

**UNIVERSIDAD NACIONAL TECNOLÓGICA DE LIMA SUR
UNTELS**

**FACULTAD DE INGENIERÍA Y GESTIÓN
ESCUELA PROFESIONAL DE INGENIERÍA ELECTRÓNICA Y
TELECOMUNICACIONES**



**“PREDICCIÓN DEL DESGASTE DE LA CUCHILLA EN UNA
FRESADORA CNC UTILIZANDO ALGORITMOS DE MACHINE
LEARNING”**

TESIS

**PARA OPTAR EL TÍTULO PROFESIONAL DE:
INGENIERO ELECTRÓNICO Y TELECOMUNICACIONES**

PRESENTADO POR EL BACHILLER:

PAIMA SAHUMA, JAIME JAIR

Villa El Salvador, 2023

PERÚ



**Universidad Nacional
Tecnológica de Lima Sur**

DECLARACIÓN JURADA DE NO HABER INICIADO TRÁMITE DE TITULACIÓN POR OTRA MODALIDAD

Yo JAIME JAIR PAIMA SAHUMA, Bachiller de la Escuela Profesional de Ingeniería Electrónica y Telecomunicaciones con DNI N° 73478926 y código de estudiante N° 2015100237, DECLARÓ NO HABER INICIADO TRÁMITE DE TITULACIÓN POR OTRA MODALIDAD.

Asumiendo que de no cumplir con el presente compromiso la UNTELS adopte las medidas administrativas que correspondan.

En fe de lo cual firmo la presente DECLARACIÓN JURADA, a los 03 días del mes de Enero del 2022.

Para tener una idea clara de la predicción con machine learning del desgaste que tenga aplicación en la cuchilla a la hora de reducir el costo computacional. En la sección II nos enfocaremos en presentar un marco teórico sólido y actualizado que respalda la investigación a nivel nacional e internacional relacionados con el desgaste de cuchillas. En el apartado III se centra en la descripción de la metodología utilizada en la investigación con una base de datos específica y se presentan los resultados obtenidos. En el apartado IV se explican y analizan los resultados obtenidos con la eficacia de los principales hallazgos y se analizan los datos obtenidos para su interpretación posterior. Las conclusiones correspondientes a la investigación sobre el desgaste donde se destacan los resultados más relevantes detallados en la Sección V, y también se mencionan recomendaciones a considerar y tener en cuenta para futuros estudios y temas relacionados con la predicción del desgaste de cuchillas.

Nombre y Apellido: JAIME JAIR PAIMA SAHUMA
DNI N°: 73478926



**Universidad Nacional
Tecnológica de Lima Sur**

DECLARACIÓN JURADA DE REALIZAR TRABAJO INÉDITO

Yo JAIME JAIR PAIMA SAHUMA, Bachiller de la Escuela Profesional de Ingeniería Electrónica y Telecomunicaciones con DNI N° 73478926 y código de estudiante N° 2015100237, DECLARO que el trabajo de investigación que presento como tesis para la obtención del Título de Licenciatura en Ingeniería Electrónica y Telecomunicaciones es original, siendo resultado de mi trabajo de investigación personal, el cual no he copiado de otro trabajo de investigación, ni utilizado ideas, fórmulas, ni citas completas “stricto sensu”; así como ilustraciones diversas, sacadas de cualquier tesis, obra, artículo, memoria, etc., (en versión digital o impresa).

Caso contrario, menciono de forma clara y exacta su origen o autor, tanto en el cuerpo del texto, figuras, cuadros, tablas u otros que tengan derechos de autor.

Asimismo, DECLARO que el trabajo de investigación que pongo en consideración para evaluación no ha sido presentado anteriormente para obtener algún grado académico o título, ni ha sido publicado en sitio alguno.

Soy consciente de que el hecho de no respetar los derechos de autor y hacer plagio, es objeto de sanciones universitarias y/o legales, por lo que asumo cualquier responsabilidad que pudiera derivarse de irregularidades en la tesis, así como de los derechos sobre la obra presentada.

En fe de lo cual firmo la presente DECLARACIÓN JURADA, a los 03 días del mes de Enero del 2022.

Nombre y Apellido: JAIME JAIR PAIMA SAHUMA
DNI N°: 73478926

DEDICATORIA

A Dios todopoderoso, por guiarme con la fortaleza para superar las situaciones presentadas durante todo proceso estudiantil, para lograr la finalización de esta tesis y por todas las bendiciones recibidas hasta el día de hoy.

A mi madre, Rosa Yesenia Sahuma Gutiérrez, por su apoyo incondicional y por su confianza durante todo mi proceso de formación Educativa, ser ejemplo de perseverancia, por haberme orientado siempre hacia el camino de lucha y superación constante e intentar ser una buena madre a tan corta edad cuando me tuvo en su vientre y cuando nací para convertirme en su orgullo. Sin ella mis logros no se harían realidad.

A mi padre, Jaime Paima Garcia, por haber estado a mi lado durante el tiempo que pudo en el período académico, aconsejándome y apoyándome en todo momento de mi carrera, mostrándome con su ejemplo de fortaleza y el modelo para no doblegarme en ningún momento.

A mis tres hermanos, siendo menores que yo, serán siempre una extensión más de mi vida, que me han acompañado en los momentos más difíciles a lo largo de todo este proceso. Son una inmensa bendición durante todo el viaje de mi vida.

A toda mi familia por haberme forjado en la persona que soy en la actualidad; muchos de mis logros se los debo a ustedes, entre los que se incluye la realización de mi tesis. Me formaron con reglas, exigencias y con algunas libertades, y me motivaron a ser constante para alcanzar mis anhelos personales y profesionales. El regalo más grande que Dios me supo entregar, mis ganas de lograr ser un varón de bien, correcto y fuerte para lograr salir adelante.

AGRADECIMIENTOS

A mi madre, por siempre ser fuerte en mí y querer que sea cada vez mejor.

A mi padre, por intentar ser mejor y apoyarme de una u otra manera.

A mis hermanos, por siempre sacarme una sonrisa en esos momentos tristes y hacerme sentir orgulloso de ellos en cada uno de sus triunfos.

A mis familias, Paima y Sahuma, por ser parte de mi vida y el motor que me ha apoyado en la consecución de mis objetivos para alcanzar mis metas.

A la UNTELS, que me dio la bienvenida al mundo profesional como tal, las oportunidades y beneficios que me ha brindado al ser incomparables, y antes de todo esto ni pensaba que fuera posible que algún día si quisiera me topara con alguna de todas ellas.

Agradezco de corazón por la ayuda de mis maestros, compañeros, a los investigadores (Principal y asociados) quienes me brindaron constantemente su conocimiento en el proceso de realización de la tesis, a mi asesor y a la universidad en general por todo lo anterior en conjunto con todos los copiosos conocimientos que me ha otorgado a lo largo de todo el proceso formativo.

Agradezco el financiamiento de la investigación por parte del CONCYTEC-FONDECYT en el marco del concurso E038-01, con contrato No. 020-2019- FONDECYT-BM-INC.INV.

RESUMEN

En los tiempos actuales, los avances en tecnología han permitido mejorar los procesos de manufactura en la industria metalmecánica gracias a la disponibilidad de sensores y técnicas avanzadas de análisis de datos. En particular, en el proceso de fresado CNC, se pueden conseguir mejoras en la calidad de las piezas trabajadas y en los costos de producción mediante la predicción del desgaste de la herramienta de corte. A pesar de los esfuerzos realizados en este sentido, poco se ha hecho para mejorar la precisión de estas predicciones con un menor costo computacional.

En la presente investigación, se utilizan técnicas de aprendizaje automático para predecir el desgaste de tres herramientas de corte en una fresadora CNC, utilizando señales de sensores de fuerza y aceleración (Li et al., 2009). Se emplearon técnicas de preprocesamiento, ingeniería de características hacia adelante, ingeniería de características hacia atrás, Regresión de Vectores de Soporte (SVR, por sus siglas en inglés) y la optimización de hiperparámetros bayesianos para reducir el costo computacional. Como resultado, se logró predecir el desgaste de las herramientas de corte con un número reducido de características, lo que permitió reducir significativamente el costo computacional de la predicción.

Con la aplicación de los métodos indicados anteriormente se obtuvieron valores del error cuadrático medio (RMSE, por sus siglas en inglés) de 4.29 para c1, 7.8 para c4 y 8.08 para c6, utilizando únicamente cuatro características. En total, se realizaron alrededor de 72,000 predicciones para llegar a estos resultados. Es importante destacar que estos valores son comparables con los resultados de RMSE que se encuentran en el estado del arte, donde se utilizan alrededor de 60 características. Además, el uso de un número reducido de características y un algoritmo sencillo permite reducir significativamente el costo computacional de la predicción.

En conclusión, los resultados obtenidos en esta investigación demuestran que es posible predecir el desgaste de las herramientas de corte de una fresadora CNC con una precisión comparable a la del estado del arte, utilizando un número reducido de características y un algoritmo sencillo, lo que reduce significativamente el costo computacional de la predicción.

Palabras clave: Optimización de hiperparámetros, Regresión de Vectores de Soporte, Ingeniería de características, Aprendizaje supervisado, Costo computacional.

ABSTRACT

Currently, advances in technology have allowed for the improvement of manufacturing processes in the metalworking industry through the availability of sensors and advanced data analysis techniques. In particular, in the CNC milling process, improvements in the quality of worked pieces and production costs can be achieved by predicting the wear of the cutting tool. Despite efforts made in this regard, little has been done to improve the accuracy of these predictions with lower computational costs.

In this research, machine learning techniques are used to predict the wear of three cutting tools on a CNC mill, using force and acceleration sensor signals (Li et al., 2009). Preprocessing techniques, forward feature engineering, backward feature engineering, Support Vector Regression (SVR), and Bayesian hyperparameter optimization were employed to reduce computational costs. As a result, wear on cutting tools was successfully predicted with a reduced number of characteristics, significantly reducing the computational cost of the prediction.

The application of the methods outlined above resulted in root mean square error (RMSE) values of 4.29 for c1, 7.8 for c4, and 8.08 for c6, using only four characteristics. Approximately 72,000 predictions were made to achieve these results. It is important to note that these values are comparable to RMSE results found in the state of the art, where around 60 characteristics are used. Furthermore, the use of a reduced number of characteristics and a simple algorithm significantly reduces the computational cost of the prediction.

In conclusion, the results obtained in this research demonstrate that it is possible to predict the wear of cutting tools on a CNC mill with an accuracy comparable to that of the state of the art, using a reduced number of characteristics and a simple algorithm, significantly reducing the computational cost of the prediction.

In conclusion, this research demonstrates that it is possible to accurately predict the wear of cutting tools on a CNC mill with a simplified approach, using a limited number of characteristics and a computationally efficient algorithm. The results achieve an accuracy comparable to state-of-the-art methods, while significantly reducing the computational cost of the prediction.

Keywords: Hyperparameter Optimization, Support Vector Regression, Feature Engineering, Supervised Learning, Computational Cost.

ÍNDICE

DEDICATORIA.....	IV
AGRADECIMIENTOS	V
RESUMEN.....	VI
ABSTRACT.....	VII
ÍNDICE.....	VIII
LISTA DE FIGURAS	X
LISTA DE TABLAS	XI
INTRODUCCIÓN.....	12
I. PLANTEAMIENTO DEL PROBLEMA.....	15
1.1 Motivación.....	15
1.2 Estado del arte.....	15
1.3 Descripción del problema	16
1.4 Formulación del problema	18
<i>1.4.1 Problema general.....</i>	<i>18</i>
<i>1.4.2 Problemas específicos</i>	<i>18</i>
1.5 Objetivos.....	18
<i>1.5.1 Objetivo general</i>	<i>18</i>
<i>1.5.2 Objetivos específicos</i>	<i>18</i>
1.6 Delimitación de la investigación.....	19
1.7 Justificación.....	19
<i>1.7.1 Justificación tecnológica</i>	<i>20</i>
<i>1.7.2 Justificación económica.....</i>	<i>20</i>
<i>1.7.3 Justificación teórica</i>	<i>20</i>
II. MARCO TEÓRICO.....	21
2.1 Antecedentes.....	21
<i>2.1.1 Nacionales</i>	<i>21</i>
<i>2.1.2 Internacionales.....</i>	<i>22</i>
2.2 Bases teóricas.....	26
<i>2.2.1 Máquinas CNC.....</i>	<i>26</i>
<i>2.2.2 Fresadora CNC</i>	<i>41</i>
<i>2.2.3 Herramientas de corte</i>	<i>43</i>

2.2.4	<i>Aprendizaje automático</i>	48
2.2.5	<i>Búsqueda de características</i>	51
2.2.6	<i>Preprocesamiento de los datos</i>	54
2.2.7	<i>Modelos de Regresión</i>	56
2.2.8	<i>Optimización de Hiperparámetros</i>	59
2.2.9	<i>Herramientas para el uso de aprendizaje automático</i>	59
2.2.10	Costo computacional	60
III.	METODOLOGÍA	62
3.1	Descripción de la metodología	62
3.1.1	<i>Enfoque de investigación</i>	62
3.1.2	<i>Alcance de investigación</i>	62
3.2	Implementación de la investigación	63
3.2.1	<i>Diagrama de flujo</i>	63
3.2.2	<i>Base de datos utilizado</i>	66
3.2.3	<i>Implementación de un modelo de Aprendizaje automático</i>	70
3.2.4	<i>Selección de la cantidad óptima de características</i>	76
3.2.5	<i>Predicción del desgaste con reducción del costo computacional</i>	79
3.2.6	<i>Verificación final del desgaste con mínimo error de predicción</i>	80
3.3	Resultados	82
3.3.1	<i>Se construyó un modelo de aprendizaje automático</i>	82
3.3.2	<i>Se seleccionaron 15 características para cada cuchilla</i>	87
3.3.3	<i>Se seleccionaron 15 características para las 3 cuchillas</i>	97
3.3.4	<i>Se seleccionaron 4 características para las 3 cuchillas</i>	101
IV.	DISCUSIÓN DE RESULTADOS	117
V.	CONCLUSIONES	127
VI.	RECOMENDACIONES	129
VII.	REFERENCIA BIBLIOGRÁFICAS	131
ANEXOS		141
Anexo 1.	Glosario de términos	142
Anexo 2.	Código de los algoritmos de la tesis	144
Anexo 3.	Matriz de consistencia	144
Anexo 4.	Presupuesto de la tesis	146
Anexo 5.	Contrato del financiamiento	147

LISTA DE FIGURAS

Figura 1 <i>Diseño estructural de la máquina CNC.</i>	28
Figura 2 <i>Diagrama general del manejo de la secuencia de cortes en una máquina CNC</i>	29
Figura 3 <i>Taladro CNC</i>	30
Figura 4 <i>Torno CNC</i>	30
Figura 5 <i>Fresadora CNC</i>	31
Figura 6 <i>Fresadora CNC</i>	31
Figura 7 <i>Diagrama de máquina CNC</i>	35
Figura 8 <i>Diagrama de bloques del sistema de control de una máquina CNC</i>	40
Figura 9 <i>Fresas</i>	45
Figura 10 <i>Desgaste de la herramienta de corte</i>	47
Figura 11 <i>Diagrama de aprendizaje automático cuando aprende</i>	49
Figura 12 <i>Funcionamiento básico del SVR</i>	58
Figura 13 <i>Programación para medir el tiempo de inicio y finalización de un código.</i>	61
Figura 14 <i>Flujograma del proyecto de investigación</i>	63
Figura 15 <i>Supervisión en el proceso de fresado en alta velocidad</i>	66
Figura 16 <i>Máximo desgaste de c1, c4 y c6</i>	67
Figura 17 <i>Comparación gráfica de RMSE entre los elementos de cada lista de características.</i> 78	
Figura 18 <i>Comparación de la primera prueba para las 3 cuchillas.</i>	88
Figura 19 <i>Comparación de la segunda prueba en las 3 cuchillas.</i>	89
Figura 20 <i>Comparación de las 2 pruebas</i>	89
Figura 21 <i>Resultados del entrenamiento usando c4 y c6</i>	94
Figura 22 <i>Valores de validación y aproximación entre señales para c1</i>	94
Figura 23 <i>Resultados del entrenamiento usando c1 y c6</i>	95
Figura 24 <i>Valores de validación y aproximación entre señales para c4</i>	95
Figura 25 <i>Resultados del entrenamiento usando c1 y c4</i>	96
Figura 26 <i>Valores de validación y aproximación entre señales para c6</i>	96
Figura 27 <i>Resultados del entrenamiento usando c4 y c6</i>	98
Figura 28 <i>Valores de validación y aproximación entre señales para c1</i>	99
Figura 29 <i>Resultados del entrenamiento usando c1 y c6</i>	99
Figura 30 <i>Valores de validación y aproximación entre señales para c4</i>	100
Figura 31 <i>Resultados del entrenamiento usando c1 y c4</i>	100
Figura 32 <i>Valores de validación y aproximación entre señales para c6</i>	101
Figura 33 <i>Cuadro completo de los grupos de características para las 3 Cuchillas.</i>	102
Figura 34 <i>Resultados del entrenamiento usando c4 y c6</i>	103
Figura 35 <i>Valores de validación y aproximación entre señales para c1</i>	104
Figura 36 <i>Resultados del entrenamiento usando c1 y c6</i>	104
Figura 37 <i>Valores de validación y aproximación entre señales para c4</i>	105
Figura 38 <i>Resultados del entrenamiento usando c1 y c4</i>	105
Figura 39 <i>Valores de validación y aproximación entre señales para c6</i>	106
Figura 40 <i>Resultados del entrenamiento usando c4 y c6</i>	107
Figura 41 <i>Valores de validación y aproximación entre señales para c1</i>	108

Figura 42 Resultados del entrenamiento usando <i>c1</i> y <i>c6</i>	108
Figura 43 Valores de validación y aproximación entre señales para <i>c4</i>	109
Figura 44 Resultados del entrenamiento usando <i>c1</i> y <i>c4</i>	109
Figura 45 Valores de validación y aproximación entre señales para <i>c6</i>	110
Figura 46 Comparación en <i>Boxplot</i> para <i>c1</i>	112
Figura 47 Comparación en <i>Boxplot</i> para <i>c4</i>	114
Figura 48 Comparación en <i>Boxplot</i> para <i>c6</i>	116

LISTA DE TABLAS

Tabla 1 Códigos <i>G</i> y <i>M</i> para una fresadora CNC	38
Tabla 2 Los tipos de desgastes en herramientas de corte	46
Tabla 3 Señales de fuerza y aceleración de cada eje y cuchilla de corte 10.....	68
Tabla 4 Señales de la Emisión Acústica para cada cuchilla en el corte 10.....	69
Tabla 5 lista de características extraídas	72
Tabla 6 Agrupamiento de datos para el entrenamiento y la validación.....	73
Tabla 7 Total de las características.	83
Tabla 8 Imágenes de algunas características sin detrend	84
Tabla 9 Imágenes de algunas características con detrend	85
Tabla 10 Entrenamiento usando el modelo de aprendizaje automático para las 3 cuchillas	86
Tabla 11 Validación usando el modelo de aprendizaje automático para las 3 cuchillas	86
Tabla 12 Primera prueba en las 3 cuchillas.	87
Tabla 13 Segunda prueba para las 3 cuchillas.	88
Tabla 14 Resultados para la cuchilla <i>c1</i>	90
Tabla 15 Resultados para la cuchilla <i>c4</i>	91
Tabla 16 Resultados para la cuchilla <i>c6</i>	92
Tabla 17 Las 15 mejores características de cada cuchilla.	93
Tabla 18 Valores de las 15 características seleccionadas para cada cuchilla	93
Tabla 19 Las 15 mejores características para las 3 cuchillas.	97
Tabla 20 Valores de las 15 características seleccionadas para las 3 cuchillas.....	98
Tabla 21 Elección de las menores RMSE en las 3 cuchillas.	101
Tabla 22 Valor de la mejor característica en las 3 cuchillas	103
Tabla 23 Valores de las 4 características seleccionadas para las 3 cuchillas.	107
Tabla 24 Comparación entre las 4 y 60 características en la cuchilla <i>c1</i>	111
Tabla 25 Comparación entre las 4 y 60 características en la cuchilla <i>c4</i>	113
Tabla 26 Comparación entre las 4 y 60 características en la cuchilla <i>c6</i>	114
Tabla 27 Características de investigaciones	118
Tabla 28 Presupuesto de la tesis	146

INTRODUCCIÓN

Las empresas metalmeccánicas tienen el propósito de fabricar piezas y componentes metálicos, y para ello es imprescindible el uso de maquinaria especializada como son los taladros, tornos y fresadoras CNC. El uso de estos equipos lleva al desgaste inevitable de sus herramientas de corte. Aunque estos equipos son altamente eficientes y precisos, el desgaste de las herramientas de corte es inevitable debido a que se usan constantemente y repetitivamente, lo cual requiere que se reemplacen oportunamente. Si el cambio de la herramienta de corte se realiza demasiado tarde, se puede afectar la calidad de las piezas fabricadas, y si se hace muy temprano se puede llevar a incrementar los costos innecesariamente. Por esta razón, es fundamental predecir el desgaste de las herramientas de corte. A lo largo de los años, muchos investigadores han desarrollado métodos y técnicas para predecir el desgaste de las herramientas de corte, a fin de obtener resultados precisos y confiables. Sin embargo, hay algunas dificultades que limitan la precisión de la predicción en todo el proceso de elaboración, como la medición de datos, la limpieza de datos y el costo computacional. La medición de datos puede ser una tarea difícil, especialmente cuando se trata de datos no estructurados y complejos, como la vibración de la máquina o la fuerza de la herramienta. Además, el costo computacional puede ser significativo, ya que se requiere una gran cantidad de procesamiento de datos y análisis para obtener resultados precisos. Para superar estas dificultades, es necesario trabajar en la optimización de los procesos de medición y limpieza de datos, utilizando técnicas avanzadas de análisis de datos y sistemas de monitoreo en línea. Durante la selección de características, se tiene que monitorear los valores de los hiperparámetros para facilitar la predicción del desgaste. Otras técnicas de aprendizaje automático, como las redes neuronales, pueden ayudar a predecir el desgaste de la herramienta de corte, pero con un mayor costo computacional.

En el rubro de la metalmeccánica, la fresadora de control numérico computarizado (CNC) es fundamental para los procesos de mecanizado y fabricación actuales. Esta tecnología permite reducir significativamente los tiempos de producción, mejorar la calidad de los productos y realizar estudios experimentales precisos mediante la utilización de sensores. Estos sensores permiten medir fuerzas, aceleraciones y emisiones acústicas durante el proceso de fresado y generar datos en formatos de series temporales. Es necesario realizar un preprocesamiento adecuado de dichos datos antes de entrenar los modelos de aprendizaje automático. El preprocesamiento incluye la limpieza de datos, la

normalización y la selección de características relevantes. De esta forma, se pueden obtener modelos de predicción más precisos y confiables.

El objetivo principal de la tesis es utilizar las señales que se obtienen durante el proceso de fresado en un algoritmo de aprendizaje automático para realizar la predicción del desgaste de la cuchilla en una fresadora CNC con un reducido costo computacional. La estructura de la tesis es lógica y coherente, y ha sido organizada por siete capítulos cuidadosamente elaborados para presentar un análisis exhaustivo del problema planteado, su desarrollo y las conclusiones de la investigación que representa una valiosa aportación a la comunidad académica y profesional.

La presente tesis aborda el problema del desgaste de la cuchilla en una fresadora CNC, un tema de gran relevancia en la industria. Con el objetivo de proporcionar una base sólida para la investigación, el Capítulo I, se presenta una introducción detallada del problema sobre el desgaste, donde se describe la motivación y estado del arte del tema de la investigación; también incluye la descripción del problema, formulación del problema, se presentan los objetivos específicos a cumplir, la delimitación de la investigación y su justificación, de esta manera, se pretende establecer una base sólida para la realización de la investigación y explica la relevancia con el estudio. En el Capítulo II, se enfoca en el marco teórico sólido y actualizado sobre el que se sustenta la investigación, aquí se presentan los antecedentes de la investigación tanto a niveles nacionales como internacionales, relacionados con el tema de la presente tesis y también se exponen las bases teóricas que fundamentan los diversos métodos utilizados en la investigación, esto permitirá una mejor comprensión de los fundamentos teóricos que sirvieron de base para la realización de la investigación. A continuación, en el Capítulo III, se desarrolla la descripción de la metodología, la implementación de la investigación con una base de datos específica que fue utilizada y se exponen los resultados obtenidos para dar a conocer finalmente si se lograron los objetivos planteados en el Capítulo I, es importante para entender cómo se realizó la investigación y qué métodos se utilizaron para alcanzar los objetivos. En el Capítulo IV, se presenta el análisis de los resultados obtenidos en la investigación, mediante la metodología empleada en el Capítulo III, se describen los principales hallazgos y se analizan los datos obtenidos para su posterior interpretación es crucial para entender qué se descubrió a partir de la investigación. En el Capítulo V, se presentan las conclusiones correspondientes a la investigación del desgaste de la cuchilla, basándose en los objetivos específicos planteados en el Capítulo I, se destacan los

resultados más relevantes y se ofrecen recomendaciones para la solución de problemas prácticos en el ámbito industrial. Este capítulo es clave para entender el impacto de la investigación y su contribución al conocimiento del desgaste de cuchillas. En el Capítulo VI, se detallan recomendaciones derivadas de la experiencia aprendida en la presente investigación, que podrían ser útiles para los futuros estudios y temas referentes a la predicción del desgaste que se podrán tomar como base a esta tesis, y se sugieren posibles líneas de investigación para profundizar en este campo y para sugerir caminos para el avance del conocimiento. Finalmente, en el Capítulo VII, se presentan las referencias bibliográficas que fueron utilizadas en toda la tesis, las cuales han sido cuidadosamente seleccionadas para respaldar y enriquecer los hallazgos presentados en la investigación.

CAPÍTULO I

I. PLANTEAMIENTO DEL PROBLEMA

El siguiente apartado describe el problema que consiste en cómo lograr la predicción del desgaste de la cuchilla en una fresadora CNC. Por consiguiente, es importante tener un buen conocimiento experimental para poder comprender los datos de la cuchilla en la obtención de una buena predicción con la finalidad de conseguir un estudio de buenos resultados esperados.

A continuación, se van a tratar los siguientes temas: Motivación, estado del arte, descripción del problema, formulación del problema, los objetivos, delimitación de la investigación y la justificación.

1.1 Motivación

La presente investigación busca aportar mejoras en la predicción del desgaste de la cuchilla de una fresadora CNC, equipo muy utilizado actualmente en la industria del rubro metalmecánico. Una fresadora CNC es empleada en procesos industriales para el mecanizado de piezas como ejes o direcciones y es así que se ha convertido en objeto de estudio debido a su gran implicancia en el desarrollo de la ingeniería como tal. Antiguamente, parte de los problemas de calidad en las piezas comúnmente se debían al factor humano (técnico o de mantenimientos en general), ya que la fabricación de piezas las realizaba un técnico mecánico en máquinas de herramientas (torno, fresadora, cepilladora, etc.) pero en tiempos modernos este factor ha sido reemplazado por las máquinas de control numérico computarizado (CNC) por tener una mejor tecnología siendo programable por un especialista con experiencia previa, más aún con este cambio, siguen existiendo problemas de calidad en la pieza terminada y costes de retrabajo, por lo que el punto de vista se dirige a la pieza de corte para que sea una cuchilla o una pastilla de corte.

1.2 Estado del arte

Diversos estudios se han llevado a cabo para predecir el desgaste de la herramienta de corte utilizando la base de datos de Li et al. (2009). Los más recientes e importantes trabajos se mencionan a continuación.

El modelo de red neuronal basada en transformador (TBNN), haciendo el estudio para la predicción del desgaste de herramientas donde empleo la mejora la capacidad del modelo con la red de memoria a largo y corto plazo (LSTM). La investigación

mencionada supera a otros métodos con sus resultados y se relaciona con su base de datos utilizado en el presente trabajo de investigación (C. Liu et al., 2020). Donde la se nota dejar con los objetivos propuestos por lograr.

La presencia de modelados de la descomposición de valores singulares (SVD) y una red neuronal bidireccional de memoria a corto plazo a largo plazo (BiLSTM) para la predicción del desgaste de la herramienta. Los resultados de esta investigación son muy notorios por los valores de las características usadas para las redes neuronales (Wu et al., 2020). Este proceso contribuye a la realización de las características donde se toma como parte del objetivo específico con la clasificación del bayesiano y empleo la misma base de datos que la investigación Li et al. (2009).

