



UNIVERSIDAD JOSÉ ANTONIO PÁEZ  
 COORDINACIÓN DE PASANTÍAS Y TRABAJO DE GRADO  
 FACULTAD DE INGENIERÍA

ACTA DE APROBACIÓN DEL INFORME DE PASANTÍA O  
 TRABAJO DE GRADO

El jurado designado por la Facultad de Ingeniería para la evaluación del Informe Final de Pasantía o Trabajo de Grado titulado:

Evaluación de la resistencia al desgaste de una fundición gris y fundición blanca, por medio de redes neuronales.

Realizado por el (la) Br. Herrera F. Diego A.

C.I. N° 26924282 cursante de la carrera de Ingeniería Mecánica hace constar después de analizar su contenido y oír la exposición oral, considera que reúne los méritos suficientes para su aprobación asignándole la CALIFICACIÓN DEFINITIVA D<sup>ta</sup> Veinte 20 PUNTOS

El Jurado

Romanells  
 Tutor Académico (coordinador)  
 Nombre: Donato Romanells  
 C.I. 4131877

Agdy  
 Jurado (I)  
 Nombre: Antonio Esteves  
 C.I. 25.892.738

Pizzella  
 Jurado (2)  
 Nombre: Giovanni Pizzella Fecha: 06/09/2021  
 C.I. 4455859

PARA SER LLENADO POR LA COORDINACIÓN DE PASANTÍA Y TRABAJO DE GRADO

He recibido Original del Acta de Aprobación para ser colocada en la solvencia Académica

Nombre del Graduando:  
 C.I.  
 Fecha:

Romanells  
 Coordinación de Pasantía y Trabajo de Grado  
 SEMESTRE: 2021-1er



UNIVERSIDAD JOSÉ ANTONIO PÁEZ

**EVALUACIÓN DE LA RESISTENCIA AL DESGASTE DE UNA  
FUNDICIÓN GRIS Y FUNDICIÓN BLANCA, POR MEDIO DE REDES  
NEURONALES.**

**Autores:**

Herrera F. Diego A.

Jaramillo A. Néstor G.

**Tutor:**

Ing. Donato Romanello

Urb. Yuma II, calle N° 3. Municipio San Diego  
Telefono: (0241) 8765395 – Celular: (0414) 6783399



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

**EVALUACIÓN DE LA RESISTENCIA AL DESGASTE DE UNA  
FUNDICIÓN GRIS Y FUNDICIÓN BLANCA, POR MEDIO DE REDES  
NEURONALES.**

Trabajo de grado presentado como requisito para optar al título de  
**INGENIERO MECÁNICO**

**Autores:**

Herrera F. Diego A.  
Jaramillo A. Néstor G.

**Tutor:** Ing. Donato Romanello

San Diego, Agosto 2021



FI-M-003-2021-ICR(TG)

Valencia, 23 de julio de 2021

Ciudadanos:  
Herrera F., Diego A.  
26.924.282  
Jaramillo A., Nestor G.  
27.434.359  
Presente-

Cumplo con informarle que la Comisión de Trabajo de Grado y Pasantías de la Facultad de Ingeniería en su reunión N° 03-2021 de fecha 26-05-2021 aprobó el proyecto de trabajo de grado titulado *EVALUACION DE LA RESISTENCIA AL DESGASTE DE UNA FUNDICION GRIS Y UNA FUNDICION BLANCA, POR MEDIO DE REDES NEURONALES*, presentado por usted (es) como requisito para optar al título de Ingeniero Mecánico.

Se ratifica la designación del Ing. Donato Romanello C.I: 4.131.877 como Tutor Académico que los asesorara en el desarrollo de este proyecto.

Atentamente,

  
Dr. Francisco Gelanzé Sevilla.  
Decano



c.c. Coordinación de Pasantías y Trabajo de Grado (1)

FG/m.a.



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

**ACEPTACIÓN DEL TUTOR**

Quien suscribe, Ing. Donato Romanello, portador de la cédula de identidad N°4.131.877, hace constar que ha leído el proyecto de trabajo de grado, presentado por los ciudadanos Herrera Franco, Diego Andrés. Titular de la cédula de identidad N° 26.924.282 y Jaramillo Aponte, Néstor Gabriel. Titular de la cedula de identidad N° 27.434.359 titulado **EVALUACIÓN DE LA RESISTENCIA AI DESGASTE DE UNA FUNDICIÓN GRIS Y UNA FUNDICIÓN BLANCA POR MEDIO DE REDES NEURONALES**, 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, 7 de Agosto del año dos mil veintiuno.

**DONATO ROMANELLO L.**

---

**Ing. Donato Romanello**  
**C.I.: 4.131.877**

## **DEDICATORIA**

El presente trabajo de grado va dedicado primero y principal a Dios y la virgen, gracias a ellos como guía hemos logrado alcanzar los objetivos e iluminarnos en el camino del bien, bendiciéndonos y dándonos sobre todo salud para continuar con nuestras metas trazadas sin desfallecer. Mis Padres Franco Ana V. y Herrera José A. quién han sido mis guías, he contado con su apoyo, su confianza y amor en este largo trayecto, me faltara vida para agradecerle lo que han hecho de mí este par de seres A mis familiares, por su amor y consejos en todos estos años, Ha sido el orgullo y el privilegio pertenecer a estas dos grandes familias.

A todas las personas que nos han apoyado y han hecho que el trabajo se realice con éxito y a compartido sus conocimientos y experiencia con nosotros, a nuestros profesores Giovanni Pizzella, Gruber Caraballo y Luis Ortega quienes con la enseñanza de sus valiosos conocimientos hicieron que podamos crecer día a día como profesionales, gracias a cada uno de ustedes por su paciencia, dedicación y apoyo incondicional.

Finalmente quisiera agradecer por las grandes amistades que en el transcurso de esta Carrera me ha dejado de los cuales no hemos nutrido mutuamente de conocimiento y experiencia inolvidables.

## **AGRADECIMIENTO**

Agradecemos primeramente a dios por permitir la realización de este trabajo y darnos la sabiduría y conocimientos necesarios para lograrlo, no hay palabras ni frases suficientes para agradecer a todas aquellas personas que han colaborado para lograr esta meta, así haya sido de una forma muy pequeña al final sin eso no hubiera sido posible llegar hasta acá, quiero hacer una mención especial a los compañeros de estudio, a los profesores, a la familia pero en especial a mis padres Néstor Jaramillo y Fexdalia Aponte que fueron son y serán parte fundamental de todo este proceso. Sin mucho más que decir  
**GRACIAS**

## ÍNDICE

<b>CONTENIDO</b>	<b>pág.</b>
<b>INDICE DE FIGURAS.....</b>	<b>xiii</b>
<b>INDICE DE TABLAS.....</b>	<b>xiv</b>
<b>INDICE DE GRÁFICOS.....</b>	<b>xv</b>
<b>RESUMEN INFORMATIVO.....</b>	<b>xvi</b>
<b>INTRODUCCIÓN.....</b>	<b>1</b>
<b>CAPÍTULO</b>	
<b>I EL PROBLEMA</b>	
1.1. Planteamiento del Problema.....	3
1.2 Formulación del problema.....	5
1.3 Objetivos de la Investigación.....	5
1.3.1 Objetivo General.....	5
1.3.2 Objetivos Específicos.....	5
1.4 justificación.....	6
1.5 alcances.....	7
1.6 limitaciones.....	7
<b>II MARCO TEÓRICO</b>	
2.1 Antecedentes de la investigación.....	8
2.2 Bases teórica.....	11
2.2.1 redes neuronales artificiales.....	11
2.2.2 Definición de redes neuronales.....	13
2.2.3 Características de las redes neuronales.....	14
2.2.4 Ventajas de las redes neuronales artificiales.....	15
2.2.5 Tipos de redes neuronales.....	16
2.2.6 Elementos que conforman una red neuronal.....	16

2.2.7 Clasificación de las redes neuronales.....	18
2.2.7.1 Según su arquitectura.....	18
2.2.7.2 Según su aprendizaje.....	20
2.2.7.3 Según su aplicación.....	21
2.2.8 Aspectos fundamentales del hierro.....	21
2.2.9 Producción del hierro y el acero.....	22
2.2.10 Fabricación del hierro.....	22
2.2.11 El hierro.....	23
2.2.12 Características del hierro.....	23
2.2.13 Introducción a las fundiciones grises.....	23
2.2.14 Clasificación de las fundiciones férricas.....	25
2.2.15 La fundición gris.....	26
2.2.16 Clasificación de las fundiciones grises.....	27
2.2.17 Composición de una fundición gris.....	28
2.2.18 Propiedades de las fundiciones grises.....	28
2.2.19 Ventajas de las fundiciones grises.....	29
2.2.20 Las fundiciones blancas.....	31
2.2.21 Fundiciones maleables.....	31
2.2.22 Fundiciones nodulares.....	32
2.2.23 Tribología de las fundiciones de hierro.....	32
2.2.24 Mecanismos de desgaste.....	33
2.2.24.1 Desgaste abrasivo.....	34
2.2.24.2 Desgaste adhesivo.....	35
2.2.24.3 Desgaste corrosivo.....	35
2.2.24.4 Desgaste por fatiga.....	35
2.2.24.5 Desgaste por cavitación.....	36
2.2.24.6 Desgaste erosivo.....	36
2.3 Definición de términos básicos.....	37

### **III MARCO METODOLÓGICO**

3.1 Tipo de investigación.....	38
3.2 Diseño de investigación.....	38
3.3 Nivel de investigación.....	39
3.4 Población y muestra.....	39
3.5 Técnicas e instrumentos de recolección de datos.....	39
3.5.1 Técnica empleada.....	40
3.5.2 Instrumento de recolección de datos.....	40
3.6 Fases de la investigación.....	41

### **IV RESULTADOS DE LA INVESTIGACIÓN**

4.1 Recaudar y obtener datos sobre el desgaste.....	42
4.1.1 Ensayo 1.....	42
4.1.1.1 Ensayo impeller tumbler.....	44
4.1.1.2 Procedimiento para realizar ensayo impeller tumbler.....	46
4.1.1.3 Resultados.....	48
4.1.1.4 Análisis metalográfico.....	49
4.1.2 Ensayo 2.....	53
4.1.2.1 Obtención de probetas.....	55
4.1.2.2 Pruebas de desgaste.....	55
4.1.2.3 Resultados.....	56
4.1.3 Ensayo 3.....	57
4.1.3.1 Equipo de prueba RWAT.....	58
4.1.3.2 Resultados.....	59
4.1.3.3 Pruebas metalográficas.....	61
4.1.4 Microestructura de fundiciones de hierro.....	74
4.2 Diseñar las redes neuronales para evaluar el desgaste.....	76
4.2.1 Pasos para crear una red neuronal.....	76
4.3 Establecer parámetros para la mejora de tiempo/precisión de la red.....	83

4.4 Comparaciones entre datos existentes y valores obtenidos por la red.....	86
4.4.1 Comparación de resultados ensayo 1.....	87
4.4.2 Comparación de resultados ensayo 2.....	87
4.4.3 Comparación de resultados ensayo 3.....	88
4.4.4 Error promedio.....	89
<b>CONCLUSIONES.....</b>	<b>93</b>
<b>RECOMENDACIONES.....</b>	<b>95</b>
<b>REFERENCIAS BIBLIOGRAFICAS.....</b>	<b>97</b>
<b>ANEXOS.....</b>	<b>99</b>

## LISTA DE FIGURAS

<b>FIGURA</b>	<b>pág.</b>
1. Neurona biológica.....	12
2. Red neuronal artificial.....	14
3. Red neuronal artificial.....	17
4. RNA con conexiones adelante mono capa.....	18
5. RNA con conexiones adelante multicapa.....	19
6. RNA con conexiones hacia atrás.....	19
7. Aprendizaje supervisado RNA.....	20
8. Dimensiones de muestra.....	43
9. Ilustración de muestra.....	44
10. Fotografía equipo IT.....	45
11. Esquema de ángulos de muestra.....	46
12. Metalografía aleación A-1.....	51
13. Metalografía aleación A-4.....	52
14. Metalografía aleación A-9.....	53
15. Dimensiones probeta de desgaste.....	58
16. Densidad y volumen perdido por muestra.....	59
17. Metalografía fundición 1.....	63
17.1 Metalografía fundición 2.....	66
17.2 Metalografía fundición 3.....	68
17.3 Metalografía fundición 4.....	71
17.4 Metalografía fundición 5.....	74
18. Datos Excel.....	77
19. Subida de datos a plataforma.....	78
20. Carga de datos a red neuronal.....	78
21. Separación de valores en X,Y.....	79
22. Separación de valores en X,Y red neuronal.....	81
23. Predicción.....	81

24. Importación de librerías.....	83
25. Épocas de la red neuronal.....	84
26. Numero de capas y neuronas.....	85
27. Loss mae msd de la RNA.....	86
28. Learning rate.....	86
29. Modelo de predicción.....	86
30. Ecuación de error promedio.....	89
31. Función stim Excel.....	95
32. Algoritmo de programación parte 1.....	99
33. Algoritmo de programación parte 2.....	99
34. Algoritmo de programación parte 3.....	100
35. Algoritmo de programación parte 4.....	101
36. Algoritmo de programación parte 5.....	101
37. Algoritmo de programación parte 6.....	102
38. Algoritmo de programación parte 7.....	102

## LISTA DE TABLAS

<b>TABLA</b>	<b>pág.</b>
1. Datos fundiciones blancas 1.....	48
2. Datos fundiciones blancas 2.....	48
3. Composición química fundiciones blancas.....	49
4. Composición química fundiciones grises.....	54
5. Composición química fundiciones blancas.....	56
6. Dureza fundiciones blancas.....	56
7. Datos fundiciones grises.....	57
8. Condiciones de operación prueba de desgaste.....	58
9. Datos fundiciones blancas.....	60
10. Error fundiciones grises.....	90
11. Error fundiciones blancas.....	90

12. Datos para RNA fundición blanca.....	91
13. Error fundición blanca 2.....	91

## LISTA DE GRÁFICOS

<b>GRÁFICO</b>	<b>pág.</b>
1. Comparación entre resultados experimentales y predicción de la Red Neuronal Fundiciones Grises .....	87
2. Comparación entre resultados experimentales y predicción de la Red Neuronal Fundiciones Blancas .....	88
3. Comparación entre resultados experimentales y predicción de la Red Neuronal Fundiciones Blancas 2 .....	89



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

**EVALUACIÓN DE LA RESISTENCIA AL DESGASTE DE  
UNA FUNDICIÓN GRIS Y FUNDICIÓN BLANCA, POR  
MEDIO DE REDES NEURONALES.**

**Autor:** Herrera Diego  
Jaramillo Néstor  
**Tutor:** Ing. Donato Romanello  
**Fecha:** Agosto 2021

**RESUMEN INFORMATIVO**

El estudio del hierro ha tenido gran relevancia en el desarrollo de la tecnología y de la industria ya que ha contribuido a la experimentación de un salto cualitativo en cuanto a la construcción de piezas metálicas. Tomando en cuenta el estudio de las redes neuronales se emplea la arquitectura más usada en los últimos años la cual corresponde al Multi Layer Perceptron MLP, multicapa la cual se seleccionó como estructura para el diseño de las redes neuronales en este estudio. El presente trabajo de investigación tuvo como objetivo general evaluar la resistencia el desgaste de una fundición gris y una fundición blanca mediante redes neuronales. Esto se realizó mediante las pruebas de desgaste y los ensayos metalográficos, lo que permitió al final hacer las comparaciones del desgaste de las fundiciones blancas y grises con MLP. La metodología de esta investigación corresponde a un proyecto factible, apoyado en una investigación documental, bajo un nivel descriptivo y en un diseño experimental. Con referencia a la técnica de recolección de datos se aplicó la observación directa y el instrumento de recolección de datos se emplea una guía de observación.

**Descriptor:** Desgaste, viruta, corrosión, tribología, hierro

## INTRODUCCIÓN

El hierro se encuentra en grandes cantidades en la corteza terrestre formando parte de diversos minerales (óxidos, minerales hidratados, carbonatos, sulfuros, entre otros). Desde tiempos prehistóricos, el hombre ha aprendido a preparar y procesar estos minerales por medio de operaciones de lavado, triturado y clasificado, separación de la ganga, calcinado, sinterizado y granulado, para fundir los minerales y obtener hierro y acero. A lo largo de la historia, muchos países han desarrollado una próspera industria siderúrgica basada en los suministros locales de mineral y en la proximidad de bosques para obtener carbón vegetal como combustible. A comienzos del siglo XVIII, el descubrimiento de que se podía utilizar coque en lugar de carbón vegetal revolucionó la industria, hizo posible un rápido desarrollo de la misma y sentó las bases para los demás avances de la Revolución Industrial.

Los estándares de hoy en día exigen que las fundiciones y su capacidad de desgaste sean evaluadas a través de procesos que arrojen resultados más precisos y efectivos con respecto al hierro. Esto ha conllevado al análisis profundo de las nuevas tecnologías como el estudio de las Redes Neuronales Artificiales RNA, pero tomando en cuenta las variables de entrada al perceptron. Por consiguiente, se tiene como propósito en esta investigación evaluar la resistencia al desgaste una fundición gris y una fundición blanca, por medio de redes neuronales artificiales, específicamente la Multi Layer Perceptron MLP.(Díaz 2017)

Así mismo resulta importante mencionar que, la presente investigación está estructurada siguiendo los pasos metodológicos pertinentes y necesarios para llevar a cabo y culminar de manera exitosa los objetivos que se plantean, el cual consta de (4) capítulos: El capítulo I, comprende el planteamiento de problema, el objetivo general, los objetivos específicos, justificación, alcance y limitaciones de esta investigación. El capítulo II, abarca marco teórico, conformado por antecedentes de la investigación bases teóricas. El capítulo II comprende marco metodológico donde se muestra

detalladamente las actividades efectuadas en esta investigación para alcanzar los objetivos propuestos. El capítulo IV se nombra los resultados, conclusiones y recomendaciones.

# CAPÍTULO I

## EL PROBLEMA

### 1.1. Planteamiento del problema

El hierro ha tenido un papel relevante en el desarrollo tecnológico e industrial de la humanidad, fue descubierto en la prehistoria y era utilizado como adorno y para fabricar armas. El objeto más antiguo existente, es un grupo de cuentas oxidadas encontradas en Egipto 4000 a.c. Todo esto, comienza en la edad del hierro con los Hilitas en el área de Palestina, donde el hierro sustituyó las labores asociadas al cobre de manera bastante rápida. El mineral de hierro es muy abundante en la tierra, supone el 5% del peso de la corteza terrestre, por lo que su aprovisionamiento no es difícil, pero, sin embargo, son necesarios combustibles de alta capacidad calorífica para su reducción, generalmente se utilizó el carbón vegetal, esto según Ordoñez (2017).

En este orden de ideas, para entender que es el hierro se debe saber que es uno de los metales que más ha contribuido a la civilización, permitiendo experimentar un salto cualitativo en cuanto a construcciones y herramientas se refiere. También, es un metal que ha estado muy presente a lo largo de la historia, ya que llevamos usándolo desde hace más de 6000 años.

Los estándares en la actualidad requieren que el uso del hierro también está limitado por la tecnología aun simple de producción en hornos abiertos a los vientos que, alcanzando temperaturas relativamente bajas, permitían la formación de una masa pastosa que era forjada a golpes de martillo, es decir; de alto contenido de carbono (baja dureza) y su aplicación en herramientas, esto de acuerdo con Palacios (2015). Todo esto surgió con la llegada de la Revolución Industrial a mediados del siglo XVIII, donde el hierro y el acero fueron las piezas fundamentales que iniciaron el desarrollo industrial.

Por otro lado, todo lo relacionado con el estudio del hierro ha llevado a la incursión de nuevas tecnologías en los últimos años, de modo que este sea mayor

calidad. Por esta razón, en 1995, la producción mundial de arrabio fue notable, es por ello que en ese mismo año la industria del acero ha experimentado una revolución tecnológica, que ha favorecido la creación de nuevas capacidades de producción mediante la instalación de hornos eléctricos de arco (EAF) para la producción del acero en todo el mundo. Los hierros también conocidos como fundiciones, son aleaciones hierro carbono que se caracterizan por tener un contenido de carbono mayor al 2% en peso; están presentes además otros elementos de aleación tales como manganeso, silicio, fósforo, entre otros, el alto contenido de carbono hace que el hierro fundido presente fragilidad por lo cual la mayoría de las fundiciones comerciales se usan porcentajes de carbono que van desde el 2,5 al 4% es decir son aleaciones hipoeutécticas.

