



UNIVERSIDAD JOSÉ ANTONIO PÁEZ

**PREDICCIÓN DEL ACABADO SUPERFICIAL
EN EL MECANIZADO CONVENCIONAL DEL
ACERO AISI 1045 UTILIZANDO REDES
NEURONALES ARTIFICIALES**

Autor
Igor D. Fernández D.

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



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

**PREDICCIÓN DEL ACABADO SUPERFICIAL EN EL MECANIZADO
CONVENCIONAL DEL ACERO AISI 1045 UTILIZANDO REDES
NEURONALES ARTIFICIALES**

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

Autor: Igor D. Fernández D.
C.I. 30.097.589

Tutor: MSc. Ing. Donato Romanello L.
C.I. 4.131.877

San Diego, Mayo de 2022



ACTA DE APROBACIÓN

INFORME FINAL DE PASANTÍA

TRABAJO DE GRADO

El jurado designado por la Facultad de Ingeniería para la evaluación del Informe Final de Pasantía o Trabajo de Grado titulado: Predicción del Acabado Superficial en el mecanizado convencional del Acero AISI 1045 utilizando redes neuronales artificiales

Realizado por el (la) Br. Igor Fernandez
C.I. N° 30 097 589 cursante de la carrera de Mecánica

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

APROBADO

NO APROBADO

El Jurado

Tutor/Académico (Coordinador)
Nombre Donato Romanillo
C.I. 4131877

Jurado
Nombre GIOVANNI PIZZELLA P
C.I. 4455859

Jurado
Nombre FREDY BATULAGAN
C.I. 11151678

Fecha 03-06-2022






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

**CONSTANCIA DE ACEPTACIÓN PARA PRESENTACIÓN PÚBLICA DEL
TRABAJO DE GRADO**

Quien suscribe, MSc. Ing. Donato Romanello Lombardi, portador de la cédula de identidad N° 4.131.877, en mi carácter de tutor del trabajo de grado presentado por el ciudadano Igor D. Fernández D., titular de la cédula de identidad N° 30.097.589, titulado **PREDICCIÓN DEL ACABADO SUPERFICIAL EN EL MECANIZADO CONVENCIONAL DEL ACERO AISI 1045 UTILIZANDO REDES NEURONALES ARTIFICIALES**, presentado como requisito parcial para optar al título de Ingeniero Mecánico, considero que dicho trabajo reúne los requisitos y méritos suficientes para ser sometido a la presentación pública y evaluación por parte del jurado examinador que se designe.

En San Diego, a los 24 días del mes de mayo del año dos mil veintidós.


MSc. Ing. Donato Romanello L.
C.I: 4.131.877



Valencia, 27 de abril de 2022

Ciudadano:
FERNANDEZ DAVILA, IGOR DAVID
30.097.589

Presente -

Cumplo con informarle que la comisión de Trabajo de Grado y Pasantías de la Facultad de Ingeniería en su reunión N° 2-2022 de fecha 15/02/2022 aprobó el proyecto de grado titulado:

Predicción del acabado superficial en el mecanizado convencional del acero AISI 1045 utilizado en redes neuronales artificiales.

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

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



Atentamente

Dr. Francisco Gelanzé Sevilla.
Decano de Ingeniería

AGRADECIMIENTOS

Agradezco primeramente a Dios, por hacer posibles todas las otras cosas por las que quiero agradecer, por mantenerme con la salud, la sabiduría, y la fortaleza necesarias para siempre salir adelante y contra la adversidad, en toda situación.

Agradezco profundamente a mis padres, Dayana, y Jorge, por ser los primeros en hacer posible todo lo demás. Por darme la vida, por siempre estar allí, por su protagonismo en la formación de la persona que soy hoy día, y por ser una fuente de amor y apoyo eterna e incondicional. ¡Gracias mamá, gracias papá!

Agradezco a mi hermanito, Isaac, por ser una luz constante en cualquier momento, por la alegría y la felicidad que me transmite cuando estamos juntos, por su ánimo y su espíritu; y por su curiosidad constante y su imaginación activa, que siempre está ofreciéndome ideas, ¡y hasta ayudándome a estudiar! ¡Gracias hermanito!

A mi abuela, Marisa, por ser el pilar fundamental de la educación en la familia, la mejor profesora, mi primera mentora, que siempre ha contribuido de forma vital, paciente y sabia a mi formación y a mi criterio, con todo el amor del mundo y con toda su dedicación también. ¡Gracias abuela!

A mi abuelo, Orlando, por haber estado conmigo, por haberme impulsado, aconsejado, y por haberme apoyado tanto siempre, y aún más, por haber sido el motor más grande de la etapa más importante de mi carrera. Gracias a ti pudo hacerse este trabajo, y gracias a ti aprendí prácticamente todo lo que necesité para él, con todo lo que me enseñaste, y aún sigo expectante por todo lo que me queda aprender de ti. ¡Gracias abuelo!

A mi tutor, el profesor Donato, por todo. Por ser mi mentor, el mejor profesor de mi pregrado, por orientarme y aconsejarme sobre tantas cosas en los momentos en los que la situación país nos hizo cuestionarnos tanto el futuro, por ser de las personas más

influyentes en enseñarme del valor de la paciencia, y por haber sido, junto a mi abuelo, uno de los elementos más importantes de este trabajo. ¡Gracias profesor!

Y agradezco a mis compañeros, maestros, amigos y seres queridos, por haber estado ahí en tanto, por haber compartido conmigo el día a día durante toda la carrera, por haber estado en las buenas y en las malas, por ayudarme tanto siempre y por haber sido quienes fueron conmigo. Especialmente a ustedes, Pedro, Daniel, Carlos, Aldo, y a mi novia, intensa y locamente amada, que intensa y locamente me amó, a mi Gabriela, por haber estado allí desde el principio hasta el final, sin flaquear nunca, presentes siempre en los momentos más importantes; así como a la profesora Alicia y al profesor Giovanni, por su extenso papel en mi formación profesional, desde los inicios de la carrera hasta ahora, al profesor Fredy y a la profesora Yndira; y a Miguel y a Gustavo, por toda su ayuda en estos últimos semestres, y en especial, en mi trabajo de grado. ¡A ustedes también, gracias!

¡A todos, muchísimas gracias! Porque fueron los mejores compañeros que pude tener en este recorrido, y espero seguirlo viviendo con ustedes por mucho, mucho tiempo más. Este logro es mío, y de ustedes, que estuvieron ahí. ¡Es de todos!

Igor David Fernández Dávila

DEDICATORIA

Al ángel tan hermoso que Dios me dio el permiso de conocer, que estuvo a mi lado en todos esos momentos, que me enseñó tanto y que tuvo una contribución tan grande en mí, como persona, y para que pudiese llevar a cabo este trabajo y para hacer mucho más. A mi princesa preciosa, tierna, y dulce, mi chiquita, en quien siempre pensé como lo máximo, la mejor, y que aún hoy en día, siento y sé que era la mejor de todos nosotros. Porque siempre estarás con todos, y porque siempre estarás y te sentiré aquí, conmigo, animándonos, animándome; impulsándonos e impulsándome siempre hacia delante. A mi amada novia, a mi tan inconmensurablemente amada y amorosa novia, a mi Gabriela. Lo volvería a hacer todo por ti, por mí y por nosotros, una y mil, e infinitas veces más. Porque te amé, y aún te amo demasiado, y por eso, este logro, este trabajo, y más, solo quiero dedicártelos a ti; mi princesa, mi ángel, mi amor.

Y aunque pienso que las palabras no alcanzan ni son, ni serán, jamás y nunca, suficientes para expresarte todo lo que sentí ni lo que incluso ahora siento, tengo que empezar por aquí.

Y me contenta saber, Preciosa, que eres feliz, en ese mejor lugar, mejor que cualquiera en este mundo, mucho más cerca de Dios.

Te amé, te amo, y siempre te amaré.

Tu novio, tu amor. Tu Igor.

ÍNDICE

CONTENIDO	PP.
ÍNDICE DE CUADROS	x
ÍNDICE DE FIGURAS	xi
ÍNDICE DE TABLAS	xiv
RESUMEN	xv
INTRODUCCIÓN	1
CAPÍTULO	
I EL PROBLEMA	
1.1 Planteamiento del Problema.....	4
1.2 Formulación del Problema.....	6
1.3 Objetivos de la Investigación.....	6
1.3.1 Objetivo General.....	6
1.3.2 Objetivos Específicos.....	6
1.4 Justificación.....	7
1.5 Alcance y Limitaciones.....	9
1.5.1 Alcance.....	9
1.5.1 Limitaciones.....	9
II MARCO TEÓRICO	
2.1 Antecedentes.....	11
2.2 Bases Teóricas.....	20
2.2.1 Mecanizado.....	20
2.2.1.1 Torneado.....	21
2.2.1.2 Herramientas.....	23
2.2.2 Acabado Superficial.....	28
2.2.2.1 Rugosidad Superficial.....	28
2.2.2.2 Medición de la Rugosidad.....	32
2.2.3 Acero AISI 1045.....	37
2.2.3.1 Parámetros de Mecanizado.....	38
2.2.4 Redes Neuronales Artificiales.....	40
2.2.4.1 Perceptrones.....	40
2.3 Definición de Términos Básicos.....	42
III MARCO METODOLÓGICO	
3.1 Tipo de Investigación.....	44
3.2 Diseño de la Investigación.....	44
3.3 Nivel de la Investigación.....	45
3.4 Población y Muestra.....	45
3.4.1 Población.....	45

3.4.2 Muestra.....	45
3.5 Técnicas de Recolección de Datos.....	46
3.5.1 Observación Directa.....	46
3.5.2 Revisión Documental.....	46
3.6 Instrumentos Utilizados en la Recolección de Datos.....	47
3.7 Técnicas de Procesamiento y Análisis de Datos.....	48
3.8 Fases Metodológicas.....	49
IV RESULTADOS	
4.1 Diagnóstico de las mejores condiciones de corte para los ensayos	51
4.1.1. Geometría de las Probetas.....	51
4.1.2. Composición Química del Material.....	53
4.1.3. Propiedades Mecánicas del Material.....	53
4.1.3.1. Microestructura.....	53
4.1.3.2. Dureza.....	54
4.1.3.3. Maquinabilidad.....	59
4.1.4. Máquinas Herramienta.....	60
4.1.4.1. Sierra de Vaivén.....	60
4.1.4.2. Torno de Banco Paralelo.....	61
4.1.5. Herramientas de Corte.....	62
4.1.5.1. Hoja de Sierra.....	62
4.1.5.2. Portaherramientas de Cuchillas Orientables.....	63
4.1.5.3. Cuchilla Orientable de Carburo de Tungsteno.....	64
4.1.5.4. Mecha de Centro de Acero Rápido.....	66
4.1.5.5. Cuchilla Orientable de Acero Rápido.....	67
4.1.6. Parámetros de Corte.....	68
4.1.6.1. Velocidad de Corte.....	69
4.1.6.2. Avance.....	70
4.1.6.3. Profundidad de Corte.....	71
4.1.6.4. Tablas de Datos.....	71
4.2. Mecanizado de las muestras de acero, con las herramientas y los parámetros determinados.....	72
4.2.1. Corte con Sierra.....	73
4.2.2. Refrentado.....	75
4.2.3. Perforación de Centros.....	78
4.2.4. Cilindrado.....	79
4.2.5. Afilado de Herramientas.....	82
4.2.6. Ensayos.....	84
4.2.7. Almacenaje.....	85
4.3. Medición de rugosidad superficial de los resultados del torneado.....	86

4.3.1. Nomenclatura de Probetas.....	87
4.3.2. Proceso de Medición con Rugosímetro.....	89
4.3.3. Resultados de Medición e Interpretación; Rugosímetro y Microscopio.....	92
4.4. Selección de la red neuronal artificial.....	110
4.4.1. Matemáticas de la Red: Forward y Backpropagation, Problemas de Regresión.....	110
4.4.2. Influencia de los Hiperparámetros en la Red.....	113
4.4.3. Python vs Joone.....	119
4.5. Aplicación de la red neuronal artificial.....	119
4.5.1. Estructura de la Red en Joone.....	120
4.5.2. Datos de Entrada.....	122
4.5.3. Datos de Salida.....	124
4.5.3.1. Valores Reales; Datos de Entrenamiento.....	124
4.5.4. Optimización de Hiperparámetros.....	129
4.5.4.1. Valores Predichos por la Red.....	136
4.5.5. Discusión de Resultados.....	140
IV CONCLUSIONES Y RECOMENDACIONES	
5.1. Conclusiones.....	147
5.2. Recomendaciones.....	148
REFERENCIAS BIBLIOGRÁFICAS	150
ANEXOS	
A Instrumentos de Medición Utilizados.....	155
B Ángulos de las Herramientas de Corte.....	160
C Desgaste de las Herramientas de Corte.....	165
D Parámetros de Corte Originales, Diseño Factorial Completo.....	166

LISTADO DE CUADROS

CONTENIDO

CUADRO		pp.
1	Cuchilla Orientable de Acero Rápido, Modelo AC-16 222 S, de Impero, en Catálogo.....	67
2	Resultados de Rugosidad de la Probeta 11123.....	93
3	Resultados de Rugosidad de la Probeta 11131.....	94
4	Resultados de Rugosidad de la Probeta 12111.....	95
5	Resultados de Rugosidad de la Probeta 12112.....	96
6	Resultados de Rugosidad de la Probeta 12113.....	97
7	Resultados de Rugosidad de la Probeta 12121.....	98
8	Resultados de Rugosidad de la Probeta 12122.....	99
9	Resultados de Rugosidad de la Probeta 12123.....	100
10	Resultados de Rugosidad de la Probeta 12133.....	101
11	Resultados de Rugosidad de la Probeta 12211.....	102
12	Resultados de Rugosidad de la Probeta 12223.....	103
13	Resultados de Rugosidad de la Probeta 12231.....	104
14	Resultados de Rugosidad de la Probeta 12311.....	105
15	Resultados de Rugosidad de la Probeta 12312.....	106
16	Resultados de Rugosidad de la Probeta 21111.....	107
17	Resultados de Rugosidad de la Probeta 21112.....	108
18	Resultados de Rugosidad de la Probeta S/C.....	109

LISTADO DE FIGURAS

CONTENIDO

FIGURA		pp.
1	Torno de banco.....	22
2	Cuchilla orientable con filos de carburo de tungsteno.....	24
3	Cuchilla orientable con filos de acero rápido	24
4	Desgaste de las herramientas.....	26
5	Gráfica logarítmica de vida útil de una herramienta de carburo de tungsteno de Kennametal.....	27
6	Curvas de vida útil de herramienta para distintos materiales de corte.....	28
7	Superficie geométrica de la pieza.....	29
8	Superficie real de la pieza	30
9	Perfil real de una sección de la pieza.....	30
10	Línea media de los mínimos cuadrados.....	30
11	Línea media aritmética.....	31
12	Cresta local del perfil.....	31
13	Valle local del perfil.....	31
14	Cresta del perfil.....	32
15	Forma de expresar las especificaciones de la rugosidad.....	32
16	Rugosímetro de palpador mecánico.....	33
17	Altura de una cresta del perfil.....	34
18	Profundidad de un valle del perfil.....	34
19	Altura de una irregularidad del perfil.....	35
20	Valores máximos de la profundidad, la altura de una cresta y la del perfil.....	35
21	Pasos medios de las irregularidades del perfil.....	36
22	Pasos de las crestas locales del perfil.....	36
23	Longitud desarrollada, relación de longitud y densidad de las crestas.....	36
24	Segmentos de longitud portante.....	37
25	Curva de la tasa de longitud portante.....	37
26	Resultados de rugosidad para distintas configuraciones de corte, en función de la velocidad de corte.....	39
27	Resultados de rugosidad para distintas configuraciones de corte, en función del avance.....	39
28	Arquitectura de una red neuronal artificial.....	40
29	Arquitectura de un perceptrón multicapa.....	41
30	Vista Transversal de la Geometría de las Probetas.....	52

31	Vista Longitudinal de la Geometría de las Probetas.....	52
32	Microestructura del Acero AISI 1045.....	54
33	Primera Probeta de Dureza, Cilindrada.....	55
34	Resultados de las cinco mediciones de dureza en la longitud de la probeta cilindrada.....	56
35	Gráfico de los resultados de las mediciones de dureza en la longitud de la probeta cilindrada.....	56
36	Análisis estadístico de los resultados de la medición de dureza la probeta cilindrada.....	57
37	Segunda Probeta de Dureza, Refrentada.....	57
38	Resultados de las cinco mediciones de dureza en la longitud de la probeta refrentada.....	58
39	Gráfico de los resultados de las mediciones de dureza en la longitud de la probeta refrentada.....	58
40	Análisis estadístico de los resultados de la medición de dureza la probeta refrentada.....	59
41	Sierra de Vaivén SABI-HER30.....	61
42	Torno de Banco Paralelo, CD6260C.....	62
43	Hoja de Sierra de HSS utilizada en la Sierra de Vaivén.....	63
44	Portaherramientas Impero para Cuchillas Orientables.....	64
45	Cuchilla Orientable de Carburo de Tungsteno, modelo FB 16, grado P6, de Impero Tools.....	65
46	Cuchilla Orientable FB 16-P6 Utilizada en los Ensayos	65
47	Mecha de Centro de 4 mm, HSS.....	66
48	Configuración de las Herramientas de Corte, con el Mandril..	66
49	Cuchilla Orientable de Acero Rápido, Modelo AC-16 222 S, Utilizada.....	68
50	Velocidades Rotacionales Disponibles en el Torno.....	69
51	Velocidades de Avance Disponibles en el Torno.....	70
52	Escala en Manivela del Carro Transversal.....	71
53	Barra Inicial de Acero AISI 1045.....	73
54	Proceso de Corte con Sierra de las Probetas.....	74
55	Conjunto Inicial de Probetas.....	75
56	Configuración en el Torno para Refrentado y Perforado.....	76
57	Ejecución del Refrentado.....	77
58	Mecha de Centro de 4 mm, HSS; tras Fractura de una Punta...	78
59	Perforación de Centro en las Probetas.....	79
60	Conjunto de Probetas Perforadas.....	79
61	Configuración para el Cilindrado.....	80
62	Ejecución del Cilindrado.....	81
63	Conjunto de Probetas Cilindradas.....	81

64	Conjunto de Probetas Cilindradas con Línea Divisoria.....	82
65	Piedra de Esmerilar de Óxido de Zirconio.....	83
66	Piedra de Esmerilar de Óxido de Aluminio.....	83
67	Ejecución del Ensayo en el Carburo de Tungsteno Refrigerado	84
68	Probetas Ensayadas y Lubricadas para su Preservación.....	85
69	Probetas Ensayadas, Lubricadas y Almacenadas Herméticamente.....	86
70	Vista Lateral de la Primera Configuración de Medición.....	91
71	Vista Superior de la Segunda Configuración de Medición.....	91
72	Coste como Función de los Pesos de la Red.....	112
73	Arquitectura de la Red Neuronal a Aplicar.....	115
74	Efecto de una Tasa de Aprendizaje Pequeña, y de una Alta.....	116
75	Efecto del Momento en el Descenso de Gradiente.....	117
76	Funciones de Activación: Sigmoidal, Tangente Hiperbólica, y Unidad Lineal Rectificada.....	118
77	Estructura de la Red Neuronal, Construida en Joone.....	121
78	Datos de Entrenamiento de la Red.....	127
79	Selección de Columnas de Parámetros de Corte del Archivo de datos de Entrenamiento, en el Advanced Column Selector, Sección Izquierda.....	127
80	Selección de Columnas de Parámetros de Corte del Archivo de datos de Entrenamiento, en el Advanced Column Selector, Sección Derecha.....	128
81	Selección de Columnas de Rugosidad, en el Advanced Column Selector, Sección Izquierda.....	128
82	Selección de Columna de Rugosidad del Archivo de Datos de Entrenamiento, en el Advanced Column Selector, Sección Derecha.....	129
83	Primer Intento, 0.2 LR, 0.3 M, 1000 E.....	130
84	Primer Intento, 0.2 LR, 0.3 M, 10000 E.....	131
85	Primer Intento, 0.2 LR, 0.1 M, 10000 E.....	132
86	Primer Intento, 0.1 LR, 0.1 M, 1000 E.....	133
87	Primer Intento, 0.1 LR, 0.1 M, 20000 E.....	134
88	Vigésimo Tercer Intento, 0.1 LR, 0.1 M, 20000 E.....	135
89	Resultados Predichos de Rugosidad Normalizados, en su formato de Archivo de Salida Original.....	137
90	Mínimos Locales y Puntos de Silla o Ensilladura, en la Función de Coste con Respecto a los Pesos.....	139

LISTADO DE TABLAS

CONTENIDO

TABLA		pp.
1	Fórmulas y parámetros del torneado.....	22
2	Rugosidad promedio del proceso de torneado.....	29
3	Parámetros de toma de muestras.....	39
4	Composición Química del Acero AISI 1045.....	53
5	Parámetros de Mecanizado Seleccionados para las Probetas de Medición de Rugosidad.....	88
6	Primer Modelo de Medición de Rugosidad.....	89
7	Segundo Modelo de Medición de Rugosidad.....	90
8	Primer Modelo de Medición de Rugosidad, con Valores.....	92
9	Segundo Modelo de Medición de Rugosidad, con Valores.....	92
10	Datos de Entrada de la Red Neuronal.....	122
11	Datos de Entrada de la Red Neuronal, Normalizados.....	123
12	Datos de Entrenamiento de Rugosidad, Medidos.....	125
13	Datos de Entrenamiento de Rugosidad, Medidos; Normalizados	126
14	Resultados Predichos de Rugosidad luego de Deshacer la Normalización, y Comparación con Valores Reales.....	138



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

**PREDICCIÓN DEL ACABADO SUPERFICIAL EN EL MECANIZADO
CONVENCIONAL DEL ACERO AISI 1045 UTILIZANDO REDES
NEURONALES ARTIFICIALES**

Autor: Fernández D. Igor D.

Tutor: MSc. Ing. Donato Romanello L.

Fecha: Mayo, 2022

RESUMEN INFORMATIVO

La presente investigación fue desarrollada en la escuela de Ingeniería Mecánica de la Universidad José Antonio Páez y en la empresa Tornoval C.A., dedicada al mecanizado. Actualmente, el mecanizado es dividido entre convencional y CNC, y, en ambos, es la labor de un supervisor considerar las mejores características de corte para los acabados deseados y los materiales dados, o usar tablas que lo hagan. No obstante, en ocasiones, dichos pasos no se cumplen, afectando la calidad y las máquinas mismas en el proceso. Por ello, se realizó una red neuronal artificial, que, de los resultados tomados de la medición con el rugosímetro Mitutoyo SurfTest SJ-201, se concluyó pudiendo alcanzar un ECM de hasta 0.0011 en la predicción del parámetro Ra en el acero AISI 1045; a partir de lo cual se recomienda realizar estudios posteriores con materiales adicionales, para ampliar las capacidades de la misma. La investigación fue de tipo proyecto especial, de diseño de campo y documental, y con metodología cuantitativa se aplicaron la revisión documental y la observación directa. Enmarcada dentro de la línea de investigación Desarrollo de Nuevas Tecnologías de la Información y Comunicación.

Descriptor: Investigación, cuantitativa, simulación, mecanizado, redes neuronales artificiales, rugosidad superficial, AISI 1045.

INTRODUCCIÓN

Durante la historia de la manufactura, siempre se ha contado con el acero y con el mecanizado como dos elementos imprescindibles del desarrollo humano. Desde que se descubriese que el arranque de viruta es el método más conveniente para la consecución de los mejores acabados superficiales, el mismo ha sido la forma más extendida de realizarlos. A la vez, el acero es, probablemente, el material con el que se realizan la mayor cantidad de obras de ingeniería, dadas sus aplicaciones estructurales y sus excelentes propiedades, de entre las cuales, el AISI 1045 destaca enormemente por su gran versatilidad y aplicabilidad.

Dada la importancia que tienen dichos dos factores, es pertinente contribuir a la exactitud de la realización de las operaciones de manufactura que los engloben a ambos. Así, como se comentó anteriormente, el mecanizado está, en la actualidad, dividido, usualmente, entre dos paradigmas; el convencional, y el CNC. No obstante, en ambos casos, aunque la máquina puede llegar a poseer un mayor o menor grado de independencia dado su nivel de automatización, y con ello, de precisión, en cualquiera de los dos, sigue siendo, básicamente, una herramienta, y, por tanto, podría decirse que solo interpreta ordenes, considerándola un sistema.

Si dichas órdenes no son las más convenientes para la ejecución de una operación, su calidad final está restringida a ser menor que la que podría alcanzar, y en el proceso, incluso es posible, dependiendo del grado de desviación que exista de los parámetros de corte más apropiados, que la máquina herramienta pueda sufrir daños o desperfectos, al igual que la pieza a trabajar.

En este aspecto, el error en las órdenes suele darse a través de un operador o supervisor, que, al configurar la máquina, no posean todos los datos necesarios para hacerlo, o no posean los datos correctos, ya que los mismos pueden variar dependiendo del tipo de material, y del tipo de operación a realizar en él. Lo ideal en estos casos, es tener una serie de tablas o resultados de investigaciones anteriores que den ideas de cuáles son los mejores parámetros de corte a utilizar, de forma que se tome una decisión informada al configurar las máquinas con ellos precisamente.

Sin embargo, no en todos los talleres se poseen dichas tablas, y no todos los supervisores que las tienen las utilizan, siendo la experiencia la que en multitud de ocasiones dirige la configuración de las herramientas. Así, el porcentaje de error dentro de los parámetros del acabado y del resto del maquinado puede incrementarse, debido a la negativa de utilizar las fuentes, pero, más frecuentemente, a la ausencia de las mismas en el lugar de trabajo.

De esta manera, el segundo punto es el que se tiene como propósito resolver durante la investigación, creando y estudiando la aplicabilidad de una herramienta computacional que no requiera que el operador tenga un gran número de tablas, si no, solamente, un medio de ejecutar el programa que y de indicarle los datos de su operación, como el acabado superficial necesario y el material a trabajar.

De esa forma, la red neuronal artificial será la base de la creación de dicha herramienta, y para su entrenamiento se utilizarán los mismos factores que se desea en el futuro se obtengan a partir de la iteración de la red; los parámetros de corte principales del torneado, la velocidad de avance, la profundidad de corte, y la velocidad rotacional de la pieza. Esto, para herramientas de carburo de tungsteno y de acero rápido, las de uso más extendido en el mecanizado, tras medir sus resultados de rugosidad superficial con un rugosímetro.

Luego, es importante mencionar que la investigación está estructurada en cuatro capítulos, siguiendo los pasos metodológicos apropiados necesarios para llevarla a cabo y para cumplir de manera exitosa los objetivos planteados; el capítulo I incluye el planteamiento del problema, su formulación, sus objetivos, general y específicos, su justificación, limitaciones, y alcance.

El capítulo II estudia los antecedentes existentes y seleccionados para el análisis del tema, y ubica a todas las bases teóricas que representan el fundamento de la investigación y permiten alcanzar su comprensión, además de definir a sus términos. En el capítulo III se expone la metodología utilizada para desarrollar la investigación y la obtención y análisis de sus resultados, y en el capítulo IV se muestran los recursos

con los que se cuenta para la realización de la investigación, y nombrando a los humanos, institucionales, materiales, y al tiempo.