Zhang desarrollaron un sistema de predicción de la vida útil de una herramienta de corte, donde se empleó la precisión del modelo propuesto de tres capas convolucionales y dos capas de agrupación con resultados de predicción logró alcanzar el 87,3%. Se tiene la idea de reducir en un 30% del costo de fabricación (Zhang et al., 2021). Esta investigación influye en la realización de objetivos propuesto que intenta reducir el coste computacional y la utilidad de la importancia de la misma base de datos que la investigación Li et al. (2009).

1.3 Descripción del problema

El desgaste es la degradación de la pieza de una máquina de herramienta (brocas, cuchillas y fresas) que debido al proceso de uso constantemente en las aplicaciones, la predicción es diseñada para la valoración o conocimiento de la determinación de cuánto tiempo puede durar dicha pieza. La cuchilla es utilizada en fresadoras CNC, torno, taladro, etc. Según Prado, T. (2015) el estado de la pieza de corte tiene principal influencia en la calidad de la pieza acabada, en este caso una matriz, y está a su vez en los costes de producción de estas, con lo cual, el estudio del desgaste no gira en torno solamente en la vida de la herramienta sino de las repercusiones que este desgaste influye en los costes de la pieza final.

Por otra parte, las herramientas de corte, como cualquier otro material producido, tiene una vida útil determinada por el fabricante, la cual se expresa como horas de trabajo, que, al llegar al límite, la pieza debe ser reemplazada, aunque en la práctica este cambio se efectúa por la inspección visual ejecutada por el técnico a cargo basándose en su experiencia. No obstante, estos procedimientos empíricos, si bien dan una predicción del desgaste, no dan garantías para la producción de piezas que no tengan observaciones

por calidad de acabado superficial deficiente o que requieran de un retrabajo para poder terminar su proceso.

En ese sentido, la vida útil de la herramienta se relaciona directamente con las cargas y fuerzas aplicadas, que deforman la geometría del corte y que sumado a los efectos de las altas velocidades que estos procesos requieren, generan malos acabados en las piezas mecanizadas (Redacción Interempresas, 2012).

Por ello los fabricantes consideran que existe la necesidad de desarrollar modelos predichos que indiquen las fallas mecánicas y la vida útil de los diferentes sistemas o componentes de fabricación, para integrar las predicciones del desgaste que podrían ser basados en modelos. Sin embargo, el problema radica en que muchas empresas no están en la capacidad de responder rápidamente ante este tipo de situaciones al usar una fresadora por el desgaste continuo de la cuchilla con trabajos innecesarios y un mal funcionamiento a largo plazo, pudiendo desprenderse la cuchilla y llegar a una ruptura incluso de la máquina (Li et al., 2009).

Asimismo, la falla de la herramienta de corte puede resultar en mala calidad del acabado en la superficie y precisión dimensional de una pieza terminada, o posible daño a la máquina. Es decir, la supervisión de las condiciones en la herramienta para el proceso de fresado en alta velocidad es uno de tantos niveles de respuesta al registrar anomalías o fallas inminentes. Zhou & Xue (2018) hacen una revisión de métodos para el monitoreo de la herramienta de corte y muestran que la manera más efectiva para predecir la vida útil o desgaste de las piezas de corte debe ser analizando las características no visibles, como porcentaje de material en la composición o las fuerzas medidas durante los cortes, ya que esta información nos permite analizar el comportamiento interno de la pieza, además de predecir dichas particularidades de forma más exacta.

De acuerdo con lo anterior, es necesario la elaboración de algún método, un análisis de los datos en las cuchillas constantemente y de la vida útil restante de las herramientas de corte, con el propósito de evitar problemas tales como calidad, costes de trabajo y retrabajo, además de ser una herramienta importante para ayudar a realizar mantenimientos predichos y preventivos, que disminuyan o eliminen los tiempos muertos en la producción.

Para este trabajo de investigación se usarán los datos proporcionados por el desafío de datos de la conferencia de la sociedad PHM 2010 (Li et al., 2009). Los datos fueron tomados utilizando equipos como dinamómetro, acelerómetro y de emisión acústica. El

desgaste de 3 cuchillas se midió utilizando un microscopio. Se estima que el tiempo del experimento de corte tomó aproximadamente 30 horas para cada cuchilla. La predicción del desgaste se realizará usando las series temporales de fuerza, aceleración y emisión acústica. Dicha predicción será contrastada con los datos experimentales.

1.4 Formulación del problema

Al no contar con un sistema de predicción del desgaste, podría significar un retraso en las funciones de la producción. En los tiempos actuales, un buen servicio de tecnología es vital para el funcionamiento eficiente de una empresa, teniendo en cuenta lo anterior, el problema general y específicos de este proyecto son los siguientes:

1.4.1 Problema general

¿Cómo predecir en un tiempo óptimo el desgaste de la cuchilla de una fresadora CNC?

1.4.2 Problemas específicos

- ¿Cómo extraer grupos de características de la fuerza, aceleración y emisión acústica de la cuchilla?
- ¿De qué manera se puede disminuir el costo de procesamiento computacional en la predicción del desgaste de la cuchilla en la fresadora CNC?
- ¿Cómo predecir el desgaste de la cuchilla en el tiempo y la reducción del costo computacional?
- ¿Cómo seleccionar el mínimo error de predicción en los datos de la cuchilla de la fresadora CNC?

1.5 Objetivos

El objetivo general y específico de este proyecto son los siguientes:

1.5.1 Objetivo general

Utilizar las señales que se obtienen durante el proceso de fresado en un algoritmo de aprendizaje automático para realizar la predicción del desgaste de la cuchilla de una fresadora CNC con un reducido costo computacional.

1.5.2 Objetivos específicos

- Implementar un modelo de aprendizaje automático a partir de las señales adquiridas de la cuchilla en una fresadora CNC para seleccionar los grupos de características.

- Seleccionar una cantidad óptima de características de la base de datos para lograr disminuir el costo de procesamiento computacional en la predicción del desgaste de la cuchilla en una fresadora CNC.
- Implementar un modelo de aprendizaje automático con los datos de la cuchilla en una fresadora CNC para la predicción del desgaste de la cuchilla en el tiempo y la reducción del costo computacional.
- Realizar las predicciones del desgaste original y del desgaste corregido de la cuchilla en una fresadora CNC para la verificación final y encontrar el mínimo error de predicción.

1.6 Delimitación de la investigación

La presente investigación buscará generar un algoritmo de predicción para el desgaste de la cuchilla y obtener la idea de la vida útil con punta de bola de 6 mm y 3 filos de una máquina CNC, en relación con el registro de mediciones de fuerzas y aceleraciones en los ejes X, Y y Z y las emisiones acústicas, tomadas en 315 cortes.

La presente investigación se llevó a cabo en el distrito de Villa El Salvador del departamento de Lima Metropolitana en Perú, utilizando los datos de la cuchilla de una Fresadora CNC de modelo RFM 760/2 en un estudio previo (PHM 2010). Además, constará de dos etapas: la primera, que incluye la parte experimental de la tesis llevada a cabo durante el periodo 2021-2022, y la segunda, que consiste en la documentación y redacción necesaria para la sustentación del trabajo, programada en el periodo de la investigación que se desarrolló en un periodo de 8 meses, comenzando en agosto de 2022 y finalizando en abril de 2023.

1.7 Justificación

Actualmente, se tiene un especial interés en estudios de predicción con datos pre experimentados, en esta ocasión se desea conocer el desgaste de la cuchilla de una fresadora CNC con aplicaciones del aprendizaje automático, en este procedimiento se emplean efectos beneficiosos para disminuir los costos ocasionados por el control constante de la máquina, el recambio innecesario de la cuchilla, las cuales producen hoy en día que haya un mal concepto del trabajador siendo un proceso de control automatizado.

Este estudio, tiene su justificación de la siguiente manera:

1.7.1 Justificación tecnológica

En la actualidad debemos adaptarnos a nuevos conocimientos y desarrollos tecnológicos. Actualmente, el desarrollo de la industria 4.0 está revolucionando los parámetros de trabajo y automatización de las empresas. Particularmente el aprendizaje automático es una técnica que puede ser usada para la predicción de falla de equipos. En esta investigación se realizará la predicción del desgaste de la cuchilla en una fresadora CNC. Conocer el desgaste de la cuchilla nos permitirá estimar el tiempo de vida útil remanente y así realizar oportunamente un cambio de la cuchilla. Asimismo, a futuro esta investigación puede servir como referencia para otros componentes de otros equipos industriales.

1.7.2 Justificación económica

Se justifica económicamente porque reduce el costo del tiempo muerto en la CNC, con mayor producción y ahorro de dinero en las paradas de máquinas que no funcionan por no saber cuándo y en qué momento refaccionar o cambiar la cuchilla, logra una disminución de los costos de recambio o mano de obra, logrando así que la máquina esté rectificadas, de esta manera el proceso es productivo en tiempo real, sin fallas ni malgasto de bienes.

1.7.3 Justificación teórica

Diferentes estudios (Zegarra et al., 2022; Zhao et al., 2017, 2019), que han empleado varios métodos para predecir el desgaste de la herramienta de corte utilizando la base de datos de Li et al. (2009). Los trabajos de (Zhao et al., 2017, 2019), muestran buenos resultados utilizando Redes neuronales cuyo costo computacional es alto. Sin embargo, el trabajo de Zegarra et al. (2022), muestra resultados similares utilizando 1 o 2 características para regresión de vectores de soporte y Aumento de gradiente extremo con una significativa reducción del costo computacional. Dichos resultados motivan a extender la investigación y determinar la influencia de un mayor número de características en la predicción. Un entendimiento del rol del número de características servirá para futuros estudios de desgaste de equipos industriales.

CAPÍTULO II

II. MARCO TEÓRICO

El presente capítulo muestra el fundamento teórico, el cual contiene los antecedentes nacionales e internacionales, y el marco teórico que ayudará a comprender mejor los temas relacionados con la investigación.

El siguiente apartado describe el Marco Teórico (Antecedentes y Bases Teóricas) de todo el estudio que es de gran importancia para la investigación con explicaciones teóricas con ideas relacionados a algoritmos de predicción del desgaste de una Fresadora CNC.

2.1 Antecedentes

A continuación, se presenta una relación de estudios e investigaciones relacionados bibliográficamente con el trabajo de tesis propuesto, resaltando brevemente, en cada uno de ellos, los aspectos relacionados con la investigación realizadas anteriormente por autores Nacionales e Internacionales, en relación a la predicción con aplicaciones de aprendizaje automático.

2.1.1 Nacionales

En el ámbito nacional se han desarrollado diversos algoritmos de aprendizaje automático. El trabajo de (Carrillo Rosales, 2019) utiliza regresión logística lineal, árboles de decisión y máquinas de soporte vectorial para mejorar la precisión en la detección de fraudes en el consumo de agua potable no facturada. Se reportó una precisión de 97.71% luego de la validación. Precisión superior al 95.7% alcanzado por el trabajo de Palomino y Rivera (2016). De igual forma en esta tesis se van a utilizar varios algoritmos para buscar los mejores resultados.

Acercándonos al objeto de estudio, podemos mencionar el trabajo desarrollado por (Arias et al., 2021) donde se usa aprendizaje automático para clasificar el desgaste de la herramienta de corte en una fresadora. Los datos para este estudio se obtuvieron del desafío de la conferencia 2010 de la Sociedad PHM. El desgaste se agrupa en varias regiones (muy bajo, bajo, medio, alto, muy alto) usando un modelo de mezcla gaussiana (GMM) con un número pequeño de características de las series temporales. También se predice el desgaste con un modelo de red neuronal compleja (CNN) usando una pequeña parte de las series temporales. Los resultados obtenidos fueron superiores a 0,85 y 0,81

para la precisión y para f1, respectivamente. En el presente trabajo de tesis se buscará de igual forma usar la cantidad necesaria de datos para obtener buenos resultados.

Profundizando el uso adecuado de las características de las series temporales, se debe resaltar la investigación de (Casusol et al., 2021) donde se predice el tiempo de vida útil remanente de la herramienta de corte de una fresadora. La base de datos para este estudio se obtuvo del primer desafío de datos de Foxconn 2020. En dicho trabajo inicialmente se utilizan técnicas de preprocesamiento y luego se utiliza la optimización de hiperparámetros para la regresión de vectores de soporte con validación cruzada. Se consigue obtener predicciones de la vida útil remanente de la herramienta de corte similares a la obtenida por el primer puesto del concurso. En este sentido la presente tesis buscará identificar las características más importantes de las series temporales para mejorar la predicción del desgaste de la herramienta de corte de la fresadora.

2.1.2 Internacionales

La presente investigación muestra la realización del proceso de detección de la vida útil de la herramienta de corte. Donde se destaca a (P. Wang & Gao, 2015) donde los datos utilizados fueron obtenidos de (Li et al., 2009). La predicción de la vida útil fue realizada utilizando LSPF (Filtrado de Partículas de Búsqueda Local). El modelo de predicción fue alimentado con señales de aceleración y fuerza. Los estudios realizados fueron para predecir 100 y 200 últimos cortes. Para los últimos 200 cortes, se obtuvieron errores en la predicción de 15.4% y 9.6% para SIR (Remuestreo de importancia secuencial) y LSPF, respectivamente. Para los últimos 100 cortes, se obtuvieron errores en la predicción de 11.7% y 3.5% para SIR y LSPF, respectivamente. Se concluye que el modelo LSPF es mejor en comparación al SIR. Así mismo, se observa que a menor cantidad de corte por predecir será menor el margen de error. Se verá un aporte con la elección del corte al utilizar la misma base de datos en esta tesis.

Se realiza la evaluación y predicción del desgaste de la herramienta. El actual trabajo presentado por (J. Wang et al., 2015) mediante un método probabilístico basado en el filtrado de partículas para tener en cuenta las incertidumbres en el proceso de desgaste de la herramienta. La predicción del desgaste de la herramienta fue realizada utilizando la integración del filtro de partículas y modelo auto regresivo (AR-PF) y la integración de filtro de partículas y el modelo SVR (SVR-PF). En los resultados se observa que los errores de predicción para el AR-PF y SVR-PF son aproximadamente 1.6% y 1.3%, respectivamente para predecir 150 cortes posteriores. El modelo auto

regresivo y la regresión de vectores de soporte han demostrado mejorar el rendimiento del filtro de partículas, lo que proporciona una mejor precisión de predicción. También es observado que la disminución del error de predicción se debe a la disminución del número de cortes de predicción. Del mismo modo, se aplica en la presente tesis el modelo de SVR por sus buenos resultados al utilizarlo.

Al realizarse las investigaciones se predijo la detección del desgaste mediante la función de una nueva técnica multisensorial en la herramienta usando reducción de dimensiones y el modelo de regresión vectorial de soporte (SVR) destacando a (J. Wang et al., 2017). Los datos utilizados en este trabajo fueron obtenidos de (Li et al., 2009). Se probaron las técnicas de reducción de dimensiones como: Kernel principal component analysis (KPCA), Locally linear embedding (LLE), Nonlinear dimensionality reduction (ISOMAP) y Minimum redundancy maximum relevance (mRMR). El modelo de SVR fue alimentado con las características: RMS, Variance, Maximum, skewness, Peak-to-Peak, Spectral skewness, Spectral kurtosis y Wavelet energy. Los resultados de RMSE para la predicción de desgaste utilizando SVR en los métodos KPCA, LLE, ISOMAP y mRMR fueron 5.44, 10.25, 10.66 y 8.63, respectivamente. Los resultados muestran que el análisis de los métodos del KPCA se desempeña mejor. Igualmente, la presente tesis emplea la misma base de datos, reducción de dimensiones y el modelo SVR a las características.

Las investigaciones de la eficiencia donde los métodos de aprendizaje profundo que redefinen el aprendizaje de representación a partir de datos sin procesar fueron utilizados por (Zhao et al., 2018). La predicción del desgaste real de los filos (medición fuera de línea) a partir de los datos sensoriales de siete señales se seleccionaron tres registros de vibración acústica individuales llamados c1, c4 y c6 como conjunto de datos cada 315 muestras. El modelo de unidades recurrentes cerradas basadas en características locales (LFGRU) el estado de la máquina herramienta CNC: predicción del desgaste de la herramienta, diagnóstico de fallas en la caja de cambios y detección de fallas incipientes en los rodamientos verifican la efectividad y generalización del LFGRU propuesto. En los sistemas de monitoreo del estado de la máquina (MHMS) la información es buena en la detección de fallas después de la ocurrencia de ciertas fallas. La precisión de las mejores interpretaciones es de LFGRU en MAE y RMSE son para C1 es de 4 y 5.4 respectivamente. La mejora de las redes la unidad recurrente cerrada (GRU) se adoptan para aprender la representación de la secuencia de características locales. En tres tareas

reales de monitorización se verificó la eficacia y solidez del modelo LFGRU propuesto por el autor. De la misma forma, se emplea el uso de las 3 cuchillas (c1, c4 y c6) en la presente tesis para obtener el menor RMSE posible.

El uso del modelo aprendizaje profundo (DL) se investigó para el monitoreo del estado de la máquina. Se utilizó el conjunto de datos PHM SOCIETY (2010) utilizado por (Zhao et al., 2019). Se muestra en una máquina CNC de alta velocidad durante las operaciones de fresado en seco y su diagrama esquemático de la plataforma experimental se muestra en 12. Se encuentran disponibles tres registros de cortadores individuales indicados como c1, c4 y c6 y cada registro contiene 315 muestras de datos donde c4 se usa como datos de prueba, mientras que los otros registros c1 y c6 se usan como datos de entrenamiento. Se diseña el conjunto correcto de características y luego se proporciona a algunos algoritmos de aprendizaje automático poco profundos que incluyen Support Vector Machines (SVM), Naive Bayes (NB), regresión logística. En este trabajo se compararon los modelos tales como: Linear SVR, RBF SVR, Random Forest, Neural Network, Autoencoder (AE), Denoising Autoencoder, Deep Belief Network (DBN), Memoria a largo plazo (LSTM), Bi-LSTM, Convolutional Neural Networks (CNN), Recurrent Neural Networks (RNN). Los resultados de todos los enfoques en la predicción del desgaste de la herramienta en los dos criterios, incluidos MAE y RMSE donde para este último LSTM, Bi-direccional LSTM, y CNN obteniendo 13.9, 13.8 y 14 respectivamente. Los MHMS basados en DL propuestos se resumen de acuerdo con cuatro categorías de arquitectura DL como: Modelos de codificador automático, modelos de máquinas de Boltzmann restringidas, redes neuronales convolucionales y redes neuronales recurrentes. Con la misma idea, se trabaja en la investigación actual con la misma base de datos y la aplicación del modelo de aprendizaje automático para lograr un menor RMSE.

Los estudios de modelado para la predicción del desgaste de la herramienta basada en la descomposición de valores singulares (SVD) y una red neuronal bidireccional de memoria a corto plazo a largo plazo (BiLSTM). Se destaca la investigación de (Wu et al., 2020) donde el conjunto de datos abiertos en el desafío PHM 2010 de una máquina CNC fueron utilizados para la predicción del desgaste. La señal de fuerza de corte sin procesar es reconstruida por la matriz de Hankle, y la SVD de la matriz reconstruida se emplea para extraer las características de la señal. Estas características se usan como entrada del modelo BiLSTM. En este trabajo se comparan 2 tipos de características (Características

SVD y Característica de dominio de tiempo) obteniendo como resultado el mejor valor de predicción del BiLSTM basado en característica SVD para MAE, MAPE y RMSE que tiene como valores de 2.76, 2.33 y 3.92 respectivamente. En comparación con los resultados de la predicción de diferentes neuronales recurrentes, el modelo de red BiLSTM tiene mejor resultado. Del mismo modo, en este trabajo de investigación se emplea la misma base de datos, logrando buenos resultados, empleando redes neuronales.

El modelo de red neuronal guiado por la física para la predicción del desgaste de la herramienta que propusieron (J. Wang et al., 2020). En este trabajo se realizó la comparación de 5 modelos tales como: Bi-Direccional GRU (Bi-GRU), convolutional neural network (CNN), long short-term memory (LSTM), and support vector regression (SVR) y el modelo propuesto. Los datos utilizados en la implementación de estos modelos fueron obtenidos de (Li et al., 2009). Los resultados de RMSE se observan con un menor valor en la base de datos c1, teniendo como valores: 9.2, 12.3, 16.1, 15.6, 5.1 para Bi-Directional, GRU, LSTM, SVR y el modelo propuesto, respectivamente. Cuando se trata de problemas físicos, se requiere una comprensión profunda del proceso físico como guía de entrenamiento en datos guiados por la física impulsados (PGDD). El modelo PGDD funciona de manera insatisfactoria en ausencia de muestras etiquetadas. No existe un método estándar al que hacer referencia al diseñar la estructura del modelo que integre datos y física de manera efectiva. El modelo propuesto basado en la física mostró mejores resultados en comparación a los demás métodos. De igual manera, la presente investigación hace uso de los mismos datos para obtener los mejores resultados y menores RMSE posible en la cuchilla.

El desarrollo de un nuevo modelo de red neuronal de base tensorial (TBNN), se resalta el trabajo de (H. Liu et al., 2020) para predecir el desgaste de herramientas que utilizan los datos experimentales de las fresadoras CNC de alta velocidad por (Li et al., 2009). Se emplea la red de memoria a largo y corto plazo (LSTM) multicapa para mejorar la capacidad de capturar información de posición en el modelo TBNN. A partir de las señales del sensor sin procesar se extraen tres características en el dominio del tiempo (maximum, mean, variance). El método propuesto supera a otros métodos en las tres métricas de evaluación: el coeficiente de determinación (R^2), el error cuadrático medio (RMSE) y el error absoluto medio (MAE). Se compara el rendimiento con los demás métodos dando el menor resultado en TBNN para c1: R^2 , RMSE y MAE el valor de 0.95, 6.12 y 4.29 respectivamente. El modelo de transformador que resuelve el

desgaste de la herramienta de estimación para poder mejorar la precisión. La superioridad de este método se verifica en comparación con otros métodos sugeridos, superando a otros métodos en las tres métricas de evaluación (R^2 , RMSE y MAE). En la presente tesis se busca obtener la misma finalidad de conseguir la predicción del desgaste experimentalmente posible con métodos y aplicaciones para lograr el mejor resultado.

El trabajo final corresponde a (Zhang et al., 2021), donde estudiaron la predicción de la vida útil restante de una herramienta de corte, desarrollando de forma sistemática una nueva metodología que integra el exponente de Hurst y la red neuronal convolucional híbrida (el algoritmo de red de memoria a corto plazo y largo). En la investigación de la predicción de RUL sobre herramientas de corte se adoptó el conjunto de datos del Society Conference Data Challenge PHM 2010. La precisión del modelo propuesto de tres capas convolucionales y dos capas de agrupación es del 75,3 %. Los resultados mostraron que, con base en el estudio de caso de esta investigación, la precisión de predicción de la metodología propuesta alcanzó el 87.3 %, que son significativamente mejores que las de los algoritmos de evaluación comparativa. Se investigó mostrando que el 30 % del costo de fabricación podría ahorrarse adoptando este sistema. Al igual que la presente investigación, trata de conocer el tiempo estimado para predecir la herramienta de corte con las cantidades necesarias al querer obtener una reducción en el costo de producción.

2.2 Bases teóricas

La siguiente sección describe las variables de estudio relevantes para la investigación.

2.2.1 Máquinas CNC

Las máquinas CNC contemporáneas efectúan el diseño con una serie de instrucciones que utilizan para lograr cortar las piezas. En múltiples herramientas al realizar cada uno de todos los cortes deseados (diferentes tamaños de cuchilla). La capacidad de poder programar dispositivos informáticos, ya que son nuevas técnicas de producción, y de esa manera controlar herramientas de máquinas, logrando incrementar la calidad de los productos finales, permite avanzar rápidamente la productividad en talleres, al automatizar los procesos altamente técnicos que consumían mucho tiempo, la reducción de costos y mano de obra (Kelly & Hood, 2010).

El maquinado CNC tiene proceso de manufactura que mediante la programación de software que se define el proceso que maneja los movimientos de las herramientas de corte en la pieza a trabajar, donde dirigen a los movimientos que realizará el corte del

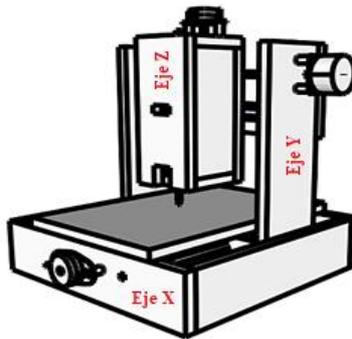
metal, que representa uno de los dos métodos más comunes para generar prototipos a partir de un archivo de software digital. Las máquinas CNC son dispositivos electromecánicos que tienen la aplicación de manipular herramientas en talleres, efectuando entradas de la programación. Por ejemplo, el definir los ejes de rotación de la pieza de corte y el eje de la pieza a mecanizar, se efectúan de manera automática por la computadora de la máquina. Estas máquinas utilizan los modelos 3D de las piezas, para determinar las rutas de barrido con las herramientas de corte, la cual es parte de los métodos sustractivos (Kelly & Hood, 2010).

Actualmente, el mecanizado contiene la aplicación de transformar una pieza de material (un bloque de plástico o metal), y obtener al final un producto terminado (pieza creada), mediante un proceso controlado de eliminación en el material inicial. Es similar a las impresiones 3D que actualmente se utilizan en investigaciones y tienen mucha proyección, la máquina CNC se basa en instrucciones digitales de un archivo de Fabricación Asistida por Computadora (CAM) o Diseño de Ayuda Asistida por Computadora (CAD). En estos equipos se usan el recibimiento de los datos que se aplican en el software CAD/CAM que en otras investigaciones con la misma idea se emplean. En algunos casos se involucra el actuador de corte, debido a que se puede proceder a un proceso manual (Arango & Pineda, 2010).

Los cortes automatizados mejoran con la velocidad y la precisión que se puede generar en las piezas de prototipo más precisas que con entradas manuales, especialmente cuando es un material de polipropileno. La máquina clásica se mueve lateralmente en uno o dos ejes de coordenadas (X, Y), mientras que las máquinas tecnológicas se mueven en los ejes, longitudinalmente (eje Z), ya que son capaces de voltear automáticamente, logrando eliminar el material restante que antes se encontraba debajo. Es el caso de las implementaciones que tiene como tal las máquinas CNC (tornos, fresadoras, cortadoras, etc.), con movimientos en sus tres ejes (X, Y y Z) como se ve mostrado en la Figura 1 con el uso del control numérico computarizado donde tres ejes permiten moverse y cortar en tres dimensiones. El diseño de la estructura del movimiento se encuentra en el eje X de derecha a izquierda; en eje Y, siendo él, más largo, se mueve de atrás hacia adelante y en el eje Z, logra estabilizar y relieves en la forma de cortar de abajo hacia arriba. Debido a que tiene muchas posibilidades en el modo de corte y no es perpendicular a los ejes X e Y, se logra una eficiencia para cortar de distintas formas o maneras complejas, que incluso llegan al campo de la arquitectura. (Alonso et al., 2015).

Figura 1

Diseño estructural de la máquina CNC.



Fuente: (Alonso et al., 2015).

Las máquinas CNC se indican en tipos de equipos y los trabajos que pueden ejecutar por el dispositivo de entrada (introducir datos para el proceso). Las fábricas utilizan una alta cantidad de piezas y requieren todas ellas sin ningún solo error para ello se prosiguen 6 elementos:

- Unidad de control

Es una pieza indispensable que maneja la lista de códigos continua y limpia.

- Máquina herramienta

Sirve para dar formas a piezas sólidas, en especial a metales y suelen ser máquinas estacionarias.

- Sistema de accionamiento

Sirve para convertir la energía eléctrica en mecánica

- Dispositivo de realimentación

Sirven para enviar la señal al variador o controlador de movimiento en el monitoreo la operación

- Monitor

Muestra la información de la CNC.

- Accesorios programables

Cambiador automático de herramienta, velocidad en Y, activación de husillo y refrigerante.