Dentro de las aleaciones hierro-carbono las fundiciones presentan un papel importante a nivel industrial, ya que son ampliamente utilizados en la fabricación de diferentes elementos de máquina como arboles de leva, bancadas y otros elementos que se obtienen por colada, ya que las fundiciones no pueden someterse a procesos de deformación plástica. Las fundiciones blancas presentan un contenido de carbono que oscila entre 1,8 y 3.6%, por su parte el contenido de silicio se encuentra entre el 0,5 y 2%. Generalmente, el carbono se presenta en forma de cementita lo que la hace extremadamente dura y muy frágil, limitándola solo a aplicaciones de resistencia al desgaste. Por su parte, la fundición gris presenta un contenido de carbono que varía entre 2.5 y 4% y debido a que el grafito que se encuentra en forma laminar posee gran facilidad a los mecanizados debido a que este cumple una función lubricante en el desprendimiento de la viruta.

En general, las piezas realizadas con fundiciones son bastante más económicas que sus homologas en acero, pero estas tienen cierta ventaja en aplicaciones de desgaste, ya que en ese apartado ofrecen igual o inclusive mejores propiedades que los aceros a un costo menor, debido a esto surge la

necesidad de desarrollar un método para evaluar la resistencia al desgaste de las fundiciones gris y blanca.

Si se desea saber la resistencia al desgaste que pudieran tener ciertas piezas en su campo de trabajo, teniendo resultados similares a los obtenidos en los laboratorios, la mejor opción sería usando redes neuronales, que su objetivo es resolver los problemas de la misma manera que el cerebro humano, aunque las redes neuronales son más abstractas, reúnen una serie de técnicas informáticas para realizar funciones de aprendizaje y autocorrección a través de algoritmos o códigos de programación computacional para resolver diversos problemas, de forma similar a como lo haría el ser humano.

## **1.2. Formulación del problema**

Ya definido el problema se plantea la siguiente interrogante: ¿Cómo evaluar la resistencia al desgaste de una fundición gris y una fundición blanca?

## **1.3. Objetivos de la investigación**

### **1.3.1. Objetivo General**

Evaluar la resistencia al desgaste de una fundición gris y una fundición blanca mediante redes neuronales.

### **1.3.2. Objetivos específicos**

1. Recaudar y obtener datos sobre el desgaste y la forma en la que ocurre en las distintas fundiciones.
2. Diseñar las redes neuronales para evaluar el desgaste en la fundición gris y blanca.
3. Establecer parámetros para la mejora del tiempo de respuesta y precisión de las redes neuronales.
4. Realizar comparaciones entre datos ya existentes y valores obtenidos por medio de redes neuronales.

## **1.4. Justificación**

En la mayoría de los componentes o piezas mecánicas diseñadas, puede llegar a existir una probabilidad de falla, es por tal motivo, que en el área de ingeniería se han desarrollado amplios estudios de los tipos de fallas que se pueden producir y las causas

que originan las mismas. Una falla muy importante que sucede en piezas mecánicas es el desgaste es un fenómeno físico que conduce a una pérdida o deformación del material. El fallo por desgaste es el tipo de fallo cuya probabilidad de aparición se incrementa con el tiempo de operación o con el número de operaciones del elemento o de las tensiones aplicadas. Los distintos equipos tienen muchos componentes que se desgastan al hacer su trabajo.

Por ellos para ciertos tipos de aplicaciones se usan fundiciones de hierro que son aleaciones de hierro carbono del 2 al 5%, cantidades de silicio del 2 al 4%, del manganeso hasta 1%, bajo azufre y bajo fósforo. Se caracterizan por que se pueden vaciar del horno cubilote para obtener piezas de muy diferente tamaño y complejidad, pero no pueden ser sometidas a deformación plástica, no son dúctiles ni maleables y poco soldables, pero sí maquinables, relativamente duras y resistentes a la corrosión y al desgaste.

La mayor ventaja de las fundiciones de hierro es su alta resistencia al desgaste, que es una propiedad que depende principalmente de las características de la roca madre. Este factor cobra importancia cuando las partículas van a estar sometidas a un roce continuo como es el caso de pisos y pavimentos, para lo cual los agregados que se utilizan deben estar duros. Las fundiciones son muy usadas en el área de la ingeniería por ser más fáciles de maquinar que los aceros, se pueden fabricar piezas de diferente tamaño y complejidad, al tener las fundiciones unas temperaturas de fusión claramente inferiores a las de los aceros, en su fabricación no se necesitan equipos ni hornos muy costosos, por lo que las instalaciones necesarias son más sencillas y económicas. Absorben las vibraciones mecánicas y actúan como auto lubricantes. Son resistentes al choque térmico, a la corrosión y presentan buena resistencia al desgaste y son relativamente duras.

De esta manera se puede decir que, la importancia de la elaboración de esta investigación consiste en utilizar la herramienta de redes neuronales artificiales para así evaluar la resistencia al desgaste de las fundiciones grises y fundiciones blancas, por medio de los conocimientos previos experimentales

y teóricos, con la convicción de que dicha herramienta pueda dar resultados bastantes precisos, asemejándose de manera directa a los obtenidos de forma convencional, Díaz (2017). Por otra parte, también se justifica este estudio ya que las redes neuronales artificiales tienen suficiente nivel de confianza para ser utilizada como medio alternativo al normalizado para la obtención de los resultados de resistencia al desgaste de una fundición gris y fundición blanca.

### **1.5. Alcance**

La investigación se basará en el uso de redes neuronales artificiales para evaluar la resistencia al desgaste en una fundición gris y una fundición blanca siguiendo lineamientos previamente descritos en los objetivos trazados para dicha investigación.

### **1.6. Limitaciones**

Esta investigación se realizará mediante el uso de herramientas como las son las redes neuronales, para de esta forma evaluar el desgaste de una fundición gris y una fundición blanca, limitando únicamente el estudio en el fundamento de variables en la tribología de la red neuronal perceptron multicapa.

## CAPÍTULO II

### MARCO TEÓRICO

#### **2.1 Antecedentes de la investigación**

En este capítulo se presenta la recopilación de una serie de aspectos teóricos que sirven de sustento a la presente investigación. En primer lugar, se presentan algunas investigaciones que se utilizaron de referencia en cuanto al tipo de problema, así como también la metodología y la manera en que los autores abordaron dichos problemas. Luego se hará una revisión teórica que permitirá facilitar la recopilación de la información, y fortalecer los conocimientos de las herramientas empleadas y por último se presentan las definiciones del conjunto de términos usados en este trabajo de grado.

Se destaca primeramente un estudio llevado a cabo en la Universidad de Cesar Vallejo- Perú por Malaver Manuel (2015), para obtener el grado de Ingeniero en Sistemas titulado **“Aplicación de Redes Neuronales para determinar el pronóstico de las ventas en la empresa Catering & Buffets MyS ubicada en la ciudad de Piura”**. La presente investigación tuvo como objetivo principal determinar el pronóstico de las ventas de los servicios que ofrece Catering & Buffets MyS con el menor porcentaje de error al aplicar las redes neuronales. Esto se logró gracias a la metodología que planteó Kaastra y Boyd, donde se encuentra una serie de pasos para poder modelar desde cero la red neuronal para obtener el pronóstico. El tipo de red neuronal que se seleccionó fueron las redes neuronales multicapas, puesto que, poseen una capa oculta donde se realiza todo el procesamiento de los datos que la capa de entrada le suministra y cuyo resultado es enviada a la capa de salida. Se realizaron tres diferentes configuraciones de red neuronal para hallar el más mínimo error, siendo la tercera red neuronal planteada, la más adecuada por presentar el menor porcentaje de error (1%), con lo que se logró comprobar la hipótesis planteada. Como conclusión a esta investigación, se comprobó que las redes multicapas son las más adecuadas para realizar los pronósticos de las ventas, y que la

herramienta de red neuronal son precisas para este tipo de aplicación. La relación de dicha investigación con este trabajo de grado, está en que el uso de la red neuronal permite obtener un resultado confiable para establecer el nivel de confianza en los resultados.

De la misma manera, se menciona un estudio realizado en la Universidad Tecnológica de Buenos Aires por Gómez Manuel (2016), para obtener el grado de Ingeniero en Sistemas titulado **“Redes Neuronales aplicadas a los negocios: Análisis de un caso”**. El propósito de este trabajo es desarrollar un modelo que permita el reconocimiento de patrones de negocio. Para resolver este problema de una manera simple y eficiente se utilizarán redes neuronales artificiales, que mediante el aprendizaje supervisado simplifican y aceleran el proceso de procesamiento de la información, con el propósito de encontrar patrones implícitos dentro de la masa de la información. El objetivo planteado es el de aplicar las redes neuronales artificiales a un problema real de negocio, con el fin de encontrar la solución al principal problema de los negocios, es decir, la satisfacción de las necesidades del cliente. Específicamente, se trabajará sobre una base de datos de ventas de una confitería, analizando los patrones y comportamientos de ventas con el fin de optimizar la oferta en función de los clientes. Utilizando herramientas de redes neuronales artificiales se estudiarán los patrones de consumo de los clientes de la confitería (estudio de clasificación) y la composición de dicha clientela (estudio de segmentación o “clustering”). En base a los resultados de la misma, se analizarán posibles mejoras a la oferta del local. Como conclusión, se intentará demostrar la viabilidad de la aplicación de las redes neuronales al mundo de los negocios. También, este guarda una estrecha relación con esta investigación ya que a través del uso de las redes neuronales se observaron los patrones de consumo (gastos) sobre la base de datos del negocio en particular.

Por otra parte, es destacado un estudio realizado en la Universidad de UBI de Mallorca por Montaña Juan (2016), para obtener el título de Psicólogo en su trabajo

titulado **“Redes Neuronales Artificiales aplicadas al análisis de datos”**. El estudio del efecto o importancia de las variables de entrada en una red MLP es uno de los aspectos más críticos en la utilización de las RNA orientadas al análisis de datos, debido a que el valor de los parámetros obtenidos por la red no tiene una interpretación práctica a diferencia de un modelo de regresión clásico. Como consecuencia, las RNA se han presentado al usuario como una especie de “caja negra” a partir de las cuales no es posible analizar el papel que desempeña cada variable de entrada en la predicción realizada.

A modo de resumen, se exponen los objetivos e hipótesis que nos planteamos en la tesis, según la línea de investigación llevada a cabo. En la aplicación de RNA al campo de las conductas adictivas, nos proponemos dos objetivos: a) La creación de una red neuronal capaz de discriminar entre sujetos consumidores y no consumidores de éxtasis a partir de las respuestas dadas a un cuestionario en la población de jóvenes europeos. b) La identificación de los factores de riesgo asociados al consumo de éxtasis mediante la aplicación de un análisis de sensibilidad. Hemos podido comprobar a partir del estudio bibliométrico que las principales áreas de aplicación de las RNA en nuestra base de datos son la medicina, la ingeniería y la biología. También se ha observado que las aplicaciones en el campo de las ciencias del comportamiento aún son incipientes.

Dentro de este campo, el uso y abuso de sustancias comprende un conjunto de conductas complejas que son iniciadas, mantenidas y modificadas por una variedad de factores conocidos y desconocidos. La relación de este estudio en particular radica en que a través de la aplicación de una red neuronal se obtienen resultados de gastos o consumos y el comportamiento de los mismos.


También, se menciona un estudio realizado en la Universidad Nacional de Cajamarca por Díaz Manuel (2017), para obtener el título de Ingeniero Civil en su trabajo titulado **“Uso de las Redes Neuronales Artificiales en el Modelado del ensayo de resistencia a compresión de concreto de construcción según la norma ASTM C39/C39M”**. El objetivo principal de la presente tesis, consiste en el pronóstico de la Resistencia a Compresión del concreto mediante un sistema basado en Redes

Neuronales Artificiales. La metodología implementada consistió inicialmente en recopilar una base histórica de diseños de mezclas (propiedades físicas de los agregados y cantidades de materiales por m<sup>3</sup>), para resistencias a la compresión del concreto comprendidas entre 210kg/cm<sup>2</sup> y 300kg/cm<sup>2</sup>, de trabajos de tesis ejecutadas en la Facultad de Ingeniería, así como las correspondientes resistencias a la compresión de los testigos ensayados según la norma ASTM C39. Luego se aplicó el software MATLAB para la fase de aprendizaje y entrenamiento del mismo, proponiéndose cinco Redes Neuronales Artificiales (Perceptrones Multicapa) que pronostiquen la Resistencia a la Compresión de cuatro diseños de mezclas (de f'c de 210kg/cm<sup>2</sup>, 250kg/cm<sup>2</sup>, 280kg/cm<sup>2</sup> y 300kg/cm<sup>2</sup>) a las edades de 7, 14 y 28 días (10 testigos para cada ensayo, haciendo un total de 120 probetas), y en el proceso de contraste y validación, se encontró una tasa de error de hasta 3.29%, lo que permite concluir que este método es totalmente válido en el diseño de proyección del concreto normal. La relación que guarda esta investigación, reafirma que la técnica más adecuada para evaluar el desgaste o consumo es a través de redes neuronales ya que es precisas y confiables en el momento de valorar algún parámetro.

## **2.2 Bases teóricas**

### **2.2.1 Redes Neuronales Artificiales.**

Las Redes Neuronales Artificiales, imitan el funcionamiento del sistema nervioso, sistemas que actúan como los humanos (son aquellos que imitan el comportamiento del hombre, el ejemplo más claro es el del robot), sistemas que piensan de modo racional (se caracterizan por imitar el pensamiento lógico de los humanos), es decir, en una cuestión concreta razonan como expertos. Se los emplea especialmente a la hora de buscar mejoras en la calidad y en la rapidez de un servicio) y sistemas que actúan de manera racional (imitan de carácter racional el comportamiento de una persona, siendo capaces de percibir el entorno y actuar en consecuencia) a través de las neuronas biológicas, como lo muestra la figura 1.



**Figura 1.** Neurona Biológica.

Fuente: Díaz ( 2017).

El cerebro humano posee unos diez mil millones de células nerviosas, o neuronas. En promedio, cada neurona se conecta a otras a través de unas diez mil conexiones, o “sinapsis”. La red neuronal del cerebro forma un sistema masivo de procesamiento paralelo de información, en contraste con las computadoras en las cuales un único procesador ejecuta linealmente una serie de instrucciones.

Resulta importante destacar, que las redes neuronales nacieron gracias a la investigación en Inteligencia Artificial. Más específicamente, surgieron de los intentos de imitar la tolerancia a fallas y capacidad de aprendizaje de los sistemas neurales biológicos a través de modelar la estructura de bajo nivel del cerebro, Gómez (2016). Si bien esta tecnología parece moderna, sus orígenes se remontan a la primera mitad del siglo XX.

La inteligencia es la capacidad de elegir, entre varias posibilidades, aquella opción más acertada para la resolución de un problema. En este sentido, cabe distinguirla de la sabiduría, en tanto que esta última es tan solo una acumulación de conocimiento, mientras que la inteligencia implica hacer el mejor uso de un saber previo. No obstante, el modo para identificar la cualidad de ser inteligente ha sido enormemente debatido. En el ámbito de las ciencias de la computación se denomina como inteligencia artificial a la facultad de razonamiento que ostenta un agente que no está vivo, tal es el caso de un robot, por citar uno de

los ejemplos más populares, y que le fue conferida gracias al diseño y desarrollo de diversos procesos gestados por los seres humanos, Díaz (2017). Cabe destacarse que además del poder de razonar, estos dispositivos son capaces de desarrollar muchas conductas y actividades especialmente humanas como puede ser resolver un problema dado, practicar un deporte, entre otros.

El concepto de Inteligencia Artificial, también conocido por las siglas AI, se le debe al informático estadounidense John McCarthy, quien en el año 1956 lo pronunció por primera vez en una conferencia causando un gran impacto en el ámbito de la tecnología. A partir de ese entonces, el concepto se esparció fantásticamente por el mundo y por ello hoy es tan común su uso cuando queremos referirnos a aquellas máquinas o aparatos dotados de una inteligencia símil a la de los seres humanos, Díaz (2017). McCarthy además del concepto aportó muchísimos conocimientos de vanguardia al campo de la inteligencia artificial.


### **2.2.2 Definición de redes neuronales artificiales.**

Una Red Neuronal Artificial (RNA) es un paradigma de procesamiento de información que está inspirado en la forma en que los tejidos nerviosos biológicos, tales como el cerebro, procesan la información. El elemento clave de esta corriente es la estructura novedosa del sistema de discernir de la información. Se compone de un gran número de elementos de procesamiento altamente interconectados (neuronas) funcionando al unísono para resolver problemas específicos, es por ello que se ha convertido en una opción viable para la ingeniería, Gómez (2016).

Por otra parte, también Díaz (2017) define las Redes Neuronales:

Las Redes de Neuronas Artificiales (denominadas habitualmente en castellano como RNA o en inglés como ANN, por Artificial Neural Networks) pueden definirse en primera aproximación como redes interconectadas masivamente en paralelo de elementos básicos muy simples de tipo software o hardware con organización jerárquica, capaces de adoptar un comportamiento colectivo adaptativo con el

que intentan interactuar con los objetos del mundo real de modo análogo como lo hace el sistema nervioso biológico.



**Figura 2.** Red Neuronal Artificial.

Fuente: Chaparrini, F (2018).

Así mismo, una RNA intenta emular las funciones computacionales elementales de la red nerviosa del cerebro humano, en base a la interconexión de multitud de elementos de procesamiento, cada uno de los cuales presenta un comportamiento completamente local, un ejemplo de esto lo demuestra la figura 2. Cada conexión está asociada a un peso, que representa la información utilizada por las neuronas para resolver un problema específico.

### **2.2.3 Características de las redes neuronales artificiales.**

Las características fundamentales de las RNA son: (Jaramillo, 2005).

- **Aprenden de la experiencia:** las RNA pueden modificar su comportamiento como respuesta a su entorno. Dado un conjunto de entradas, las RNA se ajustan para producir respuestas consistentes.
- **Generalizan de ejemplos anteriores a los ejemplos nuevos:** una vez que la RNA esté entrenada, la respuesta de la red puede ser, hasta un cierto punto, insensible a pequeñas variaciones en las entradas, lo que las hace idóneas para el reconocimiento de patrones.
- **Abstracción de la esencia de las entradas:** Algunas RNA son capaces de abstraer información de un conjunto de entradas. Por ejemplo, en el caso de reconocimiento de patrones, una red puede ser entrenada en una

secuencia de patrones distorsionados de una letra. Una vez que la red sea correctamente entrenada será capaz de producir un resultado correcto ante una entrada distorsionada, lo que significa que ha sido capaz de aprender algo que nunca había visto.

#### **2.2.4 Ventajas de las Redes Neuronales Artificiales.**

De acuerdo con Díaz (2017):

- No linealidad. El procesador neuronal es básicamente no lineal y, por consecuencia la red neuronal también.
- Aprendizaje. Las RNA tienen la habilidad de aprender mediante una etapa que se llama etapa de aprendizaje. Esta consiste en proporcionar a la RNA datos como entrada, a su vez que se le indica cuál es la salida (respuesta) esperada.
- Auto organización. Una RNA crea su propia representación de la información en su interior, descargando al usuario de esto.
- Adaptabilidad. La red tiene la capacidad de adaptar sus parámetros, aún en tiempo real.
- Tolerancia a fallos. Debido a que una RNA almacena la información de forma redundante, ésta puede seguir respondiendo de manera aceptable aun si se daña parcialmente.
- Uniformidad en el análisis y diseño. Esto permitirá garantizar características precisas.
- Tiempo real. La estructura de una RNA es paralela, por lo cual, si esto es implementado con computadoras o en dispositivos electrónicos especiales, se pueden obtener respuestas en tiempo real.
- Analogía con las redes biológicas. Esto permite la utilización mutua del conocimiento de las dos áreas.

