

**CORPORACIÓN MEXICANA DE INVESTIGACIÓN EN MATERIALES**

**DIVISIÓN DE ESTUDIOS DE POSGRADO**



**COMIMSA**



**"ANÁLISIS TRIBOLÓGICO PARA LA PREDICCIÓN DEL  
DESGASTE EN ACERO INOXIDABLE MEDIANTE  
UNA RED NEURONAL ARTIFICIAL"**

**POR**

**GUILLERMO ABRAHAM FLORES MENDOZA**

**TESIS**

**Que para obtener el Grado Académico de**

**MAESTRO EN CIENCIA Y TECNOLOGÍA  
en Sistemas de Manufactura Avanzada**

**Saltillo, Coahuila**

**Diciembre de 2016**

**"Análisis tribológico para la predicción del desgaste en acero inoxidable  
mediante una red neuronal artificial"**

*Por*

*Guillermo Abraham Flores Mendoza*

Tesis

*Presentada al Programa Interinstitucional en Ciencia y Tecnología*

**Sede**

**Corporación Mexicana de Investigación en Materiales, S.A. de C.V.**

*Como requisito parcial para obtener el Grado Académico de*

*Maestría en Ciencia y Tecnología*

**En Sistemas de Manufactura Avanzada**

**Programa Interinstitucional en Ciencia y Tecnología COMIMSA / CONACyT**

**Saltillo, Coahuila**

**Diciembre de 2016**

## **AGRADECIMIENTOS**

A través de éstas líneas deseo expresar mi agradecimiento a la Corporación Mexicana de Investigación en Materiales y al Consejo Nacional de Ciencia y Tecnología por la oportunidad para realizar mis estudios de posgrado y utilizar los materiales y equipos sin los cuales el presente proyecto no se habría concretado.

Agradezco a las personas que dedicaron su tiempo y atención a la revisión del presente trabajo, sus comentarios y contribuciones fueron invaluable.

# ÍNDICE

AGRADECIMIENTOS .....	i
ÍNDICE DE FIGURAS .....	v
ÍNDICE DE TABLAS .....	ix
SÍNTESIS .....	1
1. INTRODUCCIÓN .....	2
1.2 Descripción del problema .....	3
1.3 Preguntas de Investigación .....	4
1.4 Hipótesis .....	5
1.5 Objetivo General.....	5
1.5.1 Objetivos Específicos.....	5
1.6 Alcance y Delimitaciones .....	5
1.7 Justificación.....	6
1.8 Aportación científica y tecnológica.....	6
2. ESTADO DEL ARTE Y MARCO TEÓRICO .....	7
2.1 Antecedentes de la tribología .....	7
2.1.1 Fricción .....	10
2.1.2 Lubricación .....	10
2.1.3 Desgaste .....	11
2.1.4 Modelo clásico de desgaste.....	12
2.2 Soft Computing .....	13
2.3 Redes Neuronales Artificiales .....	14
2.3.2 Función de Base Radial.....	16
2.3.3 Función de Base Radial Rediseñada.....	20
2.2 Estado del arte.....	27
3. DESARROLLO EXPERIMENTAL .....	50
3.1 Metodología.....	50
3.2 Diseño de experimentos .....	52
3.3 Preparación metalográfica .....	53
3.4 Pruebas de desgaste .....	56
3.5 Propiedades del Acero 316L.....	57

3.6	Dureza.....	57
4.	RESULTADOS .....	59
4.1	ACERO INOXIDABLE 304.....	59
4.1.1	Huella de desgaste .....	59
4.1.2	Cálculo del desgaste .....	65
4.1.3	Desgaste de las muestras .....	65
4.1.4	Microscopio Electrónico de Barrido.....	67
4.1.5	Coeficiente de fricción .....	72
4.1.6	Implementación de Red Neuronal.....	76
4.1.6.1	Pre-tratamiento de datos .....	76
4.1.6.2	Cálculo de los Centros.....	77
4.1.6.3	Cálculo de la distancia de Mahalanobis .....	78
4.1.6.4	Función de Base Radial Gaussiana .....	79
4.1.6.5	Cálculo de los pesos.....	79
4.1.6.6	Cálculo de la predicción.....	80
4.1.6.7	Supuestos Estadísticos .....	81
4.1.6.8	Análisis de Varianza .....	83
4.2	Acero Inoxidable 316L .....	87
4.2.1	Huella de desgaste .....	87
4.2.2	Cálculo del desgaste .....	93
4.2.3	Desgaste de las muestras .....	93
4.2.4	Coeficiente de fricción .....	95
4.2.5	Implementación de Red Neuronal.....	98
4.2.5.1	Cálculo de los pesos.....	99
4.2.5.2	Cálculo de la predicción.....	99
4.2.5.3	Supuestos Estadísticos .....	100
4.2.5.4	Análisis de Varianza .....	102
4.3	Validación Acero 316L.....	106
4.3.1	Huella de desgaste .....	106
4.3.2	Cálculo del desgaste .....	111
4.3.3	Desgaste de las muestras .....	111
4.3.4	Coeficiente de fricción .....	113

4.4 Validación de los resultados .....	115
5. CONCLUSIONES .....	119
BIBLIOGRAFÍA.....	123

## ÍNDICE DE FIGURAS

Figura 1. Egipto lubricando para el transporte de la estatua de Ti (a), acercamiento de la imagen (b) (Dowson, 1998).....	7
Figura 2. Imagen digitalizada de uno de los experimentos de da Vinci del <i>Codex Arundel</i> (Dowson, 1998).....	8
Figura 3. Propiedades afectadas en la superficie (Anton Paar, 2014). ....	9
Figura 4. La relación entre la fuerza de fricción y la fuerza normal (Anton Paar, 2014).....	10
Figura 5. Regímenes de lubricación (Shaffer, 2013). ....	11
Figura 6. Componentes del Soft Computing.....	14
Figura 7. Algoritmos de aprendizaje.....	16
Figura 8. Estructura del funcionamiento de la RBF (Colmenares, 2016) .....	18
Figura 9. Red Neuronal Rediseñada de Función de Base Radial (Colmenares, 2016).....	27
Figura 10. Diagrama de flujo de la metodología.....	50
Figura 11. Barra de acero 316L.....	53
Figura 12. Barra de metal posicionada para el corte.....	54
Figura 13. Proceso de desbaste.....	54
Figura 14. Muestra terminada con acabado espejo .....	55
Figura 15. Limpieza ultrasónica de las muestras .....	55
Figura 16. Pin-on-disk configurado para pruebas lubricadas .....	56
Figura 17. Prueba de dureza Vickers.....	57
Figura 18. Resultado del test de dureza.....	58
Figura 19. Ancho de la huella de la condición 1 a 30° (a) y 60° (b).....	59
Figura 20. Ancho de la huella de la condición 2 a 60° (a) y 330° (b).....	60
Figura 21. Ancho de la huella de la condición 3 a 210° (a) y 270° (b).....	60
Figura 22. Ancho de la huella de la condición 4 a 30° (a) y 270° (b).....	60
Figura 23. Ancho de la huella de la condición 5 a 30° (a) y 240° (b).....	61
Figura 24. Ancho de la huella de la condición 6 a 120° (a) y 330° (b).....	61

Figura 25. Ancho de la huella de la condición 7 a 90° (a) y 270° (b).....	62
Figura 26. Ancho de la huella de la condición 8 a 0° (a) y 330° (b).....	62
Figura 27. Ancho de la huella de la condición 9 a 0° (a) y 240° (b).....	62
Figura 28. Ancho de la huella de la condición 10 a 30° (a) y 180° (b).....	63
Figura 29. Ancho de la huella de la condición 11 a 30° (a) y 270° (b).....	63
Figura 30. Volumen perdido de las muestras .....	66
Figura 31. Gráfica de barras del volumen perdido en las muestras .....	67
Figura 32. Condición 1 a 100X (izquierda) y 300X (derecha).....	67
Figura 33. Condición 2 a 100X (izquierda) y 300X (derecha).....	68
Figura 34. Condición 3 a 100X (izquierda) y 300X (derecha).....	69
Figura 35. Condición 4 a 100X (izquierda) y 300X (derecha).....	69
Figura 36. Condición 5 a 100X (izquierda) y 300X (derecha).....	70
Figura 37. Condición 6 a 100X (izquierda) y 300X (derecha).....	70
Figura 38. Condición 7 a 100X (izquierda) y 300X (derecha).....	71
Figura 39. Condición 8 a 100X (izquierda) y 200X (derecha).....	71
Figura 40. Condición 9 a 100X (izquierda) y 300X (derecha).....	72
Figura 41. Condiciones 1 y 2 de desgaste .....	73
Figura 42. Condiciones 3 y 4 de desgaste .....	73
Figura 43. Condiciones 5 y 6 de desgaste .....	74
Figura 44. Condiciones 7 y 8 de desgaste .....	75
Figura 45. Condiciones 9, 10 y 11 de desgaste .....	75
Figura 46. Gráfica de predicción contra objetivo .....	80
Figura 47. Intervalos de confianza de la predicción .....	85
Figura 48. Ancho de la huella de la condición 1 a 180° (a) y 300° (b).....	87
Figura 49. Ancho de la huella de la condición 2 a 30° (a) y 240° (b).....	87
Figura 50. Ancho de la huella de la condición 3 a 0° (a) y 210° (b).....	88
Figura 51. Ancho de la huella de la condición 4 a 30° (a) y 210° (b).....	88
Figura 52. Ancho de la huella de la condición 5 a 150° (a) y 300° (b).....	88
Figura 53. Ancho de la huella de la condición 6 a 0° (a) y 180° (b).....	89
Figura 54. Ancho de la huella de la condición 7 a 30° (a) y 270° (b).....	89



Figura 55. Ancho de la huella de la condición 8 a 0° (a) y 270° (b).....	90
Figura 56. Ancho de la huella de la condición 9 a 120° (a) y 300° (b).....	90
Figura 57. Ancho de la huella de la condición 10 a 60° (a) y 270° (b).....	90
Figura 58. Ancho de la huella de la condición 11 a 90° (a) y 300° (b).....	91
Figura 59. Volumen perdido de las muestras .....	94
Figura 60. Gráfica de barras del volumen perdido en las muestras .....	94
Figura 61. Condiciones 1 y 2 de desgaste .....	95
Figura 62. Condiciones 3 y 4 de desgaste .....	96
Figura 63. Condiciones 5 y 6 de desgaste .....	96
Figura 64. Condiciones 7 y 8 de desgaste .....	97
Figura 65. Condiciones 9, 10 y 11 de desgaste .....	98
Figura 66. Gráfica de predicción contra objetivo .....	100
Figura 67. Intervalos de confianza de la predicción .....	104
Figura 68. Ancho de la huella de la condición 1 a 0° (a) y 180° (b).....	107
Figura 69. Ancho de la huella de la condición 2 a 90° (a) y 270° (b).....	107
Figura 70. Ancho de la huella de la condición 3 a 0° (a) y 180° (b).....	107
Figura 71. Ancho de la huella de la condición 4 a 30° (a) y 210° (b).....	108
Figura 72. Ancho de la huella de la condición 5 a 120° (a) y 210° (b).....	108
Figura 73. Ancho de la huella de la condición 6 a 0° (a) y 330° (b).....	109
Figura 74. Ancho de la huella de la condición 7 a 90° (a) y 300° (b).....	109
Figura 75. Ancho de la huella de la condición 8 a 30° (a) y 270° (b).....	109
Figura 76. Volumen perdido de las muestras .....	112
Figura 77. Gráfica de barras del volumen perdido en las muestras .....	112
Figura 78. Condiciones 1 y 2 de desgaste .....	113
Figura 79. Condiciones 3 y 4 de desgaste .....	114
Figura 80. Condiciones 5 y 6 de desgaste .....	114
Figura 81. Condiciones 7 y 8 de desgaste .....	115
Figura 82. Resultados de validación en los intervalos de confianza .....	116
Figura 83. Comparación entre resultados experimentales, predicción de la ANN y Archard para el Acero 304L.....	117

Figura 84. Comparación entre resultados experimentales, predicción de la ANN y Archard para el Acero 304L..... 118

## ÍNDICE DE TABLAS

Tabla 1. Diseño de experimentos .....	53
Tabla 2. Composición química del acero 316L % e.p. ....	57
Tabla 3. Dureza Vickers y equivalencia en Rockwell C.....	58
Tabla 4. Ancho de la huella de desgaste.....	64
Tabla 5. Volumen perdido y velocidad de desgaste de la muestra .....	65
Tabla 6. ANOVA aplicado al proceso de desgaste.....	83
Tabla 7. Error estándar de los pesos (Standard error) .....	83
Tabla 8. Prueba de significancia de las variables.....	84
Tabla 9. Intervalo de confianza de los pesos .....	84
Tabla 10. Intervalo de confianza de las estimaciones .....	84
Tabla 11. Métricas estadísticas de evaluación .....	85
Tabla 12. Ancho de huella de desgaste. ....	92
Tabla 13. Volumen perdido y tasa de desgaste de la muestra.....	93
Tabla 14. ANOVA aplicado al proceso de desgaste.....	102
Tabla 15. Error estándar de los pesos.....	102
Tabla 16. Prueba de significancia de las variables.....	103
Tabla 17. Intervalo de confianza de los pesos .....	103
Tabla 18. Intervalo de confianza de las estimaciones .....	104
Tabla 19. Métricas estadísticas de evaluación .....	105
Tabla 20. Ancho de huella de desgaste. ....	110
Tabla 21. Volumen perdido y tasa de desgaste de la muestra.....	111

## SÍNTESIS

La manufactura en su sentido más amplio se refiere al proceso de transformación de materias primas en productos terminados; aunque el término puede abarcar desde un proceso artesanal hasta la producción industrial de tecnología de punta, el concepto se suele referir de forma general a la producción industrial a gran escala. El estudio del ciclo de vida de un producto requiere que el desempeño sea considerado para su diseño, producción, distribución, uso y eliminación. Uno de los factores de mayor importancia a considerar en el ciclo de vida es el desgaste mecánico.

El desgaste mecánico es un proceso que implica una serie de interacciones complejas en el material a nivel microscópico debido al contacto y movimiento entre materiales. La teoría clásica sobre el desgaste mecánico, específicamente la formulada por Archard considera el comportamiento del desgaste como lineal, sin embargo los estudios actuales sobre el tema han demostrado que existen discrepancias en los resultados del modelo de Archard debido a la alta variabilidad del proceso de desgaste.

La falta de un modelo único para el desgaste, obliga a buscar herramientas matemáticas alternativas que permitan hacer una estimación del desgaste. Durante el presente trabajo se realiza una predicción del desgaste utilizando una red neuronal de función de base radial, y se compara contra los resultados experimentales y los resultados obtenidos a través del modelo clásico a fin de evaluar su utilidad en este problema.

**Palabras clave:** Desgaste volumétrico, Archard, *Red Neuronal, Función de Base Radial.*

## 1. INTRODUCCIÓN

La tribología se define como la ciencia de la fricción, desgaste y lubricación. En esencia, es el tratado de los cuerpos cuyas superficies se encuentran en contacto y en movimiento relativo. La relevancia del estudio de la tribología radica en la comprensión de los fenómenos que se presentan durante los mecanismos de fricción, lubricación y desgaste. El estudio de la tribología inicia con la revolución industrial debido al aumento del diseño y uso de diversos mecanismos, desde las vías de un ferrocarril, automóviles, hasta aplicaciones como los Sistemas Microelectromecánicos (MEMS, por sus siglas en inglés) (Yang, 2016) y productos de uso biomédico. Un ejemplo de uso cotidiano que requiere el análisis de una ciencia como la tribología, es la escritura con una pluma en un papel, donde existe una carga normal que debe estar controlada entre la pluma y el papel para que durante la escritura no exista un daño en ninguna de las dos partes que involucran el sistema de escritura (Bhushan, 2013).

La tribología como ciencia tiene cabida en otras disciplinas como lo es el caso de la ingeniería biomédica. El desgaste mecánico de las prótesis para restauración o rehabilitación de huesos humanos, es un área donde resulta imperativo el contar con un elemento metálico que posea características mecánicas apropiadas, así como resistencia a la corrosión considerando que se encuentra en un medio salino (Johansson, 1989).

Si se considera que las articulaciones prostéticas pueden presentar fenómenos de lubricación, fricción y desgaste, existe la posibilidad que se genere alto desgaste producto de rangos elevados de fricción así como regímenes inadecuados de lubricación que convergen en un daño o rechazo al implante (Muley, 2016; Sobral, 2016; Zhao, 2016).

Es en este sentido, que durante el presente estudio se utiliza el acero inoxidable 316L, con el fin de investigar y evaluar el desgaste en un elemento biocompatible durante una prueba de pin-on-disk.

## **1.2 Descripción del problema**

El desgaste y la fricción tienen su origen en una serie de complejas interacciones que ocurren a escala microscópica entre superficies que se encuentran en contacto y en movimiento. Dichas interacciones están regidas por características como el tipo de material, geometría, topología, y factores como la carga, temperatura, tipo de contacto, condiciones atmosféricas, por mencionar solo algunos (Axen, 2001).

Los análisis tribológicos actuales, permiten conocer las características físicas de los materiales que se encuentran en contacto y movimiento. Sin embargo, aunque algunas de estas propiedades son por regla general constantes, el estudio actual de los mismos ha demostrado que estas características se ven modificadas de forma espontánea por diversos factores tales como los mecanismos de desgaste, temperatura, regímenes de lubricación, entre otros, resultado en un comportamiento no lineal, contrario a lo sugieren los postulados clásicos del desgaste.

Lo anterior es causa de una deficiencia en el conocimiento real del comportamiento de un sistema mecánico, de modo que existe siempre la posibilidad que se presenten anomalías en el sistema. Estudios experimentales han demostrado que el comportamiento inicial del desgaste no es lineal como se señala en la teoría clásica, sino hasta que éstos alcanzan el estado tribológico estacionario.

El acero inoxidable 316L austenítico es un materiales biocompatible cuyas aplicaciones van desde implantes quirúrgicos principalmente aquellos

utilizados como soporte de cargas, como lo son las prótesis para piernas y cadera, la fabricación de placas craneales, varillas espinales, prótesis de reemplazo en las articulaciones, implantes dentales y catéteres (Köse, 2016).

De lo anterior se desprende la necesidad de estudiar los mecanismos tribológicos que rigen un material de uso biomédico como lo es al acero 316L, más aún predecir el desgaste considerando la no linealidad que rige su comportamiento, mediante alguna herramienta matemática no tradicional. Por lo anterior se opta por el uso de las redes neuronales artificiales.

Pertenecientes a los sistemas de cómputo suave (SC, por sus siglas en inglés) las Redes Neuronales Artificiales (ANN, por sus siglas en inglés) son una herramienta conocida por su tolerancia a las imprecisiones e incertidumbre propias de un sistema cuyo comportamiento carece de linealidad (Leema, 2015).

En resumen, el problema que se presenta es la imposibilidad de predecir el desgaste real de un acero 316L debido a su no linealidad, por lo que se busca desarrollar una metodología basada en redes neuronales artificiales para estimar el desgaste.

### **1.3 Preguntas de Investigación**

- ¿Cuál será el desgaste volumétrico para el material seleccionado bajo las condiciones establecidas en el diseño de experimentos?
- ¿Cuáles son los modelos de Redes Neuronales existentes que se adecuan al problema?
- ¿Cómo es que el modelo propuesto será evaluado?
- ¿Cómo se comporta el modelo de redes neuronales respecto a los resultados experimentales y al modelo clásico de Archard?

## **1.4 Hipótesis**

H<sub>1</sub>: Por medio del desarrollo de una metodología basada en una red neuronal artificial se podrá predecir el desgaste volumétrico de un acero inoxidable en una prueba pin-on-disk con un intervalo de confianza.

## **1.5 Objetivo General**

Analizar y desarrollar la metodología de una red neuronal con una función de base radial cuya inferencia estadística permita evaluar el modelo propuesto y estimar el desgaste volumétrico asignándole un intervalo de confianza.

### **1.5.1 Objetivos Específicos**

- Realizar pruebas de desgaste en pin-on-disk. Conocer el desgaste experimental
- Seleccionar y desarrollar un modelo de Red Neuronal para la predicción del desgaste volumétrico.
- Analizar la predicción resultante usando las pruebas estadísticas que validan el modelo.
- Analizar los resultados del modelo de desgaste propuesto con los resultados experimentales y el modelo clásico.

## **1.6 Alcance y Delimitaciones**

Generación de una metodología para un modelo de estimación del desgaste volumétrico para una prueba en pin-on-disk.



El estudio se limitará a la predicción del desgaste sin considerar las características tribológicas de los diferentes mecanismos de desgaste ni la modificación de la microestructura del material. A su vez, queda establecido que el trabajo no está enfocado a la optimización de ninguno de los parámetros tribológicos.

### **1.7 Justificación**

El modelo clásico de desgaste planteado por Archard y Holm permite realizar una proyección para predecir el desgaste mecánico de forma lineal. Sin embargo, las pruebas experimentales han demostrado no linealidad en el proceso de desgaste mecánico. Por lo anterior se propone generar una metodología para la estimación del desgaste mediante el uso de una red neuronal artificial. La red neuronal será evaluada mediante inferencia estadística, a fin de determinar qué tan adecuado es el modelo, así como dar un rango de confianza de la estimación.

### **1.8 Aportación científica y tecnológica**


La aportación científica está dada por el desarrollo de una metodología para la aplicación de una Red Neuronal Artificial para la predicción del desgaste de una prueba pin-on-disk.

La aportación tecnológica resulta de la integración del modelo de red neuronales desarrollado a un sistema de programación para automatizar el cálculo de la estimación, de modo que este sea aplicable a otros materiales.

## 2. ESTADO DEL ARTE Y MARCO TEÓRICO

### 2.1 Antecedentes de la tribología


Aunque el término tribología en sí mismo es nuevo, el uso del raciocinio por parte de culturas antiguas para el estudio –sin plena conciencia- de los factores que competen a la misma, se hace presente en los vestigios que nos heredaron. Se tiene conocimiento de algunos vehículos primitivos con ruedas utilizados hace 5000 años en China y Medio Oriente, de acuerdo con Dowson, la primera evidencia del uso de la tribología se aprecia en los jeroglíficos egipcios, probablemente del año 2400 A.C encontrados en la tumba de Saqqara en Egipto (Figura 1) (Dowson, 1998).



**Figura 1.** Egipto lubricando para el transporte de la estatua de Ti (a), acercamiento de la imagen (b) (Dowson, 1998).

Siglos después, Leonardo da Vinci incursiona en el estudio de la fricción aún sin conocer el concepto de fuerza que definiría Newton posteriormente. Los estudios de da Vinci le permitieron deducir que un cuerpo posee una resistencia de fricción que es igual a una cuarta parte del peso del objeto (Figura 2). Lo anterior si bien en la actualidad se sabe es incorrecto, es parte de una metodología formal para investigar la fricción, de donde se desprenden las primeras dos leyes: (1) la fricción es independiente al área de contacto y (2) la

fricción es directamente proporcional a la carga aplicada. Sin saberlo, da Vinci introdujo el concepto de coeficiente de fricción aunque al no publicar sus resultados no se le dio el reconocimiento por dichos experimentos (Pitenis, 2014).



**Figura 2.** Imagen digitalizada de uno de los experimentos de da Vinci del *Codex Arundel* (Dowson, 1998).

El francés Guillaume Amontons fue un físico quién se dio a la tarea de investigar y postular sus resultados sobre el estudio de la fricción, que fueron los mismos que da Vinci, al retomar estos estudios postuló una serie de teorías. Amontons concluyó que la fricción está íntimamente relacionada con la rugosidad, de modo que “estableció su concepto de fricción, que lo atribuyó a la fuerza requerida para levantar las asperezas superficiales de los cuerpos de deslizamiento” (Álvarez Vera, 2012).

Leonard Euler incursionó en el estudio teórico y experimental de la fricción. Él introdujo la diferenciación entre las fuerzas de fricción estática y cinética, además de haber resuelto el problema de la fricción entre una cuerda y polea, que fue el primer problema de fricción resuelto analíticamente en la historia en el año 1750. Fue Euler quien definió el símbolo  $\mu$  como el coeficiente de fricción. Euler postuló el “Modelo de Tomlinson”, donde se asevera que la fricción es originada por pequeñas irregularidades triangulares, cuyo gradiente es el coeficiente de fricción (Popov, 2010).

