastar menos recursos, esto de forma indirecta se relaciona con poder realizar un trabajo con el menor esfuerzo, menor gasto de energía y un menor porcentaje de error. En el presente una de las formas de poder alcanzar dicho objetivo es la automatización, los trabajo realizados por maquinas inteligentes pre-reprogramadas para cumplir con una acción específica de forma más eficiente, pero, esto no significa que una maquina sea verdaderamente inteligente, por lo cual el futuro de la automatización y la evolución humana, no son las acciones pre-programadas realizadas por maquinas si no una inteligencia real, similar a nuestra, aquí es donde, las inteligencias artificiales se presentan como parte del futuro de la industria y la evolución tecnológica de la humanidad.

Uno de los puntos de interés a nivel en las empresas del ámbito industrial es el constante funcionamiento de forma óptima de las maquinarias y equipos que conforman el apartado de producción, para ello se debe evitar o minimizar lo máximo posible las paradas repentinas. Una forma de poder medir cuándo ocurrirá una falla es tener un monitorio constante de las condiciones o variables de funcionamiento de la máquina, de modo que al analizar patrones se pueda predecir posible existencia de fallas. Por ello en el presente trabajo se busca entonces implementar una inteligencia artificial que en base a las condiciones de funcionamiento de un tambor secador de negro de humo pueda predecir con antelación averías, e identificar la vida útil de la maquinaria. En base a esto se estructura el presente trabajo de la siguiente forma.

Capítulo I: se busca dar visibilidad a la problemática mediante su planteamiento y de acuerdo a la resolución de la problemática, se presentan los objetivos a llevar en el proyecto y las limitantes del mismo

Capítulo II: Sustenta teóricamente el trabajo además de ser las bases para la realización del estudio, definiéndose el contexto que rodea al proyecto y revisándose bibliográficamente tanto antecedentes como teorías útiles para el desarrollo del trabajo.

Capítulo III: Cubre los diversos pasos metodológicos utilizados para formular estrategias diseñadas para lograr los objetivos propuestos.

Capítulo IV: Resultados, se presentan mediante gráficos, tablas y datos, los desenlaces de la investigación y se describe el proceso de obtención de los mismos.

CAPÍTULO I

EL PROBLEMA

1.1 Planteamiento del problema:

El proceso de secado de materiales consta de separar pequeñas cantidades de agua u otro líquido de un sólido con el fin de reducir el contenido de humedad debido al mismo. Este se puede realizar por diferentes métodos, algunos tan sencillos como secadores sopladores con resistencias adaptadas o más complejos como sistemas de secado rotativos. De igual forma una de las variables comunes que se encuentra presente en este tipo de procesos es la temperatura, mediante esta se logra separar los líquidos del material a secar, aumentándose la energía interna en el fluido proporcionándose un cambio de estado. La forma mediante la cual se aplica dicha temperatura hace variar el tipo de proceso, para el interés de la investigación se profundiza en los procesos de secado mediante corriente de aire caliente, específicamente en el sistema de secado mediante tambor rotativo.

El secado mediante tambor secador rotativo se compone como su nombre lo indica, de un cilindro metálico hueco que gira sobre su eje, con una ligera inclinación, para permitir el desliz de los sólidos a secar hacia la boca de salida, este suele estar acompañado de paletas en la superficie interna del mismo permitiendo así una mejor y mayor distribución del material en cuestión para el secado. Se alimentan por la boca de entrada y por la boca de salida se provee de gas caliente, que habrá de secar a contracorriente el sólido que se desliza despacio hacia la salida, a medida este va avanzando. El método de calentamiento es por contacto indirecto a través de la pared del cilindro que se calienta por el paso de los gases y a su vez el contacto directo existente entre los gases y el material a secar. Permittedose así que las partículas atraviesan una sección relativamente corta, a medida que se deslizan, mientras su humedad disminuye a medida que descienden.

Al tratarse de un proceso de secado de negro de humo, el mismo material conforma parte importante del sistema, debido a las altas concentraciones de CO₂ que implican su presencia, esto con la capacidad de atacar corrosivamente el tambor, el cual suele estar hecho de acero, degradándolo gradualmente con el paso del tiempo.

Es por esto que, el proceso de secado de negro de humo mediante un tambor secador consta de múltiples variables presentes en su funcionamiento, tiene intrínseca en si magnitudes como; un flujo de aire caliente, niveles alterados de oxígeno, tensiones debido a los apoyos y

sistemas de transmisión de potencia, deformaciones debido a la temperatura, un ángulo de inclinación, flujo másico de material a secar (negro de humo) y un ambiente corrosivo. Por ende, es un buen candidato a presentar fallas y se vuelve una tarea complicada el mantener bajo control dichas variables. Significando esto una dificultad a la hora de predecir cuándo el tambor está en correcto tiempo de ser cambiado (antes de que falle, pero después de ser aprovechado al máximo).

Por ende, la problemática radica en la dificultad para predecir fallas y averías en el proceso de secado de negro de humo, esto trae consigo inconvenientes relacionados con paradas no planificadas en la maquinaria o el desaprovechamiento de las piezas debido a una mala estimación de la vida útil de las mismas, significando pérdidas monetarias tanto de forma directa como indirecta para la industria dedicada al secado de negro de humo mediante corriente de aire caliente.

Al hacerse referencia a la predicción de fallas en maquinarias y equipos industriales, se encuentra relación directa con las técnicas de mantenimiento que permitan el monitoreo de las mismas para predecir y evitar paradas o fallas que puedan afectar todo el proceso productivo. Es por esto que, el mantenimiento es una de las actividades fundamentales para el correcto funcionamiento de la industria, permitiendo así que las maquinarias y equipos funcionen de forma óptima, de modo que repercute directamente en el proceso productivo. El no tener un correcto mantenimiento de las maquinarias y equipos puede llevar a paradas no planificadas y averías, significando pérdidas monetarias importantes a la empresa tanto por el remplazo de piezas dañadas por fallas repentinas, como en el tiempo productivo perdido de las máquinas. Existen diferentes técnicas de mantenimiento entre las cuales resaltan el mantenimiento; correctivo, preventivo y predictivo.

Al céntranos en este último tipo de mantenimiento y de acuerdo con, Olarte et al. (2010) Se define el mantenimiento predictivo como el monitoreo de un conjunto de variables mediante ensayos no destructivos de modo que se realiza un seguimiento constante de las máquinas y equipos, de forma que se pueda detectar con antelación un funcionamiento irregular y prever la ocurrencia de fallas, permitiendo así la programación y planificación de paradas y reparaciones sin afectar el proceso productivo.

Este método es el más cercano a un mantenimiento ideal, no obstante, también es un tipo de mantenimiento un poco más técnico, avanzado y costoso, requiriendo de equipos especializados y personal formado con técnicas de análisis y detección de múltiples variables que

den indicios para anteponerse a una falla, de modo que se pueda planificar la forma más óptima de abordarla.

Aunque la implementación de un correcto mantenimiento predictivo disminuye en la industria del secado de negro de humo las paradas no planificadas, no hay garantía de que todas las fallas puedan ser descubiertas antes de que ocurran, debido a inconvenientes varios, entre ellos, el proceso de análisis de los datos tomados por las herramientas que miden constantemente las condiciones de trabajo del tambor, significando en errores que concluyen en predicciones equivocadas, imprecisas o incluso en averías no percibidas.

En Venezuela. En el apartado del mantenimiento es común el manejo de técnicas como el mantenimiento correctivo, preventivo, he incluso predictivo de forma clásica. Tomando como ejemplo el mantenimiento realizado en la industria petrolera del occidente del país, ver Variables dependientes 1, se puede tener una idea de la forma en la cual se aplican o realizan mantenimiento a maquinarias y a equipos en la región.

Cuadro 1: Indicadores, tipos de mantenimiento aplicado en la industria petrolera en al occidente del país.

INDICADOR	Nº	ÍTEMS	\bar{x}	CATEGORÍA
Correctivo	1	Las acciones de mantenimiento se ejecutan luego de ocurrida la falla del equipo.	2,71	Moderada aplicación/Leve fortaleza
	2	Luego de una falla, se realiza un diagnóstico para definir la causa raíz de la misma.	2,04	Baja aplicación/Debilidad
	3	Las fallas se controlan para evitar se afecte la seguridad del ambiente	2,64	Moderada aplicación/Leve fortaleza
		Promedio indicador	2,46	Baja aplicación/Debilidad
Preventivo	4	Los mantenedores realizan inspecciones periódicas a los equipos	1,68	Muy baja aplicación/Debilidad
	5	Realizan reemplazos de piezas a intervalos de tiempo fijos en los equipos	2,64	Moderada aplicación/Leve fortaleza
	6	Aplican técnicas para monitorear la condición de funcionalidad de los equipos	2,43	Baja aplicación/Debilidad

Continuación, cuadro 1: Indicadores, tipos de mantenimiento aplicado en la industria petrolera en al occidente del país.

INDICADOR	N°	ÍTEMS	\bar{x}	CATEGORÍA
Preventivo		Promedio indicador	2,25	Baja aplicación/Debilidad
Predictivo	7	Al ejecutar acciones de mantenimiento a los equipos, se interrumpe el normal funcionamiento en las unidades de medición	3,11	Moderada aplicación/Leve fortaleza
	8	Las actividades de mantenimiento incluyen análisis termo-gráfico de los componentes asociados	3,36	Moderada aplicación/Leve fortaleza
	9	Las actividades de mantenimiento ejecutadas incluyen análisis de corrosión a los componentes asociados.	3,00	Moderada aplicación/Leve fortaleza
		Promedio indicador	3,15	Moderada aplicación/Leve fortaleza
Proactivo	10	Realizan actividades de mantenimiento que permitan incrementar la vida útil de los equipos mediante un control de la falla.	2,36	Baja aplicación/Debilidad
	11	Establecen un control para cada una de las maquinas que requiere mantenimiento	2,21	Baja aplicación/Debilidad
	12	Fortalecen los procesos mediante análisis de modos de fallas	2,57	Baja aplicación/Debilidad
		Promedio indicador	2,38	Baja aplicación/Debilidad

Nota. Los indicadores se separan en Categorías, 4,21-5,00 muy alta aplicación, 3,41-4,20 alta aplicación, 2,61-3,40 moderada aplicación, 1,81-2,60 baja aplicación, 1,00-1,80 muy baja aplicación.

Fuente. Adaptado de *Tipos de mantenimiento aplicados en la industria petrolera venezolana de la Región Occidente* (p. 139-140), por R. Paredes, 2020, Revista Ingeniería, 4 (9).

Al observarse los datos es notable que por más que se apliquen cierto tipo de mantenimientos como el predictivo, todos presentan signos de oportunidad de mejora, esto no es muy diferente al resto de la industria en Venezuela en donde se aplican más que todo mantenimiento de tipo preventivo en base a lo indicado por los fabricantes de las piezas o por análisis realizados por las mismas empresas en base a los datos brindado en anteriores fallas y la observación directa, esto no siempre acierta al predecirse averías, significando la aparición de paradas no planificadas que llevan a mayor tiempo implementado en reparaciones o la sustitución

de piezas con vida útil aprovechable. Esto representa que en la industria venezolana existe gran campo para mejorar los métodos de mantenimiento aplicados.

1.1.2 Formulación del problema:

¿Cómo se puede predecir las fallas en los sistemas de secado de negro de humo que permitan minimizar las paradas no planificadas?

1.2 Objetivos de la investigación:

1.2.1 Objetivo general:

Propuesta de diseño de un sistema para predecir fallas en un tambor secador de negro de humo implementando inteligencias artificiales.

1.2.2 Objetivos específicos:

- Diagnosticar las condiciones de trabajo del secador de negro de humo y la variabilidad de esta a través del tiempo.
- Analizar la data mediante modelados matemáticos y procesos de simulación implementando software CAD.
- Definir los hiperparámetros óptimos en relación a las condiciones de trabajo del tambor, implementando lenguaje de programación Python.
- Comparar las predicciones realizadas por la inteligencia artificial con valores guías para cuantificar su progreso.
- Estudiar la viabilidad técnica y ambiental, para una posible aplicación en la industria.

1.3 Justificación de la investigación:

La implementación de las inteligencias artificiales en un ámbito industrial es en si algo novedoso, mediante el machine learning se puede beneficiar la mayoría de procesos productivos, ya que puede ser una versión avanzada de automatización de procesos, en la cuales las máquinas no solo realizar tareas pre-programadas, si no que pueden reconocer patrones y predecir comportamientos.

La investigación consta de relacionar las fallas concurridas en un tambor secador rotativo en el proceso de secado de negro de humo con el machine learning y la inteligencia artificial, de forma que las fallas se puedan predecir de modo certero, sabiéndose cuando y como ocurrirá una avería. Por lo cual propone de forma indirecta un modelo de mantenimiento predictivo cercano a uno ideal, este atractivo es algo que puede beneficiar a diferentes empresas que trabajen no solo con el secado de negro de humo si no también cualquier tipo de proceso de secado semejante,

debido a que los resultados de la investigación pueden ser extrapolados aumentando el campo de aplicación de la propuesta, explotándose así el uso de estas nuevas tecnologías incluso en ámbitos variados. De forma directa esto beneficiaría a las empresas que lo aplique y de forma indirecta beneficiaría a los consumidores de los productos que se generen.

Asimismo, significaría un avance para la región respecto al nivel tecnológico, en el cual la aplicación del mantenimiento de maquinarias puede ser en su mayoría predictivo, significando en un control más sólido sobre los parámetros de los equipos y el mantenimiento de los mismos, resultando en menores cantidades de paradas no planificadas y por ende en menores pérdidas monetarias debido al mantenimiento.

Además, este estudio cuenta con un gran valor teórico puesto que permite cuantificar los posibles beneficios de implementar inteligencias artificiales en la industria, tomando como caso estudio la predicción de fallas en un tambor secado de negro de humo implementado herramientas de ingeniería para su ejecución.

1.4 Alcance y limitaciones:

El proyecto está delimitado a la propuesta de diseño del sistema de predicción mediante inteligencia artificial y a la medición de la eficiencia de la misma respecto a una posible aplicación. Además, está limitado al estudio de la misma al proceso de secado a un tambor secador rotativo de negro de humo implementándose para ellos procesos de simulación.

Entre las limitaciones resalta el elevado consumo de capacidad de procesamiento de equipos computacionales, la falta de investigaciones previas que relacionen los procesos de secado con las inteligencias artificiales, el tiempo límite de dos semestres para la finalización del proyecto.

CAPÍTULO II

MARCO TEÓRICO

En concordancia con Arias. F, “El marco teórico o marco referencial, es el producto de la revisión documental-bibliográfica, y consiste en una recopilación de ideas, posturas de autores, conceptos y definiciones, que sirven de base a la investigación por realizar.” (2012, pág. 106)

Debido a esto, en este apartado se busca dar sustento teórico a la investigación, siendo una base para los cumplimientos de los objetivos, implementándose para ello una revisión bibliográfica que marque los pilares de la investigación. Adicionalmente se incluyen los trabajos previos realizados similares, los cuales aportan datos importantes referentes a la aplicación de redes neuronales, machine learning e inteligencias artificiales.

2.1 Antecedentes de la investigación:

Tume M. (2022), en su trabajo de grado titulado **“Estado del arte de la inteligencia artificial y su aplicación en el mantenimiento”** para obtener el título de Ingeniero Mecánico-Eléctrico en la Universidad de Piura, Perú. Esta investigación tiene la finalidad de demostrar y relevar la importancia de la inteligencia artificial aplicada a un ámbito industrial y reducir mediante esta tecnología intervenciones debido a fallas en equipos, relacionando así el machine learning con los sistemas de mantenimiento predictivo. Implementando como data información de una simulación de la degradación de un turbo ventilador obtenido de un repositorio de la NASA con el objeto de “investigar sobre el diagnóstico y pronóstico multimedia real que interpretan los diversos datos adquiridos por una red de sensores distribuidos y utilizar los flujos de datos para tomar decisiones críticas, lo cual permite proporcionar avances significativos en una amplia gama de aplicaciones.” (Tume M. 2022, p.57).

Esta investigación se corresponde directamente con el presente trabajo, puesto que relaciona de forma continua las aplicaciones de inteligencias artificiales con la industria, principalmente en la mejora de la técnica de mantenimiento predictivo, he implementa datos simulados de deterioro en una maquinaria para poder así predecir fallas en el mismo. Guardando de esta forma amplias similitudes con el actual proyecto.

Igualmente, De los ríos Tomalá G. (2019), en su trabajo de grado titulado **“Mantenimiento predictivo para la supervisión de motores eléctricos aplicando técnicas de inteligencia artificial”** para obtener el título de ingeniero electrónico en control y automatismo, en la Universidad Católica de Santiago de Guayaquil, Ecuador. Esta investigación se basó en la

implementación de redes neuronales artificiales para el análisis de múltiples variables provenientes de la variación de la velocidad de giro y múltiples sensores que brindaban data constante que permitían conocer el estado del motor y así determinar el momento óptimo en el cual se le podía realizar mantenimiento.

Esta investigación aporta un caso práctico en el cual se implementa el machine learning, para la predicción de fallas en una maquina rotativa, siendo en este caso un motor de inducción, utilizándose para ello redes neuronales artificiales y un conjunto de sensores de modo que la data fuera analizada por la inteligencia artificial a tiempo real en un prototipo, de esta forma guardando relación con la presente investigación al ser un ejemplo de aplicación de inteligencias artificiales en el análisis de datos de un mantenimiento predictivo.

Así mismo, Villegas A. (2019), en su trabajo de grado titulado **“desarrollo de un sistema de análisis automático para la segmentación, clasificación y conteo de leucocitos en imágenes digitales de frotis de sangre periférica”** para optar al grado de Magister en Ingeniería Eléctrica, en la Universidad de Carabobo. En esta investigación se implementan un modelo de redes neuronales artificiales convolucionales profundas las cuales simulan las neuronas de la corteza visual primaria de un cerebro biológico, esto permitiendo el reconocimiento de patrones en imágenes, en este caso implementado para identificar y contar leucocitos en sangre, aun puede ser una aplicación de inteligencia artificial extrapolable fuera del ámbito medico en donde parte de los datos a analizar sean fotografías.

Esta aplicación del machine learning se puede relacionar con el mantenimiento predictivo, en caso que la información con la cual se trabaje sean imágenes, pudiéndose detectar en máquinas por ejemplo, variaciones de temperatura al implementarse cámaras térmicas, detección de irregularidades en un material o pieza mediante el análisis de radiografías o incluso la predicción de fallas mediante el análisis de fotografías realizadas a un equipo, como puede ser el analizar el aumento de las picaduras generadas en el tambor secador debido al ambiente corrosivo a través del tiempo.

De mismo modo, Terán R. (2019), en su trabajo de grado titulado **“comparación de los métodos emergentes utilizados en el análisis espectral de corriente estática para determinar las condiciones de cojinetes en motores de inducción”** para obtener el título de Magister en Ingeniería Eléctrica, en la Universidad de Carabobo. En este estudio se comparan diferentes métodos emergentes para el análisis de las condiciones de los cojinetes de un motor de

inducción, esto debido a que las fallas que puedan presentar los cojinetes hacen variar la corriente de armadura del motor, siendo esta la variable que se analizó y sirvió de dato para aplicar como método de detección de falla, el análisis lineal discriminante, las máquinas de vectores soporte y las redes neuronales artificiales. Como conclusión Terán R. Obtuvo que no solo era posible identificar que existía una falla en el cojinete debido a la variación de corriente de armadura del motor si no que puedo identificar qué tipo falla ocurría en el cojinete mediante el análisis de la corriente como dato y su perturbación en el dominio del tiempo o en espectro de la frecuencia.

Esta investigación aporta la idea de que cualquier dato que pueda tener relación directa o indirecta con la falla de una pieza, puede generar patrones analizables por métodos diferentes los cuales tienen la posibilidad de predecir o diagnosticar la falla, entre estos métodos las redes neuronales artificiales, que nuevamente resultan ser un apartado con atractivo a la aplicación en el ámbito industrial en el área de mantenimiento predictivo de maquinarias y equipos de cualquier tipo.

Por último, Gonzales W. (2018), en su trabajo de grado titulado **“Redes Neuronales Binarizadas entrenadas mediante Aprendizaje Estructural Adaptativo (Estudio experimental)”** para obtener el título de licenciado en computación, en la Universidad Central de Venezuela. Esta investigación comparara diferentes modelos de redes neuronales profundas (AdaNet y AdaBnn) implementando ambas aprendizaje estructural adaptativo con la finalidad de evaluar el desempeño de los diferentes modelos en la tarea de clasificación binaria y multi-clase de imágenes.

La clasificación de imágenes también es una herramienta importante para la cual se puede hacer uso de inteligencias artificiales, en si los modelos de clasificación sea de imágenes u otro tipo de datos ayudan a distinguir diferentes grupos de variables, al extrapolar esta aplicación los métodos de clasificación mediante redes neuronales se pueden hacer referencia a la implementación de modelos de clasificación para no solo la predicción de fallas en maquinarias si no la detección y clasificación de los tipos de problemáticas que las mismas puedan estar presentado en el momento, significando así el poder definir el origen de las averías.

Al implementarse redes neuronales, machine learning, depp learning, en estas investigaciones antecedentes, ya de forma directa o indirecta existe relación con el presente trabajo puesto que se desea conocer la factibilidad de una posible aplicación industrial en el área de predicción de fallas en un tambor secador de negro de humo, para ellos tanto las herramientas

de clasificación como de análisis de datos mediante la aplicación de estas tecnologías son un antecedente a la presente investigación y aportan información relevante en este ámbito, de forma variada.

2.2 Bases teóricas:

2.2.1 Mantenimiento industrial:

El mantenimiento es un campo de la ingeniería con gran importancia presente en el ámbito industrial de acuerdo con Olarte et al. Podemos definir mantenimiento como “el conjunto de actividades encaminadas a garantizar el correcto funcionamiento de las máquinas e instalaciones que conforman un proceso de producción permitiendo que éste alcance su máximo rendimiento” (2010, pág. 355). Por lo cual, para un correcto funcionamiento de las maquinarias y equipos presentes en un proceso productivo, el mantenimiento no puede ser un ámbito descuidado.

2.2.2 Tipos de mantenimiento:

La forma en la cual se clasifican los tipos de mantenimiento es variada y depende del punto de vista de aplicación de los mismos, aun así, acorde con De Leon F. (1998), se puede definir de forma tradicional en base a un enfoque más metodológico los siguientes tipos de mantenimiento:

- **Mantenimiento correctivo:** este es un tipo de mantenimiento simple que solo hace presencia posterior al momento en el cual ocurre la falla en los equipos, por lo cual también se le conoce como mantenimiento a rotura, por ende, es un tipo de mantenimiento en el cual no se toma control sobre el estado de la maquina hasta que ocurre la avería.
- **Mantenimiento preventivo:** es un tipo de técnica de mantenimiento que como su nombre lo indica busca prevenir la fallas, de modo que siempre se tengan los equipos y maquinarias a disposición cuando se necesiten, esto se logra mediante revisiones periódicas de las maquinarias mediante desmontaje total o parcial de la mismas y cambiar elementos o piezas, tanto los que resulten oportunos a simple vista como los que requieran de un cambio sistemático determinado por su tiempo de funcionamiento.
- **Mantenimiento predictivo:**

La idea básica de esta filosofía de mantenimiento parte del conocimiento del estado de los equipos. De esta manera es posible, por un lado, reemplazar los elementos cuando realmente no se encuentren en buenas condiciones operativas, suprimiendo las paradas por inspección innecesarias y, por otro lado, evitar las averías imprevistas, mediante la detección de cualquier anomalía funcional y el seguimiento de su posible evolución. (De Leon F. 1998, Pág. 28).

Es de entender que el mantenimiento predictivo busca realizar la labor de mantenimiento en el momento óptimo a ser implementado, para esto se necesitan una constante vigilancia de los parámetros de funcionamiento de los equipos, la mayoría de las máquinas y componentes de máquinas exteriorizan su estado antes de fallar, por ende, entender esta condición del equipo mediante la variación de los parámetros de funcionamiento es fundamental para predecir la avería.

2.2.3 Técnicas de mantenimiento predictivo implementadas en la industria:

Cuando se habla de técnicas de mantenimiento predictivo se hace referencia a los diferentes métodos mediante los cuales se pueden medir los datos de las condiciones de trabajo de los equipos o maquinarias y en dado caso los métodos de análisis de los datos obtenidos por las mediciones y comparación con los parámetros de funcionamiento ideales para la predicción de fallas. Entre estos métodos encontramos de acuerdo con Olarte et al (2010):

- **Análisis de vibraciones:** esta técnica se basa en el monitoreo de máquinas rotativas a través de las variaciones de sus vibraciones, estas se alteran cuando algo funciona de forma irregular, lo cual puede ser indicador de que hay necesidad de hacer una revisión en el equipo.
- **Termografías:** es una técnica que estudia la temperatura de las máquinas y su variación, transformando la radiación resultante del calor emitido en luz visible, permitiendo poder realizar un análisis en base a esa información de forma visual.
- **Análisis por ultra sonido:** se basa en el estudio de maquinarias y equipos mediante el análisis de las ondas de sonido de alta frecuencia (más de 20 kHz), estas ondas tienen dos aplicaciones, el poder transformar los ultras sonidos generados por las máquinas en sonido audible, permitiendo localizar el origen de una falla y la implementación de estas ondas para atravesar el material y analizarlo volumétricamente encontrándose grietas o hendiduras internas.
- **Análisis de aceite:** se analiza el estado de las máquinas mediante el estado físico y químico del aceite lubricante, puesto que este protege del desgaste, controla la temperatura y elimina impurezas, este análisis se realiza puesto que cuando el aceite se encuentra contaminado o degradado las máquinas tienden a fallar.

A dichas técnicas se pueden agregar en concordancia con Fernández F. (2005) los métodos de medición predictivos para el análisis de la corrosión en la industria.

En la industria existen diferentes medios corrosivos, no solo la corrosión general generada por la atmósfera, están presentes fenómenos corrosivos como son, la corrosión galvánica ocurrida

entre dos metales de naturaleza diferente unidos a través de una solución acuosa que actúa como electrolito, también existe la corrosión por aireación diferencial común en zonas de pobre oxígeno, la corrosión por tensiones superficiales y las corrosiones químicas o incluso corrosión bacteriana, todos estos diferentes tipos de ambientes corrosivos pueden provocar fallas en máquinas y equipos. Los métodos que generalmente se implementan para dichas mediciones son los mencionados a continuación en los ensayos no destructivos.

Ensayos no destructivos: los mismos métodos implementados para la detección de grietas y porosidades son implementados para el estudio de la propagación de corrosión en metales, para ello se implementan ensayos superficiales (inspección visual, líquidos penetrantes, partículas magnéticas).

- Inspección visual: es la observación visual directa o indirecta por parte de un experto, basándose en la experiencia del profesional que está realizando la inspección.
- Líquidos penetrantes: es la implementación de líquidos pulverizados con un agente reactivo que se incorporan en posibles grietas o hendiduras difíciles de ver a simple vista por su reducido tamaño, para una posterior revelación con un agente químico.
- Partículas magnéticas: se basa en la pulverización de un líquido portante que incorpora en suspensión partículas férricas, este se adiciona a la superficie, la cual es posteriormente es magnetizada, en caso de existir irregularidades estas pueden ser medidas por las variaciones en las líneas de campo, ubicándose una concentración de partículas férricas en el defecto superficial.