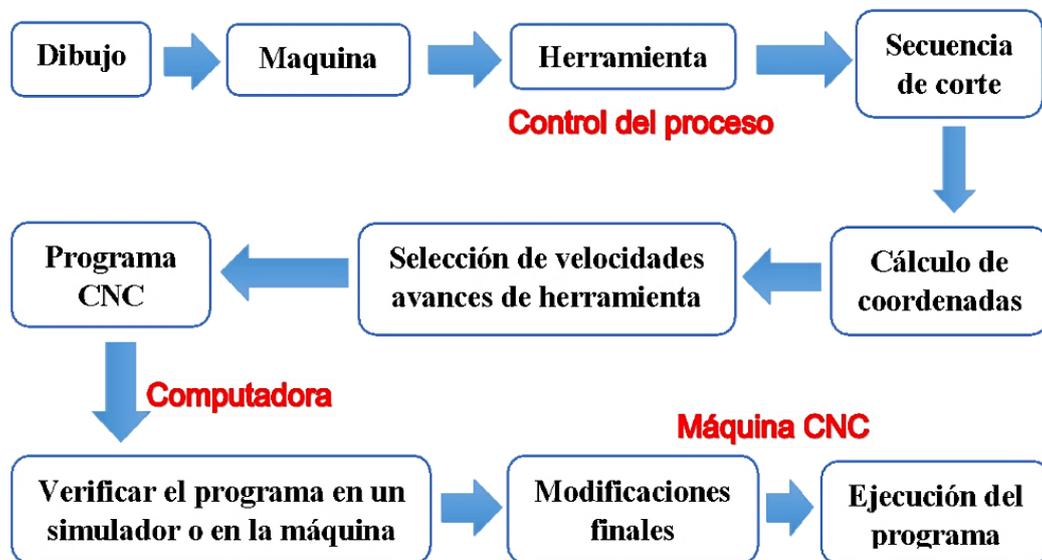
- Programa CNC

Es un listado de instrucciones que hará la máquina.

- Controlador CNC
Interpreta el programa y acciona una serie de comandos en orden secuencial.
- Programa CAM
Funciona juntamente con el diseño para definir la configuración de la pieza.
- Sistema DNC
Es una computadora conectada en red con una o más máquinas.
- Control de movimiento
Permite establecer posiciones precisas y una sincronización de acuerdo con fuerza, aceleración y desaceleración.

Figura 2

Diagrama general del manejo de la secuencia de cortes en una máquina CNC



Fuente: (Mejía-Ugalde, 2014).

Cuando nos referimos a CNC tendremos siempre la idea de que estemos siempre hablando de los usuarios de sistemas CAD/CAM, pero hay casos que nos encontramos con conceptos que son prioridad para otros. En total podemos enumerar tres tipos genéricos:

a) Máquinas de control punto a punto

Este tipo de máquinas solo se mecanizan en los puntos iniciales y finales de las piezas, pero no en los trayectos. No requiere de control sobre parámetros de velocidad y trayecto. Utilizado en taladros y punteadores CNC (Sebastián Pérez & Luis Pérez, 2013).

Figura 3

Taladro CNC



Fuente: («Taladro CNC», 2021).

b) Máquinas de control paraxial

Este tipo de máquinas nos permite programar desplazamientos a lo largo de todo el eje, con la salvedad de que la trayectoria debe ser paralela al eje de movimiento, es decir, no puede hacer un canal chavetero. En este tipo ingresan los tornos CNC (Sebastián Pérez & Luis Pérez, 2013).

Figura 4

Torno CNC



Fuente: (ROMI Máquinas España S.A., s. f.).

c) Máquinas de control interpolador o continuo

Son las más polivalentes, porque permite hacer cualquier trayectoria sobre la superficie del material, permite reducir alturas, crear canales, contorneado de piezas. Estas máquinas poseen orientación por modelos 3D y simulación en ordenador. Aquí podemos encontrar a las fresadoras CNC, cortadoras e impresoras 3D (Sebastián Pérez & Luis Pérez, 2013).

Figura 5

Fresadora CNC



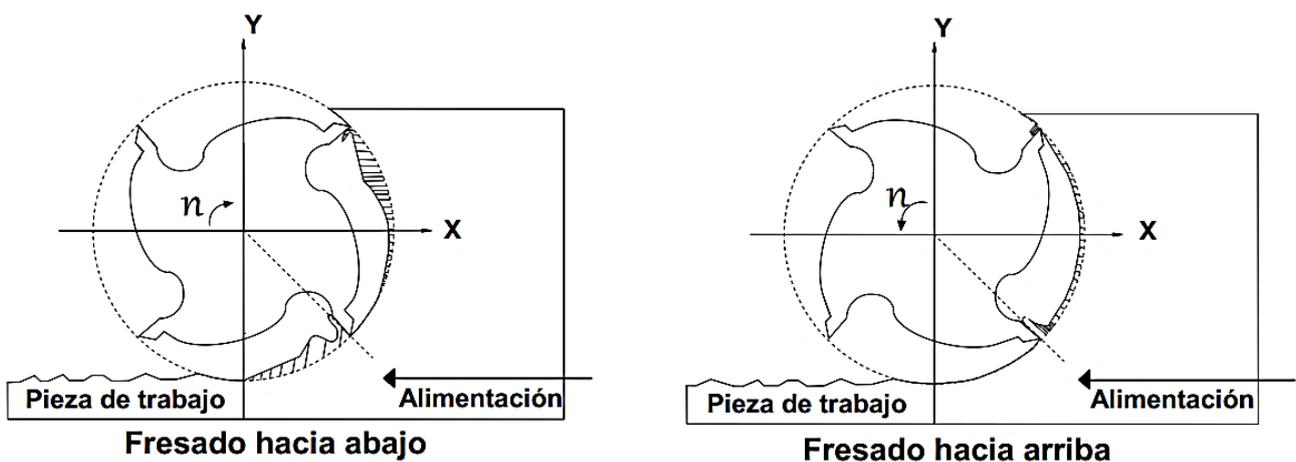
Fuente: (Heller Máquina-Herramienta, S.L., s. f.).

La máquina fresadora de codo y columna (de consola) es la máquina herramienta básica para fresado. Deriva su nombre del hecho de que sus dos principales componentes son una columna que soporta el husillo y un codo (se parece a un codo humano) que soporta la mesa de trabajo. Se puede disponer de máquinas horizontales o verticales. La pieza se mueve alrededor en uno de los ejes, mientras que la pieza de corte se mantiene estática. Requieren de un soporte para que no sea empujada por las altas revoluciones del material (Haynes, 2016).

Se muestra en la Figura 6 el fresado hacia abajo y el fresado hacia arriba donde se diferencia el sentido de giro (n) que se observa el proceso de la pieza de trabajo siendo alimentada por la velocidad que se le aplique (Altintas, 2012).

Figura 6

Fresadora CNC



Fuente: (Altintas, 2012).

Los cortadores son perfectos para las herramientas de corte, producen un buen acabado superficial y eliminan eficazmente las virutas en las cavidades de las placas que logran cambiar el espesor. En la práctica, se utilizan tres tipos de fresado: la operación de fresado convencional, operación de corte descendente y el fresado se denomina fresado periférico o final (Altintas, 2012).

2.2.1.1 Tipos de máquinas CNC

Los tipos de máquinas CNC se definen en las siguientes clasificaciones donde las más usadas son las máquinas CNC estáticas y portátiles entre ellas (Suh et al., 2008):

- Fresadora

Realiza piezas de formas específicas, mediante un proceso de mecanismo con el uso de una fresa, el mecanizado es un modo de manufactura por remoción del material (abrasión y arranque de viruta).

- Electroerosión

Es un arco eléctrico que se encuentra entre una pieza y un electrodo localizado en un medio dieléctrico logrando extraer partículas de la pieza hasta conseguir reproducir en ellas las formas de un electrodo.

- Torno

La máquina hace girar las piezas mientras que otras herramientas realizan los cortes según las condiciones que se programaron previamente en las indicaciones a realizar es utilizado por las industrias por el alto nivel de precisión y fiabilidad.

- Taladradoras

El taladrado es una operación de maquinado que se utiliza para hacer barrenos (agujeros redondos) sobre una pieza.

- Estampadora

Tiene la función de decorar ropa, carteles y pancartas cualquier superficie apta para la sublimación

- Rectificadora

Es una máquina herramienta que sirve para realizar mecanizados por abrasión con mayor precisión dimensional y con menores rugosidades que el mecanizado por el arranque de viruta utilizando discos abrasivos llamados muelas.

- Prensa

Sirve para compactar

- Máquina de corte por láser

Corta o grava con la ayuda de un control desde un programa 2D.

- Brazo robotizado

Sirven para hacer tareas continuas que impliquen mover objetos de distintos pesos con precisión para realizar diferentes montajes con ángulos y posiciones diferentes.

- Chorro de agua

Corta materiales blandos como espumas, plásticos, papel, paneles de cemento, etc.

- Acero al carbono

Fabricadas en acero al carbono, con una resistencia térmica de 250 - 300 °C, pasada esta temperatura pierde su filo. Se emplean en velocidades bajas o torneado de maderas o plásticos (De Máquinas y Herramientas, 2015).

- Acero rápido

Fabricado en acero aleado con elementos ferrosos como el tungsteno, cromo, vanadio, molibdeno y otros. Tiene una resistencia térmica de 650 °C, utilizado para metales blandos (De Máquinas y Herramientas, 2015).

- Carburo cementado

Fabricados a base del polvo de carburo y el cobalto, llegan a una resistencia térmica de 850 °C y destacan por su dureza y alta resistencia al desgaste. Utilizado para maquinariar hierro colado, materiales no ferrosos y abrasivos (De Máquinas y Herramientas, 2015).

- Cermet

Es una combinación de material cerámico y metal, las partículas base son de TiC, TiCN y TiN a diferencia del carburo de tungsteno, y una combinación de níquel - cobalto. Posee una alta resistencia al desgaste, estabilidad química y resistencia térmica, usado en materiales de acero, fundiciones y virutas dúctiles (De Máquinas y Herramientas, 2015).

- Cerámica

Basadas en óxido de aluminio o en nitruro de silicio, presentan alta dureza en altas temperaturas y no son reactivas ante los materiales del material mecanizado. Se emplean en el sector automotor y autopartes (De Máquinas y Herramientas, 2015).

- Nitruro de Boro Cúbico

Superado sólo por el diamante, presenta una alta resistencia a la temperatura, gran resistencia al desgaste y buena estabilidad química. Es frágil pero más tenaz que la cerámica (De Máquinas y Herramientas, 2015).

- Diamante policristalino

Material sintético, casi tan duro como el diamante natural, alta resistencia al desgaste, baja conductividad térmica, por lo que posee una mayor cantidad de vida útil en comparación a las anteriores mencionadas, la temperatura de corte no debe exceder los 600 °C, usado para mecanizado de materiales ferrosos y no para materiales tenaces (De Máquinas y Herramientas, 2015).

Los equipos antes mencionados se clasifican según la manera en que se realicen sus funciones o trabajos en específico:

- ✓ Máquinas de control punto a punto.
- ✓ Máquinas de control paraxial.
- ✓ Máquinas de control interpolar o continuo.

2.2.1.2 Partes de la máquina CNC

El CNC es el uso de un computador para controlar movimientos, velocidades y trayectorias para el maquinado de piezas, para esto necesitan controlar los movimientos de la mesa o bancada, de los ejes de movimiento de la pieza (según sea necesario), las velocidades y posiciones de las piezas de corte o desbaste (esta acción se realiza mediante servomotores). Las CNC de mayor tamaño disponen de un sistema de retroalimentación que monitorea y ajusta las velocidades (Youssef & El-Hofy, 2020).

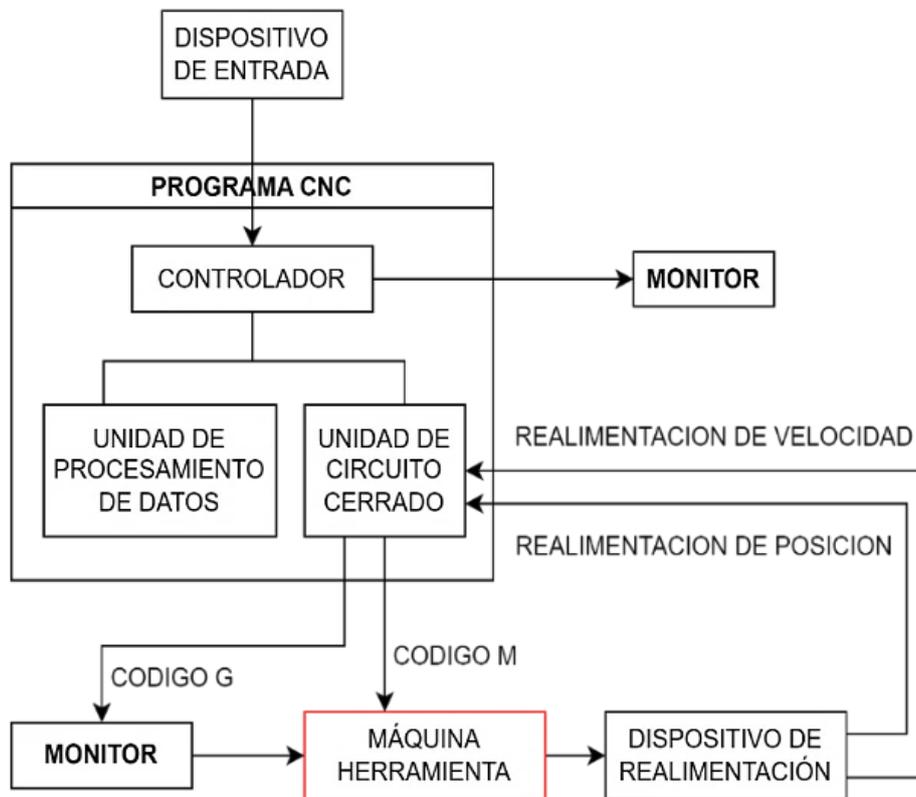
Normalmente, se una máquina CNC se compone de:

- Dispositivo de entrada
- Unidad de control o controlador
- Máquina herramienta
- Sistema de accionamiento
- Dispositivos de retroalimentación (sólo en sistemas con servomotores)
- Monitor

La Figura 7 muestra un diagrama de bloques de una máquina CNC típica, provista de servomotores.

Figura 7

Diagrama de máquina CNC



Fuente: (Kibria et al., 2019)

a) Control de movimiento

En todas las máquinas CNC se tienen características en común, como dos o más direcciones de movimiento programables llamadas ejes. El eje de movimiento puede ser en dirección recto (línea recta) o giratorio (trayecto circular). Una de las primeras especificaciones que dan a entender es la complejidad de una CNC por el número de ejes que tiene y por ende será mayor la complejidad al usarlo (Robotics and CNC, 2020)

Los ejes de una máquina CNC son esenciales para crear los movimientos necesarios para el proceso de fabricación. Si se utiliza el ejemplo de un taladro industrial, entonces los ejes pondrán la herramienta en el agujero a mecanizar (2 ejes) y realizarán la operación (el 3er eje). Los ejes están etiquetados con letras. Los nombres más comunes para los ejes lineales son X, Y y Z, mientras que los nombres más comunes para los ejes de rotación son A, B y C (Robotics and CNC, 2020).

El control de movimiento puede ser realizarse e implementarse mediante dos sistemas que pueden funcionar individualmente o en combinación entre ellos:

- Valores absolutos (código G90)

Las coordenadas del punto de destino son referidas al punto de origen de coordenadas. Se usan las variables X y Z, por la medida del diámetro final y la medida en dirección paralela al eje de giro del husillo, respectivamente (Robotics and CNC, 2020).

- Valores incrementales (código G91)

Las coordenadas del destino son referidas al inicio. Se usan las variables U y W para la distancia radial y medida en dirección paralela al eje de giro del husillo, respectivamente (Robotics and CNC, 2020).

b) Accesorios programables

Una máquina CNC no será útil si solo tiene control del movimiento. Casi todas las máquinas se pueden programar de diferentes maneras. El tipo de máquina particular está directamente vinculado a sus accesorios programables, por lo que cualquier funcionalidad requerida se puede programar en una máquina CNC (Robotics and CNC, 2020).

Un centro de mecanizado tienen al menos las funciones específicas programables:

- Cambiador automático de herramienta

La mayoría de los centros de mecanizado tendrían muchas herramientas diferentes en un portaherramientas para cuando se requiera. La herramienta se puede colocar de forma automática en el husillo para realizar el mecanizado (Robotics and CNC, 2020).

- Velocidad y activación del husillo

La velocidad del husillo (unidad RPM) se puede especificar fácilmente y el husillo puede girar no sólo en sentido horario o antihorario, sino que también se puede detener (Robotics and CNC, 2020).

- Refrigerante

Muchas operaciones de maquinado requieren refrigerante para lubricación y enfriamiento. El refrigerante se puede encender y apagar durante el ciclo de trabajo de la máquina (Robotics and CNC, 2020).

c) Programa CNC

Este es un listado secuencial de instrucciones que realizará la máquina. Las instrucciones se denominan programas CNC, que deben contener toda la información necesaria para preparar el mecanizado de la pieza (Robotics and CNC, 2020).

El programa CNC está escrito en lenguajes de bajo nivel nombrados G y M, estandarizado por la norma del estándar 6983 de ISO (Organización Internacional de Normalización) y RS274 de EIA (Alianza de Industrias Electrónicas) y compuesto por términos Generales (código G) y Misceláneas (código M). El programa presenta un formato de oraciones que consta de bloques, encabezados por la letra N, tal como visualizamos en la Tabla 1, donde en cada movimiento o acción se realiza de forma secuencial y cada bloque está numerado y generalmente contiene un comando (Robotics and CNC, 2020).

El código G describen las funciones de movimiento de la máquina (rápidos, avances, radiales, pausas y ciclos), mientras que los códigos M describen otras funciones misceláneas que se requieren para el procesamiento parcial de la pieza, pero que no corresponden al movimiento de la máquina (arranque y parada del husillo, cambio de herramienta, refrigerante, programa parado) como se muestra en la Tabla 1 (Robotics and CNC, 2020).

Cada código a su vez contiene variables (direcciones), delimitadas por otros caracteres y especificadas por el programador para cada función específica. Por ejemplo, F define la velocidad de avance, S es la rapidez del husillo, T es la herramienta específica, X, Y y Z el movimiento de los ejes, I, J y K la localización del centro de un arco, etc (Robotics and CNC, 2020).

Cabe señalar que cada máquina tiene su propio programa CNC. Para ello, en la Tabla 1 se muestran los códigos G y M más utilizados para fresadoras CNC. Son herramientas utilizadas en mayor medida para cortar las funciones para arranques de viruta, mediante el movimiento de una herramienta de rotación con varios labios/cortes a la que se le denomina fresa. Estas máquinas pueden hacer distintos tipos de fresado en diferentes superficies. Los centros de corte por control numérico están pensados para dar soluciones a una gran variedad de productos de distintos sectores desde el rotulista o taller de metalmecánicas hasta el sector industrial y la enseñanza (la fabricación digital). Según el modelo de que se trate, algunos de los códigos pueden estar inhabilitados (TecnoEdu, s. f.).

Tabla 1*Códigos G y M para una fresadora CNC*

Códigos G	Códigos M
G00: Posicionamiento rápido (sin maquinar)	M00: Parada
G01: Interpolación lineal (maquinado)	M01: Parada opcional
G02: Interpolación circular (horario)	M02: Reset del programa
G03: Interpolación circular (antihorario)	M03: Hacer girar el husillo en sentido horario
G04: Compás de espera	M04: Hacer girar el husillo en sentido antihorario
G15: Programación en coordenadas polares	M05: Frenar el husillo
G20: Comienzo de uso de unidades imperiales (pulgadas)	M06: Cambiar de herramienta
G21: Comienzo de uso de unidades métricas	M08: Abrir el paso del refrigerante
G28: Volver al home de la máquina	M09: Cerrar el paso de los refrigerantes
G40: Cancelar compensación de radio de curvatura de herramienta	M10: Abrir mordazas
G41: Compensación de radio de herramienta a la izquierda	M11: Cerrar mordazas
G42: Compensación de radio de herramienta a la derecha	M13: Hacer girar el husillo en sentido horario y abrir el paso de refrigerante
G50: Cambio de escala	M14: Hacer girar el husillo en sentido antihorario y abrir el paso de refrigerante
G68: Rotación de coordenadas	M30: Finalizar programar y poner el puntero de ejecución en su inicio
G73: Ciclos encajonados	M38: Abrir la guarda
G74: Perforado con ciclo de giro antihorario para descargar virutas	M39: Cerrar la guarda
G76: Alesado fino	M62: Activar salida auxiliar 1
G80: Cancelar ciclo encajonado	M67: Esperar que la entrada 2 este en ON
G81: Taladro	M71: Activa el espejo en Y
G82: Taladro con giro antihorario	M80: Desactivar el espejo en X
G83: Taladro profundo con ciclos de retracción para retiro de viruta	M81: Desactivar el espejo en Y
G90: Coordenadas absolutas	M98: Llamada a subprograma
G91: Coordenadas relativas	M99: Retorno de subprograma
G92: Desplazamiento del área de trabajo	
G94: Velocidad de corte expresada en avance por minuto	
G95: Velocidad de corte expresada en avance por revolución	
G98: Retorno al nivel inicial	
G99: Retorno al nivel R	
G107: Programación del eje	

Fuente: (*Control numérico, s. f.*)

d) Controlador CNC

Este componente principal interpreta el programa CNC y ejecuta la serie de comandos en orden secuencial. Mientras lee el programa, la unidad de control activa las funciones apropiadas de la máquina, dirige el movimiento de los ejes y, en general, sigue las instrucciones dadas en el programa (Webmaster, 2019).

Además de interpretar el programa CNC, el controlador tiene varios otros propósitos, por ejemplo:

- Modificar (cambiar) los programas si se detectan errores.
- Realizar funciones de verificación especial (como el funcionamiento en vacío) para confirmar la precisión del programa CNC.
- Define ciertas entradas importantes del operador, como el valor de longitud de la herramienta.

e) Programa CAM

La importancia del programa CAM (Fabricación asistida por computadora) cuando la escritura del programa CNC es difícil, posiblemente debido a la ignorancia del operador o aplicaciones complejas. En muchos casos, el programa CAM funciona conjuntamente con el diseño asistido por computadora (CAD). Esto elimina la necesidad de redefinir la configuración de la pieza para el programa CAM. El programador CNC sólo necesita especificar las operaciones de mecanizado a realizar y el programa CAM se generará automáticamente el programa CNC (Webmaster, 2019).

f) Sistema DNC

Una vez que se haya desarrollado el programa CNC (manualmente o con un programa CAM), se debe cargar en el controlador y para ello se utiliza un sistema de distribución de control numérico (DNC). Un sistema DNC es una computadora en red con una o más máquinas CNC. Tradicionalmente, los programas se efectuaban mediante un protocolo rudimentario de comunicaciones seriales (RS-232C). Sin embargo, la tecnología ha evolucionado para dar a las consolas de hoy mayores capacidades de conectividad para que puedan conectarse en red de formas más tradicionales, como a través de Ethernet (Webmaster, 2019).

La máquina CNC consta de seis elementos principales (Webmaster, 2019):

- Dispositivo de entrada.
- Unidad de control o controlador.
- Máquina herramienta.
- Sistema de accionamiento.
- Dispositivos de realimentación (sólo en sistemas con servomotores).
- Monitor.

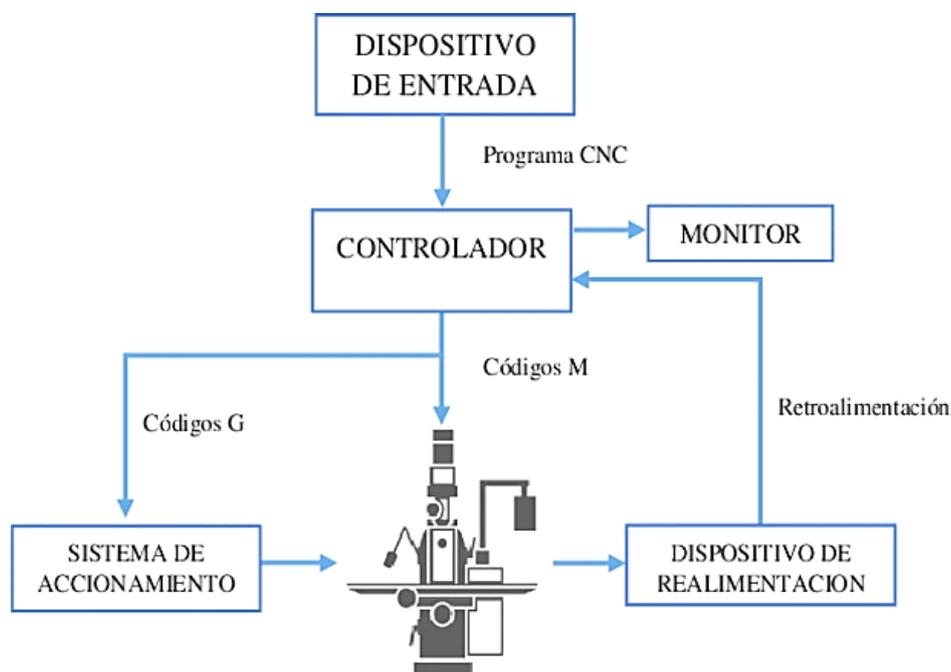
Tiene diferentes elementos como se observa en la Figura 8, donde el componente principal es el circuito de control que interpreta las señales eléctricas enviadas por la computadora o el microcontrolador para controlar la posición relativa del actuador rotativo, también puede controlar la velocidad del motor, señales de entrada y salida mientras el dispositivo se encuentra en funcionamiento (Narváz Encalada, 2021).

- Máquina herramienta (tres ejes).
- Sistema de accionamiento.
- Monitor (interfaz de visualizar las operaciones).

La primera fresadora CNC fue desarrollada por el Instituto tecnológico de Massachusetts, mostrando en la Figura 8 se observará el sistema de la máquina CNC.

Figura 8

Diagrama de bloques del sistema de control de una máquina CNC



Fuente: (Narváz Encalada, 2021).

2.2.2 Fresadora CNC

Una fresadora se utiliza para dar forma y acabado a piezas de trabajo mediante el arranque de viruta. Convencionalmente se refiere a las características habituales que emplea un trabajador en procesos de control manualmente y mecánico debido a la experiencia previa o establece el movimiento automático. Las fresadoras se pueden clasificar de acuerdo con su sistema de control como fresadoras convencionales o fresadoras con control numérico computarizado (CNC) (Casado, 2020)

En una fresadora convencional, un operador controla manualmente o establece el movimiento automático. En el caso de la fresadora CNC, todos los movimientos se establecen mediante un programa de software por computadora logrando controlar electrónicamente el movimiento de uno o más ejes en la máquina. Por lo general una fresadora CNC cuenta con un tambor de herramientas y un sistema automático de cambio de herramientas. En la actualidad, un cambio de herramienta solo requiere de fracciones de segundo (Haynes, 2016).

Una fresadora CNC tiene unidades mecánicas, de electrónica de potencia y de control numérico. La unidad mecánica está compuesta de una mesa de trabajo, husillo y mecanismo de accionamiento de alimentación. La unidad de electrónica de potencia consiste de motores de avance y de sus servoamplificadores, fuente de alimentación en alto voltaje, y los finales de carrera. La unidad de control numérico consiste de una computadora y de sensores de posición y velocidad para cada mecanismo de accionamiento (Altintas, 2012).

En una fresadora CNC el husillo gira en un amplio rango de velocidades, pudiendo llegar hasta 35.000 rev/min. Por otro lado, las unidades de alimentación usualmente convierten el movimiento angular de los motores en movimiento lineal, con una velocidad lineal de hasta 30.000 mm/min. Los servomotores más utilizados para los accionamientos de alimentación son los motores de corriente continua (CC) por su eficiente capacidad de entrega de par a varias velocidades (Altintas, 2012).

2.2.2.1 Componentes mecánicos y Torque

El motor de accionamiento de avance tiene que superar las cargas estáticas y dinámicas en la máquina herramienta. Las fuentes de las cargas estáticas son las pérdidas por fricción en las guías y cojinetes, así como las fuerzas de corte transversales que actúan en la dirección del movimiento de la placa. El motor debe proporcionar suficiente par dinámico para acelerar momentáneamente la placa, la pieza de trabajo y el tornillo

guía hasta que el accionamiento alcance la velocidad constante deseada. Los fabricantes de servomotores definen el par dinámico como par máximo o entrega de corriente máxima con un período de 2 a 3 segundos. Los motores deben tener una tasa de transferencia de un par continuo y máximo de un tiempo de transferencia suficientemente altos para superar las cargas estáticas y dinámicas, respectivamente (Altintas, 2012).

Las cargas estáticas tienen tres fuentes (fricción en las guías deslizantes, las pérdidas por fricción en los cojinetes de la transmisión de alimentación y las fuerzas de corte). La fricción en las guías depende del tipo de contacto entre la placa deslizante y la guía permanente. Altos coeficientes de fricción se encuentran en guías de lubricación simple, donde el área de contacto de la superficie de la guía y la placa metálica es grande. En guías hidrostáticas e hidrodinámicas, donde se inyecta un lubricante entre la placa y la guía, se reduce el área de contacto del metal. El coeficiente de fricción es probablemente el más bajo en los diseños de guías en los que se utilizan rodamientos de rodillos en la placa de la guía (Altintas, 2012).