### **2.2.5 Tipos de Neuronales Artificiales.**

Las neuronas artificiales se pueden clasificar de acuerdo a los valores que pueden tomar, Matick (2016). Entonces, es suficiente diferenciar entre dos tipos principales:

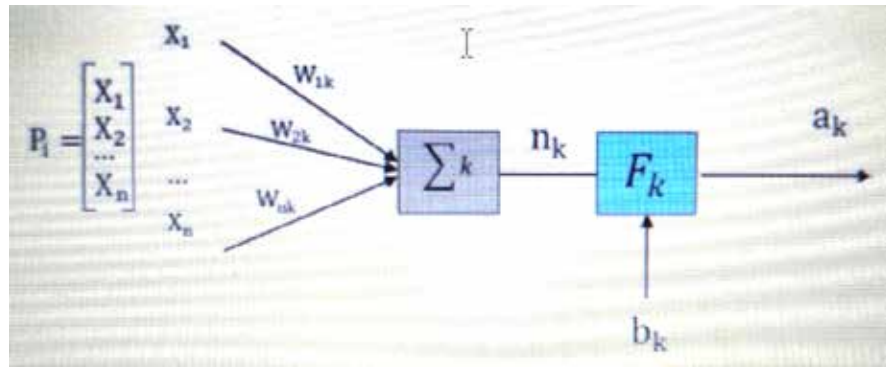
- Neuronas binarias.
- Neuronas reales.

Las neuronas binarias solamente pueden tomar valores dentro del intervalo  $\{0, 1\}$  o  $\{-1, 1\}$ , mientras que las neuronas reales pueden hacerlo dentro del rango  $[0, 1]$  o  $[-1, 1]$ . Los pesos normalmente no están restringidos a un cierto intervalo, aunque para aplicaciones específicas puede ser esto necesario.

### **2.2.6 Elementos que componen una red neuronal.**

Las redes neuronales artificiales están constituidas por una serie de neuronas interconectadas y arregladas en tres capas (esto último puede variar). Los datos ingresan por medio de la “capa de entrada”, pasan a través de la “capa oculta” y salen por la “capa de salida”, Matick (2016). Cabe mencionar que la capa oculta puede estar constituida por varias capas.

Según Díaz (2017), los elementos individuales de cálculo que forman los modelos de sistemas neuronales artificiales, reciben el nombre de Elementos de Procesado o Neuronas Artificiales. Cada unidad realiza un trabajo muy simple: recibe impulsos de otras unidades o de estímulos externos y calcula una señal de salida que propaga a otras unidades y, además, realiza un ajuste de sus pesos. Este tipo de modelos, es inherentemente paralelo en el sentido de que varias unidades pueden realizar sus cálculos al mismo tiempo, como lo muestra la figura 3.



**Figura 3.** Red Neuronal Artificial.

Fuente: Díaz, M (2017).

$$a = F_k (W_{ij} P_i + b_k) \quad \text{Ec. 1}$$

Donde:

a: es la salida de la neurona.

F<sub>k</sub>: es la función de transferencia de la neurona.

W<sub>ij</sub>: es la matriz de pesos.

P<sub>i</sub>: es el patrón de entrenamiento.

b<sub>k</sub>: es el umbral de activación de la neurona.

Este esquema de elemento de procesado tiene las siguientes características, Díaz (2017):

- Cada elemento de procesado puede tener varias entradas asociadas a propiedades diferentes.
- La entrada de tendencia es opcional (valor constante).
- Las entradas pueden ser: Excitadoras, inhibitoras, de ganancia, de disparo fortuito o de amortiguamiento.
- Las entradas están ponderadas por un factor multiplicativo de peso o intensidad de conexión que resaltan de forma diferente la importancia de cada entrada.
- Cada elemento de procesado tiene un valor de activación calculado en función del valor de entrada neto (calculado a partir de las entradas y los

pesos asociados a ellas). En algunos casos, el valor de activación, depende además de la entrada neta del valor anterior de activación.

- Una vez calculado el valor de activación, se determina un valor de salida aplicando una función de salida sobre la activación del elemento de procesado.

### 2.2.7 Clasificación de las Redes Neuronales Artificiales.

Las RNA se pueden clasificar según su arquitectura, el tipo de aprendizaje y según sus aplicaciones, Díaz (2017),

### 2.2.8 Según su Arquitectura.


Las neuronas de una RNA están distribuidas en niveles o capas que están unidas entre sí por conexiones llamadas sinapsis; dependiendo del sentido de sus conexiones pueden ser recurrentes y no recurrentes.

#### **Con Conexiones hacia Adelante (No Recurrentes o Feedforward)**

Son aquellas cuyas conexiones son hacia adelante y unidireccionales. Según el número de capas que posean pueden ser Monocapas o Multicapas.

#### **Redes Neuronales Monocapa.**

Sólo tienen una capa de neuronas que proyectan las entradas a una capa de neuronas de salida, donde se realizan diferentes cálculos.



**Figura 4.** RNA con conexiones adelante Mono-capa.

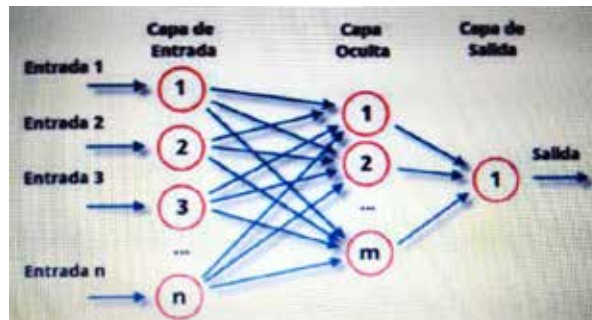
Fuente: Díaz, M (2017).

Entre las RNA más conocidas con esta arquitectura se encuentran: el Monolayer Perceptron y el ADALINE (como perceptrón, pero con función lineal a la salida), como lo muestra la figura 4.

#### **Redes Neuronales Multicapa.**

Es una generalización de la anterior existiendo un conjunto de capas intermedias entre la entrada y la salida.

Entre las RNA más conocidas con esta arquitectura se encuentran el Multilayer Perceptron y el MADALINE, como lo describe la figura 5.




**Figura 5.** RNA con conexiones adelante Multicapa.

Fuente: Díaz, M (2017).

### **Con Conexiones hacia Atrás (Recurrentes o Feedback)**

Se caracterizan por la existencia conexiones de retorno entre neuronas de una determinada capa con otras de capas anteriores, conexiones entre neuronas una misma capa o conexiones de una neurona consigo misma, como lo muestra la figura 6.



**Figura 6.** RNA con conexiones hacia atrás.

Fuente: Díaz, M (2017).

Entre las más conocidas con esta arquitectura se encuentran las SOM de Kohonen, Hopfield y las redes ART.


### **2.2.9 Según Su Aprendizaje**

#### **Aprendizaje No Supervisado (Sin Maestro)**

Estas redes no tienen una referencia de comparación por lo cual contemplan auto organización y auto asociación, como procesos de obtención de la salida de la red. Se caracteriza por que la salida no requiere ser contrastada con algo específico ya conocido (maestro). El aprendizaje no supervisado es conocido también como auto supervisado no requieren influencia externa para ajustar los pesos de las conexiones entre sus neuronas, por ello, suele decirse que estas redes son capaces de auto organizarse.

### Aprendizaje Supervisado (con Maestro)

Cuando tiene un supervisor en el entrenamiento de la red, significa que existe un parámetro de referencia ya conocido (maestro), el cual es comparado con las salidas de la red, el aprendizaje supervisado se caracteriza por un entrenamiento controlado por un agente externo que determina la respuesta que debería generar la red a partir de una entrada determinada, un ejemplo de este tipo de neurona lo describe la figura 7. El supervisor comprueba la salida de la red y en el caso de que ésta no coincida con la deseada, se procederá a modificar los pesos de las conexiones, con el fin de conseguir que la salida obtenida se aproxime a la deseada.



**Figura 7.** Aprendizaje supervisado de una RNA.

Fuente: Díaz, M (2017).

#### 2.2.10 Según su Aplicación.

- Redes de Reconocimiento de Patrones, son del tipo no recurrente y con aprendizaje supervisado.

- Redes de Clasificación, hacen uso del aprendizaje no supervisado para obtener características de clasificación a base de las entradas del problema.
- Redes de Predicción, tienen como objetivo modelar una función no lineal.
- Redes de Mapeo de Características.

#### **2.2.11. Aspectos fundamentales del hierro.**

Desde tiempos prehistóricos, el hombre ha aprendido a preparar y procesar este mineral es por medio de operaciones de lavado, triturado y clasificado, separación de la ganga, calcinado, sinterizado y granulado, para fundir los minerales y obtener hierro y acero, Moffil (2015). A lo largo de la historia, muchos países han desarrollado una próspera industria siderúrgica basada en los suministros locales de mineral y en la proximidad de bosques para obtener carbón vegetal como combustible.

A comienzos del siglo XVIII, el descubrimiento de que se podía utilizar coque en lugar de carbón vegetal revolucionó la industria, hizo posible un rápido desarrollo de la misma y sentó las bases para los demás avances de la Revolución Industrial. Los países que poseían yacimientos naturales de carbón próximos a yacimientos de mineral de hierro disfrutaron de grandes ventajas, Moffil (2015).

Durante los últimos decenios, se han desarrollado y alcanzado el éxito los procesos conocidos como de reducción directa. Los minerales de hierro, en especial los de ley alta o los enriquecidos, se reducen a hierro esponjoso por extracción del oxígeno que contienen, obteniéndose de este modo un material ferroso que sustituye a la chatarra.

#### **2.2.12. Producción del hierro y el acero.**

En 1995, la producción mundial de arrabio fue de 578 millones de toneladas. Ese mismo año, la producción mundial de lingote de acero alcanzó los 828 millones de toneladas. La industria del acero ha experimentado una revolución tecnológica que ha favorecido la creación de nuevas capacidades de producción mediante la instalación de hornos eléctricos de arco (EAF, electric

arc furnace) alimentados con chatarra de acero reciclada en pequeñas acerías, Moffil (2015). Aunque las acerías integradas que producen acero a partir de mineral de hierro están logrando altas cotas de eficiencia, las acerías EAF con capacidades de producción inferiores a 1 millón de toneladas anuales son cada vez más habituales en los principales países productores de acero de todo el mundo.

### **2.2.13. Fabricación del hierro.**

La principal peculiaridad de la fabricación de hierro es el alto horno, en el cual se funde (reduce) el mineral de hierro para producir el arrabio. El horno se carga por la parte superior con mineral de hierro, coque y caliza; por la solera se inyecta aire caliente, a menudo enriquecido con oxígeno; y el monóxido de carbono producido a partir del coque transforma el mineral de hierro en un arrabio con carbono.

Es por ello, que la caliza actúa como fundente. A la temperatura de 1.600°C, el arrabio se funde y se acumula en la solera, y la caliza se combina con la tierra formando escoria, Moffil (2015). El horno se sangra (es decir, se retira el arrabio) periódicamente, y entonces el arrabio puede moldearse en forma de lingotes para su uso posterior (por ejemplo, en fundiciones), o se recoge en crisoles en los que se traslada, todavía fundido, a la acería.

Es importante destacar, que algunas grandes plantas disponen de hornos de coque en la misma instalación. Generalmente, los minerales de hierro se someten a procesos especiales de preparación antes de ser cargados en el alto horno (lavado, reducción a un tamaño óptimo por triturado y cribado, separación del mineral menudo para sinterizarlo y granularlo, clasificación mecánica para separar la ganga, calcinado, sinterizado y granulado). La escoria retirada del horno puede transformarse en la planta para otros usos, en especial para fabricar cemento.

#### **2.2.14. El hierro.**

Es el más importante de los metales utilizados en la en la construcción de ingeniería, es decir que es usado en ingeniería civil y geotecnia. Está disponible en abundancia, pero no ocurre libremente en la naturaleza. Este debe su mayor utilidad al hecho de que se alea libremente con otros elementos, y sus propiedades inherentes se alteran y mejoran notablemente para diferentes condiciones de servicio. Los principios químicos fundamentales en la extracción del hierro de los minerales son muy simples, Moffil (2015).

El calentamiento de los minerales en presencia de un agente reductor dará como resultado la formación de CO o CO<sub>2</sub>, librado como un gas y hierro metálico.

#### **2.2.15. Características del hierro.**

- El hierro puro es un metal plateado que conduce bien el calor y la electricidad. El hierro es demasiado reactivo para existir solo, por lo que solo ocurre naturalmente en la corteza terrestre como minerales de hierro, como hematita, magnetita y siderita.
- Una característica de identificación del hierro es que es fuertemente magnético.
- Expuesto a un fuerte campo magnético, cualquier pieza de hierro puede magnetizarse. Los científicos creen que el núcleo de la tierra está formado por aproximadamente 90% de hierro.

#### **2.2.16. Introducción a las fundiciones férreas.**

Las fundiciones son aleaciones de hierro, carbono y silicio que generalmente contienen también manganeso, fósforo y azufre. Son de mayor contenido en carbono que los aceros (2,5 a 4 %) y adquieren su forma definitiva directamente por colada, no siendo nunca las fundiciones sometidas a procesos de deformación plástica ni en frío ni en caliente. En general, no son dúctiles ni maleables y no pueden forjarse ni laminarse, pero existen algunas fundiciones que son excepción, las cuales son tenaces y tienen cierta ductilidad.

En este grupo de excepción se incluyen las fundiciones maleables y otras especiales como las fundiciones “dúctiles” de grafito esferoidal, cuya fabricación se ha iniciado todavía hace muy pocos años. El cubilote es la instalación más empleada para la fabricación de la mayoría de las piezas de fundición, Moffil (2015). Un porcentaje de piezas mucho más pequeñas se obtienen utilizando hornos de reverbero, hornos de crisol y hornos eléctricos, siendo estas últimas instalaciones las más utilizadas para la fabricación de fundiciones de calidad, fundiciones aleadas y de alta resistencia. En algunos casos excepcionales se fabrican piezas de gran tamaño, colando directamente la fundición desde el horno alto.

Para la fabricación de piezas de fundición, se emplean generalmente como materia prima fundamental el arrabio. Además, se utilizan, también en las cargas de los hornos y cubilotes, chatarras de fundición, y a veces, se emplean además cantidades variables de chatarra de acero. Durante los procesos de fabricación se suelen hacer algunas veces adiciones de ferrosilicio y ferromanganeso y, en algunas ocasiones especiales, se añade también ferrocromo y níquel, para obtener en cada caso la composición deseada.

En la práctica, el contenido de carbono varía de 2,5 a 4 %, siendo lo más frecuente que oscile de 2,75 a 3,5 %. El contenido en silicio suele oscilar de 1 a 3,8 % y el de manganeso de 0,4 a 1,5 %. Muy raras veces los contenidos de silicio y manganeso llegan al 4 %, y en ocasiones se fabrican fundiciones especiales hasta el 15 % de silicio. Los porcentajes de azufre suelen oscilar de 0,01 a 0,12 %, los de fósforo de 0,020 a 0,10 % y en algunos casos llega a 1,5 %. Para conseguir ciertas características especiales, se fabrican fundiciones aleadas que, además de los elementos citados, contienen también porcentajes variables de cobre, níquel, cromo, molibdeno.

#### **2.2.17. Clasificación de las fundiciones férreas.**

Por ser muchos y muy diferentes los factores que hay que tener en cuenta para la clasificación y selección de las fundiciones, es difícil establecer una

clasificación simple y clara de las mismas, Moffil (2015). La más antigua y conocida de las clasificaciones establece cuatro grupos: fundición blanca, gris, atruchada y maleable. A estos cuatro grupos se le añade en la actualidad otro grupo, el de las fundiciones especiales, en el que se pueden incluir las fundiciones aleadas que contienen elementos especiales, las fundiciones nodulares, aciculares e inoculadas.

- **Por su fractura**

El criterio es el aspecto de las fracturas que presentan al romperse los lingotes de hierro, obtenidos en el horno alto colados en arena. Por el aspecto que tienen después de rotas las piezas fundidas, se clasifican en: fundición gris, blanca y atruchada. La fundición gris contiene, en general mucho silicio, 1 a 3,8 %; la blanca poco silicio, generalmente menos del 1 %, y la atruchada tiene, comúnmente, un contenido de silicio intermedio, variable de 0,6 a 1,5 %. El color oscuro que tienen las estructuras de las fundiciones grises y atruchadas, se debe a la presencia en las mismas de gran cantidad de láminas de grafito.

El contenido en silicio de las aleaciones hierro - carbono y la velocidad de enfriamiento, tienen gran influencia en la formación de una u otra clase de fundición. Las velocidades de enfriamiento muy lentas favorecen la formación de fundición gris; el enfriamiento rápido tiende en cambio, a producir fundición blanca.

- **Por su microestructura**

Las fundiciones que se obtienen en los hornos altos y en los cubilotes se pueden clasificar de acuerdo con la microestructura en tres grandes grupos:

1. Fundiciones en las que todo el carbono se encuentra combinado, formando cementita y que al romperse presentan fracturas de fundición blanca. Fundiciones en las que todo el carbono se encuentra en estado libre, formando grafito. Las cuales son llamadas fundiciones ferríticas.
2. Fundiciones en las que parte del carbono se encuentra combinado formando cementita y parte libre en forma de grafito. A este grupo, que es el más

importante de todos, pertenecen la mayoría de las fundiciones que se fabrican y utilizan normalmente, como son las fundiciones grises atruchadas, perlíticas.

### **2.2.18. La fundición gris.**

Se llama así por el aspecto de su fractura, que es de color gris. Es aquella en la cual el carbono se encuentra en alto grado o en su totalidad en estado libre en forma de grafito laminar. La fundición gris (a excepción de la blanca) se diferencia del acero debido que en su estructura hay inclusiones de grafito cuya cantidad, forma, tamaño y distribución varían dentro de unos límites muy amplios y da lugar a diferentes fundiciones grises. Estas fundiciones son un material compuesto de grafito, y de otro material matriz que frecuentemente está compuesto por un intermetálico cerámico (cementita), y otro material (ferrita) que es metálico, Moffil (2015).

Por consiguiente, Su colabilidad es mejor en cuanto mayor sea el contenido de carbono por ser pequeño el intervalo de temperaturas entre líquido y sólido. Algunas de ellas, las de composición eutéctica, solidifican a temperatura constante. Las fundiciones grises dan poco rechupe, 1 % de contracción lineal aproximadamente, inferior a la de los aceros y fundiciones blancas. La pequeña contracción al solidificar se debe a que su densidad (entre 6,95 y 7,35 g/cm<sup>3</sup>, menor cuanto más carbono) es inferior a la de las fundiciones blancas (7,7 g/cm<sup>3</sup>) y a la de los aceros (7,87 g/cm<sup>3</sup>).

La característica radical de las fundiciones grises es que no presentan ledeburita. En su estructura micrográfica aparece grafito, que puede ser de diversos tipos, disperso en una matriz similar a la de un acero. El comportamiento mecánico de una fundición gris resulta parecido al de un acero con numerosas microfisuras taponadas por grafito. La cohesión entre el grafito y la matriz metálica es casi nula. Debido a la gran diferencia entre los coeficientes de dilatación del hierro y del grafito, este se despegará fácilmente de la matriz, Moffil (2015).

La tenacidad de las fundiciones grises es mayor que la de las fundiciones blancas, pero por el efecto de entalla debido al grafito laminar, resulta insuficiente. Por eso, cuando se requiere un material tenaz, no debe utilizarse fundición blanca, ni tampoco fundición gris laminar. Puede señalarse, con carácter general, que la resistencia a la tracción disminuye en las fundiciones grises laminares al aumentar el contenido de carbono. El grafito disminuye la sección real del constituyente matriz, el que aguanta el esfuerzo de tracción. Además, el efecto entalla del grafito laminar, disminuye la tenacidad.

Por otra parte, gracias a la buena colabilidad de las fundiciones grises es posible moldear piezas de paredes delgadas, tales como tubos para aletas con radiadores, rodets para bombas, anillos para compresores, etc. Para una buena colabilidad, se requiere que el intervalo de solidificación sea el menor posible, o lo que es igual, altos valores de carbono equivalente, Moffil (2015). Las fundiciones grises ordinarias presentan buena resistencia a la corrosión, superior a los aceros. Los productos de corrosión quedan apresados por el esqueleto de grafito y dificultan el deterioro de zonas más profundas.

#### **2.2.19. Clasificación de las fundiciones grises.**

Las fundiciones grises se pueden clasificar de varias formas, pero una de las más usuales es la clasificación por la estructura de la matriz:

##### **a) Fundición gris perlítica.**

Su estructura está formada de perlita con inclusiones de grafito (en la figura 1.1a, el grafito se ve en forma de vetas pequeñas). Como se sabe, la perlita contiene un 0,8 % de C, por consiguiente, esta unidad de carbono se halla en la fundición perlítica gris en estado ligado (es decir, en forma de cementita). La cantidad restante se encuentra en estado libre, o sea, en forma de grafito.

##### **b) Fundición gris ferrítica.**

En esta fundición la matriz es ferrita y todo el carbono que hay en la aleación está en forma de grafito.