2.2.4 Inteligencia artificial:

2.2.4.1 Redes neuronales artificiales:

López R. y Fernández J. definen las redes neuronales artificiales como:

Las Redes Neuronales Artificiales (RNAs) son modelos computacionales que surgieron como un intento de conseguir formalizaciones matemáticas acerca de la estructura del cerebro. Las RNAs imitan la estructura hardware del sistema nervioso, centrándose en el funcionamiento del cerebro humano, basado en el aprendizaje a través de la experiencia, con la consiguiente extracción de conocimiento a partir de la misma.

El fin último perseguido por una RNA es la emulación del sistema nervioso central biológico a través de procesadores artificiales, que incluso permitan evitar los fallos o errores humanos. Así, una RNA puede considerarse un modelo matemático de las teóricas actividades mentales y cerebrales, basado en la explotación del procesamiento local en paralelo y las propiedades de la representación distribuida. (López, Fernández, 2008, pág. 16).

Debido a que las redes neuronales artificiales son una simulación matemática de los procesos cognitivos del cerebro humano, se puede comprender las RNAs como una inteligencia artificial, de modo que al igual que el cerebro humano puede reaccionar ante estímulos del exterior, procesar la información y dar una respuesta en relación a dicho estímulo, en las redes neuronales artificiales dichos estímulos se comportan como los datos de entrada y las respuestas los datos de salida de la red. De forma idéntica al funcionamiento del aprendizaje del humano, las redes neuronales también aprenden mediante un proceso de retroalimentación al comparar las respuestas producidas a partir de los datos analizados con las respuestas reales, disminuyendo así su error de precisión hasta el punto de poder acertar con los datos reales y alcanzar errores de precisión que tienden a cero.

Las inteligencias artificiales se pueden relacionar directamente con el mantenimiento predictivo, debido a que las variables de entrada de datos para el análisis de información en las redes neuronales perfectamente pueden ser las variables de funcionamiento medidas por las técnicas de mantenimiento predictivo aplicadas en la industria, así esta información puede ser procesada por una red neuronal y obtener un resultado relacionado a la predicción de una falla.

2.2.4.2 Neurona artificial:

Las neuronas artificiales son la unidad mínima de procesamiento de la red, estas por si solas no pueden realizar operaciones muy complejas, pero en conjunto las capacidades de procesamiento aumentan exponencialmente, los estímulos del exterior (datos de entrada) son analizados por neuronas artificiales, estas arrojan resultados que son a su vez analizados por más neuronas intermedias y al final la última capa de neuronas arrojan un resultado en relación al estímulo inicial, López R. y Fernández J. Clasifica estas neuronas en tres tipos:

- Las neuronas de entrada reciben señales desde el entorno, provenientes de sensores o de otros sectores del sistema (como archivos de almacenamiento de patrones de aprendizaje).
- Las neuronas de salida envían su señal directamente fuera del sistema una vez finalizado el tratamiento de la información (salidas de la red).
- Las neuronas ocultas reciben estímulos y emiten salidas dentro del sistema, sin mantener contacto alguno con el exterior. En ellas se lleva a cabo el procesamiento básico de la información, estableciendo la representación interna de ésta. (López, Fernández, 2008, Pág. 21). Esta estructura se puede visualizar en la figura 1.




Figura 1: tipos de neurona artificial

Fuente: Extraído de *Las redes neuronales artificiales* (P.21), López, R. F., & Fernández, J. M. F. (2008).

2.2.4.3 Elementos y características importantes de una red neuronal artificial:

Con las neuronas artificiales se trata de imitar las características más relevantes de las neuronas biológicas, por ende, los elementos los elementos que conforman cada neurona artificial de forma básica son, ver figura 2:

- Un valor o estado de activación inicial (a_{t-1}).
- Uno estímulos o entradas a la neurona (x_i).
- Una función de propagación (Net_i).
- Una función de activación o transferencia (f).
- Una función de salida (F).
- Una señal de salida (y_i).
- Una regla de aprendizaje.

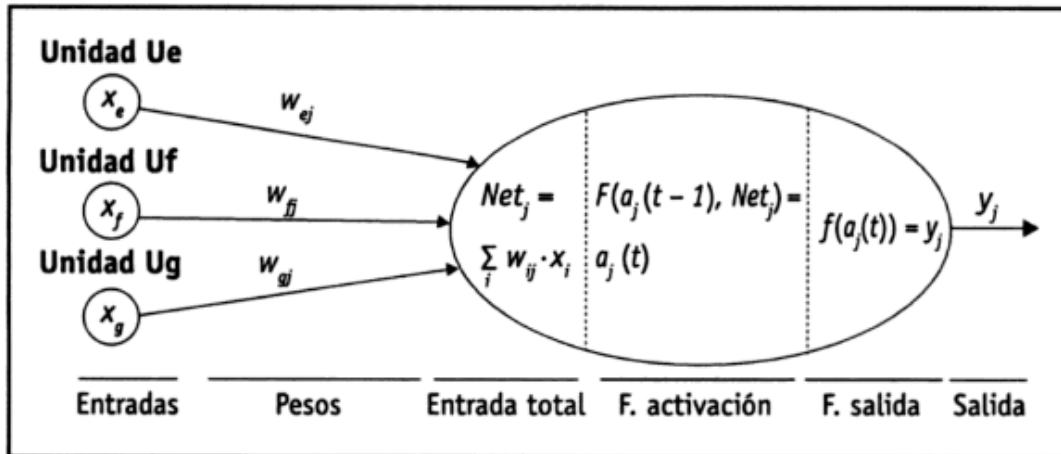


Figura 2: modelo genérico de neurona artificial con los elementos que la conforman.

Fuente: Extraído de *Las redes neuronales artificiales* (P.21), López, R. F., & Fernández, J. M. F. (2008).

- a) Valor o estado de activación inicial: hace referencia al estado inicial, de reposos o excitación de todas las neuronas de la red, estos dependen de un valor de activación, este valor puede ser continuo ($[0,1]$ o $[-1,1]$) o discreto ($\{0,1\}$, $\{-1,1\}$), limitado o ilimitado según la entrada total recibida y el umbral de la propia neurona. Ejemplo:

$$A(t) = [a_1(t), \dots, a_i(t), \dots, a_n(t)]$$

Siendo esta la función de activación de todas las neuronas de la red, tomando como $a_i(t)$ la activación de la i -enésima unidad respecto al tiempo.

- b) Estimulo de entrada de la neurona: son las variables procedentes del exterior que se presentan a las neuronas de entrada, estas variables pueden tener una naturaleza binaria o continúa. Las neuronas de capas superiores a las de entrada, reciben como entrada de información la salida de la primera capa, esta información también puede ser binaria o continua, y están acompañadas pesos (valor numérico multiplicado a la salida de una neurona w_j) que indican su valor relativo.
- c) Función de propagación: esta función es la regla que establece los parámetros a seguir para relacionar la entrada de una unidad y los pesos de las conexiones que llegan a esa unidad, por ende, los pesos w_j afectan la relación de la neurona emisora (a_i) con la neurona receptora (a_j). Esta relación se efectúa dependiendo de si el valor del peso es: positivo, negativo o neutro.

- $w_g +$: la interacción entre a_i y a_j es excitadora, a_j recibe una señal de a_i que tendera a activarla.
- $w_g -$: la interacción entre a_i y a_j es inhibidora, a_j recibe una señal de a_i que tendera a desactivarla.
- $w_g = 0$: no hay conexión entre neuronas.

Entendiendo esto, la función de propagación permite la obtener a partir de las entradas y los pesos recibidos el valor del potencial postsináptico (Net_i) para un momento t. La función más habitual es de tipo lineal y se basa en la suma ponderada de las entradas con los pesos sinápticos asociados a ellas:

$$Net_i(t) = \sum_i w_{ij} \cdot x_i(t)$$

También se puede expresar como el producto escalar de los vectores de entrada y el vector traspuesto de pesos de la red:

$$Net_i(t) = \sum_i w_{ij} \cdot x_i(t) = w_j^T \cdot x_i$$

- d) Función de activación o transferencia: esta función combina la entrada total a la j-ésima neurona o potencia postsináptico (Net_i), siendo la función que modifica la señal de salida de la neurona o establece un parámetro para se debe sobrepasar para poder proseguir a otra neurona, por ende, estas funciones son la manera de transmitir la información por las conexiones de salida, esta función toma una forma de $a_j = f(Net_j(t))$, las funciones de activación más comunes se pueden ver en la figura 3.

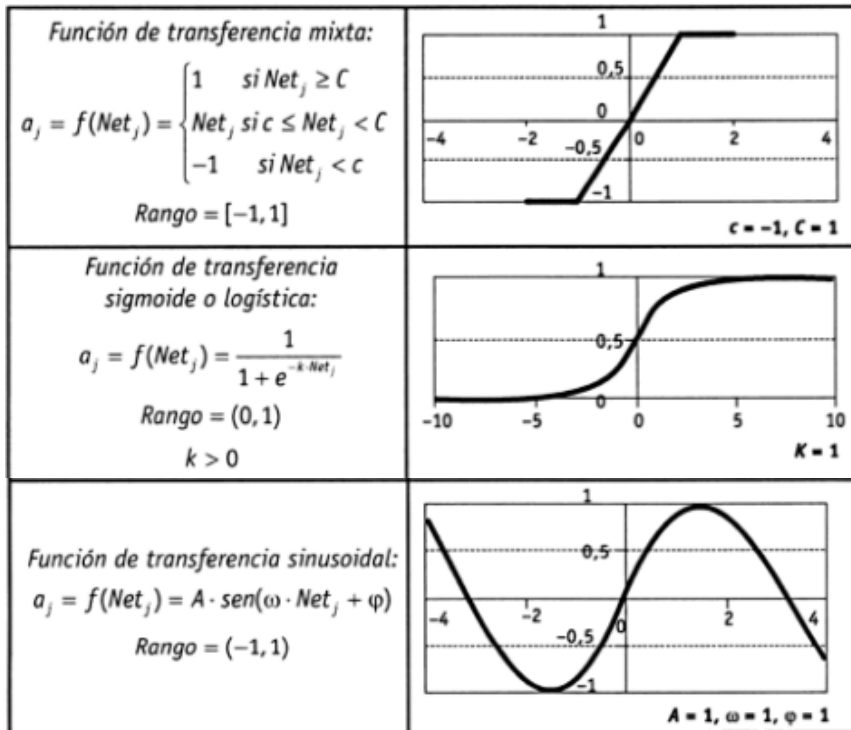


Figura 3: Principales tipos de función de activación o transferencia.

Fuente: Extraído de *Las redes neuronales artificiales* (P.21), López, R. F., & Fernández, J. M. F. (2008).

- e) Función de salida: La función de salida (F) trasforma el estado actual de activación $a_j = f(Net_j(t))$, en una señal de salida $y_j(t)$, siendo:

$$f) \quad y_j(t) = F(a_j) = F\left(f(Net_j(t))\right)$$

El vector que contiene las salidas de todas las neuronas en un instante t se expresa como:

$$\begin{aligned} Y(t) &= F(a_1(t), a_2(t), \dots, a_j(t), a_n(t)) \\ &= F\left(f(Net_1(t)), f(Net_2(t)), \dots, f(Net_j(t)), f(Net_n(t))\right) \end{aligned}$$

Esta función de salida generalmente coincide con la función identidad $F(x) = x$, por lo que el estado de activación de la neurona se considera su estado final: $y_j(t) = F(a_j(t)) =$

$$f(Net_j(t)) = f\left[\sum_{i=0}^N w_{ij}(t) \cdot x_i(t)\right]$$

- g) Señal de salida: es por último el dato resultado de la red neuronal, siendo estos o binarios o continuos, dependiendo del tipo de resultado requerido se determinará la función de transferencia y salida que debe implementarse en la última capa de neuronas.

2.2.4.4 Arquitectura de las redes neuronales artificiales:

Como su nombre lo indican las redes neuronales artificiales con un conjunto ordenado de neuronas artificiales las cuales constan con diferentes parámetros y modelos de ordenamiento, aun así, por lo general se organizan en capas y su arquitectura como indican López R. y Fernández J. (2008) está conformada por:

- El número de capas del sistema.
- El número de neuronas por capa.
- el grado de conectividad entre las neuronas.
- el tipo de conexiones neuronales.

Además de poderse clasificar el tipo de red según su estructura en capas, y según el flujo de datos de la red, ver figura 4.

a) Según sus estructuras de capas:

- Redes mono capa, compuestas por una única capa de neuronas, entre las que se establecen conexiones laterales y, en ocasiones, auto recurrente.
- Redes multicapa, son cuyas neuronas se organizan en varias capas (de entrada, oculta(s) y de salida). La capa a la que pertenece la neurona puede distinguirse mediante la observación del origen de las señales que recibe y el destino de la señal que genera.

b) Según el flujo de datos de la red:

- Redes unidireccionales o de propagación hacia adelante, son en las que ninguna salida neuronal es entrada de unidades de la misma capa o de capas precedentes. La información circula en un único sentido, desde las neuronas de entrada hacia las neuronas de salida de la red.
- Redes de propagación hacia atrás, son en las que las salidas de las neuronas pueden servir de entradas a unidades del mismo nivel (conexiones laterales) o de niveles previos. Las redes de propagación hacia atrás que presentan lazos cerrados se denominan sistemas recurrentes.




Figura 4: Arquitecturas típicas de RNAs.

Nota. a) Conexión hacia adelante, b) conexión hacia atrás, c) conexiones laterales, d) conexiones auto recurrentes.

Fuente. Adaptado de *Las redes neuronales artificiales* (P.21), López, R. F., & Fernández, J. M. F. (2008).

2.2.5 Tambor rotativo:

Un tambor secador rotativo es una maquinaria bien definida por su nombre, es un tambor implementado para el secado de material húmedo mediante un flujo de aire caliente generado por un quemador en contra flujo respecto al movimiento del material a secar, con la finalidad de evaporar las partículas de agua presentes en el material en cuestión, este moviliza el material mediante la rotación empujándolo con unas aletas que contiene en su superficie interior a medida que la gravedad genera una fuerza en sentido del flujo másico debido a que generalmente se encuentra con una pendiente de inclinación. Son implementados para el secado de casi cualquier tipo de material granulado o similar, como biomasas, lodos y en el caso de esta investigación, negro de humo. En la siguiente figura se puede observar un esquema de un tambor secador rotativo, ver figura 5.




Figura 5: Esquema de tambor secador rotativo.

Fuente. Extraído de *Rotary Dryer Design & Working Principle* [imagen], 991 Metallurgist.

2.2.6 Ambiente corrosivo (Negro de humo):


El dióxido de carbono es formado cuándo se quema cualquier sustancia con contenido en carbono, en relación a esto el negro de humo en si es un pigmento conformado en su mayoría de carbono resultado de la combustión incompleta de materiales, como aceites, grasas, brea, hulla, maderas resinosas, plantas o gas, todos ellos con contenido en carbono pero debido a que la combustión fue incompleta una parte del carbono se oxido y transformo en dióxido de carbono y la otra parte queda depositada en el hollín en una superficie fría generalmente metálica.

Por lo cual el ambiente presente dentro de un tambor secador de negro de humo presenta las cualidades idóneas para que exista la corrosión, temperaturas elevadas que aceleran los mecanismos de corrosión y ambiente rico en CO₂ y agua. La corrosión por CO₂ es también llamada corrosión dulce, y afecta principalmente a aceros al carbono y aceros de baja aleación, este proceso implica la disolución gaseosa del CO₂ en una fase acuosa donde se forma ácido carbónico H₂CO₃, compuesto que induce el ataque corrosivo en el metal a través de las reacciones electroquímicas anódicas y catódicas que degradan el material.


El mecanismo de reacción de este tipo de corrosión implica reacciones anódicas y caóticas con la hidratación del gas y la formación de H₂CO₃, a este corresponde cuatro pasos mencionados a continuación:

- 1) Creación de los agentes reactivos en la solución:

- CO₂ en la corriente del flujo ejerce una presión parcial, permitiendo su disolución en fase acuosa.




- Al hidratarse este compuesto forma ácido carbónico:



- El ácido carbónico se disocia para formar iones de hidrogeno H⁺ y bicarbonato HCO₃⁻






- Los iones del bicarbonato también se disocian para formar iones carbonato he iones hidrogeno.



- Los iones H⁺ permiten también la reacción de disociación de agua






2) Transferencia de los agentes reactivos desde la solución a la superficie del metal.




3) Reacciones electroquímicas en la superficie del metal.


- Catódicas:




- Anódica:




4) Transporte de productos de corrosión desde la superficie del metal a la solución.





Cuando las concentraciones de iones ferrosos e iones de carbonato superan el límite de solubilidad del carbonato de hierro, se requiere especial atención a la formación de este compuesto que se indica en la siguiente reacción:



. La precipitación de FeCO₃ puede aumentar la resistencia a la transferencia de masa para las especies corrosivas, al tiempo que disminuye la superficie metálica disponible para el proceso de corrosión y en algunos casos puede llegar a controlar la velocidad de reacción del CO₂

Aun así, el daño realizado por la corrosión de CO₂ se encuentran presentes y se caracterizan por tomar forma de corrosión general o uniforme, aunque también se puede presentar de forma localizada en picaduras.

2.3 Bases legales:

Uno de los sustentos que tiene esta investigación en el ámbito legal es la comisión venezolana de normas industriales (COVENIN), siendo este un modelo y ente encargado de la normalización y la estandarización en la industria venezolana en base a los lineamientos de calidad, esta establece los requisitos mínimos para diferentes tipos de actividades industriales, como ensayos, productos, materiales, procedimientos, entre otros aspectos que son regidos por dicha norma. Ejemplos de normas COVENIN que pueden guardar relación directa o indirecta con la investigación son:

- COVENIN 3049-93 mantenimiento definiciones.
- COVENIN 318-84 ensayos no destructivos, ultrasonido, terminología.
- COVENIN 2500-93 manual para evaluar los sistemas de mantenimiento de la industria. (1ra. Revisión).

De forma internacional se toma como base la *organización internacional de normalización* (ISO), esta norma crea estándares internacionales compuesto por diversas organizaciones nacionales de normalización. Entre los ejemplos de estas normas que sustentan apoyo al presente trabajo, podemos denotar:

- Norma ISO 17359:2018 Supervisión del estado y diagnóstico de las máquinas. Directrices generales.

En normas más recientes ya hacen presencia las inteligencias artificiales ejemplos de estas pueden ser:

- ISO/CEI 22989:2022 Tecnología de la información — Inteligencia artificial — Conceptos y terminología de la inteligencia artificial
- ISO/CEI 24668:2022 Tecnología de la información — Inteligencia artificial — Marco de gestión de procesos para análisis de big data.

Otra organización que cabe mencionar es la asociación nacional de ingenieros de corrosión (NACE internacional), es una organización dedicada a la investigación de la corrosión, por lo que es un organismo que regula y emite criterios para el control y prevención de la corrosión. NACE International se ha convertido en el líder mundial en el desarrollo de estándares, certificación y educación para la prevención y el control de la corrosión. Debido a que en este estudio el tambor secador de negro de humo presenta un ambiente corrosivo es importante tener a la mano normas respecto al mismo.

2.4 Definición de términos:

- Corrosión (Métales): es un proceso natural que convierte un metal refinado en un óxido químicamente más estable. Es el deterioro gradual de los materiales por reacción química o electroquímica con su entorno.
- Deep learning/ aprendizaje profundo: es un subconjunto de machine learning (que a su vez es parte de la inteligencia artificial) donde las redes neuronales, algoritmos inspirados en cómo funciona el cerebro humano, aprenden de grandes cantidades de datos.
- Falla (mantenimiento): son eventos inesperados que implican el mal funcionamiento o el cese en las funciones de los equipos, lo que impacta directamente en la productividad de una empresa.
- Hiperparámetros: en machine learning se definen los hiperparámetros como los parámetros definidos explícitamente por el usuario para controlar el proceso de aprendizaje de una red neuronal.
- Industria: Sector económica y técnica que consiste en transformar las materias primas hasta convertirlas en productos adecuados para satisfacer las necesidades del ser humano
- Inteligencia artificial: es la simulación de procesos de inteligencia humana por parte de máquinas, especialmente sistemas informáticos. Estos procesos incluyen el aprendizaje (la

adquisición de información y reglas para el uso de la información), el razonamiento (usando las reglas para llegar a conclusiones aproximadas o definitivas) y la autocorrección.

- Internet de las cosas: se refiere a la red colectiva de dispositivos conectados y a la tecnología que facilita la comunicación entre los dispositivos y la nube, así como entre los propios dispositivos.
- Machine learning/ Aprendizaje automático: es una disciplina del campo de la Inteligencia Artificial que, a través de algoritmos, dota a los ordenadores de la capacidad de identificar patrones en datos masivos y elaborar predicciones
- Parada: Una parada de planta o de mantenimiento, es un período durante el cual la planta se encuentra fuera de servicio, permitiendo efectuar tareas de mantenimiento como inspecciones, reparaciones generales, sustituciones, rediseños de máquinas, etcétera.
- Redes neuronales convolucionales: es un tipo de red neuronal artificial donde las neuronas artificiales, corresponden a campos receptivos de una manera muy similar a las neuronas en la corteza visual primaria de un cerebro biológico, pudiendo así reconocer patrones en imágenes.

CAPÍTULO III

MARCO METODOLÓGICO

3.1 Tipo de investigación:

El tipo de investigación se encuentra delimitado por la definición de proyecto factible, según Arias se puede definir proyecto factible como una “propuesta de acción para resolver un problema práctico o satisfacer una necesidad. Es indispensable que dicha propuesta se acompañe de una investigación que demuestre su factibilidad o posibilidad de realización” (2006, pág. 134).

En el presente trabajo la investigación es de tipo proyecto factible debido a su naturaleza de ser una propuesta de diseño de un sistema de predicción de fallas, mediante la aplicación de una inteligencia artificial, para la solución de la problemática que implica analizar la información en los mantenimientos predictivos con la finalidad de reducir así las paradas no planificadas en el proceso de secado de negro de humo, así mismo midiéndose la factibilidad de la aplicación de estas nuevas tecnologías en procesos industriales similares al tratado en la investigación.

3.2 Diseño de la investigación:

El diseño de la investigación hace referencia a la modalidad mediante la cual será abordada problemática en cuestión respecto a la obtención de los datos por medio de los cuales se trabajara y si estos serán o no modificados por el investigador, El diseño de investigación se puede definir como “la estrategia general que adopta el investigador para responder al problema planteado, En atención al diseño, la investigación se clasifica en: documental, de campo y experimental”(Arias, 2016, pág. 27).

El diseño de la investigación es de tipo documental experimental, Arias define el diseño de la investigación documental y experimental respectivamente como:

La investigación documental es un proceso basado en la búsqueda, recuperación, análisis, crítica e interpretación de datos secundarios, es decir, los obtenidos y registrados por otros investigadores en fuentes documentales: impresas, audiovisuales o electrónicas. Como en toda investigación, el propósito de ese diseño es el aporte de nuevos conocimientos. (Arias, 2016, pág. 27).

Por otro lado, La investigación experimental es un proceso que consiste en someter a un objeto o grupo de individuos, a determinadas condiciones, estímulos o tratamiento (variable independiente), para observar los efectos o reacciones que se producen (variable dependiente). (Arias, 2016, pág. 34).

El presente se asocia con el marco de diseño de investigación documental y experimental, debido a que todos los datos que serán obtenidos del funcionamiento y fallas de un tambor secador

de negro de humo no serán tomando de forma directa por el investigador si no que serán datos secundarios tomados de bibliografías y fuentes variadas, a su vez trabajándose a partir de los mismos datos, modificándolos de acuerdo a la variabilidad misma de las condiciones de trabajo del tambor y las salidas obtenidas en la inteligencia artificial para un correcto entrenamiento de la red neuronal. Consiguiéndose así la relación entre las variables dependientes e independientes a través de proceso de retroalimentación.

3.3 Nivel de la investigación:

El nivel de la investigación hace referencia a la profundidad con la que será abordado el fenómeno a estudiar, en este caso la investigación es de tipo descriptiva, este modelo de investigación consiste en:

La caracterización de un hecho, fenómeno, individuo o grupo, con el fin de conocer su estructura o comportamiento. Los resultados de este tipo de investigación se ubican en un nivel intermedio en cuanto a la profundidad de los conocimientos se refiere (Arias, 2016, pág. 24).

Esta definición se relaciona completamente con la presente investigación debido a que el objetivo de la misma consta de predecir el momento en el cual va a fallar una pieza, para esto se busca analizar un conjunto de variables con la finalidad de conocer de forma global no solo el por qué puede ocurrir una falla en un tambor secador si no en qué momento esta se aparentara en el tiempo, siendo esta una descripción precisa de la situación del tambor secador en todo momento, además que se busca describir que tan eficiente puede ser la aplicación de la inteligencia artificial en el mantenimiento predictivo en maquinarias y equipos industriales semejantes al tambor secador de negro de humo.

3.4 Población y muestra:

3.4.1 Población:

Una de las finalidades de una investigación científica es poder extender los resultados a la mayor cantidad casos donde sea posible aplicarlos de modo que generalmente se estudia en favor de un grupo de objetos o individuos con la finalidad de que los conocimientos adquiridos puedan ser extrapolables a los mismos, respecto a esto, una definición de la población en una investigación puede ser:

La población, o en términos más precisos población objetivo, es un conjunto finito o infinito de elementos con características comunes para los cuales serán extensivos las conclusiones de la investigación. Esta queda delimitada por el problema y por los objetivos del estudio. (Arias, 2016, pág. 81).

En relación a lo mencionado, en proporción de esta investigación se puede considerar como población todos los objetos a los cuales pueden ser extrapolables los resultados obtenidos, en este caso como la investigación hace referencia la predicción de fallas en un proceso de secado de un material (negro de humo), En la población se considera de forma general los procesos de secado mediante un flujo de aire caliente.

Ejemplos de estos procesos pueden ser, las maquinarias de tambor secador rotativo de diferentes tipos de materiales, como secadores de lodo, de biomasa, de pigmento, además de los procesos de secado similares, como pueden ser, secadores de bandejas, secadores continuos de túnel, secadores rotatorios, secadores de tambor rotatorio y secadores por aspersion.

3.4.2 Muestra:

Arias define la muestra como “un subconjunto representativo y finito que se extrae de la población accesible” (2016, pág. 83). Por ende, una muestra es un conjunto más pequeño tomado para el estudio, este cual hace referencia a la población generalizando los resultados con un margen de error conocidos, pero suficientemente bajo para que dichos conocimientos puedan ser aplicados al resto de la población.

De acuerdo con esto la muestra en el presente trabajo es el tambor secador rotativo de negro de humo, hacia el cual va dirigidos la investigación.

3.5 Técnica e instrumentos de recolección de datos:

Las técnicas e instrumentos de recolección de datos están estrechamente relacionadas con el diseño de la investigación, “Se entenderá por técnica de investigación, el procedimiento o forma particular de obtener datos o información” (Arias, 2016, pág. 67), de mismo modos se puede definir los instrumentos de recolección de datos implementados en una investigación como “cualquier recurso, dispositivo o formato (en papel o digital), que se utiliza para obtener, registrar o almacenar información” (Arias, 2016, pág. 68).

En base a esto y considerando que el diseño de la investigación es de tipo documental las técnicas implementadas para la recolección de datos son, el análisis documental y el análisis de contenido, básicamente la revisión y análisis de medios bibliográficos, repositorios y bases teorías referente al proceso de secado de negro de humo mediante tambor secador rotativo, mientras que los instrumentos de recolección de datos serán, fichas, tablas, computadoras y sus unidades de almacenaje, cuadro de registro y clasificación de categorías.

3.6 Técnica de análisis de resultados:

En base a un tipo de investigación documental el análisis de datos, de acuerdo con Arias (2016) consta del desglose de la información obtenida en ideas principales y secundarias con el fin de darle un sentido y estructura a las mismas, de este modo identificar la relación o vínculos existentes.