Las cargas dinámicas en las máquinas herramienta requieren un alto par de aceleración durante los cambios de velocidad. La inercia reflejada en el eje del motor consiste en la inercia de la placa, pieza, husillo, engranajes y el eje del motor. El momento de inercia de la placa y la pieza de trabajo reflejada en el eje del husillo. Hay dos dispositivos básicos de retroalimentación en el sistema de control para la transmisión de avance (transductores de retroalimentación de posición y velocidad) (Altintas, 2012).

Los tacómetros se utilizan como transductores de velocidad y los codificadores se utilizan como transductores de realimentación de posición en general. Un tacómetro es un pequeño motor de CC de imán permanente montado directamente en la parte trasera del eje del servomotor. El tacómetro produce un voltaje proporcional a la velocidad real del eje del motor. Tiene una constante establecida en fábrica y una ganancia ajustable que permite sintonizar el bucle de retroalimentación de velocidad (Altintas, 2012).

Los codificadores se utilizan como transductores de medición de posición digital en servoaccionamientos. El codificador se basa en el principio de emisión de luz con fotodiodos. Los fabricantes de servomotores suelen proporcionar codificadores de eje y tacómetro instalados en la parte trasera del eje del motor en la fábrica. El codificador se proporciona con una densidad de línea y el tipo de decodificador de detección utilizado. Los codificadores se representan simplemente como una ganancia K_e (conteos/rad o conteos/mm) en el análisis de bucle de control de posición (Altintas, 2012).

Los accionamientos de alimentación pueden funcionar con motores eléctricos que pueden ser paso a paso (CC o CA) o hidráulicos. El tipo de motor utilizado depende en gran medida de los requisitos de entrega de par y tiempo de respuesta de la máquina herramienta o del accionamiento del robot. Los motores hidráulicos se utilizan cuando se requiere un amplio rango de par y una respuesta rápida de un sistema de accionamiento. Los motores hidráulicos rotativos se utilizan en robots, tornos y fresadoras industriales de servicio pesado. Los motores hidráulicos lineales con unidades de desplazamiento de pistón se utilizan en rectificadoras, cepilladoras y perfiladoras donde se requiere un movimiento alternativo. Las desventajas de los accionamientos hidráulicos incluyen fugas, baja eficiencia, sensibilidad a la suciedad en el aceite de suministro y altos costos de mantenimiento. Los motores paso a paso eléctricos no son comunes en los sistemas de accionamiento de alimentación donde la carga de corte es alta. Se utilizan sin dispositivos de retroalimentación del motor de pasos, se controla con movimientos de pasos angulares que se envían en forma de pulsos de control desde una computadora. En los arranques y el frenado, si el par dinámico requerido es grande, el motor paso a paso puede deslizar algunos de los pulsos de control de posición (Altintas, 2012).

2.2.3 Herramientas de corte

Son piezas de desgaste o desbaste que sirven para a retirar capas de material, para poder reducir medidas, generar canales o formas distintas a las originales del material base, estas se encuentran sometidas a condiciones de temperatura extrema y grandes tensiones, deben ser fabricadas en materiales que soporten estas condiciones y de dar un acabado superficial de calidad (Chariguamán Tapia & Jarrin Gualoto, 2019).

Las herramientas de corte dependen del material de composición que presente alta dureza, resistencia a temperaturas elevadas, desgaste y ductilidad (Denkena, 2013). Se dividen en:

- Acero al carbono

Fabricadas en acero al carbono, con una resistencia térmica de 250-300 °C, pasada esta temperatura pierde su filo. Se emplean en velocidades bajas o torneado de maderas o plásticos (Youssef & El-Hofy, 2020).

- Acero rápido

Fabricado en acero aleado con elementos ferrosos como el tungsteno, cromo, vanadio, molibdeno y otros. Tiene una resistencia térmica de 650 °C, utilizado para metales blandos (Youssef & El-Hofy, 2020).

- **Carburo cementado**

Fabricados a base de polvo de carburo que, combinado con el cobalto, llegan a una resistencia térmica de 850 °C. destacan por su dureza y alta resistencia al desgaste. Utilizado para maquinar hierro colado, materiales no ferrosos y materiales abrasivos (Youssef & El-Hofy, 2020).
- **Cermet**

Es combinación de material cerámico y metal, las partículas base son de TiC, TiCN y TiN en vez de carburo de tungsteno, y una combinación de níquel-cobalto. Posee una alta resistencia al desgaste, estabilidad química y resistencia térmica, utilizado en materiales de viruta dúctil, aceros y fundiciones dúctiles (Youssef & El-Hofy, 2020).
- **Cerámica**

Basadas en óxido de aluminio o en nitruro de silicio, presentan alta dureza en altas temperaturas y no son reactivas ante los materiales del material mecanizado. Se emplean en el sector automotor y autopartes (Youssef & El-Hofy, 2020).
- **Nitruro de Boro Cúbico**

Superado sólo por el diamante, presenta una alta resistencia a la temperatura, gran resistencia al desgaste y buena estabilidad química. Es frágil pero más tenaz que la cerámica (Youssef & El-Hofy, 2020).
- **Diamante policristalino**

Material sintético, casi tan duro como el diamante natural, alta resistencia al desgaste, baja conductividad térmica, por lo que posee una mayor cantidad de vida útil en comparación a las anteriores mencionadas, la temperatura de corte no debe exceder los 600 °C, usado para mecanizado de materiales ferrosos y no para materiales tenaces (Youssef & El-Hofy, 2020).
- **Cortador giratorio**

Es probablemente una de las tecnologías más utilizada en las máquinas CNC, donde se basan en su proceso, en el desgaste de las superficies del material, por medio de una herramienta llamada fresa que vemos en la Figura 9, donde se encuentra girando sobre su eje, con el parecido funcionamiento al del taladro, pero esta pieza puede moverse en más de un eje (Haynes, 2016).

Figura 9

Fresas



Fuente: Imagen referencial de (TRESDE, 2019).

2.2.3.1 Desgaste en las herramientas de corte

En la industria, el desgaste de la herramienta de corte es un problema inevitable que puede tener graves consecuencias si no se maneja adecuadamente. Es por eso que es fundamental cambiar la fresa en el momento oportuno, ni muy temprano ni muy tarde, a fin de evitar productos defectuosos, fallas en el equipo y demoras en la producción.

Para prevenir esto, es necesario predecir el desgaste de la fresa progresivo hasta llegar a la rotura, lo que permitirá tomar las medidas necesarias antes de que sea demasiado tarde (Ferguson et al., 2018). Los principales desgastes en la herramienta de corte se pueden observar en la Tabla 2, y es importante llevar un seguimiento constante del desgaste de la herramienta para asegurar la eficiencia del proceso de corte y la calidad del producto final.

Para predecir el desgaste de la herramienta de corte, existen diversas técnicas de monitoreo, como el análisis de vibraciones, el análisis acústico, el análisis de imágenes y el análisis de señales eléctricas. Estas técnicas permiten medir el desgaste de la herramienta de manera no destructiva, lo que es importante para evitar dañar la herramienta y el equipo.

Además, es importante tener en cuenta que el desgaste de la herramienta de corte no es homogéneo y puede variar dependiendo de varios factores, como la velocidad de corte, la fuerza de corte, la geometría de la herramienta, el material de la pieza de trabajo, entre otros. Por lo tanto, es necesario tener en cuenta estos factores al predecir el desgaste de la herramienta y tomar las medidas necesarias para mantener la eficiencia del proceso de corte y la calidad del producto final.

Tabla 2*Los tipos de desgastes en herramientas de corte*

Tipo de Desgaste	Causal	Descripción	Fotografía
Desgaste en incidencia	Abrasivo	Se genera por la abrasión generada por el contacto repetitivo con materiales duros.	
Desgaste en cráter	Químico	Caracterizado por el desprendimiento de cubiertas de la herramienta, esto se debe a las reacciones químicas que ocurren entre la herramienta de corte y material	
Filo de aportación	Adhesivo	Ocurrencia de soldeo por presión de virutas en la superficie de la cuchilla de corte.	
Desgaste en entalla	Adhesivo	Caracterizado por la adherencia de virutas en una de las caras de corte de la herramienta, causada por el desprendimiento de otras.	
Deformación plástica	Térmico	Tiene lugar después de que la herramienta de corte se haya reblandecido por las temperaturas excesivas.	
Fisuras térmicas	Térmico	Debido a los cambios bruscos de temperatura entre caliente y frío, puede generar fisuras perpendiculares al filo de corte.	
Astillamiento / rotura del filo	Mecánico	El astillamiento o rotura se debe a una sobrecarga al límite de tracción de la cuchilla, puede tener su origen en el martilleo de la viruta, la profundidad de corte y el avance de la cuchilla	

Fuente: (Sandvik Coromant, s. f.).

2.2.3.2 Medición del desgaste de la herramienta de corte

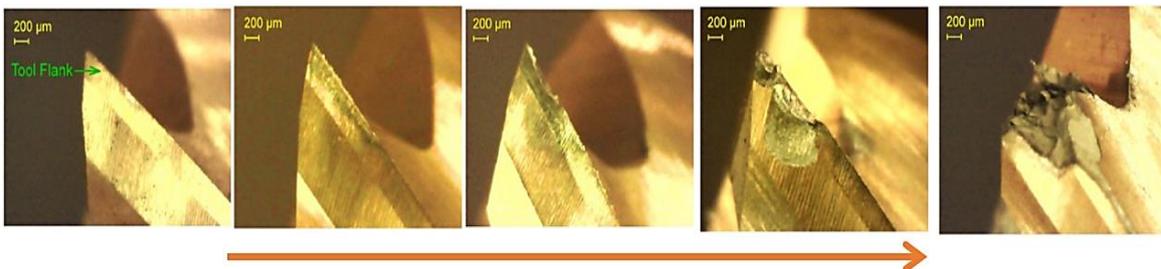
Los sensores empleados en la medición de fuerza, aceleración y emisión acústica se ubican en la máquina CNC, para el estudio del desgaste de filos de un modo individual, donde se trabaja fuera de línea, se retira la herramienta de corte, luego de ello se observa en el microscopio (Teti et al., 2010).

Los procesos empleados son observados en el método de la red neuronal difusa (FNN) y se llevó a cabo un estudio con el mismo conjunto de datos experimentales, en la técnica de medición se realiza comúnmente el seguimiento de las operaciones de los cortes, se logra entender que incluso en el tiempo al procesar se seleccionan los mejores datos, así sea el más corto (Li et al., 2009).

Tal como se muestra en la Figura 10 se ve el desgaste de la herramienta de corte en un tiempo de proceso de uso y se ven el cambio constante de la misma y se entiende que el tema de la investigación en todo CNC es el saber en qué momento cambiarlo.

Figura 10

Desgaste de la herramienta de corte



Fuente: (Ferguson et al., 2018). A data processing pipeline for prediction of milling machine tool condition from raw sensor data. Smart and sustainable manufacturing systems, 2.

Se categorizan en dos enfoques (Teti et al., 2010): directa e indirecta.

a) Método Directo

En este enfoque directo, la cantidad real de la variable se utiliza en la medición del desgaste de la herramienta, por ejemplo, el uso de cámaras para inspección visual, isótopos radiactivos, rayos láser y resistencia eléctrica. Muchos métodos directos se utilizan en aplicaciones de técnicas de laboratorio, esto se debe a las limitaciones que son ocasionadas por problemas en el mecanizado, el uso de fluidos de corte y la iluminación. En efecto, la medición directa tiene un alto grado de precisión y es usado en laboratorio para investigaciones de medición indispensables durante los procesos de mecanizado (Teti et al., 2010).

b) Método Indirecto

En el enfoque indirecto, se pueden medir cantidades auxiliares como son los componentes de la fuerza de corte. Las correlaciones determinadas empíricamente deducen a la cantidad real. Los métodos indirectos no tienen la precisión de los métodos directos, las ventajas de este método son la menor complejidad para aplicar en situaciones prácticas de manera eficiente. A diferencia de la detección tradicional del condicionamiento de la herramienta, el monitoreo de los procesos de mecanizado es continuo, se realizan a través de dispositivos de detección para la cuantificación de su rendimiento y optimizar el proceso con sensores (Teti et al., 2010).

2.2.4 Aprendizaje automático

Es una disciplina científica del ámbito de la Inteligencia Artificial (IA) que crea sistemas que aprenden de manera automática. Aprender en este contexto quiere decir identificar patrones complejos en millones de datos. La máquina que realmente está en constante trabajo se obtienen datos que serán utilizados en el estudio, ya que el que realmente aprende es el algoritmo que revisa los datos y es capaz de predecir comportamientos futuros, como el estudio de esta tesis que al predecir el desgaste de la cuchilla utilizando los datos de corte que fueron estudiados de manera experimental. Los diferentes algoritmos de aprendizaje automático (ML) se trabajan con los siguientes casos: Supervised learning, Unsupervised learning, Semi-supervised learning, Reinforcement learning (Simeone, 2018).

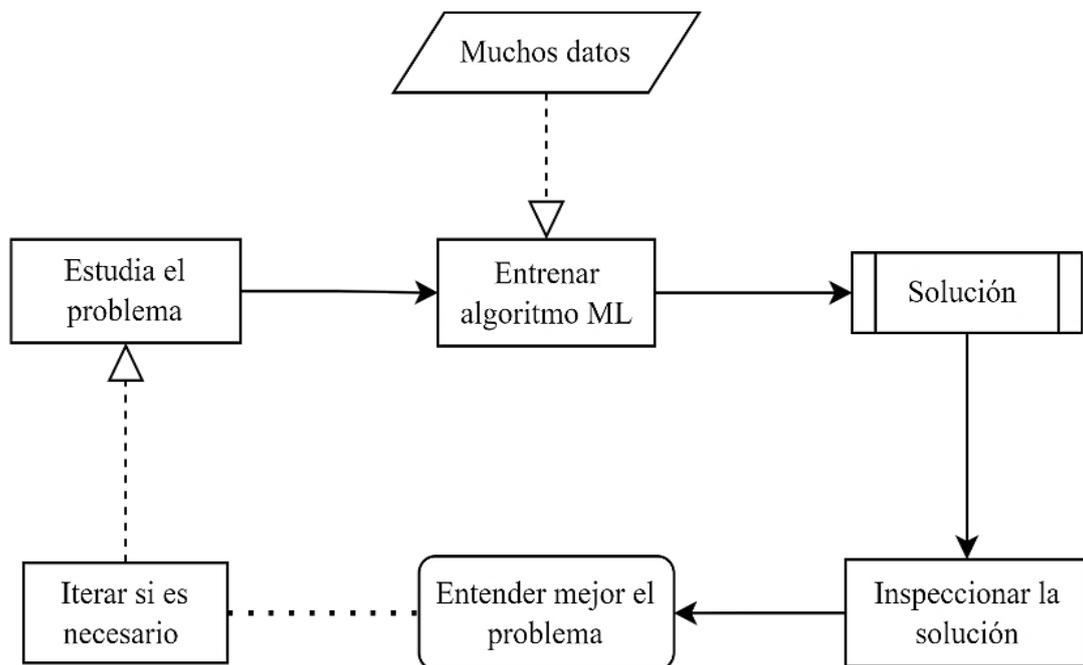
El aprendizaje automático es ideal para los problemas con los cuales las soluciones existentes requieren mucho ajuste manual o largas listas de reglas, en un algoritmo de aprendizaje automático a menudo se puede simplificar el código y realizar pruebas con los datos mejor obtenidos. Utilizando el concepto de aprendizaje automático, donde se usan estadísticas y algoritmos computacionales para proporcionar a los ordenadores la capacidad de «aprender», es decir, mejorar sus resultados en una tarea específica tras procesar datos en suficiente cantidad y sin unas instrucciones explícitas externas proporcionadas por el programador. El ámbito del ML está estrechamente relacionado con otros campos, como la simulación y el modelado, la optimización de sistemas y la estadística. En todos ellos se emplean de manera intensiva técnicas matemáticas comunes que requieren entrenamiento específico (Núñez Reiz et al., 2019).

Para problemas complejos para los que no existe una buena solución utilizando un método tradicional con un enfoque que las mejores técnicas de ML pueden encontrar una solución. Con entornos fluctuantes un sistema de ML puede adaptarse a nuevos datos para obtener información sobre problemas complejos y grandes cantidades de datos. A veces, esto podría revelar correlaciones insospechadas o nuevas tendencias y, por lo tanto, conducirá a una mejor comprensión del problema. La aplicación de técnicas de ML para profundizar en grandes cantidades de datos puede ayudar a descubrir patrones que no eran evidentes de inmediato. Esto se llama minería de datos (Géron, 2019).

Finalmente, el aprendizaje automático puede ayudar a los humanos a aprender como se muestra en la Figura 11, en donde el algoritmo puede inspeccionar constantemente logrando visualizar lo que realmente ha aprendido, aunque en otros algoritmos esto puede ser complicado (Géron, 2019).

Figura 11

Diagrama de aprendizaje automático cuando aprende



Nota: Adaptado de (Géron, 2019), p.8

2.2.4.1 Tipos de algoritmos del aprendizaje automático

En el aprendizaje automático se observan los tipos de algoritmos de aprendizaje: supervisado, no supervisado, sistemas semi supervisados y de refuerzo (Wei-Meng, 2019). Los algoritmos de aprendizaje automático se dividen principalmente en dos categorías amplias:

2.2.4.1.1 Aprendizaje supervisado

El algoritmo de aprendizaje supervisado es la rama más compleja y compleja del aprendizaje automático y se utilizan en casi todos los campos, incluida la inteligencia artificial, la computación cognitiva y el procesamiento del lenguaje. La máquina aprende a reconocer la salida y esto es impulsado por tareas que pueden ser de clasificación o regresión (Mishra, 2019).

Se construye un modelo matemático debido al entrenamiento que está representado por una matriz o vector, a veces llamado vector de características, y los datos de entrenamiento se representan por una matriz del conjunto de datos etiquetados, y sin etiquetar, que contienen ambas entradas y salidas requeridas. Se tiene las variables dependientes (la variable que está tratando de predecir) e independientes (usado para predecir la variable dependiente). Sin embargo, en algunos casos solo tenemos variables independientes (Deisenroth et al., 2020).

Están entrenados con datos etiquetados. Se entiende que, los datos incluyen ejemplos de la respuesta deseada y ello se obtienen en el aprendizaje automático supervisado (Wei-Meng, 2019).

2.2.4.1.2 Aprendizaje no supervisado

El aprendizaje no supervisado es una rama del aprendizaje automático que no tiene una columna de destino o la salida no está definida. Solo necesitamos descubrir los patrones o grupos únicos útiles de los datos posibles sin etiquetas, ya que el objetivo es encontrar alguna relación al predecir un patrón en el conjunto de datos y mostrarlo en un gráfico (Wei-Meng, 2019).

El concepto básico del algoritmo no supervisado es aplicado de la siguiente manera:

- Primero los codificamos a mano en Excel.
- Implementamos en R.
- Implementamos en Python.

En el aprendizaje no supervisado, solo mostramos los datos de entrada al dispositivo y le pedimos al dispositivo que agrupe las entradas según la correlación, la similitud o la diferencias, etc. El aprendizaje supervisado se centra en la presentación de obras (Ayyadevara, 2018).

El proceso de “aprendizaje” es debido a que los algoritmos automatizados que tienen la función “aprende”, a cómo recopilar patrones a partir de datos; por lo tanto, se tendrá al nuevo conjunto de datos y el aprendizaje se produce al tomar un conjunto de características de entrada que se retroalimenta con los valores del codificador automático (Alpaydin, 2022).

Se describen muchas técnicas de aprendizaje no supervisadas del mundo real, y donde se aplicarían los algoritmos básicos y las ventajas que ofrecen. La tarea principal del aprendizaje no supervisado es el análisis de bloques o conglomerados. La entrada de bloques en cada uno de los cuales se describe mediante un vector de valores de atributos, pero sin ninguna etiqueta del tipo de clase. El resultado es un conjunto de dos o más bloques (Kubat & Kubat, 2021).

2.2.5 Búsqueda de características

La extracción de las características desde las series temporales con señales sin procesar no se puede usar directamente con métodos tradicionales como es el SVR, XGboost, Árboles de decisión, etc. Por lo tanto, es necesario convertir las series temporales en características numéricas que puedan procesarse sin perder la información de los datos sin procesar (Géron, 2019)

Se debe realizar con más precisión, la elección de un tamaño óptimo tanto de la serie temporal sin procesar como de la preprocesada, donde se eligen los puntos cruciales que se efectuará la extracción y la distribución con el dominio de tiempo. El tiempo de la señal puede efectuarse de corto o larga duración, son adecuados con respecto al tamaño impreciso donde se encontrarán los mejores resultados, se pueden encontrar diversas fórmulas para extraer características de las series temporales en el dominio del tiempo (Nixon & Aguado, 2019).

En las series temporales se pueden obtener una gran cantidad de características. Los usos de todas las características obtenidas nos garantizan una buena predicción. Por lo tanto, es necesario encontrar las características más importantes. Esta es la parte más laboriosa del proceso de predicción y se necesita un conocimiento profundo del área de estudio. Las series temporales tienen información del corte de un lugar o momento en específico durante el proceso de análisis más exacto, logrando que las características extraídas sean obtenidas como resultados de los siguientes procesos: *máximum*, *mínimum*, *peak-to-peak (ptp)*, *median*, *skewness*, *kurtosis*, *standard_deviation*, *abs_energy*, *absolute energy* y muchos más (Nixon & Aguado, 2019).

En la mayoría de los equipos monitoreados se pueden encontrar series temporales como datos de medición, así como los casos en las mediciones de aceleración. Se aplicará el procedimiento para la extracción de información en las series temporales debido a los métodos de aprendizaje automático que utilizan las señales completas como los datos de entrada. Es por eso la importancia de extraer las características más representativas de las series temporales (Duboue, 2020).

Existen métodos automatizados que permiten encontrar las características más importantes. Para la presente tesis se utilizarán: ingeniería de características hacia adelante e ingeniería de características hacia atrás.

2.2.5.1 Extracción de características de las series temporales

El software para la extracción de características de series temporales sobre la base de pruebas de hipótesis escalables (tsfresh) es un paquete perteneciente a Python que se utiliza para calcular características de las series temporales de una forma automática y con ello se obtienen las funciones de datos, tiempo y frecuencia disponibles; también toda la lista de características se puede leer en esta aplicación (Christ et al., 2018).

En condiciones clásicas se utilizan tres diccionarios como son predefinidos para ser usados inmediatamente:

- `tsfresh.feature_extraction.settings.ComprehensiveFCParameters`:
Contiene todas las características sin y con parámetros.
- `tsfresh.feature_extraction.settings.EfficientFCParameters`:
Contiene unas pocas características para un testeo rápido.
- `tsfresh.feature_extraction.settings.MinimalFCParameters`:
Similar a `ComprehensiveFCParameters` pero sin las características que son computacionalmente demandantes.

2.2.5.2 Selección de características

A veces, cuando ajustan los modelos para lograr probar la precisión predicha, descubren que está con demasiados predictores (variables de las características). Puede aprovechar su conocimiento del dominio, para reducir los predictores hasta que solo tenga aquellos que le ofrezcan con su modelo una precisión superior y esta técnica debería ir acompañada de nuestra estrategia de validación. Pero si no tiene conocimiento del dominio, existen algunas técnicas automatizadas diseñadas para atacar el problema: Ingeniería de características hacia adelante y hacia atrás (Duboue, 2020).

2.2.5.2.1 Ingeniería de características hacia adelante

Se implementó la ingeniería de características hacia adelante, donde la característica se evalúa individualmente cada 1 de todas las características por separado, y se selecciona la que proporciona los mejores resultados de predicción. Se evalúan todas las combinaciones posibles de la característica seleccionadas por los atributos de relevancia para el objetivo o etiqueta a trabajar en conjunto con el modelado de regresión, donde los atributos deben ser numéricos o binomios en la etiqueta. Luego, se selecciona el de mejores predicciones. Así, sucesivamente, se añadieron más funciones hasta que no se obtiene ninguna mejora al anterior (Duboue, 2020).

Una vez que una variable es añadida al conjunto, es nunca quitado en iteraciones posteriores, incluso si su influencia en el objetivo disminuye conjuntos de datos con un gran número de aportes en las variables donde el rasgo de la selección es requerido (Kotu & Deshpande, 2018).

2.2.5.2.2 Ingeniería de características hacia atrás

Comienza con un modelo de regresión múltiple de alta calidad que incluya la menor cantidad de características posible de un conjunto de todas las variables independientes y elimina una por una en función al resultado de lo que se predijo, ya que ello conduce la mayor mejora, pero dejará de eliminar variables cuando el modelo sin afectar la capacidad predicha se deteriora o permanece estable. Para realizar una ingeniería de características hacia atrás regresivas del proceso de aprendizaje (entrenamiento y prueba) se pueden especificar varios parámetros para habilitar la función de selección donde ahora está incluido en el factor de cancelación inversa, donde se puede usar con frecuencia dos funciones de R de forma iterativa (Drop1 y Update), para ejecutar una serie de pruebas y actualizar todas las entradas del factor de rendimiento se seleccionan en la ventana de activación de la prueba de la validación dividida donde todas las operaciones y conexiones son necesarios para construir el modelo de regresión modificado, donde drop1 elige la variable de exclusión del modelo que tenga el efecto menos significativo en la reducción del ajuste. Se han eliminado propiedades con una caída del 5% al 10% que es probablemente demasiado agresiva. Esto confirma que el análisis de regresión hacia atrás funciona bien, incluso cuando se incluyeron menos variables (Kotu & Deshpande, 2018).

2.2.6 Preprocesamiento de los datos

El preprocesamiento de datos es una tarea esencial del aprendizaje automático realizada por científicos, la ciencia de datos y proyectos de análisis de datos en general, donde este método para transformar datos sin procesar en una forma más formateada, ya que sin ello no se pueden utilizar. Dado que los datos recopilados no tienen formato o son formatos brutos, entonces puede que no sea posible entrenar el modelo con ellos. El procesamiento cuidadoso de estos datos sin procesar es importante para interpretarlos correctamente y, en última instancia, evitar resultado negativo en la predicción. En otras palabras, la calidad de un algoritmo de aprendizaje automático depende exclusivamente del tipo de conjunto de datos con el que se alimenta el modelo. Por lo tanto, el preprocesamiento de datos se utiliza para mantener esta calidad. Es decir, pueden ser ruidosos, como valores faltantes e información relevante, números en forma de cadena y no estructurados. El preprocesamiento de datos mejora la eficiencia y la precisión de los modelos de aprendizaje automático. Filtrar ese ruido y se logra la ayuda al comprender el conjunto de datos, los seis pasos diferentes (Importación de bibliotecas, importar la base de datos, verificación de valores faltantes, verificación de datos categóricos, escalado de características y división de datos en conjuntos de capacitación, validación y evaluación) los cuales son necesarios para realizar el preprocesamiento de datos en el aprendizaje automático (*6 pasos para el preprocesamiento de datos*, s. f.).

1. Importación de bibliotecas

Las bibliotecas más importantes en Python son:

- a) Numpy: La biblioteca utilizada principalmente para implementar o utilizar cálculos matemáticos complejos para el aprendizaje automático. Es conveniente realizar operaciones en arreglos de matrices multidimensionales.
- b) Pandas: La biblioteca de código abierto que proporciona estructuras de datos y herramientas de análisis de datos para que sea fácil de usar en Python. Está diseñado porque trabaja con datos etiquetados para que sea fácil e intuitivo.
- c) Matplotlib: Biblioteca de visualización proporcionada por Python para gráficos 2D o matriciales. Se basa en matrices numpy y está diseñado para funcionar con la pila más amplia de Scipy. La visualización de conjuntos de datos es útil en escenarios donde hay gran cantidad de datos disponibles. Los gráficos disponibles en matplotlib son lineales, barras, diagramas de dispersión, histogramas, etc.

- d) Seaborn: La biblioteca de visualización proporcionada por Python que entrega una interfaz de alto nivel para dibujar gráficos estadísticos atractivos e informativos.