##### **c) Fundición gris ferrito-perlítica.**

La estructura de esta fundición está formada por ferrita y perlita e inclusiones de grafito. En esta fundición la cantidad de carbono ligado es menor que el 0,8 % de C.

#### **2.2.20. Composición de una fundición gris.**

Las fundiciones no son resultado de aleaciones simples de Fe – C, sino que influyen en su estructura y propiedades diversos elementos. Son cinco los elementos básicos que caracterizan a una función: C – Si – S – Mn – P. Los niveles de carbono y silicio encontrados en el hierro comercial varían ampliamente. La mayoría de los hierros grises comerciales se producen con niveles de carbono desde 2,5 hasta 4 %C. Los niveles normales de silicio varían desde 1 hasta 3,8 %Si. El hierro gris es normalmente considerado como una aleación ternaria Fe – C – Si, Moffil (2015).

En este sentido, un hierro con carbono equivalente de 4,3 % es considerado de composición eutéctica. La mayoría de los hierros son hipoeutécticos (esto es,  $C_{eq} < 4,3$ ). Todas las propiedades mecánicas y físicas del hierro gris son descritas en función del carbono equivalente.

#### **2.2.21. Propiedades generales de las fundiciones grises.**

Tal vez convenga subrayar, a modo de introducción a las propiedades, que las fundiciones grises son un material compuesto de grafito, y de otro material matriz, Moffil (2015). Este material a su vez, frecuentemente está compuesto por un intermetálico "cerámico" - la cementita -, y otro material - la ferrita - que es metálico.

- Las fundiciones son aleaciones férreas que requieren para su elaboración menos energía que los aceros, porque con similar capacidad calorífica su temperatura de fusión es menor. Presentan, además, excelentes características de colabilidad y dan poco rechupe.
- Su colabilidad es mejor cuanto mayor es su contenido de carbono, por ser pequeño el intervalo de temperaturas entre el líquido y sólido.

Algunas de ellas, las de composición eutéctica, solidifican a temperatura constante.

- Las fundiciones grises dan poco rechupe, 1 % de contracción lineal aproximadamente, inferior al de los aceros y fundiciones blancas, como puede verse en la tabla 1.2. La pequeña contracción al solidificar se debe a que su densidad (entre 6,95 y 7,35 g/cm<sup>3</sup>, menor cuanto más carbono) es inferior a la de las fundiciones blancas (7,7 g/cm<sup>3</sup>) y a la de los aceros (densidad del hierro 7,97 g/cm<sup>3</sup>).
- La característica radical de las fundiciones grises es que no presentan ledeburita. En su estructura micrográfica aparece grafito que puede ser de diversos tipos, disperso en una matriz similar a un acero.
- La conductividad térmica de las fundiciones grises es aproximadamente 46 w/m.K; superior a la de los aceros. En ello influye el grafito, buen conductor. La capacidad para disipar calor es, por tanto, mayor en las fundiciones grises - mayor cuanto más cantidad de grafito, y mejor si el grafito es laminar que esferoidal - que en los aceros. Para aprovechar esta propiedad, las lingoteras para acero líquido se fabrican de fundición gris hipereutéctica.
- La resistencia de las fundiciones grises al choque térmico resulta, también, mejor para contenidos altos en carbono.

#### **2.2.22. Ventajas de las fundiciones grises.**

El empleo de la fundición gris para la fabricación de piezas para usos muy diversos, ofrece, entre otras, las siguientes ventajas, Moffil (2015).

- 1) Las piezas de fundiciones grises son, en general más baratas que las de acero (que es el material que más se utiliza en los talleres y fábricas de maquinaria, motores, instalaciones). Su fabricación es también más sencilla por emplearse instalaciones menos costosas y realizarse la fusión a temperaturas relativamente poco elevadas y más bajas que aquellas correspondientes al acero.

- 2) Las fundiciones son, en general, mucho más fáciles de mecanizar que los aceros.
- 3) Se pueden fabricar con relativa facilidad piezas de grandes dimensiones y también piezas pequeñas y complicadas que se pueden obtener con gran precisión de formas y medidas. Además, en ellas es mucho menos frecuente la aparición de zonas porosas que en las piezas fabricadas con acero fundido.
- 4) Para numerosos elementos de motores, maquinaria, etc., son suficientes las características mecánicas que poseen las fundiciones. Su resistencia a la compresión es muy elevada (50 a 100 kg/mm<sup>2</sup>) y su resistencia a la tracción (que puede variar de 12 a 70 kg /mm<sup>2</sup>) es también aceptable para muchas aplicaciones. Tienen buena resistencia al desgaste y absorben muy bien (mucho mejor que el acero) las vibraciones de máquinas, motores, a las que a veces están sometidas.
- 5) Su fabricación exige menos precauciones que la del acero y, sin necesidad de conocimientos técnicos muy especiales, se llegan a obtener fundiciones con características muy aceptables para numerosas aplicaciones.
- 6) Como las temperaturas de fusión de las fundiciones son, como hemos dicho antes, bastante bajas, se pueden sobrepasar con bastante facilidad. Por lo tanto, suele ser bastante fácil conseguir que las fundiciones en estado líquido tengan gran fluidez, y con ello se facilita la fabricación de piezas de poco espesor.
- 7) En la solidificación presentan mucho menos contracción que los aceros y, además, su fabricación no exige como en los aceros, el empleo de refractarios relativamente especiales de precio elevado.

### **2.2.23. Las fundiciones blancas.**

Son aleaciones Fe-C cuyos procesos de solidificación y transformaciones en estado sólido, se realizan siguiendo las leyes generales del diagrama

metaestable: su estructura está constituida principalmente por perlita y cementita: grupos de colonias de perlita derivados de la austenita primaria (libre), rodeados por ledeburita transformada, formada por cementita y perlita. Se producen principalmente por moldeo de la aleación en moldes metálicos con un ajuste apropiado de la composición química, Moffil (2015). Se caracterizan por su gran dureza y fragilidad, causadas por la presencia de cantidades importantes de cementita. En general no son maquinables y el acabado se realiza siempre por rectificado.

Aplicaciones: para equipos de movimiento de tierra minería y molienda, para bolas de molinos de bolas, como materia prima para fabricar aceros, para obtener fundiciones maleables.

#### **2.2.24. Fundiciones maleables.**

Se obtienen por recocido de fundiciones blancas en condiciones especiales. La designación de fundición maleable utilizada por la mayoría de los países, es en realidad un término impropio que puede inducir al error de pensar que el fin del tratamiento térmico es obtener productos fácilmente forjables, Moffil (2015). En realidad, se producen para reemplazar piezas que deberían ser fabricadas por forjado.

Existen dos procedimientos de fabricación que dan lugar a:

- Fundición maleable europea o de corazón blanco (zona exterior descarburada-ferrita y zona interior de ferrita y perlita).
- Fundición maleable americana o de corazón negro (ferrita y copos de grafito). Ambos procesos consisten en la fabricación de las piezas en fundición blanca, seguido de un recocido.

#### **2.2.25. Fundiciones nodulares.**

Para reducir el problema de la fragilidad de las fundiciones con grafito laminar, y su baja resistencia al impacto, se desarrollaron fundiciones con el grafito en forma de pequeñas esferas o nódulos. Su técnica consiste en lograr la precipitación del grafito mediante el agregado de sustancias llamadas

nodulizantes. Se fabrican directamente en bruto de fusión sin necesidad de tratamiento térmico posterior, añadiendo cerio o magnesio a la fundición en estado líquido inmediatamente antes de ser coladas en los moldes. La adición de estos elementos altera el normal mecanismo de solidificación de la fundición, provocando la separación del grafito en forma nodular. La microestructura de estas fundiciones suele estar constituida por esferoides de grafito rodeados por aureolas de ferrita sobre un fondo o matriz de perlita (ojo de buey), Moffil (2015).

De este modo, la continuidad de la matriz se interrumpe mucho menos que cuando el grafito se encuentra en forma laminar, provocando una resistencia a la tracción y tenacidad mayor. Teniendo propiedades similares, la ventaja de la fundición nodular con respecto a la maleable es que se obtiene directamente de fusión sin necesidad de tratamiento térmico posterior. Además, los nódulos presentan una forma más esférica que los aglomerados de copos más o menos irregulares que aparecen en la fundición maleable.

Aplicaciones: cigüeñales, árboles de leva, ciertos mecanismos de biela-manivela.

#### **2.2.26. Tribología de las fundiciones de hierro.**

La definición formal de tribología es: "la ciencia y tecnología de las superficies interactuando en movimiento relativo y de los temas y prácticas relacionadas". A pesar de ser un término de reciente creación los tópicos que abarcan su estudio han sido de interés para la humanidad desde que se tuvieron necesidades como la transportación y la alimentación. Se puede decir que desde que el hombre aprendió como hacer fuego o inventó la rueda, ha trabajado con tópicos como son la fricción y el desgaste. La tribología estudia todos los aspectos relacionados con fricción, lubricación y desgaste, Madero (2016). El auge de esta ciencia comenzó a tomar gran interés por el año de 1966 donde un estudio realizado por el gobierno de la Gran Bretaña, ahora conocido como el reporte Jost, sugirió que en el Reino Unido se podían lograr ahorros de hasta 500

millones de libras esterlinas, al aplicar tecnología tribológica en el diseño, construcción y operación de maquinaria industrial.

En este sentido, en la presente y futura situación económica, los materiales y la conservación de la energía están llegando a tener gran importancia. El desgaste y la corrosión son las principales causas de pérdida del material. Cualquier reducción en el desgaste de los materiales traerá considerables ahorros. La fricción por otra parte es una causa seria de la disipación de energía, que al igual que el desgaste traerá significativos ahorros si es controlada.

En este sentido, la lubricación es un proceso en donde la fricción y el desgaste entre dos superficies sólidas en movimiento relativo pueden ser reducidos, interponiendo entre las superficies un lubricante. La fricción y el desgaste están basados en interacciones físicas entre dos superficies con movimiento relativo. El rol de la lubricación es el de separar las superficies en movimiento por medio de una película sólida, líquida, o gaseosa que permita el movimiento con bajas resistencias, sin causar ningún daño.

#### **2.2.27. Mecanismo de desgaste.**

El desgaste puede ser definido como el proceso mediante el cual material es desprendido de una o de ambas superficies que se encuentran en contacto, ocurriendo cuando estas se encuentran en movimiento relativo una de la otra. En un buen diseño tribológico, la pérdida de material es un proceso muy lento, pero es estable y continuo. Clasificar los tipos de desgaste que se pueden presentar en un material suele ser difícil.

La razón de esta dificultad es que el desgaste o resistencia al desgaste no es una propiedad intrínseca del material, como lo es el esfuerzo o la dureza, sino que está en función del sistema en el que opera, el término "sistema" cubre los materiales de los que son manufacturados los componentes, la naturaleza de la interacción y la interacción con el medio circundante, Madero (2016). Como un intento de estandarizar, el trabajo ha sido usado para sentar bases para la especificación alemana DIN 50 320. Esta especificación define cuatro

mecanismos básicos: adhesión, abrasión, fatiga y acciones triboquímicas, otros mecanismos como picadura, fretting, erosión, cavitación. Son abarcados por los cuatro mecanismos mencionados anteriormente.

#### **2.2.28. Desgaste abrasivo.**

En el desgaste abrasivo el material es removido o desplazado de una superficie por partículas duras, de una superficie que es deslizada contra otra.

Existen dos formas básicas de abrasión.

- Abrasión por desgaste de dos cuerpos.
- Abrasión por desgaste de tres cuerpos.

El primero de ellos ocurre cuando las protuberancias duras de una superficie son deslizadas contra otra. Un ejemplo de esto es el pulido de una muestra mediante el uso de lijas. Mientras que el otro, el tres cuerpos, se presenta en sistemas donde partículas tienen la libertad de deslizarse o girar entre dos superficies en contacto, el caso de aceites lubricantes contaminados en un sistema de deslizamiento puede ser claro ejemplo de este tipo de abrasión. Los rangos de desgaste en la abrasión de tres cuerpos, son generalmente más bajos, que en el sistema abrasión de dos cuerpos, Madero (2016).

#### **2.2.29. Desgaste adhesivo.**

El desgaste adhesivo ocurre entre dos superficies que se encuentren en contacto, las cuales se adhieren fuertemente formando uniones entre ellas. Un deslizamiento producirá un desprendimiento de material de la superficie suave. Si el material es dúctil, la deformación que se produzca antes de la separación de la partícula es mucho mayor, si esta ha sido separada de la aspereza puede permanecer unida a la otra aspereza como material transferido de una superficie a otra o puede ser liberada como partícula de desgaste, Madero (2016). En algunos casos, el punto de cedencia del material es excedido y las asperezas se deforman plásticamente hasta que el área real de contacto incrementa lo suficiente para soportar la carga aplicada, de tal modo que las superficies pueden adherirse.

Esto causará que la soldadura en frío, se lleve a cabo. Deslizamientos continuos causarán que las uniones entre asperezas sean cizalladas y nuevas uniones sean formadas. Algunos factores como partículas de contaminantes pueden ayudar a minimizar esta adhesión, las cuales se dispersan del área de contacto por el movimiento relativo tangencial que ocurre en la interfase.

#### **2.2.30. Desgaste corrosivo.**

Es caracterizado como la degradación de materiales en donde la corrosión y los mecanismos de desgaste se encuentran involucrados. La combinación de efectos de desgaste y corrosión puede resultar en una pérdida total de material mucho más grande que si se presentarían por adición o individualmente, Madero (2016). La deformación plástica por altos esfuerzos de contacto causa endurecimiento por deformación y susceptibilidad al ataque químico. De igual forma la deformación plástica ocurrida en el mecanismo de desgaste por impacto puede hacer que las superficies sean más susceptibles a la corrosión.

#### **2.2.31. Desgaste por fatiga.**

La fatiga en la superficie y sub superficie se observa durante deslizamiento y apisonamiento repetido. Los repetidos ciclos de carga y descarga a los cuales los materiales son expuestos pueden inducir la formación de grietas superficiales y sub superficiales, que eventualmente, después de un número crítico de ciclos resultarán en la rotura de la superficie, Madero (2016). Antes de este punto crítico el desgaste del material es despreciable, lo que no sucede con el desgaste causado por un mecanismo adhesivo o abrasivo, donde el desgaste causa un deterioro gradual del material desde el inicio del proceso. Por tanto, la cantidad de material eliminado debido a la fatiga no es un parámetro útil. Mucho más relevante es la vida útil en términos del número de revoluciones o ciclos de trabajo antes de que ocurra la falla por fatiga.

### **2.2.32. Desgaste por cavitación.**

Es el fenómeno de cavitación, donde pequeñas cavidades de vacío (burbujas) se forman en un fluido sometido a grandes velocidades u ondas sónicas de gran energía. Este fenómeno erosiona el material debido a las grandes presiones transitorias durante el colapso de burbujas. Este desgaste es más suave que la erosión y parece ser controlado por la resistencia a la fatiga de los materiales, Madero (2016). La ocurrencia de este tipo de desgaste es común en la mayoría de maquinaria que está sujeta a vibración durante su operación. Básicamente el desgaste por vibración es una forma de desgaste adhesivo o abrasivo, donde la carga normal causa adhesión entre asperezas y el movimiento oscilatorio causa su rotura.

### **2.2.33. Desgaste erosivo.**

Cuando una superficie sólida está expuesta a múltiples impactos de partículas duras, experimenta una forma de desgaste llamada erosión, la cual genera pérdida del material en la superficie como consecuencia de la interacción mecánica con las partículas. El impacto de las partículas duras provoca deformación, fractura y remoción de material en la superficie dañada, Madero (2016).

La partícula experimenta la fuerza de la gravedad en su centro de masa, fuerzas de contacto causadas por el contacto con otras partículas, fuerza de reacción de la superficie al momento del impacto y la fuerza de arrastre obtenida del medio que transporta la partícula (algún fluido). Sin embargo, la fuerza dominante en una partícula erosiva, la cual es la principal responsable de su desaceleración desde su velocidad de impacto inicial, es generalmente la fuerza de contacto ejercida por la superficie.

## **2.3. Definición de términos básicos.**

**Aleación:** Mezcla sólida homogénea de dos o más metales con algunos elementos no metálicos.

**Arrabio:** Es un material metálico que contiene al menos el 90% de hierro que provienen de diferentes materiales enriquecidos en hierro como la hematita o la magnetita. Básicamente, es un subproducto obtenido del proceso de fabricación del hierro puro.

**Binario:** Que está en un sistema de numeración de base dos.

**Carbón:** Sustancia sólida, ligera, negra y combustible, que resulta de la destilación o de la combustión incompleta de la leña o de otros cuerpos orgánicos.

**Dendritas:** Son ramificaciones terminales presentes en las neuronas que garantizan la recepción de los impulsos nerviosos que llegan desde un axón correspondiente a otra neurona.

**Dúctil:** Material que puede deformarse, moldearse, malearse o extenderse con facilidad.

**Hipoeutécticas:** Son las aleaciones que presentan una mayor cantidad de la fase sólida más común en el diagrama. En consecuencia, la mayoría de los diagramas se representan con el metal más común del lado izquierdo del punto eutéctico.

**Maquinabilidad:** Es una propiedad de los materiales que permite comparar la facilidad con la que pueden ser mecanizados por arranque de viruta.

**Sinapsis:** Región de comunicación entre la neurita o prolongación citoplasmática de una neurona y las dendritas o el cuerpo de otra.

## **CAPÍTULO III**

### **MARCO METODOLÓGICO**

#### **3.1 Tipo de investigación.**

En todo proceso de investigación, es fundamental establecer la metodología que sirva de guía para lograr las metas indicadas en los objetivos. A continuación, se presentó la metodología que se emplea en el desarrollo de este trabajo. De esta forma, el presente trabajo se inserta dentro del criterio y características de un proyecto factible, pues tuvo como objetivo, dar solución a un problema real; se basó en una investigación de campo de tipo descriptivo, apoyado en una investigación documental.

De acuerdo con el Manual de Trabajo de Grado de Especialización y Maestría y Tesis Doctorales, de la Universidad Pedagógica y Experimental Libertador – UPEL (2006):

“El Proyecto Factible consiste en la investigación, elaboración y desarrollo de una propuesta de un modelo operativo viable para solucionar problemas, requerimientos o necesidades de organizaciones o grupos sociales; puede referirse a la formulación de políticas, programas, tecnologías, métodos o procesos. El Proyecto debe tener apoyo en una investigación de tipo documental, de campo o un diseño que incluya ambas modalidades.”  
(p.13).

#### **3.2 Nivel de investigación.**

El nivel de investigación se refiere según Arias (2014) “al grado de profundidad con que se aborda un objeto o fenómeno” (p.47). Así pues, el nivel de esta investigación es descriptivo, porque incluye la descripción, el análisis e interpretación de la naturaleza actual en la que se presentaron los hechos en este caso, la distribución de los almacenes.

Se dice que se apoyó en una investigación documental, debido a que se revisaron trabajos ya realizados en el área para tener la base de la evaluación de la resistencia al desgaste de una fundición gris y blanca mediante redes neuronales, por esto se recurrió

a fuentes de datos con información ya registrada, tales como libros, páginas web, datos estadísticos, archivos, entre otros y de esta manera fundamentaron las conclusiones del estudio en técnicas y herramientas teóricas ya conocidas.

### **3.3 Diseño de investigación.**

El diseño de investigación está basado en un diseño experimental y se refiere a:

“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 (variables dependientes)”. (Arias, 2014, p. 33)

Se emplea a nivel metodológico un diseño experimental debido a que, se manipulan diversas variables e información obtenidas de diferentes fuentes para así poder realizar una base de datos que permitan el desarrollo de las redes neuronales artificiales.

### **3.4. Población y Muestra.**

#### **Población**

Maneiro N y Mejías A (2016), se refieren a la población como “la totalidad de las observaciones o información, que caracteriza un fenómeno respecto del cual se desea realizar un estudio” (p. 19). En esta investigación se tomó como población el hierro.

#### **Muestra**

Arias F, (2014) define la muestra como “un subconjunto representativo y finito que se extrae de la población accesible” (p. 83). En este caso, la muestra fue intencional de fundición Gris y fundición Blanca.

### **3.5 Técnicas e instrumentos de recolección de datos.**

“Se entiende por técnica, el procedimiento o forma particular de obtener datos o información”, según Arias (2014).

Los instrumentos de investigación son parte fundamental de la misma ya que son los medios por los cuales el investigador puede recolectar datos sobre la problemática en la que está trabajando, esto de acuerdo con (Arias 2014). Entonces, tomando en

cuenta lo mencionado anteriormente, en esta investigación para la recolección de información en la presente investigación, se optó por aquellas técnicas que ayudaron al logro de los objetivos y a obtener la información necesaria de manera organizada y precisa.