Por su parte, el gallo Charles Augustin Coulomb realizó contribuciones en lo que refiere a la fricción en seco. En específico, logró corroborar y diferenciar la fricción cinética y estática, lo que quedó plasmado en su obra *Theory of simple machines* de 1781 (Popov, 2010). A Coulomb se le atribuye la tercera ley de la fricción, que asegura que la fuerza de fricción es independiente de la velocidad (Álvarez Vera, 2012).

Hoy en día sabemos que las superficies no son planas, tienen características físicas y químicas; las físicas son la rugosidad que dicta el área y fuerza de contacto, mientras que las químicas se refieren a las capas que componen el material estudiado, donde se tiene una compatibilidad química, resistencia a la cizalladura y propiedades lubricantes (viscosidad) (Figura 3).





Figura 3. Propiedades afectadas en la superficie (Anton Paar, 2014).

La tribología como ciencia estudia tres áreas principales que serán descritas a continuación.

### 2.1.1 Fricción

Se denomina fricción a la resistencia que presenta un cuerpo cuando se encuentra en contacto con otro mientras existe un movimiento entre ellos (Figura 4), donde intervienen fuerzas de adhesión y abrasión. Las fuerzas de adhesión son moleculares y son de tipo electrostático (Vander Voort, 1984), por su parte las fuerzas de abrasión son fuerzas mecánicas que incluyen deformación plástica y elástica. El coeficiente de fricción  $\mu$  es una constante de proporción que resulta del cociente de la fuerza de fricción dividida por la fuerza normal.



**Figura 4.** La relación entre la fuerza de fricción y la fuerza normal (Anton Paar, 2014).

Del estudio de la fricción, se desprenden las tres leyes que se enuncian a continuación.

- La fuerza de fricción es proporcional a la fuerza normal.
- La fuerza de fricción es independiente del área de contacto.
- La fuerza de fricción es independiente de la velocidad de deslizamiento.

### 2.1.2 Lubricación

La lubricación tiene como función (Shaffer, 2013), (Croccolo, 2016):

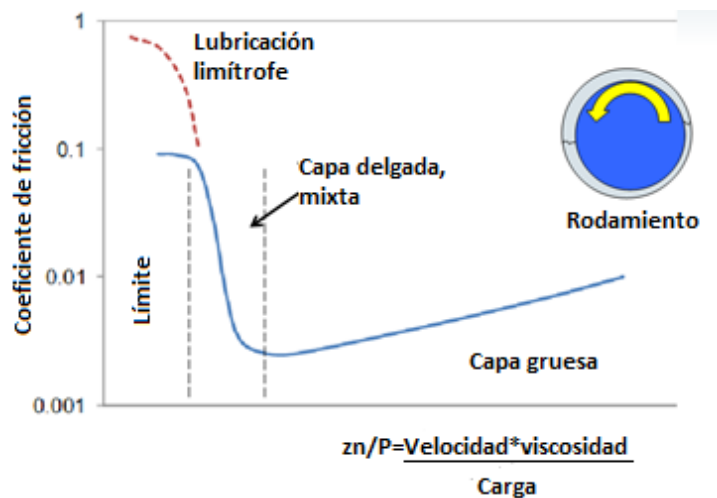
- Reducir la fricción.
- Prevenir o minimizar el desgaste.

- Disipar calor.
- Retirar material sobrante.

Dentro de la lubricación, se encuentra un régimen que puede estar basado en el espesor de la capa del lubricante, donde el valor de una constante  $\lambda$  representa el índice de espesor de la capa líquida de la rugosidad de la superficie (Shaffer, 2013).

- $\lambda > 3$  capa completa de lubricación
- $1.2 > \lambda > 3$  capa mixta o delgada de lubricación
- $\lambda < 1.2$  lubricación límite

Donde los regímenes de lubricación se aprecian en la Figura 5:



**Figura 5.** Regímenes de lubricación (Shaffer, 2013).

### 2.1.3 Desgaste

El desgaste se define como la remoción de material de un cuerpo cuando se encuentra en contacto y en movimiento con otro. Existen 6 modos primarios de desgaste (Popov, 2010):

- Abrasivo.

- Adhesivo.
- Corrosivo por Fretting.
- Erosión.
- Fatiga por contacto.
- Tribo-corrosión.

#### 2.1.4 Modelo clásico de desgaste

El modelo clásico de desgaste es conocido como ecuación de Archard, el cual estudia el proceso de desgaste en un metal mediante un área de contacto esférico cuya área de contacto será el radio del mismo. Su modelo básico propuesto se presenta en la Ec. 1.

$$W = k \frac{L}{3a} \quad \text{Ec. 1}$$

$W$  es el volumen de material removido,  $L$  la carga aplicada y  $a$  es el radio de contacto. La constante  $K$  es un valor de probabilidad que expresa el efecto potencial que la interacción de asperezas tendrá en la formación de partículas de desgaste (Cox, 2012).

Holm, con base en los trabajos de Archard postula que la cantidad de desgaste es igual a la carga aplicada  $L$  multiplicada por la distancia de deslizamiento  $S$ , e inversamente proporcional a la dureza  $H$  de la superficie a desgastar.

$$W = k \frac{LS}{H} \quad \text{Ec. 2}$$

Donde  $k$  es el coeficiente adimensional del desgaste del material mencionado por Archard (Bhushan, 2013) y utilizado en casi todas las propuestas de modelado de desgaste existentes en la actualidad.

Se ha encontrado que en la literatura revisada muchos de los estudiosos del tema toman la ecuación básica de Archard para generar nuevos modelos de desgaste acordes a las condiciones específicas del estudio en cuestión, donde algunos consideran los efectos del contacto plástico y elástico (Cox, 2012).

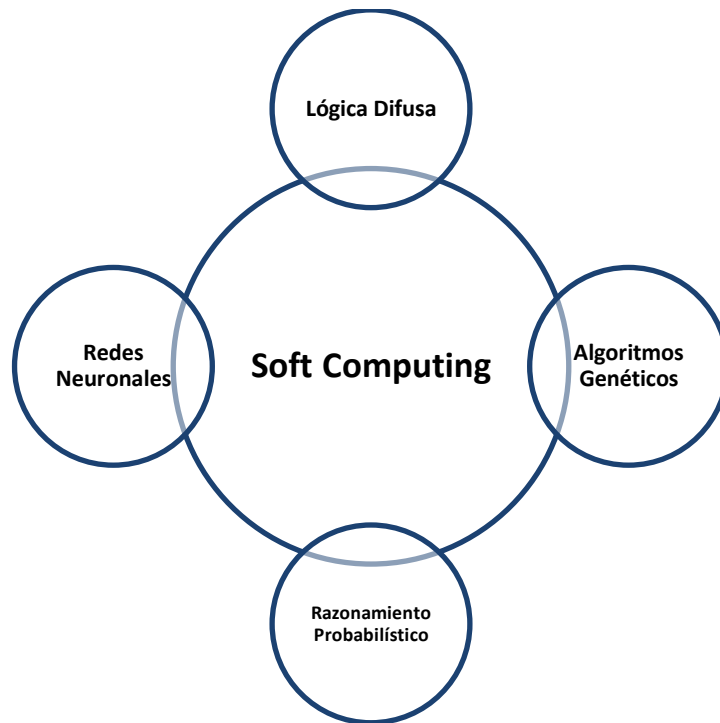
Sin embargo, hasta la actualidad se siguen realizando análisis desde diferentes enfoques que buscan mostrar un panorama más amplio que el de Archard, puesto que el modelo original propuesto en los años 50's desconociendo algunas de las consideraciones que los materiales presentan durante el desgaste.

## **2.2 Soft Computing**

Se le denomina SC a la combinación de técnicas de los sistemas inteligentes computacionales, capaces de emular el pensamiento humano en un campo específico mediante auto-adaptación a un ambiente dinámico, auto aprendizaje y la toma de decisiones (Jang, Sun, & Mizutani, 1997). Probablemente se pueda hablar del nacimiento formal del Soft Computing en el año 1981, cuando se crea la Iniciativa en Cómputo Suave de Berkeley (BISC, por sus siglas en inglés) en la Universidad Berkeley en California. La idea del SC es lograr la convergencia de aquellas metodologías que en su base de trabajo contengan características de los sistemas inteligentes.

El SC se compone de cuatro disciplinas: Lógica difusa, Redes Neuronales, Algoritmos Genéticos y Razonamiento Probabilístico (González, 2012; Nieto González, 2010) (Figura 6).





**Figura 6.** Componentes del Soft Computing

### **2.3 Redes Neuronales Artificiales**

Inspiradas en la estructura biológica que se forma debido a la interconexión de células nerviosas cerebrales llamadas neuronas, encargadas de la integración de señales provenientes del mundo exterior o de otras células, así como de la conducción de respuestas mediante células efectoras (Purves, 2004), las redes neuronales artificiales son una simulación que permiten el procesamiento de información de forma auto-organizacional y auto-adaptativa que a diferencia de los sistemas expertos no requieren una fase de entrenamiento extensiva y que permiten la resolución de problemas no lineales.

Los primeros modelos de redes neuronales artificiales se desarrollaron en 1943 por Warren McCulloch y Walter Pitts, quienes demostraron que una red neuronal artificial era capaz de realizar cualquier operación lógica y aritmética.

La elección de un tipo de red neuronal está en función de criterios como la arquitectura de la red, la asociación de las señales de entrada y los mecanismos de aprendizaje. Sin embargo, dichos criterios no establecen una metodología para seleccionar un tipo de red en específico de acuerdo a un problema específico (Cortés Peralta, 2005). Se conocen 3 arquitecturas básicas en las redes neuronales:

- Red de capa simple. En la literatura es llamada red de capa simple *feedforward*. Este tipo de red consiste en solo dos capas, la primera de entrada y la segunda de salida. Las interconexiones que contienen los pesos, se encargan de conectar cada una de las entradas con la salida de forma unidireccional.
- Red multicapa. Este tipo de red al igual que la anterior, tiene una capa de entrada y salida, pero con una o más capas intermedias que a su vez contienen a los pesos y que son llamadas capas ocultas. Las capas ocultas se encargan de realizar los cálculos previos antes de direccionar las entradas hacia la capa de salida.
- Redes recurrentes. Su principal característica radica en que al menos existe un ciclo de retroalimentación, donde la capa de salida se encuentra conectada a la capa de entrada.

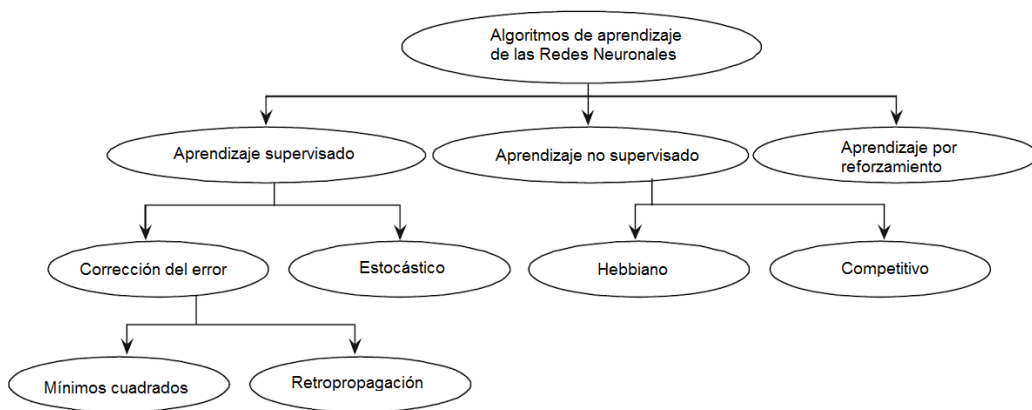
Se le llama aprendizaje al proceso por medio del cual, se adaptan los parámetros conocidos como pesos de una red neuronal. Existen tres métodos de aprendizaje para una red neuronal:

- Aprendizaje supervisado. Para el aprendizaje cada patrón de entrada es asociado a una salida en particular. Este tipo de aprendizaje incluye un entrenamiento controlado por un agente externo que suele denominarse supervisor o maestro.
- Aprendizaje no supervisado. Este método de aprendizaje no permite que la red tenga la salida objetivo durante el entrenamiento. A diferencia del aprendizaje supervisado, no cuenta con un agente externo que controle el

aprendizaje, sino con una serie de reglas que permiten a la red aprender mediante asociaciones.

- Aprendizaje por reforzamiento. Este método utiliza la salida objetivo pero no para entrenar los patrones, sino para indicar si la respuesta generada por la red es o no correcta. En caso de acertar o fallar, la red recibe una señal de refuerzo acorde a si tuvo éxito o no. En función de la señal de refuerzo se ajustan los pesos basándose en mecanismos de probabilidades.

En la Figura 7 se aprecian algunos de los algoritmos de aprendizaje que existen en redes neuronales.



**Figura 7.** Algoritmos de aprendizaje

### 2.3.2 Función de Base Radial

La Función de Base Radial (RBF, por sus siglas en inglés) originalmente fue desarrollada por Powell alrededor de 1980 y fue creada para interpolación numérica como una variante del perceptron multicapa. Más tarde, Broomhead y Lowe introducen un método alternativo al perceptron multicapa para hacer ajuste a funciones no lineales con la función de base radial.

La diferencia fundamental de esta arquitectura respecto al perceptron multicapa, es la operación en la capa oculta. Las neuronas de ésta capa en lugar de realizar una suma ponderada de las entradas y aplicarle una función de activación sigmoidea, se utiliza la distancia que separa al vector de entradas del vector sináptico generado en cada una de las neuronas, denominado centroide.

En general, una RBF tiene una estructura unidireccional de 3 capas (Haykin, 2004):

- Capa de Entrada para los patrones de entrenamiento y prueba.
- Capa Oculta completamente interconectada entre todos sus nodos con la capa de entrada y activada mediante una función radial.
- Capa de Salida completamente interconectada a la capa y activada mediante una función lineal.

Es indispensable entender algunas particularidades de esta topología:

- Los nodos ocultos poseen una función de base radial, cuyos parámetros son el centro y el ancho.
- Existe un centro para cada función radial de la capa oculta. Estos definen un vector de la misma dimensión que el vector de entrada. y normalmente hay un centro diferente por cada neurona de la capa oculta.
- El ancho, es el término con el que se identifica la amplitud de la campana de Gauss originada por la función radial; en otras palabras, es la desviación estándar de la función radial.

El primer cálculo efectuado en la capa oculta es hallar en un nodo la distancia radial (distancia euclidiana)  $d$  entre el vector de entrada  $x$  con  $n$  observaciones y su centro  $c$ :

$$d = \|x - c\| = \sqrt{(x_1 - c_1)^2 + (x_2 - c_2)^2 + \dots + (x_n - c_n)^2} \quad \text{Ec. 3}$$

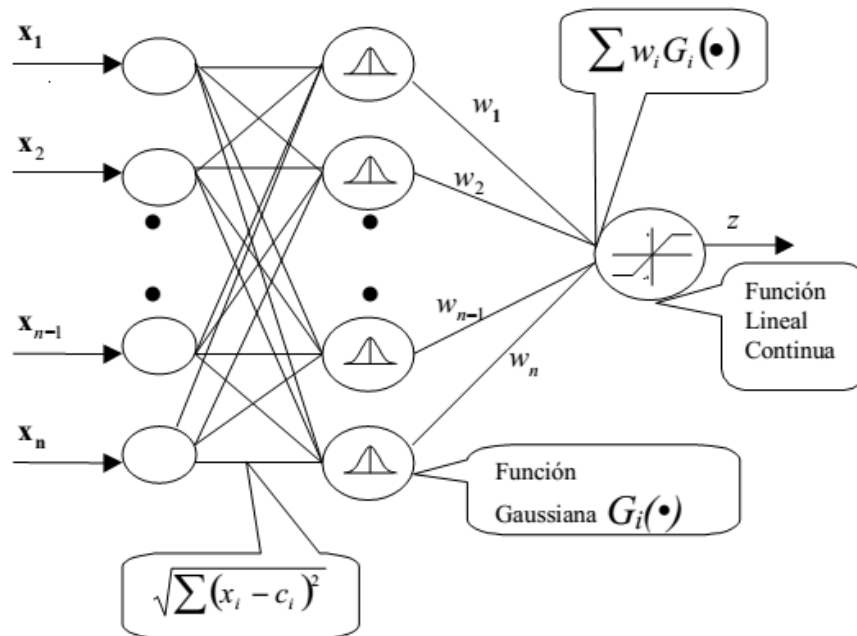
El valor  $v$  es la componente de entrada para activar la función radial. La función de activación es una función de base radial. Lo anterior se debe a que el radio o distancia, es el argumento de esa función que finalmente permite calcular el peso o la influencia en cada neurona.

Algunas de las funciones de activación de la función de base radial son:

$$\text{Gaussiana } f(v) = \exp\left\{-\frac{v^2}{2\sigma^2}\right\} \quad \text{Ec. 4}$$

$$\text{Multicuadrática } f(v) = (v^2 + \sigma^2)^{1/2} \quad \text{Ec. 5}$$

$$\text{Inversa multicuadrática } f(v) = \frac{1}{(v^2 + \sigma^2)^{1/2}} \quad \text{Ec. 6}$$



**Figura 8.** Estructura del funcionamiento de la RBF (Colmenares, 2016)

Entre la capa oculta y la capa de salida se hallan los pesos  $w$  que se verían modificados de acuerdo al algoritmo de entrenamiento. La salida puede resumirse como:  $y = \sum w_i G(\cdot)$ , donde  $G(\cdot)$  es la salida de la capa oculta y corresponde con la

función radial aplicada a la distancia euclidiana de cada una de las neuronas ocultas.

De acuerdo con (Colmenares, 2016), si suponemos un hiperplano en un espacio N-dimensional, la RBF ejecuta una correspondencia no lineal entre los patrones que definen el vector de entradas con el espacio definido por la capa oculta y una correspondencia lineal de este espacio al espacio de salida, es decir, busca una superficie que describa las entradas.

Bajo la premisa de una función que describa una interpolación, Powell establece la relación (Haykin, 2004):

$$F(x) = \sum_{i=1}^N w_i G(\|x - x_i\|) \quad \text{Ec.7}$$

Expresado de forma matricial:

$$Gw = y \quad \text{Ec.8}$$

Donde cada elemento

$$g_{i,j} = (\|x - x_i\|); j,i=1\dots N \quad \text{Ec.9}$$

$$z = [z_1, z_2, z_2, \dots, z_N]^T \quad \text{Ec.10}$$

$$w = [w_1, w_2, w_2, \dots, w_N]^T \quad \text{Ec.11}$$

Considerando todas las observaciones distintas, G es una matriz positiva definida, por lo que los pesos pueden ser calculados mediante la inversa de G.

$$w = G^{-1}z \quad \text{Ec.12}$$

### 2.3.3 Función de Base Radial Rediseñada

Existe una variante de la función de base radial propuesta por Praga y colaboradores, donde se hace uso de un modelo de aprendizaje híbrido para la función de base radial. Dicho modelo, permite que se aplique inferencia estadística para generar y validar la efectividad del modelo de red neuronal resultante (Praga-Alejo, 2013).

Las características que hacen atractivo a este rediseño de red neuronal para ser estudiado son:

- Realizar inferencia estadística para validar el modelo.
- Analizar qué tan bien la ANN explica la variabilidad del proceso.
- Probar la significancia de las variables del modelo.
- El modelo resultante suele tener una mayor precisión a los modelos de base radial tradicionales.

El proceso de aprendizaje de esta ANN, se logra utilizando un algoritmo genético para el cálculo de los centros de la red y la distancia de Mahalanobis. Los pasos a seguir para la generación de este modelo son:

- Generar centroides de la red mediante un algoritmo genético.
- Calcular la distancia de Mahalanobis.
- Aplicar la función de base radial.
- Generar los pesos y la predicción.
- Aplicar inferencia estadística.

i) Función objetivo para entrenamiento de la red neuronal.

Se busca maximizar el coeficiente  $R^2$  (Ec.13), que es una métrica de evaluación, donde  $y_i$  representa la respuesta experimental. Dicha métrica

estadística permite evaluar la proporción de la variabilidad total explicada por el modelo.

$$R^2 = 1 - \frac{y'y - w'G'y}{y'y - (\sum_{i=1}^n y_i)^2 / n} \quad \text{Ec.13}$$

ii) La Distribución de los residuales deben ser normales  $\varepsilon = N(0, \sigma^2)$   
 Para probar la normalidad de los residuales, se utiliza la prueba Anderson-Darling. El estadístico de la prueba Anderson-Darling indica que, cuando su valor es menor a un valor crítico determinado, la distribución ajusta adecuadamente a los datos. La prueba de normalidad de esta métrica se define como:

$$H_0: \text{los datos siguen una distribución normal}$$

$$H_1: \text{los datos no siguen una distribución normal}$$

El estadístico se define como:

$$A^2 = -N - \left(\frac{1}{N}\right) \sum_{i=1}^N (2i - 1) \left( \ln(F(Y_i)) + \ln(1 - \ln(F(Y_{N+1-i}))) \right) \quad \text{Ec.14}$$

Donde F es la distribución acumulada de la función de distribución normal y  $Y_i$  representa las observaciones ordenadas.

iii) Las varianzas del residual  $\varepsilon$  deben ser de varianzas iguales.  
 Para asegurar que existe homogeneidad en las varianzas, se usa la prueba de Breusch-Pagan, la cual no depende del número de observaciones, o de la variable que genera heterocedasticidad. Este estadístico está basado en mínimos cuadrados ordinarios, donde se asume que para el modelo:

$$Y = X\beta + U \quad \text{Ec.15}$$



Donde  $\beta$  se calcula mediante la matriz de interpolación y la estimación de los pesos habituales de la RBF y  $U$  es el error residual. Las perturbaciones  $U_i$  se distribuyen de forma normal con varianza constante:

$$\sigma_i^2 = h(z_i\theta) \quad \text{Ec.16}$$

Donde  $\theta$  es un vector de coeficientes ( $p \times 1$ ) sin relación a  $\beta$ , y  $z$  es un vector de variables ( $p \times 1$ ), donde  $p$  es el número de variables regresoras del modelo. Si asumimos el primer elemento como 1, y la hipótesis nula de homocedasticidad es:

$$H_0 = \theta_2 = \theta_3 = \theta_4 = \dots = \theta_p = 0$$

Las variables  $z_i$  pueden ser una de las variables de regresión que afecten la varianza del modelo. Si el estadístico calculado es mayor que el valor de tablas, entonces la hipótesis se rechaza.

La prueba de White es otro de los métodos para probar la homogeneidad entre las varianzas de los residuales. La matriz de varianza-covarianza de White está dada por:

$$\sum w = \frac{N}{N-k} (X'X)^{-1} \left( \sum_{i=1}^N \widehat{u}_i^2 x_i x_i^T \right) (XX')^{-1} \quad 17$$

Donde  $N$  representa el número de observaciones,  $k$  el número de regresores y  $u_i^2$  el cuadrado del residual del modelo estimado por mínimos cuadrados. El valor convencional de los mínimos cuadrados es:

$$V = \sigma^2 [X'X]^{-1} \quad \text{Ec.18}$$

Y la varianza del error del modelo se encuentra dado por

$$\sigma^2 = \sum u_i^2 / (N - k) \quad \text{Ec.19}$$

iv) Los residuales no deben estar correlacionados

La prueba Durbin-Watson se utiliza para saber si los errores se encuentran correlacionados; la prueba se basa en el supuesto de que los errores son generados por un proceso autoregresivo de primer orden mediante:

$$d = \frac{\sum_{t=2}^n (e_t - e_{t-1})^2}{\sum_{t=1}^n e_t^2} \quad \text{Ec.20}$$

Si  $d < d_L$  se rechaza  $H_0$ , si  $d > d_u$  no se rechaza  $H_0$ , si  $d_L < d < d_u$  la prueba es inconclusa.

v) Análisis de Varianza

Para ajustar el modelo requiere que se cumplan ciertos supuestos como los mencionados anteriormente. Una vez que se cumple lo anterior es posible realizar un análisis de varianza (ANOVA, por sus siglas en inglés) y la inferencia estadística. El ANOVA es un procedimiento para determinar la significancia estadística entre la variable dependiente y una o más variables independientes. El modelo lineal estadístico que representa las observaciones está dado por:

$$y_{ij} = \mu + \tau_i + \varepsilon_{ij} \begin{cases} i=1,2,\dots,a \\ j=1,2,\dots,n \end{cases} \quad \text{Ec.21}$$

Donde  $y_{ij}$  es la observación ( $ij$ ),  $\mu$  es un parámetro común al promedio global,  $\tau_i$  es un efecto del  $i$ -ésimo tratamiento y  $\varepsilon_{ij}$  es el error aleatorio.