Para la presente investigación la técnica de análisis de resultados debe ser un modelo de comparación y retroalimentación, el estudio tiene como finalidad predecir las fallas en el procesos de secado de negro de humo en un tambor secador rotativo mediante la aplicación de un inteligencia artificial, para estar seguros que se está o no logrando el objetivo se deben comparar los resultados obtenidos por la red neuronal con resultados cercanos a los reales (obtenidos mediante simulación y modelado matemáticos) en un funcionamiento regular de la maquinaria, midiéndose así el porcentaje de error que se obtenga, mediante el cual se calibra el sistema para ser más preciso al generar resultados.

3.7 Fases metodológicas:

Fase I: Diagnostico de las condiciones de trabajo del secador de negro de humo y la variabilidad de esta a través del tiempo:

En esta fase se busca identificar y clasificar las condiciones presentes en el proceso de secado de negro de humo, tanto las condiciones de trabajo normales como los parámetros en las cuales estas varían, el diagnostico de dichas condiciones se realiza mediante la búsqueda de información en bibliografías y antecedentes relacionadas los tambores secadores rotativos, con la finalidad de conocer las variables intrínsecas en su funcionamiento y también la variabilidad de estas a través del tiempo, en dado caso que el funcionamiento sea tanto regular como irregular.

Fase II: Análisis de la data mediante modelados matemáticos y procesos de simulación implementando software CAD:

Los datos obtenidos de la fase anterior deben ser analizados mediante modelos matemáticos y procesos de simulación que definan el funcionamiento del tambor secador, a modo de obtener una relación entre la variación de las condiciones de trabajo del tambor secador y la ocurrencias de fallas en el mismo, de manera que se pueda evaluar la condición de un tambor secador simulado en todo momento en referencia a sus condiciones de trabajo, brindando así como datos las causas de fallas en analogía a las variables de funcionamiento.

Fase III: Definición de los hiperparámetros óptimos en relación a las condiciones de trabajo del tambor, implementando lenguaje de programación Python:

En esta fase se debe programar una red neuronal artificial, la cual procederá a ser entrenada con los datos obtenidos de la fase anterior, para esto los hiperparámetros que definen a la red debe ser modificados de acuerdo a las condiciones de trabajo del tambor secador, conforme a los datos de predicción deseados y al método de entrenamiento de la red, implementándose como herramienta para ello el lenguaje de programación Python.

Esta red neuronal artificial tiene el objetivo de predecir las fallas del tambor secador modelado, en base a los datos brindados respecto a su funcionamiento. Además de utilizar el porcentaje de error obtenido en cada predicción para una retroalimentación, cambiando de forma continua y automática sus parámetros para acercarse así a porcentajes de error mínimos y obteniéndose resultados concretos.

Fase IV: Comparación de las predicciones realizadas por la inteligencia artificial con valores guías para cuantificar su progreso:

En esta fase se evalúa la el rendimiento de la red neuronal en su trabajo de predecir las fallas, se plantea un modelo de tambor secador con condiciones iniciarles diferentes a los utilizados para entrenar la red que emule las condiciones reales de un tambos secador en su ciclo de vida, posteriormente se comparan los resultados obtenidos tanto por la red neuronal como por el nuevo modelo de tambor secador y se evalúa la diferencia entre ambas predicciones, para poder medir que tan cercanos son ambos resultados y de esta forma definir el rendimiento de la red neuronal en la predicción de fallas.

Fase V: Evaluación de la viabilidad técnica y ambiental, para una posible aplicación en la industria:

En esta última fase se analiza qué tan viable es la aplicación de esta propuesta ya a nivel industrial desde un punto de vista técnico y ambienta, para esto se debe evaluar qué tipo de tecnología, formación, medidas de seguridad y lineamientos previos son necesarios para la ampliación de esta nueva tecnología en los procesos de mantenimiento predictivo y si no existe limitante a la hora de poder llevar acabo la implementación de las redes neuronales en sistemas de precisión de fallas en la industria.

Desde un punto de vista ambiental se debe analizar que tanto daño la aplicación de lo investigado puede generar al ambiente tanto de forma directa como indirecta, cumpliendo con los estándares que rigen la cantidad de contaminación que puede generar.

3.8 Confiabilidad de la investigación:

La confiabilidad y la validez de la investigación consta que los resultados sean consistentes y coherentes, de modo que se puedan replicar al seguirse los mismos pasos, para que sean válidos los resultados obtenidos tiene que ser cuantificables y objetivos además de ser precisos.

Haciendo referencia a los instrumentos implementados en las investigaciones cuantitativas, estos deben ser estables en los datos obtenidos y anular el riesgo de variación en los distintos casos y momentos de aplicación, lo que significa que se deben obtener sistemáticamente los mismos datos al implementarse en una misma situación en repetidas ocasiones.

CAPÍTULO IV

RESULTADOS

En este capítulo se presenta el recorrido en la ejecución del presente trabajo de grado y los resultados obtenidos de la investigación, desplegándose así los procedimientos ejecutados en el desarrollo de cada una de las fases mencionadas anteriormente en el capítulo III, de modo que, se consiguen conclusiones y datos, cumpliéndose con los objetivos planteados respecto a la implementación de inteligencias artificiales en forma de apoyo, para la oportuna detección de fallas en el proceso de secado de negro de humo.

4.1 Diagnóstico de las condiciones de trabajo del secador de negro de humo y la variabilidad de esta a través del tiempo:

Las condiciones de trabajo del tambor secador de negro de humo son el conjunto de variables presentes en su funcionamiento y su entorno. Para el proceso de secado algunas de estas variables son controladas, como puede ser: la temperatura, el flujo de negro de humo, el flujo de aire, la velocidad de rotación, la inclinación del tambor, entre otras. El control de estas variables permite un correcto funcionamiento de la maquinaria para obtener un producto seco de calidad. Estas variables permiten conocer de forma ideal como debe estar trabajando el tambor secador y tener así un punto de partida para la obtención de datos que permitan así relacionar dichas variables con el estado del tambor.

En la realidad por lo general las variables no se encuentran 100% controladas todo el tiempo, por lo cual, aunque se quiera obtener un valor muy cercano a uno ideal, lo más seguro es tener siempre un porcentaje de error, esto significa una variabilidad en las mismas condiciones de funcionamiento del tambor a través del tiempo. Esta variabilidad en las condiciones reales de trabajo del tambor también hace variar la condición de deterioro del mismo, haciendo que estas sean muy diferentes a las calculadas con datos teóricos ideales.

Todo esto se traduce que es necesario un levantamiento de información de los datos de funcionamiento del tambor secador y la viabilidad de estas a través del tiempo, de modo que dicho cambio pueda ser contemplado en el apartado de predicción de fallas, siendo así la finalidad de esta fase, por lo que se procede a presentarse las condiciones, variables y constantes presentes en el proceso de secado de negro de humo obtenidos documentalmente.

4.1.1 Definición de las constantes y dimensionado del tambor secador:

Las constantes son todos aquellos que no van a variar con el tiempo, es necesario definir las mismas ya que permite reducir la investigación para un caso específico de tambor secador, permitiendo así contemplarse las soluciones en el caso de interés de la investigación.

Entre las constantes que presenta el tambor secador tenemos el material del cual está constituido, este es:

- Acero inoxidable AISI 304.

Tabla 1: Propiedades mecánicas del Acero inoxidable AISI 304.

Propiedad	Valor	Unidades
Modulo Elástico	1.9e+11	N/m ²
Coefficiente de Poisson	0.29	N/D
Modulo cortante	7.5e+10	N/m ²
Densidad de masa	8000	Kg/m ³
Límite de tracción	517017000	N/m ²
Limite elástico	206807000	N/m ²
Coefficiente de expansión térmica	1.8e-5	/K
Conductividad térmica	16	W/(m*k)
Calor especifico	500	J/(kg*k)

Nota. Datos extraídos de SolidWorks 2014

Fuente. Méndez (2023).

Además del material que conforma el tambor secador, las mismas dimensiones del tambor también forma parte de los datos que no varían con el tiempo, por lo cual se toman como constantes en la investigación, en las siguientes figuras y cuadros se visualiza las dimensiones del tambor secador y del engranaje conducido del mismo.


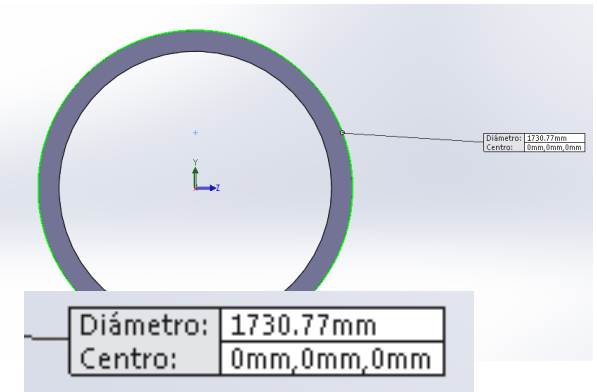
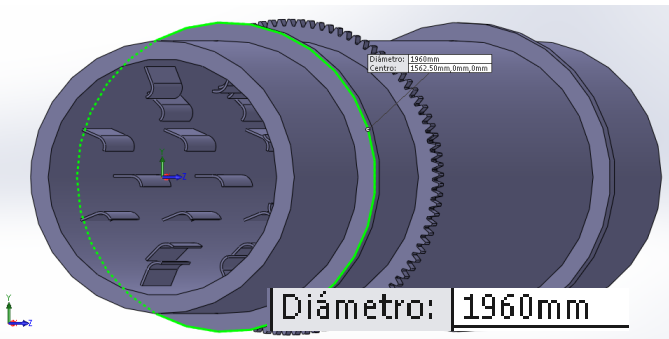
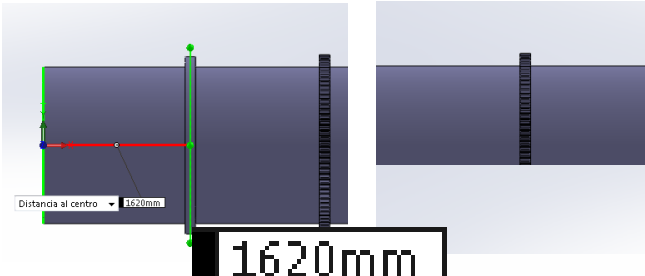
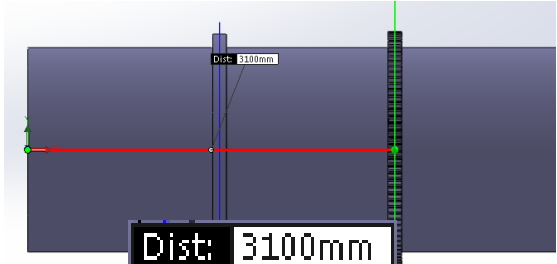


Figura 6: Modelo 3D del tambor secador hecho en SolidWorks.
Fuente. Méndez (2023).

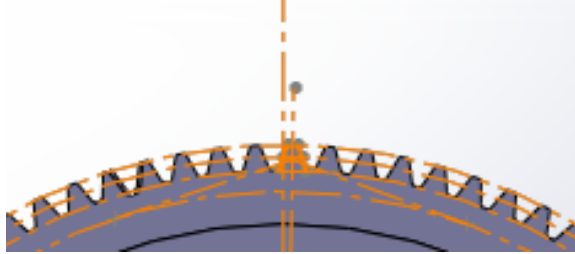
Cuadro 2: Dimensiones del tambor secador de negro de humo.

Dimensión	Magnitud	Imagen
Longitud	9 m	
Diámetro Interior	1,5 m	

<p>Diámetro exterior</p>	<p>1,731 m</p>	
<p>Diámetro Apoyo de rodillos</p>	<p>1,96m</p>	
<p>Posición longitudinal de los apoyos respecto a los extremos</p>	<p>1,62 m</p>	
<p>Posición longitudinal del engrane conducido</p>	<p>3,1 m</p>	

Fuente. Méndez (2023).

Cuadro 3: Dimensiones de engranaje conducido del tambor secador.

Dimensión	Magnitud	Imagen				
Módulo (M)	20					
Número de dientes (N)	98					
Ángulo de presión (a)	20°			"M"	= 20	20
				"N"	= 1960 / "M"	98
				"a"	= 20	20
				"hd"	= "M" * 2,167	43,34
Altura del diente (hd)	43,45 mm			Ct@Croquis5	= "Dp@Croquis5" * 0,93969	1841,79mm
				Di@Croquis5	= "De@Croquis5" - ("hd" * 2)	1913,32mm
				De@Croquis5	= "Dp@Croquis5" + "M" * 2	2000mm
				Dp@Croquis5	1960mm	1960mm
Diámetro de trazado Ct	1851,79 mm					
Diámetro Primitivo	1960 mm					
Diámetro interior	1913,32 mm					
Diámetro exterior	2000 mm					

Fuente. Méndez (2023).

4.1.2 Propiedades del negro de humo y del proceso de secado:

Gran parte de las condiciones de trabajo del proceso de secado están directamente relacionadas con las propiedades del material a secar, en este caso el negro de humo y las variables necesarias para el secado del mismo, las propiedades del negro de humo se pueden visualizar en la tabla 2 y las propiedades relacionadas con el proceso son contempladas en la tabla 3.

Tabla 2: Propiedades físicas del negro de humo.

VARIABLES	Valor	Variabilidad	Unidad
Tamaño de partícula (Polvo)	25 nm		Nanómetros
pH	8,5.	Ox. (2-4), NoOx.(6-11)	pH
Densidad		1,8 ±0,1	g/cm ³ a 20 °C
Densidad Aparente		440	kg/m ³ (Granulo)
Densidad Aparente		200	kg/m ³ (Polvo)
Solubilidad en agua	insoluble		
% volátiles (en peso)	< 2,5 %	< 2,5%	% NoOx (950 °C)
	5%	2%-8%	% Peso Oxidado
Inflamabilidad con el aire	600°		
Límite Inferior explosión en aire		50 >50	g/m ³
P. Máxima de explosión absoluta.	10 bar		bar
Calor específico	7,11		J/gK

Fuente. Extraído de *Hoja de información de seguridad del producto*, Negroven, S.A. (2020).

Tabla 3: Propiedades del proceso de secado de negro de humo.

VARIABLES Y DATOS	Valor	Variabilidad	Unidad
Producción media por año	45000 Ton/año		Tonelada
Temperatura del quemador	950 °C	±50 °C	°C
Peso de material a secar en 1 horas de trabajo	7- 10 ton	<14 ton	Tonelada
Ø Pellets	0,2 mm	±0,05 mm	Milímetros
% Humedad	47,5%	±12,5%	% Peso de agua
% Humedad final	1%		% Peso de agua
Aglutínate	Lignosulfato de sodio		
Rpm del tambor	4 rpm	4-2,5 rpm	Rev. Por minuto
Angulo de inclinación	3,5 °	± 1,5°	G. centígrados
Velocidad del aire caliente	1,375 m/s	± 1,125 m/s	Metros/seg.
potencia del motor	-11 Hp		Caballo de fuerza

Fuente. Recopilado de *Hoja de información de seguridad del producto*, Negroven.co.ve .Negroven, S.A. (2020). *Secador de tambor rotativo Jiangsu Xianfeng Drying Equipment Company, Ltd. Y las posibilidades de cooperación y complementación en el sector petroquímico* (pág. 23), Convenio inpea-cepal (1981).

4.2 Análisis de la data mediante modelos matemáticos y procesos de simulación implementando software CAD:

En base a los datos obtenidos documentalmente en la fase anterior se calculan la información y variables faltantes, mediante modelos matemáticos e implementación de software CAD, además de igual forma se simula la variación de las magnitudes a través del tiempo de uso del tambor secador, de forma que se realiza una base de datos, con los tiempos de vida de cada tambor simulado en base a las condiciones a las que fue sometido en toda su vida útil, todo esto con la finalidad de generar un dataset el cual servirá para entrenar la red neuronal de la inteligencia artificial del presente trabajo de grado.

4.2.1 Flujo de negro de humo en el tambor secador:

Tomando como referencia las toneladas a procesar de negro de humo para una producción de 45000 toneladas al año se calcula la cantidad de negro de humo que debe ser secado en el proceso productivo por cada hora de trabajo.

$$45000 \frac{\text{Ton}}{\text{año}} * \frac{1\text{año}}{12\text{meses}} * \frac{1\text{mes}}{4\text{semanas}} * \frac{1\text{semana}}{5\text{dias}} * \frac{1\text{dia}}{24\text{horas}}$$
$$45000 \frac{\text{Ton}}{\text{año}} = 7,81 \frac{\text{Ton}}{\text{hora}}$$

Por lo cual sabemos que, por cada hora de trabajo, el tambor rotativo debe secar 7,81 toneladas de negro de humo. Llevándose a kilogramos por segundo:

$$7,81 \frac{\text{Ton}}{\text{hora}} * \frac{1\text{hora}}{3600\text{segundos}} * \frac{1000\text{kg}}{1\text{Ton}} = 2,17 \frac{\text{kg}}{\text{s}}$$

Lo que significa que del tambor secador deben salir 2,17 kilogramos de material seco cada segundo. Tomando la densidad del negro de humo como $\rho = 440 \text{ kg/m}^3$

$$\rho = \text{kg/vol}$$

$$\text{Vol} = \frac{2,17\text{kg}}{440 \frac{\text{kg}}{\text{m}^3}} = 0,0049318\text{m}^3$$

$$0,0049318 \frac{\text{m}^3}{\text{s}}$$

4.2.2 Análisis térmico del tambor secador mediante software CAD.

Una de las variables más importantes en el proceso de secado de negro de humo es la temperatura, tanto de la corriente de aire caliente generada, como la temperatura presente en las paredes internas del tambor, mediante la transferencia de calor entre el aire, el tambor y el negro de humo es que se logra el secado del mismo, para dar inicio a este análisis se realizó un conjunto de simulaciones en el software CAD SolidWorks, con la finalidad de obtener la temperatura de la corriente de aire, hasta, la temperatura alcanzada en la superficie interna del tambor, tomándose como variables para este análisis la el flujo masico de la corriente de aire generadas y la temperatura en el quemador.

Para esta simulación se usaron como variables de entrada el flujo masico de la corriente de aire y la temperatura del quemador, los datos implementados para las simulaciones se visualizan en el cuadro 4.

Cuadro 4: Valores iniciales para las simulaciones térmicas con flujo de aire.

Número	Temperatura del quemadora	Flujo másico de corriente de aire kg/s
1	1600 °C	0,5 kg/s, 1 kg/s, 1,5 kg/s
2	1400 °C	
3	1200 °C	
4	1000 °C	
5	800 °C	
6	600 °C	

Fuente. Méndez (2023).

En base a los valores presentados, mediante la implementación de SolidWorks se simularon las condiciones de trabajo del tambor secador a dichas temperaturas y flujo de aire, de modo que se obtuvo como resultado, los datos de la temperatura transferida por convección a la superficie interna del tambor secador, a lo largo de toda la longitud de este, teniéndose así las siguientes figuras, gráficos y tablas de datos.

Simulación 1: 1600 °C y 1 kg/s.


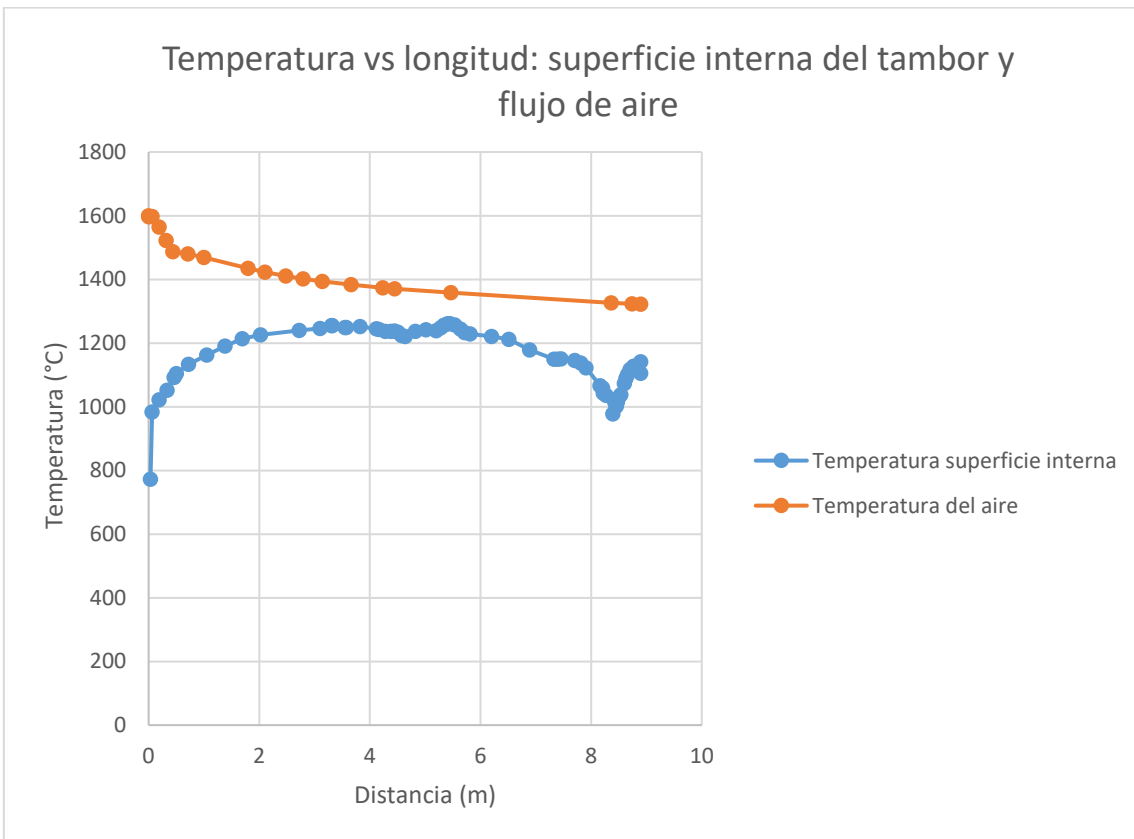


Figura 7: Valores de temperatura en el plano medio del tambor secador en la simulación 1.

Fuente. Méndez (2023)

Gráfico 1: Curva de temperatura en relación a la distancia (Simulación 1):



Fuente. Méndez (2023)

Simulación 2: 1400 °C y 1 kg/s.


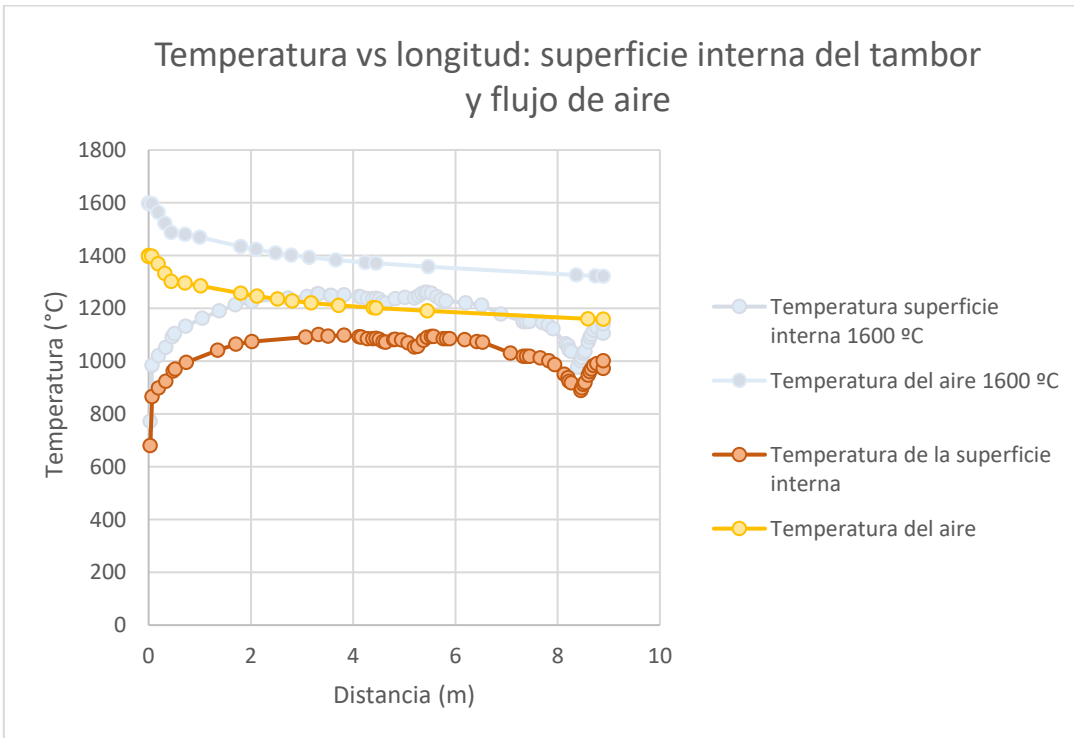


Figura 8: Valores de temperatura en el plano medio del tambor secador en la simulación 2.

Fuente. Méndez (2023)

Gráfico 2: Curva de temperatura en relación a la distancia (Simulación 2):



Fuente. Méndez (2023)

Simulación 3: 1200 °C y 1 kg/s.


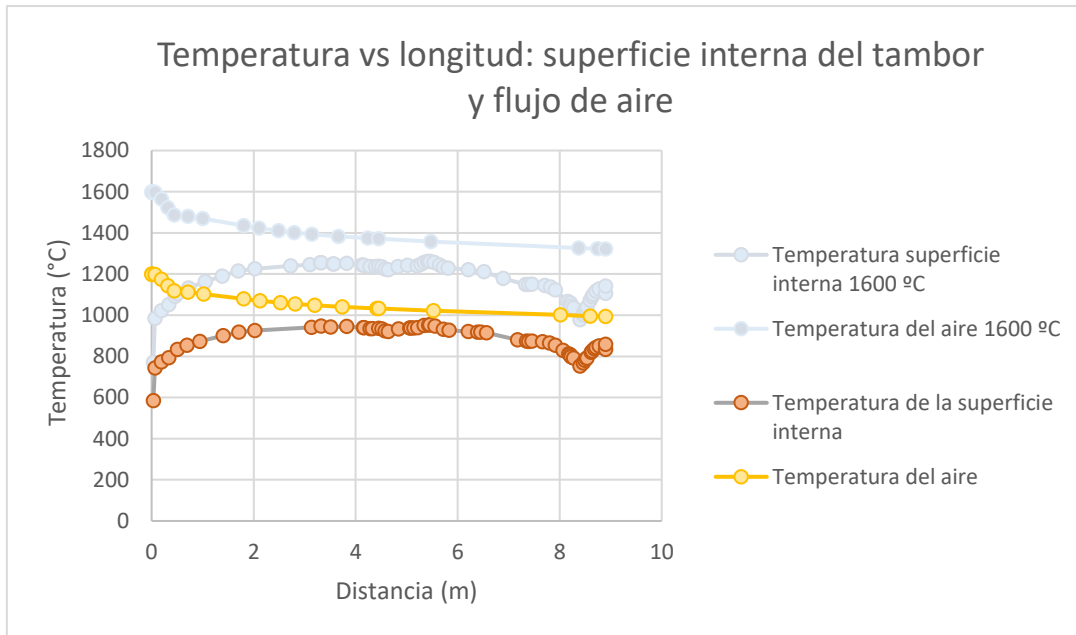


Figura 9: Valores de temperatura en el plano medio del tambor secador en la simulación 3.

Fuente. Méndez (2023)

Gráfico 3: Curva de temperatura en relación a la distancia (Simulación 3):



Fuente. Méndez (2023)

Simulación 4: 1000 °C y 1 kg/s.