### **3.5.1. Técnica empleada.**

#### **Observación directa**

La observación directa es el proceso en el cual el investigador recolecta datos directamente desde el medio ambiente del fenómeno a estudiar, por otro lado, Hurtado (2010) la define como: "... un proceso de atención, recopilación, selección y registro de información para el cual el investigador se apoya en sus sentidos" (p.459). Esta técnica se empleó para el conocimiento del problema y así comenzar la búsqueda de la solución, ya que a través de la misma se pudo obtener información sobre el desgaste de dichas fundiciones.

De acuerdo con Arias (2014), la revisión 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" (p.27).

La revisión bibliográfica está fundamentada en la exploración sistemática, rigurosa y profunda de material documental de cualquier clase. Se procura el análisis de los fenómenos o el establecimiento de la relación entre dos o más variables. Cuando se opta por este tipo de estudio, el investigador utiliza documentos; los recolecta, selecciona, analiza y presenta resultados coherentes, esto de acuerdo con Stracuzzi (2003).

### **3.5.2. Instrumento de Recolección de Datos.**

Con respecto al Instrumento de recolección de datos se aplicará una guía de observación, para así lograr obtener información directa y confiable.

Por esto, Arias (2014), asegura que:

"Los instrumentos son los medios materiales que se emplean para recoger y almacenar la información. Ejemplo: fichas, formatos de cuestionario, guía de

entrevista, lista de cotejo, grabador, cámara fotográfica o de video” (p. 111).

### **3.6 Fases de la investigación.**

**Fase I: recaudar y obtener datos sobre el desgaste y la forma en la que ocurre en las distintas fundiciones.**

En primer lugar, se realizará una minuciosa investigación sobre el desgaste y las distintas formas en la que este ocurre. Todo esto tomando en cuenta el tipo de fundición y otros datos sobre estas.

**Fase II: Diseñar las redes neuronales para evaluar el desgaste en la fundición gris y blanca.**

En esta fase se tiene como objetivo diseñar las redes neuronales, lo que al respecto relaciona el tipo de neurona artificial a implementar y la función, basándose en las variables del proceso anterior.

**Fase III: Establecer Parámetro para la mejora de tiempo/precisión de la red neuronal.**

En esta última fase, se procede al establecimiento de los parámetros de la red neuronal para que, el desgaste en las fundiciones grises o blancas, tenga unos valores aceptables y la red neuronal de los resultados en el menor tiempo posible.

**Fase IIV: Realizar comparaciones entre datos ya existentes y valores obtenidos por medio de redes neuronales.**

En esta fase, se realizarán las contrastaciones de datos que están establecidas para los tipos de redes neuronales y los valores que se obtengan de la misma para evaluar la resistencia del desgaste.

## **CAPÍTULO IV**

### **RESULTADOS DE LA INVESTIGACIÓN**

#### **4.1 Recaudar y obtener datos sobre el desgaste y la forma en la que ocurre en las distintas fundiciones**

A continuación, se describen la forma en que fueron obtenidos los distintos grupos de datos sobre distintos tipos de fundiciones que posteriormente fueron cargados a la red neuronal para poder observar su comportamiento en distintos escenarios ya que las propiedades de los materiales son diferentes y los datos que arrojan los ensayos también. Lo que se traduce en distintos datos de entrada a la red

Las fundiciones o hierros fundidos son aleaciones hierro-carbono-silicio que típicamente contienen de 2% a 4% C y 0.5% a 3% Si, y que durante su solidificación experimentan la reacción eutéctica. De acuerdo a su microestructura es posible clasificar los cinco tipos más importantes de hierros fundidos: fundición gris, fundición blanca, fundición maleable, fundición dúctil o esferoidal y la fundición de grafito compacto


Las fundiciones blancas o hierros blancos solidifican siguiendo el diagrama de fases metaestable, por lo tanto, todo el carbono presente en la muestra se encuentra disuelto en el hierro o formando carburo de hierro. Este tipo de fundición es muy dura y frágil y recibe su nombre por el color blanco que se puede ver en la superficie cuando esta se fractura.

Existe una gran cantidad de información científica sobre la solidificación, la que proporciona las herramientas necesarias para obtener una visión de la microestructura de este tipo de fundiciones, con la que es posible estimar las propiedades de desgaste y/o tratamientos térmicos óptimos, sin necesidad de recurrir a una investigación metalúrgica larga y costosa


##### **4.1.1 Ensayo 1**

Según Romero Orrego (2018), quien realizo una serie de experimentos entre los cuales destaca un ensayo de tambor impulsor con muestras de distintas fundiciones blancas y grises el cual tuvo las siguientes características

La materia prima corresponde a nueve fundiciones blancas de alto contenido de cromo, de cada fundición se realizó una probeta. Estas fueron medidas con un pie de metro digital, para verificar que las dimensiones de cada probeta fuesen las adecuadas para ser sometidas al ensayo de desgaste en el equipo IT. Las dimensiones de cada probeta deben ser 71.2x25.4x10.0 mm, como se muestra en la Figura 8 y 9.



**Figura 8:** Ilustración esquemática de los ángulos de muestra  
Fuente: Romero O. (2018).



**Figura 9:** Ilustración esquemática de los ángulos de muestra

**Fuente:** Romero O. (2018).


El ensayo de desgaste fue realizado en el equipo IT (descrito a continuación), en el cual se utilizó una probeta patrón de acero permitiendo realizar una comparación entre los ensayos realizados, es decir, la probeta patrón se utilizó como un indicador de la repetitividad de los ensayos.

#### **4.1.1.1 Ensayo impeller tumbler**

El Impeller Tumbler (IT) o tambor impulsor, es un dispositivo de prueba de desgaste por abrasión impacto, desarrollado por primera vez para estudiar la abrasividad de los minerales, pero se puede usar de forma natural para probar metales y otros materiales en cuanto a su comportamiento al desgaste por impacto y abrasión.

El tambor impulsor consta: del impulsor, donde una o varias probetas se unen a un porta muestra. El impulsor gira dentro de un tambor, que contiene material abrasivo. El tambor está girando en la misma dirección que los impulsores para mantener los

abrasivos en movimiento. El tambor se encuentra sellado con una tapa para mantener el abrasivo dentro del tambor.



**Figura 10:** Fotografía equipo IT, partes que componen el equipo.

(a) Motor que impulsa el tambor, (b) Reductor, (c) Tambor, (d) Porta probetas, (e) Motor que impulsa el porta probeta.


**Fuente:** Romero O. (2018).

La cantidad de desgaste se determina como la pérdida de masa en la muestra. Las pruebas se pueden realizar con una o varias muestras simultáneamente. Si solo se usa una muestra, el desgaste es mayor, esto se debe a que una mayor cantidad de partículas de material abrasivo colisionan con la muestra, ya que no hay otras muestras en el interior, de modo que la gravilla se tritura más lentamente. En el caso de utilizar tres muestras, se puede hacer una comparación de varios materiales en las mismas condiciones, y es posible el uso de una muestra de referencia. Esto no solo proporciona datos de comparación fiables, sino que también ayuda a evaluar la calidad de los resultados.

El material abrasivo puede presentar diferencias en sus propiedades, a pesar de haber sido extraído de la misma cantera y tener una distribución de tamaño homogénea. Al ser utilizada una muestra de referencia, para la cual se conoce un resultado típico, es posible detectar si el lote del material abrasivo usado fue de alguna manera diferente de los otros lotes. La distribución del tamaño y la forma de las partículas abrasivas también cambian a medida que avanza la prueba, lo que generalmente produce una

disminución en su capacidad de causar desgaste. Para minimizar este efecto, el abrasivo se debe cambiar cada 15 o 20 minutos.

Las condiciones de impacto pueden cambiar usando diferente porta muestras con diferentes ángulos de muestra. El término “Ángulo de muestra” se usa en este caso, ya que el material abrasivo se mueve libremente en el interior del tambor y su Ángulo de impacto en la superficie no se puede determinar: Al cambiar el Ángulo de las muestras, también se puede cambiar el ángulo de impacto dominante. La figura 11 presenta los dibujos esquemáticos de los ángulos de muestra usados



**Figura 11:** Ilustración esquemática de los ángulos de muestra

**Fuente:** Romero O. (2018).

En el tambor impulsor, las muestras están sometidas tanto a impactos como a abrasión: el impacto tiene lugar cuando la partícula abrasiva primero hace contacto con la muestra, y la abrasión a medida que la partícula se desliza sobre la muestra en movimiento hacia adelante

A continuación, se enlista el procedimiento para asegurar la repetitividad de los ensayos. El ensayo de abrasión impacto posee un sencillo procedimiento, el cual debe ser realizado rigurosamente para asegurar la repetitividad de cada ensayo

#### **4.1.1.2 Procedimiento para realizar ensayo en equipo IT:**

**1.** Se debe seleccionar el material abrasivo (gravilla), aproximadamente  $\frac{3}{4}$  pulgada de diámetro, con la mayor esfericidad posible, además, debe estar libre de humedad.

**2.** Se pesan 900 gr. del material abrasivo antes seleccionado.

**3.** El tambor es cargado con los 900 gr. de material abrasivo.

**4.** La limpieza superficial de las probetas, se realiza con papel absorbente empapado en alcohol, para eliminar residuos como: aceite o lubricante utilizado durante el mecanizado, grasa adherida producto de la manipulación, polvo u otros residuos acumulados. La limpieza se debe realizar justo antes de ser pesadas.

**5.** El set compuesto por las tres probetas es montado en el portaprobetas, se debe asegurar la sujeción de cada una de ellas, además, se debe tener precaución para prevenir que estas se suelten durante el ensayo, como medida de prevención se deben revisar en cada detención del equipo.

**6.** Se une el conjunto tambor- portaprobetas y se asegura la tapa acrílica, además, se debe bloquear la base móvil del portaprobetas, para que esta no deslice durante el ensayo.

**7.** Iniciar ensayo.

**8.** Cada 20 minutos el equipo se detiene y se cambia el material abrasivo, el tambor se debe limpiar antes de cargar el material abrasivo nuevo.

**9.** Luego de 60 minutos de ensayo, las probetas son retiradas del equipo, son llevadas al laboratorio, se limpian y pesan (siguiendo el mismo procedimiento de limpieza antes descrito).

**10.** El ensayo es realizado durante 300 minutos (5 horas). Los puntos 8 y 9 del procedimiento, se deben repetir durante la totalidad del ensayo.

Una vez concluida la prueba las probetas son retiradas de la máquina para proceder a evaluarlas y realizar ensayos posteriores

#### 4.1.1.3 Resultados

**Tabla 1:** Tabla de datos fundiciones blancas

Nombre	N° de probetas	Clasificación según Norma
A-1	4	ASTM A-532,II-B
A-2	3	ASTM A-532,II-B
A-3	5	ASTM A-532,II-B
A-4	2	ASTM A-532,II-D
A-5	6	ASTM A-532,II-B
A-6	2	ASTM A-532,III-A
A-7	6	ASTM A-532,II-B
A-8	4	ASTM A-532,III-A
A-9	4	ASTM A-532, II-B

Fuente: Romero O. (2018).

**Tabla 2:** Tabla de datos fundiciones blancas

fundición blanca	Pérdida de masa (g)	peso específico (kg/dm <sup>3</sup> )	dureza (HB)
A-1	0.1781	7.4	700.8
A-2	0.1717	7.5	694.5
A-3	0.171	7.6	692.0
A-4	0.1788	7.7	697.0
A-5	0.1648	7.3	689.5
A-6	0.2347	7.6	689.5
A-7	0.1784	7.5	689.6
A-8	0.1951	7.2	618.3
A-9	0.1196	7.6	692.0

Fuente: Romero O. (2018),

Las diferencias observadas en la pérdida de masa entre una fundición y otra son consecuencia directa de los distintos valores que tienen sus propiedades mecánicas, siendo la más influyente en esto la dureza. También juega un papel muy importante la metalografía y la composición química de las distintas muestras ya que dicha composición va variando de acuerdo a los porcentajes de los distintos elementos (carbono, cromo, níquel, entre otros) lo que genera cambios en distintas proporciones sobre las propiedades mecánicas del material.

En la siguiente tabla podremos observar más detalladamente la composición química de las aleaciones usadas en estas pruebas

**Tabla 3:** composición química fundiciones blancas

Aleación	ASTM A-532	%C Norma	%C Muestra	%Cr Norma	%Cr Muestra	%Mo Norma	%Mo Muestra
A-1	II-B	2.0–3.3	2,420	14.0–18.0	16,760	3.0 máx.	1,090
A-2	II-B	2.0–3.3	2,500	14.0–18.0	15,200	3.0 máx.	2,690
A-3	II-B	2.0–3.3	2,540	14.0–18.0	15,260	3.0 máx.	0,960
A-4	II-D	2.0–3.3	2,640	18.0–23.0	18,050	3.0 máx.	1,710
A-5	II-B	2.0–3.3	2,570	14.0–18.0	17,400	3.0 máx.	0,640
A-6	III-A	2.0–3.3	2,780	23.0–30.0	23,740	3.0 máx.	0,770
A-7	II-B	2.0–3.3	2,400	14.0–18.0	14,360	3.0 máx.	2,420
A-8	III-A	2.0–3.3	2,580	23.0–30.0	28,770	3.0 máx.	0,230
A-9	II-B	2.0–3.3	2,550	14.0–18.0	17,880	3.0 máx.	0,620

Fuente: Romero O. (2018)

#### 4.1.1.4 Análisis Metalográfico


El análisis metalográfico de las aleaciones en estudio se realizó con el objetivo de identificar y cuantificar las fases presentes en cada una de ellas. Para esto, las muestras fueron atacadas con diferentes reactivos, los que permiten revelar su microestructura con distintas tonalidades. Las fundiciones blancas

estudiadas son del tipo hipoeutético altamente aleado, por lo que su diagrama de fases se ve modificado en gran medida en comparación al de una con menor cantidad de elementos de aleación. Estos cambios generan una variación en la composición química de los microconstituyentes formados durante la solidificación, y en algunos casos también producen cambios en la morfología y cinética de formación de las diferentes fases. Para llevar a cabo la cuantificación de las fases presentes en cada caso, se realizó análisis de imagen con el software *Image Pro Plus*. Para esto se consideró un total de cuatro imágenes de distintas zonas de la muestra, tomadas al azar, con un aumento de 50X. Posteriormente, se calcula el promedio obtenido en cada una de las imágenes analizadas.

#### **Aleación A-1**

En la Figura 12 se muestran los resultados obtenidos para la muestra A-1, en la que es posible identificar una matriz de martensita (fase más oscura), cuyo crecimiento se produce a partir de las dendritas de austenita durante el proceso de enfriamiento de esta aleación (los brazos de las dendritas están cortados) y la estructura adyacente presenta un crecimiento del tipo eutético, compuesto por carburos (fase de color blanco) y martensita.

En la Figura (d), analizada luego de realizado el ensayo de desgaste, es posible observar la fractura que sufren los carburos debido a los impactos reiterados que éstos reciben durante el ensayo.




**Figura 12:** Micrografía aleación A-1 (a) previo ensayo, aumento 100X; (b) previo ensayo, aumento 1000X; (c) post-ensayo superficie, aumento 100X; (d) post-ensayo superficie, aumento 1000X. Reactivo de ataque Nital 5%.

Fuente: Romero O. (2018).

#### **Aleación A-4.**

En las micrografías de la Figura 13 se puede ver, al igual que en los casos anteriores, una matriz de martensita y la estructura adyacente presenta un crecimiento del tipo eutéctico, compuesto por carburos y martensita.

En el círculo rojo de la figura (d) es posible observar que los carburos de la superficie han sufrido fracturas producto de los reiterados impactos durante el ensayo de desgaste. Además, en el círculo azul de la misma imagen se pueden observar carburos que han precipitado en la matriz, la presencia de este tipo carburos, posiblemente es producto de una precipitación secundaria, la cual es realizada mediante un tratamiento térmico posterior (se desconoce historial metalúrgico).




**Figura 13:** Micrografía aleación A-4 (a) previo ensayo, aumento 100X; (b) previo ensayo, aumento 1000X; (c) post-ensayo superficie, aumento 200X; (d) post-ensayo superficie, aumento 1000X. Reactivo de ataque Nital 5%.

Fuente: Romero O. (2018).

### **Aleación A-9.**

En las micrografías de la Figura 14 se puede ver, al igual que en los casos anteriores, una matriz de martensita y la estructura adyacente presenta un crecimiento del tipo eutéctico, compuesto por carburos y martensita empobrecida en Cromo. Cabe destacar que en este caso fue posible observar límite de grano de la austenita.

En la Figura (d) no es posible observar los carburos fracturados en la superficie de desgaste, puesto que estas no fueron preparadas con resina para mantener los bordes, como consecuencia, los carburos de la superficie se desprendieron durante su preparación para análisis metalográfico.



**Figura 14:** Micrografía aleación A-9 (a) pre-ensayo, aumento 100X; (b) pre-ensayo, aumento 1000X; (c) post-ensayo superficie, aumento 200X; (d) post ensayo superficie, aumento 1000x. Reactivo de ataque Nital 5%.

Fuente: Romero O. (2018).

En las aleaciones A-2, A-3, A-5 y A-6, se identificaron las mismas fases que en A-1, presentando solamente diferencias en la distribución y tamaño. En las aleaciones A-7 y A-8 presenta una microestructura similar y se observa precipitación secundaria como la observada en A-4. Ver Anexo de las micrografías indicadas.

#### 4.1.2 Ensayo 2

En las pruebas realizadas por Hernández De la Torre (2019) quien tenía como objetivo seleccionar una fundición adecuada para cuchillas de molino azucarero. En esa oportunidad fueron variando ciertos elementos aleantes como cromo y estaño para observar cómo influía esto en el comportamiento de la aleación y sus propiedades

Se procedió a la selección de los elementos de aleación sobre la base de las siguientes premisas:

- Uso en pequeñas cantidades de elementos que fueran fuertes promotores de perlita.
- Uso de elementos aleantes en la carga o inoculados en la cazuela, que faciliten su aplicación en los talleres.

Se comprobó la influencia de estos elementos de aleación sobre la dureza y la maquinabilidad, variando la adición del cromo entre 0,5 % y 1,5 %. El límite inferior se tomó de 0,5 % partiendo de lo establecido por Hernández (2006).

En resumen, al proponerse una fundición mejorada con adición de cromo y modificación de la matriz metálica con estaño, apenas se conjuga la acción de elementos aleatorios respecto a la composición química de la fundición gris FG-18, tomada como aleación base de referencia o patrón (ver tabla 4)

**Tabla 4:** composición química de la fundición gris

<b>Aleación</b>	<b>C</b>	<b>Si</b>	<b>Mn</b>	<b>P</b>	<b>S</b>	<b>Cr</b>	<b>Ni</b>	<b>Sn</b>	<b>Fe</b>
	3,25	1,84	0,63	0,214	0,12	0,00	0,01	---	93,92

**Fuente:** Romero O. (2018).

Para el estudio de la influencia de los elementos aleantes sobre el comportamiento del desgaste se definió como variable dependiente el desgaste volumétrico (Wv) y como variables independientes, el porcentaje de cromo y de estaño.

Se decidió, variando la adición del cromo en dos niveles, uno mínimo de 0,5 % y un máximo de 1,5 %, además de la adición de estaño en 0,1 %, obteniéndose las siguientes aleaciones experimentales:

Aleación 1. FG-18, Patrón

Aleación 2. FG-18, con adición de 0,5 % de Cr

Aleación 3. FG-18, con adición de 0,5 % de Cr y modificada con 0,1 % de Sn

Aleación 4. FG-18, con adición de 1,5 % de Cr

Aleación 5. FG-18, con adición de 1,5 % de Cr y modificada con 0,1 % de Sn.