CAPÍTULO I

EL PROBLEMA

1.1. Planteamiento del Problema

Mundialmente, en la manufactura, se requiere de manera constante un incremento progresivo en la capacidad de los procesos de dar precisiones mayores a la vez que requerir tiempos de producción disminuidos, así como de procesos más sistematizados y menor cantidad de errores de fabricación. En el mecanizado, esto es particularmente común, y es una preocupación abordada de manera reiterada, a través de dos factores: la velocidad de producción, y la calidad de la fabricación.

De entre estos aspectos, en la actualidad, se tiene una complicación considerable en la forma de adecuar dichas variables a cada proceso particular, y aún más, cuando para la calidad se tiene que tomar en cuenta el acabado superficial, puesto a que las formas comunes de aproximarse a los valores de rugosidad en el mecanizado convencional no son precisas.

De esta forma, un tipo de aplicación fundamental para la industria de dichos procesos, es el torneado en máquinas de diferentes aleaciones; de entre las cuales, una de las más comunes, es el acero al carbono AISI 1045, y una base del problema planteado como origen de la investigación, se encuentra en la incapacidad de los métodos convencionales de encontrar, aplicar y ayudar a optimizar las mencionadas relaciones entre la velocidad de producción y el acabado superficial como requerimiento de calidad.

Globalmente, dichos métodos comunes de aproximación a los acabados en el mecanizado convencional, se realizan a través de dos formas principales relacionadas; primero, con la aplicación de los parámetros que se creen convenientes para satisfacer las necesidades, obtenidos directamente en planta, al momento de trabajar, desde la experiencia de los operadores, y segundo, con tablas registradas y estandarizadas.

El hecho, en el caso presente, se refiere a las limitaciones subyacentes en ambos métodos; ya que, en la primera situación expuesta, la experiencia de los operadores puede poseer un margen de error relativamente alto en algunos procesos, y, en la segunda, la forma en la que las tablas registradas se escriben normalmente, no es óptima para particularizar el mecanizado de cada pieza en cada aplicación.

Esto debido, a que las tablas de parámetros de mecanizado están, por lo general, escritas para dos conjuntos de valores clave: primero, los parámetros de mecanizado para desbaste, y segundo, los de mecanizado para acabado. En el mecanizado de desbaste, como es conocido, se tiene como objetivo reducir al máximo el volumen de la pieza en un tiempo relativamente corto, en ocasiones, manteniendo una integridad considerable en las herramientas.

Mientras que, por su parte, en los mecanizados de acabado, se desea, en teoría, obtener las mejores rugosidades posibles para una aplicación en particular, tomando en cuenta el tiempo de operación, pero sin, necesariamente, priorizarlo. De esta forma, se observa que, en el segundo punto, las tablas registradas mencionadas anteriormente, solo suelen llevar señaladas combinaciones de parámetros para un valor específico de rugosidad, que, si bien en sus definiciones ha sido considerado óptimo con respecto a una referencia, en las aplicaciones convencionales de taller puede ser exagerado, o insuficiente.

Así, en el primer caso, si el mismo es exagerado, se tendrá una cantidad de tiempo extra innecesaria aplicada en los procesos, resultando en una pérdida de recursos, en especial del más valioso de la operación; el tiempo. Mientras que, en el segundo, si es insuficiente, se considerarán insatisfechos los requerimientos específicos de las piezas, a pesar de haber utilizado la, aparentemente, más apropiada combinación para obtenerlos. También se encuentra que estos factores suelen poseer una incidencia mayor en los mercados poco modernizados, que proviene de la ausencia de las herramientas adecuadas para la planificación, previsión y sistematización de las

operaciones. Por eso, a nivel nacional, la, comparativamente pequeña cantidad de máquinas herramienta de control numérico computarizado agrava la situación.

Esto, a su vez, promueve la pérdida de recursos empleados en los procesos en función de la exageración en su uso, o la falta de cumplimiento en los requerimientos necesarios de las piezas fabricadas, a partir de, en, en primer lugar, la forma de obtener acabados superficiales en base a necesidades dadas de rugosidad superficial, en operaciones de torneado convencional; en aleaciones altamente comerciales y muy frecuentemente utilizadas, como lo es, en este caso, el acero al carbono AISI 1045.

1.2. Formulación del Problema

¿Cómo puede predecirse el acabado superficial en el mecanizado convencional del acero AISI 1045?

1.3. Objetivos de la Investigación

1.3.1. Objetivo General

Predecir el acabado superficial en el mecanizado convencional del acero AISI 1045 utilizando redes neuronales artificiales.

1.3.2. Objetivos Específicos

- Diagnosticar las mejores condiciones de corte para los ensayos.
- Mecanizar muestras de acero AISI 1045 con los parámetros experimentales obtenidos en el diagnóstico.
- Realizar mediciones de rugosidad superficial de los resultados del proceso de corte.
- Seleccionar la red neuronal artificial que relacionará los parámetros de mecanizado utilizados con la rugosidad superficial resultante del proceso.
- Aplicar la red neuronal artificial seleccionada, con las mediciones obtenidas a través del rugosímetro.

1.4. Justificación de la Investigación

En la actualidad, el maquinado convencional es una de las formas de manufactura más utilizadas y extensas de todo el mundo. Desde piezas enteras hasta acabados y roscas, son todos realizados, mayormente, por alguna forma de mecanizado convencional. Históricamente, los acabados han sido dados de forma empírica, o con una base científica en diversas tablas realizadas para algunos estudios, que muestran proporciones entre los distintos tipos de rugosidades que pueden encontrarse según diferentes formas de fabricación.

Por otro lado, las herramientas computacionales que permiten la simulación convencional para reproducir el proceso y predecir sus características, suelen estar basadas de una forma u otra en el método de los elementos finitos, que puede ser altamente exigente en sus requerimientos de cómputo para diseños complicados. Por esas razones, se considera en extremo conveniente la introducción de una herramienta computacional fácilmente utilizable, de menores requerimientos, que permita también predecir en grandes escalas los resultados de distintas formas de fabricación por mecanizado, altamente adaptable.

Iniciando la misma con unas configuraciones específicas, se estima que el impacto económico y cualitativo de las piezas elaboradas luego de una considerable premeditación y planificación, ha de ser significativamente alto, para permitir y causar el avance de la tecnología y la ciencia de la fabricación. De solucionar el problema, se daría una calidad incrementada en la totalidad de las piezas diseñadas y fabricadas con el método deseado, de manera que, por extensión, se posean mejores condiciones de producción y operación en aquellos sectores donde sean implementadas, que, considerando la amplitud del uso de los productos del sector del mecanizado, pueden ofrecer un impacto positivo considerable en la civilización y la industria.

Así, las organizaciones y entes responsables de la realización de estos procesos de mecanizado, y más aún, los que aprovechan directamente sus creaciones como

resultados, observarían un beneficio rentable, confiable y conveniente en la percepción de la mencionada posibilidad de predicción de los acabados, como una herramienta, en principio iterativa, que les permita calcular, planificar, prever y configurar de manera exacta y más precisa los trabajos y piezas que han de fabricar, con, de manera deseable, distintos tipos de materiales y configuraciones; en cuanto a parámetros y condiciones.

De esta forma, el beneficio económico principal de la red neuronal como herramienta entrenada está en su capacidad de reducir las pérdidas en productividad o calidad. Ya sean las que estén relacionadas con la disminución en los tiempos de producción de piezas que no requieran acabados tan detallados como los estandarizados en las tablas de las que usualmente se calculan los parámetros de corte, o por el aumento en la calidad de aquellas que tengan el caso opuesto, con acabados no lo suficientemente finos en las mismas.

Por su parte, el beneficio social más importante de la investigación es la capacidad de sus resultados de reducir el esfuerzo manual incluido en la producción de los bienes, dado que, al reducir la complejidad del cálculo de los parámetros de corte e incrementar su exactitud se disminuye el tiempo que ha de invertir el personal especializado en dicha tarea y sus asignaciones relacionadas, además de que, al reducir el tiempo de producción de algunas piezas, se reduce también el tiempo de trabajo en ellas, y por mejorar su precisión con respecto a los requerimientos, también se simplifica el trabajo del control de calidad. Todo esto también conlleva la aparición de una mayor cantidad de productos, con una mejor calidad, en y para la sociedad.

A su vez, la investigación también contribuye al beneficio ambiental del mundo, por su capacidad de reducir la cantidad de material desperdiciado en el proceso, a través de la refinación de las formas y métodos del mismo, que conllevan un desgaste menor de herramientas de corte en la realización del mecanizado, y también una menor cantidad de material de trabajo perdido por la utilización de parámetros inadecuados, así como una mayor vida útil de las máquinas por la disminución de los valores de corte

extremos. Todos estos factores incrementan el tiempo en el que el material invertido en el proceso es útil, de forma que disminuyen los desechos del mismo.

1.5. Alcance y Limitaciones

1.5.1. Alcance

Durante el transcurso de la investigación se obtendrá una red neuronal funcional que prediga los acabados superficiales de las operaciones de mecanizado, para el acero AISI 1045, en un torno de banco convencional, y para dos herramientas, una de acero rápido, y una de carburo de tungsteno. En este aspecto, la misma permitirá la recepción de los parámetros concernientes a dichos procesos y la interacción a través de funciones que realicen los cálculos y trabajen las relaciones necesarias para estimar los datos que se requieren como resultados. La red recomendada para la realización del proceso, de tomar las variables del proceso y predecir el acabado de las superficies en términos de sus parámetros de rugosidad superficial, es una multicapa que utilice neuronas del tipo real, con aprendizaje supervisado.

En consecuencia, será posible, a través de las recomendaciones de operación, configurar las máquinas para elaborar las piezas como se requieren, de forma sistemática y precisa, reduciendo las demoras, la necesidad de prueba y error, y disminuyendo las desviaciones de las tolerancias en las piezas, de entre las que estén provocadas por causas asociadas al acabado superficial.

1.5.2. Limitaciones

La investigación se centra en la realización de una red neuronal para, ciertos parámetros variables, como velocidad rotacional de la pieza, profundidad de corte de la herramienta, y velocidad de avance de la misma; y para ciertos parámetros fijos, como la máquina, un torno de banco convencional; las herramientas, de carburo de tungsteno y acero rápido; el material, AISI 1045, la condición de refrigeración, refrigerado y en seco, y las operaciones de mecanizado, principalmente, en torno al cilindrado.

De forma, que los parámetros variables, como la profundidad de corte, la velocidad rotacional, y el avance, han de ser, de hecho, variados dentro de cierto rango establecido en el diseño experimental, para conseguir la capacidad de predicción de la red en base a esos datos básicos, que han de ser los que le permitan simular cualquier circunstancia o situación que se aferre a los parámetros fijos fundamentales. La misma también se ve limitada por el tipo de red a aplicar, que, para el caso, estará dentro de las clasificaciones multicapa, reales, mientras que el aprendizaje de la misma está alrededor de la clasificación del tipo supervisado.

CAPÍTULO II

MARCO TEÓRICO

El marco teórico es definido como el conjunto de ideas, teorías y procedimientos que sirven a un investigador para completar su actividad. Así, Hernández, R., Fernández, C., y Baptista, P. (2014) señalan que un Marco Teórico es “Un compendio escrito de artículos, libros y otros documentos, que describen el estado pasado y actual del conocimiento sobre el problema de estudio. Nos ayuda a documentar cómo nuestra investigación agrega valor a la literatura existente”.

Así mismo, se añade que “Es un proceso de inmersión en el conocimiento existente y disponible que puede estar vinculado con nuestro planteamiento del problema, y un producto que a su vez es parte de un producto mayor: el reporte de investigación... Ello implica exponer y analizar las teorías, las conceptualizaciones y los antecedentes en general, que se consideren válidos para el correcto encuadre del estudio... El marco teórico proporciona una visión de dónde se sitúa el planteamiento propuesto dentro del campo de conocimiento en el cual nos moveremos.” (Hernández, R., Fernández, C., y Baptista, P; 2014:60). De esta forma, en este capítulo se presentan, principalmente; los antecedentes de la investigación y las bases teóricas sobre las cuales se desarrolló, así como algunos términos básicos pertinentes al campo de la misma.

2.1. Antecedentes de la Investigación

Yrady M. y Mujica V. (2020), en su trabajo de grado, realizado en la Universidad José Antonio Páez, para optar al título de ingeniero mecánico, llamado “**Estudio de la Rugosidad Superficial de un Acero AISI 1045 Tratado Térmicamente y Torneado por CNC Mediante la Implementación de una Red Neuronal Artificial**”, tuvieron, como objetivo general, determinar la rugosidad superficial de dicho acero en función de los parámetros del torneado CNC, analizándolos con una RNA.

En dicho trabajo, se concluyó que las RNA son capaces de predecir con alta precisión la rugosidad de dicho acero en variadas condiciones, así como, que mientras más detalles se obtuvieran del material, incluyendo su tratamiento térmico, más precisos serían tales resultados. De igual forma, fue concluyente que el algoritmo Backpropagation, con una múltiple iteración de valores de entrada, fue capaz de requerir la oscilación de las variables de salida a partir de las de entrada, siendo efectivo para entrenar a la red.

Además, obtuvieron entre sus resultados que el valor más preciso fue el del acero templado y revenido, seguido por el acero en su condición original, y luego el normalizado, y el recocido. De entre estos aspectos, es interesante el nivel de exactitud obtenido en el acero en condición inicial, que es el más competente a la investigación. La velocidad de avance fue concluida como el parámetro más significado en el torneado en el estudio, indicando que, a niveles más bajos, sus valores fueron más cercanos a los reales.

El aporte principal de dicha investigación a la presente, fue en la sección inicial de las fases de selección y aplicación de la red neuronal artificial, durante la visualización y concepción de la misma, a través del ejemplo anterior que pudo observarse dentro de los gráficos y álgebra de la elaboración de la arquitectura 3-9-1 de Yrady y Mujica, así como de la estandarización y presentación de sus datos en torno a material y herramientas de corte.

Así mismo, Gómez, R. (2020) en su trabajo de grado, desarrollado en la Universidad José Antonio Páez, como requisito para optar el título de ingeniero mecánico, titulado **“Desarrollo de un Modelo de Redes Neuronales Artificiales que**

Permitan Predecir las Fallas del Acero SAE 1020 Sometido a un Proceso de Mecanizado Mediante un Torno de Control Numérico Computarizado”, tuvo como objetivo general desarrollar un modelo tal que se predijeran las fallas de dicho acero, fabricado por torneado CNC.

En tal estudio, se concluyó que los parámetros más importantes del torneado son la velocidad de corte, la de avance, y la profundidad de corte, así como el material de la herramienta. Además, comparando datos de la red, se encontró que, de los parámetros anteriores, la herramienta y su radio de punta son los más influyentes, señalando que un radio de punta mayor favorecerá mejores acabados, y que la profundidad de corte ha de ser menor al mismo. El margen de error en este estudio fue, también, del 5%, y su mejor resultado en cuanto a la herramienta se dio con un radio de punta de 0.8 mm en una profundidad de corte de 0.25 mm, para un valor de rugosidad de $0.389284975 \mu\text{m}$.

En este caso, el enfoque utilizó de igual manera Backpropagation, con resultados muy exactos y precisos, que en este caso en bajas iteraciones en la entrada generaron poca oscilación en la salida con respecto a los factores reales. Así mismo, determinaron que más neuronas no representan necesariamente una mejor predicción en la red, en las capas ocultas. Esto porque podrían complicar la estructura y aumentar el número de iteraciones, hasta un punto sobre el que no se amplifique necesariamente la exactitud de la predicción.

La mayor influencia de la investigación de Gómez en la actual, fue la forma y base de la realización de la red neuronal artificial, a través de la exposición y utilización del software Joone, como presentación de alternativa a la idea original de utilizar Python, y como forma de identificar las estructuras y funcionamientos básicos del Joone mismo, en cuanto a la aplicación de la red neuronal artificial en el programa; y el aporte del error cuadrático medio más pequeño encontrado en la literatura, utilizado como referencia posteriormente para el entrenamiento de la red.

También, Curra, D., Hernández, L. de la Rosa, J. Zambrano, P. Guerrero, y Pérez, R. (2020), en su artículo titulado **“Estimación del Consumo Específico de Energía en el Torneado de Alta Velocidad del Acero AISI-1045 Utilizando Redes Neuronales”**, tuvieron como objetivo general el desarrollo de un sistema de redes neuronales artificiales capaz de predecir la energía específica consumida en el torneado de alta velocidad de muestras de acero AISI 1045.

Durante tal estudio, los investigadores utilizaron insertos como herramientas de corte, con carburo de tungsteno sin recubrimiento y con cerámicas como materiales. Además, para la caracterización del material de trabajo, realizaron ensayos de dureza con resultados de 258 HB en cinco muestras en la diagonal de un disco. Los insertos en cuestión tuvieron un ángulo en el filo principal de 95° , un ángulo de ataque de 0° , un ángulo de incidencia principal de 7° , y un ángulo de inclinación del filo de corte de 0° .

Los bordes de las herramientas fueron inspeccionados con un microscopio óptico Nikon Epiphot a 50 aumentos, para descartar cualquier defecto con observación directa. Además, se utilizó un rugosímetro Carl Zeiss para la medición de la rugosidad superficial de los insertos mismos; y se encontró que la misma fue menor a 0.25 micrómetros.

Las piezas se mecanizaron en un torno CNC Milltronics de una velocidad máxima de 3000 RPM, a un diámetro de 80 mm y con una longitud de 300 mm, con una relación de longitud/diámetro escogida para evitar inestabilidades elásticas y vibraciones. Además, durante el estudio, se midieron las fuerzas de corte con un dinamómetro piezoeléctrico tipo 9257 B de Kistler, con una tarjeta de adquisición de datos National Instruments modelo PC16024. También, se utilizó el software LabView para almacenar y analizar datos, convirtiendo también la señal analógica del dinamómetro en digital.

Para el procesamiento y ajuste de los datos obtenidos, en la investigación se utilizó Matlab 2017b, por ser un lenguaje de programación de alto nivel con capacidad de graficar y facilidades para las aplicaciones computacionales. Luego, los investigadores pasaron a elaborar un modelo matemático de varios parámetros de corte que les permitiese escribir a la potencia y luego a la energía como función de las fuerzas a medir con el dinamómetro. En la investigación, utilizaron dos insertos, sin refrigeración, con profundidad de corte y avance constantes, variando tres velocidades de corte y cinco tiempos de duración de la prueba. De esta forma, su combinación de variables les dio un número ideal de 30 elementos en la conformación de los modelos de tablas obtenidos del factorial.

Para el diseño de la red, consideraron distintas combinaciones de hiperparámetros, de entre las que escogieron, por su rendimiento, una arquitectura 5-25-3, con funciones sigmoideas y tangentes hiperbólicas en la sección oculta, y unidad lineal idéntica en la capa de salida. El algoritmo utilizado de backpropagation fue el de Levenberg-Marquardt.

Del estudio, se obtuvo, finalmente, la red para predecir el consumo específico de energía en cuestión, utilizando un perceptrón multicapas como el descrito anteriormente. Así mismo, se concluyó que el enfoque de redes neuronales es óptimo hacia este tipo de problemas, porque sus resultados evidenciaron un buen nivel de fiabilidad en la predicción, con desviaciones pequeñas y un error cuadrático medio bajo.

El estudio de Curra, Hernández, de la Rosa, Zambrano, Guerrero y Pérez resultó ser relevante para la presente investigación por su utilización del rugosímetro y el microscopio óptico en la inspección de las superficies, así como por ser una primera exposición explícita al diseño factorial completo utilizado para organizar, inicialmente, los parámetros de corte aplicados a las probetas de mecanizado en el transcurso de la investigación. También, contribuyó a la idea finalmente planteada en las

recomendaciones de realizar parte del estudio aplicando un dinamómetro para la observación de las fuerzas de corte en el conjunto.

Además, Morales, Y. Zamora, Y. Vásquez, P. Porras, M. Bárzaga, J. y López, R. (2018), en su trabajo de nombre “**Comparación entre Redes Neuronales Artificiales y Regresión Múltiple para la Predicción de la Rugosidad Superficial en el Torneado en Seco**”, tuvieron como objetivo obtener un modelo de redes neuronales, y uno de regresión múltiple, a partir de sus experimentos, para realizar su comparación evaluando el error, y así definir en qué medida era conveniente cada enfoque para la predicción de la rugosidad en el torneado sin refrigeración.

En este estudio, también se realizó un diseño factorial completo para mejorar la fiabilidad de los valores. Así mismo, la red neuronal utilizada fue igualmente un perceptrón multicapa, y se tomaron en cuenta la velocidad de corte, de avance, y el tiempo de mecanizado. El material utilizado fue acero inoxidable 316L, y las velocidades utilizadas fueron de 400 m/min y 450 m/min. El algoritmo utilizado en backpropagation fue el descenso de gradiente. En este caso, la efectividad de los modelos se midió, para la regresión múltiple, con sus coeficientes de determinación, y para la red neuronal, con su error medio absoluto.

En el estudio, los ensayos se llevaron a cabo en seco, en un torno CNC multifuncional Okuma, modelo Multus B200-W, con una rotación del husillo de entre 50 y 5000 RPM. La composición química del acero utilizado fue C 0,015 %, Si 0,58 %, Mn 1,50 %, Cr 16,95 %, Mo 2,05 %, Ni 10,08 %, P 0,031 %, S 0,029 % y N 0,059 %. Las probetas fueron de 100 mm de diámetro y 200 mm de longitud, y las herramientas, dos tipos de insertos de carburo de tungsteno: con recubrimiento de carbo-nitruro de titanio, óxido de aluminio y nitruro de titanio, con espesor de 15 micrómetros, y otro con recubrimiento de, solo nitruro de titanio, de espesor 5 micrómetros. La rugosidad, fue medida por el parámetro Ra, con un rugosímetro Carl

Zeiss modelo SURFCOM 1500SD2. El ángulo de incidencia principal fue de 7° , el de ataque de 0° , y el radio de punta de 0.4 mm.

Para las condiciones de corte escogidas, se utilizaron dos avances, dos materiales de herramienta, dos velocidades, y; cuatro tiempos por cada método, lo que hizo un total de ocho tiempos de corte como muestras. Así, se tuvo un factorial de 64 ensayos. Del estudio, en los resultados se observó una fuerte relación entre las variables estimadas y la respuesta, y en la regresión se cumplieron la homocedasticidad, la no autocorrelación de residuos, la normalidad y la media nula.

A la vez, en la red neuronal, se utilizó el algoritmo Levenberg-Marquardt, y los mejores resultados se obtuvieron de la estructura 3-5-1, la misma se codificó con el Neural Network Toolbox de Matlab; los resultados se evaluaron con el error medio absoluto, que se encontró en rangos aceptables. La comparación del error medio absoluto de la regresión con el de la red mostró que la primera podía tener un error de entre 22.78 y 5.153, mientras que en la segunda, podía ser tan bajo como 2.869, y tan alto como 6.946, en un rango mucho menor al de la regresión; por ende, se indicó que la red fue más precisa.

La investigación de Morales, Zamora, Vásquez, Porras, Bárzaga y López; aportó conocimientos importantes en la realización final del diseño factorial completo aplicado en el presente estudio, y fungió además como corroboración adicional de que la forma del perceptrón multicapa podía ser altamente eficiente para la caracterización de la rugosidad. Sirvió también para identificar al error medio absoluto como alternativa al error cuadrático medio, a pesar de que se escogiera finalmente al segundo. También como referencia para escoger los ángulos de ataque del estudio, y para la selección de la arquitectura final de la red, y para comparar la efectividad de la misma con el método de regresión lineal.

Por último, Cárdenas, J. (2017), en su investigación de título “**Optimización de los Parámetros Tecnológicos en el Proceso de Fresado para obtener la Mínima**

Rugosidad en el Acero AISI/SAE 1045”, tuvo como objetivo general establecer modelos predictivos de la rugosidad de un acero AISI/SAE 1045, después de la operación de planeado en CNC, analizando los parámetros tecnológicos de velocidad de corte, velocidad de avance y profundidad de pasada.

Así, durante la investigación, se diseñó el experimento con el arreglo ortogonal de Taguchi como medio de obtención de la cantidad de probetas necesarias para la caracterización adecuada del estudio; tomando en cuenta velocidad de corte, velocidad de avance y de pasada. Así mismo, se utilizó el análisis estadístico de varianza para determinar la influencia de los parámetros en la rugosidad, y se obtuvo un modelo matemático para predecir el valor de la misma luego del proceso de planeado, utilizando regresión múltiple. Luego, se estableció una red neuronal artificial para predecir el valor, y compararlo con el de la regresión lineal.

En la investigación, las probetas tuvieron 60 mm de alto, 115 de largo y $\frac{3}{4}$ de pulgada de ancho. El rugosímetro utilizado fue un MarfSurf PS1 de Mahr, con stylus, y el parámetro de rugosidad para la medición fue el Ra. El centro de mecanizado en cuestión es de Leadwell, modelo v20-i, de 3 ejes y 20 herramientas. Los insertos, por su parte, fueron de carburo de tungsteno recubiertos con nitruro de titanio y aluminio, de Kennametal. Los parámetros fueron una velocidad de corte de 720 ft/min, un avance de 0.06 mm/rev y una profundidad de corte de 0.15 mm, recomendados por la misma Kennametal para las condiciones de corte. Así, se obtuvieron una velocidad de 3503 RPM, y un avance de 210 mm/min.

Luego, se definieron 27 ensayos, desde el arreglo ortogonal, por tener 3 variables con 3 niveles. Los ensayos se realizaron sin un orden específico, y controlando el centro de mecanizado de forma manual, la medida de la rugosidad se realizó dos veces por cada pasada, y el promedio de ambos datos se tuvo en cuenta en el arreglo ortogonal. Así, del arreglo ortogonal y del diseño de Taguchi se encontró que la rugosidad mínima

del estudio fue a 4777 RPM, 48 mm/min, y una profundidad de corte de 0.15 mm, dando un parámetro Ra de 0.095 micrómetros.

En el ANOVA, se observó que el gráfico de cajón de la velocidad del husillo, realizado en MiniTab, posee una distribución de los datos muy dispersos, por lo que se reafirma que la velocidad del husillo afecta en gran medida a la rugosidad, y que entre más baja sea la primera, mayor será la dispersión en los valores de esta última. A mayor velocidad, menor rugosidad.

Sobre el avance, se observa que el primer nivel, el avance más pequeño, los valores de rugosidad son mucho más pequeños y menos dispersos que los de los otros niveles. Así mismo, los niveles más altos, o los avances más rápidos, varían en gran medida y con una dispersión considerable. Por su parte, la dispersión en la profundidad de corte no es significativa, lo que confirma que dicha variable no posee una influencia con una medida tan alta como las otras dos. De la regresión lineal, por su parte, se obtuvieron valores similares para confirmar que, a menor avance y mayor velocidad de corte, suele ser mejor el valor de rugosidad.