Para el ANOVA resulta imprescindible realizar la descomposición de la suma de cuadrados:

$$SS_{Total} = \sum_{i=1}^a \sum_{j=1}^n (y_{ij} - \bar{y} \dots)^2 = y'y - (\sum_{i=1}^n y_i)^2/n \quad \text{Ec.22}$$

Que puede expresarse como:

$$SS_{Total} = SS_{RBF\ MODEL} + SS_{Error} = y'y - (\sum_{i=1}^n y_i)^2/n \quad \text{Ec.23}$$

$SS_{RBF\ MODEL}$  es llamado la suma de cuadrados y se encuentra dado por:

$$SS_{RBF\ MODEL} = w'G'y - (\sum_{i=1}^n y_i)^2/n \quad \text{Ec.24}$$

Por otro lado, el error residual se expresa como:

$$SS_{Error} = y'y - w'G'y = e'e \quad \text{Ec.25}$$

En lo que refiere al error medio cuadrático de dichos componentes, se tiene que:

$$MS_{RBF\ MODEL} = \frac{SS_{RBF\ MODEL}}{a-1} = \frac{w'G'y - (\sum_{i=1}^n y_i)^2/n}{a-1} \quad \text{Ec.26}$$

$$MS_{Error} = \frac{SS_{Error}}{N-a} = \frac{y'y - w'G'y}{N-a} \quad \text{Ec.27}$$

El error estándar de los pesos  $W_j$  se calcula mediante:

$$se(w_j) = \sqrt{\sigma^2 C_{jj}} \quad \text{Ec.28}$$

Lo anterior nos permite hallar el estadístico  $T_0$  definido como:

$$T_0 = \frac{w_j}{se(w_j)} \quad \text{Ec.29}$$

Una vez obtenidos los valores anteriores, es posible obtener los intervalos de confianza para los pesos ( $w_j$ ) y la predicción ( $\hat{y}$ ):

$$w_j - t_{\alpha/2, n-p} \sqrt{\sigma^2 C_{jj}} \leq w_j \leq w_j + t_{\alpha/2, n-p} \sqrt{\sigma^2 C_{jj}} \quad \text{Ec.30}$$

$$\hat{y}_0 - t_{\alpha/2, n-p} \sqrt{\sigma^2 (g_0 (G'G)^{-1} g_0')} \leq \hat{y}_0 \leq \hat{y}_0 + t_{\alpha/2, n-p} \sqrt{\sigma^2 (g_0 (G'G)^{-1} g_0')} \quad \text{Ec.31}$$

Donde los elementos  $g_0$  son la diagonal de la matriz definida por:

$$H = G(G'G)^{-1}G' \quad \text{Ec.32}$$

Para el análisis y validación se hace uso de métricas estadísticas para evaluar el modelo, tales como:

$$R_{Adj}^2 = 1 - \frac{SS_{Error}/(n-p)}{SS_{Total}/(n-1)} \quad \text{Ec.33}$$

El estadístico  $R_{Adj}^2$  decrece si se agregan factores no significativos al modelo.

$$MS_{error} = \frac{SS_{Error}}{N-a} \quad \text{Ec.34}$$

En lo que se refiere al análisis de residuales, se utilizan el error medio cuadrático  $MS_{error}$  que es un promedio de los residuales del ajuste. El error medio cuadrático de predicción (PREMS), el cual debe ser menor al  $MS_{error}$ .

$$PREMS = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad \text{Ec.35}$$

La suma de cuadrados del error de predicción (PRESS) permite determinar qué tan bien trabaja un modelo para predecir nuevos datos, y se define como:

$$PRESS = \sum_{i=1}^n \left( \frac{e_i}{1-h_{ii}} \right)^2 \quad \text{Ec.36}$$

Finalmente se utiliza el estadístico  $R^2_{Predicción}$ , que evalúa cuan buen predictor es el modelo.

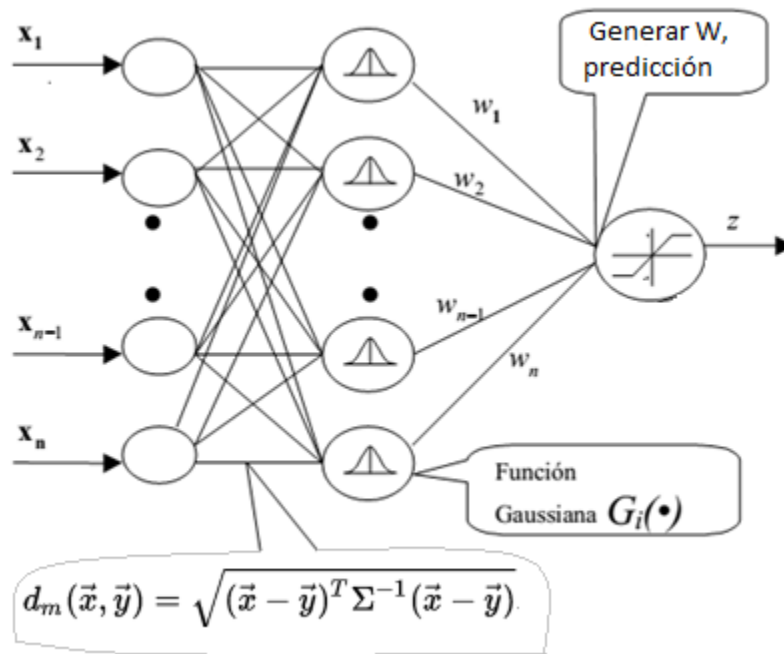
$$R^2_{Prediction} = 1 - \frac{PRESS}{SS_{Total}} \quad \text{Ec.37}$$

vi) Distancia de Mahalanobis

Es la distancia entre un punto de los datos y el centroide de un espacio multivariado (media general). La distancia de Mahalanobis se utiliza en el análisis de componentes principales para identificar valores atípicos. Es un método multivariado más potente para detectar valores atípicos que el procedimiento de evaluar una variable a la vez, porque toma en cuenta todas las diferentes escalas entre las variables y las correlaciona entre sí.

Matemáticamente, la distancia de Mahalanobis entre dos variables aleatorias con la misma distribución de probabilidad  $\vec{x}$  y  $\vec{y}$  con matriz de covarianza  $\Sigma$  se define como:

$$d_m(\vec{x}, \vec{y}) = \sqrt{(\vec{x} - \vec{y})^T \Sigma^{-1} (\vec{x} - \vec{y})} \quad \text{Ec.38}$$



**Figura 9.** Red Neuronal Rediseñada de Función de Base Radial (Colmenares, 2016).

En la Figura 9 se aprecia la red neuronal modificada en su arquitectura de función de base radial. La primera acción es el cálculo de los centros mediante un algoritmo genético con una función objetivo  $R^2$ . Una vez obtenidos los centros, se calcula la distancia de Mahalanobis, se calculan los pesos y en consecuencia es posible generar una predicción. Realizar la inferencia estadística permite averiguar si es o no posible construir el análisis de varianza que evaluará la red.

## 2.2 Estado del arte

El acero inoxidable 316L austenítico es uno de los materiales preferidos en el campo médico. Sus aplicaciones van desde implantes quirúrgicos, principalmente aquellos utilizados como soporte de cargas como lo son las prótesis para piernas y cadera, la fabricación de placas craneales, varillas espinales, prótesis de reemplazo en las articulaciones, implantes dentales y catéteres (Köse, 2016).

Es importante mencionar que cuando un implante está sometido a cargas aplicadas de forma cíclica, existe la certeza de que se genere desgaste por estrés mecánico, el cual clínicamente se sabe genera inflamación y eventualmente una respuesta celular de rechazo de la pieza implantada (Muley, 2016; Sobral, 2016; Zhao, 2016).

El acero 316L es uno de los materiales biocompatibles más utilizado en prótesis e implantes (Saravanan, 2016; Ahmed, 2016) gracias a sus características mecánicas y resistencia a la corrosión. Las aleaciones Fe-Cr-Ni que contienen 10.5% de cromo (como mínimo), y 1.2% de carbono (máximo) son llamadas aceros inoxidable. Estos se clasifican de acuerdo a la microestructura en cinco categorías: austenita, martensita, ferrita, dúplex y acero endurecido por precipitación (Köse, 2016). Además del acero inoxidable 316L, existen algunos otros materiales de uso biocompatibles, como lo son las aleaciones de titanio, alúmina, zirconia, y fosfatos de calcio (Sola, 2016).

Los aceros inoxidables austeníticos son los más comúnmente utilizados en la industria médica debido a sus propiedades mecánicas, resistencia a la corrosión, bajo costo y biocompatibilidad (Akmal, 2016; Kurgan, 2016; Wang W. L., 2016; Helsen, 1998; Shahryari, 2018). Las aplicaciones biomédicas de éste metal son los soportes de carga (rodilla, cadera), placas craneales, placas para fractura, clavos para espina dorsal (Köse, 2016), sustratos para recubrimientos sol-gel empleado en implantes dentales (Muley, 2016), etc.

Resulta importante destacar que una de las condiciones primarias para un implante ortopédico es que el material sea no ferromagnético, además de las características de resistencia a la corrosión y desgaste en presencia de fluidos salinos como lo son los corporales (Juan-Díaz, 2016). Cabe destacar que el acero

316L es utilizado como material base que es sometido a modificaciones superficiales para implantes metálicos (Frajkorová, 2016).

Cuando un implante se usa a un material cuya rigidez no es similar, por ejemplo, un hueso, el movimiento bajo cargas aplicadas de forma cíclica genera desgaste por estrés; la acumulación de iones metálicos y partículas en los tejidos circundantes clínicamente genera inflamación y una respuesta celular adversa que eventualmente culmina en el rechazo y pérdida del implante (Zhao, 2016; Kawashima, 2012; Calin, 2013; Sobral, 2016).

Algunos autores aseguran que los aceros inoxidable así como las aleaciones Co-Cr y Ti-6Al-V no son ideales para implantes humanos de largo plazo debido a su alto contenido de elementos citotóxicos (Fischer, 2016).

Desde la década de los 50's se ha investigado con pericia los fenómenos que rigen el desgaste de los materiales que se encuentran en movimiento. Lo anterior no ha sido posible de forma significativa debido a factores microscópicos como lo son la calidad superficial, heterogeneidades del material, temperaturas locales, entre otros. El modelo clásico propuesto por Archard y Holm para desgaste, contempla la rapidez del desgaste como proporcional a la carga aplicada e inversamente proporcional a la dureza del material. El área de contacto real es la suma de los contactos individuales que ocurren entre asperezas y que compromete a tres elementos básicos: número, tamaño y distribución. Sobre mencionar que existe una influencia debido a la transferencia de material entre superficies rozantes y en la rapidez del desgaste (Bustamante, 2005).

Si bien la teoría clásica señala un modelo lineal para conocer el desgaste, la experimentación ha demostrado que ésta no es siempre acertada, por lo que se han estudiado metodologías alternas para describir y entender los



comportamientos de dicho fenómeno. A continuación se describen algunas de las propuestas:

*Modeling the sliding wear and friction properties of polyphenylene sulfide composites using artificial neural networks* (Gyurova, 2010) presenta un trabajo de modelado para conocer la velocidad de desgaste y el coeficiente de fricción en compuestos de sulfuro de polifenileno (PPS). Los autores de éste trabajo realizan pruebas en pin-on-disk, donde los parámetros que se variaron fueron la presión y la velocidad de deslizamiento (de  $1 \text{ MPa} \cdot \text{m/s}$  a  $9 \text{ MPa} \cdot \text{m/s}$ ) con tres pines de diferente material durante un tiempo de 20 horas con el fin de alcanzar un estado estacionario de las condiciones tribológicas, aunque en algunos casos se detuvo la prueba cuando visualmente el desgaste era excesivo. El coeficiente de fricción así como la fuerza de fricción fueron registrados durante la prueba, sin embargo la velocidad de desgaste específica se calculó de acuerdo a la pérdida de masa mediante la ecuación de Archard. Debido a la no linealidad del proceso se utilizan Redes Neuronales Artificiales, específicamente el algoritmo de Retropropagación, con el fin no solo de modelar el proceso, sino de entender las relaciones que existen entre las propiedades mecánicas y térmicas con las tribológicas. Aunado a la red neuronal, se utiliza un algoritmo de optimización OBS (Optimal Brain Surgeon) para eliminar los valores de *los pesos* innecesarios y hacer más efectivo el algoritmo. Como entradas del sistema generado, se utilizaron propiedades del material a evaluar como la dureza, módulo de Young, módulo de elasticidad, conductividad térmica, entre otros. Resulta importante señalar que los cambios observados en las diferentes fases de las pruebas son debidas a los mecanismos de desgaste, principalmente desgaste abrasivo y adhesivo. Se concluye que la predicción del desgaste mejora cuando se utilizan como parámetros de entrada la microdureza, tensión y módulo de compresión así como la composición del material. El resultado final es una predicción que ayuda a reducir el número de pruebas tribológicas.

*Prediction of contact temperature rise between rough sliding bodies: An artificial neural network approaches* (Ray, 2009) es un estudio que aborda el tema de la temperatura de contacto entre dos cuerpos que se encuentran en movimiento entre sí. La complejidad de ésta búsqueda se entiende cuando se conoce que la rugosidad de las superficies cambia constantemente durante el movimiento. Las temperaturas de contacto son conocidas como “flash temperatures/points”, y su importancia radica en que estas influyen en las características de fricción y desgaste debido al cambio del comportamiento mecánico, térmico y metalográfico. El calor generado por la fricción puede deberse principalmente a cargas de operación, velocidad de deslizamiento, propiedades térmicas y mecánicas así como a los cambios en la topografía de contacto. Los autores proponen un esquema de aprendizaje supervisado; la Retropropagación mediante el algoritmo del Gradiente Descendente para calcular los pesos de la red. Cabe destacar que para el cálculo de la matriz Hessiana, se utilizó una aproximación mediante el Jacobiano, puesto que se sabe que no todas las ecuaciones poseen una segunda derivada. Las entradas de la red neuronal tal y como lo señala el autor fueron: carga normal, distancia de deslizamiento, rugosidad inicial de la superficie, coeficiente de fricción, dureza del material, módulo de elasticidad, conductividad térmica y calor específico; las salidas de la misma fueron la temperatura de contacto y la rugosidad final de la superficie. Se hizo uso de 192 bases de datos obtenidas de resultados experimentales previos. En lo que se refiere a hacer más eficiente la red neuronal en el entrenamiento, los autores normalizan las entradas y los valores objetivo, de modo que la media sea cero y la desviación estándar 1. Se seleccionó un perceptron multicapa de con una sola capa oculta cuya función de activación es la tangente hiperbólica sigmoidea.

La búsqueda de un algoritmo para el desgaste se encuentra presente en diferentes aplicaciones de la ingeniería. *En Effect of different features to drill-wear prediction with backpropagation neural network* (Xu, 2014) se utiliza la red neuronal de retropropagación para predecir el desgaste de uno de los rincones de

una herramienta de acero de alta velocidad para hacer perforaciones en diferentes materiales. Lo anterior, fue logrado mediante la extracción de las características de las componentes dinámicas y estáticas de la fuerza resultante de la penetración, y el torque, mediante transformada wavelet utilizando el algoritmo de retropropagación. Una de las características interesantes desarrolladas, es la descomposición de las señales de entrada provenientes de las componentes de las fuerzas estáticas y dinámicas. Por otro lado, el entrenamiento de la red neuronal de retropropagación se logra a través de datos tales como las condiciones de perforación, el material de trabajo, diámetro de la herramienta para maquinarse y velocidad de la herramienta. El error medio cuadrático se usa para medir el desempeño de la red neuronal, mientras que con la regresión lineal se evalúa la correlación entre el desgaste real y el arrojado por la red neuronal.

El trabajo titulado *On the influence of surface roughness on real area of contact in normal, dry, friction free, rough contact by using a neural network* (Rapetto, 2009), se establece la relación que existe entre la fricción y la carga. Los autores encuentran que, si el área de contacto es pequeña, entonces la fuerza de carga se reduce a una distribución entre un cierto número de asperezas, que resulta en picos de alta presión que pueden provocar la falla del componente. Además, la fricción genera un calentamiento extremo que puede llegar a los cientos de grados Celsius debido a las asperezas de la superficie sometidas a altas cargas, dicho fenómeno es llamado temperaturas flash. Lo anterior logra prevenirse mediante una película de lubricante que actúa entre la carga y la superficie donde se ejerce esta última, logrando una acción hidrodinámica donde la efectividad de esta separación estará en función de la viscosidad del lubricante. Lo anterior resulta altamente importante puesto que muchos de los problemas tribológicos tienen relación directa con dichos fenómenos y propiedades. Para el contacto existen dos tipos de modelos, estadísticos y determinísticos. Rapetto, junto a los demás autores optan por utilizar una red neuronal debido a que esta técnica tiene la habilidad de aprender relaciones entre datos, generalizando así un

modelo que es funcional aun en datos que no han sido evaluados. Los autores utilizaron cinco diferentes superficies de acero que tras ser sometidas a una prueba de ball-on-disk, fueron medidas utilizando un perfilómetro óptico; la idea fue obtener de una superficie 3D, mediante varios perfiles en 2D. Los datos que se utilizaron en éste proyecto provienen de la rugosidad estándar de cada perfil: promedio de la línea central, raíz cuadrada, sesgo o asimetría, curtosis, tangente media, profundidad del núcleo de rugosidad. Para evaluar la red neuronal se utilizó un criterio de error cuadrático medio, donde la red resultante utilizó únicamente 2 capas ocultas y las funciones de activación utilizadas fueron las hiperbólicas.

En *Neural network prediction of brake friction materials wear* (Aleksendric, 2010) se señala la existencia de dos modelos clásicos:  $V = KPL/H$ , donde  $V$  es el volumen erosionado en  $[m^3]$ ,  $K$  es el coeficiente de fricción,  $P$  es la carga normal en [Newtons],  $L$  la distancia recorrida en [metros] y  $H$  la dureza del material; y el segundo modelo  $V = k_f P^a V^b t^c$ , donde  $V$  es la velocidad de deslizamiento en [m/s],  $K$  es el coeficiente de fricción,  $P$  es la carga normal en [Newtons],  $t$  el tiempo de deslizamiento en [s] y  $a$ ,  $b$  y  $c$  son los exponentes que dependen del material y las condiciones de deslizamiento. La complejidad de los fenómenos y mecanismos que rigen éste proceso mecánico resultan en un modelado altamente complicado por parte de las matemáticas clásicas, por lo que una red neuronal resulta ideal para tales fines. Los datos de entrada tomados fueron el tiempo de frenado contra el torque, temperatura, velocidad y presión aplicada en los frenos, en lo que respecta al comportamiento de los frenos; por otro, lado se tomaron en cuenta también la composición y manufactura del material bajo fricción. Un dato importante es que el tipo de red neuronal es inicialmente desconocido por lo que los autores utilizaron diferentes arquitecturas de red para entrenamiento: Levenberg–Marquardt, Regulación Bayesiana, Retropropagación, Gradiente Conjugado y Gradiente Descendente, donde la función de activación fue siempre la sigmoidea. El resultado fueron 75 tipos de redes desarrolladas donde la Regulación Bayesiana obtuvo los mejores resultados.

Al igual que Dragan (Aleksendric, 2010), Jakuba Gzjewski se interesó por evaluar el nivel de desgaste en una herramienta de corte para túneles en el campo de la minería y excavación, pero mediante un sistema neurodifuso. En principio, las señales emanadas del corte se deben filtrar debido al ruido en el sistema, por lo que se sugiere utilizar la transformada wavelet (WT) por su utilidad en la compresión y reducción de ruido en los datos aunque dependiendo la aplicación también se hace mención de la transformada wavelet continua (CWT); dichas técnicas permiten obtener información en el dominio del tiempo y la frecuencia. Para el análisis de las herramientas de corte se utilizó un sistema difuso en su arquitectura Sugeno. En lo que respecta a la red neuronal se optó por un perceptron multicapa, que consiste en un gradual y continuo cambio de los pesos en la red, llevando el error medio cuadrado a un mínimo (Gajewski, 2013).

*Image data processing via neural networks for tool wear prediction* (D'Addona, 2013) es otro de los enfoques que se han dado a la evaluación del desgaste de herramientas por medio de procesamiento digital de imágenes. La necesidad de detectar el nivel de desgaste en herramientas de manufactura resulta crucial en términos de la calidad del producto terminado. Los autores utilizan imágenes de herramientas de corte en buen estado contra aquellas que han sido utilizadas y desgastada, con el fin de emparejar las imágenes entre ellas, y de esta forma evaluar el desgaste en tiempo real mediante la evaluación del espesor de un cráter que se forma en la superficie de la herramienta. Por medio de una red neuronal de retropropagación los vectores de entrada utilizados fueron la media, mediana y modo del nivel de gris de la imagen, la desviación estándar de los grises así como el sesgo, la curtosis y el número de píxeles. Los autores nuevamente han optado por normalizar a 1 los valores de entrada tal como lo hicieron Ray, S., & Chowdhury (Ray, 2009). Si bien el resultado final no se llegó a un resultado óptimo, los autores hacen observaciones de importancia, donde principalmente hablan de la necesidad de homogenizar las imágenes por medio de las cuales se trabaja en su reconocimiento.

*Characterization, pore size measurement and wear model of a sintered Cu–W nano composite using radial basis functional neural network* (Leema, 2015), es un estudio que habla de las bondades del cobre como elemento de contacto eléctrico, sin embargo el elemento por sí mismo presenta una pobre resistencia mecánica, lo que lo hace susceptible al uso de aleaciones para poder emplearlo en un mayor número de aplicaciones. Por tal motivo, es necesario evaluar las condiciones tribológicas que resultan de una aleación por ejemplo Cobre-Tungsteno. Entonces la necesidad de utilizar un modelo matemático que sea ajustable a un sistema con alta precisión para predecir el desgaste resulta en la elección de una herramienta como las redes neuronales, que forman parte de los sistemas de SC. El mismo autor habla sobre la poca aplicación de las funciones de base radial para la predicción del desgaste (Leema, 2015), pese a que ésta arquitectura ha demostrado requerir un menor tiempo de cómputo. Las funciones de base radial consisten en una capa oculta de kernel radial y una capa de salida lineal. Para evaluar el tipo de red fue necesario utilizar el error medio cuadrado. El resultado son valores con mínima discordancia entre el resultado experimental y el predicho mediante la red.

Si bien el modelo original del perceptron propuesto por Rosenblatt resulta relativamente simple, al paso de los años ha sido aumentado en capacidades mediante la adición y combinación de diferentes técnicas matemáticas. *“Convergence Models for Rosenblatt Perceptron Learning Algorithm”* (Diggavi S. N., 1995) estudia la convergencia del perceptron, la cual de acuerdo con los autores depende del tamaño del paso o de la velocidad de aprendizaje, la fuerza de la señal de entrada o varianza ( $\sigma^2$ ) así como la estabilidad del algoritmo que se da esencialmente en  $\mu=0$ . Un aporte interesante de éste trabajo, es que el ajuste de los pesos del perceptron pueden llegar a una convergencia mediante el uso de un método de gradiente estocástico como mínimos cuadrados. Cabe mencionar que para éste análisis se consideraron el *bias* estable, es decir que tenía un valor

no modificable y el valor del vector de pesos es reemplazado por el promedio del error del vector de pesos.

Aunque el uso del perceptron se sugiere como un clasificador lineal, es posible la implementación de una estructura multicapa para el perceptron. En "*Analysis and study of perceptron to solve XOR problem*" (Yanling, 2002), se abunda el uso del perceptron en un problema no lineal, por lo que mediante estructuras multicapa es posible solucionar un problema donde la clasificación no es posible mediante un sistema lineal. Los autores proponen algunas soluciones entre las que destacan artificios matemáticos como el uso de la factorización o elevar al cuadrado las entradas, lo cual simplifica el algoritmo que es evaluado por la función de activación, además de reducir el tiempo de convergencia del algoritmo.