Figura 10: Valores de temperatura en el plano medio del tambor secador en la simulación 4.

Fuente. Méndez (2023)

Gráfico 4: Curva de temperatura en relación a la distancia (Simulación 4):



Fuente. Méndez (2023)

Simulación 5: 800 °C y 1 kg/s.





Figura 11: Valores de temperatura en el plano medio del tambor secador en la simulación 5.

Fuente. Méndez (2023)

Gráfico 5: Curva de temperatura en relación a la distancia (Simulación 5):



Fuente. Méndez (2023)

Simulación 6: 600 °C y 1 kg/s.





Figura 12: Valores de temperatura en el plano medio del tambor secador en la simulación 6.

Fuente. Méndez (2023)

Gráfico 6: Curva de temperatura en relación con la distancia (Simulación 6):



Fuente. Méndez (2023)

Simulación 7: 1600 °C y 1,5 kg/s.





Figura 13: Valores de temperatura en el plano medio del tambor secador en la simulación 7.

Fuente. Méndez (2023)

Gráfico 7: Curva de temperatura en relación a la distancia (Simulación 7):



Fuente. Méndez (2023)

Simulación 8: 1400 °C y 1,5 kg/s.





Figura 14: Valores de temperatura en el plano medio del tambor secador en la simulación 8.

Fuente. Méndez (2023)

Gráfico 8: Curva de temperatura en relación a la distancia (Simulación 8):



Fuente. Méndez (2023)

Simulación 9: 1200 °C y 1,5 kg/s.





Figura 15: Valores de temperatura en el plano medio del tambor secador en la simulación 9.

Fuente. Méndez (2023)

Gráfico 9: Curva de temperatura en relación a la distancia (Simulación 9):



Fuente. Méndez (2023)

Simulación 10: 1000 °C y 1,5 kg/s.





Figura 16: Valores de temperatura en el plano medio del tambor secador en la simulación 10.

Fuente. Méndez (2023)

Gráfico 10: Curva de temperatura en relación a la distancia (Simulación 10):



Fuente. Méndez (2023)

Simulación 11: 800 °C y 1,5 kg/s.





Figura 17: Valores de temperatura en el plano medio del tambor secador en la simulación 11.

Fuente. Méndez (2023)

Gráfico 11: Curva de temperatura en relación a la distancia (Simulación 11):



Fuente. Méndez (2023)

Simulación 12: 600 °C y 1,5 kg/s.





Figura 18: Valores de temperatura en el plano medio del tambor secador en la simulación 12.

Fuente. Méndez (2023)

Gráfico 12: Curva de temperatura en relación a la distancia (Simulación 12):



Fuente. Méndez (2023)

Simulación 13: 1600 °C y 0,5 kg/s.





Figura 19: Valores de temperatura en el plano medio del tambor secador en la simulación 13.

Fuente. Méndez (2023)

Gráfico 13: Curva de temperatura en relación a la distancia (Simulación 13):



Fuente. Méndez (2023)

Simulación 14: 1400 °C y 0,5 kg/s.





Figura 20: Valores de temperatura en el plano medio del tambor secador en la simulación 14.

Fuente. Méndez (2023)

Gráfico 14: Curva de temperatura en relación a la distancia (Simulación 14):



Fuente. Méndez (2023)

Simulación 15: 1200 °C y 0,5 kg/s.





Figura 21: Valores de temperatura en el plano medio del tambor secador en la simulación 15.

Fuente. Méndez (2023)

Gráfico 15: Curva de temperatura en relación a la distancia (Simulación 15):



Fuente. Méndez (2023)

Simulación 16: 1000 °C y 0,5 kg/s.





Figura 22: Valores de temperatura en el plano medio del tambor secador en la simulación 16.

Fuente. Méndez (2023)

Gráfico 16: Curva de temperatura en relación a la distancia (Simulación 16):



Fuente. Méndez (2023)

Simulación 17: 800 °C y 0,5 kg/s.





Figura 23: Valores de temperatura en el plano medio del tambor secador en la simulación 17.

Fuente. Méndez (2023)

Gráfico 17: Curva de temperatura en relación a la distancia (Simulación 17):



Fuente. Méndez (2023)

Simulación 18: 600 °C y 0,5 kg/s.





Figura 24: Valores de temperatura en el plano medio del tambor secador en la simulación 18.

Fuente. Méndez (2023)

Gráfico 18: Curva de temperatura en relación a la distancia (Simulación 18):




Fuente. Méndez (2023)

En base a estas simulaciones se obtuvieron como resultados los valores de temperatura de la superficie interna del tambor tanto como la temperatura del fluido en el centro de este, todo en base a al flujo másico de corriente de aire caliente para diferentes valores de temperatura inicial (temperatura en el quemador). Con relación a esto, en base a las gráficas de la velocidad del fluido se observa que estas tienden a tener un patrón o forma similar. Pero con pequeñas variaciones debido al cambio de las variables iniciales independientes, temperatura inicial y flujo de aire.

Estas variaciones se pueden ver de mejor forma en las siguientes gráficas, en las cuales se comparan los comportamientos de la temperatura dentro del tambor secador, en relación a la variabilidad de la temperatura del quemador y el flujo másico de la corriente de aire.

Gráfico 19: Curvas de temperatura vs distancia, con relación a la temperatura inicial, con 0,5 kh/s de flujo de aire constante.




Fuente. Méndez (2023)

Al observar la familia de curvas en la gráfica 19, es evidente la diferencia que existe en la temperatura de la superficie interna del tambor secador al variar la temperatura en el quemador, por regla general al disminuir la temperatura en general se puede visualizar como en la superficie interna del tambor también disminuye la temperatura, aun así existen puntos de máxima temperatura los cuales de forma anti intuitiva no están en la zona más cercana a él quemador, estos picos máximos se comprenden en los intervalos entre los 3 y 5 metros de longitud, esto

sucede debido al recorrido del aire caliente el cual en esas zonas retorna para llenar la el volumen inicial del tambor aledaña a la superficie interna en los primeros 4 metros (observable en las figuras 7 – 24 en las flechas de dirección de flujo)

Gráfico 20: Curvas de temperatura vs distancia, con relación al flujo de aire inicial, con 1600 °C de temperatura del quemador constante.



Fuente. Méndez (2023)

En la gráfica se puede observar cómo de igual forma a la temperatura inicial la variación del flujo de aire tiene también impacto en los valores de temperatura en la superficie interna del tambor. El cambio del flujo másico tiene mayor impacto cuando este tiene valores pequeños como se puede visualizar en la curva formada por un flujo másico a 0,5 k/s y una temperatura de 1600°C. este comportamiento es intuitivo, puesto que, al haber mayor flujo de aire, este se desplaza más rápidamente permitiendo mayor transferencia de calor en áreas más alejadas del quemador.

Referente a toda esta información extraída de procesos de simulación se crearon un conjunto de tablas donde se engloban las magnitudes de temperatura en la superficie interna del tambor secador en relación con la variación en la temperatura del quemador y al flujo de aire analizado, dichas tablas son la 4, la 5 y la 6, presentadas a continuación.

Tabla 4: Valores de la temperatura para 1 k/s de flujo de aire.

Flujo másico 1 Kg/s								
Tabla 4. Temperatura de la superficie interna del tambor secador en base a la temperatura del quemador y el flujo másico del aire caliente.								
Temperatura (C°)	Longitud del secador (m)							
	0,5	1	1,5	2	2,5	3	3,5	4
1600	1102,8	1158,0	1199,3	1225,3	1235,2	1243,9	1250,0	1247,5
1550	1068,7	1122,2	1162,3	1187,3	1196,9	1205,4	1211,4	1209,3
1500	1034,6	1086,4	1125,3	1149,4	1158,5	1166,9	1172,7	1171,2
1450	1000,5	1050,6	1088,3	1111,5	1120,2	1128,4	1134,1	1133,0
1400	966,4	1014,9	1051,3	1073,5	1081,8	1089,8	1095,5	1094,9
1350	932,9	980,0	1015,0	1036,5	1044,4	1052,1	1057,2	1056,6
1300	899,3	945,2	978,7	999,5	1007,1	1014,3	1018,9	1018,4
1250	865,7	910,3	942,4	962,4	969,7	976,6	980,6	980,1
1200	832,1	875,5	906,1	925,4	932,3	938,8	942,3	941,9
1150	798,3	839,8	869,0	887,5	894,0	900,3	903,6	903,0
1100	764,4	804,1	832,0	849,5	855,8	861,8	864,8	864,1
1050	730,5	768,4	794,9	811,5	817,5	823,2	826,1	825,2
1000	696,7	732,7	757,9	773,6	779,3	784,7	787,3	786,3
950	661,8	695,6	719,7	734,6	740,0	745,2	747,7	746,9
900	627,0	658,6	681,5	695,6	700,7	705,7	708,1	707,6
850	592,1	621,5	643,3	656,7	661,5	666,2	668,5	668,2
800	557,3	584,5	605,1	617,7	622,2	626,7	628,8	628,8
750	521,2	546,9	566,2	578,0	582,2	586,4	588,3	588,2
700	485,1	509,3	527,4	538,3	542,2	546,1	547,8	547,6
650	448,9	471,7	488,5	498,6	502,1	505,9	507,3	507,0
600	412,8	434,2	449,6	459,0	462,1	465,6	466,7	466,4

Fuente. Méndez (2023)

Tabla 4 Continuación: Valores de la temperatura para 1 k/s de flujo de aire.

Flujo másico 1 Kg/s									
Tabla 4 continuación. Temperatura de la superficie interna del tambor secador en base a la temperatura del quemador y el flujo másico del aire caliente.									
Temperatura (C°)	Longitud del secador (m)								
	4,5	5	5,5	6	6,5	7	7,5	8	8,5
1600	1234,2	1241,6	1258,6	1224,5	1212,5	1171,6	1149,1	1102,0	1027,1
1550	1196,6	1200,2	1216,9	1189,3	1177,4	1137,8	1116,1	1070,3	1000,9
1500	1159,0	1158,7	1175,3	1154,0	1142,2	1104,0	1083,2	1038,5	974,8
1450	1121,3	1117,2	1133,7	1118,8	1107,1	1070,2	1050,2	1006,8	948,7
1400	1083,7	1075,8	1092,0	1083,5	1072,0	1036,4	1017,2	975,0	922,6
1350	1046,1	1041,1	1056,6	1043,8	1033,0	999,8	981,2	941,0	887,8
1300	1008,5	1006,3	1021,1	1004,1	994,0	963,1	945,2	907,1	853,0
1250	970,9	971,6	985,6	964,4	955,0	926,5	909,2	873,1	818,3
1200	933,3	936,9	950,2	924,7	916,0	889,9	873,2	839,1	783,5
1150	894,6	898,2	910,8	886,7	878,2	853,3	837,2	804,8	752,1
1100	855,9	859,4	871,4	848,8	840,3	816,8	801,1	770,4	720,7
1050	817,2	820,7	832,0	810,9	802,5	780,2	765,1	736,1	689,3
1000	778,5	782,0	792,7	772,9	764,7	743,6	729,1	701,8	657,9
950	739,3	742,9	753,4	734,0	726,2	706,0	691,6	665,2	623,7
900	700,1	703,8	714,1	695,0	687,6	668,3	654,0	628,5	589,5
850	660,9	664,8	674,8	656,1	649,1	630,7	616,5	591,9	555,3
800	621,7	625,7	635,6	617,1	610,6	593,0	579,0	555,2	521,1
750	581,2	584,4	593,2	576,1	569,8	553,0	539,5	516,7	484,8
700	540,7	543,1	550,9	535,0	528,9	513,0	499,9	478,2	448,5
650	500,1	501,8	508,6	493,9	488,1	472,9	460,4	439,7	412,3
600	459,6	460,5	466,2	452,9	447,3	432,9	420,8	401,2	376,0

Fuente. Méndez (2023)

Tabla 5: Valores de la temperatura para 0,5 k/s de flujo de aire.

Flujo másico 0,5 Kg/s								
Tabla 5. Temperatura de la superficie interna del tambor secador en base a la temperatura del quemador y el flujo másico del aire caliente.								
Temperatura (C°)	Longitud del secador (m)							
	0,5	1	1,5	2	2,5	3	3,5	4
1600	948,2	1101	1042,6	1070,5	1083,2	1090,5	1095,9	1095,8
1550	915,5	966,6	1006,9	1034,3	1046,5	1053,7	1059,1	1058,3
1500	882,9	932,2	971,3	998,1	1009,9	1016,9	1022,3	1020,9
1450	850,3	897,7	935,6	961,8	973,2	980,1	985,5	983,4
1400	817,7	863,3	899,9	925,6	936,5	943,2	948,7	945,9
1350	783,5	827,7	863,4	888,3	898,7	905,2	910,3	907,3
1300	749,4	792,1	826,8	850,9	860,8	867,2	871,8	868,8
1250	715,3	756,5	790,2	813,5	822,9	829,2	833,4	830,3
1200	681,1	720,9	753,7	776,1	785,1	791,2	795,0	791,7
1150	647,0	685,3	717,0	738,6	747,0	752,9	756,3	752,9
1100	612,8	649,7	680,3	701,0	708,9	714,6	717,5	714,1
1050	578,6	614,1	643,6	663,4	670,8	676,3	678,8	675,2
1000	544,5	578,5	607,0	625,9	632,7	638,0	640,1	636,4
950	510,7	543,3	570,7	588,8	595,3	600,3	601,9	598,2
900	476,9	508,2	534,4	551,7	557,9	562,6	563,6	559,9
850	443,1	473,1	498,2	514,7	520,5	524,9	525,4	521,7
800	409,4	438,0	461,9	477,6	483,1	487,2	487,2	483,4
750	378,0	405,0	427,7	442,5	447,6	451,5	451,2	447,4
700	346,6	372,1	393,5	407,4	412,1	415,7	415,3	411,3
650	315,2	339,1	359,3	372,3	376,6	380,0	379,3	375,3
600	283,9	306,2	325,1	337,2	341,1	344,3	343,4	339,3

Fuente. Méndez (2023)

Tabla 5 continuación: Valores de la temperatura para 0,5 k/s de flujo de aire.

Flujo másico 0,5 Kg/s									
Tabla 5 continuación. Temperatura de la superficie interna del tambor secador en base a la temperatura del quemador y el flujo másico del aire caliente.									
Temperatura (C°)	Longitud del secador (m)								
	4,5	5	5,5	6	6,5	7	7,5	8	8,5
1600	1082,0	1086,1	1085,2	1054,6	1037,7	965,3	907,4	798,8	76,7
1550	1044,2	1047,1	1040,1	1011,9	991,9	912,0	854,1	718,4	137,1
1500	1006,4	1008,1	994,9	969,2	946,0	858,7	800,9	638,0	197,5
1450	968,6	969,0	949,8	926,4	900,2	805,5	747,6	557,6	257,9
1400	930,9	930,0	904,7	883,7	854,3	752,2	694,4	477,2	318,4
1350	891,4	891,4	867,4	842,7	808,4	703,6	642,9	441,6	296,3
1300	851,9	852,7	830,1	801,7	762,6	655,0	591,4	405,9	274,3
1250	812,5	814,1	792,9	760,7	716,7	606,4	540,0	370,2	252,2
1200	773,0	775,5	755,6	719,8	670,8	557,7	488,5	334,5	230,2
1150	734,1	734,4	714,2	679,5	634,4	532,7	469,0	321,2	215,8
1100	695,2	693,3	672,8	639,2	597,9	507,6	449,5	307,9	201,3
1050	656,3	652,2	631,4	598,9	561,5	482,5	430,0	294,6	186,9
1000	617,4	611,1	590,1	558,6	525,1	457,4	410,5	281,3	172,5
950	578,6	573,0	553,7	519,5	484,3	415,1	369,2	252,5	157,8
900	539,8	534,8	517,3	480,3	443,4	372,8	327,9	223,8	143,1
850	501,0	496,6	480,9	441,2	402,6	330,5	286,7	195,0	128,4
800	462,3	458,5	444,6	402,1	361,8	288,3	245,4	166,2	113,7
750	426,1	327,7	407,0	366,5	329,8	258,6	222,5	152,2	104,5
700	390,0	196,8	369,4	330,9	297,8	228,9	199,5	138,1	95,2
650	353,9	66,0	331,8	295,4	265,8	199,2	176,6	124,1	86,0
600	317,8	-64,9	294,1	259,8	233,8	169,5	153,6	110,0	76,7

Fuente. Méndez (2023)

Tabla 6: Valores de la temperatura para 1,5 k/s de flujo de aire.

Flujo másico 1,5 Kg/s								
Tabla 6. Temperatura de la superficie interna del tambor secador en base a la temperatura del quemador y el flujo másico del aire caliente.								
Temperatura (C°)	Longitud del secador (m)							
	0,5	1	1,5	2	2,5	3	3,5	4
1600	1138,6	1190,1	1230,6	1259,1	1272,9	1285,0	1289,6	1288,8
1550	1103,1	1153,8	1192,9	1220,8	1233,8	1245,6	1250,0	1249,3
1500	1067,6	1117,5	1155,1	1182,4	1194,7	1206,2	1210,4	1209,9
1450	1032,2	1081,2	1117,4	1144,0	1155,6	1166,7	1170,8	1170,5
1400	996,7	1044,9	1079,6	1105,6	1116,5	1127,3	1131,1	1131,0
1350	962,9	1009,2	1042,7	1067,5	1078,2	1088,4	1092,1	1092,0
1300	929,1	973,5	1005,9	1029,4	1039,8	1049,5	1053,1	1053,0
1250	895,3	937,8	969,0	991,2	1001,5	1010,6	1014,0	1014,0
1200	861,5	902,2	932,1	953,1	963,1	971,6	975,0	974,9
1150	826,2	865,7	894,3	914,2	923,8	932,1	935,3	935,3
1100	791,0	829,2	856,4	875,2	884,5	892,6	895,7	895,7
1050	755,8	792,7	818,5	836,3	845,2	853,1	856,0	856,0
1000	720,6	756,2	780,7	797,3	805,9	813,6	816,3	816,4
950	650,9	682,1	704,3	719,0	726,9	733,8	736,2	736,3
900	616,0	645,0	666,1	679,9	687,3	693,9	696,2	696,2
850	581,2	608,0	627,9	640,8	647,8	654,0	656,1	656,1
800	581,2	608,0	627,9	640,8	647,8	654,0	656,1	656,1
750	545,2	570,6	589,2	601,2	607,8	613,6	615,6	615,6
700	509,2	533,2	550,5	561,7	567,7	573,2	575,1	575,1
650	473,2	495,8	511,8	522,2	527,6	532,8	534,6	534,6
600	437,2	458,3	473,2	482,7	487,6	492,4	494,1	494,1

Fuente. Méndez (2023)

Tabla 6 Continuación: Valores de la temperatura para 1,5 k/s de flujo de aire.

Flujo másico 1,5 Kg/s									
Tabla 6 continuación. Temperatura de la superficie interna del tambor secador en base a la temperatura del quemador y el flujo másico del aire caliente.									
Temperatura (C°)	Longitud del secador (m)								
	4,5	5	5,5	6	6,5	7	7,5	8	8,5
1600	1272,3	1270,1	1277,8	1266,1	1256,1	1227,9	1208,5	1170,8	1109,4
1550	1233,9	1234,1	1236,0	1227,8	1217,8	1190,5	1171,4	1135,1	1076,0
1500	1195,6	1198,0	1194,2	1189,6	1179,6	1153,1	1134,3	1099,4	1042,6
1450	1157,2	1162,0	1152,5	1151,3	1141,4	1115,7	1097,2	1063,6	1009,2
1400	1118,8	1126,0	1110,7	1113,1	1103,1	1078,2	1060,1	1027,9	975,8
1350	1080,5	1087,8	861,8	1075,6	1065,9	1042,1	1024,7	993,2	943,3
1300	1042,1	1049,6	612,9	1038,1	1028,8	1006,0	989,2	958,5	910,8
1250	1003,8	1011,4	364,0	1000,7	991,6	969,9	953,8	923,9	878,2
1200	965,5	973,2	115,1	963,2	954,4	933,7	918,4	889,2	845,7
1150	926,3	933,2	291,5	923,3	915,1	895,6	880,8	853,2	811,8
1100	887,2	893,2	467,8	883,3	875,7	857,5	843,3	817,1	777,9
1050	848,1	853,2	644,2	843,4	836,3	819,4	805,8	781,1	744,0
1000	809,0	813,2	820,6	803,5	796,9	781,3	768,3	745,0	710,1
950	729,4	732,7	739,5	723,4	718,1	705,1	693,5	672,9	642,2
900	689,5	692,4	698,9	683,4	678,7	666,9	656,1	636,8	608,3
850	649,7	652,2	658,4	643,3	639,3	628,8	618,7	600,8	574,3
800	649,7	652,2	658,4	643,3	639,3	628,8	618,7	600,8	574,3
750	609,7	612,0	615,0	604,1	600,1	590,2	580,6	563,8	539,1
700	569,6	571,7	571,6	565,0	560,9	551,6	542,6	526,8	503,9
650	529,5	531,5	528,2	525,8	521,7	513,1	504,5	489,9	468,8
600	489,4	491,3	484,8	486,6	482,5	474,5	466,5	452,9	433,6

Fuente. Méndez (2023)

Estas tablas, resultado de los procesos de simulación térmica en la superficie del tambor secador son de gran importancia para la creación del conjunto de datos (Dataset) que se utiliza posteriormente para el entrenamiento de la red neuronal en la inteligencia artificial del presente proyecto.

4.2.3 Velocidad de transferencia de calor, balances de masa y energía:

Considerándose que este tambor secador debe secar por media 7810 kg/h de negro de humo, con contenido inicial de humedad de 47,5% y se reduce a 1% sobre base seca, el calor específico es 0,711 j/g K (1,6981 Btu/lb °F) se estima la entrada del negro de humo a 28 °C (82.4°F) y se espera que la temperatura de salida del solido no supere los 100 °C (2012°F). Se dispone de aire caliente a 1100 °C (2012°F) y con un porcentaje de humedad menor al 0,5%. la velocidad másica del aire se calcula en base a el flujo másico de aire y el área de sección transversal del tambor.

- $\text{Área de sección transversal} = \pi r^2 = \pi(1,5/2)^2 = 1,76715 \text{ m}^2 = 19.0214 \text{ ft}^2$
- flujo de aire ejemplo: $6.23 \text{ kg/s} = 22428 \text{ kg/h} = 49445.276 \text{ lb/h}$
- velocidad másica del aire $(2000 - 25000 \text{ kg/h m}^2) = 12.691,62 \text{ kg/h m}^2 = 2599.5 \text{ lb/h ft}^2$

ya teniendo estos datos, se necesitan las temperaturas de bulbo húmedo para poder continuar con el análisis, para ellos se implementa la carta psicrométrica, se considera el secador adiabático, por lo cual la temperatura de bulbo húmedo a lo largo del tambor secador también se considera constante, además, mientras se encuentre en el proceso de secado constante se considera que la temperatura del bulbo húmedo es igual a la temperatura del sólido, en este caso el negro de humo secándose.

Para obtener la temperatura de bulbo húmedo se utilizó la aplicación web flycarpet.net, ingresando los datos de temperatura de entrada y la humedad del aire de entrada se obtiene la siguiente figura.




Figura 25: Carta psicrométrica web para la obtención de bulbo húmedo (www.flycarpet.net/en/PsyOnline).

Fuente. Méndez (2023)

La figura indica que la temperatura de bulbo húmedo del aire en la entrada son 78.459°C (173.226°F). Tendiendo la temperatura del bulbo húmedo se puede implementar la ecuación de número de unidad de transferencia de un secador con la finalidad de obtener la temperatura de bulbo seco en la salida del secador, esta ecuación toma la siguiente expresión.

$$N_t = \ln \frac{T_{hb} - T_{wb}}{T_{ha} - T_{wb}}$$

Siendo:

- T_{hb} =Temperatura del aire de entrada
- T_{ha} = *Temperatura del aire de salida*
- T_{wb} = *temperatura de bulbo húmedo*
- N_t =número de unidad de transferencia (valor entre 1,5-3)

suponiendo $N_t=1,5$ utilizando la ecuación se obtiene que:

$$1,5 = \ln \frac{2012^{\circ}F - 173.226^{\circ}F}{T_{ha} - 173.226^{\circ}F}$$

$$T_{ha}=583,509 \text{ }^{\circ}F (306,4^{\circ}C)$$

Para la continuación del estudio se aplica un balance de masa y energía. se deben tener entonces como datos preliminares, calor latente de vaporización, calor específico del sólido, calor específico del aire y el calor húmedo del aire de entrada. agrupando dichos datos se tienen que:

$$\lambda = \text{calor latente de vaporización del agua} = 2260 \text{ kJ/kg (971,63 Btu/lb)}$$

$$C_{pl} = \text{calor específico del líquido(agua)} = 4,1868 \text{ KJ/kg}^{\circ}C (1 \text{ Btu/lb }^{\circ}F)$$

$$C_{pv} = \text{calor específico del vapor} = 1,8841 \text{ KJ/kg }^{\circ}C (0,45 \text{ Btu/lb})$$

$$C_{ae} = \text{calor específico del aire de entrada} = 1,012 \text{ J/g}^{\circ}C (0,2417 \text{ Btu/lb }^{\circ}F)$$

$$C_{ps} = \text{calor específico del sólido (negro de humo)} 0,71 \text{ kJ/kg }^{\circ}C (0,1696 \text{ Btu/lb }^{\circ}F)$$

Los valores de los calores específicos se pueden visualizar en el anexo A, B, C y tabla 2 respectivamente.

Para obtener el calor húmedo del aire de entrada se emplea la siguiente expresión.

$$C_s = C_{ae} + C_{pv} * \text{humedad} = 1,012 \text{ J/g}^{\circ}C + 1,8841 \text{ KJ/kg}^{\circ}C * 0,005 = 1,02142 \text{ KJ/kg}^{\circ}C (0,244 \text{ Btu/lb }^{\circ}F).$$

Balance de masa en el sólido:

Para obtener la cantidad de agua extraída del negro de humo se implementa un balance de masa de agua del sólido, mediante la siguiente ecuación:

$$\dot{m}_v = \dot{m}_s(\Delta x)$$

Siendo:

- $\dot{m}_s = \text{Flujo masico sel negro de humo seco} = 2,17 \frac{\text{kg}}{\text{s}} = 7812 \text{ kg/h}$
- $(\Delta x) = \text{diferencia de humedades del sólido} = \text{humedad inicial} - \text{humedad final}$

$$\Delta x = 47\% - 1\% = 0,46$$

$\dot{m}_v = \text{masa de agua evaporada del sólido}$

$$\dot{m}_v = 7812 \frac{\text{kg}}{\text{h}} (0,46) = 3593,52 \text{ kg/h} = 0,99 \text{ kg/s} (3593,52 \text{ lb/h})$$

Balance de energía en el sólido (Negro de humo):

La cantidad de calor transferido por unidad de masa de sólido q_T/m_s , es.

$$\frac{q_T}{m_s} = c_{ps}(T_{sb} - T_{sa}) + X_a c_{pl}(T_v - T_{sa}) + (X_a - X_b)\lambda + X_b c_{pl}(T_{sb} - T_v) + (X_a - X_b)c_{pv}(T_{va} - T_v)$$

siendo:

- T_{sa} =temperatura de alimentación
- T_v =temperatura de vaporización, se toma la temperatura de bulbo húmedo.
- T_{sb} =temperatura final de los sólidos, se toma la temperatura esperada.
- T_{va} =temperatura final del vapor = T_{ha}
- λ =calor latente de vaporización
- $X_a = \text{humedad inicial}$
- $X_b = \text{humedad final}$
- $c_{ps}, c_{pl}, c_{pv} = \text{calores específicos del sólido, líquido y vapor, respectivamente.}$

$$\frac{q_T}{m_s} = c_{ps}(T_{sb} - T_{sa}) + X_a c_{pl}(T_v - T_{sa}) + (X_a - X_b)\lambda + X_b c_{pl}(T_{sb} - T_v) + (X_a - X_b)c_{pv}(T_{va} - T_v)$$

Para visualizar la ecuación se separan y resuelven cada una de sus partes por separado en el siguiente cuadro.