En la utilización de la red neuronal se compararon 42 redes neuronales, variando principalmente la cantidad de neuronas, de 1 a 6 por capa, en 6 modelos de redes con una sola capa oculta, y 36 modelos con dos. La función de activación fue la sigmoideal, para romper la linealidad en la correlación de los datos de forma considerable, y se utilizó el descenso de gradiente por lotes, en lugar del estocástico. Todo fue elaborado con la toolbox “nntool” de Matlab. Se indicó además, que el error de la suma cuadrática fue el parámetro de selección de las redes, en base a lo cual se escogió una red neuronal 3-4-5-1 en arquitectura, con un error de 0.013053 a las 2000 iteraciones.

Finalmente, se observó que el error máximo del modelo matemático de la regresión lineal fue muy alto, de hasta 20.21%, mientras que su error promedio fue de 11.99%. Por otro lado, el error máximo de la red neuronal fue de 7.63%, con un promedio de 3.66%. Dicho último valor promedio hace a la red aceptable porque el

diseño del experimento se hizo con una confiabilidad del 95%, para lo que se obtuvo un error menor al 5%. Así, en este estudio también pudo concluirse que la red neuronal es más efectiva que la regresión lineal.

Así, el estudio de Cárdenas contribuyó a la investigación actual a través de la creación del arreglo ortogonal, que mostró una aproximación directa al método del arreglo de Taguchi, pero su mayor influencia se vio en la utilización de y en los resultados encontrados por su aplicación del ANOVA, en el cual se obtuvieron nociones clave acerca de la influencia final de cada uno de los parámetros de corte en el acabado superficial, que permitieron luego deducir, inferir, cuantificar y concluir; fundamentándose en las micrografías, los parámetros Ra medidos, y los valores de corte utilizados en el presente estudio, las relaciones implícitas entre todas las variables investigadas. También se confirmaron el uso del descenso de gradiente por lotes, y la ventaja de las redes neuronales sobre la regresión lineal, con base en esta investigación.

2.2. Bases Teóricas

2.2.1. Mecanizado

La manufactura por mecanizado es un método de fabricación que se fundamenta en la remoción de material para la modificación de las formas y las dimensiones. Como vía de fabricación popular, el maquinado es utilizado tanto para la formación de piezas completas como para dar los acabados superficiales requeridos en trabajos ya realizados, por sus capacidades de mejorar las rugosidades alcanzadas en las superficies de los mismos, lo cual resulta altamente conveniente tras procesos de, por ejemplo, formado y moldeado.

En cuanto al término “convencional”, él se utiliza para hacer referencia a operaciones de mecanizado que se llevan a cabo a través de máquinas herramienta clásicas, que son operadas de manera tradicional por personal humano con controles analógicos, para diferenciarlo del mecanizado avanzado o automático, realizado

mayormente por máquinas que, aunque han sido programadas y preparadas por personal humano, operan de manera principalmente autónoma.

Similarmente al resto de los procesos de manufactura, los de mecanizado se estudian en forma de sistema. En este caso, dicho sistema es integrado por la pieza a trabajar, la herramienta de corte a utilizar, la máquina herramienta en la que se realizará, y el personal que la operará. Por ello, la mayoría de los factores importantes que permiten controlar el maquinado se ven interrelacionados en torno a esos cuatro, precisamente. Durante el mecanizado, es vital considerar las fuerzas que actúan en la herramienta y el desgaste de las mismas, la potencia que consumen las operaciones, las temperaturas alcanzadas en ellas, los fluidos que se utilizan al cortar, y los acabados superficiales de las piezas.

2.2.1.1. Torneado

El torneado es un proceso que posee la capacidad de producir partes que, de manera básica, tienen formas redondas. Esto incluye formas cónicas, curvadas o ranuradas, mayormente rectas. Durante su realización, la pieza a trabajar rota, y la herramienta con la que se trabaja se mantiene en un estado de avance longitudinal o transversal, principalmente, realizando una acción de corte que permite mecanizar al material.

Los procesos de torneado se realizan en una máquina herramienta llamada torno, y los mismos utilizan herramientas de una sola punta y, en su forma más básica, se encuentran entre las máquinas convencionales en la versión del torno de banco clásico (Ver figura 1). Así mismo, como proceso el torneado posee una serie de relaciones basadas en un modelo matemático que puede ayudar a diseñar las operaciones en él (Ver tabla 1).




Figura 1: Torno de Banco.

Fuente: Kalpakjian (2008).

Tabla 1: Fórmulas y Parámetros del Torneado.

N = Velocidad de giro de la pieza de trabajo, rpm

f = Avance, mm/rev o pulg/rev

v = Velocidad de avance, o velocidad lineal de la herramienta a lo largo de la pieza de trabajo, mm/min o pulg/min

$$= fN$$

V = Velocidad superficial (tangencial) de la pieza de trabajo, m/min o pies/min

$$= \pi D_o N \text{ (para velocidad máxima)}$$

$$= \pi D_{prom} N \text{ (para velocidad promedio)}$$

l = Longitud de corte, mm o pulgadas

D_o = Diámetro original de la pieza de trabajo, mm o pulgadas

D_f = Diámetro final de la pieza de trabajo, mm o pulgadas

D_{prom} = Diámetro promedio de la pieza de trabajo, mm o pulgadas

$$= (D_o + D_f)/2$$

d = Profundidad de corte, mm o pulgadas

$$= (D_o + D_f)/2$$

t = Tiempo de corte, s o min

$$= l/fN$$

MRR = mm³/min o pulg³/min

$$= \pi D_{prom} d f N$$

Torque = N · m o libras · pie

$$= F_c D_{prom} / 2$$

Potencia = kW o hp

$$= (\text{Torque})(\omega), \text{ en la que } \omega = 2\pi N \text{ rad/min}$$

Nota: Las unidades provistas son las que se utilizan generalmente; sin embargo, en las fórmulas, deben usarse y verificarse las unidades apropiadas.

Fuente: Kalpakjian (2008).

2.2.1.2. Herramientas

Una herramienta es, en el contexto del mecanizado, una pieza de composición altamente dura y resistente que es utilizada para cortar, deformar o remover el material de una pieza de trabajo, a través del proceso de maquinado desde la máquina herramienta. En el caso del torneado, las herramientas pueden tomar distintas formas, como insertos de carburo de tungsteno, barras de acero rápido, y cuchillas orientables hechas de uno de ambos materiales, u otros, como los nitruros, otras aleaciones de aceros, cerámicos, o diamantes policristalinos. Las herramientas tienen bordes con filos adaptados a su aplicación, y existen infinidad de ellas para distintas aplicaciones, tanto con variadas formas de recubrimientos como con diversas geometrías.

- **Cuchillas Orientables**

Dentro de las herramientas que se pueden utilizar en el torneado, las orientables poseen un lugar muy importante, por su integridad estructural y sus geometrías particulares (Ver figuras 2 y 3). Las mismas poseen cuerpos generalmente hechos con aceros de herramienta de alta resistencia para soportar el esfuerzo del portaherramientas, y sus nomenclaturas y dimensiones son muy similares, en las secciones de los filos, a las de los insertos y barras, también utilizados en el corte. Por otra parte, las cuchillas orientables tienen una desventaja con respecto a tales opciones, y suele ser su menor cantidad de filos que desgastar, en comparación con los insertos, que es, no obstante, compensada por sus, usualmente, mayores dimensiones.




Figura 2: Cuchilla orientable con fillos de carburo de tungsteno.

Fuente: Catálogo online, Impero Tools. (s.f.)




Figura 3: Cuchilla orientable con fillos de acero rápido.

Fuente: Catálogo online, Impero Tools. (s.f.)

- **Desgaste y Vida Útil de las Herramientas**

A través del uso, las herramientas van perdiendo su forma y, en parte, sus propiedades, por efecto de las grandes presiones y temperaturas a las que son sometidas. Ese cambio en sus contornos puede alcanzar una cúspide catastrófica en el momento de la falla, luego de que los bordes han sido lo suficientemente desgastados para provocar una fractura de algún tipo, de entre las cuales las más características son las roturas frontales, en el flanco y en la nariz de la pieza (Ver figura 4).

En el caso del desgaste frontal, se le llama cara de ataque de la herramienta a la superficie en la que la viruta pasa durante su formación. Uno de estos desgastes toma forma de cavidad o cráter, y se origina tanto en el filo de corte como a una distancia del área de contacto, y con el tiempo se ensancha, alarga y profundiza, alcanzando los extremos de dicho borde. Es característica de materiales dúctiles que producen virutas continuas, y debilita el filo y lo rompe.

El desgaste en el flanco está siempre presente, sin importar el trabajo o material de la herramienta, ni de las condiciones de corte. El flanco es la cara de la herramienta en la que el filo de corte más grande está ubicado, la porción de la herramienta en contacto con el trabajo donde la viruta se separa, y resiste las fuerzas de avance. Este desgaste inicia en el extremo del filo y se ensancha hasta crear un área de contacto plana llamada “zona de desgaste”. Cuando los materiales no forman virutas continuas, promueven poco desgaste de cráter en la cara de la herramienta, y en esos casos, el desgaste en el flanco se hace el más importante en la falla de la misma. Esta clase de falla también puede redondear el eje de corte, y la zona de desgaste suele estar en contacto con la pieza, por lo que promueve acabados superficiales poco refinados.

El tercer tipo de desgaste es el de la punta de la herramienta, o de la nariz, y es muy similar al del flanco, pero puede ser considerado por separado. Este suele darse a un ritmo mucho más rápido que el del flanco, especialmente con radios de punta pequeños y con materiales abrasivos. Esta clase de desgaste es la más peligrosa para el acabado superficial, porque el redondeo de la punta conlleva una pérdida de filo que puede llegar incluso a modificar las dimensiones terminadas de las piezas con respecto a las esperadas, antes de que el desgaste en el flanco se convierta en un factor.




Figura 4: Desgaste de las herramientas.

Fuente: Kalpakjian (2008).

Con base en el desgaste visible que sufren las herramientas, pueden preverse las posibles causas que las harán fallar, para reducir su incidencia mediante la modificación de ciertos parámetros, y puede, además, intentarse un reacondicionamiento de las mismas que alargue su vida útil. Esto último, porque en ocasiones las mismas se encuentran en un rango de integridad en el que es posible utilizar máquinas e instrumentos especializados que permitan su modificación para restaurar en una cierta medida los filos de corte y sus bordes, de manera que las herramientas pueden funcionar durante algún tiempo más. La vida útil de la herramienta también puede ser estimada a través de la Ecuación de Taylor, tomando en cuenta el material de la misma, el material a trabajar, y las condiciones de corte:

$$VT^n = C$$

Que se encuentra del gráfico logarítmico que se obtiene al mostrar la función de la velocidad de corte contra el tiempo de vida, en el cuál n es la pendiente de la curva, y C es una constante igual a la intersección de la misma y el eje de las ordenadas, donde va la velocidad de corte. Esta velocidad C , es igual a la máxima que puede tener el corte para que la herramienta tenga una vida útil de un minuto. Aunque en teoría los materiales deberían ser los mismos, por lo general, diferentes fabricantes pueden poseer distintas gráficas de vida útil de la herramienta dependiendo de leves diferencias entre sus composiciones o sus ensayos. Así, el valor de C es igual al valor de velocidad de corte que se interseca con el eje X (Ver figuras 5 y 6).

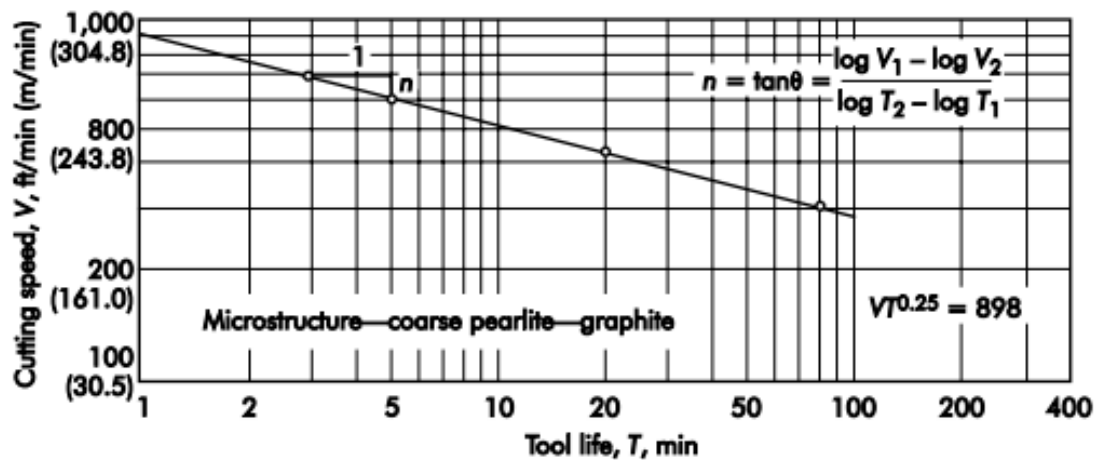


Figura 5: Gráfica logarítmica de vida útil de una herramienta de carburo de tungsteno de Kennametal.

Nota: “Los valores de C y n suelen estar sujetos a avances, profundidades de corte y geometrías de la herramienta particulares. Cambios significativos en ellos, podrían cambiar el valor de la constante C , y pueden causar un cambio muy pequeño en el exponente n . En general, n es más bien función del material de la herramienta de corte. Para algunos materiales típicos, el mismo es: HSS: $n = 0.1$ a 0.15 , Carburos: $n = 0.2$ a 0.25 , Cerámicos: $n = 0.6$ a 1.0 ”.

Fuente: Nee, Dufraine, Evans, Hill. (2010).




Figura 6: Curvas de vida útil de herramienta para distintos materiales de corte.

Nota: “De HSS a cerámico, los valores de C son de alrededor de 200, 400, 3000, y 11000, respectivamente. De la misma manera, los valores de n pueden corroborarse a través de esos mismos gráficos, para cada aplicación”.

Fuente: Kalpakjian (2008).

2.2.2. Acabado Superficial

El acabado superficial óptimo es uno de los principales objetivos de una operación de mecanizado. Un gran número de piezas que son realizadas con estos métodos, como bocinas y ejes, han de mantenerse en contacto intenso con velocidades muy altas, ocasionando fricciones enormes si los acabados de las mismas no son los más convenientes. Este parámetro influencia fuertemente características de las eficiencias de trabajo como el desgaste de las piezas, su pérdida de lubricación y la necesidad de ella, su estética, y su capacidad de resistir a la fatiga.

2.2.2.1. Rugosidad Superficial

El parámetro que muestra como una magnitud al acabado superficial, es la rugosidad superficial, indicando una medida de qué tan lisa o rugosa es una superficie;

y la misma varía dependiendo del proceso de manufactura que se haya utilizado para realizar la pieza (Para el torneado, ver la tabla 2). Es de las llamadas irregularidades menores en la superficie, y en ocasiones no es posible observarlas a simple vista, y la principal responsable de su magnitud es la herramienta de corte.

Tabla 2: Rugosidad promedio del proceso de torneado.

Rugosidad promedio en micrómetros – Ra μm													
Proceso	50	25	12.5	6.3	3.2	1.6	0.80	0.40	0.20	0.10	0.05	0.025	0.012
Torneado													

Fuente: ANSI/ASME (1985).

Dentro del estudio de la rugosidad, existen términos importantes que han sido elaborados para crear una nomenclatura con la que referirse a las distintas posibles geometrías que han de encontrarse en el estudio de la rugosidad. Entre ellas se encuentran la superficie geométrica, que es la ideal y sin rugosidades como aparece en los dibujos técnicos. La real, que es la que en verdad se encuentra en la pieza, y la de referencia, a partir de la cual se toman los parámetros de rugosidad, con la forma ideal de la geométrica; y que puede calcularse con el método de mínimos cuadrados (Ver figuras 7 y 8), así como el perfil real de la misma, obtenido al observar la línea formada por la intersección de un plano perpendicular a la superficie real, y a ella misma (Ver figura 9).




Figura 7: Superficie geométrica de la pieza.

Fuente: Pereira (2004).




Figura 8: Superficie real de la pieza.
Fuente: Pereira (2004).




Figura 9: Perfil real de una sección de la pieza.
Fuente: Pereira (2004).

De la misma manera, en el estudio bidimensional existen dos líneas importantes que corresponden a la media de mínimos cuadrados, y a la media aritmética. La primera tiene la forma del perfil geométrico, y divide el perfil para que, dentro de la longitud básica, la suma de los cuadrados de las desviaciones desde la línea sea mínima. La segunda es paralela a la dirección general del perfil, dentro de la longitud básica. En este caso, se divide el perfil de forma que la suma de áreas entre ella y el perfil, es igual en la superior y en la inferior (Ver figuras 10 y 11).

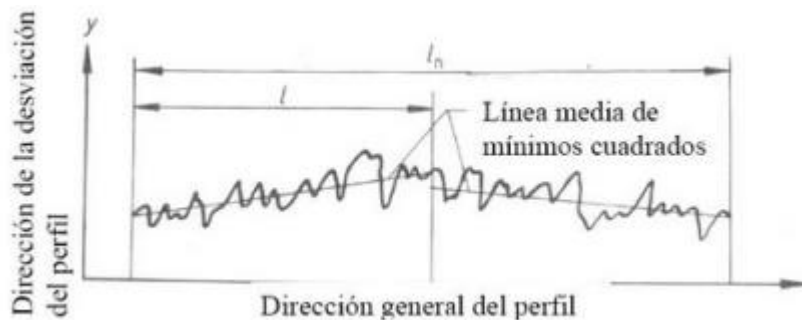


Figura 10: Línea media de los mínimos cuadrados.
Fuente: Pereira (2004).




Figura 11: Línea media aritmética.
Fuente: Pereira (2004).

En ambos casos, se le llama longitud básica, l , a la que se utiliza para separar las irregularidades de la rugosidad. Por otro lado, se le llama longitud de evaluación, l_n , a la que determina los valores de los parámetros de rugosidad. Además, ella comprende una o más longitudes básicas. Así mismo, las secciones del perfil suelen dividirse en cresta local, entre dos mínimos adyacentes del perfil; el valle local, comprendido entre dos máximos adyacentes del mismo, y la cresta, dirigida hacia el exterior del cuerpo, de forma que una, dos intersecciones consecutivas de dicho perfil, con la línea media (Ver figuras 12 a 14).




Figura 12: Cresta local del perfil.
Fuente: Pereira (2004).




Figura 13: Valle local del perfil.
Fuente: Pereira (2004).




Figura 14: Cresta del perfil.
Fuente: Pereira (2004).

2.2.2.2. Medición de la Rugosidad

La rugosidad se especifica en conformidad con la norma ISO 1302-1978 sobre dibujos técnicos, y sus características deben mostrarse en función del símbolo básico. Así, la nomenclatura incluirá, *a*, como el parámetro Ra de la rugosidad, en micrones o micropulgadas, o en números de grado de rugosidad, de N1 a N12. *b*, el método de producción, tratamiento o recubrimiento. *c*, la longitud del muestreo realizado, *d*, la dirección del marcado, *e*, la cantidad que se removerá mediante maquinado. Y *f*, donde se colocan parámetros adicionales, entre paréntesis (Ver figura 15).




Figura 15: Forma de expresar las especificaciones de la rugosidad.
Fuente: ISO (1978).

Una de las formas principales de medición de la rugosidad, es a través de un instrumento llamado “Rugosímetro de palpador mecánico”, también conocido como “Rugosímetro stylus”. Dicho instrumento funciona amplificando una señal eléctrica

generada en él por un palpador que traduce las irregularidades del perfil de la sección de la pieza a medir. Sus elementos principales incluyen al palpador mismo, junto a un mecanismo de soporte y arrastre, un amplificador electrónico, un calculador, y un registrados (Ver figura 16).




Figura 16: Rugosímetro de Palpador Mecánico.
Fuente: s.n. (s.f.)

Para utilizar el rugosímetro de palpador mecánico, el mismo ha de ser previamente calibrado y preparado en un montaje en una base, preferiblemente diseñada para él. Luego, la medición se realiza moviendo el palpador a través de la superficie objetivo, en una dirección apropiada. Así, los productos metálicos procesados, por ejemplo, son comúnmente medidos de manera perpendicular a la dirección del procesamiento, de manera que el rugosímetro capte las características superficiales de manera más confiable. De igual forma, la velocidad de captación de la medida es un elemento clave para la medición adecuada. Primero, la medición es realizada lentamente, y la velocidad se incrementa hasta que no ocurren fluctuaciones en los valores medidos.

Los parámetros con los que se expresa la rugosidad, se definen en función de las líneas de referencia y de los perfiles reales de las mediciones. Así, con respecto a las alturas de los perfiles reales, se tienen, la altura de una cresta del perfil, y_p , que se mide entre la línea media y el punto más alto de una cresta. La profundidad de valle del perfil, y_v , análoga a la altura de cresta, con el punto más bajo de un valle.

La altura de una irregularidad del perfil, que es la suma de los dos valores anteriores. La altura máxima de una cresta se denomina R_p , y la profundidad máxima de un valle, R_m . Ambos corresponden a los valores más grandes que pueden tener tanto la altura como la profundidad dentro de una longitud base. Igualmente, la altura máxima del perfil R_y , es la máxima distancia que exista entre la cresta más alta y el valle más bajo (Ver figuras 17 a 20).




Figura 17: Altura de una cresta del perfil.

Fuente: Pereira (2004).




Figura 18: Profundidad de un valle del perfil.

Fuente: Pereira (2004).




Figura 19: Altura de una irregularidad del perfil.
Fuente: Pereira (2004).






Figura 20: Valores máximos de la profundidad, la altura de una cresta y la del perfil.
Fuente: Pereira (2004).

En la dirección transversal, se tienen el paso de las irregularidades del perfil, que es la longitud de la línea media que tiene dentro una cresta y un valle, consecutivos. El paso de las crestas locales, que incluye la sección que se limita por la proyección sobre la línea media de los dos puntos de mayor altura de las crestas locales que estén más cerca del perfil. Y luego, la longitud desarrollada del perfil, como L_0 , al desarrollar el perfil en línea recta, y la relación de longitud del perfil, l_r , entre la longitud desarrollada y la básica. Luego está la densidad de las crestas del perfil, como la cantidad de crestas que existen en una unidad de longitud (Ver figuras 21 a 23).



$$S_m = \frac{1}{n} \sum S_{mi}$$

Figura 21: Pasos medios de las irregularidades del perfil.
Fuente: Pereira (2004).



$$S = \frac{1}{n} \sum S_l$$

Figura 22: Pasos de las crestas locales del perfil.
Fuente: Pereira (2004).




Figura 23: Longitud desarrollada, relación de longitud y densidad de las crestas.
Fuente: Pereira (2004).

Mientras que, con respecto a la forma en la que se presentan las irregularidades en el perfil, los parámetros que deben considerarse son la longitud portante del mismo, μ_p , la suma de las longitudes de los segmentos que se obtienen al cortar las crestas, con

una línea que es paralela a la media, dentro de la longitud base, para un nivel dado. La tasa de longitud portante, t_p , la relación entre la longitud portante y la longitud básica. Y la curva de la tasa de longitud portante, que muestra como dicha relación varía con el nivel de corte del perfil (Ver figuras 24 y 25).




Figura 24: Segmentos de longitud portante.

Fuente: Pereira (2004).




Figura 25: Curva de la tasa de longitud portante.

Fuente: Pereira (2004).

2.2.3. Acero AISI 1045

El AISI 1045 es un acero al carbono medio, de entre 0.420 y 0.50% de carbono, (también puede contener manganeso, azufre y fósforo en muy pequeñas cantidades), de entre 570 y 700 MPa, con una dureza Brinell de entre 170 y 210. Se considera un material relativamente dúctil y sin una dureza extrema, y se caracteriza por una alta soldabilidad, alta maquinabilidad, y altas resistencias y propiedades de impacto. Es común encontrarlo normalizado o laminado en caliente. Normalmente su viruta es dúctil comparada con la de aceros más duros, y es posible trabajarlo en mecanizado a velocidades altas y bajas, así como a profundidades de corte y avances elevados.

2.2.3.1. Parámetros de Mecanizado

Durante el estudio de la rugosidad en el acero, será necesaria una referencia de rangos en los que trabajar el mismo para registrar los valores de la misma en él, configurando diferentes magnitudes de avances, velocidades rotacionales y profundidades de corte. En la tabla 3 se observan los valores seleccionados para uno de estos experimentos, y en la figura 26 se observan graficados sus resultados de rugosidad.

Como puede observarse en dicha figura, para las velocidades de corte por encima de 451 m/min con avances pequeños de entre 0.01 y 0.1 mm/rev, los incrementos en la velocidad de corte tienen influencias pequeñas en la rugosidad superficial, pero para avances mayores, el comportamiento cambia. Para un avance de 0.2 mm/rev existe una tendencia a reducir la rugosidad superficial al incrementar la velocidad de corte. Mientras que con avances grandes y velocidades más pequeñas a 451 m/min, se observan incrementos grandes en la rugosidad con su aumento.

Por otra parte, para avances muy pequeños de 0.01 mm/rev, y velocidades de corte bajas, la rugosidad disminuye mucho. Por otra parte, con avances pequeños y velocidades bajas, la rugosidad incrementa enormemente, siendo casi la más alta del estudio. El punto de mejor rugosidad es el que tiene la mayor velocidad con el menor avance, a 0.01 mm/rev y 722 m/min. En las velocidades de corte fijas, la rugosidad incrementa siempre que lo hace el avance, agravándose dicho fenómeno sobre 0.1 mm/rev. No obstante, por debajo de ese avance, a velocidades muy pequeñas, la rugosidad también aumenta. De manera que, para el AISI 1045, durante el maquinado, la velocidad muy baja con el avance bajo, no es conveniente, y la velocidad muy alta con el alto, tampoco (Ver figura 27).

Tabla 3: Parámetros de toma de muestras.

Nº test.	Cutting speed [m/min]	Feed rate [mm/ rev]	Depth of cut [mm]
1	100	0,01	0,5
2	100	0,1	0,5
3	100	0,2	0,5
4	451	0,01	0,5
5	451	0,1	0,5
6	451	0,2	0,5
7	722	0,01	0,5
8	722	0,1	0,5
9	722	0,2	0,5

Fuente: Jacas-Cabrera, Rodríguez-Moliner, Lopes-Da Silveira (2015).




Figura 26: Resultados de rugosidad para distintas configuraciones de corte, en función de la velocidad de corte.
Fuente: Jacas-Cabrera, Rodríguez-Moliner, Lopes-Da Silveira (2015).




Figura 27: Resultados de rugosidad para distintas configuraciones de corte, en función del avance.
Fuente: Jacas-Cabrera, Rodríguez-Moliner, Lopes-Da Silveira (2015).

2.2.4. Redes Neuronales Artificiales

A veces abreviadas como redes neuronales simplemente, son sistemas de cómputo inspirados en y que emulan a los sistemas neuronales biológicos que constituyen los cerebros animales. Así, las mismas se unen como nodos que son llamados neuronas artificiales, y cada una de las conexiones entre ella funciona como las sinapsis del cerebro. Cada una transmite a otras neuronas y entre las conexiones existen los llamados “pesos”, que se ajustan mientras que el aprendizaje procede. Los mismos incrementan o decrecen las intensidades de las conexiones, y por lo general, las señales progresan desde la primera capa, hasta la última, atravesando las capas intermedias, en algunas ocasiones, varias veces (Ver figura 28).




Figura 28: Arquitectura de una red neuronal artificial.

Fuente: Hertz, Krogh, Palmer (1991).