*Fuzzy multilayer perceptron for pattern binary recognition* (Canuto, 1999), señala durante la detección de patrones cuan común resulta una mala clasificación debido a la superposición de las fronteras entre las clases, por lo que se dan a la tarea de implementar un sistema difuso en los cálculos realizados a fin de obtener la salida esperada durante la fase de aprendizaje. La aplicación se dio a un sistema de reconocimiento de caracteres escritos a mano o mediante una máquina, por lo que el reconocimiento de patrones será aplicado a un sistema binario compuesto por los pixeles donde se tiene o no impresión de un carácter. Por otro lado, se hace énfasis en el tiempo de entrenamiento, donde el perceptron multicapa es calificado de forma negativa en cuanto al tiempo que éste toma para el entrenamiento; sin embargo, se identifica que independientemente de la técnica ocupada (perceptron multicapa o perceptron multicapa difuso), a mayor número de iteraciones en el entrenamiento mayor será la estabilidad mostrada de este. Se rescata el hecho de que el perceptron multicapa difuso obtiene un buen desempeño en un menor número de iteraciones, lo que se traduce en un menor tiempo de procesamiento. Si bien resulta claro que en el caso de la escritura a

mano es más complicado el reconocimiento del carácter, también el perceptron multicapa difuso obtiene un mejor desempeño, alrededor de un 12% lo que es significativo tomando a consideración que una escritura a mano es siempre más complicada que una impresa.

“An extended Hamming neural network for non binary recognition” (Garcia, 1994), modifica una red neuronal de arquitectura Hamming para la detección de patrones no binarios, mediante la segmentación de las entradas en un número definido de las mismas regido por el número de bits utilizados para representar cada pixel. Básicamente, se divide una imagen en cada una de sus capas, de modo que el procesamiento de cada una de éstas sea binario, de ese modo es posible particionar un problema no binario para su correcta clasificación, es decir, volverlo linealmente separable mediante segmentación.

La importancia del perceptron radica principalmente en su bajo costo hablando en términos de implementación, por lo que es ampliamente utilizado en el reconocimiento de patrones. Una de sus características más estudiadas es el ciclo de convergencia del perceptron, la cual utiliza tras un número finito de iteraciones siempre y cuando los vectores característicos de entrenamiento sean linealmente separables. En “*Global convergence and limit cycle behaviour of weights of perceptron*” (Ho, 2008), se concluye que el vector de pesos del algoritmo es independiente a los valores iniciales asignados a éste, pero al mismo tiempo que el número de iteraciones requeridas para lograr la convergencia depende de los mismos, por lo que no se recomienda, salvo casos muy específicos, el asignar un valor inicial de ceros a dicho vector.

Pese a que el algoritmo de Rosenblatt es conocido y aplicado desde la década de los 50's como un clasificador de elementos linealmente separables, existe evidencia de que su modificación puede agilizar su convergencia. “*Modified Rosenblatt's Perceptron Algorithm and Novikoff's Theorem*” (Huang-Chi C., 2002),



usa el teorema de Novikoff como método de convergencia del perceptron, el cual se da tras un número finito de iteraciones. La modificación realizada es en el cálculo del bias, donde en lugar de tomar una variable que resulta del máximo de un conjunto de valores, se utiliza el máximo del renglón y columna mínimos. De un conjunto de datos prueba, se consigue reducir de 50 a 11 el número de iteraciones para lograr la convergencia, es decir un 78%.

Si bien el perceptron es una herramienta básica de las redes neuronales artificiales, no es la única. “*Performance Comparison of Multi-Layer Perceptron algorithms in Neural Networks*” (Khalil Alsmadi, 2009), habla de otro tipo de estructuras de mayor complejidad cuya finalidad es la de lograr una más rápida convergencia y mayor precisión en la detección de patrones. Los autores realizan una comparación entre un perceptron, un algoritmo de retro propagación y una regla Delta (variación de la regla de Hebb). Los resultados de éste estudio son interesantes: si bien el tiempo de convergencia del algoritmo de retropropagación es de tan solo 15 [s] con un error de 3.55%, la regla Delta utiliza el doble de tiempo con un error de 4.99%, el perceptron un error de 0.0019% en un tiempo de 45 minutos. Resulta evidente que como clasificador para detección de patrones el perceptron resulta más preciso, aunque sacrifica tiempo de computo.

“*Pattern recognition: neural networks in perspective*” (Wang D. , 1993), es una exploración de algunas de las técnicas específicas de las redes neuronales así como una evaluación en la detección de patrones. Las redes de Hopfield son una sola capa con conexiones recurrentes, donde cada unidad se encuentra conectada a todas las demás, de modo que por decirlo de una forma simple, ésta guarda la información del patrón buscado y cuando un nuevo patrón de entrada es detectado la memoria asociativa activa el patrón guardado que más se parezca a la entrada. Quizá el aporte más rescatable sea la descripción del algoritmo de retropropagación para el entrenamiento. Esta es considerada una ampliación del perceptron de Rosenblatt el cual a diferencia de su predecesor, modifica las

conexiones entre la entrada y las conexiones de las capas ocultas. Durante la fase de entrenamiento el error se propaga en sentido inverso a través de las conexiones entre las diferentes capas para ajustar adecuadamente la conexión de los pesos.

El perceptron multicapa aún con su simpleza, sigue siendo una de las estructuras vigentes al día de hoy. En "*Partial Discharge Pattern Recognition with Neural Networks using the Multilayer Perceptron Technique*" (Mazroua, 1993), la estructura del perceptron multicapa es sencilla, una capa de entrada y una capa de salida, con una o más capas internas ocultas, donde cada neurona se encuentra asociada con un vector de peso que es ajustable, igual que en la versión de Rosenblatt. La fase de entrenamiento o aprendizaje significa que la red neuronal artificial realiza procedimientos matemáticos de forma autónoma que le permiten ajustar sus valores para obtener una salida deseada. Durante el entrenamiento se compara la salida de la red con la salida deseada, en el caso de no empatar éstas, se modifica el vector de pesos utilizando una técnica que permita minimizar la diferencia media del cuadrado que resulta entre la salida esperada y la obtenida; durante ésta fase de entrenamiento resulta imperativo minimizar el error resultante.

Mucho se ha escrito sobre los métodos de aprendizaje para un perceptron, sin embargo la diversidad de las variantes que existen así como el tiempo que éstas requieren son siempre un factor que puede no ser positivo dependiendo de la aplicación buscada. El profesor Chia-lun Hu en su trabajo "*Robust Pattern Recognition Using Non-iteratively Learned Perceptron*" (Hu, 1997), propone un método de aprendizaje no iterativo, en un solo paso el cual satisface la independencia lineal positiva buscada en un sistema de reconocimiento del alfabeto. Para ello utiliza un análisis de los espacios vectoriales así como de la dependencia o independencia lineal que presentan según sea el caso, de modo que segmentando los vectores que componen el sistema así como con algunas

operaciones como el producto punto entre vectores es posible proponer valores mediante un sistema no iterativo. La implementación fue llevada a cabo utilizando Visual Basic para procesar y cuantificar automáticamente algunos de los caracteres escritos a mano mediante algunas técnicas como la transformada de Hankel, transformada de Fourier a fin de obtener los componentes de la frecuencia espacial, consiguiendo un sistema de detección cuyo tiempo de reconocimiento de la escritura es de 1/10 de segundo así como tener una precisión de hasta el 90% de los casos.

*“On the convergence Behavior of Rosenblatt’s Perceptron Learning Algorithm”* (Diggavi S. N., 1992), presenta un análisis en estado estable y transitorio de la convergencia del perceptron, donde el entrenamiento es modelado mediante un sistema Gaussiano mientras que los pesos del perceptron son ajustados mediante el algoritmo de Rosenblatt donde se demuestra que los puntos de convergencia del mismo están en función del tamaño del paso y de la potencia de la señal o varianza, donde el bias del sistema se considera no adaptativo, es decir que no cambia.

El tamaño del paso  $\mu$  controla la convergencia del perceptron; altos valores de éste parámetro se traducen en una más rápida convergencia pero a su vez en fluctuaciones más marcadas del vector de pesos. *“Transient Learning Comparison of Rosenblatt, Backpropagation, and LMS Algorithms for a Single-Layer Perceptron for System Identification”* (Engel, 1994), realizan una evaluación del desempeño de los algoritmos de aprendizaje de las redes neuronales con la estructuras de Rosenblatt, la Retropropagación y Mínimos cuadrados mediante un análisis teórico y una simulación de Monte Carlo. Los resultados señalan que aunque el número de iteraciones es muy cercano, el algoritmo de retropropagación resulta más eficiente que los otros dos; sin embargo, los autores enfatizan que tales resultados son subjetivos pues están a consideración de la aplicación que vaya a desarrollarse con ellos.

*"Pattern Recognition With The Decomposed Multilayer Perceptron"* (Lucas, 1993), propone descomponer un perceptron multicapa con N salidas, en múltiples perceptrones cada uno con una sola salida, de modo que se puedan reducir el número de capas ocultas en el diseño, así como a reducir el número de iteraciones. La idea es que si se tienen N clases, en lugar de utilizar un perceptron multicapa con N salidas, se empleen N perceptrones multicapa cada uno con una salida individual. La descomposición así como el número de conexiones estarán en función de la aplicación. Los autores sugieren utilizar conceptos como millones de conexiones por segundo y millones de conexiones actualizadas por segundo para medir el desempeño de la red en un DSP, escrito en lenguaje C. El problema planteado para medir el desempeño del sistema fue un sistema de reconocimiento de caracteres del servicio postal británico, en donde se asegura el perceptron multicapa segmentado alcanza una precisión de 91.2% en la fase de aprendizaje y un 77.7% en las pruebas contra un 87.3% y 75.5% para la arquitectura de un perceptron multicapa tradicional o un 70.3% y 66.9% de un clasificador euclidiano.

Aunque las redes neuronales son una herramienta excepcional, Rudasi, en su trabajo titulado *"Pattern Recognition using neural networks with a binary partitioning approach"* (Rudasi, 1991), asegura que el tiempo de entrenamiento de las mismas es una de sus principales debilidades, por lo que propone un método para reducir la búsqueda de patrones mediante la segmentación del problema a un sistema binario, lo que se traduce en una menor complejidad al entrenamiento. Se utilizan únicamente dos categorías, utilizando una red neuronal con algoritmo de retropropagación reduciendo así una red neuronal muy larga, en muchas pequeñas redes. El sistema propuesto trata sobre un identificador de voz que utiliza como datos a 47 personas del sexo masculino obtenidas de una base de datos llamada *DARPA TIMIT Acoustic Phonetic Continuous Speech Database* cuya versión es de 1988. Se analizó el espectro en frecuencias de las señales acústicas utilizando la FFT para normalizar los coeficientes espectrales. Los resultados son

alentadores, la estructura propuesta es capaz de realizar el entrenamiento en un tercio del tiempo menos que la arquitectura original.

En lo que respecta a la lógica difusa, la detección de patrones es una de las técnicas que mejores resultados ha dado. “*A heuristic Fuzzy Logic Approach to EGM Pattern Recognition for Multifunctional Prosthesis Control*” (Ajiboye, 2005), describe el procedimiento para implementar un sistema difuso aplicado al control de prótesis transradial cuyas entradas son las señales bioeléctricas provenientes de los miembros amputados o ausentes en personas con alguna deficiencia congénita. El sistema debe ser capaz de reconocer las contracciones reflejadas en la actividad mioeléctrica –muscular- en la zona codo-muñeca del brazo, dicho sistema ha sido optimizado para su empleo mediante un DSP donde el electromiógrafo hace uso de filtros analógicos de 10 y 500 Hz, así como de una ganancia de 2000. El sistema realiza sus reglas difusas mediante la generación de funciones de membresía entre la magnitud RMS de la señal mioeléctrica y su frecuencia, generando 4 rubros, de modo que las reglas *if-then* sean del tipo *if* (contracción) *and* (características de la contracción) *then* (movimiento solicitado por el usuario). Los autores también utilizan algoritmos difusos *c-means* para generar las reglas de inferencia, donde los *cluster* difusos tienen la tarea de agrupar los datos para reducir la varianza, pero éstos no consiguen optimizar los mismos. La defuzzificación se logra a través del máximo de la media estándar. El algoritmo implementado tiene una velocidad de procesamiento en un microprocesador de 8 bits de 45.7 [ms], siendo ésta propuesta altamente prometedora en el reconocimiento de patrones específicos, sin incurrir en el control paralelo.

Resulta importante destacar que para la detección de patrones la lógica difusa juega también un papel importante cuando se trata de controlar sistemas en donde generalmente los ajustes o diagnósticos se realizan por los operadores de forma intuitiva, cualitativa y lingüística. “*Pattern recognition based on fuzzy logic*”

(Schmalzel, 1993), aplica esta técnica para el control de un sistema que monitorea las partículas suspendidas en un fluido. Para éste caso se implementó el sistema de lógica difusa en un microcontrolador de 8 bits mediante un paquete especial llamado Fuzzy-C, el cual genera un prototipo de los archivos con los que se programa el microcontrolador. Para generar las funciones de membresía se utilizó a dos operadores expertos quienes definieron las salidas (danger, caution, normal), los cuales son ingresados a una función de membresía trapezoidal para asignar un valor de pertenencia, donde se generen los conjuntos difusos que indiquen la densidad de un fluido, con el fin de emitir una alarma cuando las condiciones del mismo no sean las adecuadas. Utilizando el software Fuzzy-C la implementación para un sistema de detección de partículas en un fluido utilizó operaciones matemáticas simples que son fácilmente adaptables a un microcontrolador.

La clasificación que es propia del reconocimiento de patrones, generalmente utiliza dos clases de datos, numéricos y lingüísticos. Las redes neuronales artificiales son capaces de trabajar con datos numéricos que pueden provenir de instrumentos de medición, no así con los datos lingüísticos, de ahí la necesidad de fusionar éstas técnicas a fin de controlar un sistema. *“Fuzzy Perceptron Learning and Its Application to Classifiers with Numerical data and Linguistic Knowledge”* (Chen J. L., 1995), explora la construcción de reglas de la forma If-and-then, donde el if hace referencia a una variable lingüística, then a una de las clases donde pertenecen las variables, creando de esta forma reglas if-then difusas que dan lugar a vectores difusos para tratar una clasificación no lineal mediante un perceptron de segundo orden. Mediante un procedimiento detallado en el artículo se obtiene el vector de pesos y el proceso de generación de las reglas difusas. Finalmente los resultados apuntan a un sistema cuyos resultados son comparables a una estructura de retropropagación en donde se requiere de expertos en la implementación de las reglas, siendo la metodología propuesta más sencilla para usuarios no expertos.

Si bien la detección de fugas de agua u otros hidrocarburos en ductos no parece tener analogía con el tema, es el tópico más recurrente bajo el que se encuentra la detección de presencia de gas, puesto que si bien el objetivo a sensor es diferente, la búsqueda de patrones en señales que lleven a identificar anomalías es la misma. “*Using fuzzy theory and information entropy to detect leakage for pipelines*” (Chen Z. , 2012), trata sobre el uso de entropía de información. La entropía de información es un método de evaluación cuantitativa de la incertidumbre de los sistemas capaz de proveer una descripción de la información interna de los sistemas; es utilizada para extraer las características de las señales de la tubería, mientras las técnicas difusas son para establecer las relaciones entre causa y consecuencia de las fallas (síntomas y causas de fallas). Se establece una matriz de causas y síntomas que pasa por un análisis difuso (fuzzy cluster analysis) para establecer una clasificación de fallas. Se requieren datos experimentales y estadísticos para el análisis de información y está basado en datos de una planta piloto de agua presurizada. Los parámetros medidos fueron presión interna del agua. La jerarquización de las causas y consecuencias en la matriz de datos son primarias, la detección según reporta Chen se logra con una precisión que va del 80 al 90%, pero no se especifica la topología de la tubería que juega un papel determinante en el análisis. Utilizar la entropía de información podría resultar en un nuevo enfoque que aporte características de las mediciones tomadas, por lo que podría ser un útil aporte dentro del estudio a desarrollar.

Bingkun Gao en su “*Leakage detection of natural gas pipeline based on neural network and data fusion*” (Gao, 2013), proponen un sistema de detección de fugas de gas natural para el oleoducto de gas natural de la ciudad de Daqing en China, mediante la combinación de diferentes herramientas para análisis de información proveniente de ondas acústicas y presión. Para el preprocesamiento de la señal se usa la transformada Wavelet, específicamente para determinar una función de threshold suave, que sirve como entrada a una red neuronal diseñada

mediante función de base radial combinada con un método de interpolación multivariable, de 3 capas: 8 -4-1. Si se detecta una fuga, se utiliza esa señal como entrada de *data fusión*, la cual mediante *D-S evidence theory* permite el proceso de información de diferentes fuentes, lo que conlleva a una localización de la fuga.

Una de las herramientas que indiscutiblemente es ampliamente utilizada en el diseño de sistemas de control es el software Labview. Zhan Jiaqi, en "*Research on LABVIEW system of fire detection based on BP neural network*" (Jiaqi, 2012), realiza una detección de incendios usando detectores térmicos analógicos para tomar mediciones, mientras que con redes neuronales de retropropagación programadas directamente en lenguaje de programación G (gráfico). El tipo de red neuronal utilizada para este proyecto –retropropagación–, se eligió para modificar los pesos los pesos y los umbrales. Dicha configuración de red neuronal permite recalcular el error a través de la conexión original para corregir los pesos de la conexión y los umbrales de las neuronas de modo que es posible reducir el gap entre el resultado de la red y el valor objetivo. Si bien éste proyecto parece estar fuera de contexto, lo que resalta de él, es la posibilidad de desarrollar completamente en lenguaje propio de labview un algoritmo de red neuronal.

Dae-Sik Lee habla sobre la detección de fugas de gases orgánicos pero utilizando sensores químicos en su trabajo titulado "*SnO<sub>2</sub> gas sensing array for combustible and explosive gas leakage recognition*" (Lee, 2002). El sistema es lo que se conoce como "electronic nose system", que podría ser interpretado como sistema electrónico de olores; este utiliza una red neuronal multicapas con algoritmos de retropropagación como algoritmo de aprendizaje y un sistema neurodifuso para la cuantificación del gas. La importancia de éste trabajo se basa en los distintos gases que puede clasificar en la misma red neuronal: metano, propano, butano, gas licuado de petróleo y monóxido de carbono, todos ellos evaluando la concentración del gas en el ambiente, que específicamente para el caso del metano, nos aporta su límite inferior de explosividad que es 5.3vol%.



Para esta clasificación se hizo uso del análisis por componente principal (PCA), la cual permite mapear los datos de forma multidimensional, mediante el traslado de los datos de 2 a 3 ejes. Si bien la aportación del trabajo es considerable, hay que enfatizar que al tratarse de sensores electroquímicos, éstos tardan de 3 a 5 segundos en saturarse y comenzar a tener una medición fiable, mientras que la purga de sus sensores del gas toma 30 [s], tiempos que para un sistema que vigila un área considerable no resultan ideales, además de que los sensores electroquímicos se degradan, por lo que su lectura debe ser ajustada con cierta constancia y éstos deben ser repuestos con cierta regularidad.

Santos en *“Real-time monitoring of gas pipeline through artificial neural network”* (Santos, 2013), se enfoca a la detección de fugas en tuberías, mediante el análisis de ondas acústicas, partiendo del supuesto de que cualquier perturbación de la tubería se vería reflejada en las ondas acústicas, afectando su velocidad y amplitud de la onda. Haciendo uso de micrófonos, se realiza una descomposición de las señales en frecuencias de 1k, 5k y 9k, las cuales funcionan como entradas de la red neuronal, las cuales en principio trabajan con dos modelos, el primero de 47060 y el segundo de 47203 datos, para terminar siendo una red de configuración 12X12X1.

Akihiro Sibata en *“Neuro based clasification of gas leakage sounds in pipelines”* (Shibata, 2009), utiliza también una red neuronal como clasificador de los sonidos durante una fuga de gas. Al igual que Santos (Santos, 2013), utiliza micrófonos y sonómetros; los sonidos emanados de las fugas simuladas son analizados mediante la transformada rápida de Fourier (FFT) para obtener un espectro de potencia logarítmica que sea clasificado por la red neuronal. Dentro de su trabajo, se hace uso de la función de activación Sigmoid, además de minimizar el error mediante algoritmos de retropropagación.

*“The application of fuzzy-neural network algorithm on the estimation of inflammable gas concentration”* (Yea, 1997), busca la estimación de la concentración de gases inflamables (hidrógeno, butano y metano), mediante un sistema de análisis neuro difuso. Utilizando sensores de gas semiconductores, cuya composición fue  $SnO_2$  (dióxido de estaño) y ZnO (óxido de zinc), se utilizan los valores de las concentraciones para llevarlos al dominio de la frecuencia mediante la transformada rápida de Fourier, lo anterior se debe a que el análisis de los patrones en DC concentración-estimación, presentan una alta inferencia a cualquier variación de la concentración del gas cuantificado. Las muestras realizadas del gas fueron 200, 400, 600, 800 y 1000ppm. Como algoritmo de aprendizaje para la red neuronal se utilizaron algoritmos de retropropagación, los cuales, aunados a un sistema de inferencia difuso, probaron arrojar lecturas más estables y precisas que las obtenidas en un sistema previo realizado únicamente con inferencia difusa.

*“Probabilistic multiple model neural network based leak detection system: Experimental study”* (Abdulla, 2015), es un estudio experimental enfocado a la detección de fugas de líquidos en ductos, donde las variables son la presión de entrada, presión de salida y flujo de salida. El procesamiento de información se compone de dos tareas, una técnica de clustering KNN (K-nearest-Neighbor) y redes neuronales. El primer paso fue un análisis estadístico básico: media, rango y varianza de las mediciones, así como establecer un criterio de confianza de 95%, los cuales funcionaban como entradas a la red neuronal, cuya salida resulta en dos estados para la neurona: fuga/no fuga, dependiendo de cuál fuera el valor de éstas se determinaba la respuesta; aunque existía el caso en que las respuestas de ambas neuronas fueran iguales, por lo que podría haber una respuesta no concluyente. Las funciones que las redes neuronales utilizaron fueron la función logística y función tangencial hiperbólica con un kernel gaussiano, donde el modelo posee 11 capas ocultas, cuyo fin es predecir un valor de varianza. El

resultado final es un sistema con inmunidad al ruido cuya validación arrojó una reducción del error de 6.06% a 0%.

La comparación de sistemas de modelado tradicionales para la detección de fugas, frente a sistemas basados en redes neuronales (Matko, 2006) se ha realizado desde hace algunos años, demostrando un mejor desempeño frente a comportamientos no lineales propios de las tuberías, dichos comportamientos pueden y deben ser considerados en la dinámica del sistema dentro de la metodología que se va a llevar a cabo como parte del presente trabajo.

En el artículo *“Leakage detection of natural gas pipeline based on neural networks and data fusión”* (Gao, 2013), realiza una fusión de métodos para la detección de fugas. Analiza las ondas de sonido y las ondas producidas por una baja de presión en el sistema mediante la transformada de Fourier para después usar una red neuronal que determina si existe o no una fuga. Cabe destacar que en el artículo se especifica que entre más entrenada estén los datos de la red más precisa será esta, sin embargo, también de haber demasiados datos durante el muestreo, será más tardado el entrenamiento de la red neuronal. Es entonces necesario considerar que si bien la cantidad de los datos es importante, también lo es la calidad de los mismos, pues con ello se podría reducir la base de datos y así agilizar el proceso de análisis.