2. Importar datos

Una vez que se importa la biblioteca, el siguiente paso es cargar los datos recopilados. La biblioteca Panda se utiliza para importar los conjuntos de datos. La mayoría de estos están disponibles en formato CSV para un procesamiento más rápido. Se carga un archivo csv usando la función `read_csv` de la biblioteca panda. Otros formatos de conjuntos de datos que se pueden mostrar debemos examinarlo y buscar ruido. Para hacer esto, necesitamos crear una matriz de características X y un vector de observación Y con respecto a X .

3. Verificación de valores faltantes

Después de crear la matriz de funciones, puede notar que faltan algunos valores. El no hacerlo puede resultar en problemas durante el entrenamiento. Hay dos formas de gestionar los valores perdidos.

- a) Elimina filas enteras que contienen valores faltantes, pero puede faltar información importante. Este es el método preferido para grandes conjuntos de datos.
- b) Si una columna numérica contiene valores faltantes, puede estimar los valores utilizando la media, la mediana, la moda, etc.

4. Verificación de datos categóricos

Los datos deben estar en formato numérico para poder realizar los cálculos. Los modelos de aprendizaje automático implican cálculos matemáticos complejos y no se les pueden dar valores no numéricos. Por lo tanto, es importante convertir todos los valores de texto en números. La clase de entrenamiento del aprendizaje automático `LabelEncoder()` se usa para convertir estos valores categóricos en valores numéricos.

5. Escalado de características

Los valores de los datos sin procesar pueden ser extremadamente diferentes, lo que lleva a un entrenamiento sesgado del modelo o a una mayor complejidad en el costo computacional, para ello es importante normalizarlos. El escalado de características es una técnica utilizada para ajustar valores de datos a un rango más corto. Los métodos utilizados para escalar las características son:

- a) Reescalado (normalización min - max)
- b) Normalización media
- c) Estandarización (normalización de puntuación Z)
- d) Escalando a la longitud de la unidad

6. División de datos en conjuntos de capacitación, validación y evaluación

Finalmente, necesitamos separar los datos en tres conjuntos diferentes. Un conjunto de entrenamiento para entrenar el modelo, un conjunto de validación para validar la precisión del modelo y, finalmente, un conjunto de prueba para probar el rendimiento del modelo utilizando datos genéricos. Previo a la división del conjunto de datos, es importante mezclar el conjunto de datos para evitar sesgos. La proporción ideal para dividir el conjunto de datos es 60:20:20. Es decir, un 60% como conjunto de entrenamiento y un 20% como conjunto de prueba y validación. Para dividir el conjunto de datos, use `train_test_split` y dos veces `sklearn.model_selection`. Divida el conjunto de datos en conjuntos de entrenamiento y validación.

2.2.7 Modelos de Regresión

La regresión es un algoritmo utilizado para estimar la relación de entradas y salidas del sistema en muestras o datos de entrenamiento utilizables. La salida debe coincidir con el valor real (Bi et al., 2004).

En la regresión lineal simple, hablamos de la relación lineal entre una variable independiente y una variable dependiente, la regresión lineal simple, también se define del siguiente modo (Géron, 2019):

- **Regresión Múltiple**

La relación lineal entre dos o más variables independiente y una variable dependiente.

- **Regresión polinomial**

Modelado de la relación entre la variable dependiente e independiente utilizando un polinomio de cualquier tipo de grado en función.

- **Regresión múltiple**

El modelado polinomial de la relación entre dos o más variables independientes y una dependiente usando una n-ésima función polinomial de cualquier grado.

La principal ventaja del modelo de regresión es que la relación entre la variable de respuesta y las covariables no es una función determinista, que muestra el error. Esto significa que la respuesta es una variable aleatoria, cuya distribución depende de las variables explicativas que son covariables o independientes. Está claro que después de establecer el modelo lineal con respecto a las predicciones de variables, también es fácil comprender los parámetros de estos modelos de regresión, donde se pueden probar modelos de regresión. La variable de respuesta (dependiente) y se obtiene la lista o vector de predictores (Alpaydin, 2022).

2.2.7.1 Regresión de Vectores de Soporte

La regresión de vectores de soporte (SVR) es un algoritmo de regresión basado en el mismo algoritmo utilizado por Support Vector Machines (SVM) para crear modelos de clasificación. Se determina la relación de la regresión lineal como no lineal entre las variables explicativas que dependen del tipo de investigación y una variable objetivo, esto produciría una regresión con alta precisión predicha de los datos. (Kaneko, 2021).

Se caracteriza por el uso de los kernels (base lineal, polinomial, sigmoidea y radial) y el número de vectores de soporte, como enfoque del aprendizaje supervisado, SVR se entrena usando una función de pérdida simétrica, que iguala las desestimaciones altas y bajas para los datos de entrada que se estandarizaron antes del entrenamiento (Awad & Khanna, 2015).

a) Parámetros del Kernel RBF

Luego del entrenamiento con el kernel de función de base radial (RBF), se deben considerar dos parámetros: C y gamma (Raschka & Mirjalili, 2019).

b) El parámetro C

Es comúnmente igual a todos los núcleos de SVR, compensa la clasificación errónea de los ejemplos de entrenamiento frente a la simplicidad de la superficie de decisión. Un nivel bajo C suaviza la superficie de decisión, mientras que un nivel alto C apunta a clasificar correctamente todos los datos que se entrenan previamente (Cournapeau, 2022).

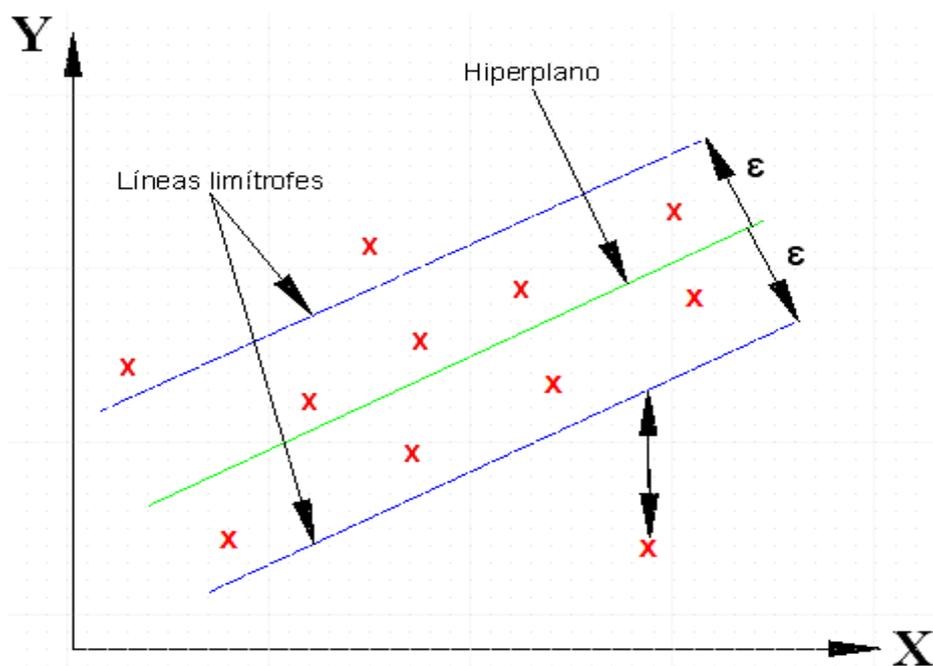
c) El parámetro gamma

Se define cuánta influencia tiene el entrenamiento en el proceso. Cuanto más grande sea el parámetro gamma es, más cerca deberán estar los datos para verse afectados y obtener un mejor resultado (Cournapeau, 2022).

La elección adecuada de C y γ es fundamental para el rendimiento de la SVR. Se recomienda usar `trial.suggest_categorical` con C , ϵ y γ espaciado exponencialmente para elegir buenos valores. La regresión lineal intenta minimizar la función de error (normalmente el error cuadrático) en todos los puntos del conjunto de entrenamiento, mientras que SVR define una zona alrededor del hiperplano donde los valores se ignoran. Los vectores de soporte construyen 1 o más hiperplanos en un espacio de infinita o alta dimensión, que se puede usar para la clasificación, regresión u otras tareas. Intuitivamente, usar el hiperplano con la distancia más larga al punto de datos de entrenamiento más cercano (el margen funcional) para cualquier clase logra una buena separación se debe a que, en general, cuanto mayor es el margen, menor es el error del clasificador. Esto significa que SVR intenta aproximarse al mejor valor dentro de los límites especificados por ϵ , como se muestra en la Figura 12 que muestra la función de decisión para un problema linealmente separable con 3 muestras en los límites marginales llamados "vectores de soporte" (Cournapeau, 2022).

Figura 12

Funcionamiento básico del SVR



Fuente: (Cournapeau, 2022).

En general, si el problema no es linealmente separable, los vectores de soporte son las muestras dentro de los límites del margen.

2.2.8 Optimización de Hiperparámetros

La optimización de Hiperparámetros se realiza a través del uso de un código abierto (Optuna) que es usado mediante un método de optimización bayesiano con la estructura al realizar una búsqueda automática en el espacio de los hiperparámetros con algoritmo de muestreo y el rendimiento de un modelo de aprendizaje automático. Los parámetros optimizados del modelo SVR (C, ϵ , gamma y kernel) con rangos específicos que dependen del tipo de investigación lograrán producir la distancia de error cuadrático medio mínimo “RMSE” (Akiba et al., 2019).

2.2.8.1 Métodos de optimización de Hiperparámetros

La optimización de hiperparámetros se utiliza para encontrar un conjunto de valores de los hiperparámetros, y así permitir que el algoritmo de aprendizaje alcance la mejor predicción. Los métodos más populares para la búsqueda de hiperparámetros son: búsqueda manual, búsqueda aleatoria, búsqueda de cuadrícula y optimización bayesiana (Agrawal, 2021).

2.2.9 Herramientas para el uso de aprendizaje automático

A continuación, se muestran dos formas de lectura y aplicación del aprendizaje automático donde tendremos un mayor detalle de los datos con los cuales trataremos en este trabajo de investigación. Donde ambas herramientas leen el lenguaje de programación que es relativamente simple de codificar y manipular, que en particular es sencillo de entender, es gratis y tiene muchas bibliotecas relacionadas a la ciencia de datos. Así mismo, existen otros tipos de herramientas o softwares en la industria como las que se mencionan a continuación.

2.2.9.1 Python

Python es uno de los lenguajes de programación más populares para resolver los problemas en la ciencia de datos, es necesario contar con herramientas que faciliten procesos como recolección, limpieza de datos, exploración de datos, modelado de datos y visualización de datos y, gracias a su código abierto con su comunidad de desarrolladores, se han desarrollado una gran cantidad de bibliotecas científicas de computación y aprendizaje automático de última generación. El aprendizaje automático (ML) es una aplicación de Python. Es tanto una guía como una referencia para el desarrollo de los sistemas de ML. En su página principal tiene explicaciones detalladas, visualizaciones y ejemplos de código, de los principios y técnicas fundamentales de ML (Raschka & Mirjalili, 2019).

2.2.9.2 Google Colaboratory

Google Colaboratory (Colab) es un servicio gratuito que combina las funciones de Jupyter Notebooks con máquinas virtuales alojadas en Google y hardware de alta gama. Colab fue diseñado para que los investigadores de inteligencia artificial y ciencia de datos compartan experimentos reproducibles y descripciones técnicas, pero también se ven las aplicaciones que se adaptan mejor a los datos del mundo real. El principal beneficio es proporcionar recursos informativos a estudiantes o investigadores recursos computacionales suficientes para ejecutar las últimas técnicas de IA de forma interactiva, la ejecución de cuadernos compartidos con código público elimina la necesidad de que los estudiantes configuren dependencias y paquetes de software separados (Nelson & Hoover, 2020).

A medida que la investigación de IA prolifera a través de formatos de codificación, en parte debido a su reproducibilidad, la experiencia con este flujo de trabajo puede preparar a los investigadores para futuras carreras en la industria o en la preparación profesional (Nelson & Hoover, 2020).

2.2.10 Costo computacional

El término "coste computacional" se refiere al costo o gasto en términos de recursos y tiempo que se requiere para llevar a cabo una operación o realizar cálculos utilizando una computadora o un sistema computacional en la informática. Generalmente, el costo computacional se relaciona con la cantidad de tiempo del CPU, memoria, ancho de banda de red y otros recursos que son empleados para completar una tarea específica. El coste computacional normalmente se refiere al tiempo de cálculo (Orozco, 2020). Un claro ejemplo sobre la medición de tiempo en un algoritmo se ve reflejado en la Figura 13.

En la figura 13 se determina el costo computacional (determinación del tiempo de ejecución) de un código que tiene un "for" con un rango de 0 a 999 donde se realiza la suma de cada elemento elevado a la potencia 100. Para calcular el tiempo del código de Python se usó el módulo time. Con dicho modulo se estableció un tiempo de inicio y fin, y al obtener la diferencia de estos valores se puede determinar el tiempo de ejecución del código. Dado que la unidad de tiempo del módulo time es en segundos (s), el resultado se convierte a milisegundo (ms) por que se trabajó con un código de cálculo rápido.

Figura 13

Código para medir el tiempo de inicio y finalización.

```
# Import time module
import time

# record start time
start = time.time()

# define a sample code segment
a = 0
for i in range(1000):
    a += (i**100)

# record end time
end = time.time()

# print the difference between start
# and end time in milli. secs
print("The time of execution of above program is :",
      (end-start) * 10**3, "ms")
```

Output:

```
The time of execution of above program is :
0.77056884765625 ms
```

Fuente: (geeks, 2021)

CAPÍTULO III

III. METODOLOGÍA

En este capítulo se aborda a detalle la metodología de la investigación que actualmente se emplea en la finalidad del cumplimiento de los objetivos específicos presentados con anterioridad, teniendo en cuenta primero la descripción de la metodológica, la implementación de la investigación y los resultados obtenidos; y se verá el proceso de trabajo con el modelo SVR del aprendizaje automático para la estimación de la predicción del desgaste de la cuchilla en una fresadora CNC.

3.1 Descripción de la metodología

La metodología propuesta a desarrollar en la presente tesis tendrá un diseño no experimental de tipo cuantitativo. En los estudios no experimentales no se manipulan las variables, ya que su propósito es observar fenómenos que ocurren en condiciones naturales para poder realizar el análisis correspondiente a lo que desee lograr. Se implementará el uso de “Python” como software de trabajo para la investigación, siendo de acceso libre y cuenta con la biblioteca scikit-learn (Cournapeau, 2022) para el análisis de datos.

Para la ejecución de los códigos escritos en Python se usará Google Colaboratory.

3.1.1 Enfoque de investigación

Para este estudio se va a utilizar la base de datos del PHM 2010 (Li et al., 2009) que cuenta con las señales de fuerza, aceleración y emisión acústica, y también proporciona las mediciones del desgaste de 3 cuchillas, denominadas como c1, c4 y c6 por la misma base de datos. Las series temporales de las fuerzas y aceleraciones son procesadas mediante métodos cuantitativos para la predicción del desgaste. Dichas predicciones se comparan con los datos del desgaste de la base de datos.

3.1.2 Alcance de investigación

Se buscará mejorar la predicción del desgaste de la herramienta de corte hasta obtener valores del error cuadrático medio (RMSE) menores a 10, empleando algoritmos de aprendizaje automático (SVR). Dado el gran número de características disponibles de los datos experimentales, para este estudio se buscará cumplir con lo antes mencionado y la menor cantidad de características para las 3 cuchillas (c1, c4 y c6).

3.2 Implementación de la investigación

Todas las etapas del proceso de investigación que se implementaron en esta investigación se muestran a continuación.

3.2.1 Diagrama de flujo

La descripción de la metodología para el desarrollo se muestra en la Figura 14 donde se observan todas las etapas a realizarse.

Figura 14

Flujograma del proyecto de investigación



Fuente: Elaboración Propia.

Al inicio, se realiza la exploración de la base de datos experimentales que fueron obtenidos de una fresadora CNC de alta velocidad (Li et al., 2009), y son de acceso público desde la página del desafío de datos de la conferencia de la Sociedad PHM 2010 (PHM society, 2010) en la cual se tiene el estudio de 3 cuchillas diferentes denominadas c1, c4 y c6. Estos datos experimentales se almacenan en una carpeta de Google Drive para el fácil acceso desde el Google Colaboratory.

Los datos que son guardados previamente en el Google Drive son leídos. Luego se juntan los datos de 2 cuchillas que son emplearlos en el entrenamiento y los datos de la tercera cuchilla restante de las 3 cuchillas, se emplea para la validación. Por ejemplo, los datos de c1 y c4 se juntarán y usarán en el entrenamiento, y los datos de c6 se usarán para la validación. Se extraen las características de los datos del entrenamiento y validación.

Para el preprocesamiento se usa el escalador “MinMaxScaler” que restringe los valores numéricos de las características en un rango de 0 a 1.

El método conocido como ingeniería de características hacia adelante se implementa de forma independiente para c1, c4 y c6. En este método se realiza la predicción del desgaste para cada una de las características y luego se selecciona la característica que genera la mejor predicción del desgaste. Después, a la característica seleccionada se le agrega otra característica y se obtiene la predicción del desgaste. Al par de características que resulte en la mejor predicción se le agrega otra característica y se obtiene la predicción del desgaste. Se le seguirán agregando características hasta que la predicción del desgaste no mejore o empeore, de esta forma se obtiene una lista de características.

Posteriormente, se emplea un algoritmo de aprendizaje automático conocido como SVR y se utiliza la optimización de hiperparámetros empleando optuna.

El desgaste que es obtenido por medio del algoritmo de aprendizaje automático es comparado con los datos experimentales del desgaste (Base de datos) utilizando la métrica RMSE. La característica o características que resulta en un RMSE menor a 10 son guardados en una lista del siguiente bloque, pero si no se cumple se pasa a la siguiente característica o características regresando al inicio de la ingeniería de características hacia adelante.

Las listas de características para cada cuchilla se eligen las características cuyo valor de RMSE sea menor y las características que son comunes en las 3 listas de las cuchillas. De esta manera, se forma una nueva lista completa de características que son utilizadas en los siguientes pasos.

Se volverán a realizar los procesos desde los datos de entrenamiento hasta el preprocesamiento

El método conocido como ingeniería de características hacia atrás se utiliza con la lista anterior para las 3 cuchillas (c1, c4 y c6). En este método al contrario de la primera etapa, se procede a retirar 1 a 1 las características de la lista seleccionada y en cada eliminación se obtiene el valor del RMSE para el grupo de características restantes con cada cuchilla. Después, se selecciona el grupo de características con un RMSE menor a todos los mayores que se pueda presentar en cada cuchilla. A la lista de características que resulte en la mejor predicción se le retira otra característica y se obtiene la predicción del desgaste. Se siguen retirando las características hasta que la predicción del desgaste no mejore o empeore, de esta forma se obtendrá la mejor lista de características.

Teniendo un grupo de características con sus hiperparámetros se ejecutarán los procesos iniciales como el entrenamiento, validación y la optimización de hiperparámetros.

Se emplea nuevamente la métrica RMSE para comparar el desgaste de la cuchilla obtenido por medio del algoritmo de aprendizaje automático y el desgaste de la base de datos. Un grupo de características se usa en c1, c4 y c6 para obtener sus RMSE en cada uno de ellos y se repetirá para todos los grupos de características diferentes. Luego de obtener los mayores en cada grupo de características diferentes, se elegirá el menor de todos ellos. El grupo de características elegido se guardará en una lista y se pasará al siguiente bloque. Si el valor de RMSE para las 3 cuchillas (c1, c4 y c6) en cada grupo de características es mayor a 10, se tendrá que comenzar nuevamente la ingeniería de características hacia atrás, quitando una característica para los siguientes grupos de características.

Con lo realizado previamente se obtiene una lista de varios grupos de características con un RMSE menor a 10 para las 3 cuchillas.

Posteriormente, se selecciona el mejor grupo de características para la predicción del desgaste en las 3 cuchillas. Se elegirá no necesariamente el menor RMSE de toda la lista, sino al que tenga uniformizados los mayores RMSE en la lista. Adicionalmente, a lo anterior, se elegirá el RMSE con la cantidad mínima de características y teniendo en cuenta que no debe variar mucho respecto al mínimo RMSE de la lista. Dicho grupo con un número pequeño de características nos permite predecir el desgaste de cualquier cuchilla con un bajo costo computacional.

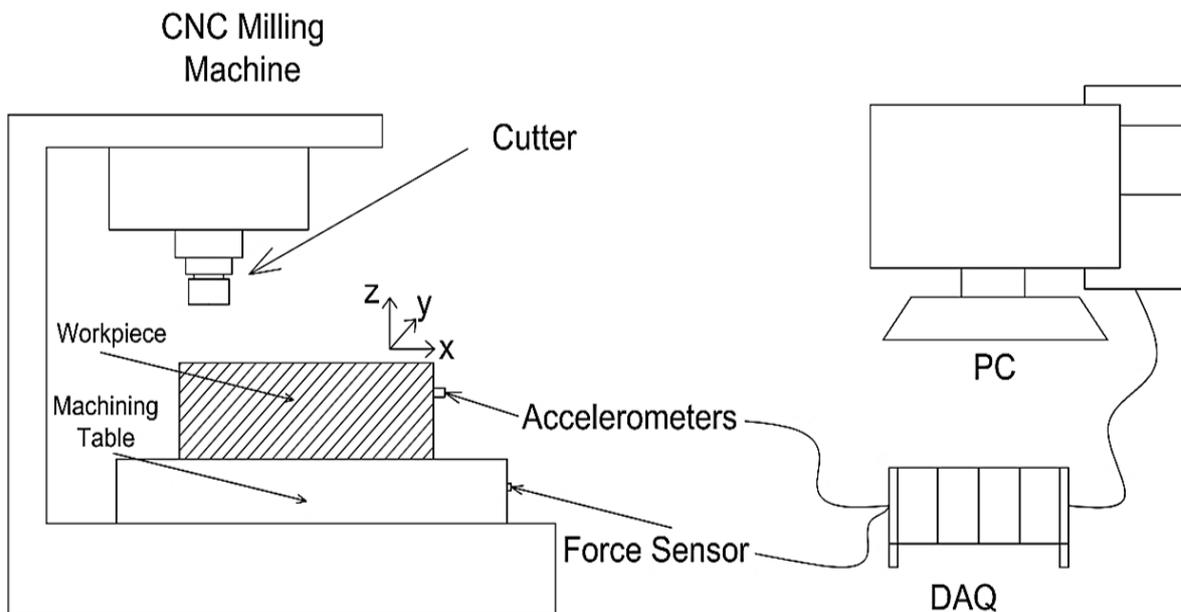
La matriz de consistencia (Anexo 3) muestra los problemas, objetivos y la metodología del trabajo de investigación.

3.2.2 Base de datos utilizado

En el presente trabajo se utiliza la base de datos provenientes de los datos experimentales fueron obtenidos de una fresadora CNC (Li et al., 2009). Los datos de señales que entregan los sensores (Acelerómetro, dinamómetro o sensor de fuerza y Emisión acústica) donde fueron adquiridos por una tarjeta de adquisición de datos (DAQ), como se muestra en la Figura 15. Toda la información es demasiado amplia, por lo que se almacenan en archivos que se elige a “The National Instruments LabVIEW 8.2” donde es usado para que los usuarios puedan observar los cambios de las señales a través de las pantallas gráficas continuas de toda la operación de fresado y observar el registro de anomalías o fallas inminentes.

Figura 15

Supervisión en el proceso de fresado en alta velocidad

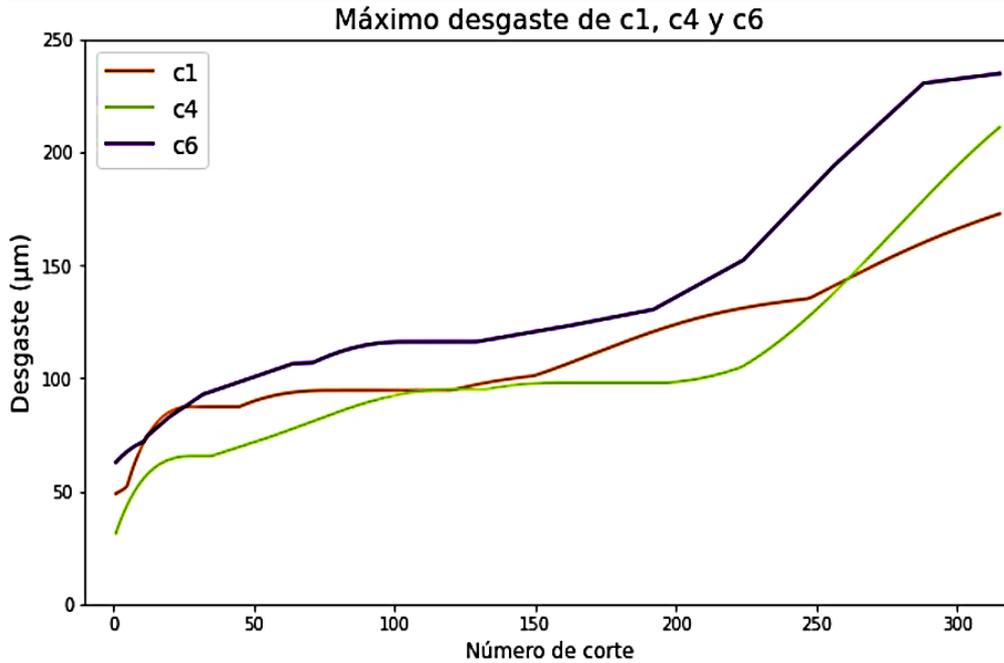


Fuente: (Zegarra et al., 2022)

Cada una de las herramientas de corte (c1, c4 y c6) utilizadas en el experimento que tiene 3 filos. El desgaste en cada uno de sus flancos se midió utilizando un sistema de microscopía LEICA MZ12. Para el desgaste de cada herramienta de corte se considera el desgaste máximo de sus 3 filos como es mostrado en la Figura 16. Cabe destacar que los valores máximos del desgaste de las cuchillas se registraron en micras (μm), siendo para c1, c4 y c6 el valor de 170 μm , 217 μm y 235 μm respectivamente.