2.2.4.1. Perceptrones

Los perceptrones son algoritmos para aprendizaje supervisado de clasificadores binarios. Estos últimos son, a su vez, funciones que deciden si una entrada, representada por un vector de números, pertenece a alguna clase específica. Es un tipo de clasificador lineal, es decir, un algoritmo de clasificación que predice con bases en una función de predicción lineal combinando un conjunto de pesos con el vector en cuestión.

De entre los perceptrones, destacan los perceptrones múltiples. Estos son clases de redes neuronales artificiales de avance hacia adelante, que consisten de, al menos, tres capas de nodos. Primero una de entrada, luego una oculta y finalmente una de salida. A excepción de los nodos de entrada, en el perceptrón múltiple cada neurona utiliza una función de activación no lineal. El mismo utiliza un algoritmo de aprendizaje llamado Backpropagation, para el entrenamiento. Sus capas múltiples y su activación no lineal lo distinguen del perceptrón común, y puede distinguir datos que no son linealmente separables (Ver figura 29).

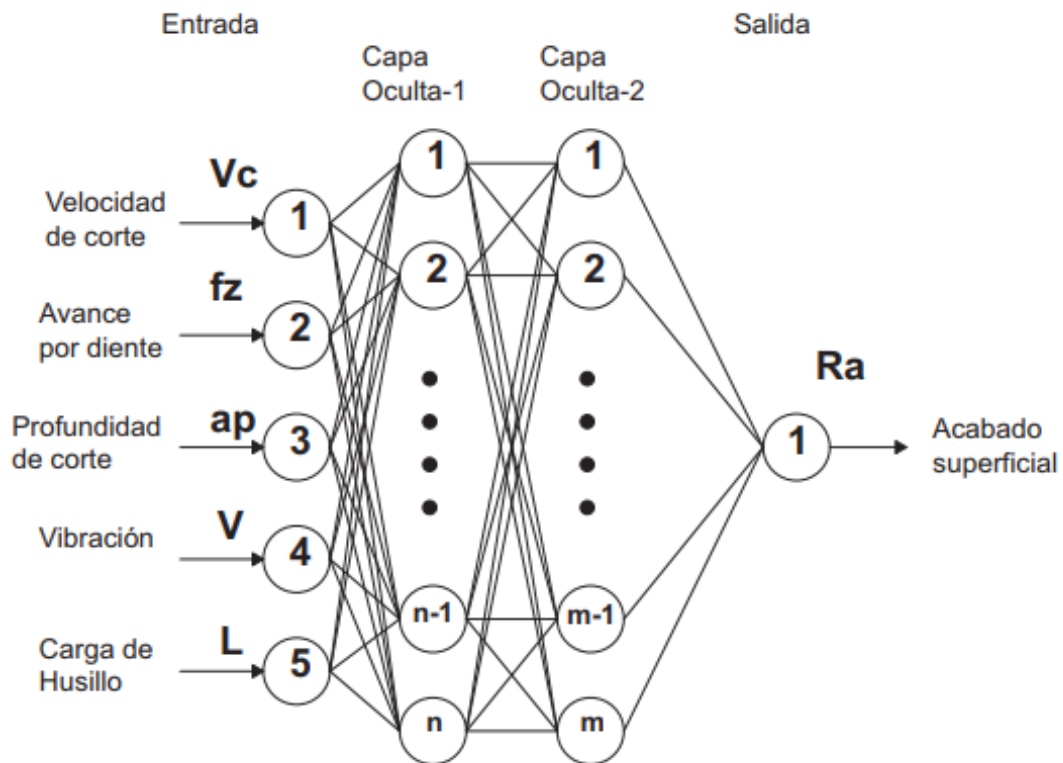


Figura 29: Arquitectura de un Perceptrón Multicapa.
Fuente: Aguilar (2006).

2.3. Definición de Términos Básicos

Acero AISI 1045: Acero al carbono medio, con alrededor de 0.45% de carbono y con posibilidad de contener algunos aleantes, relativamente dúctil y maquinable.

Herramienta de Corte: Herramienta de bordes afilados con ángulos definidos, que se utiliza en la máquina herramienta para producir la remoción de material de la pieza de trabajo.

Red Neuronal Artificial: Sistema de cómputo que emula la forma en la que las neuronas biológicas se comunican en el cerebro animal. Colección de nodos unidos que procesan señales variando valores entre sus interconexiones, para producir salidas a partir de entradas.

Refrentado: Operación de mecanizado en la que la herramienta de corte realiza superficies planas en una cara de la pieza en el torno.

Rugosidad Superficial: Magnitud con la que se estudian los acabados superficiales, una medida de las irregularidades finamente microespaciadas en las superficies.

Rugosímetro: Instrumento de medición con el que se estudian las magnitudes de rugosidad superficial en las superficies de un material.

Simulación: Imitación de una situación o un proceso. En este contexto, suele referirse a la predicción de un fenómeno con un modelo computacional, para propósitos de estudio o análisis del mismo.

Torneado Convencional: Operación de mecanizado en la que se remueve material de la pieza de trabajo rotativa con una herramienta de corte de movimiento mayormente lineal; sin asistencia de controles computarizados.

Torno de Banco: Máquina herramienta que permite realizar el torneado convencional, equipando un husillo donde girar la pieza, un carro donde sostener una torreta, y una torreta donde sostener la herramienta; así como otro que permite equilibrar a la pieza con un punto, más un sistema motriz y transmisión.

CAPÍTULO III

MARCO METODOLÓGICO

En una investigación el marco metodológico se define como el uso de métodos, técnicas, instrumentos, estrategias y procedimientos a utilizar en el estudio que se desarrolla. Al respecto, Balestrini (2006 p.125) define “el marco metodológico como la instancia referida a los métodos las diversas reglas, registros, técnicas y protocolos con los cuales una teoría y su método calculan las magnitudes de lo real”. Según Arias, F. (2012), el Marco Metodológico comprende el “conjunto de pasos, técnicas y procedimientos que se emplean para formular y resolver problemas”. (p.78). En este capítulo se presentan los aspectos correspondientes al tipo de investigación desarrollada, así como una descripción secuencial de forma detallada de las herramientas metodológicas empleadas para el logro de los objetivos.

Además, el enfoque de la investigación es, generalmente, identificado como la naturaleza del estudio, donde el mismo puede ser “cuantitativo, cualitativo y mixto” de acuerdo a Hernández, R., Fernández, C., y Baptista, P. (2014). También, indican los mismos autores, que el enfoque cuantitativo “Es secuencial y probatorio”, en él, cada etapa precede a la siguiente y no pueden eludirse pasos. Señalan, de igual forma, que “Parte de una idea que va acotándose y, una vez delimitada, se derivan objetivos y preguntas de investigación, se revisa la literatura y se construye un marco o una perspectiva teórica”.

Luego, comentan que “De las preguntas se establecen hipótesis y determinan variables; se traza un plan para probarlas (diseño); se miden las variables en un determinado contexto; se analizan las mediciones obtenidas utilizando métodos estadísticos, y se extrae una serie de conclusiones respecto de la o las hipótesis”. Dado que, en efecto, durante la realización de la investigación, la forma de llevarla a cabo fue secuencial, con objetivos y preguntas, con fases definidas; se utilizaron variables,

y aún más importante, datos numéricos y métodos estadísticos, para obtener una serie de conclusiones; se define al enfoque de la presente investigación como cuantitativo.

3.1 Tipo de Investigación

Define Raffino María (2019), “Una investigación es un procedimiento metódico, objetivo y comprobable de adquisición de nuevos conocimientos, o de aplicación de dichos conocimientos a la solución de problemas específicos.” Así como también Arias, Fidias (2012), señala que, “Los tipos de investigación pueden agruparse según el objetivo que persiguen, el nivel de profundización, la forma de hacer inferencia estadística, la forma de manipular variables, el tipo de datos o el período de tiempo de estudio.” El tipo de investigación del presente trabajo es un “Proyecto Especial”, el cual está definido según Sabino (1992) en, “El concepto de proyecto especial está relacionado con la existencia de una unidad técnico-administrativa llamada a cumplir funciones de desarrollo integral en un área determinada”. Para el autor el proyecto especial es una combinación entre la tecnología y la administración creada para el abordaje completo de un contexto específico.

3.2 Diseño de la Investigación

Por otra parte, al hablar de diseño de la investigación, Sabino (1992) expresa que “Su objeto es proporcionar un objeto de verificación que permita constatar hechos con teorías, y su forma es la de una estrategia, o plan general que determina las operaciones para hacerlo”. En tal sentido, para el presente Trabajo de Grado, se indica que el diseño de investigación es de campo y documental, ya que los datos fueron obtenidos de la realización de ensayos físicos sobre piezas trabajadas en la escuela de ingeniería mecánica de la Universidad José Antonio Páez; y para el desarrollo de dichos ensayos se consultaron fuentes documentales que contribuyeron al diseño experimental.

Sobre el particular, Arias, F. (2012); señala que se entiende por investigación de campo: “Al análisis sistemático de problemas en la realidad, con el propósito bien sea de describirlos, interpretarlos, entender su naturaleza y factores constituyentes, explicar

sus causas y efectos, o predecir su ocurrencia, donde los datos recogidos de forma directa son de la realidad”, se tiene además un diseño de investigación de tipo documental, y el mismo autor, Arias, F. (2006) dice que este tipo de investigación se refiere “Al proceso basado en la búsqueda, análisis, recuperación, interpretación y crítica de datos secundarios”. Como en cualquier investigación, la intención de este diseño es el aporte de nuevos conocimientos.

3.3 Nivel de la Investigación

El nivel de la investigación Según Arias, F (2012), “Se refiere al grado de profundidad con que se aborda un fenómeno u objeto de estudio”. (p. 145). A partir de este concepto se realiza el registro de documentos de definiciones que permitan describir fenómenos, situaciones y/o contextos. En este trabajo se realizó una investigación descriptiva porque se caracterizó un hecho, para establecer su comportamiento con base a un diseño de investigación bibliográfico, como parte del proyecto especial que caracteriza al estudio.

3.4 Población y muestra

3.4.1 Población

Según, González y Salazar, (2008) “Una población o universo puede estar referido a cualquier conjunto de elementos de los cuales se pretende indagar y conocer sus características, o una de ellas, y para el cual serán válidas las conclusiones obtenidas en la investigación.” Para este estudio, la población estuvo compuesta por, principalmente, el acero AISI 1045 trabajado a través del torneado convencional, pues sobre él se pretendió indagar, a través de la experimentación y las redes neuronales artificiales. Y, por ende, en todos aquellos entes que se encuentren relacionados con ellos en los ensayos; como, los tornos de banco y las cuchillas orientables.

3.4.2 Muestra

Según Arias, F. (2012) “La muestra es un subconjunto representativo y finito que se extrae de la población accesible” (p.83). Con base a este concepto, se puede precisar

como la muestra en este estudio, a los acabados superficiales que se realizaron en el acero AISI 1045 definido en la población, que fueron, posteriormente, analizados en la red neuronal realizada. La muestra es no probabilística de tipo intencional dado que los elementos escogidos se hacen con base a los criterios de los investigadores, en este caso, cilindros de acero.

3.5 Técnicas de Recolección de datos

Las técnicas son particulares, Arias (2006) define como técnicas y recolección de datos “El procedimiento o forma particular de obtener datos o información”. Se hizo uso de técnicas que permitieron obtener datos o información acerca del caso de estudio. Para esta investigación, la técnica de recolección de datos fue, en primer lugar, la revisión documental, donde se agruparon las distintas variables involucradas en los procesos de corte y sus rangos de efectividad más convenientes, ya descritos por varios investigadores y especialistas en el ámbito, para luego proceder al método de observación, en el cual se realizaron ensayos y se tomó nota de sus resultados para utilizarlos como data.

3.5.1 Observación Directa

Según Hernández, Fernández y Baptista (2014), expresan que “la observación directa consiste en el registro sistemático, válido y confiable de comportamiento o conducta manifiesta”. A través de esta técnica el investigador puede observar y recoger datos mediante su propia observación. Esta técnica se utilizó en el proyecto de investigación para la observación de las condiciones en forma de rugosidad superficial de las muestras torneadas, a través de los resultados vistos en el rugosímetro.

3.5.2 Revisión Documental

La revisión documental presenta un diseño no experimental de donde Hernández, Fernández y Baptista (2014) explican claramente que “El diseño no experimental de una investigación es observar un fenómeno existente, tal cual se está presentando en un contexto natural para que posteriormente a esto se pueda analizar las variables de

ese, evidenciando este proceso en el objetivo de esta revisión documental”, el cual se concentró en buscar, observar y evidenciar en esta investigación. A través de la revisión documental se recopiló información de fuentes secundarias como libros, documentos y normas; para obtener información útil que permitió profundizar conocimientos existentes en el área, lo que mejoró el desarrollo de las bases teóricas utilizadas.

3.6 Instrumentos utilizados en la recolección de datos

Arias, F. (2012) indica que “un instrumento de recolección de datos es cualquier recurso, dispositivo o formato que se utiliza para obtener, registrar o almacenar información” (p.68). En el presente trabajo especial de grado se aplicaron los siguientes instrumentos de recolección de datos:

- **Fichas de Contenido o de revisión documental**

Es uno de los instrumentos de investigación documental más usados, dado que permiten conservar los datos que se van obteniendo de una forma organizada y visible. Para la presente investigación se aplicó este instrumento en el proceso de revisión documental. Así, en fichas, se anotó la información encontrada en los documentos tales como comentarios y argumentos producto de la lectura, dado que estas fichas ayudan a la memoria y son un método efectivo de clasificación de la información.

- **Fichas bibliográficas**

La ficha bibliográfica se usa para documentar los datos de la revisión de la bibliografía, en ella se llevaron los datos de apellidos y nombres del autor, título del documento, editorial, lugar de la publicación.

- **Registro de páginas electrónicas**

Este instrumento consiste en el uso de bibliotecas electrónicas para recopilar información de tipo documental.

- **Rugosímetro**

Dispositivo utilizado de manera instrumental para obtener la magnitud de la rugosidad superficial de una sección de un material estudiado.

- **Perfilómetro**

Se utilizó este dispositivo para obtener información sobre los ángulos de las herramientas de corte.

- **Durómetro**

Se utilizó este dispositivo para obtener información sobre la dureza del material de trabajo.

- **Microscopio Óptico**

Se utilizó este dispositivo para realizar la caracterización de la microestructura, a través de una metalografía, del material de trabajo.

- **Microscopio Digital**

Se utilizó este dispositivo para observar el acabado superficial a un rango de aumento mayor.

3.7. Técnicas de Procesamiento y Análisis de datos

En relación con el propósito del análisis de los datos Balestrini (2006) destaca, que el mismo "implica el establecimiento de categorías, la ordenación y manipulación de los datos para resumirlos y poder sacar algunos resultados en función de las interrogantes de la investigación" (p.169). Por su parte, Arias (2006) lo refiere como "la técnica dirigida a la cuantificación y clasificación de las ideas de un texto, mediante categorías preestablecidas" (p. 77).

Para el análisis y procesamiento de datos, se utilizó la organización y sistematización de la información para luego realizar la presentación en gráficos y tablas, también se realizó una red neuronal artificial que permitió estudiar los resultados del estudio para generalizar el modelo matemático que los describe. Con base a la información de las distintas fuentes obtenidas en la revisión documental, se analizó la misma con el fin de filtrar, organizar y presentar la información relevante para el logro de los objetivos del trabajo de investigación.

3.8. Fases Metodológicas

Este proyecto de investigación estuvo estructurado en cinco fases metodológicas, vinculadas con cada objetivo planteado para conseguir al logro del objetivo general.

Fase I Diagnóstico de las mejores condiciones de corte para los ensayos.

En esta fase, se decidió, en base a experimentos anteriores, cuáles serían los mejores parámetros de corte dentro de los establecidos a evaluar como variables, y se escogió la forma de utilizar las herramientas, para realizar los ensayos en la fase posterior.

Fase II Mecanizado de las muestras de acero, con las herramientas y los parámetros determinados.

Se tornearon las piezas en el torno de banco, con las condiciones de corte determinadas en la fase anterior, en un cierto número de ocasiones, para conseguir los parámetros más apropiados para la medición de la rugosidad.

Fase III Medición de rugosidad superficial de los resultados del torneado.

Se realizaron mediciones de rugosidad superficial de las piezas torneadas. En este paso se utilizó el rugosímetro para obtener los valores de la rugosidad en cada superficie mecanizada, y se registró la misma para su análisis posterior.

Fase IV Selección de la red neuronal artificial.

En esta etapa se evaluaron las opciones adicionales existentes sobre las redes neuronales artificiales que podían utilizarse para el estudio de los datos presentes en las muestras recogidas con el rugosímetro, y a partir de dicha evaluación, se escogió el modelo de inicialización más conveniente.

Fase V Aplicación de la red neuronal artificial.

Una vez elegida la red neuronal artificial a utilizar en la inicialización, la misma fue elaborada utilizando un software conveniente; Joone, y una vez que su estructura fue creada y se encontró en operación funcional, se procedió a entrenar a la red ingresando los valores obtenidos en la medición para otorgarle la capacidad de predecir

resultados, optimizando sus hiperparámetros. Así, se finalizó la investigación luego de terminar el entrenamiento de la red, una vez que su error se encontró en un rango igual o menor al valor de un mínimo aceptable.

CAPÍTULO IV

RESULTADOS

En este capítulo, se realiza la exposición de los resultados de la ejecución de la investigación, a través de la presentación de cada una de sus fases metodológicas de manera subsecuente:

4.1. Diagnóstico de las mejores condiciones de corte para los ensayos.

Durante el diagnóstico de las mejores condiciones de corte para los ensayos se tomaron en cuenta varios parámetros importantes, como; la geometría de las probetas utilizadas, el material de trabajo y sus propiedades mecánicas, las capacidades de la máquina herramienta, las capacidades de la herramienta, los acabados que se producían y en última instancia, el rango de caracterización que los mismos le permitirían a la herramienta resultante de la investigación.

4.1.1. Geometría de las Probetas

La geometría de las probetas del ensayo se definió a través de parte de los resultados de una investigación precedente, de la que se conservan las probetas en el laboratorio de Metrología de la Escuela de Ingeniería Mecánica. En dicho mostrador, se observan las probetas de rugosidad en torneado como cilindros de alrededor de 40 mm de diámetro y 100 mm de largo. De esa forma, las probetas de la investigación se escogieron de dimensiones parecidas, en este caso, 41 mm antes del ensayo, como se ve en la figura 30, y dimensiones variadas luego de realizado el mismo, y alrededor de 100 mm de largo, como se observa en la figura 31.



Figura 30: Vista Transversal de la Geometría de las Probetas, 41 mm de diámetro.

Fuente: Fernández (2022).



Figura 31: Vista Longitudinal de la Geometría de las Probetas, aproximadamente 100 mm de longitud.

Fuente: Fernández (2022).

La importancia de la uniformidad en el diámetro entre todas las probetas del ensayo radicó en que todas influían en la velocidad de corte, y dicho valor tenía que ser idéntico, de ser posible, entre todas ellas. De esa forma, si bien las probetas pudieron tener longitudes ligeramente variadas, un factor vital a considerar fue mantener el diámetro idéntico en todas ellas. No obstante, el diámetro original de la barra utilizada para el estudio, era de 44.5 mm, por lo que el mismo se rebajó hasta el diámetro seleccionado de 41 mm, torneando.

4.1.2. Composición Química del Material

La composición química del material de trabajo, por su parte, fue la estándar del acero AISI 1045, que se observa en la tabla 4:

Tabla 4: Composición Química del Acero AISI 1045.

Cantidades de cada Elemento en la Composición Química, en %				
Fe	C	Mn	P	S
98.81	0.45	0.65	0.040	0.050

Fuente: ASM (2005).

4.1.3. Propiedades Mecánicas del Material

En este aspecto, los tres factores más importantes a considerar en el material fueron su microestructura, su dureza y su maquinabilidad.

4.1.3.1. Microestructura

La microestructura del material se estudió a través de una probeta metalográfica extraída de uno de los cilindros de las probetas principales del mecanizado, en un microscopio metalúrgico invertido modelo 3035 de AccuScope (Ver Anexo A). La misma fue cortada en la sierra de vaivén, con abundante refrigeración, para evitar el cambio de fase y por ende de los resultados de la metalografía. Luego, la misma fue lijada y finalmente pulida, para la obtención de una superficie apropiada para la metalografía. Por último, se aplicó nital al 2% como químico de ataque para revelar la microestructura de la probeta.




Figura 32: Microestructura del Acero AISI 1045.

Fuente: Fernández (2022).

En la figura 32, puede observarse el resultado de la metalografía. En ella, se observa una microestructura con abundante cantidad de perlita fina, como la forma laminar oscura, mientras que a la vez pueden observarse entre esas concentraciones perlíticas, regiones ferríticas, en la zona clara, y entre las láminas. La proporción presente en la microestructura es correspondiente a la del AISI 1045, trabajado en frío por medios de conformación volumétrica y luego normalizado.

4.1.3.2. Dureza

La verificación de la dureza se realizó con dos probetas diferentes, para caracterizar ambas superficies del material; la radial cilindrada y la transversal refrentada, en un durómetro Rockwell modelo LC-200R, de Buehler (Ver Anexo A). Este paso se llevó a cabo con la intención de, en conjunto con la metalografía,

caracterizar al material para verificar que sus propiedades fuesen convenientes para la realización del experimento. La primera probeta del ensayo de dureza puede observarse en la figura 33, cilindrada, y en la 37 la segunda, refrentada; mientras que los resultados de su análisis pueden observarse en las figuras 34 y 38 para los valores de las cinco mediciones, en las 35 y 39 para las gráficas de los mismos, y en las 36 y 40 para su análisis estadístico; en cada caso la primera figura de cada pareja correspondiendo a la probeta cilindrada, y la segunda a la refrentada, respectivamente.



Figura 33: Primera Probeta de Dureza, Cilindrada.

Fuente: Fernández (2022).




Figura 34: Resultados de las cinco mediciones de dureza en la longitud de la probeta cilindrada.
Fuente: Fernández (2022).



Figura 35: Gráfico de los resultados de las mediciones de dureza en la longitud de la probeta cilindrada.
Fuente: Fernández (2022).




Figura 36: Análisis estadístico de los resultados de la medición de dureza la probeta cilindrada.
Fuente: Fernández (2022).



Figura 37: Segunda Probeta de Dureza, Refrentada.
Fuente: Fernández (2022).




Figura 38: Resultados de las cinco mediciones de dureza en la longitud de la probeta refrentada.
Fuente: Fernández (2022).




Figura 39: Gráfico de los resultados de las mediciones de dureza en la longitud de la probeta refrentada.
Fuente: Fernández (2022).



Figura 40: Análisis estadístico de los resultados de la medición de dureza la probeta refrentada.
Fuente: Fernández (2022).

De esta forma, de las figuras 36 y 40 se observa que los valores medios de dureza para la probeta cilindrada y la refrentada son de 100.18 y 97.82, respectivamente, ambos Rockwell B. De la base de datos online de MatWeb, se encuentra que la dureza Rockwell B del AISI 1045 luego de ser torneado, es de alrededor de 94 Rockwell B, valor que se indica lo suficientemente cercano para considerar una caracterización exitosa del material de trabajo como AISI 1045, y por ende adecuado para el mecanizado en cuestión.

4.1.3.3. Maquinabilidad

También según la base de datos de MatWeb, se encuentra que la maquinabilidad del AISI 1045, luego del normalizado, es del 65%, y luego de torneado, del 56% en comparación con el valor base, que es el AISI 1212. Este valor de maquinabilidad no está entre los mejores, por la cantidad de carbono del acero. En este caso, se tiene un

acero de medio carbono con una dureza considerable y en el que puede haber carburos que sean agresivos a la herramienta de corte. No obstante, lo que esto puede significar, es que sea necesario afilar la herramienta de forma reiterada, y que el desgaste ha de ser monitoreado durante el estudio.

4.1.4. Máquinas Herramienta

4.1.4.1. Sierra de Vaivén

En la figura 41 se observa la sierra utilizada para cortar las probetas desde su barra original en la empresa Tornoval C.A., de modelo SABI-HER30. La influencia principal de la sierra en el estudio se da por la forma en la que el corte con ella afecta al material de trabajo, y, aún así, el hecho de que la medición se realice a la región cilindrada y no a la refrentada aísla en casi su totalidad el efecto de la misma. Así, la consideración de la condición en la que la sierra deja al material de trabajo partiría de su influencia en el desgaste que pueda producir en la herramienta la dureza que deje la misma para el refrentado, pero este factor también se redujo a través de la inclusión del paso del afilado de las herramientas antes de realizar el ensayo.



Figura 41: Sierra de Vaivén SABI-HER30
Fuente: Fernández (2022).

4.1.4.2. Torno de Banco Paralelo

A continuación, en la figura 42 se tiene el torno de banco paralelo convencional del laboratorio de procesos de manufactura, en la escuela de ingeniería mecánica de la Universidad José Antonio Páez. Dicha máquina herramienta es, quizás, el factor más influyente del estudio, pues, es en él que se realiza la mayor parte real de la investigación. De esa forma, la influencia del torno en el diagnóstico de los parámetros de corte viene dada por sus capacidades, y por su diseño e instalación.



Figura 42: Torno de Banco Paralelo, CD6260C.
Fuente: Fernández (2022).

De esa forma, uno de los factores principales del torno está en el hecho de que, como máquina herramienta convencional, las velocidades de corte que puede alcanzar, la estabilidad de sus elementos, y la forma de su instalación, conllevan, en teoría, una precisión menor a la que se cree podría conseguirse con una máquina herramienta de control numérico computarizado. Por esta razón, también se indica interesante encontrar la diferencia entre sus resultados y los de máquinas avanzadas. Así, su influencia más grande en la sección práctica está en sus mencionadas velocidades de corte, que se analizarán más adelante en el desarrollo de la fase.

4.1.5. Herramientas de Corte

4.1.5.1. Hoja de Sierra

En la figura 43 se observa la hoja de sierra utilizada como herramienta en el corte de las probetas en la sierra de vaivén. Al igual que se indicó con la sierra propiamente dicha, la influencia de ambas es relativamente baja, en función de la minimización obtenida a partir del refrentado que se realizó sobre las secciones cortadas con ellas, y por el afilado de la herramienta utilizada para los ensayos luego del refrentado mismo.



Figura 43: Hoja de Sierra de HSS utilizada en la Sierra de Vaivén.
Fuente: Fernández (2022).

4.1.5.2. Portaherramientas de Cuchillas Orientables

En la figura 44 se observa el portaherramientas utilizado en el torno para sostener las cuchillas orientables utilizados. El portaherramientas en cuestión es un modelo de Impero Tools, en él, la herramienta se sostiene a través de un tornillo que se aprieta para ejercer la fuerza que la mantiene en su lugar, como es común en otros portaherramientas, pero, además, el mismo permite un cierto grado de inclinación de la cuchilla sin inclinar la torreta del torno, a diferencia de los portaherramientas para insertos.



Figura 44: Portaherramientas Impero para Cuchillas Orientables.

Fuente: Fernández (2022).