Algunos de los métodos de análisis de fugas tradicionales, son modelos matemáticos que utilizan herramientas para modelar fenómenos no lineales, tales como la expansión de la función de transferencia trascendental en series de Taylor, los cuales pueden ser realizados por una red neuronal lineal en una o varias capas (Matko, 2006). Es importante recalcar que éste método sólo fue utilizado como método de corrección únicamente para la simulación de la tubería mediante el software PIPESIM. Su aportación es eliminar la polarización propia del sensor además de algunos efectos no lineales que no pueden ser modelados con

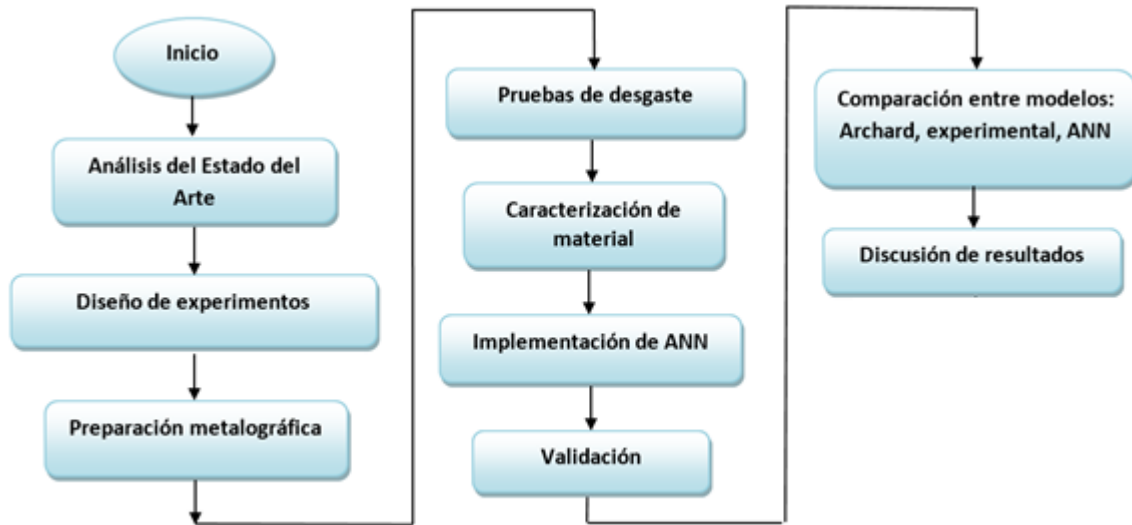
PIPESIM. De igual forma, dentro de la metodología a desarrollar se debe contemplar la posibilidad de realizar un híbrido con un sistema comercial con el fin de complementar, resarcir las debilidades para generar un producto que aporte una solución más viable a la detección de fugas.

Los sistemas de detección de anomalías ligados a variables físicas como el gas, se sustentan en la densidad de gas hidrocarburo, la concentración de este, temperatura ambiental, etc. Para ello se usan técnicas como algoritmos de retropropagación en redes neuronales para el entrenamiento de la red, la principal aportación de la retropropagación es ajustar el valor de los pesos de la red neuronal y los umbrales de disparo (Jiaqi, 2012).

### 3. DESARROLLO EXPERIMENTAL

#### 3.1 Metodología

La metodología desarrollada se muestra en el diagrama de flujo de la Figura 10.



**Figura 10.** Diagrama de flujo de la metodología.

1. Análisis del Estado del Arte. Se realiza una búsqueda referente a los modelos clásicos de desgaste y sus variantes, así como algunos estudios relacionados a las aplicaciones de las Redes Neuronales en problemas de desgaste.
2. Se planea un diseño de experimentos donde se definen los factores y sus respectivos niveles.
3. La preparación metalográfica consta del corte del material, pulido hasta el acabado espejo, limpieza y adecuación de las muestras para montaje en el tribómetro.
4. Pruebas de desgaste. Se realizaron un total de 11 corridas por cada material, 8 pertenecientes a un diseño de experimentos  $2^3$  y con 3 puntos centrales. Se utilizó agua desionizada como lubricante.

5. La caracterización del material se refiere a la medición de la huella de desgaste, así como el cálculo del volumen perdido, el coeficiente de fricción promedio, dureza, entre otros.
6. La implementación de la Red Neuronal Artificial se contempla mediante la Función de Base Radial.
7. La validación de la red neuronal se hará mediante un segundo tratamiento respetando las mismas características.
8. Finalmente se realizará una comparación entre el modelo experimental, de Archard y el desarrollado por la Función de base Radial Propuesta.

De la metodología descrita, se desprenden algunas tareas particulares que se señalan a continuación:

#### Preparación metalográfica:

- Rectificado de la barra de metal.
- Corte de muestras de acero.
- Preparación metalográfica: desbaste, pulido y limpieza ultrasónica.
- Pruebas de desgaste pin-on-disk.

#### Caracterización:

- Medición de la huella de desgaste.
- Cálculo del volumen perdido.
- Cálculo de la masa perdida.
- Cálculo de la tasa de desgaste.
- Cálculo del factor de desgaste.

#### Implementación de Red Neuronal:

- Cálculo de los centros.
- Estimación de los pesos.

- Estimación de la respuesta estimada.
- Cálculo del ANOVA.
- Comparación y discusión de resultados.

### **3.2 Diseño de experimentos**

El diseño de experimentos (DOE, por sus siglas en inglés) tiene como objetivo determinar qué variables de entrada del sistema tienen una mayor influencia sobre la respuesta. El DOE permite determinar cuál es la variable de entrada que tiene mayor influencia para que la salida se encuentre en el valor nominal deseado, así mismo, permite determinar el o los ajustes adecuados para la variable de mayor influencia en la variabilidad de la respuesta (Montgomery, 1991).

El DOE deberá contemplar tres factores: velocidad (A), carga (B) y distancia (C), cada uno con dos niveles propuestos (alto y bajo). Lo anterior se refiere a que se seleccionaran tres velocidades, tres cargas y 3 distancias diferentes. Entonces el diseño factorial será un  $2^3$ , lo que requerirá 8 combinaciones de tratamientos por cada réplica.

**Tabla 1.** Diseño de experimentos

Condición	FACTORES		
	Velocidad[RPM]	Distancia [m]	Carga [N]
1	50	100	2
2	150	100	2
3	50	1000	2
4	150	1000	2
5	50	100	10
6	150	100	10
7	50	1000	10
8	150	1000	10
9	100	550	6
10	100	550	6
11	100	550	6

### 3.3 Preparación metalográfica

Se utilizó una barra redonda de acero 316L, de 50 cm de longitud y 1 in de espesor como se muestra en la Figura 11. La barra descrita, fue sometida a un procedimiento de preparación metalográfica para pruebas de desgaste en un tribómetro.



**Figura 11.** Barra de acero 316L

El primer paso, es segmentar la barra en piezas que sea posible someter a un proceso de desbaste, para utilizarlas en un tribómetro. La cortadora utilizada para segmentar la barra de acero cuenta con un disco de carburo de silicio cuyo espesor es de 2 mm. El montaje realizado se aprecia en la Figura 12.






**Figura 12.** Barra de metal posicionada para el corte

Una vez hecho el corte, quedan piezas de aproximadamente 8 mm de espesor, las cuales son sometidas a un proceso de desbaste (Figura 13) con lijas 120, 240, 360, 400, 600, y 1200. Cada vez que se tiene una superficie completamente homogénea, en un solo sentido correspondiente el giro de la lija, así como carente de rayas transversales o de caras que muestren una superficie no paralela, se pasa a una siguiente lija, tomando precaución de girar la muestra en un ángulo de 90° con la orientación de las rayas dejadas por la lija previa. La finalidad de lo anterior es eliminar rayas cuya profundidad pueda afectar las pruebas en el tribómetro o la microestructura.



**Figura 13.** Proceso de desbaste

Considerando que hasta este punto la pieza una superficie uniforme y paralela entre ambas caras, se pule mediante un paño de 1  $\mu\text{m}$  con pasta de diamante de 0.3  $\mu\text{m}$ , lo que concluye en darle acabado espejo (Figura 14).



**Figura 14.** Muestra terminada con acabado espejo

Una vez terminada la fase de desbaste y pulido, se requiere una etapa de limpieza, la cuál puede ser física o química. La limpieza física de las muestras elimina suciedad sólida y grasas, mientras que una limpieza química elimina contaminantes. Se utilizó una limpieza física únicamente con una solución de agua jabonosa. El siguiente proceso fue la limpieza ultrasónica, que es en la actualidad uno de los métodos más eficientes de limpieza (Vander Voort, 1984). Esta produce fluctuaciones en la presión hidrostática cuando una onda acústica intermitente es transmitida en un medio líquido. La tina de limpieza se llena de agua destilada hasta el nivel indicado por el mismo equipo, mientras que en un vaso de precipitado -previamente aseado y seco, sin rastros de jabón o cualquier otra partícula- donde se colocan las muestras pulidas en el fondo para después llenar el vaso con alcohol por encima del nivel donde se observa el agua destilada. El tiempo de limpieza ultrasónica se configuró en 20 minutos (Figura 15).




**Figura 15.** Limpieza ultrasónica de las muestras

Es importante destacar que una vez que se ha terminado la limpieza ultrasónica, se deben tomar las muestras cuidadosamente por los cantos, preferentemente con guantes para evitar contaminar la superficie, en su defecto utilizando la mano completamente limpia.

### 3.4 Pruebas de desgaste

Se utilizó un tribómetro Anton Paar para realizar pruebas de desgaste en las muestras preparadas. El pin utilizado fue de Zafiro; el ensamble del tribómetro requerido para realizar pruebas de pin-on-disk lubricadas se aprecia en la Figura 16. Algunas consideraciones especiales a notar para las pruebas lubricadas son:

- Se utilizó una calza de baquelita de 3.5 mm aproximadamente para ajustar la muestra con la base.
- Se utilizó agua desionizada como lubricante cuya pureza es  $<10\mu\text{S/ml}$
- La cantidad de lubricante osciló entre 40 y 50 ml, dependiendo del espesor de la muestra en cuestión.
- Se colocó una tapa blanda con el fin de no derramar lubricante



**Figura 16.** Pin-on-disk configurado para pruebas lubricadas

Los procedimientos descritos durante la prueba de pin-on-disk se hicieron con estricto apego a la norma G99 de la (ASTM, 2010).

### 3.5 Propiedades del Acero 316L


La composición química del acero inoxidable 316L en % en peso (Köse, 2016):

**Tabla 2.** Composición química del acero 316L % e.p.

<b>C</b>	<b>Si</b>	<b>Mn</b>	<b>P</b>	<b>S</b>	<b>Cr</b>	<b>Mo</b>	<b>Ni</b>	<b>Al</b>	<b>Co</b>
0.013	0.528	1.859	0.052	0.0010	16.94	2.065	9.336	0.0020	0.267
<b>Cu</b>	<b>Nb</b>	<b>Ti</b>	<b>V</b>	<b>W</b>	<b>Pb</b>	<b>Sn</b>	<b>Zn</b>	<b>N</b>	<b>Fe</b>
0.248	0.0338	0.014	0.086	0.099	0.0010	0.026	0.027	0.026	68.36


### 3.6 Dureza

Mediante un equipo de medición de dureza Wilson modelo Tukon 2500, se analizó la dureza Vickers del acero 316L con una carga de 0.5 gr (Figura 17):



**Figura 17.** Prueba de dureza Vickers

El resultado del reporte de la prueba Vickers se aprecia en la Figura 18.



**Figura 18.** Resultado del test de dureza

La equivalencia entre la dureza Vickers y la dureza Rockwell C se aprecia en la Tabla 3.

**Tabla 3.** Dureza Vickers y equivalencia en Rockwell C

Punto	Distancia	Dureza Vickers	Dureza GPa
1	0.000	257 HV 0.5	2.52 [GPa]
2	0.100	241 HV 0.5	2.363 [GPa]
3	0.200	262 HV 0.5	2.569 [GPa]
4	0.300	251 HV 0.5	2.462 [GPa]
5	0.400	239 HV 0.5	2.344 [GPa]


## 4. RESULTADOS

Se evaluaron dos materiales para el pin de desgaste utilizado durante la prueba pin-on-disk: zafiro y alúmina. Los resultados que a continuación se muestran se subdividen en dos secciones acorde a los diferentes materiales utilizados.

### 4.1 ACERO INOXIDABLE 304


#### 4.1.1 Huella de desgaste

La huella de desgaste dejada por el pin durante la prueba de desgaste resulta irregular considerando los cambios en los mecanismos de desgaste presentes durante la prueba hasta que ésta alcanza el estado tribológico estable. Para conocer el ancho de la huella, se realizaron mediciones: 3 tomas cada 30°, de modo que se obtuvieron un total de 36 mediciones del ancho de la huella en cada una de las muestras.




**Figura 19.** Ancho de la huella de la condición 1 a 30° (a) y 60° (b).







**Figura 20.** Ancho de la huella de la condición 2 a 60° (a) y 330° (b).




**Figura 21.** Ancho de la huella de la condición 3 a 210° (a) y 270° (b).



**Figura 22.** Ancho de la huella de la condición 4 a 30° (a) y 270° (b).




**Figura 23.** Ancho de la huella de la condición 5 a 30° (a) y 240° (b).




**Figura 24.** Ancho de la huella de la condición 6 a 120° (a) y 330° (b).







**Figura 25.** Ancho de la huella de la condición 7 a 90° (a) y 270° (b).




**Figura 26.** Ancho de la huella de la condición 8 a 0° (a) y 330° (b).



**Figura 27.** Ancho de la huella de la condición 9 a 0° (a) y 240° (b).



**Figura 28.** Ancho de la huella de la condición 10 a 30° (a) y 180° (b).



**Figura 29.** Ancho de la huella de la condición 11 a 30° (a) y 270° (b).

Las figuras muestran el ancho de la huella en 3 sitios, en dos ángulos diferentes. Siendo la misma muestra y con el mismo acercamiento, se aprecia que la huella tiene un ancho diferente, lo que nos indica que el desgaste no fue uniforme hablando en términos del área desgastada.

El resultado se promedia para conocer una aproximación del ancho de la huella en toda la muestra. Se obtiene la desviación estándar para estimar un rango de tolerancia de dicho ancho.



**Tabla 4.** Ancho de la huella de desgaste

°	1	2	3	4	5	6	7	8	9	10	11
0°	236.76	169.74	315.7	116.51	275.34	281.6	476.73	803.83	355.14	466.3	326.18
	236.76	169.21	108.93	117.96	290.47	284.73	476.73	755.81	362.44	474.61	365.89
	236.33	163.42	309.9	117	282.64	285.25	479.87	734.28	360.88	477.86	346.07
30°	261.27	164.01	318.12	139.24	284.73	292.55	515.49	683.29	354.61	434.91	340.81
	261.8	164.38	316.21	144.99	287.86	294.64	539.59	674.95	352	462.07	346.03
	261.78	157.61	319.08	141.84	290.99	307.15	537.5	683.28	352	430.71	341.85
60°	169.69	156.64	342.1	296.2	267.52	297.78	550.11	593.7	345.22	301.08	334.69
	170.18	155.67	341.08	330.11	271.69	298.29	556.36	612.45	343.66	321.98	323.03
	170.19	155.22	339.78	317.11	267.01	302.98	555.34	608.29	341.05	338.79	335.61
90°	180.33	163.9	333.59	383.01	270.74	284.21	550.92	610.37	341.05	329.31	372.17
	190	165.84	334.55	392.14	272.19	293.03	551.97	616.62	341.57	332.44	404.57
	182.75	164.86	338.93	381.93	266.87	302.46	550.96	622.87	342.62	331.42	392.04
120°	195.56	157.61	337.94	458.42	281.08	300.9	530.02	693.69	328.55	367.98	232.09
	195.57	160.03	336.49	471.03	272.74	290.99	527.93	739.53	320.72	377.39	387.86
	194.53	159.54	335.52	411	275.34	299.85	526.9	772.85	313.43	373.21	245.68
150°	192.42	164.88	349.54	428.54	280.56	292.03	516.43	554.12	320.2	394.14	216.44
	193.39	167.76	344.23	425.39	275.34	297.25	520.62	616.62	329.08	322.31	239.42
	194.84	167.33	345.67	333.2	267	293.08	518.52	583.29	333.24	378.44	250.9
180°	178.94	159.06	354.09	320.94	268.04	302.46	503.89	562.45	328.03	314.69	213.27
	180.81	161.48	337.92	353.34	275.34	292.03	500.76	643.71	325.41	306.35	264.49
	180.48	158.09	342.09	285.39	269.61	294.64	501.79	614.53	323.32	312.57	250.9
210°	180.33	165.83	378.6	346.96	279.52	291.51	480.92	566.62	329.58	292.71	221.78
	199.67	168.25	384.86	246.17	281.08	291.51	481.97	549.96	331.66	308.39	296.89
	177.43	164.86	384.86	316.93	281.6	289.43	481.97	612.45	327.5	386.82	285.39
240°	196.29	158.57	386.94	249.09	268.04	286.29	485.07	608.29	327.5	421.31	310.5
	197.73	162.93	386.42	259.74	256.05	288.9	474.62	535.37	331.66	424.44	315.73
	197.26	158.09	383.81	259.74	256.05	286.3	480.88	491.63	323.33	431.75	312.58
270°	192.44	162.44	387.46	168.25	262.88	289.94	458.93	545.79	333.75	353.36	315.79
	192.42	160.99	390.59	163.41	267	298.29	440.12	622.87	335.84	367.98	315.73
	183.24	157.13	386.94	169.23	265.96	292.55	445.34	572.87	336.88	369.03	313.62
300°	187.58	162.44	391.11	122.32	274.83	302.98	451.61	766.62	331.68	397.26	341.87
	193.87	166.79	391.64	92.35	262.83	299.34	446.38	752.03	339.49	403.56	340.9
	193.38	162.56	389.03	109.27	268.04	296.73	451.61	702.03	329.07	396.21	357.53
330°	201.12	159.12	391.63	144.25	253.44	288.9	445.34	639.54	347.32	481.95	410.18
	216.59	159.54	391.11	144.25	251.88	285.25	454.75	689.53	341.06	485.07	379.55

	216.11	157.62	390.07	139.09	250.32	292.04	467.29	766.61	337.93	456.85	426.58
Prom	199.71	162.04	350.45	258.23	271.46	293.55	498.20	644.52	336.62	373.92	318.73
Σ	25.284	4.064	49.906	118.20	10.37	6.293	37.362	79.293	11.789	32.401	57.560

#### 4.1.2 Cálculo del desgaste

De acuerdo con la norma G99-05 de la ASTM se obtiene el volumen perdido en la muestra (ASTM, 2010) y la velocidad de desgaste mediante las siguientes ecuaciones:

$$\text{Volumen perdido, [mm}^3] = \frac{\pi(\text{radio de la huella, mm})(\text{ancho de huella, mm})^2}{6(\text{radio de la esfera, mm})} \quad \text{Ec. 36}$$

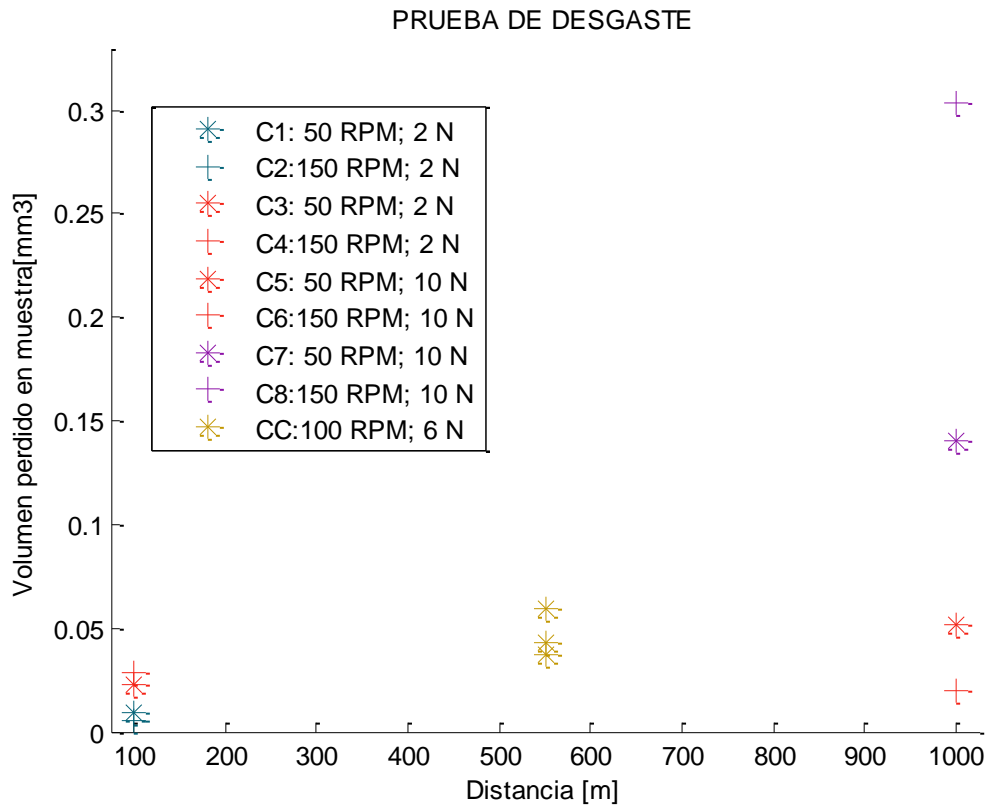
$$\text{Velocidad de desgaste, [mm}^3/\text{Nm}] = \frac{\text{Volumen perdido, mm}^3}{(\text{Carga, N})(\text{Distancia, m})} \quad \text{Ec. 37}$$

**Tabla 5.** Volumen perdido y velocidad de desgaste de la muestra

Cond.	Ancho promedio de la huella (mm)		Volumen perdido en muestra (mm <sup>3</sup> )	Velocidad de desgaste (mm <sup>3</sup> /Nm)	Coefficiente de Fricción promedio (μk)
1	0.199717778	± 0.0252816	0.009037346	4.51867E-05	0.637468755
2	0.16204	± 0.0040678	0.004826779	2.41339E-05	0.549038589
3	0.356014722	± 0.0290069	0.051191116	2.55956E-05	0.699147403
4	0.258231667	± 0.1182022	0.019535261	9.76763E-06	0.249556839
5	0.271461667	± 0.0103728	0.022694272	2.26943E-05	0.470560938
6	0.293551667	± 0.0062934	0.028697521	2.86975E-05	0.475332648
7	0.498200833	± 0.0373624	0.140282686	1.40283E-05	0.51036185
8	0.644520556	± 0.0792933	0.303739338	3.03739E-05	0.28081882
9	0.336624167	± 0.0117891	0.043273956	1.31133E-05	0.548401117
10	0.373925676	± 0.0592196	0.059312549	1.79735E-05	0.273366481
11	0.318739167	± 0.057561	0.036736436	1.11323E-05	0.269694418

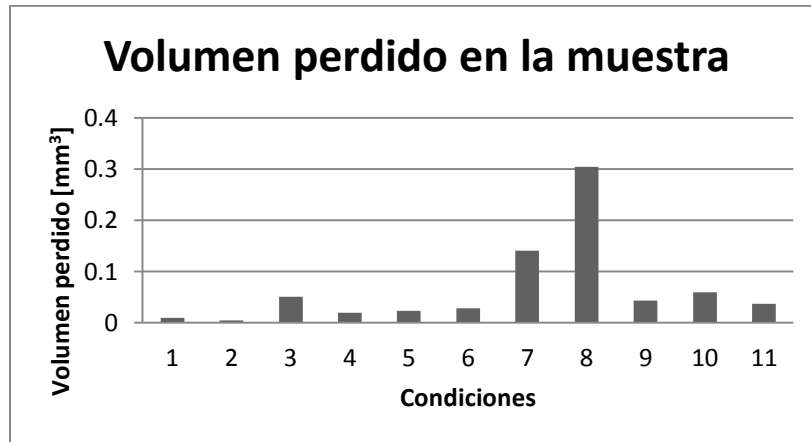
#### 4.1.3 Desgaste de las muestras

El desgaste de las muestras, expresado como el volumen perdido en mm<sup>3</sup> se aprecia en la Figura 30 respecto a la distancia.



**Figura 30.** Volumen perdido de las muestras


Por otro lado, en la Figura 31 se aprecia el volumen perdido en una gráfica de barras a fin de comparar el desgaste entre las pruebas.



**Figura 31.** Gráfica de barras del volumen perdido en las muestras


#### 4.1.4 Microscopio Electrónico de Barrido

Mediante un microscopio electrónico de barrido TESCAN-Mira 3 se obtienen imágenes de las huellas de desgaste donde se aprecia el efecto de los diferentes mecanismos.




**Figura 32.** Condición 1 a 100X (izquierda) y 300X (derecha).

En la Figura 32 se aprecia la huella producto del desgaste a 100X del lado izquierdo, mientras que del lado derecho se encuentra a 300X, donde la medición realizada del ancho concuerda con la medición observada en el microscopio a 330°.




**Figura 33.** Condición 2 a 100X (izquierda) y 300X (derecha).

En la Figura 33 se aprecia la huella de desgaste a 100X del lado izquierdo, mientras que del lado derecho se encuentra a 300X, donde la medición realizada del ancho concuerda con la medición observada en el microscopio a 270°.



**Figura 34.** Condición 3 a 100X (izquierda) y 300X (derecha).


En la Figura 34 se aprecia la huella producto del desgaste a 100X del lado izquierdo, mientras que del lado derecho se encuentra a 300X, donde la medición realizada del ancho concuerda con la medición observada en el microscopio a 330°.