Los ensayos de desgaste se realizaron replicando cuatro veces cada una de las aleaciones experimentales. Para medir el desgaste gravimétrico se limpiaron cuidadosamente las probetas con acetona y alcohol y se pesaron en una balanza analítica, tipo AVIV5/3-3; máx. 200 g y e=0,1 mg. Se colocaron en diversas posiciones en cada corrida, de modo que todas las muestras se sometieran a similares condiciones de desgaste experimental, de acuerdo al movimiento de la placa superior, portadora de la caña triturada, la que se fue renovando en cada una de las corridas

#### **4.1.2.1 Obtención de las probetas**

Todas las aleaciones se fundieron en moldes de arena, empleándose un horno de cubilote de 450 mm de diámetro interior en la preparación de la aleación base. El desmoldeo se realizó 24 h después, en condiciones normales de temperatura. Las dimensiones nominales de las probetas se obtuvieron por maquinado. Para determinar la composición química real obtenida en las probetas se utilizó un espectrógrafo Spectrocast, modelo MAGELLAN QM1

#### **4.1.2.2 Prueba de desgaste**

Los ensayos de desgaste combinado (abrasión y corrosión) se hicieron empleando el equipamiento del Laboratorio de Tribología de la Universidad de Oriente. Se realizó un ensayo de desgaste teniendo como par tribológico el bagazo de caña friccionando contra las probetas.

Se evaluaron las cinco aleaciones experimentales, que se identificaron con una primera cifra. La segunda cifra con la que se marcó cada probeta corresponde al número de orden de la misma: 1-1, 1-2, 1-3, etc. Para la realización de los ensayos se tomó en consideración el procedimiento metodológico establecido en el referido laboratorio y se empleó un tribómetro con movimiento recíprocante, con una carga de 50 N y una velocidad de traslación de 35 recorridos por minuto, durante cuatro horas.

En una placa superior se situó la caña triturada, que simuló las condiciones del primer molino azucarero y que se deslizó sobre la placa inferior; esta última cuenta con cuatro alojamientos para la ubicación de probetas prismáticas de dimensiones 104 mm x 11 mm x 5 mm.

**Tabla 5: Composición química de las fundiciones blanca**

<b>Aleación</b>	<b>C</b>	<b>Si</b>	<b>Mn</b>	<b>P</b>	<b>S</b>	<b>Cr</b>	<b>Ni</b>	<b>Sn</b>	<b>Fe</b>
1	3,25	1,84	0,63	0,21	0,12	0,00	0,01	---	93,92
2	3,21	2,02	0,51	0,18	0,08	0,51	0,01	---	93,47
3	3,15	1,99	0,74	0,16	0,08	0,49	0,01	0,11	93,25
4	3,29	2,09	0,66	0,17	0,09	1,48	0,01	---	92,19
5	3,19	2,06	0,58	0,17	0,09	1,50	0,01	0,10	92,26

Fuente: Romero O. (2018).

**Tabla 6: Dureza de las fundiciones blanca**

<b>Aleación</b>	<b>Cr (%)</b>	<b>Sn (%)</b>	<b>Dureza (HB)</b>
1	0	0	187
2	0,5	0	218
3	0,5	0,1	219
4	1,5	0	285
5	1,5	0,1	299

Fuente: Romero O. (2018).

#### **4.1.2.3 Resultados**

Al realizar el análisis de la dureza de las aleaciones con el comportamiento al desgaste, de cada una de ellas, se confirmó la relación directa que se establece entre

ambas propiedades. Los resultados obtenidos son la derivación de una rigurosa realización experimental en la cual se determinó:

**Tabla 7:** Tabla de datos fundiciones grises

aleación	pérdida de masa (g)	perdida de volumen (mm <sup>3</sup> )
1	0,0105	1,483
2	0,0066	0,9302
3	0,00053	0,7407
4	0,00047	0,6439
5	0,00036	0,4968

Fuente: Romero O. (2018).

Las distintas pérdidas de volumen y masa registradas en este experimento son consecuencia directa de las distintas composiciones químicas de cada fundición en este caso particular la variación de los porcentajes de cromo y estaño genero aumentos considerables en la dureza del material

#### 4.1.3 Ensayo 3


Siguiendo la misma línea de investigación encontramos el trabajo realizado por morales becerra (2007), del cual tenemos:

Los ensayos fueron realizados en fundiciones blancas variando el porcentaje de elementos como el cromo, el carbono y el molibdeno además de variar también el material del molde de colada

#### Pruebas de desgaste abrasivo

El desgaste evaluado en este procedimiento es del tipo abrasivo en seco. Mediante esta prueba se busca simular y evaluar la pérdida de masa de materiales sometidos a un desgaste abrasivo por medio de agentes particulados. Este ensayo simula las condiciones de trabajo de una pieza sometida a esfuerzos tangenciales sobre la superficie de contacto. Por ejemplo, en rotores de bombas y tubería de arena, pulverizadores de minerales, etc.

Las dimensiones de las probetas utilizadas para esta prueba se observan en la Fig. Probetas de Desgaste



**Figura 15:** Dimensiones de probeta de desgaste  
Fuente: Romero O. (2018).

#### 4.1.3.1 Equipo de Prueba (RWAT, *Rubber Wheel Abrasión Test*)

Para esta prueba se utilizó una máquina construida de acuerdo con las especificaciones de la norma ASTM G65, *Measuring Abrasion Using the Dry Sand/Rubber Wheel*.

El agente abrasivo es arena de sílice seca (AFS 50/70), la cual, por acción de una rueda giratoria, es presionada contra la superficie del material. El equipo se operó a 200RPM manteniéndose un estricto control sobre las revoluciones y la carga a la cual cada probeta estaba sometida.

**Tabla 8 :** Condiciones de operación para la prueba de desgaste

Condiciones de operación para la prueba de desgaste

Velocidad del Motor, RPM	1750
Velocidad de la Rueda, RPM	195
Flujo de Arena, gr/min	350
Numero de Revoluciones, Rev	2000

Diámetro Rueda, mm 228.6

Fuente: Romero O. (2018).

Previo a los ensayos de desgaste a las probetas, se realizó un proceso de calibración de la máquina. Inicialmente se corroboraron las cargas del brazo de soporte, de modo que se ejerciera una carga de 130N sobre la probeta. Posteriormente se realizó un ajuste en la geometría del mecanismo, de modo que la huella dejada por la prueba fuera homogénea y de caras paralelas. Por último, se corroboró la velocidad de la rueda, y se implementó un sistema de cepillo para remover los granos de abrasivo que se incrustan en el caucho.

Material Referencia	AISI 4340	Normalizado y revenido (28.3±0.8 HRC)
Densidad		7.85 g/mm <sup>3</sup>
Volumen perdido		65.13 ± 0.94 mm <sup>3</sup>

**Figura 16:** Densidad y volumen perdido del material de referencia.

Fuente: Romero O. (2018).

Los resultados de la Tabla Resultados de las Pruebas de Calibración, fueron obtenidos para un acero ASTM 4340, y dichos datos fueron utilizados posteriormente a manera de parámetro de normalización. En donde los valores de desgaste menores a la unidad indican una mejor resistencia al desgaste.

#### 4.1.3.2 Resultados

El volumen perdido durante el ensayo de desgaste se obtuvo al dividir el peso perdido entre la densidad de cada aleación. Se realizaron pruebas de desgaste a tres tipos de fundiciones con distintos tipos de colada los cuales aportaron distintos valores, a continuación, se muestran los resultados obtenidos en los ensayos de desgaste:

**Tabla 9:** Tabla de datos fundiciones blanca

fundición blanca (20%Cr,4.6%C,1.5%Mo) sin tratamiento térmico con superficie rectificada y pulida		
muestra	1A1	1A2
densidad (g/cm <sup>3</sup> )	7,5	7,5
masa inicial (g)	186,3299	149,9674
masa final (g)	186,2436	149,8967
pérdida de masa (mg)	86,3	70,7
perdida de volumen (mm <sup>3</sup> )	11,51	9,43
desgaste relativo	0,16	0,15
dureza (HRC)	52,7	56,4

fundición blanca (35%Cr,2,4%C,1.5%Mo) colada en molde de grafito sin tratamiento térmico con superficie rectificada y pulida				
muestra	2G1	2G2	2G3	2G4
densidad (g/cm <sup>3</sup> )	7.4	7.4	7.4	7.4
masa inicial (g)	159.3858	148.2637	145.3862	145.5290
masa final (g)	159.1817	147.9773	145.2005	145.3686
pérdida de masa (mg)	204.1	286.4	185.7	160.4
perdida de volumen (mm <sup>3</sup> )	27.58	38.70	25.09	21.68
desgaste relativo	0.42	0.59	0.39	0.33
dureza (HRC)	51.30	45.1	48.4	50.5

fundición blanca (26%Cr,2.3%C,2.0%Mo) colada en molde de arena sin tratamiento térmico con superficie rectificada y pulida				
muestra	3A1	3A2	3A3	3A4
densidad (g/cm <sup>3</sup> )	7.4	7.4	7.4	7.4
masa inicial (g)	144.5213	200.1497	193.4449	174.7582
masa final (g)	144.4225	200.0109	193.3054	174.6422
pérdida de masa (mg)	98.8	138.8	139.5	116.0
perdida de volumen (mm <sup>3</sup> )	13.35	18.76	18.85	15.68
desgaste relativo	0.20	0.29	0.29	0.24
dureza (HRC)	53.4	50.5	51.4	49.0

fundición blanca (26%Cr,2.3%C,2.0%Mo) colada en molde de grafito sin tratamiento térmico con superficie rectificada y pulida				
muestra	3G1	3G2	3G3	3G4
densidad (g/cm <sup>3</sup> )	7.4	7.4	7.4	7.4
masa inicial (g)	153.1239	152.3237	151.8256	152.9358
masa final (g)	152.5797	151.6616	151.4403	152.3826
pérdida de masa (mg)	544.2	662.1	385.3	553.2
perdida de volumen (mm <sup>3</sup> )	73.54	89.47	52.07	74.76
desgaste relativo	01.13	1.37	0.80	1.15
dureza (HRC)	58.00	58.8	57.5	57.3

Fuente: Romero O. (2018).



En este caso al igual que los anteriores se certifica que la composición química determina en cierta parte la dureza del material, pero también podemos observar que los diferentes moldes donde fueron coladas las muestras tuvieron impacto sobre las propiedades de estas. Las muestras coladas en moldes de grafitos tuvieron una dureza mayor a la de sus similares coladas en moldes de arena


#### 4.1.3.3 Pruebas Metalográficas

Las microestructuras de las fundiciones trabajadas se encuentran en la Fig. 1.1 a Fig. 1.1. Las imágenes fueron tomadas sobre superficies pulidas para muestras metalográficas, de acuerdo con la norma ASTM E3. Las muestras estudiadas corresponden a las probetas de desgaste designadas como: F1A01, F1G01, F2G01, F3A01 y F3G01. La superficie metalográfica se observa en la Fig. 7-1. Las muestras fueron lijadas (desde lija No. 60 hasta No. 1200) y luego pulidas con alúmina en suspensión (3 $\mu$ m y 0.5 $\mu$ m) hasta lograr una superficie espejo. Todas las muestras fueron atacadas durante 30 segundos con el reactivo Vilella (5ml HCl, 1ml Ácido Pírico, 100ml Etil o Metil Alcohol).

Las micrografías ópticas en fueron tomadas por una cámara digital de 4.1 Mega píxeles. Los archivos obtenidos fueron modificados en tamaño hasta lograr una dimensión de 640x480 píxeles. Las imágenes mostradas a continuación están a un 40% del tamaño real (640x480 pix).

Fundición 1 en Arena: F1A01 (20%Cr, 4.6%C, 1.5%Mo)








**Fig. 17:** Micrografías ópticas de la fundición 1 colada en Molde de Arena: (a) 50X, (b) 200X, (c) 1000X, y (d) 2000X. Atacadas con el reactivo de Vilella.


**Fuente:** Romero O. (2018).

La muestra F1A01, presenta una matriz primordialmente Austenítica con un alto contenido de carburos secundarios al interior de los espacios interdendríticos. Exhibe una considerable cantidad de carburos eutécticos en forma de placas como de barras

Fundición 1 en Grafito: F1G01 (20%Cr, 4.6%C, 1.5%Mo)











**Fig. 17.1:** Micrografías ópticas de la fundición 1 colada en Molde de Grafito: (a) 50X, (b) 500X, (c) 1000X, y (d) 2000X. Atacadas con el reactivo de Vilella.  
**Fuente:** Romero O. (2018).

La muestra F1G01, presenta una matriz de Austenita y Martensita. A diferencia de F1A01, no exhibe carburos secundarios en granos. Muestra una considerable cantidad de carburos eutécticos de menor tamaño tanto en forma de placas como en barras

Fundición 2 en Grafito: (F2G01) (35%Cr, 2.4%C, 1.5%Mo)







**Fig. 17.2:** Micrografías ópticas de la fundición 2 colada en Molde de Grafito: (a) 100X, (b) 500X, (c) 1000X, y (d) 2000X. Atacadas con el reactivo de Vilella.


**Fuente:** Romero O. (2018).

La muestra F2G01, presenta una matriz de Austenita con colonias eutécticas de carburos  $\text{Cr}_7\text{C}_3$  y austenita parcialmente transformada. Los carburos primarios son del tipo  $\text{M}_{23}\text{C}_6$  y  $\text{M}_7\text{C}_3$ , están distribuidos a lo ancho de toda la matriz, y presentan en su gran mayoría discontinuidades o núcleos de fase metálica. Al interior de los granos de austenita se presenta una gran cantidad de carburos segregados, probablemente de molibdeno o incluso del tipo  $\text{M}_{23}\text{C}_6$

Fundición 3 en Arena: (F3A01) (26%Cr, 2.3%C, 2.0%Mo)

La muestra F3A01 corresponde a un hierro hipoeutéctico, presenta una matriz de Austenita y Martensita, con carburos secundarios interdendríticos.








**Fig. 17.3:** Micrografías ópticas de la fundición 3 colada en Molde de Arena: (a) 50X, (b) 500X, (c) 1000X, y (d) 2000X. Atacadas con el reactivo de Vilella


Fuente: Romero O. (2018).

Fundición 3 en grafito: (3G01) (26%Cr, 2.3%C, 2.0%Mo)

La muestra F3G01 presenta una matriz martensítica, con una gran cantidad de carburos secundarios. En ciertas zonas presenta granos de austenita no transformada







**Fig. 17.4:** Micrografías ópticas de la fundición 3 colada en Molde de Grafito: 4.2 50X, (b) 500X, (c) 1000X, y (d) 2000X. Atacadas con el reactivo de Vilella.

Fuente: Romero O. (2018).

#### 4.1.4 Microestructura de fundiciones de hierro

Las fundiciones de hierro pueden presentar los mismos constituyentes de los aceros, más el eutéctico ledeburita compuesto de austenita y cementita, el eutéctico ternario de cementita, ferrita y fosfuro de hierro (esteadita) y el carbono en forma de láminas, nódulos o esferitas de grafito, su microestructura se basa en el diagrama hierro carbono estable.

La Ledeburita es el constituyente eutéctico que se forma al enfriar la fundición líquida de 4.3% C desde 1145°C. Está formada por 52% de cementita y 48% de austenita de 2% C. La ledeburita no existe a temperatura ambiente en las fundiciones ordinarias debido a que en el enfriamiento se transforma en cementita y perlita; sin embargo, en las fundiciones se pueden conocer las zonas

donde existió la ledeburita por el aspecto eutéctico con que quedan las agrupaciones de perlita y cementita.

Ahora la Esteadita es un constituyente de naturaleza eutéctica duro, frágil (300 a 350 Vickers) y de bajo punto de fusión (960°C), que aparece en las fundiciones de alto contenido en fósforo (más de 0.15 % P)

En las fundiciones grises la mayor parte del contenido de carbono en el hierro gris se da en forma de escamas o láminas de grafito, las cuales dan al hierro su color y sus propiedades deseables, esta fundición es fácil de maquinar, tiene alta capacidad de templado y buena fluidez para el colado, pero es quebradizo y de baja resistencia a la tracción.

Las fundiciones blancas se forman al enfriar rápidamente la fundición de hierro desde el estado líquido, siguiendo el diagrama hierro-cementita metaestable; durante el enfriamiento, la austenita solidifica a partir de la aleación fundida en forma de dendritas. A los 1130°C el líquido alcanza la composición eutéctica (4.3%C) y se solidifica como un eutéctico de austenita y cementita llamado ledeburita. Este eutéctico aparece en su mayor parte como cementita blanca que rodea las dendritas de forma de helecho.

Al enfriarse las fundiciones desde 1130°C hasta 723 °C el contenido de carbono de la austenita varía de 2 a 0.8%C al precipitarse cementita secundaria que se forma sobre las partículas de cementita ya presentes, a los 723°C la austenita se transforma en perlita, el eutectoide de los aceros. La fundición blanca se utiliza en cuerpos moledores por su gran resistencia al desgaste, el

Enfriamiento rápido evita la grafitización de la cementita, pero si se calienta de nuevo la pieza colada a una temperatura de 870°C el grafito se forma lentamente adoptando una forma característica conocida como carbono de revenido, resultando la fundición maleable. La matriz de la fundición puede ser ferrítica o perlítica si la aleación se enfría más rápidamente a partir de los 723°C al final del tratamiento de maleabilización.

Las fundiciones muchas veces tienen presencia de elementos aleantes como cromo, níquel, molibdeno, cobre entre otros. Estos elementos tienen como finalidad prevenir la formación de grafito durante la solidificación y a su vez formar carburos metálicos mucho más duros, además de prevenir la formación de perlita en la microestructura

#### **4.2 Diseñar las redes neuronales para evaluar el desgaste en la fundición gris y blanca.**

¿Alguna vez te has preguntado cómo Siri, Alexa o Cortana son capaces de responder a las consultas de los usuarios? ¿O cómo los coches autónomos pueden conducirse solos, sin ayuda humana? Todos estos sistemas tan evolucionados tienen un denominador común: la inteligencia artificial. Esta tecnología es la que les permite realizar ciertas actividades sin ser supervisadas o controladas por una persona

Una red neuronal artificial representa unidades de entrada y de salida interconectadas capaces de transmitir señales. Este sistema forma la base del aprendizaje profundo, que es un subcampo del aprendizaje automático de la computación, donde se intenta emular la propia estructura del cerebro humano. De esta manera, las redes neuronales cogen los denominados “datos de entrada” y son capaces de ser entrenadas para llegar a reconocer patrones de esa información, prediciendo la salida y creando un nuevo conjunto de datos similares para resolver problemas complejos.

##### **4.2.1 Pasos a seguir para crear una red neuronal**

Definir variables independientes y variable dependiente, en primer lugar, vamos a crear el conjunto de características de entrada, así como la variable dependiente (variables de salidas en nuestro caso la pérdida de masa en el desgaste). El conjunto de entrada contiene siete registros para red neuronal de fundiciones blancas (peso específico, dureza, módulo elástico, resistencia a la tracción, compresión y esfuerzo máximo), además creamos un conjunto de

etiquetas que corresponden con los registros anteriores. Estas etiquetas son los valores que darán más o menos peso a nuestra red neuronal y que otorgarán la prioridad.

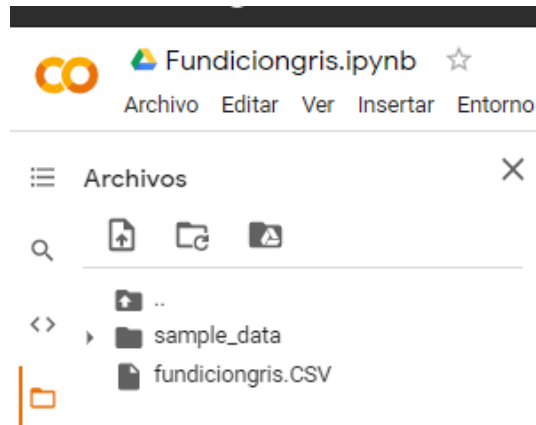
Estos valores que se le van a insertar a la red neuronal tienen que estar guardados en un archivo de Excel .CSV que prácticamente es un archivo donde una tabla separa las columnas por coma (importante tener en cuenta que este proceso no puede quedar espacio en blanco en ningún lado para que la red neuronal reconozca los datos).

	A	B	C	D	E	F	G	H
1	Experimental,peso especifico,dureza,modulo,traccion,esfuerzomax,compresion							
2	0.0105	6.9	187,66	179,386	572			
3	0.0066	7,218	77,186	391,580				
4	0.0053	7.1	219,78	189,392	582			
5	0.0047	7.2	285,85	190,402	590			
6	0.0036	7,299	87,195	412,591				
7	0.0085	7,216	78,190	150,581				
8	0.0136	7.3	300,60	178,390	592			
9	0.0056	6.8	210,68	176,375	575			
10	0.0089	7.1	214,86	184,412	586			
11	0.0027	7.2	305,75	165,390	590			
12								

**Figura 18.** Datos en Excel en formato CSV.

**Fuente:** Herrera D.- Jaramillo N. (2021)

Luego estas variables luego se cargan a la red neuronal, de lado izquierdo google colab cuenta con una pestaña en la cual puedes cargar los datos de dos formas, una es desde el ordenador y se sube a la nube de Google, pero al cerrar sección borra el archivo y a la hora de querer volver a ejecutar la red neuronal toca volver a subir el archivo y la segunda es subiendo el archivo al Drive del correo asociado a Google colab y de ahí puede cargar cualquier archivo que tenga en dicho Drive.