Cuadro 5: Resolución de ecuación del calor trasferido por unidad de masa.

$c_{ps}(T_{sb} - T_{sa})$	0,71(100-28)	51,12 kJ/kg (21.977btu/lb)
$X_a c_{pl}(T_v - T_{sa})$	0,475*4,1868(78,459-28)	100,349kJ/kg (43.14 btu/lb)
$(X_a - X_b)\lambda$	(0,475-0,001)2260	1071,24 kJ/kg (460,55 btu/lb)
$X_b c_{pl}(T_{sb} - T_v)$	0,001*4,1868(100-78,459)	0,0902 kJ/kg (0.0387 btu/lb)
$(X_a - X_b)c_{pv}(T_{va} - T_v)$	(0,475-0,001)*1,8841*(306,4-78,459)	203,565 kJ/kg (87.52 Btu/lb)
$\frac{q_T}{m_s}$		1426,124 kJ/kg (613.122Btu/lb)

El cálculo anterior es por kilo gramo de sólido, para obtener el calor total requerido multiplicamos por el flujo masico del negro de humo.

$$q_T = 7810 \text{ kg/h} * 1426,124 \text{ kJ/kg} = 11138030 \text{ kJ/h} (10556815.52 \text{ Btu/h})$$

Balance de energía del aire húmedo:

Para la obtención del flujo de aire volumétrico de aire requerido para realizar el proceso de secado se realiza un balance de energía:

$$q = C_s(T_{hb} - T_{ha}) \text{ suponiendo el calor húmedo } C_s \text{ constante, se tiene que:}$$

$$q = 1,02142 \text{ KJ/kg}^\circ\text{C} (1100^\circ\text{C} - 306,4^\circ\text{C}) = 810,6 \text{ kJ/kg} (348.49 \text{ Btu/lb})$$

Se considera negativo puesto que es calor que entrega el aire a el sólido.

Teniendo ya la cantidad de calor que entrega el aire al sólido se calcula el flujo de aire requerido con la siguiente expresión.

$$m_g = (q_T / q)$$

$$m_g = (11138030 \text{ kJ/h} / 810,6 \text{ kJ/kg}) = 12 \text{ 94,168 kg/h} (28532,596 \text{ Lb/h})$$

Debido a que se trabajó con calores específicos de aire húmedo se deben corregir los datos para obtener el flujo de aire seco requerido, ya que el aire tiene un porcentaje de humedad, para esto se implementa la siguiente expresión.

$$m_g = m_{as} * (1 + \%humedad)$$

$$m_{as} = \frac{m_g}{(1+\%humedad)} = \frac{12\,942.168\text{ kg/h}}{1+0,005} = 12877,78\text{ kg/h}(5536.45\text{ lb/h})$$

Balance de masa en el aire (balance de agua en el aire):

Para poder obtener la humedad absoluta en la salida se debe realizar un balance de agua en el aire y de este modo obtener el porcentaje de agua en aire en la salida, esto se realiza de la siguiente forma:

$$m_v = m_{as}(Y_a - Y_b)$$

$$3593,52\text{ kg/h} = 12877,78\text{ kg/h}(Y_a - 0,005)$$

$$Y_a = \%humedad\text{ en el aire en la salida} = 0,2840 = 28,40\%$$

Ya teniendo las características de masa y energía del tambor secador se procede con comprobar las dimensiones del mismo se utilizará la presente ecuación.

$$q_T = 0,125\pi DLG^{0,67}\underline{\Delta T}$$

Siendo:


D= Diámetro interno del tambor. ft

L=Longitud del tambor.

G= Velocidad másica del aire.

ΔT = Diferencias medias de temperatura, tomadas como una media logarítmica de las depresiones de bulbo húmedo en la entrada y salida del secador.

para calcular la diferencia media de temperaturas logarítmica se realiza el siguiente diagrama:



873,927°C (1582,2°F)

190,677°C(353,26°F)

Figura 26: Diagrama de temperaturas del tambor. (la parte de arriba representa el aire y la de abajo representa el sólido)

Fuente. Méndez (2023)

Con estos valores, se tiene que:

$$\underline{\Delta T} = \frac{2012^{\circ}F - 173,226^{\circ}F - (583,509^{\circ}F - 173,226^{\circ}F)}{\ln((2012^{\circ}F - 173,226^{\circ}F)/(583,509^{\circ}F - 173,226^{\circ}F))} = 952,323^{\circ}F$$

Se aplica la siguiente ecuación dimensional en la cual los datos tiene que estar en sistema inglés (btu, °F), se convierten entonces los datos faltantes a dicho sistema:

$$D=1,5 \text{ m} = 4.92126 \text{ pie}$$

$$q_T = 0,125\pi DLG^{0,67}\underline{\Delta T}$$

$$10556815.52 \text{ Btu/h} = 0,125\pi(4.92126 \text{ pie})L(2599.5 \text{ lb/h ft}^2)^{0,67}(952,323^{\circ}F)$$

$$L = 29,55 \text{ ft} = 9,007 \text{ m}$$

Queda confirmado entonces que las dimensiones del tambor están correctas para los valores de temperatura de entrada de aire caliente superiores a 1100 °C con una velocidad másica de flujo de aire de 12.691,62 kg/h m², se tiene que la cantidad de calor suministrada en el sistema de secado son 11138030 kj/h.

Al recalcular los datos pero suponiendo la temperatura de salida igual a la temperatura de bulbo húmedo, se puede obtener el punto en la longitud del tambor en la cual el negro de humo termina de secarse y ya seco empieza a ganar calor hasta la salida, esto debido a que el calor suministrado al negro de humo es calor latente, está destinado al cambio de estado de agua líquida a vapor de agua, significando que la temperatura se mantiene constante a temperatura de bulbo húmedo, además el proceso de evaporización del agua es constante, entonces la disminución del peso debido al secado también es constante, por lo cual el punto en donde se termina de secar el negro de humo es de gran interés para el siguiente apartado, en el cual se calculan los esfuerzos del tambor de acuerdo a la carga, siendo la carga principal el peso del tambor más la del negro de humo húmedo.

Por lo tanto, recalculando el balance de energía en el negro de humo para una temperatura de salida igual a la temperatura de bulbo húmedo se tiene que:

$$\frac{q_T}{m_s} = c_{ps}(T_{sb} - T_{sa}) + X_a c_{pl}(T_v - T_{sa}) + (X_a - X_b)\lambda + X_b c_{pl}(T_{sb} - T_v) + (X_a - X_b)c_{pv}(T_{va} - T_v)$$

donde: $X_b c_{pl}(T_{sb} - T_v) = 0$ y $c_{ps}(T_{sb} - T_{sa}) = 35,89 \text{ kJ/kg}$.

Cuadro 6: Segunda resolución de ecuación del calor transferido por unidad de masa.

$c_{ps}(T_{sb} - T_{sa})$	0,71(78,459-28)	35,89 kJ/kg (15.429btu/lb)
$X_a c_{pl}(T_v - T_{sa})$	0,475*4,1868(78,459-28)	100,349kJ/kg (43.14 btu/lb)
$(X_a - X_b)\lambda$	(0,475-0,001)2260	1071,24 kJ/kg (460,55 btu/lb)
$X_b c_{pl}(T_{sb} - T_v)$	0,001*4,1868(78,459-78,459)	0
$(X_a - X_b)c_{pv}(T_{va} - T_v)$	(0,475-0,001)*1,8841*(306,4-78,459)	203,565 kJ/kg (87.52 Btu/lb)
$\frac{q_T}{m_s}$		1411.044 kJ/kg (606.639Btu/lb)

El cálculo anterior es kilo julio por kilo gramo de sólido, para obtener el calor total requerido multiplicamos por el flujo masico del negro de humo.

$$q_T = 7810 \text{ kg/h} * 1411.044 \text{ kJ/kg} = 11020253.64 \text{ kJ/h} (10445185.07 \text{ Btu/h})$$

$$10445185.07 \text{ Btu/h} = 0,125\pi(4.92126 \text{ pie})L(2599.5 \text{ lb/h ft}^2)^{0,67} (952,323^\circ \text{F})$$

$$L = 29,243 \text{ ft} = 8.91 \text{ m} \text{ (punto donde el negro de humo se termina de secar)}$$

4.2.4 Calculo del tiempo de residencia del negro de humo dentro del tambor:

Como su nombre lo indica este es el tiempo idóneo en el cual el negro de humo debe permanecer dentro del tambor para efectuarse correctamente el intercambio de calor con el aire caliente y ser secado, para obtener este dato se resolvió un sistema de ecuaciones generado con los datos ya calculados anteriormente.

$$m_{secar} = z * V_t * \rho_s + m_v * T_{res}$$

donde:

- z =porcentaje de volumen que ocupa el negro de humo respecto al volumen del tambor (se supone 0,07 debido a condiciones normales de funcionamiento)
- T_{res} = tiempo idóneo de permanencia del sólido dentro del tambor.

- V_t, ρ_s y m_v son constantes, volumen del tambor ($15,9 m^3$), densidad del solido (negro de humo, $440 kg/m^3$) y masa de agua evaporada ($3593,52 kg/h$), respectivamente al sustituir y resolver se tiene que.
- $m_{secar} = 489,72kg + 3593,52 kg/h * T_{res}$ EC. 1

Del balance de energía del negro de humo en el proceso de secado se tiene que:

$$1426,124 kj/kg = \frac{Y kj}{m_{secar}} ; Ykj = \text{Cantidad de energía necesaria para el secado EC. 2}$$

$$11138030 kj/h = \frac{Y kj}{T}; \text{Siendo } T = T_{res} \text{ E.C 3}$$

Se sustituye EC. 1 en EC. 2

$$(489,72kg + 3593,52 kg/h T_{res}) * 1426,124 kj/kg = Y kj \text{ EC.4}$$

Se sustituye EC, 3 en EC.4

$$(489,72kg + 3593,52 kg/h) * 1426,124 kj/kg T_{res} = 11138030 kj/h T_{res}$$

Al resolver se tiene que:

$$T_{res} = 0,11614 h (6,96 \text{ min})$$

Esto significa que para una operación a capacidad del 7% respecto al volumen del tambor secador, el tiempo de permanencia del negro de humo dentro del mismo debe ser de 6,96 min para un correcto secado.

4.2.5 Análisis documental del medio corrosivo, corrosión a altas temperaturas con ambiente contaminado de CO₂:

Este apartado es una revisión y resumen documental de una investigación ya realizada en el trabajo de doctorado, Proy M (2013), **Corrosión a alta temperatura de acero al carbono y acero inoxidable austenítico en atmósferas contaminadas por CO₂** [Tesis de doctorado, Universidad Rey Juan Carlos]. En esta investigación Manuel Proy realiza un conjunto de pruebas a los materiales, acero al carbono 2.25Cr-1Mo y acero inoxidable 18Cr-8Ni (AISI 304), exponiéndose en ambientes a alta temperatura y concentraciones de CO₂ similares a procesos en la industria energética.

Este análisis se concentró en los resultados obtenidos de las pruebas realizadas en acero inoxidable 18Cr-8Ni, el cual es el mismo utilizado en el tambor secador del presente trabajo de grado.

De forma general a mayor temperatura, mayor y más rápido es el proceso de corrosión en metales, esto debido al fenómeno de difusión, el cual se hace mayor en condiciones de mayor

energía. Al suministrar calor a un sistema se aumenta la energía en el mismo, esto se visualiza en efectos como aumento de temperatura, cambios de estado o aumento de la reactividad en componentes químicos. Además, aunque se relacione continuamente la corrosión con la presencia de algún medio electrolítico líquido como el agua, en la corrosión a altas temperaturas este tipo de electrolitos por lo general no se encuentran presentes, por ende, los mecanismos de corrosión y degradación de metales a alta temperatura son diferentes, aun así, cambian aún más debido a la presencia de altas concentraciones de CO₂ en el ambiente.

En condiciones de concentración de CO₂ los mecanismos de corrosión que afectan al acero inoxidable presentan una morfología de ataque de corrosión localizada, este tipo de corrosión logra penetrar a través de la capa protectora que genera el acero inoxidable, permitiendo el acceso de elementos agresivos bajo la superficie protectora, esto genera un proceso de degradación interna en el material.

En la primera fase del proceso corrosivo, las especies catiónicas se comienzan a difundir a través del límite de grano, de acuerdo con Proy M et al. La difusión de estas especies como el cromo o el manganeso en los límites de grano o en zonas de acumulación de óxido de cromo trivalente (Cr₂O₃) son 100 veces mayor a todos los demás elementos para una temperatura de operación establecida.

Debido al proceso de difusión se produce un cambio microestructural en el sustrato. Inicialmente el microconstituyente principal es la austenita y durante las primeras etapas del proceso corrosivo aparece una fase de estructura BCC en la zona del sustrato adyacente a la película de productos oxidados. La difusividad de especies en estructuras de tipo BCC es más elevada que en la austenita y, por tanto, puede facilitar el desarrollo del proceso corrosivo. (Proy, 2013, Pág. 220)

De este modo, los mecanismos que se encuentran principalmente presentes en el proceso corrosivo son, primero, la oxidación externa de átomos de hierro, se ve favorecida por la ruptura de la película rica en cromo que inhibe la corrosión. Posteriormente se produce un exceso de concentración de agentes oxidantes que en conjunto con el fallo de la película protectora favorece la propagación mediante difusión de las especies corrosivas al interior, de modo que atraviesan la matriz de acero sin reaccionar para posteriormente hacerlo en el interior del sustrato metálicos.

Para visualizar la acción del medio corrosivo en el acero inoxidable 304 mediante los mecanismos descritos, se extrajeron un grupo de figuras que ilustran y resumen el proceso observado por Proy M.





Figura 27: Mecanismos de corrosión en el acero inoxidable a altas temperaturas y ambiente con CO₂.

Nota. 3A) Fe₂O₃, B3) Espinela rica en Ni, C3) Espinela rica en Ni, D3) Zona rica en cromo, A4) Oxidación intergranular, B4) Corrosión interna localizada, C4) Generación de películas internas discontinuas.

Fuente. Adaptado de *Corrosión a alta temperatura de acero al carbono y acero inoxidable austenítico en atmósferas contaminadas por CO₂* (P. 221-223), Proy M (2013).

En base a este comportamiento en la corrosión del acero inoxidable AISI 304, Proy M. midió la pérdida de masa por unidad de área a lo largo del tiempo del experimento, una de sus conclusiones fue que la tasa de pérdida de material es descrita por funciones de tipo parabólico esto es observable en las siguientes tablas y gráficos.

Gráfico 21: Pérdida de masa debido a corrosión por CO₂ a 750°C.




Fuente. Extraído de *Corrosión a alta temperatura de acero al carbono y acero inoxidable austenítico en atmósferas contaminadas por CO₂* (P. 221-223), Proy M (2013).

Tabla 7: Ecuación empírica resultante (Corrosión por CO₂ a 750°C).

Atmosphere	kinetic law	K_p [mg ² cm ⁻⁴ h ⁻¹]	R^2
air	$\left(\frac{\Delta m}{sup}\right)^2 = K_p t$	$(18 \pm 2)10^{-5}$	0.97183
air+CO ₂ (15%vol.)	$\left(\frac{\Delta m}{sup}\right)^2 = K_p t$	$(23 \pm 2)10^{-5}$	0.9816
air+ CO ₂ (25%vol.)	$\left(\frac{\Delta m}{sup}\right)^2 = K_p t$	$(61 \pm 6)10^{-5}$	0.9718

Fuente. Extraído de *Corrosión a alta temperatura de acero al carbono y acero inoxidable austenítico en atmósferas contaminadas por CO₂* (P. 221-223), Proy M (2013).

Gráfico 22: Pérdida de masa debido a corrosión por CO₂ a 850°C



Fuente. Extraído de *Corrosión a alta temperatura de acero al carbono y acero inoxidable austenítico en atmósferas contaminadas por CO₂* (P. 221-223), Proy M (2013).

Tabla 8: Ecuación empírica resultante (Corrosión por CO₂ a 850°C).

Atmosphere	kinetic law	$K_p [mg^2 cm^{-4} h^{-1}]$	R^2
aire	$\left(\frac{\Delta m}{sup}\right)^2 = K_p t$	$(12 \pm 3)10^{-4}$	0.9575
aire+CO ₂ (15%vol.)	$\left(\frac{\Delta m}{sup}\right)^2 = K_p t$	$(18 \pm 4)10^{-4}$	0.9634
aire+CO ₂ (25%vol.)	$\left(\frac{\Delta m}{sup}\right)^2 = K_p t$	$(22 \pm 4)10^{-4}$	0.9729

Fuente. Extraído de *Corrosión a alta temperatura de acero al carbono y acero inoxidable austenítico en atmósferas contaminadas por CO₂* (P. 221-223), Proy M (2013).

Como fue indicado las funciones de tipo parabólico fueron las que mejor se adaptaron al comportamiento del fenómeno de corrosión a altas temperaturas en presencia de atmósfera contaminada por CO₂, de modo que se extrajo la ecuación empírica que relaciona la superficie afectada con la pérdida de material para cierto tiempo de exposición, en base a una temperatura y porcentaje de CO₂ en el ambiente. Esta ecuación es semejante tanto para diferentes

temperaturas, como, concentraciones de carbono, siendo lo único que diferencia las expresiones es la constante k_p .

Debido a que el material del tambor secador del proyecto presenta las mismas cualidades del material utilizado en el experimento de Proy M, además de que, las temperaturas en la superficie del mismo son similares, se toma como aproximación las ecuaciones resultado del análisis para el uso en los cálculos y generación del grupo de datos (dataset) utilizado para el aprendizaje de la red neuronal de la siguiente fase.

4.2.6 Análisis de esfuerzos en el tambor secador mediante software CAD:

Para el análisis de esfuerzos en el tambor secador se debe conocer la carga a la cual éste estará sometido, como se delimitó en apartados anteriores, en un funcionamiento normal en el proceso de secado, el volumen ocupado por el negro de humo es equivalente a un 7% del volumen interno del tambor secador, tomando esto en cuenta y considerando el flujo masico calculado a inicios de esta fase, se toma de forma sencilla la masa continua de negro de humo que permanece dentro del tambor secador cuando la entrada y salida del solido es constante.

Se considera entonces la capacidad volumétrica ocupada por el negro de humo en el proceso de secado un 7% el volumen interno del tambor, el volumen del tambor es el volumen formado por la superficie interna del mismo el cual no es más que el volumen de un cilindro.

$$V_{tam} = 9m * \pi * \left(\frac{1,5m}{2}\right)^2 = 15,9 m^3; \text{ por ende, el volumen ocupado sería } 15,9 m^3 * 0,07 = 1,1133 m^3$$

teniéndose el volumen ocupado por el negro de humo se multiplica por la densidad del mismo $1,1133 m^3 * 440 \text{ kg}/m^3 = 489,854 \text{ Kg}$, esta sería la masa de negro de humo presente en el tambor en el proceso de secado, esta masa es constante, ya que hace referencia solo al negro de humo, hace falta sumarle la masa del agua que se evapora a medida que el negro de humo húmedo avanza en la longitud del tambor secador, se conoce que el porcentaje inicial de agua en el negro de humo es un aproximadamente un 47 %. Debido a que la tasa de evaporación del agua es constante, es una buena aproximación realizar una disminución lineal del agua en el sólido hasta el punto en el cual el negro de humo está completamente seco, este punto fue calculado anteriormente, siendo a los 8,91 m. De este modo, la carga generada por el negro de humo y el agua están directamente relacionadas a la distribución de su masa en el tambor, en base a lo planteado se presenta la siguiente figura.




Figura 28: Distribución de masa a lo largo del tambor secador.

Fuente. Méndez (2023)

En la figura se puede observar que mientras que la masa del negro de humo se mantiene constante a lo largo del tambor secador, la masa de agua va disminuyendo hasta el punto de total evaporación, se puede definir una función lineal que describa en este caso el comportamiento de secado del agua. siendo esta:

$$f(x) = mx + a$$

$$f(x) = -5,8x + 51,68$$

Debido a la variabilidad de masa de agua a lo largo del proceso se presentan mayor masa en la primera zona del tambor, para comprobar el efecto de dicha masa y el peso del mismo tambor, se realizó una simulación en SolidWorks (Figura 29), permitiendo cuantificar los esfuerzos y deformaciones en el tambor secador debido a el peso del sólido y liquido dentro del secador en el proceso además de la acción de la gravedad sobre este.





Figura 29: Simulación, análisis de esfuerzos en el tambor secador sin carga.

Fuente. Méndez (2023)


Gráfico 23: Tensiones de Von Mises a lo largo del tambor secador.



Fuente. Méndez (2023)

La gráfica 23 indica como dato el esfuerzo a lo largo de la sección transversal del tambor secador en toda su área, se puede observar como la mayor concentración de esfuerzos se encuentra en los apoyos. y en los extremos del tambor la menor concentración de esfuerzos, esta evaluación no considera carga más que el peso del mismo tambor secador, por lo cual esta simulación funciona como control respecto a las simulaciones posteriores, donde se aplican cargas de acuerdo a la capacidad operativa usadas con la finalidad de comparar la variación de los esfuerzos en base a la carga lo cual está directamente relacionado con la producción de negro de humo.

Gráfico 24: Comparación de tensiones de Von Mises para diferentes cargas.



Fuente. Méndez (2023)

Como se evidencia el cambio en la carga a la cual está sometida el tambor no genera cambios significativos tanto en la estructura de distribución de esfuerzos, como en los valores de los mismos, esto significa que la fuerza más predominante en el tambor es su propio peso y es la que genera los mayores esfuerzos en la estructura.

4.2.7 Criterio de falla (fatiga):

Como se indica en el apartado 4.2.5, el tipo de corrosión presente en el proceso secado es localizado, esto se proyecta la aparición y propagación de picaduras a lo largo de la superficie del tambor, siendo entonces este el tipo de corrosión principal presente en la degradación del acero inoxidable AISI 304, en base a esto se estima como criterio de falla la fatiga.

La corrosión por picaduras va de la mano con la fatiga, debido a que genera fragilización en el material eso permite las condiciones para la nucleación de grietas que tienden a propagarse debido a los esfuerzos axiales presentes en el tambor secador, todo esto en conjunto induce una disminución en el tiempo de vida útil del tambor además de una posible parada no planificada por una falla al final de la vida del secador.

Sabiendo esto, se plantea que el mayor efecto que puede tener el negro de humo sobre una falla en el tambor, es debido a la corrosión en el acero inoxidable mediante la concentración de carbono en ambiente de alta temperatura, el cual a lo largo del tiempo generaría zonas afectadas disminuyendo el área en la sección transversal mediante la producción de fisuras y grietas en el

tambor originando zonas concentradoras de esfuerzo, debido al giro del tambor los esfuerzos presentes en la superficie del mismo son cíclicos, variando en compresión y tracción respecto a el esfuerzo máximo en cada punto.

Es por esto y la formación de picaduras, que el criterio de falla para el tambor secador se encuentra enmarcado en la falla debido a fatiga, corrosión bajo tensiones cíclicas y degradación del material debido a ambiente contaminado por carbono. para tener un estándar de picadura se implementa la información de la siguiente figura.




Figura 30: Relación entre el espacio, tamaño y profundidad ocupado por picaduras.

Fuente. Extraído de *Corrosión por picadura*, Muñoz C (2014).

Para estimar en qué condiciones se encuentra el tambor secador para cada instante de tiempo se hace uso de la ecuación de las tablas 7 y 8, en esta podemos delimitar la cantidad de materia perdida debido a la corrosión a altas temperaturas en el tambor secador debido al ambiente contaminado por carbono, debido a que el mecanismo de corrosión que actual sobre la superficie del material es equivalente a una corrosión localizada, se puede asumir que la geometría formada por la pérdida de material localizado es en esencia una picadura. Para dimensionar las mismas, se toma la masa perdida debido a la corrosión como la masa perdida debido a la picadura, de este modo se puede estimar la profundidad específica de las picaduras al igualarlas en condiciones dimensionales.

A modo de simplificación se asume la geometría promedio de las picaduras como el volumen de un cono ($\frac{1}{3} * \pi * r * h$), con la finalidad de determinar la profundidad y densidad de las mismas en base a la pérdida de masa ocasionada por la corrosión.

Se calcula entonces la pérdida de masa para un tiempo de un año:

$$\left(\frac{\Delta m}{sup}\right)^2 = K_p t ; \text{ siendo, } K_p = 22 \times 10^{-4}, t = 8760 \text{ h, } sup = 94247,779 \text{ cm}^2$$

$\Delta m = 0,4137 \text{ kg}$; siendo que la densidad del acero AISI 304 es 8000 kg/m^3 , se estaría perdiendo en volumen el equivalente a, $5,17125 \times 10^{-5} \text{ m}^3 = 51712,5 \text{ mm}^3$.

Para picaduras con $h=0,4$ y $a = 0,5 \text{ mm}^2 \rightarrow r=0,39895 \text{ mm}$ el volumen medio de las mismas son: $V = \frac{1}{3} * \pi * 0,39895 \text{ mm}^2 * 0,4 \text{ mm} = 0.066669 \text{ mm}^3$. De modo que el número de picaduras presentes en esta sección del cilindro son: $51712,5 \text{ mm}^3 / 0.066669 \text{ mm}^3 = 775705,35$ picaduras, por lo tanto, la densidad de picaduras en un m^2 es: $775705,35 \text{ picaduras} / 9.4247 \text{ m}^2 = 8,2305 \times 10^4$ siendo demasiada área para el tamaño de picadura.

Aumentando el tamaño de picadura se tiene que para picaduras con $h=0,8 \text{ mm}$ y $a = 2.0 \text{ mm}^2 \rightarrow r=0,798 \text{ mm}$, $V = 0.522 \text{ mm}^3$; número de picaduras presentes = $51712,5 \text{ mm}^3 / 0.522 \text{ mm}^3 = 99156.9$ picaduras; la densidad de la picadura es $99156.9 \text{ picaduras} / 9.4247 \text{ m}^2 = 1,0520 \times 10^4$ picaduras/ m^2 .

En este último caso coincide la densidad de las picaduras con sus dimensiones. Debido a que estas dependen directamente de la masa perdida en el tambor secador, entonces esta sería la cantidad de picadura por metro cuadrado, cuando el tambor secador pierde masa debido al ambiente con concentraciones de carbono en un año.

En estas condiciones la profundidad de las picaduras es de $0,8 \text{ mm}$, ¿será suficiente para la nucleación de una grieta que pueda inducir una falla por fatiga?

Cabe resaltar que en este caso si no existiese ambiente corrosivo la nucleación de fisuras o grietas en la superficie ocuparía la mayor parte de vida útil del tambor, por lo cual tendería a fallar por alguna otra causa externa a la corrosión.