**Figura 35.** Condición 4 a 100X (izquierda) y 300X (derecha).




En la Figura 35 se aprecia la huella de desgaste a 100X del lado izquierdo, mientras que del lado derecho se encuentra a 300X, donde la medición realizada del ancho concuerda con la medición observada en el microscopio a 60°.




**Figura 36.** Condición 5 a 100X (izquierda) y 300X (derecha).

En la Figura 36 se aprecia la huella de desgaste a 100X del lado izquierdo, mientras que del lado derecho se encuentra a 300X, donde la medición realizada del ancho concuerda con la medición observada en el microscopio a 0°.




**Figura 37.** Condición 6 a 100X (izquierda) y 300X (derecha).

En la Figura 37 se aprecia la huella de desgaste a 100X del lado izquierdo, mientras que del lado derecho se encuentra a 300X, donde la medición realizada del ancho concuerda con la medición observada en el microscopio a 0°.




**Figura 38.** Condición 7 a 100X (izquierda) y 300X (derecha).

En la Figura 38 se aprecia la huella de desgaste a 100X del lado izquierdo, mientras que del lado derecho se encuentra a 300X, donde la medición realizada del ancho concuerda con la medición observada en el microscopio a 300°.



**Figura 39.** Condición 8 a 100X (izquierda) y 200X (derecha).

En la Figura 39 se aprecia la huella de desgaste a 100X del lado izquierdo, mientras que del lado derecho se encuentra a 300X, donde la medición realizada del ancho concuerda con la medición observada en el microscopio a 30°.




**Figura 40.** Condición 9 a 100X (izquierda) y 300X (derecha).

En la Figura 40 se aprecia la huella de desgaste a 100X del lado izquierdo, mientras que del lado derecho se encuentra a 300X, donde la medición realizada del ancho concuerda con la medición observada en el microscopio a 120°.


#### **4.1.5 Coeficiente de fricción**

En ésta sección, se muestran los resultados del coeficiente de fricción de cada una de las pruebas. Considerando que de acuerdo a la teoría clásica no influye la velocidad en el desgaste, se toman dos condiciones consecutivas por gráfica. Lo anterior se debe a que las condiciones en cuanto a distancia y carga son iguales.



**Figura 41.** Condiciones 1 y 2 de desgaste


Aunque las condiciones de desgaste 1 y 2 de la Figura 41 son iguales despreciando la velocidad, el coeficiente de fricción de la prueba 2 es menor al igual que la huella de desgaste (Figura 20) en comparación con la huella de la condición 1 (Figura 19).



**Figura 42.** Condiciones 3 y 4 de desgaste




En lo que respecta a la Figura 42 se observa el cambio abrupto en el coeficiente de fricción por parte de la condición 4, cuyo coeficiente es mucho menor que su contraparte, la condición 3. Se observa que el ancho de la huella de desgaste es menor en la condición 4 (Figura 22) respecto a la 3 (Figura 21).




**Figura 43.** Condiciones 5 y 6 de desgaste

En lo que respecta a las condiciones 5 y 6 de desgaste apreciadas en la Figura 43, se aprecia que el coeficiente de fricción es muy similar, de la misma manera la huella de desgaste tiene dimensiones equivalentes como se aprecia en la Figura 23 y Figura 24.



**Figura 44.** Condiciones 7 y 8 de desgaste

Las condiciones 7 y 8 mostradas en la Figura 44 muestran un coeficiente de fricción menor de parte de la condición 8, aunque contrario a la comparación hecha en las 4 primeras corridas, la huella de desgaste es más ancha de acuerdo a la Figura 26.



**Figura 45.** Condiciones 9, 10 y 11 de desgaste

Finalmente, el coeficiente de fricción de las condiciones centrales apreciadas en la Figura 45 muestra la variabilidad del proceso. Considerando que en estos puntos todas las condiciones son exactamente iguales, tenemos un coeficiente de fricción más alto por parte de la condición 9 al igual que mientras que las condiciones 10 y 11 tienen una similitud acorde a lo esperado en su coeficiente de fricción. Sin embargo, el ancho de las huellas resulta uniforme únicamente entre las huellas de las condiciones 9 y 11, mientras que la huella de la condición 10 resultó con un ancho en la huella promediado de acuerdo a la Tabla 4.

#### **4.1.6 Implementación de Red Neuronal**

En la presente sección se hará uso de la Función de Base Radial descrita en la sección 2.3.3.

##### **4.1.6.1 Pre-tratamiento de datos**

Uno de los pre-tratamientos que se les da a los datos, es el escalamiento de las variables de entrada. Lo anterior se debe a la dificultad que presenta el comparar de forma directa las diferentes magnitudes que están intrínsecas en cada una de las variables a utilizar, por lo que es recomendable trabajar con coeficientes adimensionales.

El escalamiento normal unitario es un método de normalización de coeficientes consistente en:

$$x_{ij} = \frac{x_{ij} - \bar{\mu}_j}{s_j} \quad \text{Ec. 39}$$

Donde  $\mu_j$  es la media de la variable y  $s_j$  la desviación estándar o en ocasiones el rango.

Los datos de entrada  $x$  que corresponden a los parámetros de entrada, y la respuesta experimental  $y$  que es el volumen perdido en milímetros cúbicos se presentan en un arreglo matricial a continuación:

$$x = \begin{bmatrix} 50 & 100 & 2 \\ 150 & 100 & 2 \\ 50 & 1000 & 2 \\ 150 & 1000 & 2 \\ 50 & 100 & 10 \\ 150 & 100 & 10 \\ 50 & 1000 & 10 \\ 150 & 100 & 10 \\ 100 & 550 & 6 \\ 100 & 550 & 6 \\ 100 & 550 & 6 \end{bmatrix}; \quad y = \begin{bmatrix} 0.0048 \\ 0.0025 \\ 0.0275 \\ 0.0105 \\ 0.0122 \\ 0.0154 \\ 0.0755 \\ 0.1635 \\ 0.0233 \\ 0.0319 \\ 0.0197 \end{bmatrix}$$

#### 4.1.6.2 Cálculo de los Centros

Mediante el uso de un algoritmo genético (GA), se realiza el cálculo de los centros de acuerdo a la función objetivo.

$$R^2 = 1 - \frac{z'z - w'Gtz}{z'z - (\sum_{i=1}^n z_i)^2 / n} \quad \text{Ec. 40}$$

Con los datos, se utiliza el toolbox de Matlab la cual toma los datos de entrada para generar centros de forma aleatoria que utiliza para el cálculo de las distancias de Mahalanobis.

$$d_m(\vec{x}, \vec{y}) = \sqrt{(\vec{x} - \vec{y})^T \Sigma^{-1} (\vec{x} - \vec{y})} \quad \text{Ec. 41}$$

Dichas distancias serán evaluadas mediante la función radial:

$$G(i, j) = \exp(-\|d_m\|^2) \quad \text{Ec. 42}$$



El programa genera una matriz de interpolación, añadiendo una primera columna de unos que representa el bias. Con dicha matriz, se calcula el valor de los pesos mediante:

$$w = (G^T G)^{-1} G^T y \quad \text{Ec. 43}$$

Finalmente se obtiene la estimación de  $y$ :

$$\hat{y} = Gw \quad \text{Ec. 44}$$

Usualmente, se considera como adecuado un modelo cuya  $R^2$  sea mayor a 0.70.

El valor óptimo generado por el GA cuya  $R^2$  elegida fue la más alta, corresponde a  $R^2 = 0.8111$  donde finalmente la matriz de centros está dada por:

$$c = \begin{bmatrix} 94.6195 & 141.1287 & 5.9477 \\ 96.6198 & 373.5042 & 3.8515 \\ 101.028 & 618.7335 & 2.1191 \end{bmatrix}$$

#### 4.1.6.3 Cálculo de la distancia de Mahalanobis

Una vez obtenidos los centros, se realiza el cálculo de la distancia euclidiana, entre la entrada del vector y el centro del nodo.

$$d_{i,j} = (x_{i,j} - c_{i,j})^2 + (x_{i,j+1} - c_{i,j+1})^2 \quad \text{Ec. 45}$$

#### 4..1.6.4 Función de Base Radial Gaussiana

Se aplica la función gaussiana a la distancia previamente calculada, lo que resulta en:

$$G_{i,j} = \exp\left(-\left(x_{i,j} - c_{i,j}\right)^2 + \left(x_{i,j+1} - c_{i,j+1}\right)^2\right) \quad \text{Ec. 46}$$

El resultado de estos cálculos se aprecia en la matriz de interpolación:

$$G = \begin{bmatrix} 1.8128 & 0.6912 & 1.6092 \\ 0.8329 & 0.5988 & 2.0087 \\ 11.7708 & 4.4641 & 1.2912 \\ 8.6933 & 3.1320 & 0.7760 \\ 0.6210 & 3.5177 & 9.6597 \\ 1.3688 & 0.6695 & 1.6582 \\ 4.8553 & 3.5743 & 4.3568 \\ 6.8029 & 6.6714 & 8.3033 \\ 0.0592 & -0.1750 & 0.3140 \\ 0.0592 & -0.1750 & 0.3140 \\ 10.0592 & -0.1750 & 0.3140 \end{bmatrix}$$

#### 4.1.6.5 Cálculo de los pesos

La matriz de pesos es calculada mediante la ecuación matricial

$$w = (G'G)^{-1}G'y \quad \text{Ec. 47}$$

El resultado es entonces

$$w = \begin{bmatrix} 0.0960 \\ -0.0682 \\ 0.1888 \\ -0.0710 \end{bmatrix}$$

#### 4.1.6.6 Cálculo de la predicción

La  $\hat{y}$  es la predicción que se calcula mediante  $\hat{y} = g * w$ , donde  $g$  es la matriz de interpolación y  $w$  es la matriz de pesos.

$$\hat{y} = \begin{bmatrix} -0.0034 \\ 0.0088 \\ 0.0212 \\ 0.0214 \\ 0.0147 \\ 0.0097 \\ 0.0718 \\ 0.1635 \\ 0.0261 \\ 0.0261 \\ 0.0261 \end{bmatrix}$$

El resultado de la predicción contra su objetivo se aprecia en la Figura 45.




Figura 46. Gráfica de predicción contra objetivo

El error de la predicción:

$$error = y - \hat{y}$$

Ec. 48

$$error = \begin{bmatrix} 0.0082 \\ -0.0062 \\ 0.0051 \\ -0.0109 \\ -0.0025 \\ 0.0058 \\ 0.0037 \\ 0.0000 \\ -0.0028 \\ 0.0058 \\ -0.0063 \end{bmatrix}$$

#### 4.1.6.7 Supuestos Estadísticos

Como se mencionó en la sección 2.3.3, el primer paso para evaluar los resultados de la red neuronal rediseñada es que se cumplan 3 supuestos:

- i) La Distribución de los residuales deben ser normales  $\varepsilon = N(0, \sigma^2)$   
Mediante la prueba Anderson-Darling podemos determinar si los datos tienen una distribución normal.

$$H_0: \text{Si } AD > V_c \text{ los datos siguen una distribución normal}$$
$$H_a: \text{Si } AD < V_c \text{ los datos no siguen una distribución normal}$$

El valor de la prueba Anderson-Darling obtenido resulta  $AD=0.196$

El valor Crítico contra el que se compara el resultado de Anderson-Darling está definido por:

$$V_c = \frac{0.752}{1 + \frac{0.75}{n} + \frac{225}{n^2}} =$$

El resultado de la comparación entre los valores determina que  $H_0$  se acepta, por lo que la muestra sigue una distribución normal.

$$V_c < AD$$

- ii) Las varianzas del residual  $\epsilon$  deben ser de varianzas iguales.

$H_0$ : Si  $w > w_{tablas}$  varianzas no homogéneas

$H_a$ : Si  $w < w_{tablas}$  varianzas homogéneas

Si el estadístico calculado es mayor que el valor de tablas, entonces la hipótesis se rechaza.

El valor  $w$  es igual a el número de los regresores menos uno, mientras que la  $w$  de tablas se distribuye como una  $\chi^2$ .

Lo anterior permite aceptar la hipótesis planteada, donde sí existe homogeneidad en las varianzas.

- iii) Residuales no deben estar correlacionados

La prueba Durbin-Watson se utiliza para saber si los errores se encuentran correlacionados.

$H_0$ : datos independientes

$H_a$ : datos no independientes o prueba inconclusa

Si  $d < d_L$  se rechaza  $H_0$ , si  $d > d_u$  no se rechaza  $H_0$ , si  $d_L < d < d_u$  la prueba es inconclusa.

#### 4.1.6.8 Análisis de Varianza

El ANOVA se refiere a la descomposición de la variabilidad total en sus partes componentes de origen (Montgomery, 1991) y se aprecia en la Tabla 6.

**Tabla 6. ANOVA aplicado al proceso de desgaste**

Fuente de variación	Grados de libertad	Suma de Cuadrados	Cuadrados Medios	F	P
Modelo	3	0.0747	0.0249	126.4351	0.0000
Residual	7	0.0014	1.9695E-04		
Total	10	0.0761			

El valor  $p$  de la Tabla 6 indica - cuando es menor a 0.05 – que el modelo generado es adecuado para determinar la significancia estadística de las relaciones entre variables (Praga-Alejo, 2013). El error estándar de los pesos se muestra en la Tabla 7.

**Tabla 7. Error estándar de los pesos (Standard error)**

Se( $w_1$ )	0.0095
Se( $w_2$ )	0.0053
Se( $w_3$ )	0.0129
Se( $w_4$ )	0.0060

El estadístico  $T_0$  es conocido como la *t-student*, indica que el factor en cuestión tiene efecto sobre la respuesta. Los estadísticos se aprecian en la Tabla 8. El resultado indica que el valor  $p$  de  $T_0$  es menor a 0.05, por lo que se acepta la hipótesis que afirma que la velocidad sí tiene, estadísticamente, un efecto sobre la

respuesta; del mismo modo es posible comprobar que todos los factores tienen efecto sobre la respuesta.

**Tabla 8.** Prueba de significancia de las variables

	Valor $p$ de $T_0$	
$T_0(w_1)$	11.6253	0.0000
$T_0(w_2)$	-13.7282	0.0000
$T_0(w_3)$	15.2639	0.0000
$T_0(w_4)$	-12.5839	0.0000

Los intervalos de confianza obtenidos para los pesos se observan en la Tabla 9

**Tabla 9.** Intervalo de confianza de los pesos

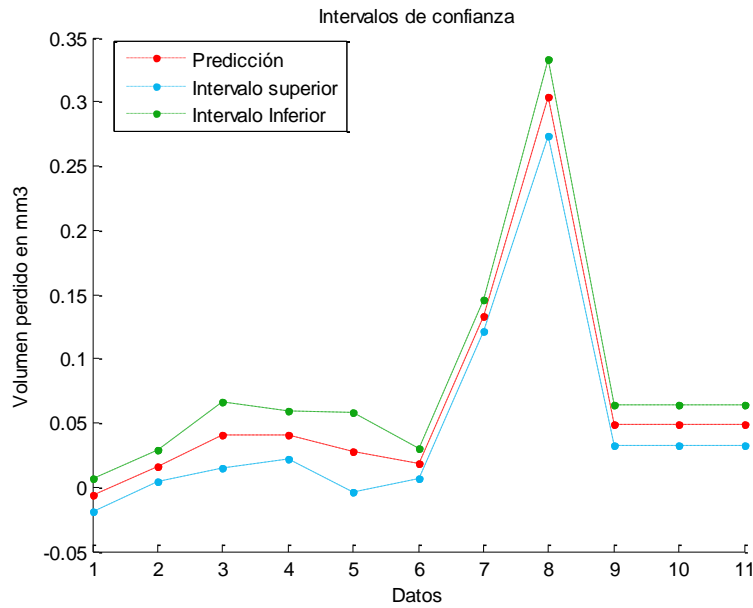
Pesos	Límite inferior	$w_j$	Límite superior
$w_0$	0.0888	0.1107	0.1327
$w_1$	-0.0844	-0.0723	-0.0601
$w_2$	0.1671	0.1968	0.2265
$w_3$	-0.0895	-0.0757	-0.0618

Los intervalos de confianza para la estimación de nuevas observaciones se aprecian en la Tabla 10.

**Tabla 10.** Intervalo de confianza de las estimaciones

Límite inferior	$y_0$	Límite superior
-0.0190154868385541	-0.00601971753268414	0.00697605177318581
0.00412192101025228	0.0163938429653658	0.0286657649204792
0.0151966217040110	0.0407942566780068	0.0663918916520026
0.0221338640561160	0.0407917722374280	0.0594496804187399
-0.00326855732197193	0.0272178022097540	0.0577041617414799
0.00632300948877866	0.0180902971261097	0.0298575847634407
0.120823812389273	0.133558149036505	0.146292485683737
0.273728466518119	0.303665297220562	0.333602127923006
0.0325712164650520	0.0482785200196448	0.0639858235742376
0.0325712164650520	0.0482785200196448	0.0639858235742376
0.0325712164650520	0.0482785200196448	0.0639858235742376

Lo anterior, gráficamente se puede observar en la Figura 47.



**Figura 47.** Intervalos de confianza de la predicción

En lo que respecta a qué tan buen predictor es el modelo, se hace uso de métricas estadísticas que permiten evaluar el modelo resultante. Lo anterior se encuentra en la Tabla 11.

**Tabla 11.** Métricas estadísticas de evaluación

Estadístico	Resultado	Estadístico	Resultado	Estadístico	Resultado
$R^2$	0.9819	$MS_{ERROR}$	1.9695E-04	<b>PRESS</b>	0.0046
$R^2_{ADJ}$	0.9819	<b>PREMS</b>	1.2533E-04	$R^2_{PRED}$	0.9396

La métrica  $R^2$  describe cuán bien el modelo explica la variabilidad evalúa el desempeño del modelo generado mediante la explicación de su variabilidad; para el caso presentado, el modelo describe la variabilidad del proceso en un 98%.



Otra métrica de evaluación señala que si el error medio cuadrático (MSERROR) es mayor al error medio cuadrático de predicción (PREMS) entonces el modelo será un buen predictor.

Finalmente, mediante el coeficiente  $R^2_{\text{PRED}}$  que indica la capacidad que tiene el modelo de red neuronal propuesto para hacer predicciones, por lo que es posible afirmar que el modelo resultante será un buen predictor.

Por otra parte, se revisó que los supuestos estadísticos del modelo se cumplan, esto es importante para asegurar que las conclusiones que se obtengan del análisis estadístico sean válidas. Son tres supuestos, los cuales se enlistan a continuación.

i) La Distribución de los residuales deben ser normales  $\varepsilon = N(0, \sigma^2)$

Mediante la prueba Anderson-Darling (AD) podemos determinar si los datos tienen una distribución normal. El *valor P* de la prueba AD es 0.4072, el cual resultó ser mayor a 0.05 (nivel de significancia de prueba), lo que significa que se cumple el supuesto de normalidad de los residuales.

ii) Las varianzas del residual  $\varepsilon$  deben ser iguales.

Para comprobar si se cumple este supuesto se realizó una prueba de homocedasticidad, el *valor P* de esta prueba es 0.3858, ya que es mayor a 0.05 es posible afirmar que las varianzas de los residuales son iguales.


iii) Los residuales no deben estar correlacionados

La prueba Durbin-Watson se utiliza para saber si los errores se encuentran correlacionados. El *valor P* de esta prueba es 0.7838, dado que es mayor al nivel de significancia utilizado, es posible afirmar que los residuales no están correlacionados. Por lo tanto este supuesto también se cumple.


## 4.2 Acero Inoxidable 316L

### 4.2.1 Huella de desgaste


Se realizó una segunda prueba de desgaste utilizando un acero inoxidable 316L. El material seleccionado para el pin en esta prueba fue alúmina. El proceso de medición y cálculo se realiza acorde a lo descrito en la sección 4.1.




**Figura 48.** Ancho de la huella de la condición 1 a 180° (a) y 300° (b).




**Figura 49.** Ancho de la huella de la condición 2 a 30° (a) y 240° (b).



**Figura 50.** Ancho de la huella de la condición 3 a 0° (a) y 210° (b).




**Figura 51.** Ancho de la huella de la condición 4 a 30° (a) y 210° (b).




**Figura 52.** Ancho de la huella de la condición 5 a 150° (a) y 300° (b).







**Figura 53.** Ancho de la huella de la condición 6 a 0° (a) y 180° (b).




**Figura 54.** Ancho de la huella de la condición 7 a 30° (a) y 270° (b).




**Figura 55.** Ancho de la huella de la condición 8 a 0° (a) y 270° (b).



**Figura 56.** Ancho de la huella de la condición 9 a 120° (a) y 300° (b).



**Figura 57.** Ancho de la huella de la condición 10 a 60° (a) y 270° (b).



**Figura 58.** Ancho de la huella de la condición 11 a 90° (a) y 300° (b).

Al igual que en las pruebas realizadas con zafiro, se promedia el resultado del ancho de la huella de desgaste y se calcula la desviación estándar para estimar un rango de tolerancia de la medición.



**Tabla 12.** Ancho de huella de desgaste.

°	1	2	3	4	5	6	7	8	9	10	11
0°	189.52	163.23	307.65	371.46	314.94	355.92	457.71	499.18	354.91	362.11	343.41
	184.14	156.94	311.8	389.21	314.93	346.33	454.39	508.49	345.27	356.78	349.46
	186.31	170.54	312.9	387.12	317.02	349.48	447.17	488.68	346.39	357.85	336.05
30°	176.3	177.87	305.66	386.19	315.01	349.96	456.5	492.88	359.93	349.48	341.24
	176.82	179.96	328.53	393.4	305.51	350.5	466.87	500.21	359.92	344.22	347.36
	173.94	178.06	302.59	367.42	311.14	355.99	447.26	505.48	361.18	340.08	347.55
60°	174.98	164.38	291.13	371.64	304.68	350.95	445.24	486.12	330.66	359.09	348.63
	175.77	165.31	288.79	374.59	310.77	348.41	445.03	496.98	339.09	360.96	352.59
	174.73	159.31	295.23	382.41	312.98	347.59	451.35	483.1	357.98	354.72	342.17
90°	178.11	166.48	327.59	375.82	308.74	350.95	446.08	509.01	362.31	345.58	344.35
	177.87	162.17	329.58	382.95	308.65	348.41	447.11	490.77	357.85	363.06	348.42
	175.11	164.43	325.72	384.26	307.78	347.59	446.71	491.91	347.49	354.26	347.82
120°	217.75	165.71	334.97	383.51	301.33	349.47	453.43	488.7	352.65	353.99	346.51
	209.26	166.36	338.99	385.04	310.74	356.78	449.19	494.91	353.66	347.38	349.46
	208.42	165.71	347.55	375.63	303.77	357.22	446.38	487.72	352.75	341.49	344.25
150°	220.43	141.44	357.85	371.57	303.43	345.4	447.12	486.77	357.84	347.63	342.71
	220.76	147.56	360.97	382.94	302.38	358.87	436.71	488.64	361.02	348.41	336.9
	222.01	139.55	360.99	382.21	301.37	343.48	450.4	485.63	348.72	356.29	337.03
180°	227.1	124.55	360.1	353.99	305.58	346.32	460.7	474.24	343.28	342.49	333.84
	228.09	125.56	365.17	366.19	301.33	362.01	457.51	476.05	350.5	341.1	342.14
	224.06	120.61	362.03	367.67	303.46	342.32	462.01	468.15	348.53	345.4	338.11
210°	224.97	128.84	376.98	361.15	307.72	365.4	478.44	449.24	345.5	338.41	353.65
	228.09	129.74	381.9	358.93	308.65	369.34	477.27	442.58	329.59	349.51	350.5
	227.45	127.92	380.93	358.99	305.52	369.55	477.26	452.3	344.22	336.9	343.41
240°	235.8	142.43	378.99	364.36	309.84	362.16	478.42	458.39	339.26	336.17	346.39
	230.18	145.47	378.75	354.72	309.7	359.92	478.31	454.1	347.36	339.09	342.13
	236.79	139.55	378.03	355.92	306.67	366.68	471.36	455.27	345.35	333.76	351.81
270°	223.92	149.8	358.08	338.22	312.88	366.29	456.94	453.09	348.86	344.32	347.44
	218.67	167.4	358.87	352.6	314.93	347.36	462.71	475.01	347.37	346.35	352.63
	223.9	149.85	354.76	355.95	317.36	366.21	460.63	468.73	347.39	347.37	347.4
300°	221.97	164.27	393.57	353.74	313.94	373.89	474.65	480.46	332.74	353.76	354.78
	219.72	150.66	393.4	350.51	311.82	376.66	472.07	476.11	354.69	351.56	353.64
	221.85	147.71	394.61	344.38	313.99	385.05	471.05	474.52	369.41	350.72	350.63
330°	210.34	148.75	374.62	383.03	301.33	371.48	474.26	490.89	354.78	357.83	355.81
	209.26	154.85	362.01	385.05	306.57	366.19	471.03	480.24	361	362.01	355.74
	206.13	149.75	354.69	379.27	302.68	364.59	480.5	483.51	360.21	361.15	350.6
<b>Prom</b>	207.23	152.85	348.22	370.33	308.58	357.63	459.99	480.50	350.54	349.48	346.57

$\sigma$	21.75	16.12	31.12	14.31	4.91	10.64	12.669	17.335	9.22	8.26	5.79
----------	-------	-------	-------	-------	------	-------	--------	--------	------	------	------

#### 4.2.2 Cálculo del desgaste

Mediante la norma G99-05 de la ASTM se obtiene el volumen perdido en la muestra y la velocidad de desgaste:


**Tabla 13.** Volumen perdido y tasa de desgaste de la muestra

Cond.	Ancho promedio de la huella (mm)		Volumen perdido en muestra (mm <sup>3</sup> )	Velocidad de desgaste (mm <sup>3</sup> /Nm)	Coefficiente de Fricción promedio ( $\mu$ k)
1	0.207236667	± 0.0217596	0.010096957	5.04848E-05	0.635335326
2	0.152853333	± 0.0161227	0.004051496	2.02575E-05	0.549702048
3	0.348221667	± 0.0311262	0.047902491	2.39512E-05	0.687957168
4	0.370334444	± 0.0143163	0.057619972	2.881E-05	0.613303542
5	0.308587222	± 0.0049189	0.033336849	3.33368E-05	0.512499511
6	0.357631111	± 0.010642	0.051891545	5.18915E-05	0.476091087
7	0.443043889	± 0.00181507	0.116190384	9.86577E-06	0.537783742
8	0.480501667	± 0.017336	0.125856433	1.25856E-05	0.48869738
9	0.350546111	± 0.0092289	0.048868182	1.48085E-05	0.530040622
10	0.34948	± 0.0082622	0.04842367	1.46738E-05	0.532174349
11	0.346571111	± 0.0057958	0.047224547	1.43105E-05	0.530228972


#### 4.2.3 Desgaste de las muestras

El desgaste de las muestras, expresado como el volumen perdido en  $mm^3$  se aprecia en la Figura 59.