Figura 16

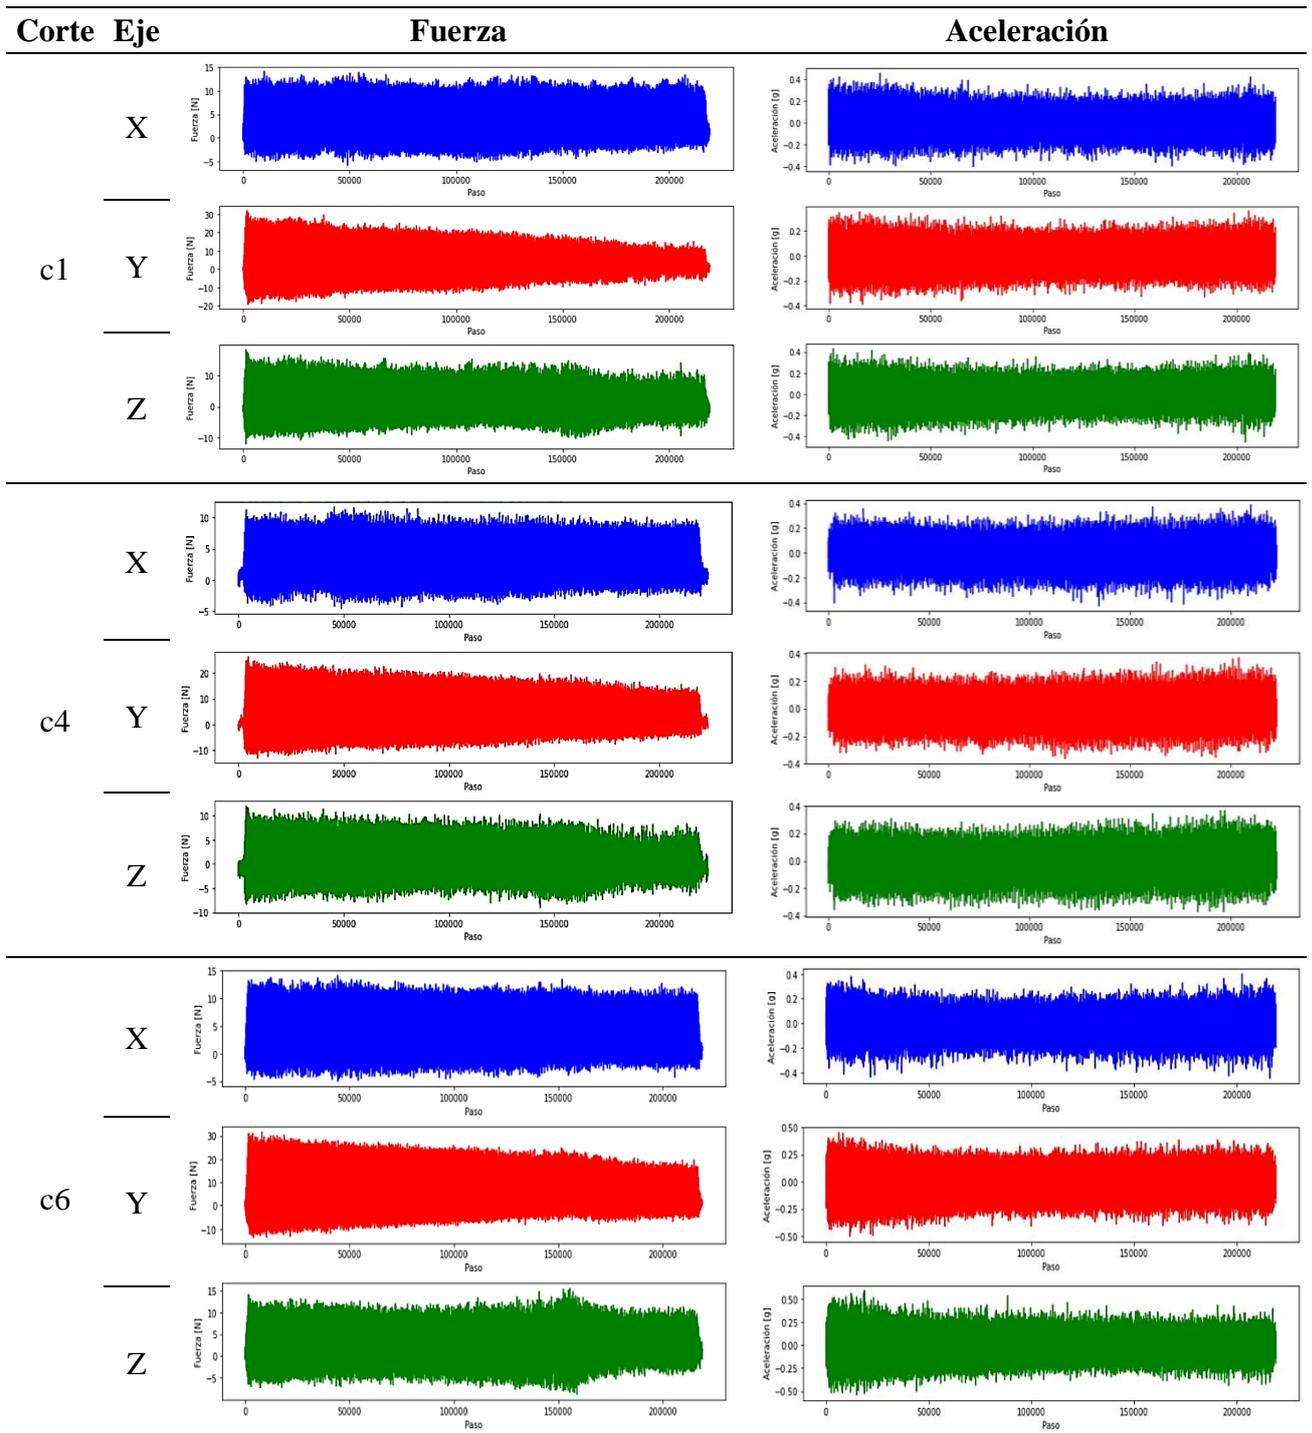
Máximo desgaste de c1, c4 y c6



El conjunto de datos es de acceso público realizado en alta velocidad para ser exactos con una frecuencia de muestreo acumulada de 96,000 Hz. Además, los datos registrados corresponden a señales de fuerzas (N) y aceleraciones (g) en las direcciones respectivas de X, Y y Z, donde principalmente se realizó el estudio para las 3 cuchillas con diferentes denominaciones c1, c4 y c6 como se observa en la Tabla 3 que emplean los sensores externos donde son presentados desde la página del desafío de datos en la conferencia de la Sociedad PHM 2010 (PHM society, 2010) conteniendo distinta información sobre los cortes y sus mediciones.

Tabla 3

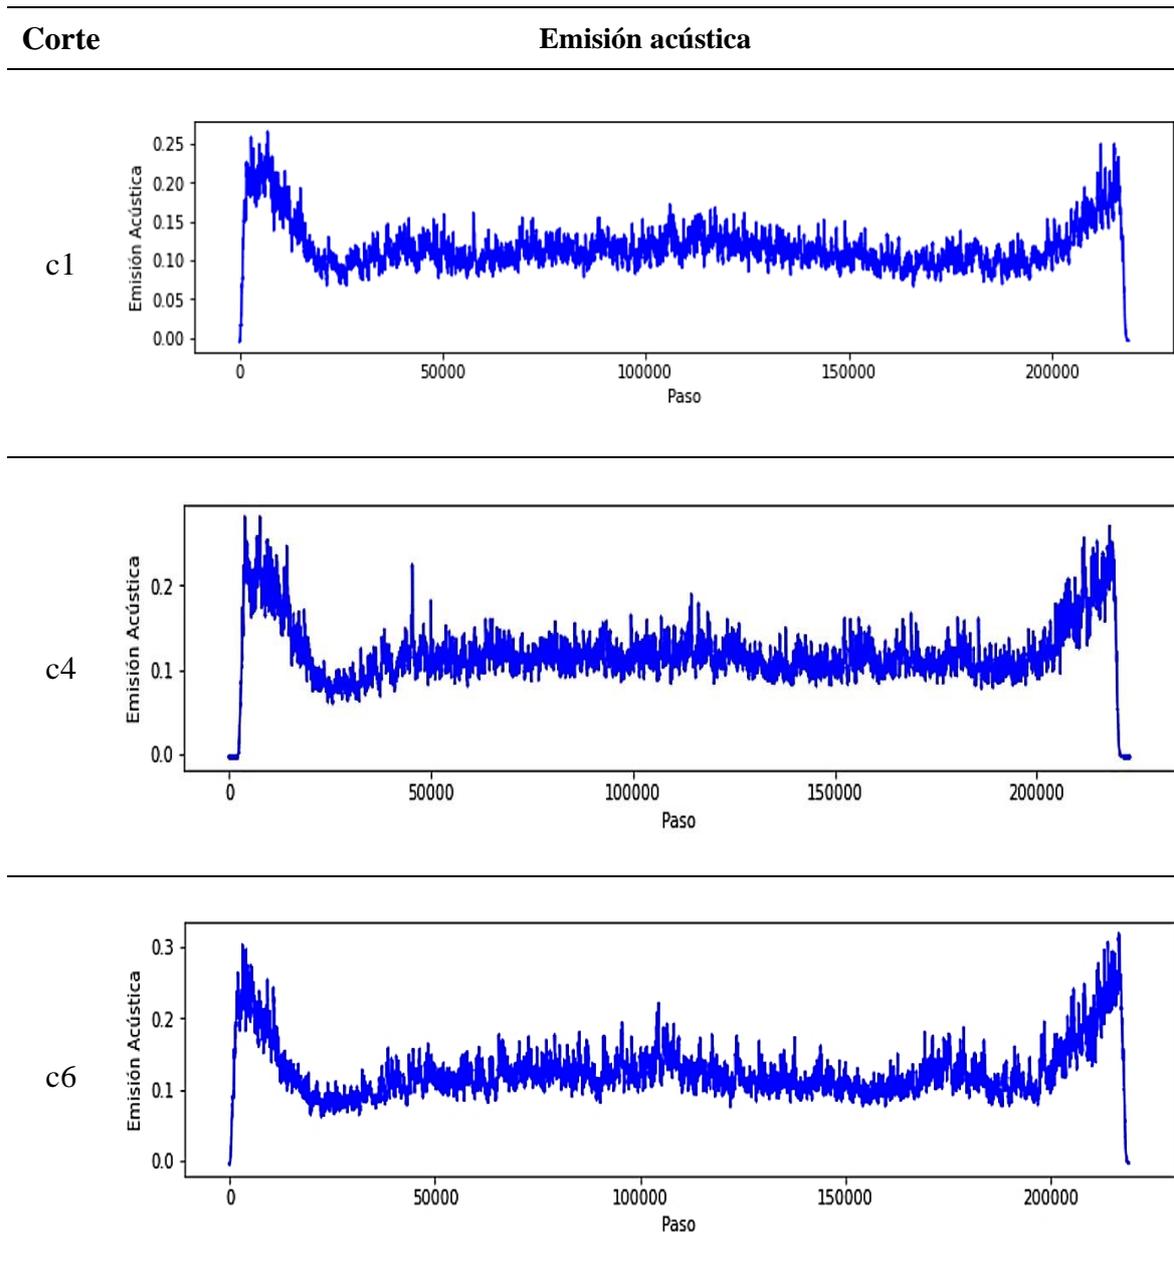
Señales de fuerza y aceleración de cada eje y cuchilla de corte 10



Los datos registrados correspondientes a la emisión acústica (AE), donde se obtuvo de la experimentación para las 3 cuchillas con diferentes denominaciones c1, c4 y c6 como se observa en la Tabla 4 que emplearon los sensores externos donde son presentados desde la página del desafío de datos en la conferencia de la Sociedad PHM 2010 (PHM society, 2010).

Tabla 4

Señales de la Emisión Acústica para cada cuchilla en el corte 10



Los equipos en general de las metalmecánicas son monitoreados por un personal capacitado. Siendo uno de los equipos en particular la fresadora CNC, este equipo es empleado en un estudio experimental previo del desgaste de sus cuchillas el cual utiliza la presente investigación. En la mayoría de los monitoreos se observan las mediciones de fuerzas y aceleraciones en forma de series temporales.

3.2.3 Implementación de un modelo de Aprendizaje automático

Al inicio se realizará la exploración de la base de datos que se utiliza en el presente trabajo. Los datos experimentales fueron obtenidos de una fresadora CNC a alta velocidad (Li et al., 2009), y son de acceso público desde la página del desafío de datos de la conferencia de la Sociedad PHM 2010 (PHM society, 2010). Los datos contienen 7 mediciones que comprenden las fuerzas (N) y aceleración (g) en las direcciones respectivas de X, Y y Z para las 3 cuchillas con diferentes denominaciones c1, c4 y c6. Estos datos experimentales se almacenaron en una carpeta de Google Drive para su fácil acceso desde el Google Colaboratory.

Los datos que fueron guardados previamente en el Google Drive donde fueron leídos. Se realizó una limpieza de datos para utilizar de toda la base de datos, logrando solo utilizar el corte 295 por su mejor resultado, ya que se puede elegir cualquier corte de los 315 en total que se tiene. Posteriormente se eliminó la tendencia de una serie temporal (detrend) siendo un cambio en la mediana a lo largo del tiempo que oscila alrededor de la rotación de la línea de tendencia a una posición horizontal (reducción o aumento constante a lo largo de la serie temporal), porque se procedió a limpiar los extremos de las series temporales, logrando un determinado tamaño para su uso (Muhammad, 2022).

El proceso de extracción de características es fundamental para tareas de regresión o clasificación aplicadas en Python. En este sentido, se utilizó el método de pruebas de hipótesis escalables (tsfresh) para calcular un gran número de características de las series temporales que van desde el buen estado de la fresadora hasta que ocurre alguna falla. Este proceso se llevó a cabo de forma automática y permitió obtener toda la lista de características necesarias. Entre las características ofrecidas por tsfresh, se encuentran aquellas basadas en transformadas de Fourier, entre las cuales destaca la Transformada Rápida de Fourier (FFT, por sus siglas en inglés). Esta técnica de procesamiento de señales permite descomponer una señal en sus componentes de frecuencia y, por tanto, obtener información relevante para la detección de posibles fallas en la fresadora.

En resumen, el uso de tsfresh permitió la extracción automática de un gran número de características relevantes para el análisis de las series temporales de la fresadora, incluyendo aquellas basadas en transformadas de Fourier como la FFT, lo que facilita la identificación de posibles fallas y la toma de decisiones oportunas para prevenir averías mayores.

Al implementar un modelo de aprendizaje automático para predecir el desgaste de las cuchillas a partir de características extraídas de las series temporales de amplitud de la vibración. Se incluyen medidas como el valor medio, la desviación estándar, el valor máximo y mínimo, entre otras. En particular, la media y la desviación estándar son medidas importantes que pueden indicar si la cuchilla está experimentando un desgaste de la cuchilla anormal. Otras características importantes incluyen el número de puntos de inflexión, el número de cruces por cero y la amplitud pico-pico de la serie temporal. Además de estas características, también se incluyeron otras como el coeficiente de autocorrelación de la serie temporal, la entropía de aproximación, la energía de la señal y el número de cruces por cero. Estas características proporcionan información valiosa sobre la naturaleza de la serie temporal y pueden ayudar a mejorar la precisión de las predicciones del modelo de aprendizaje automático. Todas estas características se calculan utilizando la biblioteca `tsfresh` en Python, lo que permite una extracción automatizada y eficiente de las características.

Durante el proceso de selección de características para el modelo de aprendizaje automático, se utilizó la lista de características presentada en la Tabla 5. Es importante destacar que estas características fueron escogidas cuidadosamente, con el objetivo de asegurar su relevancia para la predicción del desgaste de la cuchilla. La lista de la Tabla 5 incluye medidas básicas de la serie temporal, como el número de datos en la serie (n) y la desviación estándar de los valores de amplitud (σ), valores de amplitud en la distribución (z), así como características más complejas como el valor de amplitud en la i -ésima observación (z_i), la media aritmética de los valores de amplitud en la distribución (\bar{z}) y el coeficiente de wavelet en el i -ésimo nivel de descomposición (C_i). Cada una de estas características proporciona información única que puede ser utilizada para predecir el desgaste de la cuchilla con mayor precisión.

Tabla 5*lista de características extraídas*

Nombre de característica	Descripción	Ecuaciones
Abs_energy	Devuelve la energía absoluta de la serie temporal que es la suma de los valores al cuadrado de todas las amplitudes de la señal.	$E = \sum_{i=1} z_i^2$
fft_aggregated__agg type_"kurtosis"	Se utiliza para calcular la kurtosis de los valores de amplitud de la transformada de Fourier Discreta de una serie de tiempo.	$K = \frac{\sum(z_i - \bar{z})^4}{n\sigma^4}$
fft_aggregated__agg type_"skew"	Se utiliza para calcular el skewness de la asimetría de los valores de amplitud de la Transformada de Fourier Discreta de una serie de tiempo.	$Skew = \frac{\sum(z_i - \bar{z})^3}{n\sigma^3}$
Kurtosis	Devuelve la kurtosis (calculada con el coeficiente de momento estandarizado de Fisher-Pearson ajustado G2).	$z_{kurt} = E \left[\left(\frac{Z - \mu}{\sigma} \right)^4 \right]$
Maximum	Calcula el valor más alto de la serie temporal z.	$z_{max} = \max(z)$
Minimum	Calcula el valor más bajo de la serie temporal z.	$z_{min} = \min(z)$
Skewness	Devuelve la asimetría de la muestra de z (calculada con el coeficiente de momento estandarizado de Fisher-Pearson ajustado G1).	$z_{skew} = E \left[\left(\frac{Z - \mu}{\sigma} \right)^3 \right]$
Variance	Devuelve la varianza de z.	$z_{var} = \frac{1}{n} \sum_{i=1}^n (z_i - \bar{z})^2$
Peak-to-peak (PtP)	Es el cálculo de la diferencia entre el valor máximo con el valor mínimo de la porción de serie temporal.	$z_{p-p} = \max(z) - \min(z)$
Wavelet Energy (WE)	El cálculo de Wavelet Energy emplea la Transformación para las señales de entrada y logra clasificar los árboles de paquete wavelet.	$E_{WT} = \sum_{i=1} [C_i^2]$

La relación entre el desgaste y la característica nos permite saber si la característica es buena o no para el modelo de predicción. Una manera simple de visualizar la relación entre las dos variables es con la ayuda de un gráfico de dispersión donde en cada gráfico se compara la relación entre dos conjuntos de datos. A la relación antes mencionada entre los dos conjuntos de datos se conoce como "coeficiente de correlación" o simplemente "correlación". Los dos conjuntos de datos tienen 2 posibilidades donde pueden estar muy relacionados en la cual la correlación es alta y si no están muy relacionados la correlación entonces tendría el valor de cero.

La correlación puede ser clasificada de dos formas diferentes, positivas si los valores de un conjunto aumentan cuando aumentan los valores del otro conjunto y si es negativa si los valores de un conjunto disminuyen cuando aumentan los valores del otro conjunto. La correlación varía entre los valores de -1 y 1.

En pruebas iniciales se ha observado que la predicción mejora cuando el valor del desgaste del primer corte es igual a cero. Por lo que a partir de ahora a cada herramienta de corte se le resta el valor del desgaste del primer corte.

Luego, se extraerán las características de los datos para el entrenamiento y validación. Se juntaron los datos de 2 cuchillas de manera ordenada para emplearlos en el entrenamiento y los datos de la tercera cuchilla se emplearon para la validación. Por ejemplo, los datos de c1 y c4 se juntaron y usaron en el entrenamiento y los datos de c6 se usarán para la validación, tal cual se deja notar en el caso 1 de la Tabla 6 que es mostrada a continuación.

Tabla 6

Agrupamiento de datos para el entrenamiento y la validación

Cuchilla	Caso 1	Caso 2	Caso 3
c1	Entrenamiento	Entrenamiento	Validación
c4	Entrenamiento	Validación	Entrenamiento
c6	Validación	Entrenamiento	Entrenamiento

Se muestra el código para la aplicación de la Tabla 5 a continuación:

```

#Función para combinar las tres bases (c1, c4, c6).
#Para luego dividir en entrenamiento y validación.
#Esta función tiene como entrada el tipo de base que será la
validación.
def Datos_train_test(cx):
    if cx == 'c1':
        # c4 + c6 - > c1
        datos_train = datos_c4.append(datos_c6)
        datos_test = datos_c1

    if cx == 'c4':
        # c1 + c6 - > c4
        datos_train = datos_c1.append(datos_c6)
        datos_test = datos_c4

    if cx == 'c6':
        # c1 + c4 - > c6
        datos_train = datos_c1.append(datos_c4)
        datos_test = datos_c6
    return datos_train,datos_test

```

Se aplicó el escalador “MinMaxScaler” a las características que restringirá sus valores numéricos en un rango de 0 a 1.

```

# Definiendo datos de entrenamiento y validación
X_train_ = datos_train.copy()
y_train = X_train_.pop('Max_VB')

X_test_ = datos_test.copy()
y_test = X_test_.pop('Max_VB')

# Preprocesamiento
# Extrae nombres de las columnas
nombres_X = X_train_.columns.tolist()

# Escalador
scalerX = preprocessing.MinMaxScaler()
scalerX = scalerX.fit(X_train_)

X_train_s = scalerX.transform(X_train_)
X_test_s = scalerX.transform(X_test_)

X_train_s = pd.DataFrame(X_train_s, columns=nombres_X)
X_test_s = pd.DataFrame(X_test_s, columns=nombres_X)

```

Se aplicó el algoritmo de regresión de vectores de soporte (SVR) que crea modelos de regresión para una alta precisión en la predicción al utilizar los datos. Se prueba los diferentes tipos de kernel (RBF, LINEAR y SIGMOID) y el rango de valores en los casos de C, épsilon (ϵ) y gamma (γ). La regresión lineal intenta minimizar la función de error (normalmente el error cuadrático medio) en todos los puntos del conjunto de entrenamiento, mientras que SVR define una zona alrededor del hiperplano donde parámetros y valores son tomados en cuenta para el análisis correspondiente.

Las métricas de error absoluto medio (MAE), error cuadrático medio (RMSE) y R-cuadrado (R^2) son empleados para una evaluación del modelo en un análisis de regresión.

a) Error absoluto medio (MAE)

El error absoluto medio representa el promedio de la diferencia absoluta entre los valores reales y valores predichos en el conjunto de datos (si el MAE es 10 entonces hay una diferencia de 10 valores entre los valores reales y predichos en promedio). El modelo de regresión que mejor predicción se deberá a cuanto menor sea el MAE y se tendrá una predicción óptima. La relación del rendimiento dependerá exclusivamente de la base de datos. Este tipo de error es escrito matemáticamente de la siguiente manera:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}|$$

donde:

N = Números totales de observación

y_i = Valor real para la i -ésima observación

\hat{y} = Valor predicho para la i -ésima observación

b) Error cuadrático medio (RMSE)

El RMSE es el valor de error obtenido es donde se usa la raíz del error para tener la misma unidad que la variable de resultado y lograr la fácil interpretación donde la métrica es informativa de qué tan cerca están los valores predichos de la línea de regresión. Cuando la aproximación esté en el punto de la regresión, menores serán los valores de las métricas y entonces mayor será la precisión del modelo de regresión. Por lo tanto, como el mismo principio o concepto anterior, cuanto menor es el RMSE, mejor es la predicción del modelo. Las métricas de RMSE son útiles para ver si los valores atípicos interfieren con las predicciones del modelo y es RMSE la más utilizada en el análisis de regresión de todos los errores de estudios previos.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2}$$

donde:

N = Números totales de observación

y_i = Valor real para la i -ésima observación

\hat{y} = Valor predicho para la i -ésima observación

c) R-cuadrado (R^2)

Es la determinación del coeficiente que presenta lo bien que se ajusta el modelo de las variables dependientes. Se interpreta R^2 como la proporción de la información de los datos que es explicada por el modelo, donde los valores predichos que son obtenidos deben estar entre el margen de 0 a 1. Luego, son interpretados como porcentajes al describirse en la gráfica final en el eje y (variable dependiente), y se describe por la variación del eje x (predicción). Se requiere que el resultado del R^2 sea mayor, ya que mejor se ajusta el modelo en la presente investigación. Tomar en cuenta que R^2 es la medida de correlación y no de precisión, y también depende de la variación en el resultado. Necesitamos tener en cuenta las otras métricas, como RMSE, MAE, etc. Para lograr verificar si tiene sentido un R^2 más alto como parte del estudio.

$$R^2 = 1 - \frac{\sum(y_i - \hat{y})^2}{\sum(y_i - \bar{y})^2}$$

donde:

N = Números totales de observación

y_i = Valor real para la i -ésima observación

\hat{y} = Valor predicho para la i -ésima observación

Si el tipo de modelo es 100% perfecto, los valores de las métricas serán iguales a cero o aproximados a este valor.

3.2.4 Selección de la cantidad óptima de características

En primer lugar, se realiza una lista de características a partir de los datos recopilados previamente. Luego, se procede a seleccionar las características o combinaciones de ellas que tengan el menor error cuadrático medio (RMSE) posible, mediante un proceso manual. A este proceso se le conoce como ingeniería de características hacia adelante, la cual se ha implementado de forma independiente para $c1$, $c4$ y $c6$. En este método se realizó la predicción del desgaste para cada una de las características y luego se seleccionó la característica que generará la mejor predicción del desgaste, la cual es almacenada en la lista “feat_selec = []”. Después, de seleccionar a la característica se agregó otra característica donde se tuvieron 2 características juntas y se obtuvo la predicción del desgaste. Al par de características que resultó en la mejor predicción se le agregó otra característica y se obtiene la predicción del desgaste. Se siguieron agregando características hasta que la predicción del desgaste no mejoró o empeoró, de esta forma se obtiene una lista de características.

Para la predicción del desgaste que se menciona en el anterior párrafo se empleó un algoritmo de aprendizaje automático (SVR) que fue utilizado anteriormente (ver ítem 3.2.3) y se complementa al utilizar la optimización de hiperparámetros empleando optuna (método de optimización bayesiana) donde se exploran diferentes valores de los parámetros y así encontrar sus valores óptimos. Se realiza una comparación gráfica para seleccionar la característica o lista de características con el menor RMSE.

```
# Lista de características seleccionadas
# En el caso que se inicie dejar como: feat_selec=[ ]
feat_selec=[]

lista_features_ffe=genera_list_feat(lista,feat_selec)
lista_features_ffe[:5]

df_rmse = pd.DataFrame()
df_parm = pd.DataFrame()
dict_study = {}

optuna.logging.disable_default_handler()
counter = 1

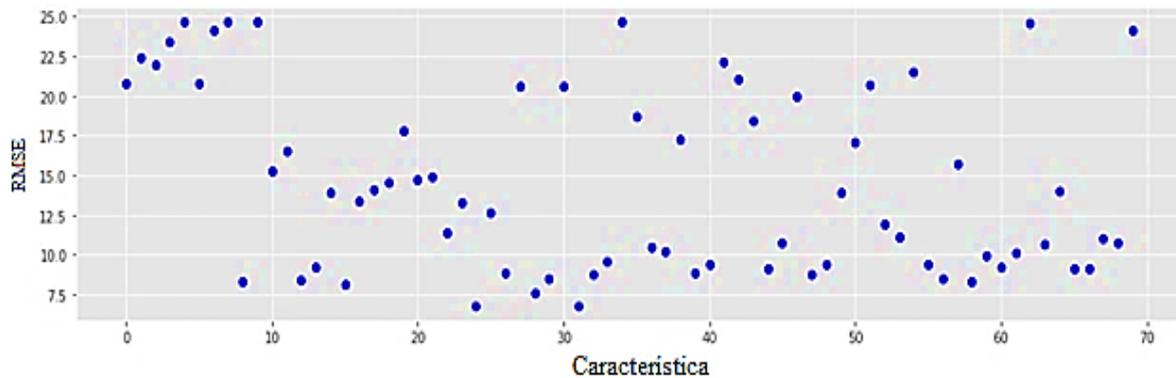
for i in lista_features_ffe:
    print("<<< " + str(counter) + " " + str(i) + " >>>")
    X_train, X_test = X_train_s[i], X_test_s[i]
    study = optuna.create_study(direction='minimize', sampler=TPESampler(multivariate=True))
    study.optimize(objective_svr, n_trials=300)
    df_rmse = df_rmse.append({'feature': str(i), 'RMSE': study.best_value}, ignore_index=True)
    df_parm = df_parm.append(study.best_params, ignore_index=True)
    dict_study[str(i)] = study.trials_dataframe()
    counter = counter + 1

# Comparación gráfica entre los RMSE de una lista de características
plt.figure(figsize=(16,4))
plt.plot(df_rmse.RMSE, 'bo')
plt.xlabel('Característica')
plt.ylabel('RMSE')
```

La comparación gráfica entre los RMSE de las listas de características previamente estudiadas se utilizó para identificar cuál es el menor RMSE de todas las listas creadas. Un ejemplo de esta comparación gráfica se muestra en la Figura 17.

Figura 17

Comparación gráfica de RMSE entre los elementos de cada lista de características



Durante el entrenamiento y validación se graficaron las curvas del desgaste real y el desgaste predicho. Dicha comparación permite entender de manera gráfica los valores de RMSE.

```
# Entrenamiento
plt.figure(figsize=(10,6))
X = np.arange(0, len(X_train_fs), step=1)
plt.plot(X,y_train,'bo')
plt.plot(y_pred_train,'ro')
plt.legend(['Medido','Pred'], loc='upper right')
plt.xlabel("Número de corte")
plt.ylabel("Desgaste (µm)")

R2, RMSE, MAE = métricas (y_train, y_pred_train)

print('**Entrenamiento**')
print('R2 = ', R2)
print('RMSE = ', RMSE)
print('MAE = ', MAE)

# Validación
plt.figure(figsize=(10,6))
plt.plot(y_test,'bo')
plt.plot(y_pred_test,'ro')
plt.legend(['Medido','Pred'], loc='upper right')
plt.xlabel("Número de corte")
plt.ylabel("Desgaste (µm)")

R2, RMSE, MAE = métricas (y_test, y_pred_test)

print('**Validación**')
print('R2 = ', R2)
print('RMSE = ', RMSE)
print('MAE = ', MAE)
```

3.2.5 Predicción del desgaste con reducción del costo computacional

De las listas de características que fueron previamente observadas (ver ítem 3.2.4) para cada una de las cuchillas para un mejor resultado en los datos del desgaste donde se eligieron las 15 características cuyo valor de RMSE es el menor y las características que fueron comunes en las 3 listas de cada cuchilla. De esta manera se formó un grupo de 15 características que será utilizada para las 3 cuchillas. Se volvieron a realizar los procesos (ver ítems 3.2.3 y 3.2.4) que corresponden a las selecciones de los datos para el entrenamiento y la validación. Los nuevos datos obtenidos del entrenamiento y la validación han sido escalados nuevamente con el proceso del “MinMaxScaler”.