Para el cálculo de la velocidad de propagación de la grieta y el ciclo de vida del tambor secador en base a fatiga se utilizó la ley de Paris-Erdogan.

$$\frac{da}{dN} = C(\Delta K)^m$$

$$\Delta K = Y \Delta \sigma \sqrt{\frac{\pi a}{Q}}$$

Donde $\frac{da}{dN}$ es el incremento de longitud de la grieta por cada ciclo de fatiga y ΔK el intervalo cíclico del factor de intensidad de tensiones, definido anteriormente. C y m son constantes que dependen del material y se determinan experimentalmente, además R es la

relación existente entre $K_{min}/K_{max} = \sigma_{min}/\sigma_{max}$. el acero inoxidable aisi 304 se considera un acero resistente a la fatiga, el valor de las constantes de parís para el mismo son las siguientes:

$$\text{Tenacidad a la fatiga del acero} = K_i = 50 \text{ Mpa m}^{(1/2)}$$

$$m = 3$$

$$C = 5 \cdot 10^{-10} \text{ (m/ciclo)}$$

$R = \sigma_{min}/\sigma_{max}$ = Aunque se tiene esfuerzos tanto positivos como negativos R va a ser 0 esto debido a que la propagación de la grieta sólo se efectúa bajo esfuerzos de tensión, por lo que se considera $\sigma_{min} = 0$.

Y=factor de forma, debido que la grieta en este caso será formada a partir de una picadura, esta se sitúa en la superficie, por lo cual se aproxima el valor del factor de forma a 3,12. $Y=3,12$.

Por lo que tenemos que:

$$K_i = Y\sigma\sqrt{\pi a}; a = \text{longitud inicial de la grieta}, \sigma = \text{tensión máxima.}$$

$$a = 0,8 \text{ mm}$$

El valor de esfuerzo es tomado directamente de las simulaciones realizadas, en este caso para capacidades normales, siendo la capacidad de trabajo simulada de 0,13%, como se presenta en la siguiente figura.




Figura 31: Esfuerzos axiales máximos presentes en el tambor secador.

Fuente. Méndez (2023)

Los valores de esfuerzos axiales en dirección del eje X (dirección del flujo) rondan los valores de 1,201MPa, de modo que:

σ en condiciones de capacidad del 0,13%= 1,201MPa max

Lo que se desea calcular es cual es el tamaño de grieta para el cual el tambor falla por fractura.

$Kc=1,12*0,672Mpa * \sqrt{\pi a_c/Q}$; sustituyendo Kc por Ki = 50 Mpa m^(1/2), siendo Q=0,12
 $a_c=21.72mm$ tamaño de la grieta para el cual los esfuerzos rompen el material.

Para el cálculo de la vida útil del tambor secador en base a fatiga se implementa la ley de Paris:

$$\frac{da}{dN} = C(\Delta K)^m$$

Al resolver la ecuación diferencial se tiene que:

$$Nc = \frac{a_c^{(1-m/2)} - a_0^{(1-m/2)}}{C * y^3 * (\Delta\sigma)^m * (1 - \frac{m}{2})}$$

Al sustituir se tiene que:

$$Nc = \frac{21.0725^{(1-3/2)} - 0.8^{(1-3/2)}}{5 * 10^{\wedge} - 10 * 3.12^3 * (1.202)^3 * (1 - \frac{3}{2})} = 68264675 \text{ ciclos}$$

Esta es la cantidad de ciclos que se requiere para alcanzar la longitud de grieta donde se vuelven críticos los esfuerzos en los vértices de la grieta y se induce una fractura. al calcular los ciclos por año que realiza el tambor secador:

$$4 \text{ rpm} = 4 \text{ ciclos/min} * 60 * 24 * 5 * 4 * 12 = 1384400 \text{ ciclos/año}$$

Por lo cual la cantidad de ciclos necesarios para alcanzar la falla por fatiga para este caso es:

$$68246575 \text{ ciclos}/1384400 \text{ ciclos/año} = 49,3 \text{ años.}$$

Si la propagación de la grieta debido a la corrosión aumenta en el tiempo, esto representa un cambio en el factor a0 en la ley de Paris, disminuyendo el tiempo de vida útil restante del tambor secador. En esta ocasión, posterior a un año de trabajo, se estima en base a las grietas nucleadas en picaduras, que el tiempo de vida de un tambor secador es alrededor de 50,3 años, para el caso de falla por fatiga.

Esto sucede cuando como en el caso se toma la nucleación de grietas en vértices de picaduras con 0,8 mm de profundidad, no obstante el crecimiento y propagación de las picaduras puede en una primera instancia mas acelerado que la propagación de una grieta nucleada con tan poca profundidad, es por esto que en el apartado 4.3.1 en las graficas 25 y 26, se realiza una

comparación de la tasa de crecimiento de ambos fenómenos con la finalidad de obtener distancias críticas de nucleación de grietas en vértices de picaduras que reduzca considerablemente la vida útil del tambor secador.

4.3 Definición de los hiperparámetros óptimos en relación a las condiciones de trabajo del tambor, implementando lenguaje de programación Python:

En este apartado se realiza el diseño de la red neuronal, se define entonces tanto los parámetros de funcionamiento de la misma como las variables de entrada y salida en base a la información recopilada, calculada y simulada en fases pasadas.

4.3.1 Creación del conjunto de datos para el entrenamiento de la red (DataSet):

En este apartado se recopila toda la información ya obtenida, mediante investigación, cálculo y simulación, en la fase 1 y la fase 2, con la finalidad de generar un conjunto de datos que simulen el ciclo de vida del secador rotativo, esto es en esencia el dataset, no es más que una agrupación de datos ordenados, donde se guardan los valores de las variables que de forma indirecta o directa representan al tambor secador.

Cuadro 7: Variables dependientes e independientes principales en el DataSet.

Tiempo transcurrido (días)	Temperatura inicial del aire (°C)	Temperatura de la superficie interna(°C)	Posición de estudio en la longitud del tambor (m)	Perdida de masa debido a la corrosión por CO2 (mg)	Propagación de la grieta. (mm)
----------------------------	-----------------------------------	--	---	--	--------------------------------

Fuente. Méndez (2023)

Estas 6 variables son las variables iniciales, dependientes e independientes del sistema, en conjunto definen al tambor secador, ya que estas hablan de cuanto tiempo se encuentra operativo y las condiciones en las cuales trabaja, en base a estas variables, las cuales son la identidad de el tambor para un tiempo n.

La finalidad del conjunto de datos es ser utilizado para entrenar una red o conjunto de redes neuronales para la predicción de un valor específico que se desea conocer y no se posee en realidad.

Para este caso en cuestión se toma como valor interés el porcentaje de vida útil del tambor secador, puesto que el tiempo de funcionamiento del tambor es una variable que se conoce, tener el porcentaje de vida útil recorrido es directamente proporcional a obtener una fecha estimada para el fin de la vida del tambor, significando esto el estimar el tiempo de ocurrencia de la falla mucho antes de que suceda.

La misión es simular con los datos en el dataset la toma y medición de las variables principales ya mencionadas a lo largo del tiempo de varios tambores secadores y en base a esto que la inteligencia artificial mediante redes neuronales identifique la relación entre los valores del conjunto de datos y el porcentaje de vida recorrida del tambor.

Debido a la gran cantidad de datos que significa el simular la toma de información con frecuencia diaria de varias vidas de tambores secadores, no se puede implementar por esta tarea hojas de cálculo de Excel (no funciona de forma óptima con mucha cantidad de datos), además los datos no se pueden añadir de forma manual debido al tiempo que consumiría dicha acción.

Se opta por programar el dataset implementando para ello el lenguaje de programación Python, para facilitar la tarea se implementa como herramienta el entorno de programación Google Colaboratory, en conjunto con librerías de análisis de datos y cálculos numéricos como son numpy y pandas.

Numpy es una biblioteca de código abierto en lenguaje Python que se utiliza para la programación científica en Python, y, en particular, para la programación en Data Science, la ingeniería, las matemáticas o la ciencia, es una herramienta especialmente para las operaciones algebraicas como matrices y vectores.

Por otro lado, Pandas es una librería en lenguaje Python que se utiliza para el análisis y procesamiento de datos. Es manejada en el ámbito de data science y machine learning, ya que ofrece estructuras fuertes y flexibles que facilitan la manipulación y tratamiento de datos.

De primera instancia se necesita una base de la cual partir, en este caso se toma de referencia el diseño del tambor secador realizado en el apartado 4.2.3, específicamente se observa que las dimensiones del tambor y el secado del negro de humo funcionan para una temperatura en el quemador de 1100°C, por lo cual se toma este valor como base para la temperatura de trabajo, debido a que esta temperatura varía levemente, se induce un factor de error de $\pm 50^\circ\text{C}$, por lo cual la temperatura del quemador en el tambor secador variara a través del tiempo en el rango de 1050°C a 1150°C. sabiéndose esto y que otra de las variables importantes del conjunto de datos es la temperatura de la superficie, se toman los resultados de las simulaciones térmicas del tambor secador del apartado 4.2.2 en la fase anterior (Apéndice 4).

De estas simulaciones se obtuvo una relación entre la temperatura del quemador y la superficie del tambor sector, donde se visualiza que, aunque la temperatura inicial se encuentre en el orden de los 1100 °C, la temperatura en la superficie del tambor no supera los 950 °C.

Estos datos se convierten en un archivo csv (valores separados por comas), para ser cargador al entorno de Google Colaboratory y sea más sencillo la lectura y análisis del mismo con herramientas de la librería pandas, esto se visualiza en el siguiente segmento de código, donde se carga el archivo csv a colab, se convierte en un dataframe y se generan las primeras variables principales del dataset, los días transcurridos, la temperatura inicial (temperatura del quemador) y la temperatura de la superficie.

Debido a la finalidad de entrenamiento que tienen el conjunto de datos, para indicar la posición a lo largo del tambor de donde se extraen la información de forma numérica, se crea una nueva columna para cada punto de la superficie específico y se le asigna una variable booleana en forma de 1 para indicar que se está haciendo referencia dicha posición y 0 para indicar que no.

A continuación, se presentan los pasos realizados para la ejecución código que permite la generación de los conjuntos de datos:

1 Importación de librerías:

```
import numpy as np
import pandas as pd
import random as rd
```

2 Cargado del csv (apéndice 4):

```
tem05csv=pd.read_csv("TEM KS 05.csv")
```

3 Generación de los días transcurridos:

```
l=[]
ran=50000
for i in range (ran):
    for j in range (17):
        l.append(i+1)
```

4 Generación de temperaturas iniciales en base al csv:

```
ti=[]

for i in range (ran):
    x=rd.randint(0,2)
    z=tem05csv["Temperatura"][x]
    for i in range (17):
        ti.append(z)
ds={"dias":l, "Temperatura inicial":ti}
df=pd.DataFrame.from_dict(ds)
```

5 Conversión de los valores de posición a lo largo del tambor en variables booleanas (ciclo realizado para cada longitud):

```

l1=[]
for i in range (ran):
    for j in range (17):
        x=j
        if x==0:
            l1.append(j+1)
        else:
            l1.append(0)
df["L 0.5"]=l1

```

6 Cálculo y anexo de la columna “Temperatura de la superficie”:

```

ts=[]
for i in range (ran):
    x=i*17
    y=df["Temperatura inicial"][x]

    if y==1050:
        for i in range (17):
            w=tem05csv.iloc[2][i+1]
            ts.append(w)
    elif y==1100:
        for i in range (17):
            w=tem05csv.iloc[1][i+1]
            ts.append(w)
    else:
        for i in range (17):
            w=tem05csv.iloc[0][i+1]
            ts.append(w)

df["Temperatura de la superficie"]=ts
df

```

Con esto, se consiguen ordenar entonces las primeras variables de interés, los días transcurridos, la temperatura inicial, las posiciones a lo largo de la longitud del tambor y la temperatura de la superficie, respectiva a cada posición y a la temperatura inicial. Al imprimir se muestra el siguiente arreglo.

	dias	Temperatura inicial	L 0.5	L 1	L 1.5	L 2	L 2.5	L 3	L 3.5	L 4	L 4.5	L 5	L 5.5	L 6	L 6.5	L 7	L 7.5	L 8	L 8.5	Temperatura de la superficie
0	1	1150	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	646.961061
1	1	1150	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	685.304914
2	1	1150	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	717.010884
3	1	1150	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	738.574015
4	1	1150	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	746.991165
...
849995	50000	1100	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	597.935693
849996	50000	1100	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	507.565430
849997	50000	1100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	449.461481
849998	50000	1100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	307.897756
849999	50000	1100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	201.332317

Figura 32: Arreglo inicial del set de datos.

Fuente. Méndez (2023)

De primera instancia no se se conoce cual va a ser el día en va a fallar el tambor secador, por lo cual la columna de días transcurridos se llena con una cantidad de días suficiente para que cualquier punto del tambor haya fallado, en este caso se usan 50000 días.

Posterior a esto se añadió la columna de la masa perdida debido a la corrosión por CO2 en el acero inoxidable AISI 304. Esta relación está comprendida en las ecuaciones empíricas de Proy. M (2013), Tabla 7 y Tabla 8.

$$\left(\frac{\Delta m}{sup}\right)^2 = K_p t$$

Para el cálculo la masa perdida, se relacionó la temperatura de la superficie en cada punto, con el paso del tiempo y la superficie en cuestión, se interpola la constante Kp dependiendo de la temperatura de la superficie en cada zona específica del tambor secador. Esto permio calcular la masa perdida a lo largo del tiempo, pero debido a que la temperatura en la superficie del material no es constante en el tiempo, puesto que la temperatura del quemador tampoco lo es, entonces la pérdida de masa también varia, para resolver esto y aproximarlo a la realidad, se realiza el siguiente arreglo.

Se calcula la perdida de masa del día en cuestión, para el día siguiente se hace lo mismo y se comparan, se obtiene la diferencia de masas, se realiza esto con todos los días y posteriormente se realiza par cada día una sumatoria de la masa perdida de todos los días anteriores, generándose el dato de la masa perdida de forma acumulativa, con varianza de temperatura y factor Kp. Esto se visualiza en el siguiente código:

7 Definición de función para la interpolación de la constante Kp:

```
def kvalor (t):  
    if t < 800 and t > 766:  
        y0=0.0015  
        x0=766  
        x1=800  
        y1=0.0026  
        t=(y0)+((t-x0)/(x1-x0))*(y1-y0)  
    elif t < 766 and t > 700:  
        y0=0.00066
```

```

x0=700
x1=766
y1=0.0015
t=(y0)+((t-x0)/(x1-x0))*(y1-y0)
elif t < 700 and t > 412:
y0=0.0003
x0=412
x1=700
y1=0.00066
t=(y0)+((t-x0)/(x1-x0))*(y1-y0)
else:
y0=0
x0=0
x1=412
y1=0.0003
t=(y0)+((t-x0)/(x1-x0))*(y1-y0)
return t
sup=235
kp=[]
t=[]
mk=[]
for i in range (len(df['L 0.5'])):
x=df["Temperatura de la superficie"][i]
kp.append(kvalor(x))
t.append(df["dias"][i])
for i in range (len(df["L 0.5"])):
k=kp[i]
te=t[i]*24
sup=235
mk.append(np.sqrt(k*te)*sup)

```

8 Se anexa la columna “Masa perdida de forma acumulativa mg”:

```

mk1=[]
for i in range (len(df["L 0.5"])):
if i >= 17:
if mk[i] > mk[i-17]:
r=mk[i]-mk[i-17]
mk1.append(r)
else:
r=mk[i-17]-mk[i]
mk1.append(r)
else:
o=mk[i]
mk1.append(mk[i])
mkk=[]

```

```

for i in range (len(df["L 0.5"])):
    if i >= 17:
        r=mkl[i]+mkl[i-17]
        mkk.append(mkl[i]+mkk[i-17])
    else:
        mkk.append(mkl[i])
df["Factor K"]=kp
df["Masa perdida de forma acumulativa mg"]=mkk

```

El resultado hasta este código al imprimir es el anexo de dos nuevas columnas al dataset de la figura 32, siendo la columna del valor del factor Kp y la columna con los valores de la masa perdida de forma acumulativa a lo largo del tiempo en miligramos.

El siguiente paso realizado fue el estudio de la longitud de la picadura en relación a la masa perdida, se obtuvo el volumen perdido de forma acumulativo a lo largo del tiempo, al usar la densidad del acero inoxidable AISI 304 de la tabla 1, y la ecuación de la densidad, densidad=masa/volumen, al sustituir la densidad del acero inoxidable 304 (8000 kg/m³) y la masa por los valores ya calculados, se obtiene el volumen perdido para cada día transcurrido. Se hace más simple la geometría de la picadura al suponerla aproximada a la geometría de un cono, y tanto para un área de base, como una superficie de propagación constante, la profundidad de la picadura sería aproximada a altura del volumen cónico. Esta idea fue llevada a cabo mediante el siguiente segmento de código.

9 Calculo y anexo de la columna “Volumen de material perdido mm³”:

```

volper=[]
for i in range (len(df["L 0.5"])):
    h=((df["Masa perdida de forma acumulativa mg"][i]))/8
    volper.append(h)
df["Volumen de material perdido mm3"]=volper

```

10 Calculo y anexo de la columna “profundidad de la picadura mm”:

```

cpic=0.01*(3*3.1416*750*500)
hcon=[]
for i in range (len(df["L 0.5"])):
    v=df["Volumen de material perdido mm3"][i]
    volcon=v/cpic
    hcon.append(3*volcon/(2))

df["profundidad de la picadura mm"]=hcon

```

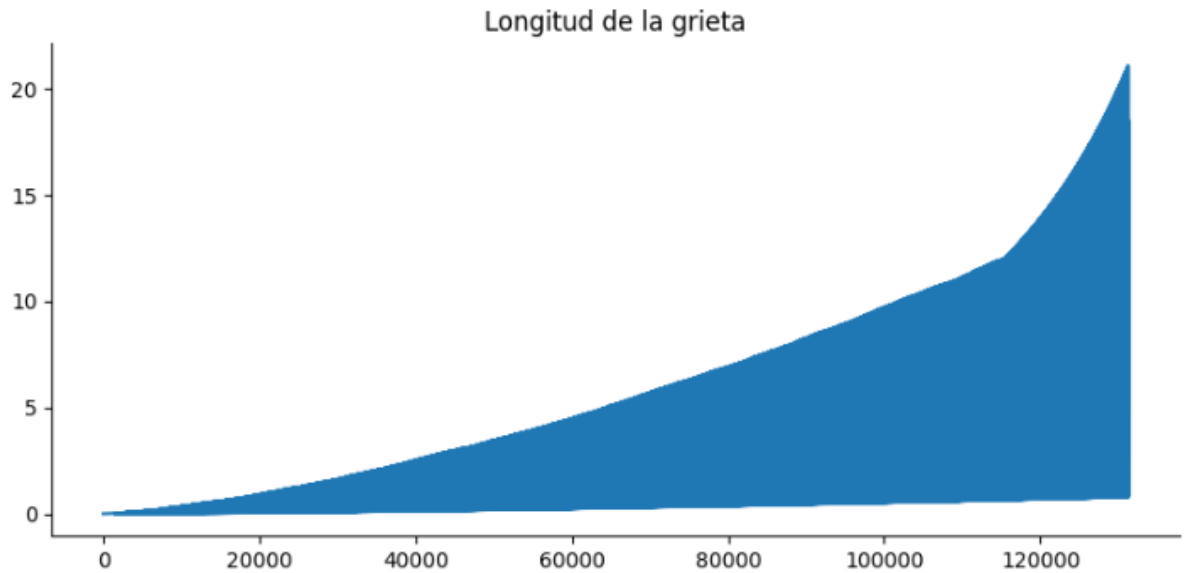
Posterior a identificar la profundidad de la picadura utiliza este dato para obtener uno de los factores más importantes en la definición del estado del tambor, partiendo del análisis de

criterio de falla realizado en el apartado 4.2.7 de la fase anterior, se visualiza que cuando la nucleación de una grieta sucede con poca profundidad de picadura la velocidad de crecimiento de la grieta es lenta, siendo que si solo dependiera de esta un tambor secador duraría en base a este criterio de falla alrededor de 50 años de servicio, no obstante, en la realización del data set al implementarse la ley de Paris-Erdogan.

$$Nc = \frac{ac^{(1-m/2)} - a0^{(1-m/2)}}{C * y^3 * (\Delta\sigma)^m * (1 - \frac{m}{2})}$$

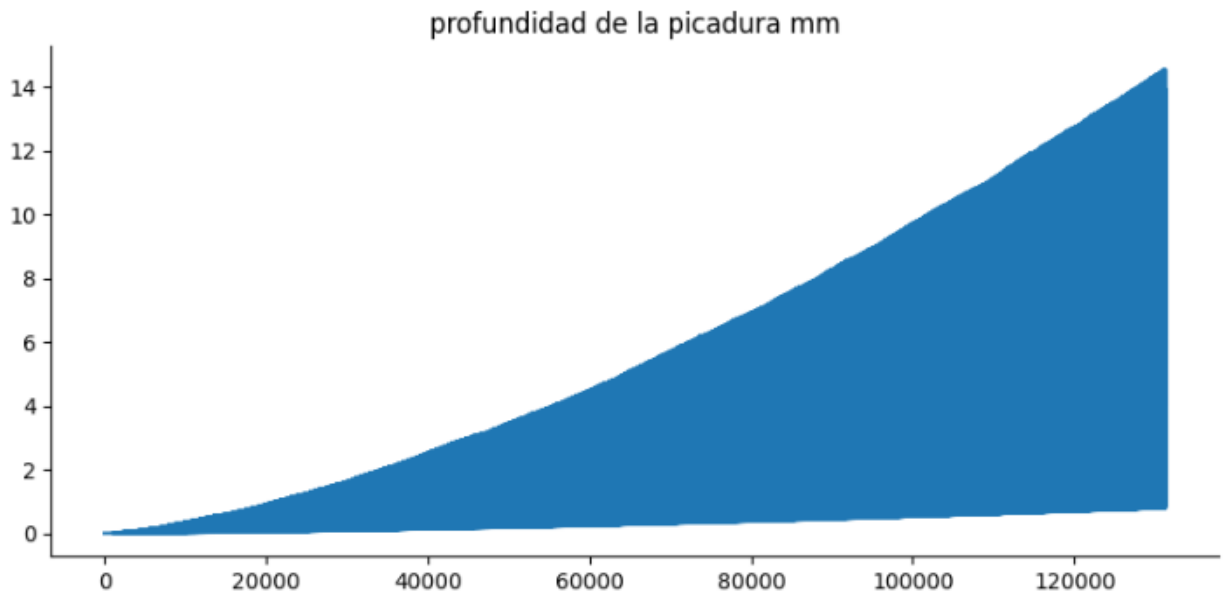
Se plantea el uso de la ecuación, pero en este caso se realiza una comparación de la tasa de crecimiento de la longitud de picadura con la tasa de crecimiento con de la grieta debido a la fatiga, estas dos se pueden visualizar en los siguientes gráficos.

Gráfico 25: Crecimiento de la grieta desde la superficie.



Fuente. Méndez (2023)

Gráfico 26: Aumento de la profundidad de la picadura.



Fuente. Méndez (2023)

Esta grafica esta realizada en base a los datos de un solo tambor secador, se puede visualizar que en un primer momento ambas presentan similitud, esto debido a que el Dataset fue diseñado con la idea de que mientras la longitud de la picadura sea mayor a la de la grieta, el punto más crítico va ser el vértice de la picadura, a partir de ahí puede nuclear una grieta, pero mientras la tasa de crecimiento de la picadura sea mayor al de la grieta, solo la picadura estará presente.

De forma diferente sucede al final de la gráfica 26, donde la naturaleza de crecimiento potencial de la propagación de la grieta supera el crecimiento de la picadura, nucleándose si una grieta en el vértice de la picadura que continuara expandiéndose hasta fracturar el material.

Todo esto esta representado en las siguientes líneas de código donde en base a esta lógica se anexa una columna al set de datos, la cual indica la longitud de la grieta para un instante dado en el ciclo de vida del tambor, además se añade una columna extra la cual indica de forma binaria si el secador se encuentra en estado de falla o no, tomando como criterio la longitud de propagación de la grieta y específicamente el fallo del material cuando esta se encuentra en valores mayores a 21.05mm.

11 Cálculo y anexo de la columna “Longitud de la grieta”, el segundo ciclo for se repite para cada posición del tambor con un valor diferente de Cn:

```
Nc=float(5371779.55)
c=float(0.0000000005)
y=float((3.12)**3)
o=float((1.202)**3)
pot=float(1-(3/2))
ac=float(21.0725)
acpot=float(21.0725**pot)
raizna=1/(1-(3/2))
ao=float(((Nc*c*y*o*pot)-ac)**raizna)
ao2=1
NC2=float((acpot-ao2**pot)/c*y*o*raizna)
ver=[]
for i in range(len(df['L 0.5'])):
    f=df["profundidad de la picadura mm"][i]
    if f >= 12:
        ver.append(1)
    else:
        ver.append(0)
vg=[]
c0=0
c1=0
for i in range(len(df['L 0.5'])):
    x=ver[i]
    if x==0:
        vg.append(df['profundidad de la picadura mm'][i])
    elif x==1 and df['L 0.5'][i]==1:
        c1=c1+1
        u=Nc-(c1*5760)
        vg.append(float(((u*c*y*o*pot)-acpot)**raizna))
```

```
df["Longitud de la grieta"]=vg
```

12 Calculo y anexo de columna “¿FALLO? 0=NO 1=SI”:

```
e=[]
for i in range (len(df['L 0.5'])):
    v=df["Longitud de la grieta"][i]
    if v > 21.05:
        e.append(1)
    else:
        e.append(0)
df["FALLO? 0=NO 1=SI"]=e
```

En este punto se añaden como columnas, la longitud de la grieta y el estado de falla del tambor, para finalizarse el dataset solo falta una cosa. Al inicio se habían definido los días transcurridos como 50000, esto debido a que se desconocía el día exacto en el cual el tambor secador iba a fallar, no obstante, al añadirse la columna de longitud de grieta y tomándose el criterio que indica que para toda grieta mayor que 21.1mm el material falla por fatiga, se comprende que para el día en el cual el valor en la columna “longitud de grieta” sea cercano a 21.1 este será el día final del ciclo de vida del tambor simulado, puesto que fallará. Se realiza entonces una búsqueda en cada punto específico de longitud del tambor secador, hasta el primer número inmediatamente mayor a 21.1mm el resto de filas posteriores se borrarán, quedando así solo las filas necesarias para representar el ciclo de vida completo del material en cada punto de la longitud del tambor secador. Esto se realiza de la siguiente forma.