**Figura 19.** Subir datos a la plataforma  
**Fuente:** Herrera D.- Jaramillo N. (2021)

Ahora para poder procesar y analizar los datos se trabajó con la biblioteca de pandas y se procedió a cargar los datos de la red neuronal.

```
[1] 1 import pandas as pd
     2 pd.__version__

'1.1.5'
```

```
1 import pandas as pd
2 df=pd.read_csv('/content/fundiciongris.CSV')
3 print (df)
4 print(df.columns)
```

	Experimental	pesoespecifico	dureza	...	traccion	esfuerzomax	compresion
0	0.0105		6.9	187	...	179	386
1	0.0066		7.0	218	...	186	391
2	0.0053		7.1	219	...	189	392
3	0.0047		7.2	285	...	190	402
4	0.0036		7.0	299	...	195	412
5	0.0085		7.0	216	...	190	150
6	0.0136		7.3	300	...	178	390
7	0.0056		6.8	210	...	176	375
8	0.0089		7.1	214	...	184	412
9	0.0027		7.2	305	...	165	390

```
[10 rows x 7 columns]
Index(['Experimental', 'pesoespecifico', 'dureza', 'modulo', 'traccion',
      'esfuerzomax', 'compresion'],
      dtype='object')
```

**Figura 20.** Carga de datos a la red neuronal.  
**Fuente:** Herrera D.- Jaramillo N. (2021)

Luego se procede a separar los datos de entradas y de salida, para ellos se nombran los datos de entrada como X y los datos de salida como Y, se le asigna que columna quiere que tome X y Y, luego se manda a imprimir la variable X para verificar que tomo los valores deseados.

```
[ ] 1 X=dataset[:,1:8]
     2 Y=dataset[:, 0]

[ ] 1 print(X)

[[ 6.9 187.  66. 179.  386. 572. ]
 [ 7.  218.  77. 186.  391. 580. ]
 [ 7.1 219.  78. 189.  392. 582. ]
 [ 7.2 285.  85. 190.  402. 590. ]
 [ 7.  299.  87. 195.  412. 591. ]
 [ 7.  216.  78. 190.  150. 581. ]
 [ 7.3 300.  60. 178.  390. 592. ]
 [ 6.8 210.  68. 176.  375. 575. ]
 [ 7.1 214.  86. 184.  412. 586. ]
 [ 7.2 305.  75. 165.  390. 590. ]]
```

**Figura 21.** Separación de los valores para X, Y de la red neuronal.

**Fuente:** Herrera D.- Jaramillo N. (2021)

Se importa tensorflow y keras dos bibliotecas de Python que nos facilitará el proceso, y se desarrolla la estructura de la red neuronal, primero se Definen los parámetros, le daremos una numeración al peso que vamos a darle a cada valor. En esta fase es donde se le definen a la red neuronal ciertos parámetros con los cuales es que se juega y tienen que ir en torno a la precisión y el tiempo de procesamiento de la red.

Después se define la función de activación y entrenar el modelo de red neuronal, la función de activación es la función sigmoidea que hay que definir, la cual explicaremos más adelante. A continuación, se define el número de épocas. Una época es la cantidad de veces que se entrara al algoritmo, utilizando los datos. Cuantas más épocas, más costoso será.

Anteriormente se analizaron las variables que se encuentran involucradas en el desgaste de las fundiciones grises, estas van a ser las capas de entrada de la red neuronal ya que son las variables independientes, las cuales para la fundición gris fueron seis (dureza, modulo elástico, resistencia de tracción, compresión, peso específico y resistencia máxima), por tal razón se definió que, consta de seis capas, donde la primera capa corresponde a las de entrada y contiene 6 neuronas las cuales equivalen a las seis variables analizadas, posterior a eso se encuentra la capa oculta aproximadamente con 13 neuronas, ¿porqué 13?, bueno teniendo lista la red neuronal con su estructura definida, lo que queda es variar los numero de capa oculta, el número de neuronas por capa oculta y el número de época y obtener la red neuronal más eficiente que se pueda; es decir, una red neuronal que las capa de salida(la pérdida de masa del desgaste) sea lo más precisa posible en el menor tiempo que se pueda, para no hacer tan pesada la red neuronal. Luego en la capa de salida es de 1 neurona con el resultado final de la pérdida de masa en el desgaste, la cual es la variable dependiente en este caso.

Para la fundición blanca se utilizaron tres variables, por ende, la red neuronal cuenta con tres neuronas, que corresponden a las capas de entrada de dicha red neuronal. Luego se encuentran las capas ocultas que se trabajó aproximadamente con 8 neuronas y la capa de salida de 1 neurona para la capa de salida.

Para poder lograr que las redes de neuronas aprendieran solas fue necesario introducir un nuevo tipo de neuronas. Las llamadas Neuronas Sigmoides son similares al perceptron, pero permiten que las entradas, en vez de ser ceros o unos, puedan tener valores reales como 0,5 o 0,377 etc... También aparecen las neuronas “bias” que siempre suman 1 en las diversas capas para resolver ciertas situaciones. La cual es aplicada en las capas, debido a que la curva y los valores que por lo general se muestran en el desgaste de fundiciones, toman un comportamiento no lineal.

```
1 def build_model():
2     model = keras.Sequential([
3         layers.Dense(16, activation='sigmoid', input_shape=(6)),
4         layers.Dense(16, activation='sigmoid'),
5         layers.Dense(16, activation='sigmoid'),
6         layers.Dense(16, activation='sigmoid'),
7         layers.Dense(16, activation='sigmoid'),
8         layers.Dense(16, activation='sigmoid'),
9         layers.Dense(16, activation='sigmoid'),
10        layers.Dense(16, activation='sigmoid'),
11        layers.Dense(16, activation='sigmoid'),
12        layers.Dense(16, activation='sigmoid'),
13        layers.Dense(16, activation='sigmoid'),
14        layers.Dense(16, activation='sigmoid'),
15        layers.Dense(16, activation='sigmoid'),
16        layers.Dense(1)
17    ])
18
19    optimizer = tf.keras.optimizers.RMSprop(learning_rate=0.00001)
20
21    model.compile(loss='mse',
22                  optimizer=optimizer,
23                  metrics=['mae', 'mse'])
24    return model
```

**Figura 22.** Separación de los valores para X, Y de la red neuronal.  
**Fuente:** Herrera D.- Jaramillo N. (2021)

El último paso sería hacer predicciones, estos pasos sirven para tener una idea de cómo lograr hacer una red neuronal a groso modo, si se habla de una red neuronal, con algunas capas entrada, otras ocultas y una de salida, se está hablando de una red neuronal Perceptrón multicapas la cual en la actualidad es una de las arquitecturas más utilizadas, es por eso que, de manera conveniente, por sus pocas limitaciones, por su capacidad como aproximador universal, su sencillo uso y su aplicabilidad es la seleccionada como estructura para el diseño de las redes neuronales del presente trabajo investigativo, es importante mencionar que no existe una regla o un proceso exacto para seleccionar la estructura más adecuada.

```
[27] 1 import numpy as np
      2 model.predict(np.array([[7,350,100,186,391,600,)]])

array([[0.00711252]], dtype=float32)
```

**Figura 23.** Predicción de la red neuronal.  
**Fuente:** Herrera D.- Jaramillo N. (2021)

Por último y no menos importante, se habla de los programas con los cuales se trabajaron, la red neuronal se realizó por medio de Google colaboratory también llamado “Google colab”, el cual es una herramienta

de Google en la nube para ejecutar código Python y crear modelos de Machine Learning a través de la nube de Google y con la posibilidad de hacer uso de sus GPU. Dicha herramienta la aplicamos en virtud de que libera a nuestra máquina de tener que llevar a cabo un trabajo demasiado difícil tanto en tiempo como en potencia o incluso nos permite realizar ese trabajo si nuestra máquina no cuenta con recursos suficientemente potentes, además permite compartir nuestro cuaderno si se necesita trabajar en equipo como en nuestro caso.

Google Colab se maneja con el lenguaje de programación Python, un lenguaje de programación versátil multiplataforma el cual ha aumentado su popularidad por ser utilizado para inteligencia artificial, muy fácil para personas que están iniciando en el mundo de la programación. En Python también puede crear redes neuronales artificiales, con palabras reales, mucho más complejas, potentes y que añadan múltiples capas ocultas y varios nodos en cada una. Estas redes pueden identificar datos lineales o no lineales, con múltiples aplicaciones en el mercado y en la industria.

Para la manipulación y análisis de datos se trabajó con la biblioteca de Pandas, una extensión de Numpy, Para el sistema de red neuronal se llevó a cabo mediante dos bibliotecas de código abierto llamada TensorFlow y Keras. En programación, una librería es un archivo o conjunto de archivos que se utilizan para facilitar la programación. Las librerías, también llamadas “frameworks”, consisten en archivos de código a los que llamamos al principio de la página.

importar keras

```
[ ] 1 import tensorflow as tf
    2 from tensorflow import keras
    3 from tensorflow.keras import layers
    4 print(tf.__version__)
    5
```

**Figura 24.** Importando librerías de la red neuronal de fundiciones grises.

**Fuente:** Herrera D.- Jaramillo N. (2021)

Es importante resaltar que debido a la gran versatilidad que poseen las redes neuronales estas se pueden adaptar a casi cualquier situación que se les presente, es decir las RNAs son capaces de trabar en base a cualquier parámetro o dato que se le asigne siempre y cuando se tengan los datos suficientes para su entrenamiento.

En el caso de este trabajo se evaluó el desgaste mediante la pérdida de masa como dato de salida, pero además de este dato las redes neuronales artificiales pueden cumplir sus funciones para predecir distintos datos a la salida como dureza, perdida de volumen, entre otros, estas inclusive se pueden diseñar para que trabajen en base a dos o más datos de salida sin embargo para que todo esto sea posible se debe contar con una amplia data para el entrenamiento

#### **4.3 Establecer Parámetro para la mejora de tiempo/precisión de la red neuronal**

Al algoritmo de backpropagation se hizo posible entrenar redes neuronales de múltiples capas de manera supervisada. Al calcular el error obtenido en la salida e ir propagando hacia las capas anteriores se van haciendo ajustes pequeños (minimizando costo) en cada iteración para lograr que la red aprenda consiguiendo que la red pueda -por ejemplo- clasificar las entradas correctamente.

Cada ciclo de corrección de propagación hacia atrás y hacia adelante para reducir la pérdida se denomina época, se trabajó para cada red neuronal con 2000 época, pero a partir de la época numero 500 la red neuronal para las fundiciones

grises no presento mejoría en el error absoluto medio y para la red neuronal para el medio.

```
1 EPOCHS = 1500
2
3 history = model.fit(
4     X,Y,
5     epochs=EPOCHS, verbose=0,
6     callbacks=[tfdocs.modeling.EpochDots()])
```

```
Epoch: 0, loss:0.0007, mae:0.0170, mse:0.0007,
.....
Epoch: 100, loss:0.0007, mae:0.0170, mse:0.0007,
.....
Epoch: 200, loss:0.0007, mae:0.0170, mse:0.0007,
.....
Epoch: 300, loss:0.0007, mae:0.0170, mse:0.0007,
.....
Epoch: 400, loss:0.0007, mae:0.0170, mse:0.0007,
.....
Epoch: 500, loss:0.0007, mae:0.0170, mse:0.0007,
```

**Figura25.** Época de la red neuronal.  
**Fuente:** Herrera D.- Jaramillo N. (2021)

Las capas ocultas para la red neuronal de fundiciones grises a partir de 10 capas ocultas ya presentaban datos coherentes y a partir de 16 neuronas no presento más mejoría significativa, con red neuronal de fundiciones blancas ya con 8 capas presentaba valores razonables, pero a partir de 10 capas ocultas no era mucho su progreso. Por eso para esta estructura de red esta es los mejores parámetros que se pudieron obtener en base a tiempo de red y su precisión en la capa de salida.

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 16)	112
dense_1 (Dense)	(None, 16)	272
dense_2 (Dense)	(None, 16)	272
dense_3 (Dense)	(None, 16)	272
dense_4 (Dense)	(None, 16)	272
dense_5 (Dense)	(None, 16)	272
dense_6 (Dense)	(None, 16)	272
dense_7 (Dense)	(None, 16)	272
dense_8 (Dense)	(None, 16)	272
dense_9 (Dense)	(None, 16)	272
dense_10 (Dense)	(None, 16)	272
dense_11 (Dense)	(None, 16)	272
dense_12 (Dense)	(None, 16)	272
dense_13 (Dense)	(None, 16)	272
dense_14 (Dense)	(None, 16)	272
dense_15 (Dense)	(None, 16)	272
dense_16 (Dense)	(None, 16)	272
dense_17 (Dense)	(None, 1)	17
Total params: 4,481		
Trainable params: 4,481		
Non-trainable params: 0		

**Figura 26.** Número de capas y Neuronas de la red neuronal de fundiciones grises.

**Fuente:** Herrera D.- Jaramillo N. (2021)

En la función de pérdida mínima que presento la red neuronal fue de Loss:  $7.8131e-06$ , presentando una alta eficiencia. Loss function, es una función que evalúa la desviación entre las predicciones realizadas por la red neuronal y los valores reales de las observaciones utilizadas durante el aprendizaje, cada vez que el modelo haga una mala predicción es penalizado. Cuanto menor es el resultado de esta función, más eficiente es la red neuronal. También dio un mae (error absoluto medio) de  $7.8131e-06$  y un de mse (cuadrado de la media de error) de  $7.8131e-06$

```
Epoch 500/2000  
1/1 - 0s - loss: 7.8131e-06 - mae: 0.0018 - mse: 7.8131e-06
```

**Figura 27.** Loss, mae, mse de la red neuronal a las 500 epoch.

**Fuente:** Herrera D.- Jaramillo N. (2021)

Learning\_rate (La razón de aprendizaje) de la red neuronal fue de 0.0001 para que en cada actualización el cambio de los pesos fuera lo más bajo posible y contar con la mayor precisión posible.

```
21 optimizer = tf.keras.optimizers.RMSprop(learning_rate=0.00001)  
22  
23 model.compile(loss='mse',  
24               optimizer=optimizer,  
25               metrics=['mae', 'mse'])  
26 return model
```

**Figura 28.** learning\_rate de la red neuronal.

**Fuente:** Herrera D.- Jaramillo N. (2021)

Para el modelo de predicción que es una forma avanzada de análisis descriptivo básico que utiliza un conjunto de datos actual e histórico para proporcionar un resultado de nuestra red neuronal.

```
[46] 1 import numpy as np  
      2 model.predict(np.array([[7, 350, 100, 186, 391, 600, ]]))  
  
array([[0.00698443]], dtype=float32)
```

**Figura 29.** Modelo de predicción de la red neuronal.


**Fuente:** Herrera D.- Jaramillo N. (2021)

#### 4.4 Realizar comparaciones entre datos ya existentes y valores obtenidos por medio de redes neuronales.

A continuación, haciendo uso de gráficos se realizó las comparaciones pertinentes entre los datos arrojados por las RNAs y los datos reales provenientes de los distintos experimentos

#### 4.4.1 Comparación de resultados primer experimento

En la **Gráfica 1** se muestran los resultados experimentales comparados contra la predicción generada a partir de una red neuronal para las fundiciones grises.




**Gráfico 1:** Comparación entre resultados experimentales y predicción de la Red Neuronal Fundiciones Grises.

**Fuente:** Herrera D.- Jaramillo N. (2021)

#### 4.4.2 Comparación de resultados segundo experimento

En la **Gráfica 2** se muestran los resultados experimentales comparados contra la predicción generada a partir de una red neuronal para las fundiciones Blanca




**Gráfico 2:** Comparación entre resultados experimentales y predicción de la Red Neuronal Fundiciones Blancas.

**Fuente:** Herrera D.- Jaramillo N. (2021)

#### 4.4.3 Comparación resultados tercer experimento

En el gráfico 3 se puede observar una comparación entre los resultados dados por la RNA y los obtenidos de forma experimental.

En este caso se quiso Comparación entre resultados experimentales y predicción de la Red Neuronal Fundiciones Blancas, el material obtenido se sometió a Pruebas de desgaste según la norma ASTM G65 descrita anteriormente, de cual se obtuvo el siguiente resultado con la red neuronal



**Tabla 5:** Comparación entre resultados experimentales y predicción de la Red Neuronal Fundiciones Blancas.

**Fuente:** Becerra, I. (2007)

#### 4.4.4 Error promedio

El error encontrado para cada dato simulado se estableció mediante la siguiente Ecuación:

$$Error[\%] = \left| \frac{R_{real} - R_{simul}}{R_{real}} \right| * 100$$

**Figura 30.** Ecuación de Error para los datos

**Fuente:** Gómez G.- Lizarazo M. (2007)

Siendo Rreal y Rsimul los valores de Pérdida de masa experimental y simulada, respectivamente. Para las fundiciones grises se obtuvo un error máximo de 13.89% y un mínimo de 6.38%, contando con un error promedio de 9.4% como se muestra en la tabla 10

**Tabla 10:** Tabla de error de fundiciones grises

Fundición Gris		
real	simulado	
pérdida de masa (g)	pérdida de masa (g)	error (%)
0,0105	0,0098	6,67%
0,0066	0,0059	10,61%
0,0053	0,0058	9,43%
0,0047	0,0050	6,38%
0,0036	0,0031	13,89%
		<b>error promedio (%)</b>
<b>S:</b>		46,98%
		9,40%

**Fuente:** Herrera D.- Jaramillo N. (2021)

Para las fundiciones Blanca se obtuvo un error máximo de 6.23% y un mínimo de 0.62 %, contando con un error promedio de 3.05% como se muestra en la tabla 11

**Tabla 11:** Tabla de error de fundiciones blancas

Fundición Blanca		
real	simulado	
pérdida de masa (g)	pérdida de masa (g)	error (%)
0,1781	0,1796	0,84%
0,1717	0,1824	6,23%
0,171	0,1781	4,15%
0,1788	0,1754	1,90%
0,1648	0,1562	5,22%
0,2347	0,2245	4,35%
0,1784	0,1795	0,62%
0,1951	0,1969	0,92%
0,1196	0,1234	3,18%
		<b>error promedio(%)</b>
<b>S:</b>		27,41%
		3,05%

**Fuente:** Herrera D.- Jaramillo N. (2021)

Para el segundo grupo de fundiciones blancas del cual se tenían los datos de la siguiente tabla como resultados reales provenientes del experimento. Se procedió a calcular el error que presento esta variación de fundiciones Blancas.

**Tabla 12:** Datos de entrada y salida para la Red Neuronal Fundiciones Blancas

MUESTRA	DENSIDAD	PERDIDAD DE MASA (g)
1A1	7,5	0,8637
1A2	7,5	0,707
2G1	7,4	2,041
2G2	7,4	2,864
2G3	7,4	1,857
2G4	7,4	1,604
3A1	7,4	0,988
3A2	7,4	1,388
3A3	7,4	1,395
3A4	7,4	1,16
3G1	7,4	5,442
3G2	7,4	6,621
3G3	7,4	3,853
3G4	7,4	5,532

**Fuente:** Becerra, I. (2007)

**Tabla 13:** Tabla de error de fundiciones blancas

	real	simulado	
MUESTRA	pérdida de masa (g)	pérdida de masa (g)	error promedio(%)
1A1	0,8637	0,884	2,35%
1A2	0,707	0,691	2,26%
2G1	2,041	2,062	1,03%
2G2	2,864	2,885	0,73%
2G3	1,857	1,8712	0,76%
2G4	1,604	1,6194	0,96%
3A1	0,988	1,0036	1,58%

3A2	1,388	1,3746	0,97%	
3A3	1,395	1,4	0,36%	
3A4	1,16	1,182	1,90%	
3G1	5,442	5,434	0,15%	
3G2	6,621	6,504	1,77%	
3G3	3,853	3,8954	1,10%	
3G4	5,532	5,5513	0,35%	error promedio(%)
<b>S:</b>			16,26%	1,16%

**Fuente:** Herrera D.- Jaramillo N. (2021)

Para esta variación de las fundiciones Blancas se obtuvo un error máximo de 2.35% y un mínimo de 0.35 %, contando con un error promedio de 1.16% como y muestra en la siguiente tabla. Demostrando así que la red no solo es cumple con los datos trabajado anteriormente si no que cualquier fundición blanca con la cual se trabaje va a cumplir con unos estándares relativamente aceptables.