El método conocido como ingeniería de características hacia atrás se utilizó con la lista obtenida anteriormente para las 3 cuchillas (c1, c4 y c6). En este método al contrario de ingeniería de características hacia adelante, porque se procederá a retirar 1 a 1 las características de la lista seleccionada y en cada eliminación se obtendrá el mejor valor del RMSE para los 15 grupos de características obtenidas serán utilizados en cada una de las 3 cuchillas. Después, se seleccionó el grupo de características con un RMSE menor al compararlos a todos los resultados de RMSE mayores que se puedan presentar en cualquiera de las 3 cuchillas. A la lista de características que resulte en la mejor predicción se le quitará otra característica y se obtendrá la predicción del desgaste. Se seguirán retirando las características repitiéndose el proceso anterior hasta que la predicción del desgaste no mejore o empeore de todas las restantes, de esta forma se obtendrá al final la selección de la mejor lista de características.

```
# Lista de características seleccionadas
# En el caso que se inicie dejar como: feat_selec=[ ]
feat_selec=['Vy_fft_aggregated_aggtype_kurtosis']

# Lista_features_ffe=genera_list_feat(lista,feat_selec)
# Lista_features_ffe[:5]
df_rmse = pd.DataFrame()
df_parm = pd.DataFrame()
dict_study = {}
optuna.logging.disable_default_handler()
counter = 1
i=feat_selec
print("<<< " + str(i) + " >>>")
X_train, X_test = X_train_s[i], X_test_s[i]
study = optuna.create_study(direction='minimize', sampler=TPESampler(multivariate=True))
study.optimize(objective_svr, n_trials=300)
df_rmse = df_rmse.append({'feature': str(i), 'RMSE': study.best_value}, ignore_index=True)
df_parm = df_parm.append(study.best_params, ignore_index=True)
dict_study[str(i)] = study.trials_dataframe()
counter = counter + 1
```

3.2.6 Verificación final del desgaste con mínimo error de predicción

Con lo realizado anteriormente que previamente se tuvo una lista de varios grupos de características con un margen en el RMSE menor a 10 para las 3 cuchillas.

Posteriormente, se seleccionó el mejor grupo de características para la predicción del desgaste en las 3 cuchillas. Se eligió no necesariamente el menor RMSE de toda la lista, sino el que tenga un nivel bajo en los mayores RMSE en la lista. Adicionalmente, a lo anterior, se eligió el RMSE con la cantidad mínima de características y teniendo en cuenta que no debe variar mucho respecto al mínimo RMSE de la lista. Dicho grupo con un número pequeño de características nos permitirá predecir el desgaste de cualquier cuchilla con un bajo costo computacional. Se tienen todos los resultados de las 15 listas que son colocados en un solo cuadro para su comparación y determinar en la elección para cada 1 de las 15 listas del valor máximo con respecto al RMSE de c1, c4 y c6.

Todos los valores de RMSE calculados anteriormente se seleccionan las listas cuyos resultados máximos sean menores a 10. El mayor número de listas que cumplan con esta condición, garantizaron la efectividad del modelo de aprendizaje automático, que posteriormente fueron guardados en tablas y gráficos para ser analizados constantemente los resultados. Al final, se obtuvieron las tablas y gráficos con todos los cálculos detallados de todo el proceso donde se busca la lista con el menor número de características y cuyo menor valor máximo de RMSE tenga una pequeña variación con respecto a las otras listas seleccionadas. Luego se procede a llevar a cabo la comparación del costo computacional asociadas a la lista de características previamente seleccionadas a través del proceso con el algoritmo de aprendizaje automático. En estas listas, se elegirán las características de manera cuidadosa, y se comparan con un conjunto de 60 características que han sido seleccionadas a partir de un estudio inicial de diez, tal como se detalla en la tabla 27, pero esas 10 características son aplicadas a las señales de fuerza y aceleración.

```

# Módulo de tiempo de importación
import time

# Hora de inicio de registro
start = time.time()

df_rmse = pd.DataFrame()
df_parm = pd.DataFrame()
dict_study = {}
optuna.logging.disable_default_handler()

counter = 1
i=feat_selec
print("<<<  " + str(i) + "  >>>")
X_train, X_test = X_train_s[i], X_test_s[i]
study = optuna.create_study(direction='minimize',
sampler=TPESampler(multivariate=True))
study.optimize(objective_svr, n_trials=300)

df_rmse = df_rmse.append({'feature': str(i), 'RMSE':
study.best_value}, ignore_index=True)
df_parm = df_parm.append(study.best_params, ignore_index=True)

dict_study[str(i)] = study.trials_dataframe()
counter = counter + 1

# Hora de finalización de registro
end = time.time()

print("The time of execution of above program is :",
      (end-start) , "s")

```

3.3 Resultados

En esta sección del presente capítulo, se presentan los resultados obtenidos siguiendo la metodología establecida para cada uno de los objetivos planteados anteriormente. Al implementar el aprendizaje automático, se logró obtener una efectiva en la predicción del desgaste de la cuchilla en la obtención de los resultados finales (entrenamiento y validación) que fueron sometidos a diferentes escenarios donde se ha buscado el mejor resultado posible, donde se obtuvo la mayor tasa de predicción que son presentados en la presente investigación de la base de datos para poder llegar de manera eficiente la cercanía posible entre el desgaste medido y desgaste predicho.

Las métricas utilizadas muestran un RMSE de 0, lo que indica una alta precisión y cercanía al valor original a medida que se incrementa la precisión en la predicción.

3.3.1 Se construyó un modelo de aprendizaje automático

Después de haber llevado a cabo la extracción de características de la base de datos, se obtiene una lista completa que incluye todas las características identificadas. Es importante destacar que cada una de estas características ha sido previamente evaluada y seleccionada por su relevancia en el proceso de predicción del desgaste de la herramienta de corte. De esta manera, es importante destacar que cada característica de esta lista es fundamental para el desarrollo del modelo y la obtención de resultados precisos y confiables en este ámbito.

La lista completa de características se presenta en la Tabla 7, la cual es el resultado de un análisis exhaustivo y minucioso de las características de la base de datos. Cada una de las características ha sido evaluada cuidadosamente y seleccionada por su relevancia en el proceso de predicción del desgaste de la herramienta de corte. Es importante tener en cuenta que estas características son vitales para la obtención de resultados precisos y confiables en la predicción del desgaste de la herramienta de corte se muestra a continuación:

Tabla 7

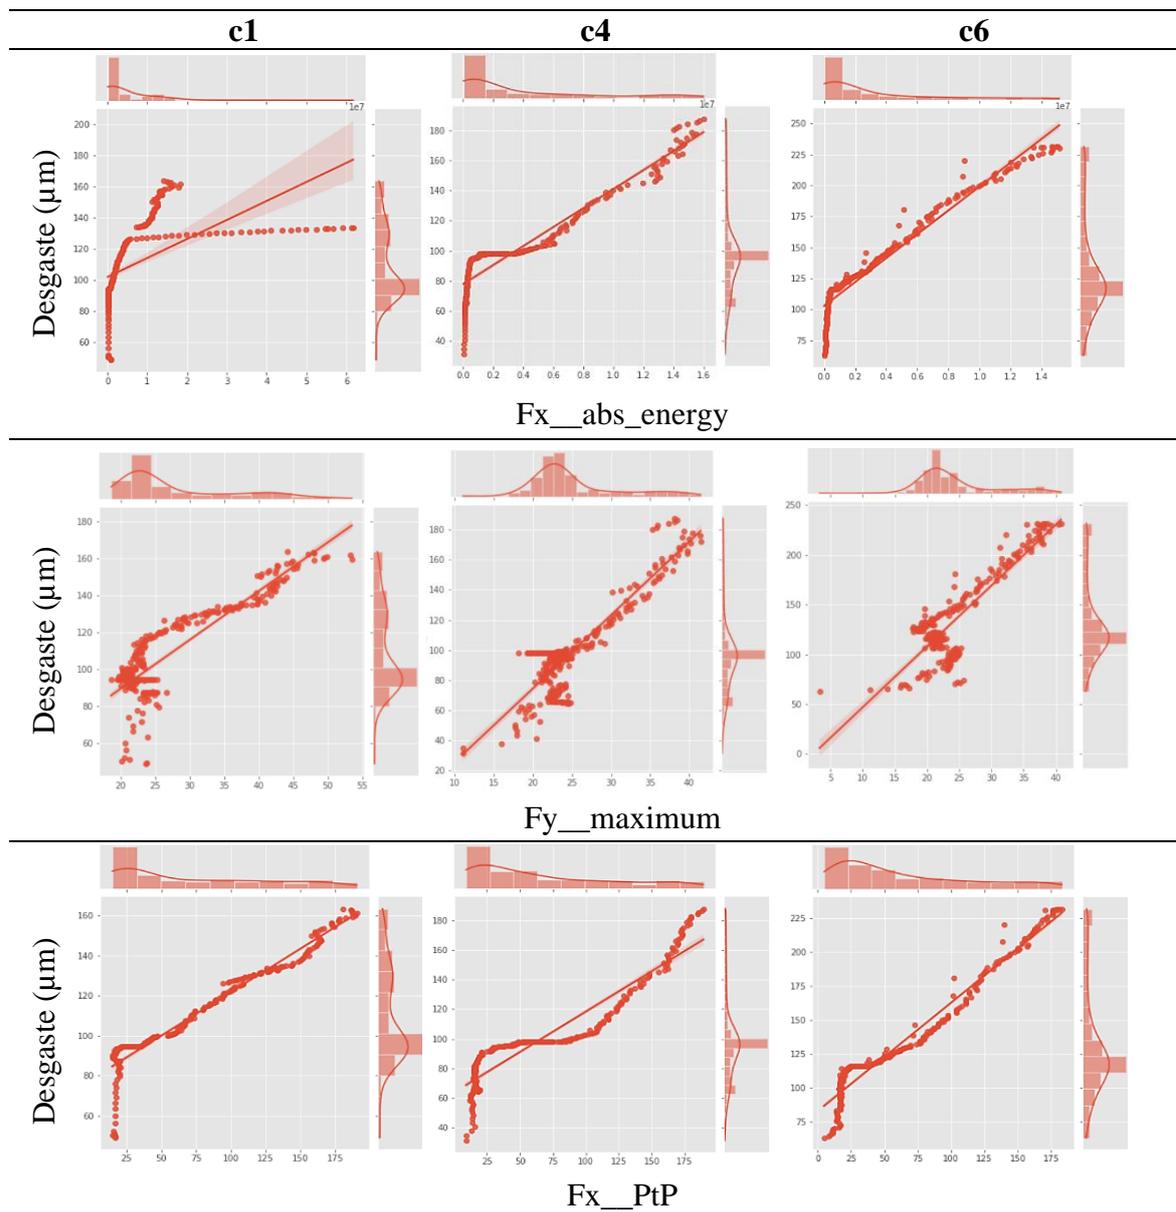
Total de las características.

Características\Señal	Fx	Fy	Fz	Vx	Vy	Vz
abs_energy	Fx__abs_energy	Fy__abs_energy	Fz__abs_energy	Vx__abs_energy	Vy__abs_energy	Vz__abs_energy
fft_aggregated_agg type_"kurtosis"	Fx__fft_aggregated_ _aggtype_"kurtosis"	Fy__fft_aggregated_ _aggtype_"kurtosis"	Fz__fft_aggregated_ _aggtype_"kurtosis"	Vx__fft_aggregated_ aggtype_"kurtosis"	Vy__fft_aggregated_ aggtype_"kurtosis"	Vz__fft_aggregated_ _aggtype_"kurtosis"
fft_aggregated_agg type_"skew"	Fx__fft_aggregated_ _aggtype_"skew"	Fy__fft_aggregated_ _aggtype_"skew"	Fz__fft_aggregated_ _aggtype_"skew"	Vx__fft_aggregated_ aggtype_"skew"	Vy__fft_aggregated_ aggtype_"skew"	Vz__fft_aggregated_ _aggtype_"skew"
kurtosis	Fx__kurtosis	Fy__kurtosis	Fz__kurtosis	Vx__kurtosis	Vy__kurtosis	Vz__kurtosis
maximum	Fx__maximum	Fy__maximum	Fz__maximum	Vx__maximum	Vy__maximum	Vz__maximum
minimum	Fx__minimum	Fy__minimum	Fz__minimum	Vx__minimum	Vy__minimum	Vz__minimum
skewness	Fx__skewness	Fy__skewness	Fz__skewness	Vx__skewness	Vy__skewness	Vz__skewness
variance	Fx__variance	Fy__variance	Fz__variance	Vx__variance	Vy__variance	Vz__variance
PtP	Fx_PtP	Fy_PtP	Fz_PtP	Vx_PtP	Vy_PtP	Vz_PtP
WE	Fx_WE	Fy_WE	Fz_WE	Vx_WE	Vy_WE	Vz_WE

Al extraer los datos de la información en las series temporales, ya que los métodos de aprendizaje automático no utilizan todas las señales como datos de entrada. Se utilizan una o un conjunto de series temporales para extraer las características, que a su vez se puede obtener: máximo, mínimo, pico a pico, kurtosis, energía absoluta, etc. Por lo tanto, es importante separar las características de la serie temporal como se muestran en las siguientes figuras con respecto al desgaste en cada una de las 3 cuchillas en la Tabla 8, con algunas características donde se puede observar una diferencia entre las cuchillas más resaltantes en la aproximación o cercanía a la recta que podría ser diferente o lejana en alguna otra cuchilla.

Tabla 8

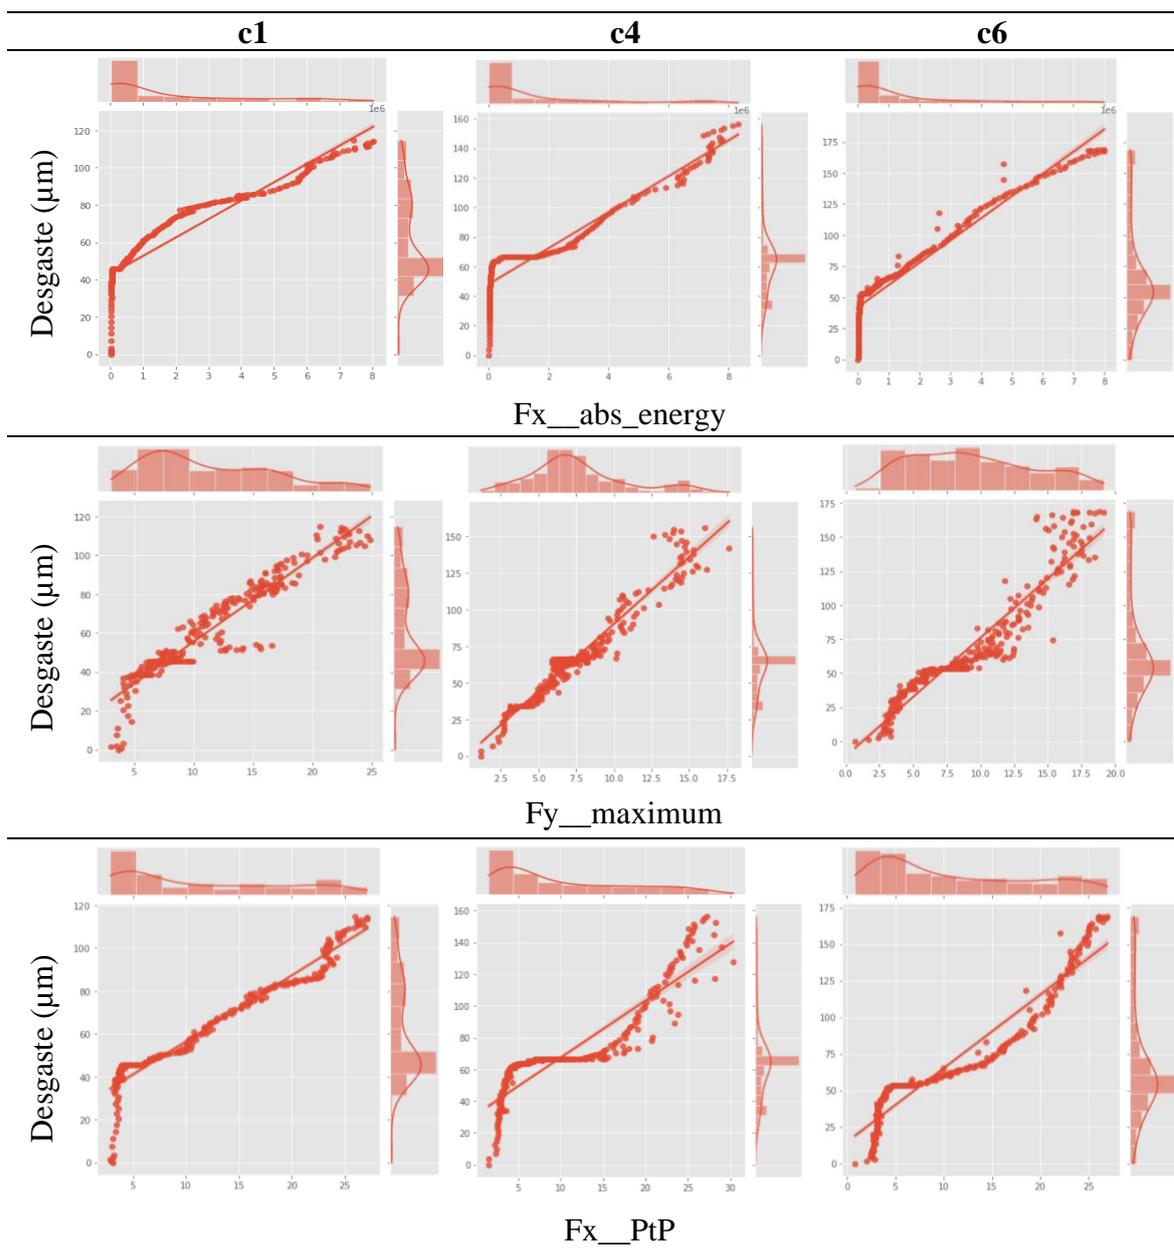
Imágenes de algunas características sin detrend



Con el uso del detrend mostrado en la Tabla 9, en algunos casos se observa una corrección de la desviación de los datos respecto a la línea de regresión como es el caso de la característica “Fx__abs_energy” para c1 y en cambio para c4 y c6 no hay un cambio significativo. Para la característica “Fy__maximum”, detrend ayuda a que los datos se aproximen a la línea de regresión para las 3 cuchillas. Para la característica “Fx__PtP”, detrend hace que los datos se alejan ligeramente de la línea de regresión para las 3 cuchillas. Detrend se ha aplicado a los datos usados en todos los análisis que se muestran de aquí en adelante.

Tabla 9

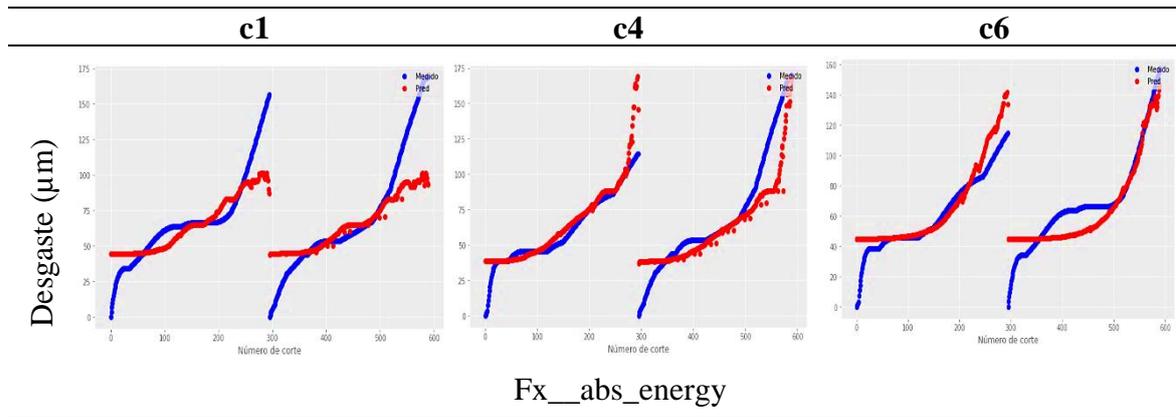
Imágenes de algunas características con detrend



En la Tabla 7 se presentan las 60 características obtenidas para este estudio. Como ejemplo particular a continuación, se presenta el entrenamiento de la característica “Fx__abs_energy” en la Tabla 10. En esta tabla se puede observar la relación entre el desgaste real y el desgaste predicho del entrenamiento para cada una de las 3 cuchillas. Similar análisis se realizó para las 59 características restantes.

Tabla 10

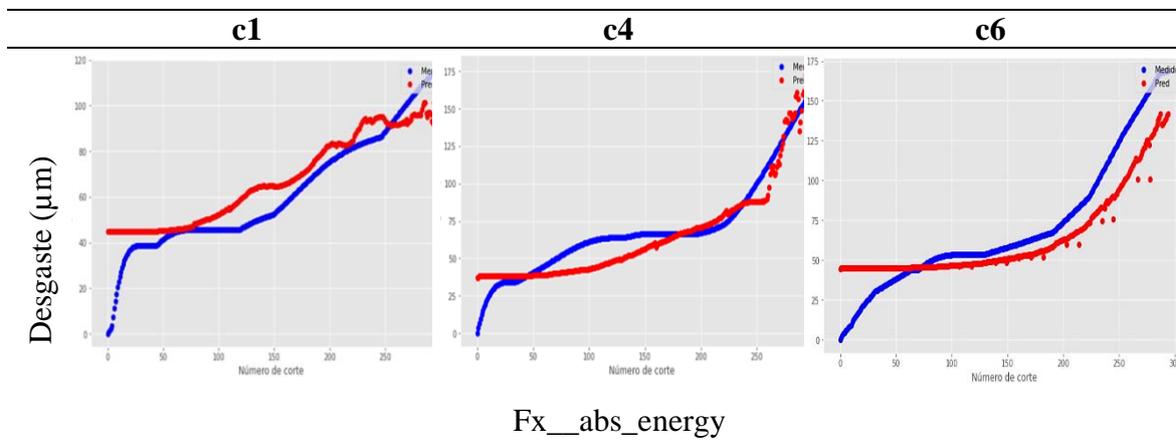
Entrenamiento usando el modelo de aprendizaje automático para las 3 cuchillas



La Tabla 11 muestra la validación para la característica seleccionada “Fx__abs_energy” comparando el desgaste real y el desgaste predicho para cada una de las 3 cuchillas. Similar análisis se realizó para las 59 características restantes.

Tabla 11

Validación usando el modelo de aprendizaje automático para las 3 cuchillas



3.3.2 Se seleccionaron 15 características para cada cuchilla

El desgaste que se obtuvo por medio del algoritmo de aprendizaje automático se comparó con los datos experimentales del desgaste (base de datos) utilizando la métrica RMSE repitiendo el proceso hasta completar una lista de 15 características. La característica o características que resultaron con un RMSE menor a 10 para las 3 cuchillas se guardaron en una lista como se muestra en la Tabla 12, siendo la primera vez que se obtuvieron resultados. Luego se repite el proceso anterior obteniendo una nueva lista de características como se observa en la Tabla 13, siendo la segunda vez que se obtuvieron los resultados. En las Tablas 12 y 13 se tienen con un RMSE menor a 10, pero si esta condición no se cumple se pasa a la siguiente característica o características regresando al inicio de la ingeniería de características hacia adelante nuevamente al inicio.

Tabla 12

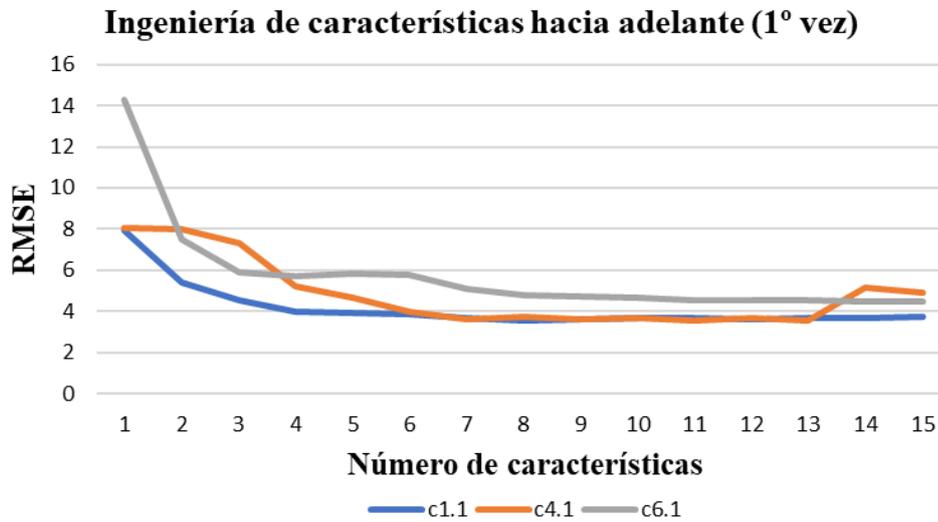
Primera prueba en las 3 cuchillas.

NC	RMSE		
	c1	c4	c6
1	7.96	8.08	14.3
2	5.4	8.02	7.47
3	4.52	7.32	5.88
4	4.01	5.22	5.7
5	3.94	4.64	5.85
6	3.88	4	5.79
7	3.69	3.6	5.12
8	3.56	3.72	4.8
9	3.59	3.62	4.75
10	3.7	3.68	4.64
11	3.67	3.53	4.55
12	3.62	3.65	4.55
13	3.67	3.56	4.57
14	3.7	5.16	4.48
15	3.73	4.88	4.47

Para tal fin, la Tabla 12 presenta los resultados al ejecutar por primera vez el código perteneciente a la ingeniería de características hacia adelante y en la Figura 18 se ve una gráfica de comparación del RMSE para las 3 cuchillas.

Figura 18

Comparación de la primera prueba para las 3 cuchillas.



En la Tabla 13, se presentan los resultados numéricos al ejecutar por segunda vez el código perteneciente a la ingeniería de características hacia adelante para cada una de las 3 cuchillas.

Tabla 13

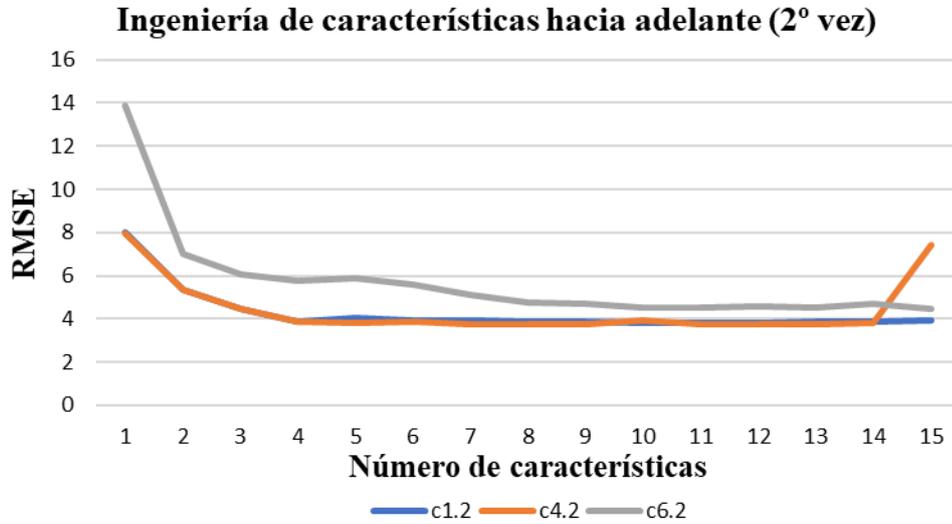
Segunda prueba para las 3 cuchillas.

NC	RMSE		
	c1	c4	c6
1	7.99	7.96	13.9
2	5.38	5.38	7.03
3	4.49	4.48	6.04
4	3.88	3.87	5.74
5	4.03	3.82	5.91
6	3.94	3.88	5.59
7	3.92	3.77	5.12
8	3.87	3.73	4.74
9	3.9	3.77	4.68
10	3.83	3.91	4.53
11	3.84	3.77	4.54
12	3.8	3.76	4.58
13	3.89	3.77	4.53
14	3.89	3.8	4.72
15	3.93	7.42	4.47

Los resultados de la Tabla 13 se muestran gráficamente en la Figura 19 para las 3 cuchillas.