13 Limpieza de filas innecesarias:

```
df11=df[df['L 0.5']==1].reset_index(drop=True)
index = df11[df11['Longitud de la grieta'] > 21.1].index[0]
df11 = df11.iloc[:index]
ds=pd.concat([df11,df12,df13,df14,df15,df16,df17,df18,df19,df110,df111,df112,df113,df114,df115,df116,df117]).reset_index(drop=True)
ds = ds.sample(frac=1)
```

De esta forma se tiene listo un código que puede generar conjuntos de datos representativos de información que definen el estado del tambor secador a lo largo de toda su vida útil, simulando si un levantamiento de información mediante rutinas de mantenimiento con frecuencia diaria, para visualizar el código completo ver (apéndice 5). para los sets de datos finales se unieron 3, 5 y 10 dataframes de tambores secadores simulados, generando en conjunto un grupo de datos ordenados que intrínsecamente contienen todo el historial de vida de cierta cantidad de tambores secadores, los cuales servirán como información para el entrenamiento de

redes neuronales que permitan predicciones respecto a la ocurrencia y lugar de falla en el tambor, el apéndice 1 y 2 son ejemplos de set de datos credos mediante el código descrito.

dias	Temperatura inicial	L 0.5	L 8	L 8.5	Temperatura de la superficie	Factor K	Masa perdida de forma acumulativa mg	Volumen de material perdido mm3	profundidad de la picadura mm	Longitud de la grieta	FALLO? 0=NO 1=SI	% Vida transcurrida	
77031	5710	1100	0	0	0	708.906894	0.000773	1.529726e+06	191215.784940	8.115431	8.115431	0	0.6804
38263	13507	1100	0	0	0	649.688966	0.000597	9.645537e+05	120569.208643	5.117104	5.117104	0	0.5459
186465	4635	1050	0	0	0	482.480040	0.000388	1.626147e+05	20326.835500	0.862696	0.862696	0	0.1678
215758	6305	1100	0	0	0	449.461481	0.000347	2.218630e+05	27732.878457	1.177017	1.177017	0	0.2060
108390	4983	1150	0	0	0	734.092026	0.001094	9.981712e+05	124771.405666	5.295451	5.295451	0	0.5205
...
297443	9030	1100	0	0	1	201.332317	0.000147	2.506779e+05	31334.734153	1.329884	1.329884	0	0.2263
301372	12959	1150	0	0	1	215.751043	0.000157	4.317707e+05	53971.332570	2.290609	2.290609	0	0.3248
27388	2632	1050	0	0	0	614.073018	0.000553	8.334141e+04	10417.676122	0.442139	0.442139	0	0.1064
326003	37590	1150	0	0	1	215.751043	0.000157	2.142683e+06	267835.431171	11.367262	11.367262	0	0.9421
183372	1542	1150	0	0	0	532.650820	0.000451	3.178550e+04	3973.187525	0.168627	0.168627	0	0.0558

328313 rows × 27 columns

Figura 33: Segmento de data set del ciclo de vida de un tambor se secador simulado.

Fuente. Méndez (2023).

4.3.2 Diseño de la red neuronal y definición de hiperparametros:

Una red neuronal es un tipo de algoritmo de aprendizaje automático que intenta emular la forma en que funciona el cerebro humano. En este caso el objetivo será el reconocimiento de patrones en los datos con la finalidad de predecir o clasificar el estado del tambor secador de modo que se pueda obtener de forma directa o indirecta el porcentaje de vida transcurrida y en base a esto estimar las fechas tentativas de ocurrencia de la falla.

Existen diferentes modelos de red neuronal con estructuras con finalidades diferentes, hay que evaluar entonces cual estructura de red neuronal se adecua de mejor forma al set de datos a utilizar. Entre los modelos de red neuronal más comunes se encuentran:

- Redes neuronales hacia adelante: primer y más simple tipo. En esta red, la información se mueve solo desde la capa de entrada directamente a través de cualquier capa oculta hasta la capa de salida sin ciclos/bucles.
- Perceptrón multicapa: El perceptrón multicapa es una red neuronal hacia adelante con una o más capas ocultas.

- Redes neuronales convolucionales: Las redes neuronales convolucionales son un tipo especializado de red neuronal que se utiliza comúnmente en aplicaciones de procesamiento de imágenes.
- Redes neuronales recurrentes: Las redes neuronales recurrentes son un tipo de red neuronal que tiene conexiones entre unidades en diferentes momentos, lo que les permite tener memoria y procesar secuencias de entrada.
- Redes neuronales de clasificación: Una red neuronal de clasificación es un tipo de modelo de aprendizaje automático que se utiliza para clasificar datos en diferentes categorías. Estos modelos aprenden a partir de datos etiquetados y luego utilizan ese conocimiento para hacer predicciones sobre nuevos datos no etiquetados.

Para este caso se selecciono el modelo de red neuronal de clasificación, se consideró que los valores del porcentaje de vida transcurrida del dataset se pueden ajustar a etiquetas representativas de segmentos de vida del tambor, así agrupando conjuntos de datos en una misma clase representativa.

Cuadro 6: Ejemplo de agrupación de clases de acuerdo al valor de “% de vida transcurrido” en el valor más cercano múltiplo de 5

Valor “% de vida transcurrido”	0.5	1	2.698	4.86	11	13	14	16	17	22	25	27
Etiqueta de clase asignada	0	0	5	5	10	15	15	15	20	20	25	30

Fuente. Méndez (2023).

Como es observable en el ejemplo del cuadro anterior, se puede asignar como clase un número cercano, en este caso se redondea el valor hacia el múltiplo de 5 mas cercano y se denota este como la clase a la cual pertenece, así obteniéndose 21 clases (contando la clase 0) para cualquier cantidad de valores comprendidos en el intervalo de 0 a 100.

Surge la duda de en cuantas clases deberían ser divididos estos valores, lo ideal sería tener la mayor cantidad de clases para tener mayor precisión de acuerdo a los datos originales, pero eso significaría tener 100 clases para poder redondearse al numero entero mas cercano o 1000 para redondearse al múltiplo de 0.1 más cercano. En base a esta solución se toma el modelo de clasificación como modelo de red neuronal implementado.

La clasificación multiclase es un problema complejo de resolver por sí solo, por lo que, para afrontarlo se debe tener una estrategia, en si un modelo de clasificación multiclase, debe ser capaz de resolver problemas de clasificación cuando se tienen mas de 3 categorías distintas, esto

en si suele ser más difícil que un problema de clasificación binaria (solo dos clases), ya que se tienen muchas más categorías y se deben distinguir entre los datos que identifica a cada una de las clases, haciendo el sistema mucho más complejo.

Es por esto que, se implementa la estrategia “one for all” (uno contra todos), este se basa en que, en lugar de entrenar un solo modelo para clasificar múltiples clases, se entrena un modelo por cada clase. Cada modelo se entrena para distinguir una clase de todas las demás clases. Esto en esencia es transformar un problema de clasificación multiclase en muchos problemas de clasificación binaria más sencillos.

Teniendo el modelo a aplicar y la estrategia a seguir se comienza con la programación de la inteligencia artificial. En este caso se implementa como entorno de programación una libreta de kaggle (entorno de ciencia de datos), se utiliza por el beneficio de aceleradores de gpu que ofrece este entorno, disminuyendo así los tiempos de entrenamiento de la red. Las librerías usadas en este caso se basen en pandas y keras (herramienta dedicada a la creación de redes neuronales).

El siguiente código muestra los pasos realizados por la programación de la arquitectura de red neuronal y el entrenamiento de modelos:

1 Importación de librerías:

```
import pandas as pd
from keras.models import Sequential
from keras.layers import Dense
from keras.wrappers.scikit_learn import KerasClassifier
from keras.utils import np_utils
from sklearn.model_selection import cross_val_score
from sklearn.model_selection import KFold
from sklearn.preprocessing import LabelEncoder
from sklearn.pipeline import Pipeline
```

2 Carga del dataset (creado en el apartado anterior 4.3.1, apéndice 1):

```
dataframe = pd.read_csv('EL_DATASET3')
```

En primera instancia se trabajó con todos los datos de dataset y con 10000 clases, con la finalidad de tener una precisión alta a la hora de realizar las predicciones, pero, existe una limitante en el momento de entrenar redes neuronales, y son, las capacidades computacionales, si se trabaja con la cantidad de datos que contiene el dataset en cuestión (alrededor de 900000 filas y 27 columnas llenas de información), y la cantidad de clases planteada de 10000, los tiempos de entrenamiento se vuelven exageradamente largos.

En ejecución (7 h 6 min 26 s) <cell line:... > cross_val_s...

Figura 34: Tiempo de entrenamiento utilizando todos los datos del dataset y 10000 clases.

Fuente. Méndez (2023).

Debido a esto se plantea la disminución de los datos en muestras representativas, y la disminución de clases, se termino optando por trabajar con 20 clases y trabajar con una muestra de alrededor de 4000 filas de datos, sacrificando precisión y haciendo los tiempos de entrenamiento posibles. Esta modificación se visualiza en el siguiente segmento de código.

3 Ajuste del set de datos para su clasificación y disminución de datos:

```
dataframe['% Vida transcurrida']=(dataframe['% Vida
transcurrida']/0.05).round() * 0.05
df1=dataframe[dataframe['% Vida transcurrida']==0].reset_index(drop=True)
df2=dataframe[dataframe['% Vida
transcurrida']==0.05].reset_index(drop=True)
df3=dataframe[dataframe['% Vida
transcurrida']==0.1].reset_index(drop=True)
df4=dataframe[dataframe['% Vida
transcurrida']==0.15].reset_index(drop=True)
df5=dataframe[dataframe['% Vida
transcurrida']==0.2].reset_index(drop=True)
df6=dataframe[dataframe['% Vida
transcurrida']==0.25].reset_index(drop=True)
df7=dataframe[dataframe['% Vida
transcurrida']==0.3].reset_index(drop=True)
df8=dataframe[dataframe['% Vida
transcurrida']==0.35].reset_index(drop=True)
df9=dataframe[dataframe['% Vida
transcurrida']==0.4].reset_index(drop=True)
df10=dataframe[dataframe['% Vida
transcurrida']==0.45].reset_index(drop=True)
df11=dataframe[dataframe['% Vida
transcurrida']==0.5].reset_index(drop=True)
df12=dataframe[dataframe['% Vida
transcurrida']==0.55].reset_index(drop=True)
df13=dataframe[dataframe['% Vida
transcurrida']==0.6].reset_index(drop=True)
df14=dataframe[dataframe['% Vida
transcurrida']==0.65].reset_index(drop=True)
df15=dataframe[dataframe['% Vida
transcurrida']==0.7].reset_index(drop=True)
```

```

df16=dataframe[dataframe['% Vida
transcurrida']==0.75].reset_index(drop=True)
df17=dataframe[dataframe['% Vida
transcurrida']==0.8].reset_index(drop=True)
df18=dataframe[dataframe['% Vida
transcurrida']==0.85].reset_index(drop=True)
df19=dataframe[dataframe['% Vida
transcurrida']==0.9].reset_index(drop=True)
df20=dataframe[dataframe['% Vida
transcurrida']==0.95].reset_index(drop=True)
df21=dataframe[dataframe['% Vida
transcurrida']==1].reset_index(drop=True)
df1=df1[:,75].reset_index(drop=True)
df2=df2[:,75].reset_index(drop=True)
df3=df3[:,75].reset_index(drop=True)
df4=df4[:,75].reset_index(drop=True)
df5=df5[:,75].reset_index(drop=True)
df6=df6[:,75].reset_index(drop=True)
df7=df7[:,75].reset_index(drop=True)
df8=df8[:,75].reset_index(drop=True)
df9=df9[:,75].reset_index(drop=True)
df10=df10[:,75].reset_index(drop=True)
df11=df11[:,75].reset_index(drop=True)
df12=df12[:,75].reset_index(drop=True)
df13=df13[:,75].reset_index(drop=True)
df14=df14[:,75].reset_index(drop=True)
df15=df15[:,75].reset_index(drop=True)
df16=df16[:,75].reset_index(drop=True)
df17=df17[:,75].reset_index(drop=True)
df18=df18[:,75].reset_index(drop=True)
df19=df19[:,75].reset_index(drop=True)
df20=df20[:,75].reset_index(drop=True)
df21=df21[:,75].reset_index(drop=True)
mindf3=pd.concat([df1,df2,df3,df4,df5,df6,df7,df8,df9,df10,df11,df12,df13
,df14,df15,df16,df17,df18,df19,df20,df21])
mindf3=mindf3.sample(frac=1)
dataframe = mindf3
dataset = dataframe.values
X = dataset[:,0:26].astype(float)
Y = dataset[:,26]
Y=Y*100

```

En el siguiente segmento de código se aplica la estrategia “one vs all” y se definen los hiperparámetros del modelo. La forma en la cual se escogieron estos hiper parámetros es en base

prueba y error, entrenado modelos con variaciones en los hiper parámetros con l finalidad de obtener porcentajes de acierto cada vez mayores. Estos hiperparámetros son los siguientes:

- Epoch: cantidad de veces en la cual se analizan todos los datos del dataset.
- Batch_size: el número de datos que es tomado por la red antes de actualizar su estructura.
- Numero de capas: cantidad de capas ocultas más las capas de entrada y salida de datos
- Numero de neuronas por capa.
- Función de activación de cada capa de neuronas.
- Función de costo.
- Optimizador.

Algunos de estos valores fueron definidos en base a reglas generales de la implementación de modelos de redes neuronales de clasificación como (número de neuronas de la capa de entrada y salida, las funciones de activación, la función de costo, etc.) mientras que otros parámetros fueron modificados en base a prueba y error (Numero de capas ocultas, numeras de neuronas por capa, etc.) este modelo fue implementado mediante las siguientes líneas de código.

4 Codificar valores de clase como enteros:

```
encoder = LabelEncoder()
encoder.fit(Y)
encoded_Y = encoder.transform(Y)
encoded_Y.max()
```

5 Convertir enteros en variables binarias

```
dummy_y = np_utils.to_categorical(encoded_Y, num_classes=21)
```

6 Definición del modelo de red neuronal, anexando hiperparmetros iniciales:

```
def baseline_model():
    # Crear modelo
    model = Sequential()
    model.add(Dense(56, input_dim=26, activation='relu'))
    model.add(Dense(64, activation='relu'))
    model.add(Dense(128, activation='relu'))
    model.add(Dense(64, activation='relu'))
    model.add(Dense(21, activation='softmax'))
    # Compilar modelo
    model.compile(loss='categorical_crossentropy', optimizer='adam',
metrics=['accuracy'])
    return model
estimator = KerasClassifier(build_fn=baseline_model, epochs=50,
batch_size=50, verbose=0)
```

```
kfold = KFold(n_splits=10, shuffle=True)
results = cross_val_score(estimator, X, dummy_y, cv=kfold)
print("Baseline: %.2f%% (%.2f%%)" % (results.mean()*100,
results.std()*100))
```

Estos serían los pasos a seguir para la codificación de la red neuronal implementando como herramienta la librería keras, para visualizar el código implementado ver (apéndice 6) . En el siguiente apartado se optimizaron los hiperparámetros mediante un proceso de retroalimentación con los resultados de predicciones obtenidas al entrenar los modelos.

4.4 Comparación las predicciones realizadas por la inteligencia artificial con valores guías para cuantificar su progreso:

En el proceso de entrenamiento se implementó la técnica de evaluación, validación cruzada K-Fold, para evaluar el rendimiento del modelo de la red neuronal. En la validación cruzada K-Fold, el conjunto de datos se divide en k partes iguales o “folds”, el modelo se entrena en k-1 folds y se evalúa en el fold restante. Este proceso se repite k veces, utilizando cada fold como conjunto de evaluación, para el caso en cuestión k=10, por lo que el modelo de inteligencia artificial divide de forma automática el dataset en 10 fragmentos, funcionando 9 de estos como datasets de entrenamiento y 1 como validación, esto se realiza 10 veces. El porcentaje de acierto para cada uno de los ciclos de entrenamiento-evaluación, son promediados, obteniéndose así el porcentaje de acierto de la red neuronal además de la desviación estándar en las predicciones de la misma.

El método de validación cruzada implementa secciones pequeñas del dataset para la evaluación del modelo entrenado, esto nos brinda del porcentaje de acierto medio de la red neuronal, no obstante, en paralelo se entrena con los mismos parámetros un modelo para realizarse un testeo al mismo de forma práctica.

En dicho testeo se le dota al modelo de un conjunto de datos sin los valores del % de vida transcurrido y se le predice este valor, clasificándolos y separándolos en intervalos de 5%, estas predicciones posteriormente son comparados con los valores correctos del porcentaje de vida transcurrida específicos de ese conjunto de datos, esta comparación es realizada mediante gráficos de distribución, siendo visible que tantos aciertos y fallas, tuvo el modelo además de que tan cerca se encontró del valor correcto.

Como fue indicado en el apartado anterior, hay hiperparametros que fueron modificados en base a prueba y error, a continuación, se muestran los resultados del uso de diferentes valores en los hiperparametros y el recorrido de obtención del modelo que presento predicciones de maneja más optima, en las siguientes cuadros, figuras y gráficos se muestra entonces el proceso de entrenamiento de la red hasta alcanzar el mayo valor posible de aciertos.

```
def baseline_model():
    # create model
    model = Sequential()
    model.add(Dense(52, input_dim=26, activation='relu'))
    model.add(Dense(64, activation='relu'))
    model.add(Dense(128, activation='relu'))
    model.add(Dense(64, activation='relu'))
    model.add(Dense(21, activation='softmax'))
    # Compile model
    model.compile(loss='categorical_crossentropy', optimizer='adam', metrics=['accuracy'])
    return model
```

Figura 35: Estructura del modelo de red neuronal de clasificación, grupo de modelos N°1

Fuente. Méndez (2023).

Cuadro 7: hiperparametros utilizados en el entrenamiento del grupo de modelos N°1.

N° Capas	N° Neuronas p/capa	Función de activación p/capa	epoch	Batch-zise	Dimensión del dataset
1 entrada	52	'relu'	100	25	27 columnas 12755 filas
2 oculta	64	'relu'			
3 oculta	128	'relu'			
4 oculta	64	'relu'			
5 oculta	21	'Softmax'			

Fuente. Méndez (2023).

Esta fue la primera configuración de hiperparametros utilizada para el entrenamiento de la red, tanto las funciones de activación como el optimizador y la función de costo son típicos de redes neuronales para problemas de clasificación, pero la cantidad de capas, el numero de neuronas, los baches y las épocas, son valores que fueron tomados de forma aleatoria.

Gráfico 27: Distribución de datos, modelo N° 1, grupo N°1.





Gráfico 28: Distribución de datos, modelo N° 2, grupo N°1.



Fuente. Méndez (2023).

```

def baseline_model():
    # create model
    model = Sequential()
    model.add(Dense(26, input_dim=26, activation='relu'))
    model.add(Dense(64, activation='relu'))
    model.add(Dense(128, activation='relu'))
    model.add(Dense(64, activation='relu'))
    model.add(Dense(21, activation='softmax'))
    # Compile model
    model.compile(loss='categorical_crossentropy', optimizer='adam', metrics=['accuracy'])
    return model

```

Figura 36: Estructura del modelo de red neuronal de clasificación, grupo de modelos N°2.

Fuente. Méndez (2023).


Debido al bajo porcentaje de acierto y los tiempos de entrenamiento altos en los modelos anteriores se decide cambiar los hiperpatrametros, con la finalidad de obtener resultados diferentes. En comparación con los hiperparametrsoe en grupo de modelos anterior, para este se cambiaron la cantidad de neuronas en la capa de entrada, haciendo que sea igual al numero de variables de entrada de la red. Con fines de acelerar los procesos de entrenamiento se disminuyeron los datos de entrenamiento, se disminuyó el epoch y se aumentó el batch-zise, estos cambios son visibles en el siguiente cuadro.

Cuadro 8: hiperparametros utilizados en el entrenamiento del grupo de modelos N° 2

N° Capas	N° Neuronas p/capa	Función de activación p/capa	epoch	Batch-zise	Dimensión del dataset
1 entrada	26	'relu'	50	50	27 columnas 6384 filas
2 oculta	64	'relu'			
3 oculta	128	'relu'			
4 oculta	64	'relu'			
5 oculta	21	'Softmax'			

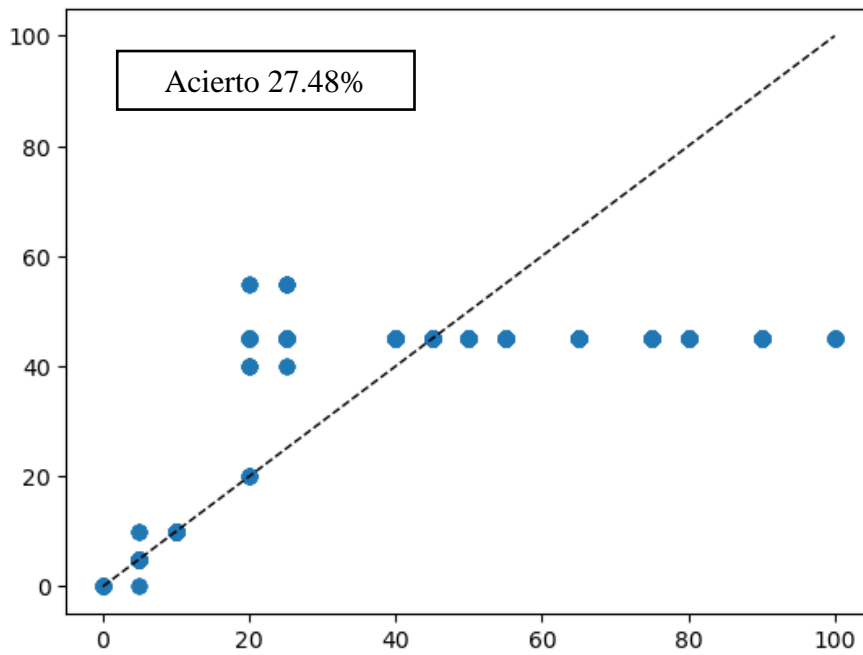
Fuente. Méndez (2023).

Gráfico 29: Distribución de datos, modelo N° 1, grupo N°2




Fuente. Méndez (2023).

Gráfico 30: Distribución de datos, modelo N° 2, grupo N°2




Fuente. Méndez (2023).

Gráfico 31: Distribución de datos, modelo N° 3, grupo N°2



Fuente. Méndez (2023).

Gráfico 32: Distribución de datos, modelo N° 4, grupo N°2



Fuente. Méndez (2023).

```

def baseline_model():
    # create model
    model = Sequential()
    model.add(Dense(26, input_dim=26, activation='relu'))
    model.add(Dense(64, activation='relu'))
    model.add(Dense(80, activation='relu'))
    model.add(Dense(80, activation='relu'))
    model.add(Dense(128, activation='relu'))
    model.add(Dense(80, activation='relu'))
    model.add(Dense(80, activation='relu'))
    model.add(Dense(64, activation='relu'))
    model.add(Dense(21, activation='softmax'))
    # Compile model
    model.compile(loss='categorical_crossentropy', optimizer='adam', metrics=['accuracy'])
    return model

```

Figura 37: Estructura del modelo de red neuronal de clasificación, grupo de modelos N°3.

Fuente. Méndez (2023).


El cambio de hiperparámetros más grande se realizó en este momento, se añadieron más capas ocultas, se añadieron más neuronas y se aumentaron los datos de entrenamiento.

Cuadro 9: hiperparámetros utilizados en el entrenamiento del grupo de modelos N° 3.

N° Capas	N° Neuronas p/capa	Función de activación p/capa	epoch	Batch-zise	Dimensión del dataset
1 entrada	26	'relu'	50	50	27 columnas 8507 filas
2 oculta	64	'relu'			
3 oculta	80	'relu'			
4 oculta	80	'relu'			
5 oculta	128	'relu'			
6 oculta	80	'relu'			
7 oculta	80	'relu'			
8 oculta	64	'relu'			
9 Salida	21	'Softmax'			


Fuente. Méndez (2023).

Gráfico 33: Distribución de datos, modelo N° 1, grupo N°3.




Fuente. Méndez (2023).

Gráfico 34: Distribución de datos, modelo N° 2, grupo N°3.




Fuente. Méndez (2023).

Gráfico 35: Distribución de datos, modelo N° 3, grupo N°3.



Fuente. Méndez (2023).

Gráfico 36: Distribución de datos, modelo N° 4, grupo N°3.



Fuente. Méndez (2023).

```

def baseline_model():
    # create model
    model = Sequential()
    model.add(Dense(26, input_dim=26, activation='relu'))
    model.add(Dense(64, activation='relu'))
    model.add(Dense(80, activation='relu'))
    model.add(Dense(80, activation='relu'))
    model.add(Dense(128, activation='relu'))
    model.add(Dense(128, activation='relu'))
    model.add(Dense(80, activation='relu'))
    model.add(Dense(80, activation='relu'))
    model.add(Dense(64, activation='relu'))
    model.add(Dense(21, activation='softmax'))
    # Compile model
    model.compile(loss='categorical_crossentropy', optimizer='adam', metrics=['accuracy'])
    return model

```

Figura 38: Estructura del modelo de red neuronal de clasificación, grupo de modelos N°4.

Fuente. Méndez (2023).


A diferencia de la estructura pasada fue agregada una nueva capa oculta con 128 neuronas, en la posición n° 6, con función de activación ‘relu’.

Cuadro 10: hiperparametros utilizados en el entrenamiento del grupo de modelos N° 4.

N° Capas	N° Neuronas p/capa	Función de activación p/capa	epoch	Batch-zise	Dimensión del dataset
1 entrada	26	‘relu’	50	50	27 columnas 8507 filas
2 oculta	64	‘relu’			
3 oculta	80	‘relu’			
4 oculta	80	‘relu’			
5 oculta	128	‘relu’			
6 oculta	128	‘relu’			
7 oculta	80	‘relu’			
8 oculta	80	‘relu’			
9 oculta	64	‘relu’			
10 Salida	21	‘Softmax’			


Fuente. Méndez (2023).

Gráfico 37: Distribución de datos, modelo N° 1, grupo N°4.




Fuente. Méndez (2023).

Gráfico 38: Distribución de datos, modelo N° 2, grupo N°4.




Fuente. Méndez (2023).

Gráfico 39: Distribución de datos, modelo N° 3, grupo N°4.



Fuente. Méndez (2023).

Gráfico 40: Distribución de datos, modelo N° 4, grupo N°4.



Fuente. Méndez (2023).

```

def baseline_model():
    # create model
    model = Sequential()
    model.add(Dense(26, input_dim=26, activation='relu'))
    model.add(Dense(64, activation='relu'))
    model.add(Dense(80, activation='relu'))
    model.add(Dense(80, activation='relu'))
    model.add(Dense(128, activation='relu'))
    model.add(Dense(128, activation='relu'))
    model.add(Dense(80, activation='relu'))
    model.add(Dense(80, activation='relu'))
    model.add(Dense(64, activation='relu'))
    model.add(Dense(21, activation='softmax'))
    # Compile model
    model.compile(loss='categorical_crossentropy', optimizer='adam', metrics=['accuracy'])
    return model

estimator = KerasClassifier(build_fn=baseline_model, epochs=100, batch_size=50, verbose=0)
estimator.fit(X, dummy_y)

```

Figura 39: Estructura del modelo de red neuronal de clasificación, grupo de modelos N°5.

Fuente. Méndez (2023).

A diferencia de la estructura pasada es que fue modificado el epochs a 100.

Cuadro 11: hiperparametros utilizados en el entrenamiento del grupo de modelos N° 5

N° Capas	N° Neuronas p/capa	Función de activación p/capa	epoch	Batch-zise	Dimensión del dataset
1 entrada	26	'relu'	100	50	27 columnas 8507 filas
2 oculta	64	'relu'			
3 oculta	80	'relu'			
4 oculta	80	'relu'			
5 oculta	128	'relu'			
6 oculta	128	'relu'			
7 oculta	80	'relu'			
8 oculta	80	'relu'			
9 oculta	64	'relu'			
10 salida	21	'Softmax'			

Fuente. Méndez (2023).

Gráfico 41: Distribución de datos, modelo N° 1, grupo N°5.





Gráfico 42: Distribución de datos, modelo N° 2, grupo N°5.




Fuente. Méndez (2023).

Cada uno de estos gráficos de dispersiones pertenece a un modelo de inteligencia artificial entrenado de forma independiente, con unos u otros hiperparámetros en base al grupo al que

pertenece, no obstante, aun siendo dos o más modelos de un mismo grupo, se observó que existen diferencias entre notorias en los porcentajes de predicciones realizadas con el dataset de testeo.


Esto tiene explicación en la naturaleza de la arquitectura de las redes neuronales, estas funcionan mediante la corrección constante de el error que existen al realizarse el entrenamiento, esto sucede mediante la búsqueda de mínimos en la función de error del modelo, la posición inicial en esta función de error esta definida por los pesos iniciales en la red neuronal, que son de carácter aleatorio, por lo cual si la posición en la función de error se encuentra lejano de un mínimo global, es muy probable que la red neuronal quede estancada en un mínimo local de la funciona al aplicar el algoritmo del descenso del gradiente, un ejemplo de esto se visualiza en los siguiente gráfico.