4.1.5.3. Cuchilla Orientable de Carburo de Tungsteno

La herramienta más importante del ensayo, porque fue con la que se mecanizaron la mayoría de las probetas, y más importante aún, la totalidad de las probetas de las cuales se obtuvieron los datos que se ingresaron en la red neuronal. La influencia de la cuchilla en el material es amplia y se remite principalmente a su propio material, y a su geometría. La herramienta se colocó en el torno a través del portaherramientas mostrado en la figura 44; a un ángulo de alrededor de 50° con el eje del husillo.

En las figuras 45 y 46 pueden verse la imagen de la cuchilla en el catálogo del fabricante, y en la realidad, como se utilizó en el ensayo. La cuchilla en cuestión es el modelo FB-16 de Impero, con un carburo de tungsteno de P6. En el catálogo pueden observarse también los ángulos y el resto de la geometría de la misma. Otras perspectivas de los ángulos utilizados se observan en el anexo B, en la medición realizada en un perfilómetro, modelo PJ-A3000, de Mitutoyo (Ver Anexo A). Así mismo, el desgaste de la cuchilla puede verse en el anexo C, visto con aumento en el microscopio digital AN-104, de Ebtools (Ver Anexo A).

FB

L : 58mm.
P : 16mm.
d : 16mm.




Figura 45: Cuchilla Orientable de Carburo de Tungsteno, modelo FB 16, grado P6, de Impero Tools.

Fuente: Catálogo Online, Impero Tools (s.f.).



Figura 46: Cuchilla Orientable FB 16-P6 Utilizada en los Ensayos.

Fuente: Fernández (2022).

4.1.5.4. Mecha de Centro de Acero Rápido

Utilizada para realizar las perforaciones en las que se ubicaron el punto fabricado en el plato y el punto giratorio en el carro del contrapunto, la mecha en cuestión puede observarse en la figura 47, como aparece en el catálogo del fabricante, la misma, además, midió 4 mm, hecha de acero rápido, con un ángulo en sus conos de 30°; hecha por Dormer. Esta se utilizó con el mandril presente en el carro del contrapunto en la figura 48, utilizando un cono morse para adaptarlo al mismo.



Figura 47: Mecha de Centro de 4 mm, HSS.

Fuente: Catálogo Online, Dormer (s.f.).




Figura 48: Configuración de las Herramientas de Corte, con el Mandril.

Fuente: Fernández (2022).

4.1.5.5. Cuchilla Orientable de Acero Rápido

Para el ensayo con el acero rápido también se utilizó una cuchilla orientable, en este caso del modelo AC-16 222 S, igualmente de Impero Tools. El modelo de la misma puede observarse en catálogo en el cuadro 1, donde es la tercera verticalmente en la columna de la izquierda, junto a sus parámetros geométricos; en la misma figura aparecen sus ángulos importantes. Por otra parte, en la figura 49 aparece la cuchilla real que se utilizó en los ensayos, con los parámetros del catálogo. Además, la misma, al igual que la de carburo de tungsteno, se utilizó en el portaherramientas Impero de la figura 44, a aproximadamente 50° con el eje del husillo.

Cuadro 1: Cuchilla Orientable de Acero Rápido, Modelo AC-16 222 S, de Impero, en Catálogo.



RIFERIMENTO	D	P	L
AC - 12 222 S	12	12	41
AC - 14 222 S	14	14	45
AC - 16 222 S	16	16	56
AC - 18 222 S	18	18	66
AC - 22 222 S	22	24	78

Fuente: Catálogo Online, Impero Tools (s.f.).



Figura 49: Cuchilla Orientable de Acero Rápido, Modelo AC-16 222 S, Utilizada.

Fuente: Fernández (2022).

Al igual que para la cuchilla de carburo de tungsteno, otras perspectivas de los ángulos utilizados se observan en el anexo B, en la medición realizada con el perfilómetro, modelo PJ-A3000, de Mitutoyo (Ver Anexo A). Y también, el desgaste de la cuchilla se observa en el anexo C, con aumento, en el microscopio digital AN-104, de Ebtools (Ver Anexo A).

4.1.6. Parámetros de Corte

Finalmente, los parámetros de corte, específicamente, se seleccionaron en función de las capacidades de la máquina herramienta. Así, en las subsecciones siguientes, se especifican las capacidades del torno para mecanizar a distintas velocidades y avances. Las profundidades de corte, por su parte, se escogieron experimentalmente, en su mayoría, en base a la condición de que los acabados superficiales no suelen estudiarse directamente en cortes grandes, y al grado de

desgaste de las herramientas, notado experimentalmente. En esta sección, se definió por antecedentes, que alrededor de tres variaciones de cada parámetro serían convenientes.

4.1.6.1. Velocidad de Corte

Durante la investigación, los dos factores determinantes en el criterio que dirigió la selección de la velocidad de corte fueron las capacidades de la máquina y el requerimiento de que las mismas permitieran caracterizar un rango relativamente amplio de velocidades, para más condiciones de mecanizado. En este aspecto, las capacidades de la máquina se observan en la figura 50.

	A	B	C	D	E
1600	545	240	105	45	
1150	395	175	75	33	
845	290	130	55	24	

Figura 50: Velocidades Rotacionales Disponibles en el Torno.

Fuente: Fernández (2022).

Experimentalmente, y por la naturaleza de la máquina herramienta, se determinó que la velocidad máxima que el torno podía trabajar con seguridad para las condiciones de los ensayos, era de 845 RPM. Por otra parte, se indicó que el carburo de tungsteno podría ofrecer mejores resultados a RPM relativamente altas, de manera que la decisión final en el rango fueron los mencionados 845 RPM, hasta 395 RPM. De tal forma, la decisión lógica en el rango intermedio fueron los 545 RPM que quedan entre ambos en la tabla de velocidades.

4.1.6.2. Avance

Teniendo la velocidad rotacional, la misma fue un factor importante para la determinación de la velocidad de avance, porque al igual que en el caso anterior, se deseaba caracterizar un rango relativamente amplio de valores, pero además se requería que los acabados fueran convenientes dentro de lo deseado en el estudio. De esa forma, se encontró que los mismos no podían ser mayores a los 0.207 mm/rev, porque para la velocidad rotacional establecida, parámetros mayores podían hacerse muy elevados y dar resultados negativos en la rugosidad superficial. Por ello se probó con dicho extremo, y con el valor más pequeño obtenible, de 0.0027 mm/rev, para intentar obtener la mejor rugosidad posible. Entre ambos, se escogió un valor intermedio, 0.104 mm/rev.

Ambos valores pueden observarse en la figura 50, en la parte superior de la tabla, en la configuración superior de la lira, con las palancas dirigidas hacia la derecha y al medio, y con los números en 1 y en 7. Se utiliza la tabla superior porque es la que muestra las capacidades del torno de realizar distintos tipos de avance en milímetros, mientras que la inferior lo hace en pulgadas.

Table 1-6: Table of feeds

		The metric table										
		mm/rev										
F	C	1	2	3	4	5	6	7	8	9	10	11
		1	0.072	0.081	0.090	0.099	0.108	0.117	0.126	0.135	0.144	0.153
2	0.144	0.162	0.180	0.198	0.216	0.234	0.252	0.270	0.288	0.306	0.324	
3	0.288	0.324	0.360	0.396	0.432	0.468	0.504	0.540	0.576	0.612	0.648	
4	0.577	0.648	0.721	0.792	0.863	0.934	1.005	1.076	1.147	1.218	1.289	
5	1.154	1.289	1.424	1.559	1.694	1.829	1.964	2.099	2.234	2.369	2.504	
6	2.308	2.596	2.884	3.172	3.460	3.748	4.036	4.324	4.612	4.900	5.188	
		The inch table										
		mm/rev										
F	C	1	2	3	4	5	6	7	8	9	10	11
		1	0.0027	0.003	0.0032	0.0034	0.0035	0.0037	0.0038	0.004	0.0043	0.0045
2	0.0054	0.006	0.0064	0.0067	0.007	0.0073	0.0077	0.008	0.0087	0.009	0.0093	
3	0.0107	0.012	0.0127	0.0135	0.014	0.0147	0.0153	0.016	0.0174	0.018	0.0187	
4	0.027	0.024	0.0235	0.027	0.028	0.029	0.031	0.032	0.035	0.036	0.0374	
5	0.043	0.048	0.051	0.054	0.056	0.059	0.061	0.064	0.069	0.072	0.075	
6	0.085	0.096	0.102	0.108	0.117	0.118	0.125	0.128	0.139	0.145	0.150	

Figura 51: Velocidades de Avance Disponibles en el Torno.

Fuente: Fernández (2022).

4.1.6.3. Profundidad de Corte

Finalmente, la profundidad de corte se caracterizó partiendo del hecho de que los acabados por lo general toman cortes relativamente pequeños, y se quiso minimizar el impacto en la rugosidad del desgaste de las herramientas y las temperaturas y fuerzas de corte. Por esas razones, se trabajó de forma experimental con tres valores; 1 mm, 0.6 mm, y 0.3 mm. Estas profundidades de corte, para los ensayos, por ser cilindrados, se aplicaron desplazando el carro de derecha a izquierda (En cuanto a sentidos de corte), ejerciendo la medida sobre la probeta, y controlándolas con el nonio del carro transversal, que aparece en la figura 51.



Figura 52: Escala en Manivela del Carro Transversal.

Fuente: Fernández (2022).

4.1.6.4. Tablas de Datos

Así, una vez definidos los parámetros de corte que se utilizarían, también se estableció ampliar los resultados incluyendo en la combinación una condición en seco y una refrigerada. Por eso, se escribió un diseño factorial con los parámetros a utilizar,

incluyendo, 3 velocidades de corte, 3 avances, 3 profundidades de corte, 2 cuchillas y 2 condiciones de refrigeración. En total, esto resultaba en:

$$N = 3 \cdot 3 \cdot 3 \cdot 2 \cdot 2 = 108 \text{ probetas}$$

Que, dividiendo cada muestra entre dos, para los mecanizados, resultó en 54 muestras para mecanizar 108 probetas. Estos fueron los datos originales, para, más adelante, medir rugosidades en cada una de ellas, obteniendo 108 resultados de rugosidad promediando varias de las mediciones para cada una de las probetas. De esta forma, las tablas de datos originales pueden observarse en el anexo D.

4.2. Mecanizado de las muestras de acero, con las herramientas y los parámetros determinados.

Durante el mecanizado de las probetas, se ejecutó la preparación de las mismas para el ensayo, y se realizó el experimento mismo, con los parámetros de corte definidos y los procesos pertinentes a la consecución de los productos finales. En este aspecto, se partió de la barra de acero AISI 1045 de 44.5 mm de diámetro que se observa en la figura 53.



Figura 53: Barra Inicial de Acero AISI 1045.
Fuente: Fernández (2022).

4.2.1. Corte con Sierra

Luego de tener la barra inicial, el primer paso fue cortar la misma en un tamaño similar de las probetas, de alrededor de hasta 105 mm para considerar la cantidad de material removida en los refrentados, antes de la sujeción entre puntos. El corte se realizó de la forma mostrada en la figura 54, con la sierra SABI-HER30 y la hoja de HSS que se observaron anteriormente.



Figura 54: Proceso de Corte con Sierra de las Probetas.
Fuente: Fernández (2022).

Luego de pasar por la sierra, se obtuvieron 54 muestras; material suficiente para las 108 probetas que se plantearon en el diseño experimental de la investigación. Una vez cortadas, las mismas se trasladaron desde Tornoval C.A., hasta el laboratorio de Procesos de Manufactura de la Escuela de Ingeniería Mecánica. Las mismas se llevaron en su condición natural, sin procesos posteriores; solo aserradas y sin remover la capa pasiva. El conjunto de probetas en cuestión puede verse en la figura 55.



Figura 55: Conjunto Inicial de Probetas.

Fuente: Fernández (2022).

4.2.2. Refrentado

Una vez en la escuela, se realizó la primera configuración en el torno para la preparación de las probetas. En función de utilizar toda su longitud, se decidió trabajar con las piezas sostenidas entre puntos. Por esto, para empezar, se refrentaron todas las probetas por ambos lados. En este caso, el procedimiento fue refrentar, y luego perforar con la mecha de centro cada cara, para tener donde colocar los puntos.

La configuración realizada para este fin puede observarse en la figura 56, mientras que la operación de refrentado propiamente dicha puede verse en la figura 57. Estos mecanizados preliminares se llevaron a cabo a velocidades relativamente bajas, de alrededor de 395 RPM, con avances de 0.104, y profundidades de corte de hasta 2.5 mm. Con estas velocidades se refrentaron las 54 muestras, para 108 probetas.



Figura 56: Configuración en el Torno para Refrentado y Perforado.
Fuente: Fernández (2022).



Figura 57: Ejecución del Refrentado.
Fuente: Fernández (2022).

4.2.3. Perforación de Centros

Utilizando la mecha de centro mencionada anteriormente, y observada en las figuras de la configuración del refrentado, se realizaron conos a 30° de hasta 10 mm de profundidad en todas las caras refrentadas de las probetas. Esta operación se realizó con los mismos parámetros de corte, configuración y refrigeración que la anterior, pues para cada cara se hicieron en forma sucesiva. Como una de las herramientas más esforzadas, también fue una de las que más desgaste recibieron, fracturando una punta, como se observa en la figura 58. Los conos resultantes de la operación pueden observarse en las figuras 59 y 60, con una probeta de muestra y el conjunto total terminado.



Figura 58: Mecha de Centro de 4 mm, HSS; tras Fractura de una Punta.
Fuente: Fernández (2022).




Figura 59: Perforación de Centro en las Probetas.

Fuente: Fernández (2022).



Figura 60: Conjunto de Probetas Perforadas.

Fuente: Fernández (2022).

4.2.4. Cilindrado

Luego de refrentadas y perforadas, las probetas pasaron al proceso de cilindrado para llevarlas al diámetro de 41 mm con el que se trabajaría en el estudio. Se realizó un cono de 30° adicional, para colocarlo en el plato, y del lado derecho se sujetaron con un punto giratorio en el carro del contrapunto. Se utilizó la cuchilla de carburo de

tungsteno para estas operaciones, y se hicieron a 845 RPM, con 0.027 mm/rev de avance y profundidades de corte de hasta 1.75 mm.

Así, en la figura 61 puede observarse la configuración realizada para el cilindrado, mientras que en la 62 la ejecución del proceso y con él la remoción de la capa pasiva. En la figura 63 pueden observarse las probetas ya cilindradas, y, luego de cilindradas, se realizó una línea divisoria en el centro longitudinal de cada muestra, para dividir las áreas de las dos probetas; esto se ve en la figura 64.




Figura 61: Configuración para el Cilindrado.

Fuente: Fernández (2022).



Figura 62: Ejecución del Cilindrado.
Fuente: Fernández (2022).



Figura 63: Conjunto de Probetas Cilindradas.
Fuente: Fernández (2022).



Figura 64: Conjunto de Probetas Cilindradas con Línea Divisoria.
Fuente: Fernández (2022).

4.2.5. Afilado de Herramientas

Luego de la preparación de las probetas, se procedió a afilar las herramientas para conservar su identidad. Esta sección de la fase también se realizó en Tornoval C.A., con las piedras de esmerilar de óxido de zirconio (Ver figura 65), primero, y luego de óxido de aluminio (Ver figura 66), para deshacerse de las mellas, cráteres y del resto del desgaste que sufrió la cuchilla durante la operación en el diagnóstico y el mecanizado; para iniciar el ensayo con la mejor integridad posible.



Figura 65: Piedra de Esmerilar de Óxido de Zirconio.

Fuente: Fernández (2022).



Figura 66: Piedra de Esmerilar de Óxido de Aluminio.

Fuente: Fernández (2022).

4.2.6. Ensayos

Por último, entre los pasos de mecanizado, se realizaron los ensayos con los parámetros definidos, para luego pasar a almacenar las probetas hasta el momento de su medición. De entre los ensayos, se encontraban planteados 108 diferentes, como se observa en las tablas del diagnóstico, pero, dos limitaciones fundamentales redujeron la cantidad de ensayos a 54. La primera, el tiempo, y la segunda, que la herramienta de acero rápido no soportó el desgaste que le provocaron los parámetros descritos al principio de la investigación, astillándose y/o fracturándose de forma reiterada en los distintos intentos, por lo que se debieron omitir sus mecanizados casi en su totalidad, y por ende de la red.

De resto, todas las probetas pudieron ser mecanizadas de manera exitosa. Con carburo de tungsteno en seco y refrigerado, y las tres velocidades de corte, las tres velocidades de avance, y las tres profundidades de corte definidas en la fase I. En la figura 67 puede observarse el proceso de mecanizado de una de las probetas de carburo de tungsteno refrigerado.



Figura 67: Ejecución del Ensayo en el Carburo de Tungsteno Refrigerado.
Fuente: Fernández (2022).

4.2.7. Almacenaje

Finalmente, tras realizar los ensayos, las probetas deben almacenarse de una forma que conserve al máximo su integridad y las proteja de la corrosión, hasta el momento en que se realicen sus mediciones de rugosidad. Este tiempo fue, para varias de ellas, relativamente considerable, puesto a que según el planteamiento de la investigación el primer enfoque fue en terminar todos los mecanizados y solo luego de ello tomar las mediciones de rugosidad. Por tanto, las mismas se limpiaron con alcohol y guantes de látex, para retirar la grasa y las huellas dactilares, y luego se lubricaron con vaselina para crear una capa pasiva protectora (Ver figura 68). Por último, se guardaron en bolsas herméticas para incrementar su protección contra el ambiente (Ver figura 69).



Figura 68: Probetas Ensayadas y Lubricadas para su Preservación.
Fuente: Fernández (2022).



Figura 69: Probetas Ensayadas, Lubricadas y Almacenadas Herméticamente.

Fuente: Fernández (2022).

4.3. Medición de rugosidad superficial de los resultados del torneado.

En esta fase, el estudio de la rugosidad se realizó de dos formas principales y se contrastó con una tercera. De esta manera, la más importante de las técnicas fue la medición con el rugosímetro, porque son dichos valores los que van a la red neuronal artificial. No obstante, se notaron también el acabado superficial macroscópico, y los patrones de la rugosidad en microscopía, para obtener una mejor caracterización cualitativa de los resultados encontrados.

En cuanto a la rugosidad, se midió en tres sectores longitudinales de cada probeta, en sus extremos, y en la división entre un lado de los cilindros y el otro, y justo en medio de ambas secciones. En cada uno de esos sectores, a su vez, se midió la rugosidad en cinco puntos angulares, luego se obtuvo el promedio de esos cinco, y finalmente se encontró el promedio de los tres longitudinales, el cual se marcó como el valor de rugosidad de la probeta.

Al microscopio, por su parte, se observaron las regiones de las probetas que mostraron los mayores valores de rugosidad en el parámetro Ra, para compararlos con las rugosidades finales obtenidas. En esta fase se utilizaron el Rugosímetro Mitutoyo SurfTest SJ-201, y el Microscopio Digital AN104, que pueden verse en el Anexo A.

4.3.1. Nomenclatura de Probetas

En esta fase, es importante explicar el código de numeración que se estandarizó para las probetas. Con base en las tablas de datos originales, se definió que el código estaría compuesto de cinco dígitos, que son:

Primer número: Material de herramienta:

Carburo: 1,

HSS: 2.

Segundo número: Refrigeración de la herramienta:

Refrigerado: 1,

Seco: 2.

Tercer número: Velocidad de Corte:

845 RPM: 1,

545 RPM: 2,

395 RPM: 3.

Cuarto número: Profundidad de Corte:

1 mm: 1,

0.6 mm: 2,

0.3 mm: 3.

Quinto número: Velocidad de Avance:

0.072 mm/rev: 1,

0.104 mm/rev: 2,

0.207 mm/rev: 3.

Ejemplo: Para el carburo de tungsteno en seco a 845 con la profundidad de 1 mm y la velocidad de avance de 0.072 mm/rev:

12111.

De forma que se tendrían 108 códigos desde el 11111 hasta el 22333. No obstante, surgió un cambio debido al factor tiempo y a las herramientas, que, al no haber

soportado el desgaste la herramienta de HSS, no se utilizaron las 108 probetas, si no que solo quedaron disponibles las 54 que se mecanizaron con el carburo de tungsteno. Y luego, por el factor tiempo, se optimizó la data reduciendo el número a 14 mediciones con carburo de tungsteno. Aparte de dichas 14, se tuvieron 3 mediciones adicionales con acero rápido. Dos en las que falló la herramienta, y una última en la que se redujeron los parámetros de corte para estudiar el desgaste. Así, la tabla 5 muestra los parámetros de medición seleccionados.

Tabla 5: Parámetros de Mecanizado Seleccionados para las Probetas de Medición de Rugosidad.

Código	Herramienta	Refrigeración	v (mm/rev)	Vc (RPM)	d (mm)
11123	WC	Refrigerado	0,207	845	0,6
11131	WC	Refrigerado	0,072	845	0,3
12111	WC	Seco	0,072	845	1
12112	WC	Seco	0,104	845	1
12113	WC	Seco	0,207	845	1
12121	WC	Seco	0,072	845	0,6
12122	WC	Seco	0,104	845	0,6
12123	WC	Seco	0,207	845	0,6
12133	WC	Seco	0,207	845	0,3
12211	WC	Seco	0,072	545	1
12223	WC	Seco	0,207	545	0,6
12231	WC	Seco	0,072	545	0,3
12311	WC	Seco	0,072	395	1
12312	WC	Seco	0,104	395	1
21111	HSS	Refrigerado	0,072	845	1
21112	HSS	Refrigerado	0,104	845	1
S/C	HSS	Refrigerado	0,104	175	0,6

Fuente: Fernández (2022).

Dentro de la cual, la última probeta no tiene código, identificado como “S/C”, o “Sin Código”, pues la misma se trabajó con una velocidad diferente a la del estudio, en

función de monitorear el desgaste de la herramienta de acero rápido, y así su aptitud ante las condiciones del experimento. Como durante dicho ensayo se notó que no era viable trabajar con el acero rápido dentro de los paradigmas de la investigación, se descartó, y por ende no se replanteó el código.

4.3.2. Proceso de Medición con Rugosímetro

En el primer paso del proceso de medición con el rugosímetro, se consideró la forma de estructurar los datos. El planteamiento original se aplicó en las primeras cinco probetas medidas, e indicaba realizar entre 3 y 5 mediciones en el perímetro de una sección longitudinal. Sin embargo, en algunas probetas, este enfoque demostró no caracterizar con completa precisión la rugosidad de las mismas, puesto a que al variar la longitud en la que se realizaba el ensayo, el parámetro promedio podía variar ligeramente.

Por eso, se implementó, para las siguientes mediciones, un proceso de medición similar, pero ampliado. Es decir, en lugar de medirse en un solo punto, en cuanto a la longitud, se midió en tres de ellos, característicos; el extremo de las probetas, la periferia de la línea divisoria, y un punto medio entre las dos. Así, el primer modelo de medición, es el que se observa en la tabla 6, y el segundo, el de la tabla 7. En ambas tablas, todos los parámetros de rugosidad representan al respectivo parámetro Ra, medidos en micrómetros con el rugosímetro.

Tabla 6: Primer Modelo de Medición de Rugosidad.

Primer Modelo						
Código de Probeta		12122	12123	12133	12311	12312
Rugosidad Promedio (μm)	Ra1					
	Ra2					
	Ra3					
	Ra4					
	Ra5					
	RaProm					

Fuente: Fernández (2022).

Tabla 7: Segundo Modelo de Medición de Rugosidad.

Segundo Modelo													
Código de Probeta		11123	11131	12111	12112	12113	12121	12211	12223	12231	21111	21112	S/C
Rugosidad en el Extremo (µm)	Ra1												
	Ra2												
	Ra3												
	Ra4												
	Ra5												
	RaProm												
Rugosidad en el Punto Medio (µm)	Ra1												
	Ra2												
	Ra3												
	Ra4												
	Ra5												
	RaProm												
Rugosidad en la Línea Divisoria (µm)	Ra1												
	Ra2												
	Ra3												
	Ra4												
	Ra5												
	RaProm												
Rugosidad Promedio Total (µm)													

Fuente: Fernández (2022).

Así, el siguiente paso del proceso de medición fue la configuración del conjunto rugosímetro – probetas; de esta forma, se utilizaron dos. Para ello, en las primeras, se colocó a las probetas en una base realizada con paralelas, y al rugosímetro en su respectiva losa para medición. Primero, se calibró el instrumento con el patrón Mitutoyo de referencia, y luego se procedió a realizar la medición directamente de las probetas ya posicionadas, con la metodología indicada al principio de la sección. Las configuraciones del instrumento y los especímenes de medición pueden observarse en las figuras 70 y 71.



Figura 70: Vista Lateral de la Primera Configuración de Medición.
Fuente: Fernández (2022).



Figura 71: Vista Superior de la Segunda Configuración de Medición.
Fuente: Fernández (2022).

Mientras se iban realizando las mediciones, los valores resultantes se iban anotando en los modelos, llenándolos y realizando los cálculos pertinentes a los valores que se obtuvieron de forma promediada. Así, en las tablas 8 y 9 pueden observarse los resultados de los procesos de medición para las 17 probetas ensayadas. Primero, las cinco que se realizaron con anterioridad, en la tabla 9, y luego, las últimas quince, incluida a la probeta que se utilizó para monitorear el desgaste del acero rápido, sin código.

Tabla 8: Primer Modelo de Medición de Rugosidad, con Valores.

Primer Modelo						
Código de Probeta		12122	12123	12133	12311	12312
Rugosidad Promedio (μm)	Ra1	2,9	3,14	3,07	3,93	4,87
	Ra2	3,09	3,22	3,26	4,13	4,84
	Ra3	2,98	3,13	3,12	4,27	4,64
	Ra4	2,97	3,12	3,26	4,08	4,77
	Ra5	3,15666667	3,09	3,23	3,97	4,96
	RaProm	3,01933333	3,14	3,188	4,076	4,816

Fuente: Fernández (2022).

Tabla 9: Segundo Modelo de Medición de Rugosidad, con Valores.