**Figura 59.** Volumen perdido de las muestras




**Figura 60.** Gráfica de barras del volumen perdido en las muestras

#### 4.2.4 Coeficiente de fricción


En esta sección, se presentan las gráficas del coeficiente de fricción durante las pruebas pin-on-disk. Se consideran dos condiciones consecutivas por gráfica. Lo anterior se debe a que las condiciones en cuanto a distancia y carga son iguales, siendo la velocidad el único factor que difiere, el cual de acuerdo a la tercera ley de la fricción no tiene efecto en la respuesta.

Aunque las condiciones de desgaste 1 y 2 de la Figura 61 son iguales despreciando la velocidad, se aprecia que el coeficiente de fricción de la condición 2 es menor que la condición 1.




**Figura 61.** Condiciones 1 y 2 de desgaste

En lo que respecta a la Figura 62, se observa el coeficiente de fricción es estable por parte de ambas condiciones, aunque a mayor velocidad el coeficiente es menor.




**Figura 62.** Condiciones 3 y 4 de desgaste

Las condiciones 5 y 6 de desgaste de la Figura 63, muestran nuevamente que el coeficiente de fricción es menor a mayor velocidad.




**Figura 63.** Condiciones 5 y 6 de desgaste

Las condiciones 7 y 8 mostradas en la Figura 64 muestran de nueva cuenta un coeficiente de fricción menor cuando la velocidad es mayor.



**Figura 64.** Condiciones 7 y 8 de desgaste

Finalmente, el coeficiente de fricción de las condiciones centrales apreciadas en la Figura 65 muestra la variabilidad del proceso, donde es posible apreciar una mayor estabilidad para las condiciones debidas al material y al pin de alúmina utilizado para desgaste.



**Figura 65.** Condiciones 9, 10 y 11 de desgaste

#### 4.2.5 Implementación de Red Neuronal

Se realizó una segunda corrida con las mismas condiciones experimentales descritas en la sección 3.2, pero utilizando un pin de alúmina. El resultado del cálculo del desgaste volumétrico con la red neuronal se muestra a continuación.

$$x = \begin{bmatrix} 50 & 100 & 2 \\ 150 & 100 & 2 \\ 50 & 1000 & 2 \\ 150 & 1000 & 2 \\ 50 & 100 & 10 \\ 150 & 100 & 10 \\ 50 & 1000 & 10 \\ 150 & 100 & 10 \\ 100 & 550 & 6 \\ 100 & 550 & 6 \\ 100 & 550 & 6 \end{bmatrix}; \quad y = \begin{bmatrix} 0.0100 \\ 0.0040 \\ 0.0479 \\ 0.0576 \\ 0.0333 \\ 0.0518 \\ 0.1104 \\ 0.1258 \\ 0.0488 \\ 0.0484 \\ 0.0472 \end{bmatrix}$$

Se realizan los mismos pasos mencionados a partir de la sección 4.1.6: un pretratamiento de datos, el cálculo de los centros y de la distancia de Mahalanobis

mediante la cual se generará una matriz de interpolación para realizar el cálculo de la predicción de la respuesta.

#### 4.2.5.1 Cálculo de los pesos

El cálculo de la matriz de pesos resulta en:


$$w = \begin{bmatrix} 0.2471 \\ 0.1304 \\ -0.2738 \\ -0.1225 \end{bmatrix}$$

#### 4.2.5.2 Cálculo de la predicción

La predicción resultante está dada por:

$$\hat{y} = \begin{bmatrix} 0.0079 \\ 0.0063 \\ 0.0514 \\ 0.0543 \\ 0.0334 \\ 0.0517 \\ 0.1150 \\ 0.1271 \\ 0.0482 \\ 0.0482 \\ 0.0482 \end{bmatrix}$$

El resultado de la predicción contra su objetivo se aprecia en laFigura 66.



**Figura 66.**Gráfica de predicción contra objetivo

El error de la predicción o residuales de la predicción:

$$error = \begin{bmatrix} 0.0022 \\ -0.00212 \\ -0.0035 \\ 0.0033 \\ -0.5352E - 6 \\ 0.2385E - 5 \\ 0.0012 \\ -0.0012 \\ 0.688E - 5 \\ 0.243E - 5 \\ -0.9555E - 5 \end{bmatrix}$$

### 4.2.5.3 Supuestos Estadísticos

Como se mencionó en la sección 2.3.3, el primer paso para evaluar los resultados de la red neuronal rediseñada es que se cumplan 3 supuestos:

iv) La Distribución de los residuales deben ser normales  $\varepsilon = N(0, \sigma^2)$

Mediante la prueba Anderson-Darling podemos determinar si los datos tienen una distribución normal.

$H_0$ : Si  $AD > V_c$  los datos siguen una distribución normal

$H_a$ : Si  $AD < V_c$  los datos no siguen una distribución normal

El valor Crítico contra el que se compara el resultado de Anderson-Darling está definido por:

$$V_c = \frac{0.752}{1 + \frac{0.75}{n} + \frac{225}{n^2}}$$

v) Las varianzas del residual  $\varepsilon$  deben ser de varianzas iguales.

$H_0$ : Si  $w > w_{tablas}$  varianzas no homogéneas

$H_a$ : Si  $w < w_{tablas}$  varianzas homogéneas

Si el estadístico calculado es mayor que el valor de tablas, entonces la hipótesis se rechaza.

El valor  $w$  es igual a el número de regresores menos uno, mientras que la  $w$  de tablas se distribuye como una  $\chi^2$ .

vi) Residuales no deben estar correlacionados

La prueba Durbin-Watson se utiliza para saber si los errores se encuentran correlacionados.



$H_0$ : datos independientes

$H_a$ : datos no independientes o prueba inconclusa

Si  $d < d_L$  se rechaza  $H_0$ , si  $d > d_u$  no se rechaza  $H_0$ , si  $d_L < d < d_u$  la prueba es inconclusa.

#### 4.2.5.4 Análisis de Varianza

El Análisis de Varianza o ANOVA se refiere a la descomposición de la variabilidad total en sus partes componentes de origen y se aprecia en la Tabla 6.

**Tabla 14. ANOVA aplicado al proceso de desgaste**

Fuente de variación	Grados de libertad	Suma de Cuadrados	Cuadrados Medios	F	P
Modelo	3	0.0140	0.0047	865.07	0.000
Residual	7	0.377E-6	0.539E-07		
Total	10	0.0140			

El valor p de la Tabla 6 indica - cuando es menor a 0.05 – que el modelo generado es adecuado para determinar la significancia estadística de las relaciones entre variables (Praga-Alejo, 2013). El error estándar de los pesos se muestra en la Tabla 7.

**Tabla 15. Error estándar de los pesos**

Se( $w_1$ )	0.0250
Se( $w_2$ )	0.0050
Se( $w_3$ )	0.0253
Se( $w_4$ )	0.0120

El estadístico  $T_0$  es conocido como la *t-student*, indica que el factor en cuestión tiene efecto sobre la respuesta. Los estadísticos se aprecian en la Tabla

16. El resultado indica que el valor  $p$  de  $T_0$  es menor a 0.05, por lo que se acepta la hipótesis que afirma que la velocidad sí tiene, estadísticamente, un efecto sobre la respuesta; del mismo modo es posible comprobar que todos los factores tienen efecto sobre la respuesta.

**Tabla 16.** Prueba de significancia de las variables

		Valor $p$ de $T_0$
$T_0(w_1)$	9.8991	0.000
$T_1(w_2)$	25.8495	0.000
$T_2(w_3)$	-10.8051	0.000
$T_3(w_4)$	-10.1741	0.000

Los intervalos de confianza obtenidos para los pesos se observan en la Tabla 17.

**Tabla 17.** Intervalo de confianza de los pesos


<b>Pesos</b>	<b>Límite inferior</b>	<b><math>w_j</math></b>	<b>Límite superior</b>
$w_0$	0.1895	0.2471	0.3046
$w_1$	0.1187	0.1304	0.1420
$w_2$	-0.3322	-0.2738	-0.2154
$w_3$	-0.1502	-0.1225	-0.0947

Los intervalos de confianza para la estimación de nuevas observaciones se aprecian en la Tabla 18.

**Tabla 18.** Intervalo de confianza de las estimaciones

Límite inferior	$y_0$	Límite superior
0.00479007480954334	0.00785208008817106	0.0109140853667988
0.00264840448717209	0.00626388332236106	0.00987936215755004
0.0489677590014059	0.0514280049634208	0.0538882509254358
0.0522556127229315	0.0543176119887206	0.0563796112545097
0.0287096621874181	0.0333903774737367	0.0380710927600553
0.0496024515274510	0.0516529997924909	0.0537035480575307
0.111485751439221	0.114953558712643	0.118421365986066
0.123077429701561	0.127063635758873	0.131049841816185
0.0451270997106705	0.0481801246334997	0.0512331495563290
0.0451270997106705	0.0481801246334997	0.0512331495563290
0.0451270997106705	0.0481801246334997	0.0512331495563290

Lo anterior, gráficamente se puede observar en la Figura 67.



**Figura 67.** Intervalos de confianza de la predicción

En lo que respecta a qué tan buen predictor es el modelo, se hace uso de métricas estadísticas que permiten evaluar el modelo resultante. Lo anterior se encuentra en la Tabla 19.

**Tabla 19.** Métricas estadísticas de evaluación

<b>Estadístico</b>	<b>Resultado</b>	<b>Estadístico</b>	<b>Resultado</b>	<b>Estadístico</b>	<b>Resultado</b>
<b>R<sup>2</sup></b>	0.997309	<b>MS<sub>ERROR</sub></b>	5.394e-06	<b>PRESS</b>	0.7780 e-06
<b>R<sup>2</sup><sub>ADJ</sub></b>	0.997309	<b>PREMS</b>	3.4329e-06	<b>R<sup>2</sup><sub>PRED</sub></b>	0.9944

La métrica  $R^2$  cuán bien el modelo explica la variabilidad evalúa el desempeño del modelo generado mediante la explicación de su variabilidad; para el caso presentado, el modelo describe la variabilidad del proceso en un 98%.

Otra métrica de evaluación señala que si el error medio cuadrático (MS<sub>ERROR</sub>) es mayor al error medio cuadrático de predicción (PREMS) entonces el modelo será un buen predictor.

Finalmente mediante el coeficiente  $R^2_{\text{PRED}}$  que indica la capacidad que tiene el modelo de red neuronal propuesto para hacer predicciones, por lo que es posible afirmar que el modelo resultante será un buen predictor.

Por otra parte, se revisó que los supuestos estadísticos del modelo se cumplan, esto es importante para asegurar que las conclusiones que se obtengan del análisis estadístico sean válidas. Son tres supuestos, los cuales se enlistan a continuación.

iv) La Distribución de los residuales deben ser normales  $\varepsilon = N(0, \sigma^2)$  Mediante la prueba Anderson-Darling (AD) podemos determinar si los datos tienen una distribución normal. El *valor P* de la prueba AD es 0.9768, el cual resultó ser

mayor a 0.05 (nivel de significancia de prueba), lo que significa que se cumple el supuesto de normalidad de los residuales.

v) Las varianzas del residual  $\epsilon$  deben ser iguales.

Para comprobar si se cumple este supuesto se realizó una prueba de homocedasticidad, el *valor P* de esta prueba es 0.8251, ya que es mayor a 0.05 es posible afirmar que las varianzas de los residuales son iguales.

vi) Los residuales no deben estar correlacionados


La prueba Durbin-Watson se utiliza para saber si los errores se encuentran correlacionados. El *valor P* de esta prueba es 0.8761, dado que es mayor al nivel de significancia utilizado, es posible afirmar que los residuales no están correlacionados. Por lo tanto este supuesto también se cumple.

### **4.3 Validación Acero 316L**


Se realizó una corrida completa de validación para las muestras de acero inoxidable 316L sometidas a desgaste mediante el pin de alúmina.

#### **4.3.1 Huella de desgaste**


El proceso de medición de la huella de desgaste y cálculo del volumen perdido se realiza acorde a lo descrito en las secciones 4.1.2 y 4.2.2.




**Figura 68.** Ancho de la huella de la condición 1 a 0° (a) y 180° (b).




**Figura 69.** Ancho de la huella de la condición 2 a 90° (a) y 270° (b).



**Figura 70.** Ancho de la huella de la condición 3 a 0° (a) y 180° (b).




**Figura 71.** Ancho de la huella de la condición 4 a 30° (a) y 210° (b).




**Figura 72.** Ancho de la huella de la condición 5 a 120° (a) y 210° (b).






**Figura 73.** Ancho de la huella de la condición 6 a 0° (a) y 330° (b).



**Figura 74.** Ancho de la huella de la condición 7 a 90° (a) y 300° (b).



**Figura 75.** Ancho de la huella de la condición 8 a 30° (a) y 270° (b).



Al igual que en las pruebas realizadas con antelación, se promedia el resultado del ancho de la huella de desgaste y se calcula la desviación estándar para estimar un rango de tolerancia de dicho ancho Tabla 20.

**Tabla 20.** Ancho de huella de desgaste.

°	1	2	3	4	5	6	7	8
0°	202.77	139.37	317.14	300.85	172.68	303.62	445.08	457.71
	213.25	136.23	322.38	295.3	176.77	301.54	440.88	454.39
	214.24	149.74	304.87	282.83	179.04	296.52	437.81	447.17
30°	201.74	192.54	321.38	319.23	165.33	280.75	432.71	456.5
	198.6	191.32	321.3	334.81	159.09	286.01	435.67	466.87
	189.42	190.29	310.96	317.31	171.59	283.2	428.41	447.26
60°	187.4	177.91	321.58	325.22	179.9	276.71	428.76	445.24
	188.21	179.89	302.59	328.62	172.61	277.64	433.62	445.03
	186.31	181.96	313.19	329.81	167.44	276.68	438.97	451.35
90°	198.44	203.93	300.56	332.34	183.02	306.92	444.53	446.08
	192.43	211.08	305.7	351.46	199.64	307.79	435.69	447.11
	198.6	210.1	295.89	347.3	177.85	301.58	424.27	446.71
120°	207.23	223.71	294.28	345.56	177.91	288.25	439.84	453.43
	201.73	201.72	301.56	348.36	179.9	290.1	446.08	449.19
	203.21	204.84	300.52	337.25	163.37	280.87	453.45	446.38
150°	211.17	212.48	297.47	322.47	178.89	257.88	436.86	447.12
	209	217.34	295.3	320.27	176.77	281.78	436.72	436.71
	211.45	195.48	291.41	308.88	174.71	269.31	441.99	450.4
180°	193.41	201.73	300.56	307.25	181.03	280.14	448.15	460.7
	198.19	196.74	293.23	291.26	157.04	280.1	449.19	457.51
	185.16	196.52	295.3	306.77	166.38	278.66	446.08	462.01
210°	191.42	226.17	288.17	303.62	166.63	291.14	447.26	478.44
	192.36	231.88	289.09	310.93	176.77	291.14	448.16	477.27
	180.18	241.27	290.25	317.42	178.89	305.76	452.35	477.26
240°	162.33	246.44	299.92	317.22	174.69	326.31	451.39	478.42
	169.49	233.97	288.02	319.22	175.73	334.55	458.55	478.31
	158.17	247.55	294.27	312.02	181.22	335.58	447.21	471.36
270°	152.1	247.55	328.85	313.12	176.87	348.34	441.23	456.94
	158.05	237.08	328.58	303.64	183.03	348.33	448.21	462.71
	154.93	247.73	316.1	304.87	185.85	345.29	447.46	460.63
300°	176.84	275.56	324.84	281.8	174.7	357.74	453.39	474.65
	181.97	246.47	329.61	291.14	178.84	351.53	451.37	472.07

	182.2	252.7	312.05	289.11	179.88	361.87	436.12	471.05
330°	174.17	243.33	314.31	293.29	171.82	327.55	447.17	474.26
	180.92	237.07	306.74	299.46	177.82	311.95	455.45	471.03
	181.12	241.34	314.02	280.77	177.88	309.87	439.5	480.5
Prom	188.56139	213.08417	298.24297	313.63278	175.59944	296.18919	443.04389	459.99361
$\sigma$	17.142138	32.678944	12.851683	19.385959	7.8089216	28.13288	8.1507	12.669091

#### 4.3.2 Cálculo del desgaste

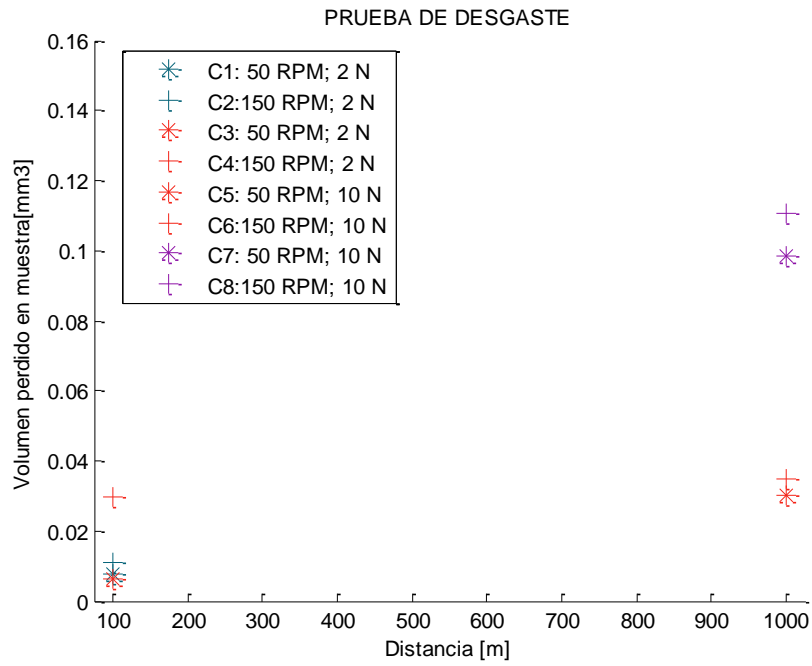
Mediante la norma G99-05 de la ASTM se obtiene el volumen perdido en la muestra, los datos se encuentran en la Tabla 21.

**Tabla 21.** Volumen perdido y tasa de desgaste de la muestra


Cond.	Ancho promedio de la huella (mm)		Volumen perdido en muestra (mm <sup>3</sup> )	Velocidad de desgaste (mm <sup>3</sup> /Nm)	Coefficiente de Fricción promedio ( $\mu$ k)
1	0.1885	± 0.0171	0.007605872	3.80294E-05	0.581768453
2	0.2130	± 0.0328	0.010976004	5.488E-05	0.493396044
3	0.2982	± 0.0128	0.030095488	1.50477E-05	0.589061081
4	0.3136	± 0.0193	0.034998953	1.74995E-05	0.252995253
5	0.1755	± 0.0078	0.006142712	6.14271E-06	0.688660026
6	0.2961	± 0.0281	0.029478022	2.9478E-05	0.442247659
7	0.4599	± 0.0126	0.098657698	9.86577E-06	0.511362851
8	0.4430	± 0.0081	0.110419588	1.1042E-05	0.449941635

#### 4.2.3 Desgaste de las muestras

El desgaste de las muestras, expresado como el volumen perdido en  $mm^3$  se aprecia en la Figura 76. La gráfica de barras del mismo proceso de desgaste volumétrico se encuentra en la Figura 77.



**Figura 76. Volumen perdido de las muestras**

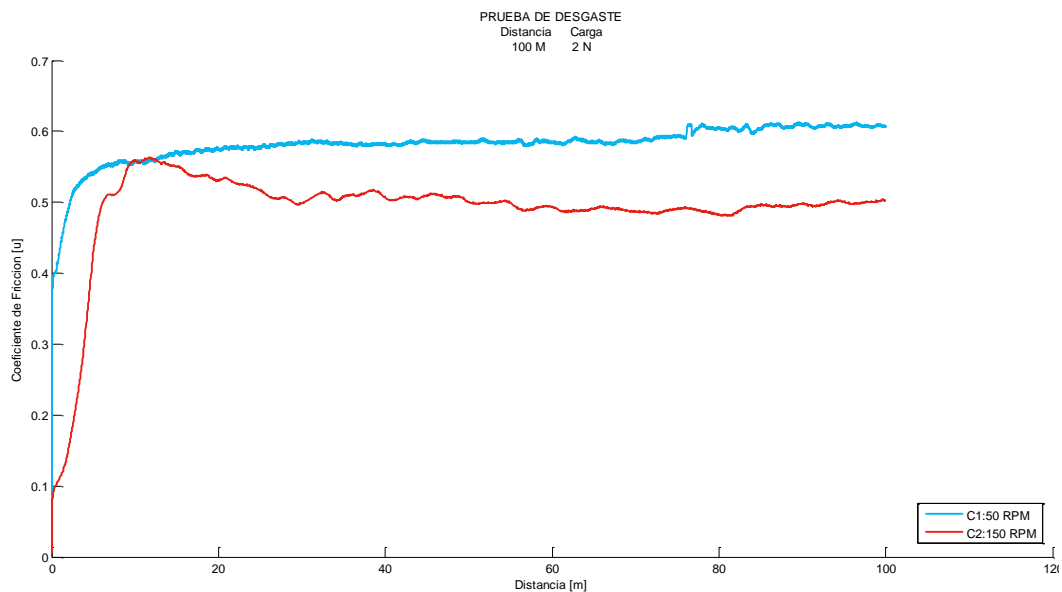


**Figura 77. Gráfica de barras del volumen perdido en las muestras**

#### 4.3.4 Coeficiente de fricción


A continuación se presentan las gráficas del coeficiente de fricción de las pruebas pin-on-disk de las muestras de validación, con el fin de compararlas respecto a las muestras de la sección 4.2.4.

Considerando las condiciones de desgaste 1 y 2 de la Figura 78 iguales, despreciando la velocidad, se aprecia que el coeficiente de fricción de la condición 2 es menor que la condición 1.