Gráfico 43: Descenso del gradiente de un punto en una función de error a un mínimo local.



Fuente. Méndez (2023).

Gráfico 44: Descenso del gradiente de un punto en una función de error a un mínimo global.



Fuente. Méndez (2023).

Este comportamiento explica por qué para condiciones de entrenamientos semejantes se pueden obtener porcentajes de predicción diferentes.


4.4.1 Selección del mejor modelo de red neuronal entrenado:

El proceso de selección del mejor modelo de la red neuronal es bastante sencillo, debido a que el testeo de cada modelo fue realizado con un conjunto de datos ajeno al de entrenamiento el porcentaje de acierto es un gran indicador de que tan fiable es el modelo a la hora de realizar predicciones, por ende, el mejor modelo de red neuronal, es aquel que tenga mayor porcentaje de acierto.

No obstante, existe una muy pequeña posibilidad de que los patrones detectados no sean generales y el hecho de tener un porcentaje de acierto alto utilizando los datos de testeo sean una casualidad, la posibilidad de que este sea el caso es muy baja, pero para confirmar que el aprendizaje de la red está generalizado, se evalúa con más conjuntos de datos, diferentes tanto a el dataset de entrenamiento como a el conjunto de testeo.

La red neuronal que mejor rendimiento tuvo en el apartado anterior fue el modelo n°2 del grupo n°5, se realiza entonces el re-testeo con otro conjunto de datos ajeno al proceso anterior, esto es visible en el siguiente gráfico.

Gráfico 45: Distribución de datos, evaluación N°2, modelo N°2, grupo N°5.



Fuente. Méndez (2023).

El porcentaje de acierto obtenido es semejante al obtenido con el primer testeo, lo que indica la generalización del aprendizaje de la red neuronal, significando este el mejor modelo resultante del entrenamiento de inteligencia artificial en este trabajo de grado, para apreciar el código utilizado en el testeo de los modelos (ver apéndice 7), para descargar los modelos entrenados en este trabajo (ver apéndice 3).

4.5 Evaluación de la viabilidad técnica y ambiental, para una posible aplicación en la industria.

La viabilidad técnica y ambiental se refiere a la evaluación de un proyecto para determinar si es factible desde un punto de vista técnico y ambiental. Esto implica evaluar si el proyecto es técnicamente posible de realizar y si cumple con los requisitos y regulaciones ambientales.

4.5.1 Viabilidad técnica:

La viabilidad técnica se enfoca en evaluar si el proyecto es posible de realizar con las herramientas, recursos y tecnologías disponibles. par la aplicación y replicación de este proyecto en el ámbito industrial, se requiere acceso a software y hardware adecuados para el entrenamiento y la implementación de la red neuronal.

En cuanto al software, existen numerosas opciones disponibles para el diseño y entrenamiento de redes neuronales, como PyTorch, TensorFlow y Keras. Estas herramientas son ampliamente utilizadas en la comunidad de aprendizaje automático y están disponibles gratuitamente, las últimas dos mencionadas fueron utilizadas para el desarrollo de este proyecto.

En cuanto al hardware, se requiere una computadora con altas capacidades computacionales y una tarjeta gráfica potente para acelerar el proceso de entrenamiento de la red neuronal. También es posible utilizar servicios en la nube para el entrenamiento, lo que puede reducir los costos y aumentar la eficiencia.

Además, para una aplicabilidad en el ámbito industrial se necesita datos tangibles y reales del equipo al cual se quiera aplicar el proyecto, si no tiene ya un levantamiento de información previo, se necesitan materiales y equipos para tomar medición suficiente para la realización óptima del set de datos y el correcto entrenamiento de la red neuronal, ejemplo de estos pueden ser: sensores térmicos, equipos de ultra sonidos, cámaras infrarrojas, entre mas equipos que permitan medir la condición y el estado del equipo.

En resumen, la viabilidad técnica del proyecto es alta debido a la disponibilidad de herramientas y tecnologías adecuadas para llevar a cabo el proyecto. Sin embargo, es importante tener en cuenta que se requiere un conocimiento sólido en el campo del aprendizaje automático y las redes neuronales para diseñar e implementar una red neuronal eficaz.

4.5.2 Viabilidad ambiental:

La viabilidad ambiental del proyecto se evalúa a través del análisis del impacto ambiental que tendrá la implementación de la inteligencia artificial en la industria. Para ello, se consideran factores como el consumo de energía y recursos durante el desarrollo y la implementación de la red neuronal, así como el impacto de la eliminación de los componentes electrónicos al final de su vida útil.

La implementación de este proyecto utiliza principalmente la computación, por lo que las herramientas principales son las computadoras. El consumo medio de una computadora de alta gama es de 0,05 kWh, lo cual es significativamente menor en comparación con el consumo de energía eléctrica de un equipo cotidiano en el ámbito industrial, como puede ser un motor eléctrico de 1 hp, que ronda alrededor de 0,746 kWh. Sin embargo, los componentes electrónicos

al finalizar su vida útil pueden ser muy contaminantes debido a la presencia de elementos como plomo, mercurio y cadmio. Por lo tanto, es importante tener cuidado al desecharlos.

Para minimizar el impacto ambiental del proyecto, se pueden tomar medidas como el uso de tecnologías más eficientes en términos de energía y recursos, así como la implementación de prácticas sostenibles en el desarrollo y la implementación del proyecto. También es importante cumplir con las regulaciones y normativas ambientales aplicables.

En resumen, la viabilidad ambiental del proyecto es alta si se toman las medidas necesarias para minimizar su impacto ambiental y se cumple con las regulaciones y normativas ambientales aplicables.

CONCLUSIONES

Los objetivos planteados en el comienzo de este proyecto titulado “Propuesta de diseño de un sistema de predicción de fallas para un tambor secador de negro de humo mediante una inteligencia artificial.” fueron cumplidos de manera satisfactoria.

Esquemalizando, Se realizo un levantamiento y análisis de información, a modo de diagnostico de las condiciones de trabajo del tambor secador, los datos fueron relacionados utilizándose tecnologías como el diseño asistido por computadora en conjunto con cálculos y análisis matemáticos, a base de esto se obtuvieron las relaciones fundamentales entre las variables que definen en esencia al secador rotativo, como su ciclo de vida, además, de la razón y causa de falla.

Teniéndose esta información, se cumplió con la realización de un set de datos ordenados, con relación entre sí, con generalidad al incluirse varios ciclos de vida de múltiples secadores, incluyéndose variables que definen a los mismos, consiguiéndose patrones que desencadenan potencial predictivo.

Este conjunto de datos se utilizó para el entrenamiento de redes neuronales que en base al machine learning aprendieron de los datos, reconociendo los patrones en la información, permitiendo así clasificar el estado del tambor secador en 20 categorías directamente proporcionales al porcentaje de vida útil transcurrido, este reconocimiento de patrones desencadenó en predicciones con más de 80% de acierto. Además, se corroboró la veracidad de estas predicciones con múltiples tests y optimización de los parámetros que definen a los modelos entrenados.

Esta investigación no solo beneficia a las productoras de negro de humo en la predicción de fallas ocasionadas por corrosión en tambores sectores, sino que es extrapolable a diferentes maquinarias de todo tipo y bajo condiciones de trabajo variables, sirviéndose así de este trabajo para futuros nuevos desarrollos e investigaciones relacionados a la aplicación del aprendizaje automático en la industria, por lo cual, estos logros implican un fresco abanico de oportunidades, ya que la implementación la tecnología del aprendizaje automático en la industria para la predicción de fallas trae consigo menos pérdidas de tiempo, mayor eficiencia, mayor confiabilidad y mejores planificaciones tanto de mantenimiento como de producción

RECOMENDACIONES

Se recomienda en lo académico continuar investigando y mejorando los modelos de inteligencia artificial: Es importante que persista la investigación y optimización de los modelos de inteligencia artificial utilizado para predecir fallas en secadores rotativos y en general en maquinaria industrial. Esto podría incluir la incorporación de más datos y variables, así como la utilización de técnicas más avanzadas de aprendizaje automático, con la finalidad de seguir aportándose avances tecnológicos, de modo que este trabajo de grado sirva de apoyo en futuras investigaciones afines.

Explorar la aplicación del modelo a otras maquinarias, El modelo desarrollado para predecir fallas en un tambor secador de negro de humo podría ser aplicado a otras maquinarias y condiciones de trabajo. Se recomienda explorar esta posibilidad y adaptar el modelo para su uso en otros contextos.

Para las posteriores investigaciones que usen como base este trabajo se recomienda:

- Realizar pruebas con diferentes conjuntos de datos para evaluar la robustez y generalización del modelo.
- El uso de aceleradores de gpu para la disminución de los tiempos de entrenamientos.
- No usar grandes cantidades de datos si no es necesario.
- No se recomienda el uso excesivo de neuronas en los modelos, las redes neuronales con muchas neuronas tienden a memorizar los datos en vez de aprender de ellos, esto desencadena en porcentajes de predicción altos, pero solo para set de datos específicos.
- Investigar la posibilidad de integrar el sistema de predicción de fallas con otros sistemas de monitoreo y control para mejorar la eficiencia y seguridad en la operación del equipo.
- Normalizar y limpiar los datos a utilizar.

Para un uso directo de los modelos implementados en este trabajo se recomienda utilizar datos de testeo limpios, con 26 columnas. Este es el formato con los cuales fueron entrenados los modelos, por lo que, es necesario que se mantenga para realizar predicciones de forma óptima.

REFERENCIAS

- Arias, F. G. (2006). **El proyecto de investigación. Introducción a la metodología científica.** 5ta. Fidas G. Arias Odón.
- Arias, F. G. (2012). **El proyecto de investigación. Introducción a la metodología científica.** 6ta. Fidas G. Arias Odón.
- De León, F. C. G. (1998). *Tecnología del mantenimiento industrial.* Editum.
- De los ríos Tomalá G. (2019). **Mantenimiento predictivo para la supervisión de motores eléctricos aplicando técnicas de inteligencia artificial** [tesis de grado, Universidad católica de Santiago de Guayaquil].
- Fernández, F. J. G. (2005). **Teoría y práctica del mantenimiento industrial avanzado.** FC editorial.
- Gonzales W. (2018), **Redes Neuronales Binarizadas entrenadas mediante Aprendizaje Estructural Adaptativo (Estudio experimental)** [Tesis de pregrado, Universidad central de Venezuela] Repositorio institucional Saber UCV: http://190.169.28.5/portal/rec_elect/listado/portada.php?cod=11286
- López, R. F., & Fernández, J. M. F. (2008). **Las redes neuronales artificiales.** Netbiblo.
- Olarte, W., Botero, M., & Cañón, B. (2010). **Importancia del mantenimiento industrial dentro de los procesos de producción.** Scientia et technica, 16(44), 354-356.
- Olarte, W., Botero, M., & Cañón, B. (2010). **Técnicas de mantenimiento predictivo utilizadas en la industria.** Scientia et technica, 2(45), 223-226.
- Paredes, R. (2020). **Tipos de mantenimiento aplicados en la industria petrolera venezolana de la Región Occidente.** Revista Ingeniería, 4(9), 129–142.
- Rotary Dryer Design & Working Principle** [imagen], 991 Metallurgist, (<https://www.911metallurgist.com/blog/rotary-dryer-design-working-principle>)
- Rouhiainen, L. (2018). **Inteligencia artificial.** Madrid: Alienta Editorial.
- Sossa Azuela, J. H. (2020). **El papel de la inteligencia artificial en la Industria 4.0.**
- Terán R. (2019). **Comparación de los métodos emergentes utilizados en el análisis espectral de corriente estatórica para determinar las condiciones de cojinetes en motores de inducción** [tesis de maestría, Universidad de Carabobo] Repositorio institucional Riuc: <http://riuc.bc.uc.edu.ve/>

- Tume M. (2022). **Estado del arte de la inteligencia artificial y su aplicación en el mantenimiento** [tesis de pregrado, Universidad de Piura].
- Villegas A. (2019). Desarrollo de un sistema de análisis automático para la segmentación, clasificación y conteo de leucocitos en imágenes digitales de frotis de sangre periférica [Tesis de maestría, Universidad de Carabobo] Repositorio institucional Riuc: <http://riuc.bc.uc.edu.ve/>
- Proy M. (2013). Corrosión a alta temperatura de acero al carbono y acero inoxidable austenítico en atmósferas contaminadas por CO₂ [Tesis de doctorado, Universidad Rey Juan Carlos] Repositorio: <https://burjcdigital.urjc.es/handle/10115/12329>
- Soto D. (2021). Implementación de mantenimiento predictivo para una bomba centrífuga utilizando machine learning [Tesis de pregrado, Universidad Antonio Nariño] Repositorio: <http://repositorio.uan.edu.co/>

ANEXOS

Anexo A: Calores específicos para diferentes materiales.

Calor específico (capacidad calorífica específica) (25 °C, 1 atm=101 325 Pa)

Material	J/(kg·K)	Material	J/(kg·K)
Aceite vegetal	2000	Hielo (-10 °C a 0 °C)	2093
Agua (0 °C a 100 °C)	4186	Hierro/Acero	452
Aire	1012	Hormigón	880
Alcohol etílico	2460	Latón	380
Alcohol metílico	2549	Litio	3560
Aluminio	897	Madera	420
Amoniaco (líquido)	4700	Magnesio	1023
Arena	290	Mármol	858
Asfalto	920	Mercurio	138
Azufre	730	Metano (275 K)	2191
Benceno	1750	Níquel	440
Calcio	650	Nitrógeno	1040
Cinc	390	Oro	129
Cobre	387	Oxígeno	918
Diamante	509	Plata	236
Dióxido de carbono (gas)	839	Plomo	128
Estaño	210	Potasio	750
Etilen glicol	2200	Sodio	1230
Gasolina	2220	Tejido humano	3500
Grafito	710	Tierra (típica)	1046
Granito	790	Vapor de agua (100 °C)	2009
Helio (gas)	5300	Vidrio (típico)	837
Hidrógeno (gas)	14267		

Anexo B: Calores específicos para diferentes sustancias.

<i>Calores específicos de algunas sustancias a 25 °C y presión atmosférica</i>		
<i>Sustancia</i>	<i>Calor específico c</i>	
	<i>J/kg. °C</i>	<i>cal/g. °C</i>
<i>Sólidos elementales</i>		
Aluminio	900	0.215
Berilio	1830	0.436
Cadmio	230	0.055
Cobre	387	0.0924
Germanio	322	0.077
Oro	129	0.0308
Hierro	448	0.107
Plomo	128	0.0305
Silicio	703	0.168
Plata	234	0.056
<i>Otros sólidos</i>		
Bronce	380	0.092
Vidrio	837	0.200
Hierro (-5 °C)	2090	0.50
Mármol	860	0.21
Madera	1700	0.41
<i>Líquidos</i>		
Alcohol (etílico)	2400	0.58
Mercurio	140	0.033
Agua (15 °C)	4186	1.00
<i>Gas</i>		
Vapor (100 °C)	2010	0.48

Anexo C: Calores latentes para diferentes sustancias.

Sustancia	Punto de fusión (°C)	Calor latente de fusión (J/kg)	Punto de ebullición (°C)	Calor latente de vaporización (J/kg)
Helio	-269.65	5.23×10^5	-268.93	2.09×10^4
Nitrógeno	-209.97	2.55×10^4	-195.81	2.01×10^5
Oxígeno	-218.79	1.38×10^4	-182.97	2.13×10^5
Alcohol etílico	-114	1.04×10^5	78	8.54×10^5
Agua	0.00	3.33×10^5	100.00	2.26×10^6
Azufre	119	3.81×10^4	444.60	3.26×10^5
Plomo	327.3	2.45×10^4	1 750	8.70×10^5
Aluminio	660	3.97×10^5	2 450	1.14×10^7
Plata	960.80	8.82×10^4	2 193	2.33×10^6
Oro	1 063.00	6.44×10^4	2 660	1.58×10^6
Cobre	1 083	1.34×10^5	1 187	5.06×10^6

APENDICES

Apéndice 1: Set de datos de entrenamiento “EL DATASET 3.csv” (Vista previa)

	días	Temperatura inicial	L 0.5	L 1	L 1.5	L 2	L 2.5	L 3	L 3.5	L 4	...
0	14788	1150	0	0	0	0	0	0	0	0	...
1	21578	1150	0	1	0	0	0	0	0	0	...
2	25963	1050	0	0	0	0	0	0	0	0	...
3	3080	1050	0	0	0	0	0	0	0	0	...
4	18991	1150	0	0	0	0	0	0	0	0	...
...
980876	5931	1150	0	0	0	0	0	0	0	0	...
980877	21722	1050	0	1	0	0	0	0	0	0	...
980878	1011	1100	0	0	0	0	0	0	0	0	...
980879	13360	1150	0	1	0	0	0	0	0	0	...
980880	24115	1150	0	0	0	0	0	0	0	0	...

...	L 8	L 8.5	Temperatura de la superficie	Factor K	Masa perdida de forma acumulativa mg	Volumen de material perdido mm3	profundidad de la picadura mm	Longitud de la grieta	FALLO? 0=NO 1=SI	% Vida transcurrida
...	1	0	321.204327	0.000234	3.926772e+05	49084.645019	2.083212	2.083212	0	0.3072
...	0	0	685.304914	0.000642	1.970240e+06	246279.991447	10.452423	10.452423	0	0.8764
...	0	0	429.956144	0.000322	1.868304e+06	233538.047112	9.911639	9.911639	0	0.8531
...	0	0	631.439366	0.000574	2.887997e+05	36099.963115	1.532126	1.532126	0	0.2353
...	0	1	215.751043	0.000157	7.760090e+05	97001.122781	4.116846	4.116846	0	0.4778
...
...	0	0	734.388257	0.001098	1.315962e+06	164495.284118	6.981380	6.981380	0	0.6323
...	0	0	614.073018	0.000553	1.964066e+06	245508.245971	10.419669	10.419669	0	0.8751
...	0	0	597.935693	0.000532	2.199934e+04	2749.916876	0.116710	0.116710	0	0.0432
...	0	0	685.304914	0.000642	9.502591e+05	118782.392719	5.041270	5.041270	0	0.5382
...	0	0	532.650820	0.000451	1.953726e+06	244215.691936	10.364812	10.364812	0	0.8766

Para tener acceso al set de datos completo, visitar:

https://drive.google.com/file/d/1yc6fT6xLWYLIB50gNQcOlw1Kk8NOHVFi/view?usp=drive_link

Apéndice 2: Set de datos de testeo “mi_dataSet9.csv” (Vista previa)

	días	Temperatura inicial	L 0.5	L 1	L 1.5	L 2	L 2.5	L 3	L 3.5	L 4	...
0	5710	1100	0	0	0	0	1	0	0	0	...
1	13507	1100	0	1	0	0	0	0	0	0	...
2	4635	1050	0	0	0	0	0	0	0	0	...
3	6305	1100	0	0	0	0	0	0	0	0	...
4	4983	1150	0	0	0	0	0	0	0	0	...
...
328308	9030	1100	0	0	0	0	0	0	0	0	...
328309	12959	1150	0	0	0	0	0	0	0	0	...
328310	2632	1050	0	1	0	0	0	0	0	0	...
328311	37590	1150	0	0	0	0	0	0	0	0	...
328312	1542	1150	0	0	0	0	0	0	0	0	...

...	L 8	L 8.5	Temperatura de la superficie	Factor K	Masa perdida de forma acumulativa mg	Volumen de material perdido mm3	profundidad de la picadura mm	Longitud de la grieta	FALLO? 0=NO 1=SI	% Vida transcurrida
...	0	0	708.906894	0.000773	1.529726e+06	191215.784940	8.115431	8.115431	0	0.6804
...	0	0	649.688966	0.000597	9.645537e+05	120569.208643	5.117104	5.117104	0	0.5459
...	0	0	482.480040	0.000388	1.626147e+05	20326.835500	0.862696	0.862696	0	0.1678
...	0	0	449.461481	0.000347	2.218630e+05	27732.878457	1.177017	1.177017	0	0.2060
...	0	0	734.092026	0.001094	9.981712e+05	124771.405666	5.295451	5.295451	0	0.5205
...
...	0	1	201.332317	0.000147	2.506779e+05	31334.734153	1.329884	1.329884	0	0.2263
...	0	1	215.751043	0.000157	4.317707e+05	53971.332570	2.290609	2.290609	0	0.3248
...	0	0	614.073018	0.000553	8.334141e+04	10417.676122	0.442139	0.442139	0	0.1064
...	0	1	215.751043	0.000157	2.142683e+06	267835.431171	11.367262	11.367262	0	0.9421
...	0	0	532.650820	0.000451	3.178550e+04	3973.187525	0.168627	0.168627	0	0.0558























Para tener acceso al set de datos completo, visitar:

https://drive.google.com/file/d/1CwMEmy_kDNzopmOUOksX6Z67oFB5qNeF/view?usp=drive_link

Apéndice 3: Modelos de IA entrenados (Vista previa).

Nomenclatura ejemplo: IA 8538.h5

- AI: Inteligencia artificial (artificial intelligence)
- 8538: 85,38% de acierto al ser testeada.
- h5: formato

Nombre ↓	Propietario	Última modifi... ▼	Tamaño de a
 IA 8538.h5 	 yo	23 ago 2023	831 kB 
 IA 7462.h5 	 yo	23 ago 2023	831 kB 
 IA 6251.h5 	 yo	23 ago 2023	632 kB 
 IA 6102.h5 	 yo	23 ago 2023	226 kB 
 IA 5769.h5 	 yo	23 ago 2023	632 kB 
 IA 5102.h5 	 yo	23 ago 2023	542 kB 
 IA 4993.h5 	 yo	23 ago 2023	632 kB 
 IA 1105.h5 	 yo	23 ago 2023	831 kB 
 IA 1042.h5 	 yo	23 ago 2023	831 kB 
 IA 42.80.h5 	 yo	23 ago 2023	831 kB 

Para tener acceso al grupo de modelos redes neuronales de clasificación entrenados en este trabajo, visitar:

https://drive.google.com/drive/folders/1OluN-afZJTh-UkLTYKyPqLiocPNes8Uw?usp=drive_link

Apéndice 4: Datos de temperatura utilizados para la generación del set de datos.

Temperatura	L 0.5	L 1	L 1.5	L 2	L 2.5
1150	646.961061	685.304914	717.010884	738.574015	746.991165
1100	612.79377	649.688966	680.328682	701.009487	708.906894
1050	578.626479	614.073018	643.64648	663.444959	670.822623

L 3	L 3.5	L 6.5	L 7	L 7.5	L 8	L 8.5
752.893074	756.263612	634.364236	532.65082	468.966817	321.204327	215.751043
714.604022	717.542223	597.935693	507.56543	449.461481	307.897756	201.332317
676.314971	678.820835	561.50715	482.48004	429.956144	294.591184	186.913592

Para tener acceso al archivo con los valores de temperatura en formato “TEM KS 05.csv”
visitar:

[https://drive.google.com/file/d/1uE3kIhy7tZqdSHQcxUOvvHTSZcF1Kh4-
/view?usp=drive_link](https://drive.google.com/file/d/1uE3kIhy7tZqdSHQcxUOvvHTSZcF1Kh4-/view?usp=drive_link)

Apéndice 5: Código para la generación de set de datos (vista previa).

```
[ ] import numpy as np
import pandas as pd
import openpyxl
import random as rd

[ ] from google.colab import files
files.upload()

[ ] # Se carga el CSV
tem05csv=pd.read_csv("TEM KS 05.csv")

tem05csv

[ ] # Ciclo for para la generacion de dias ↓
l=[]
ran=50000
for i in range (ran):
    for j in range (17):
        l.append(i+1)
# ciclo for para la generacion de temperaturas iniciales ↓
ti=[]

for i in range (ran):
    x=rd.randint(0,2)
    z=tem05csv["Temperatura"][x]
    for i in range (17):
        ti.append(z)

# tranfromcion de diccionario a dataframe
ds={"dias":l, "Temperatura inicial":ti}
```

Nota: para el correcto uso del mismo se debe cargar el archivo “TEM KS 05.csv” del apéndice 4

Para acceder al código de generación de sets de datos completo, visitar:

https://colab.research.google.com/drive/1TKBHd44uhe43NqjGrghvXUQX4_cRS_B5?usp=sharing

Apéndice 6: Código para el entrenamiento de los modelos de redes neuronales (vista previa).

```
# encode class values as integers
encoder = LabelEncoder()
encoder.fit(Y)
encoded_Y = encoder.transform(Y)
encoded_Y.max()

# convert integers to dummy variables (i.e. one hot encoded)
dummy_y = np_utils.to_categorical(encoded_Y, num_classes=21)

def baseline_model():
    # create model
    model = Sequential()
    model.add(Dense(26, input_dim=26, activation='relu'))
    model.add(Dense(64, activation='relu'))
    model.add(Dense(80, activation='relu'))
    model.add(Dense(80, activation='relu'))
    model.add(Dense(128, activation='relu'))
    model.add(Dense(128, activation='relu'))
    model.add(Dense(80, activation='relu'))
    model.add(Dense(80, activation='relu'))
    model.add(Dense(64, activation='relu'))
    model.add(Dense(21, activation='softmax'))
    # Compile model
    model.compile(loss='categorical_crossentropy', optimizer='adam', metrics=['accuracy'])
    return model
estimator = KerasClassifier(build_fn=baseline_model, epochs=80, batch_size=80, verbose=0)
kfold = KFold(n_splits=10, shuffle=True)
results = cross_val_score(estimator, X, dummy_y, cv=kfold)
print("Baseline: %.2f%% (%.2f%%)" % (results.mean()*100, results.std()*100))

[ ] estimator = KerasClassifier(build_fn=baseline_model, epochs=100, batch_size=50, verbose=0)
estimator.fit(X, dummy_y)
estimator.model.save('mi_modelo2.h5')
```

Nota: para el correcto funcionamiento requiere de cargarse el “EL DATASET 3.csv” del apéndice 1.

Para acceder al código de entrenamiento de modelos utilizado en este trabajo, visitar:

https://colab.research.google.com/drive/1VXE-OlpVv0cBvS3SAOIJNoQ1Wj40Lrh6?usp=drive_link


Apéndice 7: Código para el testeo de los modelos de redes neuronales (vista previa).

```
[ ] 45/45 [=====] - 0s 2ms/step - loss: 0.3703 - accuracy: 0.8381
45/45 [=====] - 0s 2ms/step
Test accuracy: 0.8381421566009521
```

```
[ ] encoded_Y = np.argmax(dummy_y2, axis=1)
encoded_Y
original_Y2 = encoder.inverse_transform(encoded_Y)
original_Y2
encoded_Y = np.argmax(y_predic, axis=1)
encoded_Y
original_Y = encoder.inverse_transform(encoded_Y)
original_Y
```

```
array([10., 25., 65., ..., 50., 25., 55.]
```

```
plt.scatter(original_Y2, original_Y)
plt.plot([0, 100], [0, 100], 'k--', linewidth=1)
plt.show()
```



Nota: para el correcto funcionamiento requiere de cargarse el modelo a testear y el set de datos de testeo, ejemplo: “IA 8538.h5” del apéndice 3 y “mi_dataSet9.csv” del apéndice 2.

Para acceder al código de entrenamiento de modelos utilizado en este trabajo, visitar:

https://colab.research.google.com/drive/1w3sOrvA2x4KDc0w8SY9XreLuL4wMUfsr?usp=drive_link