Segundo Modelo													
Código de Probeta		11123	11131	12111	12112	12113	12121	12211	12223	12231	21111	21112	S/C
Rugosidad en el Extremo (μm)	Ra1	6,28	4,57	1,94	2,66	2,93	2,56	3,16	3,09	3,82	2,05	2,45	6,16
	Ra2	6,33	4,75	2,21	2,32	2,98	2,54	3,34	3,21	4,37	2,21	2,25	6,4
	Ra3	6,28	4,66	2,04	2,22	3	2,88	3,16	3,15	4,05	2,09	2,19	6,05
	Ra4	6,27	4,72	1,62	1,82	2,84	2,43	3,36	3,3	3,8	2,1	2,39	8,19
	Ra5	6,2	4,56	1,92	2,25	2,94	2,86	3,18	3,31	3,89	2,21	2,2	5,67
	RaProm	6,272	4,652	1,946	2,254	2,938	2,654	3,24	3,212	3,986	2,132	2,296	6,494
Rugosidad en el Punto Medio (μm)	Ra1	6,07	5,04	1,72	1,88	2,81	2,72	3,922	3,44	4,12	2,48	2,54	6,4
	Ra2	6,16	5,09	1,75	1,95	2,82	2,39	3,382	3,31	4,17	2,44	2,27	6,24
	Ra3	6,01	5,17	1,95	1,91	2,76	2,68	3,742	3,42	4,15	2,43	2,45	6,55
	Ra4	6,11	4,9	1,98	2,03	2,81	2,55	3,722	3,32	3,78	2,21	2,18	6,39
	Ra5	6,14	4,85	1,94	2,04	2,84	2,78	3,752	3,32	4,01	2,67	2,46	5,61
	RaProm	6,098	5,01	1,868	1,962	2,808	2,624	3,08666667	3,362	4,046	2,446	2,38	6,238
Rugosidad en la Línea Divisoria (μm)	Ra1	6,05	5,21	1,94	2,06	2,82	2,91	3,43	3,29	3,63	2,48	2,01	6,1
	Ra2	6,12	5,5	1,65	2,06	3,14	2,44	2,78	3,32	3,85	2,5	2,06	7,65
	Ra3	6,13	5,38	1,81	1,97	3,05	2,39	2,78	3,46	4,02	2,63	2,24	6,21
	Ra4	6,21	5,22	1,89	2,14	3,06	2,45	3,11	3,37	3,83	2,32	2,01	6,19
	Ra5	6,16	5,19	1,89	1,87	2,87	3	3,01	3,27	3,9	2,33	2,02	6,78
	RaProm	6,134	5,3	1,836	2,02	2,988	2,638	3,025	3,342	3,846	2,452	2,068	6,586
Rugosidad Promedio Total (μm)		6,168	4,98733333	1,88333333	2,07866667	2,91133333	2,63866667	3,11688889	3,30533333	3,95933333	2,34333333	2,248	6,43933333


Fuente: Fernández (2022).

4.3.3. Resultados de Medición e Interpretación; Rugosímetro y Microscopio

En esta sección, los resultados de la medición con el rugosímetro se relacionaron con las micrografías y con la superficie macroscópica de las probetas. En su mayoría, a simple vista hay muy pocas que aparenten tener un mal acabado o una rugosidad alta. De entre ellas, en su mayoría las que lo presentan son las que poseen una mayor cantidad de irregularidades en el patrón de sus micrografías, por lo que relacionarlas con los parámetros Ra da una idea bastante completa de la superficie que se está

trabajando o viendo. Así, los cuadros del 2 al 18 muestran, a la izquierda, la Macroscopía, a la derecha, la microscopía, y debajo, el valor de Ra en micrómetros para cada medición. El término de la parte superior es el código de las probetas.


Cuadro 2: Resultados de Rugosidad de la Probeta 11123.



Fuente: Fernández (2022).

Los parámetros de corte utilizados en esta probeta fueron, carburo de tungsteno refrigerado, 845 RPM, 0.6 mm de profundidad de corte y 0.207 mm/rev de avance. De todos esos factores, el más importante sobre la rugosidad es, presumiblemente, el avance. En el cuadro 2, se observa un patrón poco regular en distancias cortas, que, sin embargo, parece repetirse cada cierta cantidad de surcos, con anchos variados entre ellos que aumentan y se reducen a lo largo de la superficie de la probeta. También se observan cráteres localizados, probablemente ocasionados por desprendimiento de material de la herramienta o por concentraciones de temperatura. Esto se relaciona con el valor del parámetro Ra, que resulta ser bastante alto con respecto al resto del estudio, factor probablemente relacionado con el patrón irregular de la superficie.


Cuadro 3: Resultados de Rugosidad de la Probeta 11131



Fuente: Fernández (2022).

Los resultados encontrados en el cuadro 3 se obtuvieron de trabajar con carburo de tungsteno refrigerado, a 845 RPM, a 0.3 mm de profundidad de corte y a 0.027 mm/rev de avance. Este patrón se ve ligeramente más regular que el anterior, pero el ancho de sus surcos es bastante delgado. La regularidad en el patrón, se presume, relacionada con la disminución en el avance, mientras que la delgadez de los surcos, con la profundidad de corte pequeña. Además, en esta muestra parecen haber menos cráteres localizados que en la anterior. Sin embargo, el parámetro R_a también es relativamente alto, factor probablemente debido a la diferencia entre alturas y caídas en el perfil.


Cuadro 4: Resultados de Rugosidad de la Probeta 12111



Fuente: Fernández (2022).

La muestra del cuadro 4 utilizó carburo de tungsteno seco, 845 RPM, 1 mm de profundidad de corte, y 0.027 mm/rev. Intuitivamente, su patrón debería ser muy regular, y en efecto, parece serlo, hasta cierto punto. Sin embargo, y aunque parece, a simple vista, tener una menor diferencia en la desviación de su perfil, sí se observa que posee una cantidad medianamente alta de cráteres localizados. Ya que, para el rugosímetro es complicado captar estos efectos, y ya que su patrón parece ser un poco más regular, es lógico que su valor de rugosidad sea mejor que los anteriores. De la misma forma, se creería que la profundidad de corte alta dejaría marcas de mayor ancho, pero el avance lento conlleva el ataque reiterado de la herramienta en la superficie, lo que puede suavizar el efecto.


Cuadro 5: Resultados de Rugosidad de la Probeta 12112



Fuente: Fernández (2022).

En el cuadro 5 se muestra una probeta trabajada con carburo de tungsteno en seco, a 845 RPM, 1 mm de profundidad de corte y 0.104 mm/rev de avance. El primer efecto notable es el ancho de los surcos. Son considerablemente mayores que en los casos anteriores, y esto se relaciona, probablemente, con el mayor avance y la profundidad de corte. Al ser mayor la rapidez de movimiento del carro, el mismo ataca cada surco de forma menos reiterada, dejando más influencia sobre la profundidad. El parámetro R_a resulta ser también bastante conveniente, y su valor va ligado a las desviaciones del perfil en la superficie, diferencias de altura que incrementan con la incidencia del corte en la pieza, que también incrementa con los parámetros, por el aumento en las vibraciones.


Cuadro 6: Resultados de Rugosidad de la Probeta 12113.



Fuente: Fernández (2022).

Aunque la probeta del cuadro 6, trabajada con carburo de tungsteno seco, a 845 RPM, 1 mm de profundidad de corte, y 0.207 mm/rev, parece tener un acabado bastante regular, el detalle que disminuye su calidad superficial ha de estar ligado al, de nuevo, aumento del avance. Tal incremento no solo hace los surcos más anchos en el material, si no que, como se comentó en la probeta anterior, incrementa también las vibraciones y por ende la incidencia de la herramienta en el material, así como la temperatura de trabajo, que conllevan a dejar surcos más profundos en el material, y con ello una desviación mayor, que el rugosímetro capta para dar el parámetro R_a .


Cuadro 7: Resultados de Rugosidad de la Probeta 12121



Fuente: Fernández (2022).

La muestra del cuadro 7 presenta un patrón, nuevamente, más irregular, trabajando con carburo de tungsteno seco, 845 RPM, 0.6 mm de profundidad de corte, y 0.027 mm/rev con surcos menos anchos y valles aparentemente menos delgados también. De igual manera, se nota un incremento en la cantidad de cráteres localizados, que en la ausencia de refrigeración se hace aún más probable por el aumento de las temperaturas, o por el desgaste de la herramienta. La disminución del ancho de los surcos encaja también con el patrón que muestra la disminución del avance, pero parece no exagerarse tanto en conjunto con la disminución de la profundidad de corte, como con su incremento.


Cuadro 8: Resultados de Rugosidad de la Probeta 12122



Fuente: Fernández (2022).

En el cuadro 8, se observa una probeta trabajada con carburo de tungsteno seco, a 845 RPM, 0.6 mm de profundidad de corte y 0.104 mm/rev en avance. Se nota en la probeta que el acabado superficial ha disminuido en calidad con respecto a varios de los anteriores, las irregularidades en la dirección de los surcos aumentaron y los cráteres localizados son, aunque pequeños, varios. El ancho de los surcos es regular, factor en el que influye el avance intermedio. Como es de esperarse para este caso con tales indicaciones cualitativas, el parámetro R_a disminuye para esta muestra.


Cuadro 9: Resultados de Rugosidad de la Probeta 12123



Fuente: Fernández (2022).

La muestra del cuadro 9, por su parte, fue mecanizada con carburo de tungsteno seco, a 845 RPM, 0.6 mm de profundidad de corte y 0.207 mm/rev de avance. El patrón parece mucho más regular en cuanto al ancho de los surcos y de sus valles, pero, se hace extremadamente más irregular en cuanto a los cráteres localizados, e incluso, se nota una pequeña cantidad de óxido de hierro cerca del centro de la micrografía. El ancho regular tiene sentido por el alto avance, y que el mismo no sea más grande también es lógico porque la profundidad de corte no es la más alta. A su vez, el parámetro R_a disminuye, factor que cobra sentido por las irregularidades de la integridad superficial.


Cuadro 10: Resultados de Rugosidad de la Probeta 12133



Fuente: Fernández (2022).

En el cuadro 10, se observa una probeta con parámetros de corte de 845 RPM, 0.3 mm de profundidad, y 0.207 mm/rev en avance, y carburo de tungsteno en seco. El aumento en el avance caracteriza el aumento en el ancho de los surcos, y a su vez, también las vibraciones que promueven valles de distintas incidencias en la longitud de la superficie. Así mismo, la irregularidad en el patrón de la superficie es mayor por las imperfecciones a lo largo de los surcos, y el aumento en cráteres localizados. La profundidad de corte pequeña parece haber influido relativamente poco, y el parámetro R_a disminuye de forma lógica por la presencia de las irregularidades.


Cuadro 11: Resultados de Rugosidad de la Probeta 12211



Fuente: Fernández (2022).

En el cuadro 11 se observa una muestra de parámetros; carburo de tungsteno seco, 545 RPM, 1 mm de profundidad de corte, y 0.027 mm/rev. En este caso, la disminución en la velocidad de corte con respecto a la mayoría de las muestras anteriores empieza a mostrar patrones menos claros, y más difuminados en sus surcos a partir de sus imperfecciones; esto también hace obtener un parámetro Ra intermedio, pero más bajo que en otras mediciones. El patrón mismo se hace mucho menos regular, y la disminución tanto en la velocidad de corte como en el avance conllevan un adelgazamiento considerable de los surcos.


Cuadro 12: Resultados de Rugosidad de la Probeta 12223



Fuente: Fernández (2022).

En el cuadro 12 se encuentra una probeta de parámetros; carburo de tungsteno seco, 545 RPM, 0.6 mm de corte, y 0.207 mm/rev de avance. Con estas condiciones, se esperaría, de hecho, una disminución en el valor Ra mayor a la observada. La calidad de la superficie evidentemente se difumina mucho más, por el efecto negativo que tiene en ella el conjunto de la disminución de la velocidad de corte y el aumento aún mayor del avance. En este caso, la profundidad de corte no parece haber afectado demasiado, ante la predominancia de los otros dos factores. Así mismo, se observa un solo cráter localizado, lógico, por la disminución de la velocidad que conlleva una disminución de la temperatura y del desgaste.


Cuadro 13: Resultados de Rugosidad de la Probeta 12231



Fuente: Fernández (2022).

En el cuadro 13, la probeta trabajada con carburo de tungsteno seco, 545 RPM, 0.3 mm de corte y 0.027 mm/rev muestra un aumento en la regularidad del patrón de anchuras de los surcos, hacia el centro izquierda de la misma, pero aumentan la cantidad y el tamaño de las imperfecciones localizadas; así como la irregularidad del patrón hacia el centro derecha de la micrografía. Por el comportamiento del cráter y el cambio en el ancho de los surcos entre un lado y otro, se considera posible que un desgaste considerable de la herramienta entre ambos puntos haya tenido lugar. Además, con las irregularidades y sus tamaños, se indica que tiene sentido la disminución del parámetro R_a .


Cuadro 14: Resultados de Rugosidad de la Probeta 12311



Fuente: Fernández (2022).

Probablemente uno de los patrones más irregulares presentes en el carburo de tungsteno seco, en el cuadro 14 se tienen además 395 RPM, 1 mm de profundidad de corte y 0.027 mm/rev de avance. Es inmediato detectar que el decrecimiento en la velocidad de corte resultó en un detrimento para la muestra en comparación con las demás, factor notable en el parámetro R_a . Al reducir la velocidad de corte se reduce la incidencia en la que la herramienta ataca la superficie, y por ende, en la mayoría de los casos, el acabado que dejan. Además de una irregularidad alta en las direcciones de los surcos, también se observa un número considerable de imperfecciones en ellos, pero se considera poco probable que estén relacionados con la temperatura o el desgaste, por la velocidad de corte baja.


Cuadro 15: Resultados de Rugosidad de la Probeta 12312



Fuente: Fernández (2022).

La muestra del cuadro 15 se trabajó con carburo de tungsteno seco, 395 RPM, 1 mm de profundidad de corte, y 0.104 mm/rev de avance. En ella, se observa un aumento aún mayor de la rugosidad en el parámetro R_a , y se observa también, desde la micrografía, que existe una mayor cantidad de imperfecciones en la superficie, desde cráteres locales pequeños, hasta discontinuidades en los surcos, y ensanchamientos y adelgazamientos en algunas secciones de ellos. Todos estos factores, se relacionan directamente con el conjunto de aumento del avance y disminución de la velocidad. De nuevo, se indica que, ante cambios de esos dos valores, la profundidad de corte no afecta de manera considerable.

Cuadro 16: Resultados de Rugosidad de la Probeta 21111




Fuente: Fernández (2022).

En el cuadro 16 se observa una de las únicas tres probetas del experimento en ser mecanizadas con acero rápido. Con refrigeración, a 845 RPM, 1 mm de profundidad de corte y 0.027 mm/rev de avance. Es evidente que el acabado del acero rápido parece ser mucho mejor que el de la mayoría de los resultados del carburo. Claro está, que, el acero está, en este caso, trabajando con un conjunto de parámetros muy convenientes en limpiar la superficie, librando de discontinuidades la mayoría de los surcos, pero sí dejando valles más profundos en varias secciones longitudinales de la muestra.

Sobre las imperfecciones, en las muestras de acero rápido, se considera más probable que sean producto del aumento de las temperaturas y del desprendimiento de material de la herramienta, puesto que el desgaste de las mismas en estas condiciones es en extremo considerable, ya que, tanto en el mecanizado de la probeta del cuadro 16 como en el de la del 17, la cuchilla orientable se fracturó en la punta durante el

mecanizado. No obstante, es evidente que el acabado es muy bueno, en cuanto a la micrografía, y es relativamente bueno, con respecto al parámetro Ra.

Cuadro 17: Resultados de Rugosidad de la Probeta 21112




Fuente: Fernández (2022).

En el cuadro 17, la probeta trabajada utilizó, también, acero rápido refrigerado. Utilizó también 845 RPM, 1 mm de profundidad de corte y 0.104 mm/rev. Reforzando la idea de que los cráteres locales que intervienen a los surcos son influenciados por el desgaste de la herramienta, se observa que en este caso el incremento en el avance acelera la agresividad sobre ella, y las temperaturas del corte, y al mismo tiempo, aumenta la incidencia de las imperfecciones en la superficie. No obstante, el parámetro Ra disminuye, y eso es una comparación interesante entre la muestra anterior y esta.

La razón más probable para dicha disminución en el parámetro Ra, sería, el incremento de la uniformidad en las secciones que no se vieron afectadas por el desprendimiento de material de la herramienta, o en las que el calor se liberó de una manera más apropiada. De otra forma, es poco probable que al aumentar el avance, y con él, el desgaste y la temperatura, mejore la rugosidad; por lo que es la hipótesis más sustentable.

Cuadro 18: Resultados de Rugosidad de la Probeta S/C



Fuente: Fernández (2022).

Finalmente, se observa en el cuadro 18, una probeta trabajada a 175 RPM, 0.104 mm/rev de avance, 0.6 mm de profundidad de corte, y acero rápido refrigerado. Es, de lejos, la peor rugosidad obtenida durante el ensayo, tanto en cuanto a la micrografía como al parámetro R_a . En este caso, es importante mencionar que el desgaste de la herramienta juega un papel un poco más pequeño que antes, porque la disminución en la velocidad de corte hace decrecer enormemente la agresividad sobre ella. Por eso, es la misma disminución en las RPM la que conlleva el acabado deficiente, junto al aumento en el avance, un patrón visto anteriormente en las demás probetas del ensayo, pero exagerado en esta, por el mayor rango de cambio entre los parámetros usados antes y aquí.

Así, en esta muestra se observan cráteres enormes, discontinuidades por todas partes, e incluso es enormemente difícil detectar los surcos como se hace en las demás muestras, solamente viéndose parte de uno a la derecha de la micrografía. De resto,

además, por el daño a la integridad superficial, se observan incluso deposiciones de óxido de hierro, formadas de manera muy próxima, en tiempo, al momento del mecanizado. Esto también tiene sentido al considerar que la velocidad de corrosión depende en gran medida del acabado superficial, y, que este es el parámetro Ra más grande obtenido en todo el experimento.

4.4. Selección de la red neuronal artificial.

Entre los aspectos considerados en esta fase, se tiene que se tomó en cuenta si el problema en cuestión era de regresión o de clasificación, se estudiaron las matemáticas de las redes y del algoritmo de Backpropagation, y de esa manera pudo caracterizarse parte del efecto que tienen los hiperparámetros en el funcionamiento completo de la red.

Así, considerando el conjunto de datos que se obtuvo, y la matriz que conformaron, se seleccionaron algunos parámetros de la red que se consideraron más relevantes para ofrecer el mejor rendimiento en la aplicación particular. Fue también, en esta fase, donde se definió finalmente el tipo de herramienta computacional con la que realizar la red.

4.4.1. Matemáticas de la Red: Forward y Backpropagation, Problemas de Regresión

Las redes neuronales, como estructuras matemáticas, funcionan a través de dos procesos. Forward Propagation, y Backpropagation, en los que se realizan una serie de operaciones. Durante el proceso de Forward Propagation, los datos recorren la red desde las neuronas de entrada, hasta las neuronas de salida. Así, los mismos pasan a formar matrices en las que básicamente se resuelven regresiones lineales, y luego se utilizan diferentes funciones de activación que insertan un cierto factor de no linealidad, o corrigen un rango de valores de salida de cada neurona. Así, cada neurona realiza primero la operación:

$$Z = XW + b$$

Donde X es un vector de entrada, W es un peso, y b es una parcialidad, o bias. Z es el valor resultante, que pasa a entrar en la función de activación de la neurona, que una vez resuelta termina siendo el valor de salida de la neurona. Si la misma es la neurona de salida de la red, es su resultado final, y si está en una capa oculta, se convierte en un valor de entrada para la capa siguiente:

$$a = f(Z)$$

Luego, los valores se encuentran, en la salida, en la función de error o coste, que suele ser el error cuadrático medio, para después implementar el algoritmo del descenso de gradiente en el proceso de backpropagation. La red ejecuta este proceso derivando la función de costes con respecto a los pesos de la red, que son los coeficientes de los términos de la regresión lineal, obteniendo la tasa de cambio de dicha función de coste con respecto a los pesos, y acercarla a 0 variando a estos últimos con una corrección, en la que interactúa λ , la tasa de aprendizaje, para repetir el proceso. En la función de coste, se indica que el resultado de la función de activación de la neurona de salida se llama \hat{y} , mientras que el resultado real para dicha combinación es y . Así, la función de coste, la derivada en cuestión, y la corrección, son:

$$J = \sum \frac{1}{2} (y - \hat{y})^2$$

$$\frac{\delta J}{\delta W}$$

$$W = W - \lambda \frac{\delta J}{\delta W}$$

También, es importante resaltar que los parámetros que se observan en las redes, suelen combinarse para formar conjuntos extremadamente grandes. Como ejemplo, se tiene que, en la red a desarrollar para el análisis de los resultados del mecanizado, se podría tener entre cinco y cuatro vectores de entre 14 y 18 valores en la capa de entrada, lo cual ya representa alrededor de 56 términos en el caso más pequeño.

En la figura 72, se observa la función de error graficada con respecto a los pesos de la red. Durante su funcionamiento, la red neuronal realiza de forma reiterada los procesos de forward y backpropagation, en el proceso usualmente llamado “entrenamiento de la red”, que consiste en, simplemente, variar valores hasta que se ha minimizado lo suficiente la función de coste. Es decir, hasta que se ha hecho lo suficientemente pequeño el error cuadrático medio, alcanzando el punto de convergencia.




Figura 72: Coste como Función de los Pesos de la Red.

Fuente: IBM (s.f.)

Además, los problemas que puede resolver una red neuronal se identifican como de clasificación o de regresión. La diferencia entre ambos, es que, fundamentalmente, la clasificación consiste en predecir una etiqueta, y la regresión en predecir una cantidad. Esto significa, a su vez, que durante la clasificación se realiza el modelado predictivo para aproximar una función desde una entrada X , hasta una salida discreta

cualitativa, Y; mientras que, en la regresión, la salida no suele ser discreta, si no continua, y más aún, cuantitativa. También cabe destacar, que existen algoritmos que, a pesar de llevar “regresión”, en sus nombres, no necesariamente indican problemas de regresión. Por ejemplo, la regresión lineal sí lo hace, pero la regresión logística no; donde la misma se utiliza es en clasificación.

Así, se indica que los problemas de clasificación suelen dar resultados que se llaman etiquetas o categorías, y en ellos, incluso si se obtienen valores continuos de probabilidades, los mismos terminan traducidos en lo que en programación se refiere como algún tipo de valor de clase, refiriendo a cualidades; mientras que los de regresión tienen como salidas valores reales, ya sean enteros o con decimales; y suelen referir cantidades, como en este caso, rugosidad. En el primer caso, la habilidad del modelo de predecir es llamada precisión, y en el segundo, es llamada error. Por eso la precisión se calcula como el número de opciones acertadas entre el total, por cien; mientras que para el error se usan valores como el cuadrático medio.

4.4.2. Influencia de los Hiperparámetros en la Red

Dado que los parámetros de la red, es decir, los valores de los pesos y de las parcialidades en las regresiones lineales, se ajustan automáticamente, los elementos que se configuran cuando se diseña la red son realmente los hiperparámetros. En este aspecto, además, la intervención directa en los modelos de aprendizaje supervisado es necesaria para la optimización de los mismos.

Así, el número de capas ocultas y de neuronas es un hiperparámetro, por ejemplo. En este caso, lo ideal es mantener la red lo más simple posible, pero, a la vez, que procese de la mejor manera los datos de entrada. Así, lo más conveniente en algunos casos es probar varios intentos manuales, porque llegado cierto punto, la adición de capas o de neuronas ya no contribuye a mejorar el error del algoritmo. Sin embargo, a la vez, existen factores que suelen cambiar esto, como el número de datos. Por lo general cuando el número de datos es lo suficientemente grande, se puede trabajar con

más neuronas para evitar el underfitting, que es el procesamiento de menos datos de los aprovechables, mientras que cuando se tienen pocos datos, es preferible usar menos para evitar el overfitting, que es lo opuesto, una red ineficiente con la data.

De esa manera, también se toman en cuenta los vectores de entrada. Es común utilizar, en la capa oculta, más neuronas que factores de entrada, para realizar un procesamiento más profundo. De esta forma, en el presente caso, donde se utilizarán cuatro vectores de entrada; velocidad de corte, de avance, profundidad de corte y refrigeración, pero teniendo pocos datos, se considera conveniente la utilización del número inmediatamente superior de neuronas a las de los vectores de entrada; es decir, 5 neuronas en la capa oculta.

Así mismo, para evitar el underfitting, y sabiendo que se tiene una sola neurona en la capa de salida, se indica apropiado utilizar una segunda capa oculta que sirva de transición entre la entrada y la salida, y que se encuentre a una cantidad de neuronas intermedia de las capas de entrada y de salida. Por ello, se escoge una capa oculta de 3 neuronas entre la capa oculta de 5 y la de salida de 1. Esto contribuye a una arquitectura final de la red de 4 – 5 – 3 – 1. Cuatro neuronas de entrada, dos capas ocultas, de 5 y 3, y una sola neurona en la salida, observada en la figura 73.




Figura 73: Arquitectura de la Red Neuronal a Aplicar.
Fuente: Fernández (2022).

Luego, está la tasa de aprendizaje. Este hiperparámetro hace referencia a la backpropagation, cuando los parámetros se actualizan de acuerdo a la función de corrección en base a la derivada con respecto a la función de costos. Lo que este factor modifica es la importancia del cambio en el peso luego de una recalibración. Es decir, qué tanto se actualiza el peso después de que se verifica la tasa de cambio de la función de coste con respecto a él. La ecuación en la que se observa la acción de la tasa de aprendizaje, es la siguiente, presentada también anteriormente, al hablar del proceso de backpropagation, y es la del descenso de gradiente:

$$W = W - \lambda \frac{\delta J}{\delta W}$$

Donde la tasa de aprendizaje es el parámetro lambda. Un lambda pequeño, conlleva una convergencia de la red muy lenta, y en el extremo, un fenómeno llamado “desvanecimiento de gradiente”. Su caso opuesto, un lambda muy alto, puede conllevar

al fenómeno de perder el mínimo, es decir, realizar un incremento tan alto que el mismo se salta en el entrenamiento, y en un caso extremo, el efecto de “gradiente explosivo”. Por lo general, este factor no puede determinarse si no de forma experimental, por lo que se iniciará en 0.1, pero se definirá en la siguiente fase. En la figura 74 se observa, a la izquierda, el efecto de una tasa de aprendizaje pequeña, que en teoría llevaría a la convergencia de forma más segura, pero más lenta; y a la derecha la de una alta, que puede hacer perder al mínimo saltándolo por el tamaño de sus incrementos.




Figura 74: Efecto de una Tasa de Aprendizaje Pequeña, y de una Alta.
Fuente: IBM (s.f.).

El momento es otro factor que se utiliza en la backpropagation, con la intención de incrementar la convergencia, pero no a través de la velocidad de aprendizaje, si no de su dirección. Cuando se agrega a los hiperparámetros, el momento almacena la información de las direcciones anteriores en las que se movió el gradiente, para proceder en ellas en recalibraciones posteriores. Así, utilizar un valor alto de momento tiende a disminuir las direcciones en las que la red se entrena, por lo que se recomienda definirlo experimentalmente también, empezando con valores pequeños, e

incrementarlos de acuerdo a cómo evolucione el error cuadrático medio, o mantenerlos constantes.




Figura 75: Efecto del Momento en el Descenso de Gradiente.
Fuente: Alto (2019).

Las funciones de activación son las que procesan las sumas ponderadas, para tener una salida significativa. Las más importantes, y las que suelen probarse, son la sigmoideal, la tangente hiperbólica, y la unidad lineal rectificadora; las tres pueden verse en la figura 76. Las funciones pueden, a su vez, estar localizadas en cualquier punto de la red, en cualquier neurona, y pueden combinarse de la forma que se desee. Sin embargo, como con los otros hiperparámetros, se deben considerar la eficiencia y la velocidad de la red al escogerlas; por eso, las más comunes en aplicaciones que requieran velocidad son las unidades lineales rectificadas, y en cuanto a la precisión, las sigmoideales. Las tangentes hiperbólicas son las menos comunes.




Figura 76: Funciones de Activación: Sigmoidal, Tangente Hiperbólica, y Unidad Lineal Rectificada.

Fuente: Alto (2019).