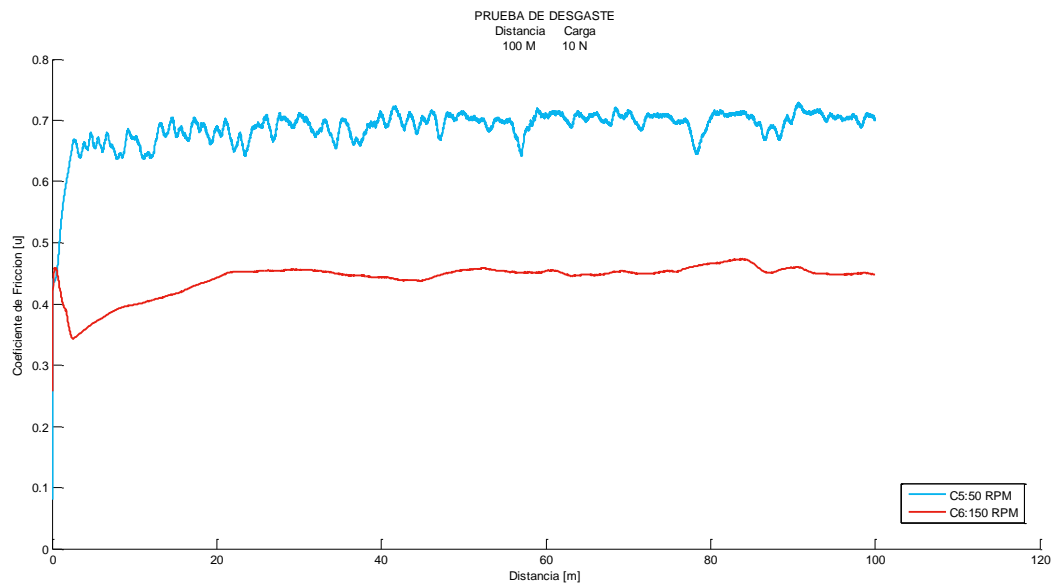
**Figura 78.** Condiciones 1 y 2 de desgaste

En lo que respecta a la Figura 79, se observa el coeficiente de fricción es estable por parte de ambas condiciones, aunque a mayor velocidad el coeficiente es menor.




**Figura 79.** Condiciones 3 y 4 de desgaste

Las condiciones 5 y 6 de desgaste de la Figura 80, muestran nuevamente que el coeficiente de fricción es menor a mayor velocidad.



**Figura 80.** Condiciones 5 y 6 de desgaste


Las condiciones 7 y 8 mostradas en la Figura 81, muestran de nueva cuenta un coeficiente de fricción menor cuando la velocidad es mayor, aunque por una diferencia mínima.



**Figura 81.** Condiciones 7 y 8 de desgaste


#### 4.4 Validación de los resultados

En la Figura 82 se aprecia el resultado de las pruebas de validación contra intervalos de confianza generados a través de la predicción hecha por la red neuronal.



**Figura 82.** Resultados de validación en los intervalos de confianza


En la Figura 83 se muestran los resultados experimentales comparados contra la predicción generada a partir de una red neuronal contra los generados a través de la ecuación de Archard. Si bien en los primeros datos, cuyas condiciones son bajas acorde al DOE previsto es posible apreciar cierta correspondencia en estos valores; sin embargo, a partir de la prueba 6, donde las condiciones de carga y distancia son altas, el modelo de Archard no consigue acercarse al desgaste real, mientras que la red neuronal generada tiene un excelente resultado.



**Figura 83.** Comparación entre resultados experimentales, predicción de la ANN y Archard para el Acero 304L

En la Figura 84 se muestran los resultados experimentales comparados contra la predicción generada a partir de una red neuronal contra los generados a través de la ecuación de Archard. En los primeros datos, cuyas condiciones son bajas acorde al DOE previsto es posible apreciar cierta correspondencia en estos valores; sin embargo, a partir de la prueba 6, donde las condiciones de carga y distancia son altas, el modelo de Archard no consigue acercarse al desgaste real, mientras que la red neuronal generada tiene un excelente resultado que puede ser apreciado gráficamente.





**Figura 84.** Comparación entre resultados experimentales, predicción de la ANN y Archard para el Acero 304L

## 5. CONCLUSIONES

La alta variabilidad del proceso de desgaste no permite conocer con certeza cuál es el material perdido tras una prueba pin-on-disk, por lo tanto, se busca el uso de herramientas matemáticas alternativas para conocer el desgaste de un material.

Los resultados de la experimentación en acero inoxidable 304 muestran que:

- El coeficiente de fricción ( $\mu$ ) resulta menor a mayor velocidad, de acuerdo con las comparaciones entre las condiciones experimentales 1 y 2 (Figura 41), la comparación entre las condiciones 3 y 4 (Figura 42) y la comparación entre las condiciones 7 y 8 (Figura 44). Lo anterior permite asegurar que la velocidad sí tiene efecto sobre el coeficiente de fricción.
- En la comparación hecha entre las condiciones 5 y 6 (Figura 43), el coeficiente de fricción ( $\mu$ ) resulta muy similar, por lo que, para éste caso se puede asegurar que la velocidad no tiene efecto alguno en la fricción.
- El ancho de la huella de desgaste resulta mayor a menor velocidad en la comparación hecha entre las condiciones 1 y 2 y la comparación entre las condiciones 3 y 4 (Tabla 4).
- El ancho de la huella de desgaste más grande a mayor velocidad para las condiciones 5 y 6, y la comparación entre las condiciones 7 y 8 (Tabla 4).

Se realizó una predicción del desgaste volumétrico con base en los datos experimentales y utilizando una red neuronal. De la validación del procedimiento de predicción, utilizando un método estadístico (ver Tabla 11), se puede afirmar que:

- El valor  $R^2 = 0.9819$ , esto es, el modelo desarrollado permite explicar en un 99% la variabilidad del proceso.
- Dado que  $PREMS < MS_{error}$  se afirma que el modelo será un buen predictor.
- El valor  $R^2_{Predicción} = 0.9396$ , lo que significa que el modelo tiene una buena capacidad para realizar predicciones.

En el caso específico del acero 304 con el pin de zafiro, se encontró que el pin sufre un severo daño tras las pruebas de desgaste, lo que ocasiona que el área de contacto del pin se aplane y en consecuencia el área de contacto se vuelva irregular, por lo que las huellas de desgaste observadas tienen una alta variabilidad. Lo anterior permite concluir que un pin de zafiro para pruebas de desgaste con las condiciones mencionadas en el diseño de experimentos, y en un acero inoxidable 304 no es ideal.

Los resultados de la experimentación en acero inoxidable 316L muestran que:

- El coeficiente de fricción ( $\mu$ ) es menor a mayor velocidad, de acuerdo con las comparaciones entre las condiciones 1 y 2 (Figura 61), la comparación entre las condiciones 3 y 4 (Figura 62), la comparación entre las condiciones 5 y 6 (Figura 63), y la comparación entre las condiciones 7 y 8 (Figura 64).

El ancho de la huella de desgaste resulta mayor a menor velocidad en la comparación hecha entre las condiciones 1 y 2 (Tabla 12).

El ancho de la huella de desgaste resulta más ancho a mayor velocidad para las condiciones 3 y 4, lo mismo sucede con las condiciones 5 y 6, y para la comparación entre las condiciones 7 y 8 (Tabla 12).

Para las pruebas de desgaste en acero inoxidable 316L con un pin de alúmina se realizan las 11 condiciones señaladas en el diseño de experimentos planteado en la sección 3.2, así como una prueba de validación.

El algoritmo de predicción construido a través de una red neuronal, es validado mediante inferencia estadística contenida en la Tabla 19 y permite afirmar que:

- El valor  $R^2 = 0.9973$ , por lo que el modelo desarrollado permite explicar en un 99% la variabilidad del proceso.
- Dado que  $PREMS < MS_{error}$  se afirma que el modelo será un buen predictor.

- El valor  $R_{predicción}^2 = 0.9944$ , lo que significa que el modelo tiene una capacidad de realizar una buena predicción.

Se realiza una prueba de validación de la condición 1, cuyos parámetros son:

- Velocidad: 50 RPM.
- Distancia: 100 metros.
- Carga: 2 N.

El resultado es congruente con la predicción y se encuentra dentro de los intervalos de confianza obtenidos como se aprecia en la Figura 84. Asimismo se realizó una validación de la muestra 8 que no se encuentra dentro de los intervalos de confianza. Las razones de lo anterior son: la alta variabilidad y discrepancias en la homogeneidad de la dureza del material, que permiten realizar algunas recomendaciones del trabajo.

Se realizaron pruebas de desgaste en pin-on-disk (Objetivo específico 1), y se utilizó una red neuronal artificial de Función de Base Radial para realizar un modelo de predicción del proceso (Objetivo específico 2). Los resultados obtenidos fueron validados estadísticamente mediante métricas que permiten evaluar su desempeño y adecuación al problema descrito (Objetivo específico 3). En lo que respecta a la comparación entre el modelo de Archard que es el modelo clásico, el modelo de predicción generado a través de una red neuronal y el modelo experimental de la sección 4.4, es posible afirmar (Objetivo específico 4):

- El modelo de Archard es adecuado para condiciones bajas de velocidad y carga, sin embargo, tiene discrepancias cuando las condiciones de desgaste son altas (Figura 83 y Figura 84).
- Por otro lado el modelo de Archard hace caso omiso al efecto que tiene la velocidad en el coeficiente de fricción, mientras que los resultados experimentales muestran lo contrario (Secciones 4.1.5, 4.2.4 y 4.3.4).

- El modelo de predicción para la pérdida volumétrica debida al desgaste en una prueba pin-on-disk generado a partir de una red neuronal, consigue resultados confiables comparándolo con los experimentales.

Es posible mencionar que fue posible generar una predicción a partir de una red neuronal y asignarle a esta un intervalo de confianza, con lo que se cumple la hipótesis 1. Adicionalmente, a partir de las pruebas de hipótesis realizadas a los factores de entrada del sistema, es posible afirmar, estadísticamente, que la velocidad sí tiene un efecto sobre la fuerza de fricción (Tabla 8 y Tabla 16), además, las gráficas del coeficiente de fricción lo confirman.

Las recomendaciones para trabajo futuro van en función del cuidado durante la selección del material, específicamente factores como: la homogeneidad en la dureza de la muestra y la revisión de la carencia de defectos que pudieran perjudicar las pruebas. Otra de las recomendaciones es, cuidar la altura de las muestras, puesto que la herramienta que sujeta las muestras es de 1 pulgada como diámetro máximo y el espesor de la muestra puede exceder el límite del envase, lo que provocaría derrame del líquido de lubricación en el equipo. Por último, es necesario revisar mediante un equipo óptico el pin de desgaste, considerando que en algunas ocasiones el pin sufre un daño al área de contacto, lo que no resulta visible para el ojo humano. No se omite recomendar el uso de diferentes materiales para corroborar el comportamiento de desgaste, así como incrementar el número de pruebas experimentales que puedan aportar mayor información el tema. Finalmente se sugiere explorar otras técnicas tales como la lógica difusa o los análisis multivariados.

## BIBLIOGRAFÍA

- Abdulla, M. B. (2015). Probabilistic multiple model neural network based leak detection system: Experimental study. *Journal of Loss Prevention in the Process Industries*, 36, 30-38.
- Ahmed, A. A. (2016). Effect of micro shot peening on the mechanical properties and corrosion behavior of two microstructure Ti-6Al-4V alloy. *Applied Surface Science*, 363, 50-58.
- Ajiboye, A. B. (2005). A heuristic fuzzy logic approach to EMG pattern recognition for multifunctional prosthesis control. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 13(3), 280-291.
- Akmal, M. H. (2016). In-vitro electrochemical and bioactivity evaluation of SS316L reinforced hydroxyapatite functionally graded materials fabricated for biomedical implants. *Ceramics International*, 42(3), 3855-3863.
- Aleksendric, D. (2010). Neural network prediction of brake friction materials wear. *Wear*, 268(1), 117-125.
- Álvarez Vera, M. (2012). PhD thesis. *Diseño y desarrollo de una prótesis de alto desempeño funcional y tribológico*. Nuevo León, Monterrey, México: UANL.
- Anton Paar. (2014). Tribometer Software Manual. Anton Paar.
- ASTM. (2010). Standard Test Method for Wear Testing with a Pin-on-Disc Apparatus. ASTM G99-05.
- Axen, N. J. (2001). *Friction and wear measurement techniques*. John Wiley & Sons.
- Bhushan, B. (2013). *Introduction to tribology*. John Wiley & Sons.
- Bustamante, F. A. (2005). Study of the model of wearing proposed by Archad. *Dyna*, 72(146), 27-43.
- Calin, M. G. (2013). Designing biocompatible Ti-based metallic glasses for implant applications. *Materials Science and Engineering: C*, 33(2), 875-883.
- Canuto, A. M. (1999). Fuzzy multi-layer perceptron for binary pattern recognition. In IET (Ed.), *Image Processing And Its Applications, 1999. Seventh International Conference on (Conf. Publ. No. 465)*, 1, pp. 260-264.
- Chen, J. L. (1995). Fuzzy perceptron learning and its application to classifiers with numerical data and linguistic knowledge. *Neural Networks, 1995. Proceedings., IEEE International Conference (pp. 3129-3133)*. IEEE.

- Chen, Z. (2012). Using fuzzy theory and information entropy to detect leakage for pipelines. *Intelligent Control and Automation (WCICA), 2012 10th World Congress* (pp. 3232-3235). IEEE.
- Colmenares, G. (2016, 05 23). Retrieved from [http://www.webdelprofesor.ula.ve/economia/gcolmen/programa/redes\\_neuronales/capitulo4\\_funciones\\_bases\\_radiales.pdf](http://www.webdelprofesor.ula.ve/economia/gcolmen/programa/redes_neuronales/capitulo4_funciones_bases_radiales.pdf)
- Cortés Peralta, B. P. (2005). Un Sistema de Patrones de Software para Redes Neuronales Artificiales. *International Conference on Pattern Languages of Programs*. México.
- Cox, R. L. (2012). *Engineered Tribological Composites*. Warrendale, Pennsylvania: SAE International.
- Croccolo, D. D. (2016). Tribological properties of bolts depending on different screw coatings and lubrications: An experimental study. *Tribology International*, 107, 199-205.
- D'Addona, D. M. (2013). Image data processing via neural networks for tool wear prediction. *Procedia CIRP*, 12, 252-257.
- Diggavi, S. N. (1992). On the convergence behavior of Rosenblatt's perceptron learning algorithm. *Signals, Systems and Computers, 1992. 1992 Conference Record of The Twenty-Sixth Asilomar Conference* (pp. 852-856). IEEE.
- Diggavi, S. N. (1995). Convergence models for Rosenblatt's perceptron learning algorithm. *IEEE transactions on signal processing*, 43(7), 1696-1702.
- Dowson, D. (1998). *History of tribology* (Second Edition ed.). London, UK: Instn Mech.
- Engel, I. &. (1994). A transient learning comparison of Rosenblatt, backpropagation, and LMS algorithms for a single-layer perceptron for system identification. *IEEE transactions on signal processing*, 42(5), 1247-1251.
- Fischer, M. J. (2016). In situ elaboration of a binary Ti–26Nb alloy by selective laser melting of elemental titanium and niobium mixed powders. *Materials Science and Engineering: C*, 62, 852-859.
- Frajkorová, F. M.-G.-H. (2016). Biodegradable bi-layered coatings shaped by dipping of Ti films followed by the EPD of gelatin/hydroxyapatite composites. *Journal of the European Ceramic Society*, 36(2), 343-355.
- Gajewski, J. J. (2013). Classification of wear level of mining tools with the use of fuzzy neural network. *Tunnelling and Underground Space Technology*, 35, 30-36.

- Gao, B. S. (2013). Leakage detection of natural gas pipeline based on neural networks and data fusion. *Measurement, Information and Control (ICMIC), 2013 International Conference*. 2, pp. 1171-1175. IEEE.
- Garcia, J. C. (1994). An extended Hamming neural network for non binary pattern recognition. In IEEE (Ed.), *In Circuits and Systems, 1994., Proceedings of the 37th Midwest Symposium*, 1, pp. 607-609.
- González, J. P. (2012). Multiple fault diagnosis in electrical power systems with dynamic load changes using soft computing. *Mexican International Conference on Artificial Intelligence* (pp. 317-328). Springer Berlin Heidelberg.
- Gyurova, L. A.-J. (2010). Modeling the sliding wear and friction properties of polyphenylene sulfide composites using artificial neural networks. *Wear*, 268(5), 708-714.
- Haykin, S. (2004). *Neural Networks. A comprehensive foundation* (Vol. 4). Pearson Prentice Hall.
- Helsen, J. A. (1998). *Metals as biomaterials*. Wiley.
- Ho, C. Y. (2008). Global convergence and limit cycle behavior of weights of perceptron. *IEEE Transactions on Neural networks*, 19(6), 938-947.
- Hu, C. L. (1997). Robust pattern recognition using non-iteratively learned perceptron. *Systems, Man, and Cybernetics, 1997. Computational Cybernetics and Simulation., 1997 IEEE International Conference*. 4, pp. 3546-3551. IEEE.
- Huang-Chi C., Y.-L. L.-J.-G. (2002). Modified Rosenblatt's perceptron algorithm and Novikoff's theorem. *IEEE International Conference on Industrial Technology*, (pp. 1282-1284).
- Jang, J.-S. R., Sun, C.-T., & Mizutani, E. (1997). *Neuro-Fuzzy And Soft Computing*. Upper Saddle River, NJ 07458: Prentice-Hall.
- Jiaqi, Z. Y. (2012). Research on LabVIEW system of fire detection based on BP neural network. *Automatic Control and Artificial Intelligence (ACAI 2012), International Conference* (pp. 1736-1739). IET.
- Johansson, B. I. (1989). Corrosion of dental copper, nickel, and gold alloys in artificial saliva and saline solutions. *Dental Materials*, 5(5), 324-328.
- Juan-Díaz, M. J.-I.-S. (2016). Development of hybrid sol-gel coatings for the improvement of metallic biomaterials performance. *Progress in Organic Coatings*, 96, 42-51.



- Kawashima, A. W. (2012). A Ni-and Cu-free Zr-based bulk metallic glass with excellent resistance to stress corrosion cracking in simulated body fluids. *Materials Science and Engineering: A*, 542, 140-146.
- Khalil Alsmadi, M. O. (2009). Performance comparison of multi-layer perceptron (Back Propagation, Delta Rule and Perceptron) algorithms in neural networks. *Advance Computing Conference, 2009. IACC 2009* (pp. 296-299). IEEE International.
- Köse, C. K. (2016). The effect of CO<sub>2</sub> laser beam welded AISI 316L austenitic stainless steel on the viability of fibroblast cells, in vitro. *Materials Science and Engineering: C*(60), 211-218.
- Kurgan, N. (2016). Effects of sintering atmosphere on microstructure and mechanical property of sintered powder metallurgy 316L stainless steel. *Materials & Design*, 52, 995-998.
- Lee, D. S. (2002). SnO<sub>2</sub> gas sensing array for combustible and explosive gas leakage recognition. *IEEE Sensors Journal*, 2(3), 140-149.
- Leema, N. R. (2015). Characterization, pore size measurement and wear model of a sintered Cu–W nano composite using radial basis functional neural network. *Materials & Design*, 68, 195-206.
- Lucas, S. Z. (1993). Pattern recognition with the decomposed multilayer perceptron. *Electronics Letters*, 29(5), 442-443.
- Matko, D. G. (2006). Neural net versus classical models for the detection and localization of leaks in pipelines. *Mathematical and Computer Modelling of Dynamical Systems*, 12(6), 505-517.
- Mazroua, A. A. (1993). PD pattern recognition with neural networks using the multilayer perceptron technique. *IEEE Transactions on Electrical Insulation*, 28(6), 1082-1089.
- Montgomery, D. &. (1991). *Diseño de experimentos*. Grupo Editorial Iberoamericana.
- Muley, S. V. (2016). An assessment of ultra fine grained 316L stainless steel for implant applications. *Acta biomaterialia*(30), 408-419.
- Nieto González, J. P. (2010). Multiple Fault Diagnosis in Electrical Power Systems with Dynamic Load Changes Using Soft Computing. *Computación y Sistemas*, 14(1), 17-30.
- Pitenis, A. A. (2014). Leonardo da Vinci's friction experiments: An old story acknowledged and repeated. *Tribology Letters*, 56(3), 509-515.

- Popov, V. (2010). Contact mechanics and friction: physical principles and applications. Springer Science & Business Media.
- Praga-Alejo, R. J.-G.-S.-V.-T.-H. (2013). Statistical inference in a redesigned Radial Basis Function neural network. *Engineering Applications of Artificial Intelligence*, 26(8), 1881-1891.
- Purves, D. A. (2004). *Neuroscience* (3a. edición ed.). Sunderland, Massachusetts E.U.A.: Sinauer Associates, Inc.
- Rapetto, M. P. (2009). On the influence of surface roughness on real area of contact in normal, dry, friction free, rough contact by using a neural network. *Wear*, 266(5), 592-595.
- Ray, S. &. (2009). Prediction of contact temperature rise between rough sliding bodies: An artificial neural network approach. *Wear*, 266(9), 1029-1038.
- Rudasi, L. &. (1991). Pattern recognition using neural networks with a binary partitioning approach. *Southeastcon'91* (pp. 726-730). IEEE.
- Santos, R. B. (2013). Real-Time Monitoring of Gas Pipeline through Artificial Neural Networks. *BRICS Congress on Computational Intelligence and 11th Brazilian Congress on Computational Intelligence* (pp. 329-334). IEEE.
- Saravanan, I. P. (2016). Optimization of wear parameters and their relative effects on TiN coated surface against Ti6Al4V alloy. *Materials & Design*, 92, 23-35.
- Schmalzel, J. L. (1993). Pattern recognition based on fuzzy logic. *Instrumentation and Measurement Technology Conference, 1993. IMTC/93. Conference Record* (pp. 681-684). IEEE.
- Shaffer, S. (2013, Enero 29). *Tribology. Introduction to the Basics of Tribology*. Retrieved from Bruker: [https://www.bruker.com/fileadmin/user\\_upload/8-PDF-Docs/SurfaceAnalysis/TMT/Webinars/Tribology\\_101\\_Webinar-1\\_Intro\\_and\\_Basics\\_29-Jan-2013.pdf](https://www.bruker.com/fileadmin/user_upload/8-PDF-Docs/SurfaceAnalysis/TMT/Webinars/Tribology_101_Webinar-1_Intro_and_Basics_29-Jan-2013.pdf)
- Shahryari, A. O. (2018). Electrochemical formation of highly pitting resistant passive films on a biomedical grade 316LVM stainless steel surface. *Materials Science and Engineering: C*, 28(1), 94-106.
- Shibata, A. K. (2009). Neuro based classification of gas leakage sounds in pipeline. *Networking, Sensing and Control, 2009. ICNSC'09. International Conference* (pp. 298-302). IEEE.

- Sobral, J. M. (2016). An accelerated buoyancy adhesion assay combined with 3-D morphometric analysis for assessing osteoblast adhesion on microgrooved substrata. *Journal of the mechanical behavior of biomedical materials*, 60, 22-37.
- Sola, A. B. (2016). Functionally graded materials for orthopedic applications—an update on design and manufacturing. *Biotechnology advances.*, 34(5), 504–531.
- Vander Voort, G. F. (1984). *Metallography, principles and practice*. ASM International.
- Wang, D. (1993). Pattern recognition: Neural networks in perspective. *IEEE Expert*, 8(4), 52-60.
- Wang, W. L. (2016). Development of novel implants with self-antibacterial performance through in-situ growth of 1D ZnO nanowire. *Colloids and Surfaces B: Biointerfaces*, 141, 623-633.
- Xu, J. Y. (2014). Effect of different features to drill-wear prediction with back propagation neural network. *Precision Engineering*, 38(4), 791-798.
- Yang, Y. H. (2016). Adhesion suppresses atomic wear in single-asperity sliding. *Wear*(352), 31-41.
- Yanling, Z. B. (2002). Analysis and study of perceptron to solve XOR problem. *In Autonomous Decentralized System, 2002. The 2nd International Workshop IEEE.*, (pp. 168-173).
- Yea, B. O. (1997). The application of fuzzy-neural network algorithm on the estimation of inflammable gas concentration. *SICE'97. Proceedings of the 36th SICE Annual Conference. International Session Papers* (pp. 941-946). IEEE.
- Zhao, G. H. (2016). Degradation of Zr-based bulk metallic glasses used in load-bearing implants: A tribocorrosion appraisal. *Journal of the mechanical behavior of biomedical materials*, 60, 56-67.