Según lo observado en los resultados obtenidos de la red neuronal podemos observar que factores con la composición química del material o la metalografía no generan cambios en los resultados de la red, el factor realmente influyente en la calidad de las predicciones realizadas por la red neuronal tomando el error promedio como medidor es la cantidad de datos o muestras dadas a la red para su entrenamiento

## CONCLUSIONES

Una vez obtenidos los datos necesarios para la entrada, salida, y entrenamiento de la red que en el caso de este trabajo fueron ensayos realizados sobre fundiciones grises y blancas con distintas características como nivel de aleación, colada, y aplicación. Posterior a esto diseñar la estructura propia de la red neuronal variando parámetros como variables de entrada, variables de salida, número de capas y número de neuronas por cada capa para obtener el porcentaje de error más pequeño posible en los resultados dados por la red se tienen las siguientes conclusiones:

En primera instancia es importante estar muy atentos a la metalografía y a las composiciones químicas de las fundiciones ya que esta influye directamente sobre la dureza del material esto resulta en una tendencia sobre el desempeño de cada Fundición sometida a desgaste, donde hay una mayor dureza existe tendencia a una menor pérdida de masa. Lo cual se traduce en menor desgaste de la muestra es decir a mayor dureza mayor es la resistencia al desgaste

Los resultados obtenidos en la red neuronal diseñada son bastante cercanos a los obtenidos en los experimentos lo cual demuestra la eficacia de dicha red a la hora de realizar la evaluación del desgaste en las distintas fundiciones, todo esto con la resaltante de que la exactitud de la red es proporcional al número de datos usados en su entrenamiento, las redes neuronales mejoran notablemente sus resultados al tener mayor número ejemplos en su entrenamiento. Esto quedó demostrado en esta investigación ya que cuando el número de muestras en los experimentos era mayor el error de la red disminuía

Los parámetros más influyentes en las redes neuronales cuando se busca aumentar la efectividad de las mismas son el número de capas ocultas, el número de neuronas por cada capa, el número de épocas y función de activación. Al jugar con estos parámetros varía la precisión en los datos de salida de la red. Al definir la función

de activación (sigmoide en este caso) se van variando los otros tres parámetros hasta obtener una combinación que genere la mayor exactitud posible

El error que se presenta entre el desgaste evaluado de forma experimental y el desgaste arrojado por las Redes Neuronales es congruente con la predicción y se encuentra dentro de los intervalos de confianza obtenidos como se aprecia es bajo demostrado en la **Gráfica 1 y Gráfica 2** siendo una red neuronal óptima para el evaluar el desgaste en fundiciones. Se comprueba que para que la RNA de mejores resultados debe ser entrenada con un número de por lo menos 8-10 muestras.


## RECOMENDACIONES

Las recomendaciones para trabajo futuro van en función del cuidado a la hora de la investigación de las pruebas de tribología del material a trabajar, buscar con mucha antelación porque para fundiciones Blancas se encuentra un poco limitada

Se pueden hacer pruebas similares con otros tipos de fundiciones (nodulares, maleables) y otros materiales (aceros) por ejemplo para así analizar el comportamiento de distintas redes neuronales. El uso de datos de experimentación o datos reales distintos u obtenidos de otro tipo de ensayos de acuerdo al material y aplicación que tendrá este

Construir redes neuronales en distintas plataformas y comparar los resultados obtenidos y así determinar cuál plataforma de construcción de RNA es la más idónea para este tipo de aplicaciones

A la hora de crear el archivo de Excel en el formato .CSV tener en cuenta que cualquier coma de más espacio demás a la hora de cargar los datos en la red le va a presentar un error, lo más recomendable es usar en Excel la función espacios o stim en ingles que quita los espacios en blanco de la casilla seleccionada.



**Figura 31:** función stim en Excel

**Fuente:** Herrera D.- Jaramillo N. (2021)

De no poseer una computadora con alto niveles de potencia usar Google Colab, o cualquier servicio en la nube que, solo teniendo un correo electrónico de Google y conexión a internet, te admitirá ejecutar y programar desde la web. No se omite recomendar usar esta red neuronal en diferentes materiales para corroborar el comportamiento de desgaste, así como incrementar el número de pruebas experimentales que puedan aportar mayor información el tema y mayor precisión a la Red Neuronal. No limitarse solo a esta estructura neuronal usada en dicha tesis, el Machine Learning es un área que se ha vuelto muy popular en los últimos años y estar al tanto de los avances que se tenga facilitará su estudio o permitirá tener nuevas diseño de redes neuronales más eficientes.

## REFERENCIAS BIBLIOGRÁFICAS

### Fuentes Bibliográficas

- Arias, F. (2014). **El proyecto de investigación**, Caracas: Episteme.
- Hernández de la Torre J. (2019) Fundición gris para cuchillas centrales de molinos azucareros.
- Hurtado, J. (2010). **El proyecto de investigación 2**. Caracas: Editorial Quirón.
- Morales B. Ivan (2007) Evaluación y caracterización de la respuesta a desgaste de dos aleaciones de hierro fundido blanco
- Romero O. Erick (2015) Análisis de la resistencia al desgaste por abrasión e impacto de fundiciones blancas de alta aleación
- Stracuzzi, S. (2003). **Metodología de la investigación cuantitativa**. Caracas: Editorial FEDUPEL.
- Zambrano, H. (2006). **Manual de Trabajo de Grado de Especialización y Maestría y Tesis Doctorales**. Caracas. Editorial: UPEL.

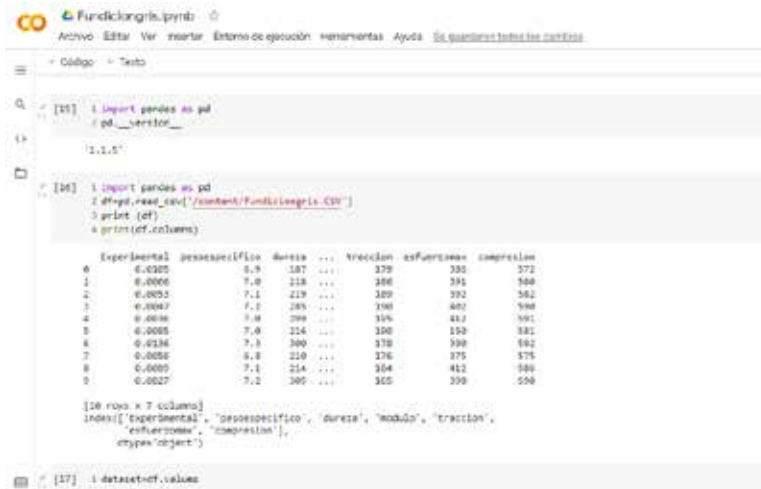
### Fuentes Electrónicas

- Chaparrini, Franco (2018). Redes Neuronales Artificiales. <https://blogthinkbing.com>. pdf. Consultado el 6 de febrero del 2021.
- Díaz, Manuel (2017). Uso de las Redes Neuronales artificiales en el Modelado del ensayo de resistencia a compresión de concreto de construcción según la Norma ASTM C39/C39M. <https://repositorio.unc.edu.pe>.pdf. Consultado el 9 de febrero.
- Jaramillo, M (2005). Características de las redes neuronales. <https://repositorio.unc.edu.pe>.pdf. Consultado el 7 de febrero.
- Gómez, Manuel (2016). Redes Neuronales aplicadas a los negocios: Análisis de un caso. <https://ri.itba.edu.ar/hand>.pdf. Consultado el 8 de febrero del 2021.

- Madero, Johan (2016). Estudio tribológico de aleaciones Antidesgaste. <https://repository.udistrital.edu.com>. Consultado el 10 de febrero de 2021.
- Maneiro N y Mejías A (2016). Manejo y Objetivos de la Ingeniería Industrial. Recuperado en: <http://servicio.bc.uc.edu.ve/ingenieriaysociedad/a5n2/art6.pdf>. Consultado el 10 de febrero del 2021.
- Malaver, Manuel (2015). Aplicación de Redes Neuronales para determinar el pronóstico de las ventas en la empresa Catering & Buffets M y S ubicada en la ciudad de Piura. [www.frro.utn.edu.ar/pdf](http://www.frro.utn.edu.ar/pdf). Consultado el 10 de febrero del 2021.
- Matich, D (2016). Redes Neuronales: Conceptos Básicos y Aplicaciones. [https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5\\_anio/orientadora1/monograis/matich-redesneuronales.pdf](https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monograis/matich-redesneuronales.pdf) consultado el 5 de febrero del 2021.
- Manual de Trabajos de Grado de Especialización y Maestría y Tesis Doctorales, 2006 <http://www.ipm.upel.edu.ve/documentospdf/Reglamentos/Estudiantes/ManualdeTrabajosdeGradodeEspecializacionyMaestriayTesisDoctorales2016.pdf>
- McCarthy (1956) Inteligencia Artificial
- Moffil, Agustine (2015). Enciclopedia de Salud y Seguridad en el Trabajo. [www.insst.es/pdf](http://www.insst.es/pdf). Consultado el 6 de febrero del 2021.
- Montaño, Juan (2016). Redes Neuronales Artificiales aplicadas al análisis de datos. <https://www.tdx.cat.net/pdf>. Consultado el 6 de febrero del 2021.

## ANEXO A

Se quiso dejar constancia del algoritmo de programación de la red neuronal hecha, para dar mayor veracidad de la tesis.



```
File Edit View Insert Help Window Help
Código Texto

[15]: 1 import pandas as pd
      2 pd.__version__

1.1.5

[16]: 1 import pandas as pd
      2 #pd.read_csv("../content/Fundaciongris.csv")
      3 print(df)
      4 print(df.columns)

  Experimental  pesoespecifico  dureza ...  Traccion  esfuercios  compresion
0      0.0285          7.0      187 ...      178      395      371
1      0.0066          7.0      218 ...      186      391      348
2      0.0055          7.1      219 ...      189      392      362
3      0.0047          7.2      285 ...      190      407      390
4      0.0036          7.0      298 ...      194      411      381
5      0.0055          7.0      214 ...      190      353      381
6      0.0136          7.3      300 ...      178      398      392
7      0.0056          6.8      210 ...      176      375      375
8      0.0050          7.1      214 ...      164      412      380
9      0.0027          7.2      305 ...      165      399      359

[10 rows x 7 columns]
Index(['Experimental', 'pesoespecifico', 'dureza', 'modulo', 'traccion',
      'esfuerzos', 'compresion'],
      dtype='object')
```

**Figura 32.** Algoritmo de programación de la Red Neuronal 1.

**Fuente:** Herrera D.- Jaramillo N. (2021)

```

Fundiciongris.ipynb
Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda Se guardaron todos los cambios

+ Código + Texto

[18] 1 print(dataset)

[[1.05e+02 6.90e+00 1.87e+02 8.60e+01 1.79e+02 5.86e+02 5.72e+02]
 [6.60e-03 7.00e+00 2.18e+02 7.70e+01 1.86e+02 3.91e+02 5.80e+02]
 [5.30e-03 7.10e+00 2.19e+02 7.80e+01 1.89e+02 3.92e+02 5.82e+02]
 [4.70e-03 7.20e+00 2.85e+02 8.50e+01 1.90e+02 4.02e+02 5.90e+02]
 [3.60e-03 7.00e+00 2.99e+02 8.70e+01 1.95e+02 4.12e+02 5.91e+02]
 [8.50e-03 7.00e+00 2.18e+02 7.80e+01 1.90e+02 1.50e+02 5.81e+02]
 [1.20e-02 7.90e+00 3.00e+02 8.00e+01 1.78e+02 3.90e+02 5.92e+02]
 [5.60e-03 6.80e+00 2.10e+02 6.80e+01 1.76e+02 3.75e+02 5.75e+02]
 [8.80e-03 7.10e+00 2.14e+02 8.60e+01 1.84e+02 4.12e+02 5.86e+02]
 [2.70e-03 7.20e+00 3.05e+02 7.90e+01 1.05e+02 3.90e+02 5.90e+02]]

[19] 1 X=dataset[:,1:6]
     2 Y=dataset[:, 0]

[20] 1 print(X)

[[ 6.9 187.  66. 179. 386. 572.]
 [ 7. 218.  77. 186. 391. 580.]
 [ 7.1 219.  78. 189. 392. 582.]
 [ 7.2 285.  85. 190. 402. 590.]
 [ 7. 299.  87. 195. 412. 591.]
 [ 7. 216.  78. 190. 190. 581.]
 [ 7.3 300.  60. 178. 390. 592.]
 [ 6.8 210.  68. 176. 375. 575.]
 [ 7.1 214.  86. 184. 412. 586.]
 [ 7.2 305.  79. 169. 390. 590.]]

```

**Figura 33.** Algoritmo de programación de la Red Neuronal 2.  
Fuente: Herrera D.- Jaramillo N. (2021)

```

Fundiciongris.ipynb
Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda Se guardaron todos los cambios

+ Código + Texto

importar keras

[21] 1 import tensorflow as tf
     2 from tensorflow import keras
     3 from tensorflow.keras import layers
     4 print(tf.__version__)
     5

2.5.0

[22] 1 def build_model():
     2     model = keras.Sequential([
     3         layers.Dense(16, activation='sigmoid', input_shape=[6]),
     4         layers.Dense(16, activation='sigmoid'),
     5         layers.Dense(16, activation='sigmoid'),
     6         layers.Dense(16, activation='sigmoid'),
     7         layers.Dense(16, activation='sigmoid'),
     8         layers.Dense(16, activation='sigmoid'),
     9         layers.Dense(16, activation='sigmoid'),
    10        layers.Dense(16, activation='sigmoid'),
    11        layers.Dense(16, activation='sigmoid'),
    12        layers.Dense(16, activation='sigmoid'),
    13        layers.Dense(16, activation='sigmoid'),
    14        layers.Dense(16, activation='sigmoid'),
    15        layers.Dense(16, activation='sigmoid'),
    16        layers.Dense(1)
    17    ])

```

**Figura 34.** Algoritmo de programación de la Red Neuronal 3.  
Fuente: Herrera D.- Jaramillo N. (2021)

```

Fundiciongris.ipynb
Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda Se guardaron todos los cambios

+ Código + Texto
[22] 24 return model
[23] 1 model= build_model()
[24] 1 model.fit(X,Y,epochs=1000,verbose=2)
Epoch 1972/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1973/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1974/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1975/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1976/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1977/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1978/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1979/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1980/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1981/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1982/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1983/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1984/2000

```

Figura 35. Algoritmo de programación de la Red Neuronal 4.

Fuente: Herrera D.- Jaramillo N. (2021)

```

Fundiciongris.ipynb
Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda Se guardaron todos los cambios

+ Código + Texto
[25] Epoch 1984/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1985/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1986/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1987/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1988/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1989/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1990/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1991/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1992/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1993/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1994/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1995/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1996/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1997/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1998/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 1999/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
Epoch 2000/2000
1/1 - 0s - loss: 1.0212e-05 - mae: 0.0027 - mse: 1.0212e-05
<tensorflow.python.keras.callbacks.History at 0x7f5d21295180>

!pip install git+https://github.com/tensorflow/docs
Collecting git+https://github.com/tensorflow/docs
  Cloning https://github.com/tensorflow/docs to /tmp/pip-req-build-w69ka_d
  Running command git clone -q https://github.com/tensorflow/docs /tmp/pip-req-build-w69ka_d
  Requirement already satisfied: error in /usr/local/lib/python3.7/dist-packages (from tensorflow-docs==0.0.0)
  Requirement already satisfied: astor in /usr/local/lib/python3.7/dist-packages (from tensorflow-docs==0.0.0)
  Requirement already satisfied: protobuf==3.9.1 in /usr/local/lib/python3.7/dist-packages (from tensorflow-docs==0.0.0)
  Requirement already satisfied: pyyaml in /usr/local/lib/python3.7/dist-packages (from tensorflow-docs==0.0.0)
  Requirement already satisfied: six in /usr/local/lib/python3.7/dist-packages (from tensorflow-docs==0.0.0)
  Building wheels for collected packages: tensorflow-docs
  Building wheel for tensorflow-docs (setup.py) ... done
  Created wheel for tensorflow-docs: filename=tensorflow_docs-0.0.0-py3-none-any.whl size=184268 sha256=524c93782462163499f9602823ac8e5
  Stored in directory: /tmp/pip-ephem-wheel-cache-u_112185/wheels/1c/40/23/4e90d5763c92b0468f1c2125e6b0ef1a464ac32e
  WARNING: Build wheel for tensorflow-docs is located: metadata 3.1 metadata for 387 version, dist 0.0.0
  Failed to build tensorflow-docs
  Installing collected packages: tensorflow-docs

```

Figura 36. Algoritmo de programación de la Red Neuronal 5.

Fuente: Herrera D.- Jaramillo N. (2021)

```

Fundiciongris.ipynb
Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda Se guardaron todos los cambios

+ Código + Texto

[24] 1 import tensorflow_docs as tfdocs
     2 import tensorflow_docs.modeling

1 EPOCHS = 1500
2
3 history = model.fit(
4     X,Y,
5     epochs=EPOCHS, verbose=0,
6     callbacks=[tfdocs.modeling.EpochDots()])

Epoch: 0, loss:0.0297, mae:0.1722, mse:0.0297,
.....
Epoch: 100, loss:0.0218, mae:0.1476, mse:0.0218,
.....
Epoch: 200, loss:0.0157, mae:0.1252, mse:0.0157,
.....
Epoch: 300, loss:0.0106, mae:0.1027, mse:0.0106,
.....
Epoch: 400, loss:0.0065, mae:0.0804, mse:0.0065,
.....
Epoch: 500, loss:0.0034, mae:0.0582, mse:0.0034,
.....
Epoch: 600, loss:0.0013, mae:0.0363, mse:0.0013,
.....
Epoch: 700, loss:0.0002, mae:0.0152, mse:0.0002,
.....
Epoch: 800, loss:0.0000, mae:0.0027, mse:0.0000,
.....
Epoch: 900, loss:0.0000, mae:0.0027, mse:0.0000,
.....

```

**Figura 37.** Algoritmo de programación de la Red Neuronal 6.

**Fuente:** Herrera D.- Jaramillo N. (2021)

```

Fundiciongris.ipynb
Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda Se guardaron todos los cambios

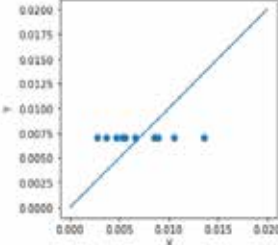
+ Código + Texto

[26] 1 import matplotlib.pyplot as plt
     2 test_predictions = model.predict(X).flatten()
     3 a = plt.axes(aspect='equal')
     4 plt.scatter(Y, test_predictions)
     5 plt.xlabel('X')
     6 plt.ylabel('Y')
     7 _ = plt.plot([0, 0.02], [0, 0.02])

1 import numpy as np
2 model.predict(np.array([[7,350,100,106,391,600]]))

array([[0.00711252]], dtype=float32)

```




**Figura 38.** Algoritmo de programación de la Red Neuronal 7.

**Fuente:** Herrera D.- Jaramillo N. (2021)


## ANEXO B

### Aleación A-2.




Micrografía aleación A-2 (a) T0, aumento 100X; (b)T0, aumento 1000X;  
(c) T5 superficie, aumento 100X; (d) T5 superficie, aumento 1000X.

**Aleación A-3.**




Micrografía aleación A-3, (a) T0, aumento 100X; (b) T0, aumento 1000X; (c) T5 superficie, aumento 100X; (d) T5 superficie, aumento 500X

**Aleación A-5.**




Micrografía aleación A-5 (a) T0, aumento 100X; (b)T0, aumento 1000X; (c) T5 superficie, aumento 100X; (d) T5 superficie, aumento 1000X

**Aleación A-6.**




Micrografía aleación A-6 (a) T0, aumento 100X; (b)T0, aumento 1000X; (c) T5 superficie, aumento 100X; (d) T5 superficie, aumento 1000X

**Aleación A-7.**



Micrografía aleación A-7 (a) T0, aumento 100X; (b)T0, aumento 500X;  
(c) T5 superficie, aumento 200X; (d) T5 superficie, aumento 1000X

**Aleación A-8.**



Micrografía aleación A-8 (a) T0, aumento 100X; (b)T0, aumento 1000X; (c) T5 superficie, aumento 100X; (d) T5 superficie, aumento 1000X