El tamaño de los lotes es otro hiperparámetro, pero referido a la cantidad de datos que se utilizan en cada ciclo del entrenamiento de la red. Como, por lo general el tamaño más manejable de datos por ciclo es de hasta 32 datos, y se tienen hasta 14 datos por parámetro, se considera apropiado utilizar dicho valor de 32 para los lotes que se utilizan en cada ciclo. De esta forma, se aumenta la precisión del entrenamiento, porque se dedica una mayor atención a los datos cuando se separan en lotes, por trabajar con menor cantidad.

Las épocas son la cantidad de veces que se quiere que el algoritmo entrene la totalidad de los datos. Estas son diferentes de las iteraciones en el sentido de que una iteración se da cada vez que se completa un ciclo de entrenamiento con un lote, mientras que una época, como se mencionó al principio, es un ciclo de entrenamiento de todos los datos. Por lo general, hasta cierto punto, incrementar las épocas disminuye el error. Por ello, es conveniente empezar con una cantidad de épocas y aumentar desde allí. Además, a una menor tasa de aprendizaje, normalmente se deben aumentar las épocas.

La mayoría de los hiperparámetros deben escogerse de manera definitiva tras la experimentación, pero para iniciar la misma es necesario escoger valores preliminares de ellos. De esa forma, se selecciona para iniciar; la arquitectura 4-5-3-1, y valores relativamente altos, con una tasa de aprendizaje de 0.2, un momento de 0.3, funciones

de activación sigmoidales, lotes de tamaño 32 y 1000 épocas. Además, se escoge el error cuadrático medio como función de coste o pérdidas.

4.4.3. Python vs Joone

Si bien el planteamiento original de la investigación contemplaba utilizar Python como medio para realizar la red neuronal artificial, a través de las librerías de Keras y TensorFlow, durante la ejecución de la misma se encontró el software Joone; un motor neural orientado a objetos programado en Java, que presentaba dos ventajas importantes: Primero, que su utilización, por estar diseñado como una aplicación para trabajar a través de un método gráfico, en lugar de exigir la utilización directa del código de programación, resultaba más práctica y más rápidamente configurable que la aplicación de Python. Y, en segundo lugar, que el hecho de estar orientado a objetos y basado en Java ofrece, en teoría, una mejor eficiencia que una aplicación idéntica en Python.

Por ambas razones, se decidió utilizar Joone en lugar de Python para el desarrollo de la red neuronal artificial. Si bien Python, técnicamente también ofrecía posibilidades mayores de automatización en la optimización de la red a través de un uso más extenso de sus librerías, en el tiempo disponible se consideró poco eficiente la curva de aprendizaje de las mismas, en gran parte porque, las ganancias en precisión de hacerlo no eran lo suficientemente grandes para justificar la extensión de tiempo que era necesario invertir en ellas, y los valores experimentales de Joone resultaron excelentes para los requerimientos de la investigación.

4.5. Aplicación de la red neuronal artificial

En la quinta fase de la investigación, se elaboró la red neuronal con la ayuda del software escogido Joone. Aquí, se presentaron los datos en el formato apropiado para su uso en el programa, se armó e interconectó la arquitectura de la red, y se preparó el archivo con los datos de salida. Luego de esto, se iteró una serie de veces con distintas combinaciones de hiperparámetros, iniciando con los definidos en la sección anterior,

entrenando a la red con los valores de entrada del proceso de medición de rugosidad, mientras se comprobaba la diferencia entre ellos para minimizar el error cuadrático medio de la aplicación; conllevando a una red con un valor del mismo relativamente bajo.

4.5.1. Estructura de la Red en Joone

El primer paso a realizar para la aplicación de la red neuronal, es representarla en Joone. Para esto, se crea un archivo con formato del tipo “.ser”, que almacena a la red de la misma, y se utilizan las funciones de valores de entrada en dos posiciones, para los valores que irán a la capa de entrada, y para los que irán a entrenar los resultados el entrenador, mejorando el error en la capa de salida, las funciones de capas con activación sigmoïdal, la de entrenador, donde está la función de pérdidas, y la de salida de datos, para identificar al archivo de salida, con los valores predichos. Así, la estructura de la red, realizada en Joone, puede observarse en la figura 77.

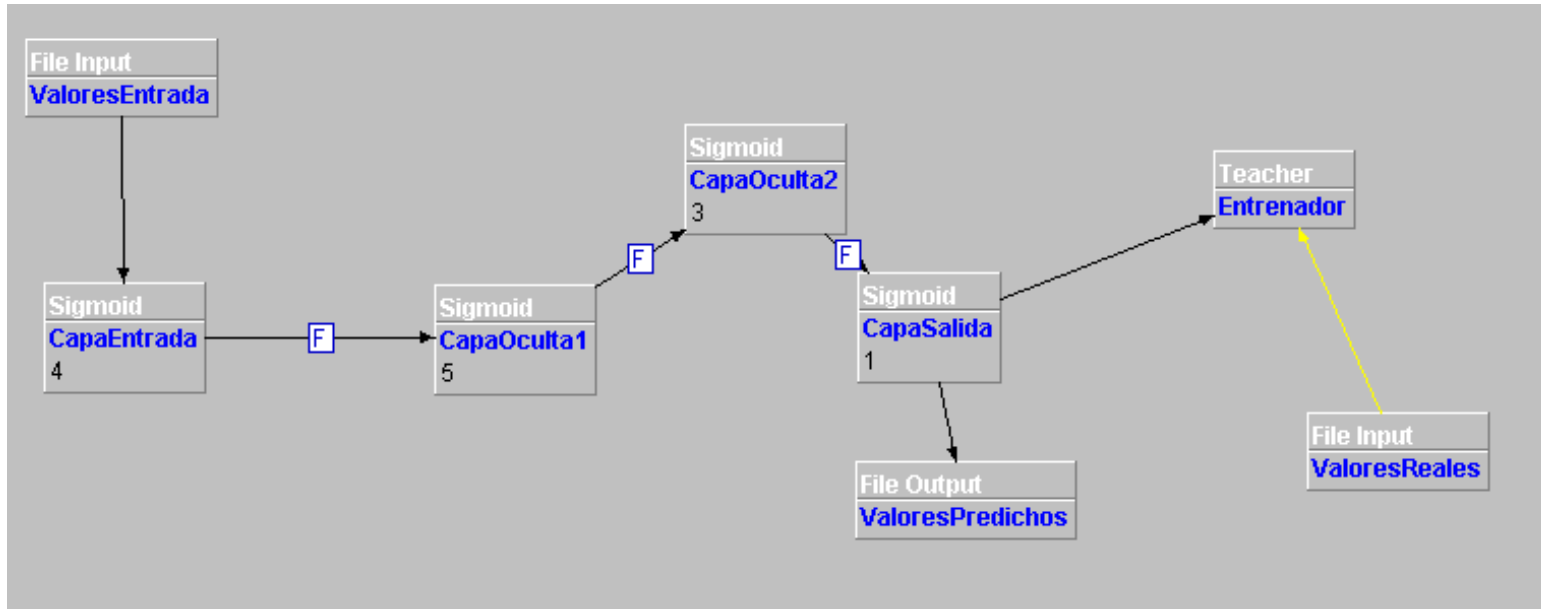


Figura 77: Estructura de la Red Neuronal, Construida en Joone.

Fuente: Fernández (2022).

4.5.2. Datos de Entrada

Los datos de entrada de la red neuronal son los valores de los parámetros de corte de los mecanizados realizados. En este aspecto, la tabla a utilizar es una versión reducida, en parámetros, de la tabla 5, en la que se eliminan los valores de las probetas de acero rápido, y se conservan todos los valores de las probetas de carburo de tungsteno. Así, se asegura el funcionamiento eficiente de la red, con una mayor posibilidad de convergencia y con un error cuadrático medio reducido. La tabla en cuestión es la 10. En ella, se eliminan los valores referentes al material, porque todas están tomadas con carburo de tungsteno.

Tabla 10: Datos de Entrada de la Red Neuronal

Código	Herramienta	Refrigeración	v (mm/rev)	Vc (RPM)	d (mm)
11123	WC	Refrigerado	0,207	845	0,6
11131	WC	Refrigerado	0,072	845	0,3
12111	WC	Seco	0,072	845	1
12112	WC	Seco	0,104	845	1
12113	WC	Seco	0,207	845	1
12121	WC	Seco	0,072	845	0,6
12122	WC	Seco	0,104	845	0,6
12123	WC	Seco	0,207	845	0,6
12133	WC	Seco	0,207	845	0,3
12211	WC	Seco	0,072	545	1
12223	WC	Seco	0,207	545	0,6
12231	WC	Seco	0,072	545	0,3
12311	WC	Seco	0,072	395	1
12312	WC	Seco	0,104	395	1

Fuente: Fernández (2022).

Sin embargo, para trabajar en la red neuronal, los datos deben estar normalizados. Por lo que se buscan los valores máximos de cada uno de los parámetros de la tabla 10, numéricos, y se asignan valores de 0 y 1 a los valores categóricos, para realizar la

normalización en base a ellos, dividiendo cada valor de la tabla entre el máximo respectivo para su categoría.

$$Valor\ Normalizado = \frac{Valor}{Valor\ Máximo}$$

Así, se obtiene que los valores máximos son, para la velocidad de avance, 0.207 mm/rev, para la velocidad rotacional 845 RPM, y para la profundidad de corte, 1 mm. Luego, se asignan los valores de 1, a las condiciones de mecanizado refrigerado, y las de 0, a las condiciones de mecanizado en seco, para normalizar también el parámetro de refrigeración. De esta forma, los parámetros normalizados, son los observados en la tabla 11.

Tabla 11: Datos de Entrada de la Red Neuronal, Normalizados

Código	Ref	v	Vc	d
11123	0	1	1	0,6
11131	0	0,34782609	1	0,3
12111	1	0,34782609	1	1
12112	1	0,50241546	1	1
12113	1	1	1	1
12121	1	0,34782609	1	0,6
12122	1	0,50241546	1	0,6
12123	1	1	1	0,6
12133	1	1	1	0,3
12211	1	0,34782609	0,64497041	1
12223	1	1	0,64497041	0,6
12231	1	0,34782609	0,64497041	0,3
12311	1	0,34782609	0,46745562	1
12312	1	0,50241546	0,46745562	1

Fuente: Fernández (2022).

Así, una vez normalizados los valores de entrada de la red, los mismos pueden pasarse al formato requerido por el software Joone para ser utilizados en la estructura creada en la sección anterior, en la función de la red llamada “Input Layer”, que se encuentra más a la izquierda dentro de la imagen, con el subtítulo “Valores de Entrada”

debajo. Este formato es, para este caso, “.txt”, y en un mismo archivo se escriben tanto los valores de entrada como los de salida reales, que son el conjunto que se usará para entrenar a los valores de la predicción. Como contienen tanto los datos de entrada como los de salida, este formato se mostrará en la siguiente sección.

4.5.3. Datos de Salida

Los datos en la salida de la red se separan en dos categorías; los valores reales son el conjunto de datos que se midió con el rugosímetro, y que se utilizarán para comparar y caracterizar el error que la red tenga en cada paso del entrenamiento. Los valores predichos, por su parte, son los que la red vaya modelando, y la idea principal detrás del proceso es que la misma aprenda lo suficiente para que estos últimos sean lo más parecidos posibles, en un caso ideal, iguales, a los originales, que se midieron en los ensayos; los reales. Como los predichos han de pasar primero por el proceso de optimizar los hiperparámetros de la red, se muestran en la siguiente sección. Por su parte, los reales aparecen aquí.

4.5.3.1. Valores Reales; Datos de Entrenamiento

De esta forma, como se mencionó, estos valores serán los que se midieron con el rugosímetro. A la vez, se recuerda que, por las condiciones del experimento, las mediciones de rugosidad de las muestras que se mecanizaron con acero rápido fueron excluidas, ya que las mismas no fueron suficientes para caracterizar la red de manera apropiada, de forma que no contribuirán a encontrar una convergencia conveniente, ni a minimizar el error, ni a mejorar la capacidad de predicción de la red. Así, los valores reales de rugosidad que se usarán en la red, fueron los que aparecen en la tabla 12. Además, al igual que en el caso de los datos de entrada, estos valores deben ser normalizados, y tomando un máximo de $6.168 \mu m$, se muestran sus datos de normalización en la tabla 13.

Tabla 12: Datos de Entrenamiento de Rugosidad, Medidos

Ra (μm)
6,168
4,98733333
1,88333333
2,07866667
2,91133333
2,63866667
3,01933333
3,14
3,188
3,11722222
3,30533333
3,95933333
4,076
4,816

Fuente: Fernández (2022).

Tabla 13: Datos de Entrenamiento de Rugosidad, Medidos; Normalizados

Ra
1
0,80858193
0,30533939
0,33700821
0,47200605
0,42779939
0,48951578
0,50907912
0,51686122
0,50538622
0,53588413
0,64191526
0,66083009
0,78080415

Fuente: Fernández (2022).

Finalmente, para utilizarlos dentro de la red neuronal, en Joone, es necesario que los datos se encuentren en un tipo de archivo particular; que, en este caso, será del formato tipo “.txt”. Por eso, los mismos se convierten a este tipo de archivos, separados por comas, teniendo en el mismo archivo tanto los datos de entrada como el conjunto de datos de entrenamiento, los modelos reales; como se observa en la figura 78. En ella, las primeras cuatro columnas se configuran en Joone para que el programa reciba sus entradas en la capa inicial, en el advanced column selector (Ver figuras 79 y 80), mientras que la última columna se configura para entrar solo como conjunto de entrenamiento (Ver figuras 80 y 81), directamente en el módulo entrenador.

```

0;1;1;0.6;1
0;0.347826087;1;0.3;0.808581928
1;0.347826087;1;1;0.305339386
1;0.502415459;1;1;0.337008214
1;1;1;1;0.472006053
1;0.347826087;1;0.6;0.427799395
1;0.502415459;1;0.6;0.48951578
1;1;1;0.6;0.509079118
1;1;1;0.3;0.516861219
1;0.347826087;0.644970414;1;0.505386223
1;1;0.644970414;0.6;0.535884133
1;0.347826087;0.644970414;0.3;0.641915262
1;0.347826087;0.467455621;1;0.660830091
1;0.502415459;0.467455621;1;0.78080415

```

Figura 78: Datos de Entrenamiento de la Red.
Fuente: Fernández (2022).




Figura 79: Selección de Columnas de Parámetros de Corte del Archivo de Datos de Entrenamiento, en el Advanced Column Selector, Sección Izquierda.
Fuente: Fernández (2022).



Figura 80: Selección de Columnas de Parámetros de Corte del Archivo de Datos de Entrenamiento, en el Advanced Column Selector, Sección Derecha.

Fuente: Fernández (2022).




Figura 81: Selección de Columna de Rugosidad del Archivo de Datos de Entrenamiento, en el Advanced Column Selector, Sección Izquierda.

Fuente: Fernández (2022).




Figura 82: Selección de Columna de Rugosidad del Archivo de Datos de Entrenamiento, en el Advanced Column Selector, Sección Derecha.

Fuente: Fernández (2022).

4.5.4. Optimización de Hiperparámetros

El último paso en la elaboración de la red es la optimización de hiperparámetros. Es decir, a partir de los valores iniciales de la primera corrida, definidos en la fase 4, buscar los mejores valores a utilizar para mejorar la precisión de la red neuronal artificial. En este caso, el único valor definido que no se pretende cambiar, es la arquitectura de la red, porque su estructura escogida es la más lógica para la aplicación, ni su función de activación, porque, según los antecedentes, la sigmoideal es la más comúnmente aplicada para trabajar con rugosidades. Así, se empieza probando con los demás hiperparámetros en sus valores definidos, y se van cambiando desde allí, hasta llegar a la meta de obtener un error cuadrático medio menor a 0.0012, el valor más bajo encontrado en los antecedentes. (Ver figuras de la 83 hasta la 88).

Controls

Epochs : 1000

RMSE : 0.008339797072809864

batchSize	32
learning	<input checked="" type="checkbox"/>
learningMode	0
learningRate	0,2
momentum	0,3
pre-learning cycles	0
singleThreadMode	<input type="checkbox"/>
supervised	<input checked="" type="checkbox"/>
epochs	1000
training patterns	14
useRMSE	<input checked="" type="checkbox"/>

Figura 83: Primer Intento, 0.2 LR, 0.3 M, 1000 E.
Fuente: Fernández (2022).

Epochs : 10000	
RMSE : 0.007341889158083315	
batchSize	32
learning	<input checked="" type="checkbox"/>
learningMode	0
learningRate	0,2
momentum	0,3
pre-learning cycles	0
singleThreadMode	<input type="checkbox"/>
supervised	<input checked="" type="checkbox"/>
epochs	10.000
training patterns	14
useRMSE	<input checked="" type="checkbox"/>

Figura 84: Primer Intento, 0.2 LR, 0.3 M, 10000 E.
Fuente: Fernández (2022).

Epochs : 10000

RMSE : 0.006836918136709246

batchSize	32
learning	<input checked="" type="checkbox"/>
learningMode	0
learningRate	0,2
momentum	0,1
pre-learning cycles	0
singleThreadMode	<input type="checkbox"/>
supervised	<input checked="" type="checkbox"/>
epochs	10.000
training patterns	14
useRMSE	<input checked="" type="checkbox"/>

Figura 85: Primer Intento, 0.2 LR, 0.1 M, 10000 E.

Fuente: Fernández (2022).

Epochs : 10000	
RMSE : 0.005466912035589569	
batchSize	32
learning	<input checked="" type="checkbox"/>
learningMode	0
learningRate	0,1
momentum	0,1
pre-learning cycles	0
singleThreadMode	<input type="checkbox"/>
supervised	<input checked="" type="checkbox"/>
epochs	10.000
training patterns	14
useRMSE	<input checked="" type="checkbox"/>

Figura 86: Primer Intento, 0.1 LR, 0.1 M, 1000 E.
Fuente: Fernández (2022).

Epochs : 20000

RMSE : 0.004752782200970844

batchSize	32
learning	<input checked="" type="checkbox"/>
learningMode	0
learningRate	0,1
momentum	0,1
pre-learning cycles	0
singleThreadMode	<input type="checkbox"/>
supervised	<input checked="" type="checkbox"/>
epochs	20.000
training patterns	14
useRMSE	<input checked="" type="checkbox"/>

Figura 87: Primer Intento, 0.1 LR, 0.1 M, 20000 E.
Fuente: Fernández (2022).

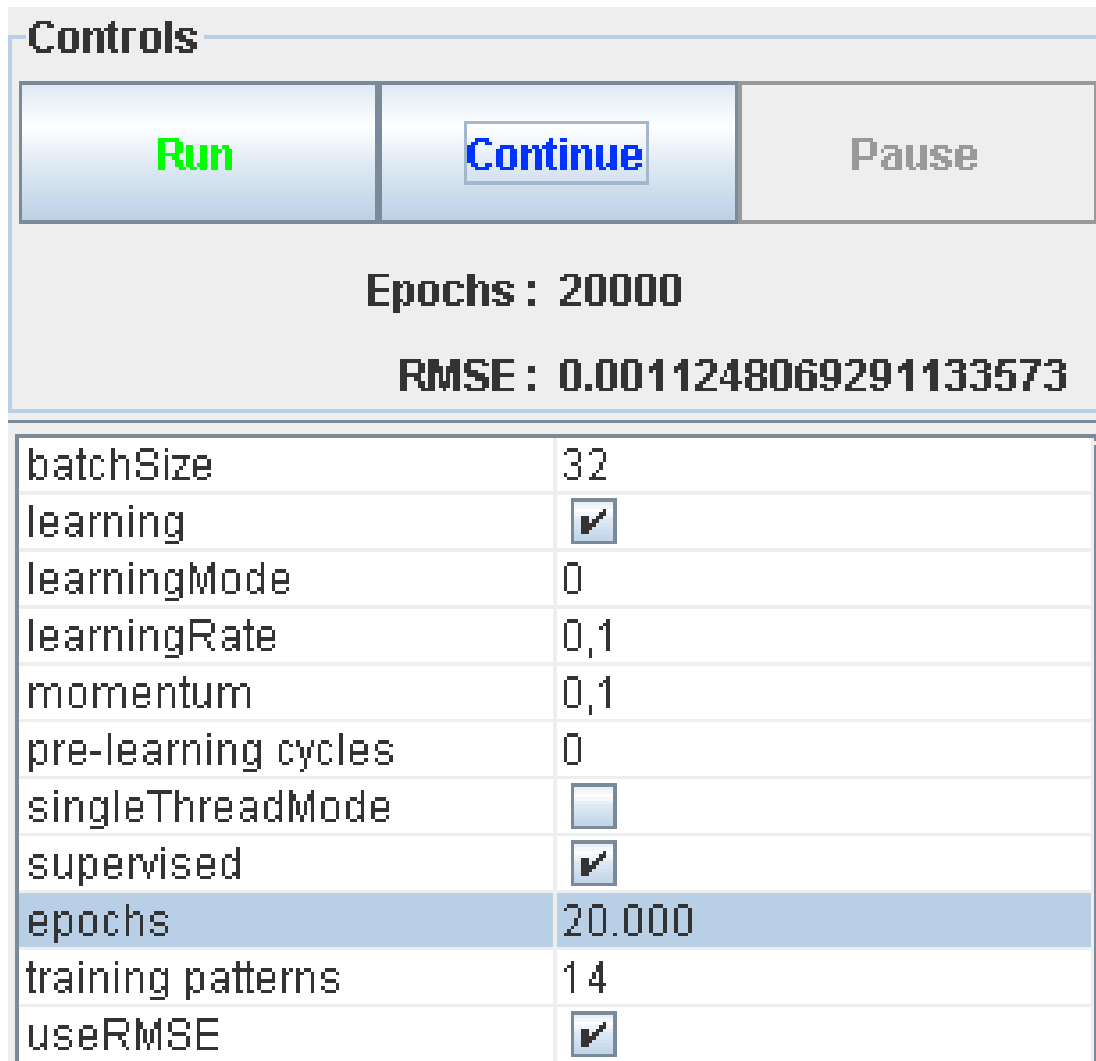


Figura 88: Vigésimo Tercer Intento, 0.1 LR, 0.1 M, 20000 E.
Fuente: Fernández (2022).

En total, se realizaron alrededor de 28 intentos, es decir, 28 recorridos completos a todas las épocas definidas, con distintos hiperparámetros. En la figura 81 se muestra el primer intento de la primera combinación, para una tasa de aprendizaje de 0.2, un momento de 0.3, y 1000 épocas. Estos parámetros se abrevian por sus nombres en inglés, como LR, M y E. De esta forma, la idea es cambiar hiperparámetros para encontrar el mejor valor inicial de error, y a partir de allí, si los entrenamientos

subsecuentes permiten seguir disminuyendo el valor del mismo, hacerlo hasta que se alcance el rango de valores deseado. Así, se observa que, al dar el mejor resultado inicial en el error cuadrático medio, la combinación 0.1 LR, 0.1 M, y 20000 E, de la figura 88, fue la mejor opción para continuar entrenando.

Tras realizar 23 entrenamientos con dichos hiperparámetros y el conjunto de datos presentes en la red, se obtuvo un error de, alrededor de 0.0011, efectivamente menor al error de 0.0012 definido por los antecedentes. Como el total de entrenamientos fue de 23, para un hiperparámetro de 20000 épocas, es posible representar que la suma de dichos ciclos completos fue de 460 mil épocas en total.

4.5.4.1. Valores Predichos por la Red

Así como la entrada directa a la red se realiza en base a los datos normalizados, la salida directa de los mismos sigue la misma forma. En este caso, se tiene una sola columna de salida, los valores predichos de rugosidad, con un error cuadrático medio de 0.0011. Los valores normalizados pueden observarse en la figura 89 en el formato de archivo .txt original, mientras que los valores luego de deshacer la normalización y la comparación de cada uno con sus valores reales puede verse en la tabla 14.

0.9762281909472094
0.7894992901772372
0.29600438202274537
0.33204060574682887
0.4612964657131477
0.4184107775681034
0.4767217281252691
0.4969902214895235
0.05060631191564569
0.4908458317311096
0.5232018822560766
0.6270587381988731
0.6484392490422773
0.7603812815408526

Figura 89: Resultados Predichos de Rugosidad Normalizados, en su formato de Archivo de Salida Original.

Fuente: Fernández (2022).

Tabla 14: Resultados Predichos de Rugosidad luego de Deshacer la Normalización, y Comparación con Valores Reales.

Ra tras deshacer la normalización (μm)	Valores reales de Ra (μm)	Comparación entre valores (μm)
6,02137548	6,168	0,14662452
4,86963162	4,98733333	0,11770171
1,82575503	1,88333333	0,05757831
2,04802646	2,07866667	0,03064021
2,8452766	2,91133333	0,06605673
2,58075768	2,63866667	0,05790899
2,94041962	3,01933333	0,07891371
3,06543569	3,14	0,07456431
0,31213973	3,188	2,87586027
3,02753709	3,11722222	0,08968513
3,22710921	3,30533333	0,07822412
3,8676983	3,95933333	0,09163504
3,99957329	4,076	0,07642671
4,69003174	4,816	0,12596826

Fuente: Fernández (2022).

Dentro de los resultados de la red, en la tabla 14, pueden notarse dos aspectos importantes; el primero, es que el error en casi todos los parámetros es, en efecto mínimo. De los 14 parámetros, 10 tienen desviaciones en el orden de las centésimas, mientras que otros 3 tienen desviaciones en décimas. Todos estos factores de error se

consideran muy pequeños dentro de los casos de utilización de las redes neuronales artificiales. Por otra parte, el valor faltante; el décimo cuarto, es el que denota el segundo aspecto importante de los resultados. El valor se desvía del valor real, por una magnitud de error que es casi igual al valor mismo. Este suceso, no obstante, no es un impedimento para el funcionamiento de la red, si no, una demostración de una propiedad interesante de las mismas; la dificultad de encontrar un mínimo global.

Esto proviene de las matemáticas explicadas en la fase 4; la base del aprendizaje de las redes neuronales es el backpropagation, que se realiza a su vez con el algoritmo del descenso de gradiente. Este último, como se explicó con anterioridad, funciona buscando que la derivada de la función de coste se haga cero, con la intención de que el error se minimice todo lo posible. Ahora, dependiendo de la función de error escogida, o de los datos utilizados, la distribución puede cambiar, de forma que se encuentre uno de dos factores importantes; un mínimo local, o un punto de silla (Ver figura 90).




Figura 90: Mínimos Locales y Puntos de Silla o Ensilladura, en la Función de Coste con Respecto a los Pesos.

Fuente: IBM (s.f.).

En ambos casos, no se encuentra un mínimo global en la función, o se encuentra más allá del rango en el que la red puede identificarlo, por lo que la consecuencia práctica es que no se puede definir un punto de convergencia general, de manera que la red neuronal encontrará uno de los otros dos casos, y así obtendrá la capacidad de predecir resultados precisos con respecto a un rango de valores, pero no a la totalidad de la data.

De esa forma, como se indica que la red dejará de aprender en el momento en el que se encuentre el primer cero en la pendiente de la función de coste, puede darse el caso de los mínimos locales, que imitan a los globales, con la pendiente incrementando en cualquier dirección, pero sin explorar todos los datos, y los puntos de silla, que solo tienen gradiente negativo hacia un lado, de forma que llegan a un máximo local en un lado y a un mínimo local del otro.

Además, se dice que, por lo general, la probabilidad de que dicho punto ocasionando la divergencia sea un punto de silla es mayor según la cantidad de datos sea más grande, mientras que la probabilidad de que la misma sea causada por un mínimo local aumenta cuando el número de datos disminuye. Considerando que el conjunto de datos utilizado es relativamente pequeño, se indica que, en el caso de la investigación, lo más probable es que la desviación esté dada por la interferencia de un mínimo local, que dificulte la ubicación de un verdadero punto de convergencia.

4.5.5. Discusión de Resultados

De la primera fase de la investigación, el diagnóstico; se identificaron los parámetros de corte que debieron utilizarse en el resto de la investigación y también se obtuvieron conclusiones como; en primer lugar, la ratificación del hecho de que, al aumentar las velocidades de corte de las piezas de trabajo, los acabados superficiales tienden a aumentar hasta cierto punto, y lo mismo es cierto en cuando se disminuyen los avances. Esto, además, se teorizó que está relacionado directamente a la longitud de material que la herramienta arranca en un momento dado, y que afecta la

uniformidad de la rugosidad, y a la vez, al desgaste de la misma y la forma en la que las partículas que esta libera en ese proceso atacan a la superficie.

De esa manera, por lo general, las vibraciones mecánicas y el desgaste de la herramienta, así como las capacidades de la máquina herramienta, identifican los valores máximos que parámetros beneficiosos, como la velocidad de corte, pueden alcanzar sin volverse agresivos, para la rugosidad al final del mecanizado. También fue notable que el refrigerante, si bien no siempre contribuyó negativamente a la rugosidad de forma directa, sí podía acelerar el proceso corrosivo y desmejorar el acabado en las probetas que no se trataban adecuadamente luego del mecanizado.

Durante la segunda fase de la investigación, el mecanizado; se realizaron diversas observaciones acerca de la forma en la que los parámetros escogidos en el diagnóstico interactuaron con los resultados, a nivel macroscópico, en cuanto a las dimensiones de las probetas y en cuanto a la idea aparente de rugosidad, en la superficie a simple vista, así como en el desgaste de las herramientas, parámetro fundamental de esta fase de la investigación.

De esta manera, se observó dentro de las dimensiones de las probetas una conicidad de hasta un máximo de 2 centésimas de milímetro, y se concluyó experimentalmente que las fuerzas de corte fueron apropiadas para la operación en cuestión, dentro del carburo de tungsteno, puesto a que, aunque la condición de sujeción entre puntos varió al principio de los ensayos, debido al desgaste en uno de ellos, para el final se mantuvo de una forma apropiada, con un punto más resistente.

Sobre la idea aparente de rugosidad, fue notable que, para los parámetros de corte escogidos, muy pocas probetas se mostraron con una rugosidad desfavorable, a simple vista. La mayoría de las mismas resultaron tener condiciones aparentemente similares, a excepción de las cortadas con la sierra de vaivén; que no tuvieron tan buen acabado a simple vista como las muestras de refrentado y cilindrado.

También se notó que las herramientas se desgastaron de una forma mucho mayor a la que se esperaba. De hecho, fue durante esta fase que se descartó la idea de utilizar la cuchilla orientable de acero rápido, ya que el desgaste de la misma fue exagerado durante los ensayos que se realizarían con ella. Con los parámetros de corte más exigentes, la cuchilla en cuestión no logró terminar el recorrido de su porción de la probeta, aun utilizando abundante refrigeración. Por ello, se eliminaron la mayoría de las probetas de acero rápido del resto del proceso, y se concluyó que dicho material no es apto para el ensayo, porque el tipo de desgaste que sufría hacía considerablemente difícil mecanizar una cantidad de probetas considerable con él, además de mantener su geometría a través de tantos procesos de afilado.

Sobre el resto del proceso de mecanizado con carburo de tungsteno, se concluyó que el desgaste de la herramienta era evidentemente mayor cuando no se utilizaba refrigeración, pero también que la herramienta de carburo de tungsteno fue muy tenaz, y soportó la mayoría de los ensayos de forma apropiada. El afilado de la misma se realizó con óxido de zirconio y carburo de silicio, donde, tras observar el filo, se notó que, si bien el óxido de zirconio retiró el material con fallas más rápidamente, el óxido de aluminio ayudó a mejorar el acabado del filo. En el acero rápido, el efecto fue parecido, pero con el óxido de aluminio en lugar del óxido de zirconio, y con el carburo de silicio en el lugar del óxido de aluminio.

Además, también se observó que la mecha de centro se fracturó en una punta durante la realización de los ensayos, lo que también demuestra y permite concluir, experimentalmente, que la fatiga de la misma, con su diámetro y el HSS, son relativamente sensibles al trabajo con el AISI 1045, debido probablemente a su dureza, por la cantidad de carbono que posee. Esta realización acerca del desgaste en función del material también es cierta para ambas cuchillas orientables, a la vez.

La maquinabilidad del 1045 fue también, responsable en gran medida, del desgaste del carburo de tungsteno y del desgaste excesivo del acero rápido en las

orientables. También fue notable la resistencia a la corrosión de las probetas una vez que se realizó en ellas el tratamiento adecuado, concluyendo que la adición del petrolato a su superficie y su almacenaje hermético la aumenta considerablemente.

En la tercera fase de la investigación, la medición de rugosidad; la primera conclusión importante es que la misma, es importante de medir a través de distintas formas, más que de una sola. En este aspecto, la Macroscopía únicamente ayudó a caracterizar las diferencias entre algunas probetas, pero para la gran mayoría, las mismas eran parecidas. Por otra parte, el rugosímetro empezó a mostrar diferencias más considerables entre varias probetas que a simple vista se encontraban en buena forma de acabado; mientras que el microscopio terminó enseñando distinciones enormes entre probetas con diferencias pequeñas entre los otros parámetros.

También se concluyó durante la medición de la rugosidad que la misma varia ampliamente a través de las piezas, aunque hayan sido sometidas a, en teoría, una única condición de sujeción, y a las mismas condiciones de corte. En este aspecto, se indica que la sujeción probablemente no es tan uniforme a lo largo de toda la probeta como se creyó inicialmente, por las deflexiones que crean las fuerzas de corte y las vibraciones mecánicas transmitidas desde la máquina. Por esta razón es que se tuvieron que realizar mediciones diversas en la longitud de la probeta, más allá de en su perímetro, teniendo que caracterizar ambas.

Igual de concluyente fue el hecho de que los parámetros Ra, al observarlos al microscopio, denotan una serie de factores que sirven de guía para identificar las imágenes que se están viendo. Así, los grandes parámetros Ra se correspondieron con micrografías mucho más regulares, y con patrones más limpios, de surcos en algunos casos más anchos, y con una inmensa cantidad menor de cráteres localizados en las marcas de fluencia, muchas menos imperfecciones en el trayecto de la herramienta.

Fue particularmente importante la diferencia entre los resultados con respecto a los parámetros de corte y a la relación entre los números Ra y las micrografías, por los

patrones que se marcaron a través de ellas; como las conclusiones en el hecho de que las velocidades de corte más altas se confirmaron como las que ofrecen los mejores acabados, siempre que el desgaste de las herramientas no sea lo suficientemente grande para crear imperfecciones en el camino de las marcas de fluencia. A su vez, los avances más grandes contribuyeron a surcos más anchos, y en la mayoría de los casos los mismos estuvieron relacionados a parámetros Ra ligeramente más altos, en gran parte por el engrosamiento de los perfiles.

Una de las conclusiones más importantes de esta fase fue el hecho de que, en la micrografía, uno de los mejores acabados se obtuvo en probetas de acero rápido con altas velocidades de corte, y si bien el parámetro Ra no fue tan alto en ellas como para algunas probetas de carburo de tungsteno, se considera que dicho fenómeno se debió a la mayor presencia de imperfecciones pequeñas en las probetas de acero, probablemente debidas al desgaste de la herramienta.

A la vez, el efecto de la velocidad de corte en los resultados fue plenamente patente en la última probeta, del estudio breve del desgaste del acero rápido, donde se utilizaron las 175 RPM, el valor más bajo del estudio, que fue a su vez una terrible microestructura, con una rápida velocidad de corrosión con respecto al resto, y con una inmensa cantidad de cráteres e imperfecciones, irregularidades y discontinuidades.

Durante la cuarta fase, la selección de la red; se concluyó que los hiperparámetros son, en efecto, los valores más importantes que pueden configurarse en su realización, así como su influencia. También, se definió que el problema en cuestión era uno de regresión, y se concluyó también que, para la cantidad de datos disponibles, la mejor arquitectura sería una que evitase el overfitting utilizando una cantidad moderada de neuronas y capas, y también que previniese el underfitting a través de un número levemente mayor al de las neuronas de entrada, y una transición suave hacia la de salida. De esta forma, se concluyó que la mejor arquitectura para la red sería 4-5-3-1.

También se concluyó que la función de activación más conveniente para la red era la sigmoïdal, por el requerimiento de precisión de la red, la cantidad de tiempo disponible para entrenarla, y la naturaleza normalizada de los datos, que encajaba perfectamente con los requerimientos de la misma, además; al ver su gráfica, se observó que la misma posee un perfil similar al de los perfiles de rugosidad.

Igualmente, entre las conclusiones de la cuarta fase se encontró que era más beneficioso inicializar a la red con el resto de los hiperparámetros en números considerables, a partir de los cuales verificar su funcionamiento y precisión para modificar en la dirección más conveniente según ellos en la fase siguiente. Por eso, en esta fase se entendió el comportamiento del momento, la tasa de aprendizaje, el tamaño de lotes, y las épocas, escogiendo finalmente las tasas de inicialización. También se concluyó durante esta fase que, dadas sus características, al compararlos, utilizar el software Joone, basado en Java, era más conveniente que utilizar Python con Keras y TensorFlow, como se había planteado originalmente.

Finalmente, en la quinta fase; la aplicación de la red, se realizaron los arreglos necesarios de los datos en términos de tipos de archivos, y se observó que la mejor forma de alimentar los datos a la red, era utilizando una técnica de normalización para el entrenamiento, aprovechando la naturaleza de la función sigmoïdal y estandarizando la data en el proceso.

Luego de la realización de la estructura, se comprobó y concluyó también que la supresión de los resultados del acero rápido del experimento mejoraba y aseguraban el funcionamiento eficiente de la red, ya que los mismos no eran suficientes datos, ni en un rango apropiado, para facilitar la convergencia de ninguna forma. En términos computacionales, se concluyó también que, si bien los datos de entrenamiento y de predicción son técnicamente de tipos muy parecidos, es mucho más conveniente trabajar a los primeros en un mismo archivo y conjunto que los de entrada, más porque

Joone lo permite de esa manera; y que los de predicción funcionan mejor en un archivo aparte, ambos del tipo “.txt” y separados por comas.

Sobre la optimización de hiperparámetros, luego de comenzar el entrenamiento de la red con los datos escogidos en la fase 4, se determinó que el error cuadrático medio debía ser menor a 0.0012, y más aún, que de entre todos los hiperparámetros probados, las mejores condiciones de la red se obtenían con los valores definidos en arquitectura y funciones, pero, además, con una tasa de aprendizaje de 0.1, un momento de 0.1, un tamaño de lotes de 32, y 20 mil épocas. Entrenar este modelo 23 veces, concluyó que la red neuronal pudo obtener el error deseado, menor a 0.0012. En este aspecto, la red alcanzó un error de 0.0011.

También se concluyó que, si bien 13 de los parámetros de los 14 utilizados tuvieron resultados excelentes, con errores en el orden de décimas o, en su mayoría, centésimas, existió un valor que divergió y se alejó de su valor necesario por una magnitud casi igual a la del valor de entrenamiento. En este aspecto, se concluyó por las características del conjunto de datos y por el comportamiento de los resultados, que lo más probable en ese caso fue la existencia de un mínimo local, por el conjunto pequeño de datos variados, lo que provoca una discontinuidad de muy baja magnitud en la predicción del mismo, para la cual no hay convergencia.

No obstante, se identifica también que, aun así, el sistema sigue siendo altamente óptimo, ya que se observa que las predicciones de $R_a = 3.14 \mu\text{m}$, y de $R_a = 3.31 \mu\text{m}$, directamente por debajo y por encima, respectivamente, del valor con el error, que es el de $R_a = 3.19 \mu\text{m}$ son excelentes, por lo que se determina que el rango de valores que pueden verse afectados por este fenómeno es poco importante; además de por el error cuadrático medio mínimo de la red en general.

CAPÍTULO V

CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones

Del diagnóstico de las condiciones de corte, se concluyó que los mejores parámetros para la realización del estudio con el material de trabajo planteado eran dos condiciones de refrigeración: En seco y refrigerado; tres velocidades de corte: 845 RPM, 545 RPM, y 395 RPM. Tres profundidades de corte: 1 mm, 0.6 mm, y 0.3 mm. Y tres velocidades de avance: 0.027 mm/rev, 0.104 mm/rev, y 0.207 mm/rev. No se consideró el material de las cuchillas, porque se encontró que las de acero rápido se desgastaban muy rápidamente.

Del mecanizado, se concluyó que los parámetros que más afectaron la vida de las herramientas fueron la velocidad de corte y el avance; y que la cuchilla de carburo de tungsteno puede tener un comportamiento excepcional en cuanto a vida útil, a altas velocidades de corte, incluso en condiciones en las que se ausenta la refrigeración, pero el aumento en el avance siempre resulta desgastar mucho más rápido cualquier tipo de cuchilla.

De la medición de rugosidad, se concluyó que los parámetros que afectaron en mayor medida al acabado superficial fueron, en primer lugar, y de manera exagerada, la velocidad de corte. En segundo, el avance, y por último, la profundidad de corte; mientras que la influencia de la refrigeración se hizo presente casi exclusivamente en la presencia o no, y en la formación, de óxido de hierro.

Durante el proceso de la selección de la red, pudo concluirse, que los mejores hiperparámetros para inicializar la red neuronal artificial a realizar en la investigación para trabajar el conjunto de datos obtenido en rugosidad, fueron, una arquitectura 4-5-3-1, funciones de activación sigmoideas, una tasa de aprendizaje y un momento de 0.2 y 0.3, un tamaño de lotes de 32, y un número de épocas de 1000.

De la aplicación de la red neuronal, fue posible llegar a la conclusión de que los mejores hiperparámetros para terminar de entrenar a la red neuronal artificial en cuestión son la arquitectura, la función de activación y el tamaño de lotes escogidos, pero una tasa de aprendizaje y un momento de 0.1, además de un número de épocas de 20000.

También de la aplicación, se concluyó que las redes neuronales pueden ser un excelente instrumento para la predicción de la rugosidad con base en modelos físicos reales, con base al error cuadrático medio obtenido en la investigación. Si bien la mayoría de los modelos comunes de regresión lineal obtienen hasta un 5% de precisión, la red tuvo un error cuadrático medio de 0.0011, lo que la hace aún más precisa, y por ende, se concluye que además de ser un instrumento excelente, son más convenientes que otras herramientas convencionales.

5.2. Recomendaciones

Se recomienda a los profesores, estudiantes y talleres de mecanizado, realizar estudios posteriores:

- En los que se utilicen portaherramientas e insertos estandarizados según normas ISO.
- En máquinas herramienta de control numérico computarizado con las mismas condiciones y parámetros de la investigación, y contrastar resultados.
- Acerca de la utilización de, principalmente, el acero rápido.
- Utilizando dinamómetro, para estudiar los efectos de las fuerzas de corte, cámara de infrarrojos para ver sus temperaturas, y ultrasonido, para analizar el funcionamiento de todos los rodamientos internos de la máquina herramienta.
- Con una mayor cantidad de materiales de trabajo, para extender las capacidades de caracterización de la red neuronal.

- Del perfil como lo grafica el stylus del rugosímetro, puesto a que pueden compararse con las micrografías del acabado para mejorar la caracterización.
- Con técnicas diferentes en el descenso de gradiente, utilizando otro tipo del mismo, distinto al por lotes.
- Con un algoritmo más complejo de optimización automática de hiperparámetros, y con variaciones más amplias de los mismos, incluidos los que se mantuvieron fijos en este caso.
- Con otros lenguajes de programación o motores de computación neuronal, y comparar los resultados.

REFERENCIAS BIBLIOGRÁFICAS

- AccuScope. (s.f.). **Catálogo Online**. <https://accu-scope.com/accuscope-microscopes.html>
- Aguilar, S. (2006). **Modelación del Acabado Superficial en Procesos de Mecanizado**. México: Instituto Tecnológico y de Estudios Superiores de Monterrey.
- Alto, V. (2019). **Neural Networks: parameters, hyperparameters and optimization strategies**. <https://towardsdatascience.com/neural-networks-parameters-hyperparameters-and-optimization-strategies-3f0842fac0a5>
- American Society for Metals. (2005) ASM Handbook. **Properties and Selection; Irons, Steels, and High-Performance Alloys. Vol 1**. Estados Unidos de América: ASM.
- American Society for Metals (1967), **Metals Handbook-Machining, Vol. 3**. Estados Unidos de América: ASM.
- Arias, F. (2006). **El Proyecto de Investigación**. Quinta edición. Venezuela: Editorial Episteme.
- Arias, F (2012). **El Proyecto de Investigación. Introducción a la Metodología Científica**. 6ta Edición. Venezuela: Editorial Episteme.
- Askeland D., Wendelin J. (2013). **Ciencia e Ingeniería de Materiales**, sexta edición, Mexico: Cengage Learning, S.A.
- Balestrini, M. (2006). **Como se Elabora el Proyecto de Investigación**. Séptima edición. Venezuela: BL Consultores Asociados.
- Buehler. (s.f.). **Catálogo Online**. <https://www.buehler.com/products/hardness-testing/>
- Callister, W., Rethwisch, D. (2018), **Materials Science and Engineering, An Introduction**. Décima Edición. Estados Unidos de América: Wiley.

- Cárdenas, J. (2017). **Optimización de los Parámetros Tecnológicos en el Proceso de Fresado para obtener la Mínima Rugosidad en el Acero AISI/SAE 1045**. Colombia: Universidad Distrital Francisco José De Caldas.
- Curra, D., Hernández, L. de la Rosa, J. Zambrano, P. Guerrero, y Pérez, R. (2020). **Estimación del Consumo Específico de Energía en el Torneado de Alta Velocidad del Acero AISI-1045 Utilizando Redes Neuronales**. Cuba: Universidad Tecnológica de La Habana José Antonio Echeverría.
- Dormer Pramet. (s.f.). **Catálogo Online**. <https://www.dormerpramet.com/br/en/>
- Flórez R., Fernández J. (2008). **Las Redes Neuronales Artificiales, Fundamentos Teóricos y Aplicaciones Teóricas**, España: Netbiblo, S.L.
- Gómez, R. (2020). **Desarrollo de un Modelo de Redes Neuronales Artificiales que Permitan Predecir las Fallas del Acero SAE 1020 Sometido a un Proceso de Mecanizado Mediante un Torno de Control Numérico Computarizado**. Venezuela: Universidad José Antonio Páez.
- González, R., Salazar, F. (2008). **Aspectos Básicos del Estudio de Muestra y Población para la Elaboración de Proyectos de Investigación**. Venezuela: Universidad de Oriente.
- Groover, M. (2007). **Fundamentos de Manufactura Moderna: Materiales, Procesos y Sistemas**. 3era edición, México: McGraw-Hill.
- Hernández L., Pérez, R., Curra, D. (s.f.). **Optimization of Cutting Parameters Based on Temperature and Surface Roughness for Turning of AISI 1045 Steel**. España: Universidad de Sevilla.
- Hernández, R., Fernández, C. y Baptista, P. (2014). **Metodología de la Investigación**. Sexta edición. México: McGraw-Hill.
- Hertz J., Krogh, A., Palmer, R. (1991). **Introduction to the Theory of Neural Computation**. Estados Unidos de América: CRC Press, Taylor & Francis.

- Hilera J., Martínez V. (1994). **Redes Neuronales Artificiales. Fundamentos, Modelos y Aplicaciones.** España: RA-MA.
- IBM Cloud Education (2020). **Gradient Descent.**
<https://www.ibm.com/cloud/learn/gradient-descent>
- Impero Tools. (s.f.). **Catálogo Online.** <https://www.imperotoolsusa.com/IMPERO-TOOLS.php>
- ISO (1978). **1302, Geometrical Product Specifications (GPS) — Indication of surface texture in technical product documentation.** Suiza: ISO.
- Jacas, M. Rodríguez, T., Lopez, J. (2015). **The Influence of Cutting Speed and Feed Rate in Surface Integrity of AISI 1045.** Cuba: Instituto Superior Politécnico José Antonio Echeverría.
- Kalpakjian S. (2008). **Manufactura, Ingeniería y Tecnología.** Quinta edición. México: Pearson Education.
- Mitutoyo. (s.f.). **Catálogo Online.** https://www.mitutoyo.com/webfoo/wp-content/uploads/US-1005_Mitutoyo_Catalog.pdf
- Morales, Y. Zamora, Y. Vásquez, P. Porras, M. Bárzaga, J. y López, R. (2018). **Comparación entre Redes Neuronales Artificiales y Regresión Múltiple para la Predicción de la Rugosidad Superficial en el Torneado en Seco.** Ecuador: Ingenius, Universidad Politécnica Salesiana.
- Nee, Dufraine, Evans, Hill. (2010). **Fundamentals of Tool Design.** Estados Unidos de América: Society of Manufacturing Engineers.
- Pereira, J. (2004). **Procesos de Fabricación por Arranque de Viruta.** Universidad de Carabobo.
- Raffino, M. (2019). **Métodos de Investigación.** Argentina (s.n).
- Sabino, C. (1992). **El Proceso de Investigación.** Venezuela: Editorial Panapo.

- Schey J. (2002). **Procesos de Manufactura**. tercera edición, México: McGraw-Hill/ Interamericana Editores, S.A.
- Shackelford, J., (2005), **Introducción a la Ciencia de Materiales para Ingenieros**, sexta edición, Pearson, Prentice Hall.
- Walmart. (s.f.). **Sección de Microscopios Digitales Comerciales**.
<https://www.walmart.com/ip/EBTOOLS-AN104-3-In-1-Electric-Microscope-Multi-Purpose-Type-C-USB-Microscope-For-Mobile-Phones-Computers-Digital-Microscope/125668967?wmlspartner=wlpa&selectedSellerId=101043400>
- Yrady M., Mujica V. (2020). **Estudio de la Rugosidad Superficial de un Acero AISI 1045 Tratado Térmicamente y Torneado por CNC Mediante la Implementación de una Red Neuronal Artificial**. Venezuela: Universidad José Antonio Páez.

ANEXOS

Anexo A. Instrumentos de Medición Utilizados

Anexo A.1: Microscopio Metalúrgico Invertido, modelo 3035, AccuScope



Fuente: Catálogo Online, AccuScope (s.f.)

Anexo A.2: Durómetro Rockwell, modelo LCR-200R, Buehler.



Fuente: Catálogo Online, Buehler (s.f.)

Anexo A.3: Perfilómetro, modelo PJ-A3000, Mitutoyo.



Fuente: Catálogo Online, Mitutoyo (s.f.)

Anexo A.4: Rugosímetro modelo SurfTest SJ-201, Mitutoyo.



Fuente: Catálogo Online, Mitutoyo (s.f.)

Anexo A.5: Microscopio Digital, modelo AN104, de EBTOOLS.



Fuente: Sección de Microscopios Digitales Comerciales, Walmart (s.f.)

Anexo B. Ángulos de las Herramientas de Corte

Anexo B.1: Ángulo Lateral del Filo de Corte, Acero Rápido.




Fuente: Fernández (2022)

Anexo B.2: Ángulo de Extremo del Filo de Corte, Acero Rápido:



Fuente: Fernández (2022)

Anexo B.3: Ángulo de Extremo del Filo de Corte, Carburo de Tungsteno:



Fuente: Fernández (2022)

Anexo B.4: Ángulo Principal del Filo de Corte, Carburo de Tungsteno:



Fuente: Fernández (2022)


Anexo B.5: Ángulo Secundario del Filo de Corte, Carburo de Tungsteno:



Fuente: Fernández (2022).

Anexo C. Desgaste de las Herramientas de Corte

Anexo C.1: Acero Rápido:



Fuente: Fernández (2022).

Anexo C.2: Carburo de Tungsteno:



Fuente: Fernández (2022).

Anexo D. Parámetros de Corte Originales, Diseño Factorial Completo

Anexo D.1: Parámetros de Corte para el Carburo de Tungsteno Refrigerado.

Herramienta y Condición de Lubricación	Velocidad de Corte (RPM)	Profundidad de Corte (mm)	Velocidad de Avance (mm/rev)
Carburo de Tungsteno Refrigerado	845	1	0.072
			0.104
			0.207
		0,6	0.072
			0.104
			0.207
		0,3	0.072
			0.104
			0.207
	545	1	0.072
			0.104
			0.207
		0,6	0.072
			0.104
			0.207
		0,3	0.072
			0.104
			0.207
	395	1	0.072
			0.104
			0.207
		0,6	0.072
			0.104
			0.207
0,3		0.072	
		0.104	
		0.207	

Fuente: Fernández (2022).

Anexo D.2: Parámetros de Corte para el Carburo de Tungsteno Seco.

Herramienta y Condición de Lubricación	Velocidad de Corte (RPM)	Profundidad de Corte (mm)	Velocidad de Avance (mm/rev)
Carburo de Tungsteno Seco	845	1	0.072
			0.104
			0.207
		0,6	0.072
			0.104
			0.207
		0,3	0.072
			0.104
			0.207
	545	1	0.072
			0.104
			0.207
		0,6	0.072
			0.104
			0.207
		0,3	0.072
			0.104
			0.207
	395	1	0.072
			0.104
			0.207
		0,6	0.072
			0.104
			0.207
0,3		0.072	
		0.104	
		0.207	

Fuente: Fernández (2022).

Anexo D.3: Parámetros de Corte para el Acero Rápido Refrigerado.

Herramienta y Condición de Lubricación	Velocidad de Corte (RPM)	Profundidad de Corte (mm)	Velocidad de Avance (mm/rev)
Acero Rápido Refrigerado	845	1	0.072
			0.104
			0.207
		0,6	0.072
			0.104
			0.207
		0,3	0.072
			0.104
			0.207
	545	1	0.072
			0.104
			0.207
		0,6	0.072
			0.104
			0.207
		0,3	0.072
			0.104
			0.207
	395	1	0.072
			0.104
			0.207
		0,6	0.072
			0.104
			0.207
0,3		0.072	
		0.104	
		0.207	

Fuente: Fernández (2022).

Anexo D.4: Parámetros de Corte para el Acero Rápido Seco.

Herramienta y Condición de Lubricación	Velocidad de Corte (RPM)	Profundidad de Corte (mm)	Velocidad de Avance (mm/rev)	
Acero Rápido Seco	845	1	0.072	
			0.104	
			0.207	
		0,6	0.072	
			0.104	
			0.207	
			0,3	0.072
				0.104
				0.207
	545	1	0.072	
			0.104	
			0.207	
		0,6	0.072	
			0.104	
			0.207	
			0,3	0.072
				0.104
				0.207
	395	1	0.072	
			0.104	
			0.207	
		0,6	0.072	
			0.104	
			0.207	
0,3			0.072	
			0.104	
			0.207	

Fuente: Fernández (2022).