Figura 19

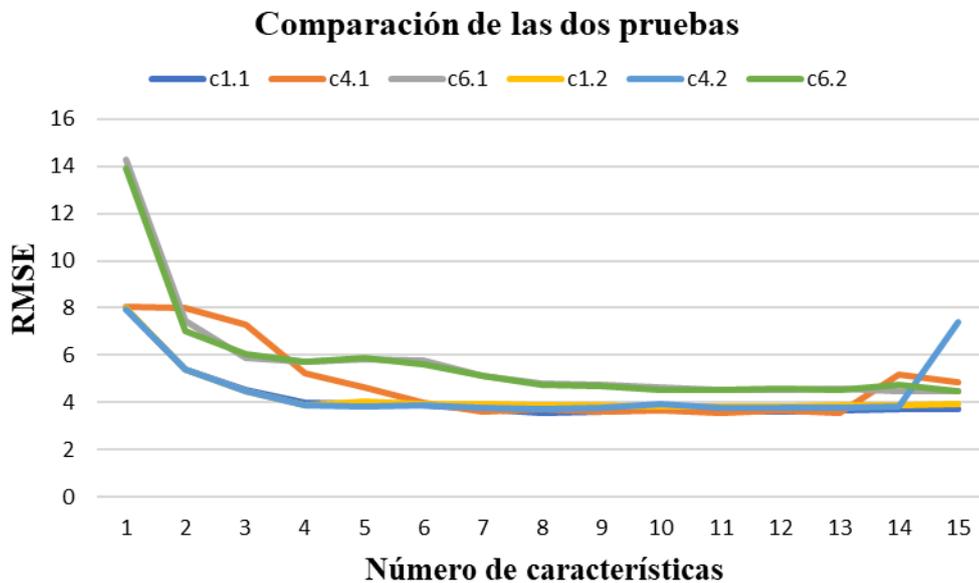
Comparación de la segunda prueba en las 3 cuchillas.



Posteriormente se procedió a juntar las curvas de las Figuras 18 y 19 en la Figura 20 de las 3 cuchillas para comparar los resultados de ejecutar el mismo código por segunda vez para c1 y c4 en ambos casos el RMSE siempre es menor a 10.

Figura 20

Comparación de las 2 pruebas.



Los resultados de las 2 predicciones usando 15 características (RMSE menor a 10) para la cuchilla c1 son mostrados en la Tabla 14. Para cada caso se muestran las pruebas, cantidad de características (NC), características, RMSE, C, ϵ , gamma y kernel.

Tabla 14

Resultados para la cuchilla c1.

Prueba	NC	Características	RMSE	C	ϵ	Gamma	Kernel
Primer	15	['Fz_PtP', 'Vy__fft_aggregated__ag gtype_"kurtosis" 'Fz__skewness', 'Vz__maximum', 'Fz__variance','Vy_WE', 'Fz__fft_aggregated__agg type_"skew" 'Vz__fft_aggregated__ag gtype_"kurtosis" 'Fz__abs_energy', 'Vz__minimum', 'Vy__minimum','Vz__ske wness', 'Vx__fft_aggregated__ag gtype_"skew"', 'Vx_PtP', 'Vy_PtP']	3.73	3914.8	8.96	0.03	RBF
Segundo	15	['Fz_PtP', 'Vy__fft_aggregated__ag gtype_"kurtosis" 'Fz__skewness', 'Vz__abs_energy', 'Vx__kurtosis', 'Vx__fft_aggregated__ag gtype_"skew"', 'Vx_WE', 'Fz__fft_aggregated__agg type_"skew" 'Vx__fft_aggregated__ag gtype_"kurtosis" 'Vx__minimum', 'Vz__minimum', 'Fz__maximum', 'Vx_PtP', 'Vx__variance', 'Fx__maximum']	3.93	212.97	10.4	0.17	RBF

Los resultados de 2 predicciones usando 15 características (RMSE menor a 10) para la cuchilla c4 son mostrados en la Tabla 15. Para cada caso se muestran las pruebas, cantidad de características (NC), características, RMSE, C, ϵ , gamma y kernel.

Tabla 15*Resultados para la cuchilla c4.*

Pruebas	NC	Características	RMSE	C	ϵ	Gamma	Kernel
Primer		['Fz_PtP', 'Vy_fft_aggregated__ aggtype_"kurtosis", 'Fz_skewness', 'Vz_abs_energy', 'Vx_kurtosis', 'Vx_fft_aggregated__ aggtype_"skew", 'Vx_WE', 'Fz_fft_aggregated__ aggtype_"skew", 'Vx_fft_aggregated__ aggtype_"kurtosis", 'Vx_minimum', 'Vz_minimum', 'Fz_maximum', 'Vx_PtP', 'Vx_variance', 'Fx_maximum']	3.93	212.97	10.4	0.17	RBF
	15	['Fz_abs_energy', 'Vy_fft_aggregated__ aggtype_"kurtosis", 'Fz_kurtosis', 'Fx_PtP', 'AE_fft_aggregated__ aggtype_"kurtosis", 'Fx_skewness', 'Fx_kurtosis', 'Fz_maximum', 'Fz_variance', 'Vy_skewness', 'AE_fft_aggregated__ aggtype_"skew", 'Fx_minimum', 'Fx_maximum', 'Fz_WE', 'Vx_fft_aggregated__ aggtype_"kurtosis"]	4.47	9846.4	1.55	0.3	RBF

Los resultados de 2 predicciones usando 15 características (RMSE menor a 10) para la cuchilla c6 son mostrados en la Tabla 16. Para cada caso se muestran las pruebas, cantidad de características (NC), características, RMSE, C, epsilon, gamma y kernel.

Tabla 16

Resultados para la cuchilla c6.

Pruebas	NC	Características	RMSE	C	ϵ	Gamma	Kernel
Primer	15	['Fz_abs_energy', 'Vy_fft_aggregated_a ggtype_"kurtosis" 'Fz_kurtosis', 'Fx_PtP', 'AE_fft_aggregated_a ggtype_"kurtosis" 'Fx_skewness', 'Fx_kurtosis', 'Fz_maximum', 'Fz_variance', 'Vy_skewness', 'AE_fft_aggregated_a ggtype_"skew" 'Fx_minimum', 'Fx_maximum', 'Fz_WE', 'Vx_fft_aggregated_a ggtype_"kurtosis"']	4.47	9846.4	1.55	0.3	RBF
Segundo	15	['Fz_abs_energy', 'Vy_fft_aggregated_a ggtype_"kurtosis" 'Fz_kurtosis', 'Fx_PtP', 'AE_fft_aggregated_a ggtype_"kurtosis" 'Fx_skewness', 'Fx_kurtosis', 'Fz_maximum', 'Fz_variance', 'Vy_skewness', 'AE_fft_aggregated_a ggtype_"skew" 'Fx_minimum', 'Fx_maximum', 'Fz_WE', 'Vx_fft_aggregated_a ggtype_"kurtosis"']	4.47	9846.4	1.55	0.3	RBF

Los resultados de las 2 pruebas con 15 características cada una (RMSE menor a 10) para c1, c4 y c6 son mostrados en las Tablas 14, 15 y 16 respectivamente. Luego se procedió a seleccionar 15 características en cada cuchilla logrando obtener 3 listas de características con el mejor resultado posible de RMSE como se muestra en la Tabla 17 para reducir las 3 listas de 15 características donde finalmente es una sola lista de 15 características.

Tabla 17*Las 15 mejores características de cada cuchilla.*

NC	RMSE		
	c1	c4	c6
15	'Vx_fft_aggregated_agg type_"skew"', 'Vx_PtP', 'Vy_PtP', 'Vy_WE', 'Vy_fft_aggregated_agg type_"kurtosis"', 'Vy_minimum', 'Vz_skewness', 'Vz_minimum', 'Vz_maximum', 'Vz_fft_aggregated_agg type_"kurtosis"', 'Fz_skewness', 'Fz_variance', 'Fz_fft_aggregated_aggt ype_"skew"', 'Fz_abs_energy', 'Fz_PtP'	'Vx_maximum', 'Vx_PtP', 'Vx_minimum', 'Vx_fft_aggregated__ aggtype_"skew"', 'Vx_fft_aggregated__ aggtype_"kurtosis"', 'Vy_fft_aggregated__ aggtype_"kurtosis"', 'Vy_minimum', 'Vy_variance', 'Vy_PtP', 'Vy_WE', 'Vy_maximum', 'Vz_minimum', 'Fz_PtP', 'Fz_skewness'	'Vx_fft_aggregated_aggt ype_"kurtosis"', 'Vy_fft_aggregated_aggt ype_"kurtosis"', 'Vy_skewness', 'Fx_kurtosis', 'Fx_skewness', 'Fx_maximum', 'Fx_minimum', 'Fx_PtP', 'Fz_WE', 'Fz_abs_energy', 'Fz_kurtosis', 'Fz_maximum', 'Fz_variance', 'AE_fft_aggregated_aggt ype_"skew"', 'AE_fft_aggregated_aggt ype_"kurtosis"'

Las mejores 15 características seleccionadas de cada cuchilla presentados en la Tabla 17 que tienen los parámetros C, ϵ , gamma y kernel en la Tabla 18 con un menor RMSE para cada cuchilla.

Tabla 18*Valores de las 15 características seleccionadas para cada cuchilla*

Cuchilla	RMSE	C	ϵ	Gamma	Kernel
c1	3.73	2590.85	8.4	0.036	RBF
c4	3.8	133.2	0.2	0.17	RBF
c6	4.47	1387.4	0.02	0.4	RBF

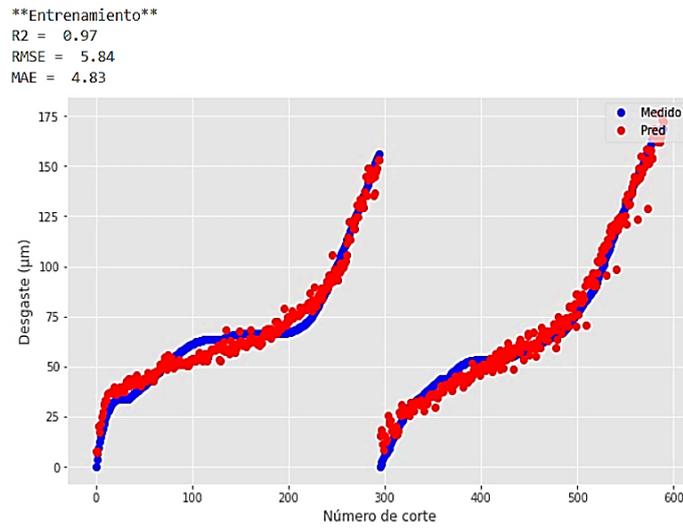
A continuación, se presentan las figuras del entrenamiento y validación para cada cuchilla utilizando las características de la Tabla 17 y los parámetros de la Tabla 18.

Cuchilla c1:

La predicción del entrenamiento usando las cuchillas c4 y c6 se muestra en la Figura 21 con su respectivo R2, RMSE y MAE donde se muestra la relación entre el desgaste real y el desgaste predicho.

Figura 21

Resultados del entrenamiento usando c4 y c6

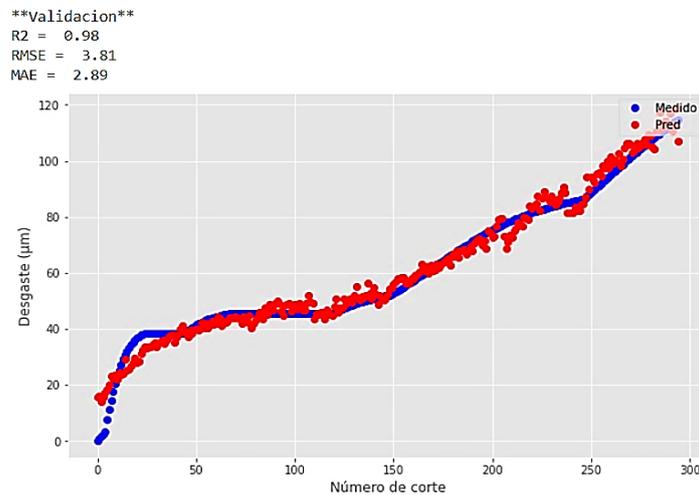


Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Para la validación de c1 se muestra en la Figura 22 la comparación entre el desgaste real y el desgaste predicho con su respectivo R2, RMSE y MAE.

Figura 22

Valores de validación y aproximación entre señales para c1



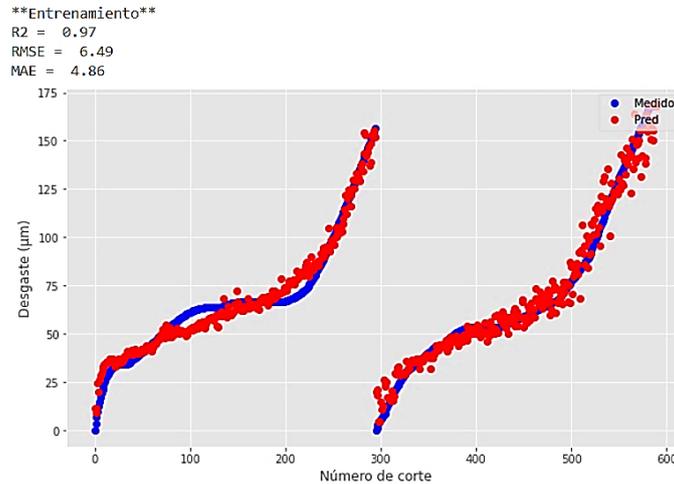
Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Cuchilla c4:

Se utilizaron las cuchillas c1 y c6 para el entrenamiento y en la Figura 23 con su respectivo R2, RMSE y MAE donde se muestra la relación entre el desgaste real y el desgaste predicho.

Figura 23

Resultados del entrenamiento usando c1 y c6

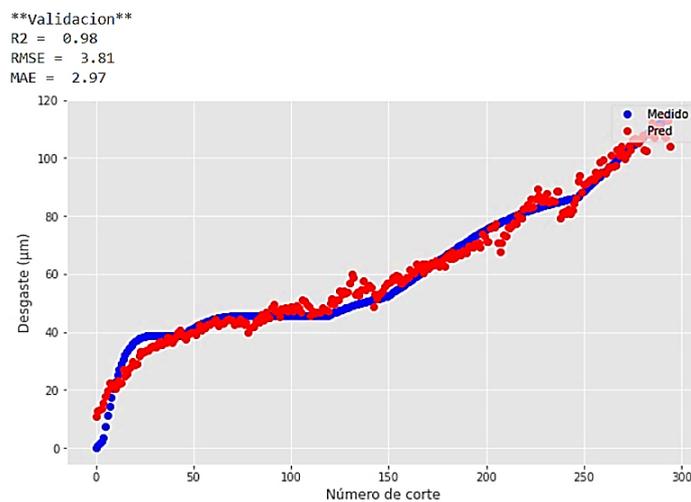


Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Para la validación de c4 se muestra en la Figura 24 la comparación entre el desgaste real y el desgaste predicho con su respectivo R2, RMSE y MAE.

Figura 24

Valores de validación y aproximación entre señales para c4



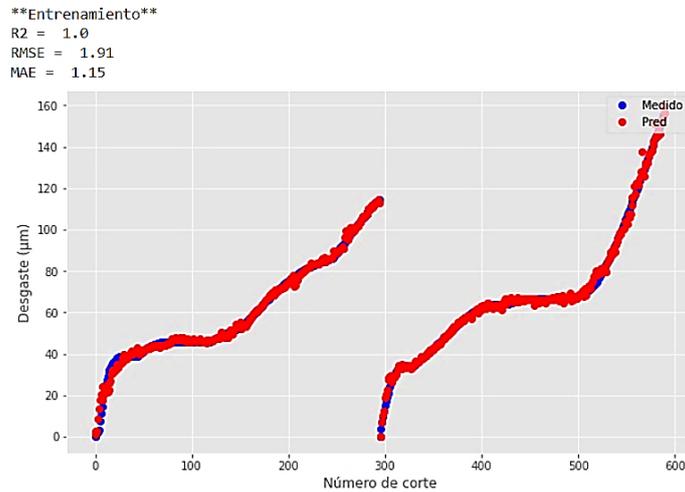
Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Cuchilla c6:

Se utilizaron las cuchillas c1 y c4 para el entrenamiento y en la Figura 25 con su respectivo R2, RMSE y MAE donde se muestra la relación entre el desgaste real y el desgaste predicho.

Figura 25

Resultados del entrenamiento usando c1 y c4

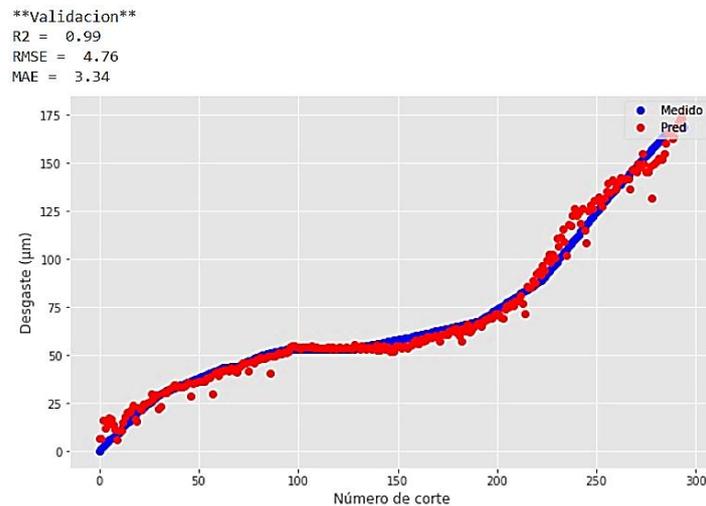


Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Para la validación de c6 se muestra en la Figura 26 la comparación entre el desgaste real y el desgaste predicho con su respectivo R2, RMSE y MAE.

Figura 26

Valores de validación y aproximación entre señales para c6



Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

3.3.3 Se seleccionaron 15 características para las 3 cuchillas

Se seleccionó el grupo de características que fueron ejecutados con el entrenamiento, validación y la optimización de hiperparámetros nuevamente. Se uso nuevamente la métrica RMSE para comparar el desgaste de la cuchilla obtenido por medio del algoritmo de aprendizaje automático y el desgaste de la base de datos. Cada uno de los grupos de características que se usaron en c1, c4 y c6 para obtener sus RMSE en cada uno de ellos y elegir el mayor RMSE de las 3 cuchillas. Lo anterior se repetirá para todos los grupos de características diferentes. Luego de obtener los mayores RMSE en cada uno de los grupos de características diferentes, se eligió el menor de todos ellos. El grupo de características elegido se guardó en una lista.

De las listas de características para cada una de las cuchillas se eligieron las 15 características cuyo valor de RMSE es el menor y de las características que fueron comunes en las 3 listas de cada cuchilla. De esta manera se formó una nueva lista de 15 características que será utilizada para las 3 cuchillas donde es mostrado en la Tabla 19. Se volvió a realizar los procesos de selección de los datos para el entrenamiento y la validación.

Tabla 19

Las 15 mejores características para las 3 cuchillas.

NC	3 cuchillas
15	'Vx_fft_aggregated__aggtype_"kurtosis", 'Vx_fft_aggregated__aggtype_"skew", 'Vx_PtP', 'Vy_PtP', 'Vy_WE', 'Vy_fft_aggregated__aggtype_"kurtosis", 'Vy__minimum', 'Vz__minimum', 'Fz__skewness', 'Fz__variance', 'Fz__abs_energy', 'Fz_PtP', 'Fz_fft_aggregated__aggtype_"skew", 'AE_fft_aggregated__aggtype_"skew", 'AE_fft_aggregated__aggtype_"kurtosis".

Las mejores 15 características seleccionadas de cada cuchilla presentados en la Tabla 19 que tienen los parámetros C, ϵ , gamma y kernel en la Tabla 20 con el menor RMSE para cada cuchilla.

Tabla 20

Valores de las 15 características seleccionadas para las 3 cuchillas

Cuchilla	RMSE	C	ϵ	Gamma	Kernel
c1	5.27	0.468	0.01	0.01	LINEAR
c4	5.07	0.54	8.81	0.09	LINEAR
c6	13.6	246.5	0.006	0.06	RBF

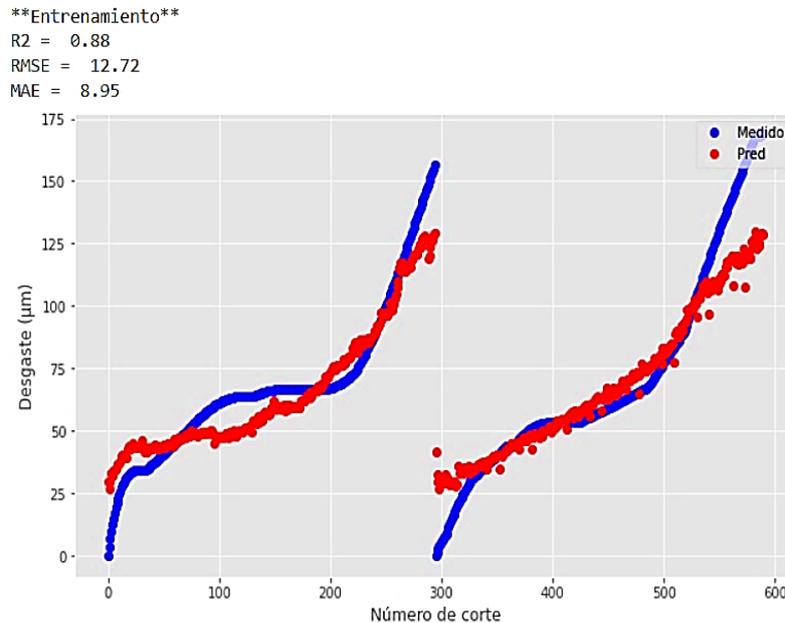
A continuación, se presentan las figuras del entrenamiento y validación para cada cuchilla utilizando las características de la Tabla 19 y los parámetros de la Tabla 20.

Cuchilla c1:

La predicción del entrenamiento usando las cuchillas c4 y c6 se muestra en la Figura 27 con su respectivo R2, RMSE y MAE donde se muestra la relación entre el desgaste real y el desgaste predicho.

Figura 27

Resultados del entrenamiento usando c4 y c6

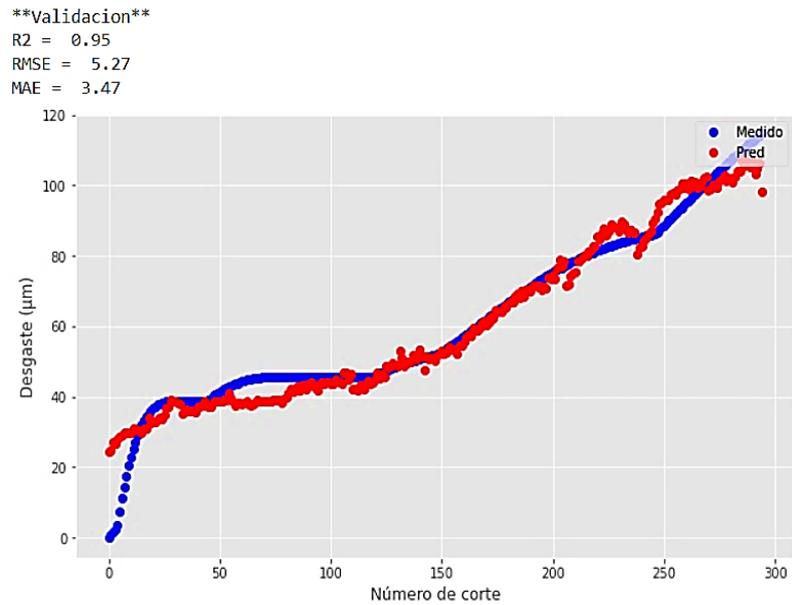


Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Para la validación de c1 se muestra en la Figura 28 la comparación entre el desgaste real y el desgaste predicho con su respectivo R2, RMSE y MAE.

Figura 28

Valores de validación y aproximación entre señales para c1



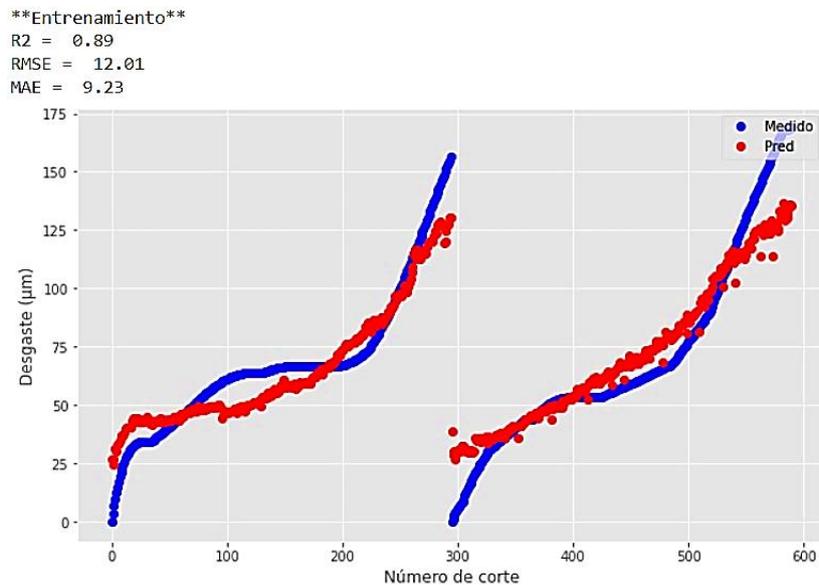
Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Cuchilla c4:

Se utilizaron las cuchillas c1 y c6 para el entrenamiento y en la Figura 29 con su respectivo R2, RMSE y MAE donde se muestra la relación entre el desgaste real y el desgaste predicho.

Figura 29

Resultados del entrenamiento usando c1 y c6

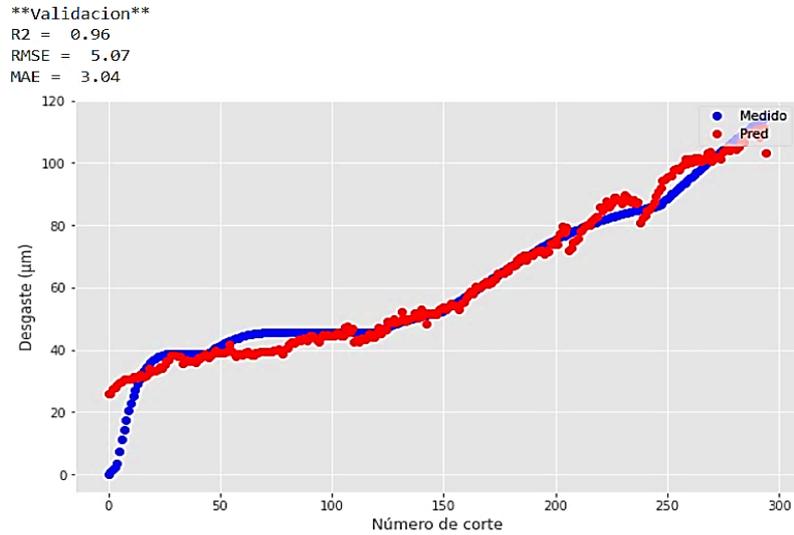


Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Para la validación de c4 se muestra en la Figura 30 la comparación entre el desgaste real y el desgaste predicho con su respectivo R2, RMSE y MAE.

Figura 30

Valores de validación y aproximación entre señales para c4



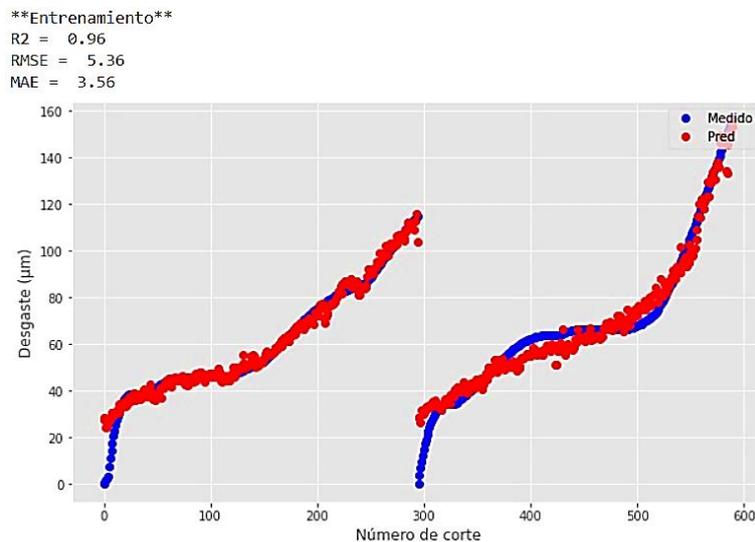
Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Cuchilla c6:

Se utilizaron las cuchillas c1 y c4 para el entrenamiento y en la Figura 31 con su respectivo R2, RMSE y MAE donde se muestra la relación entre el desgaste real y el desgaste predicho.

Figura 31

Resultados del entrenamiento usando c1 y c4

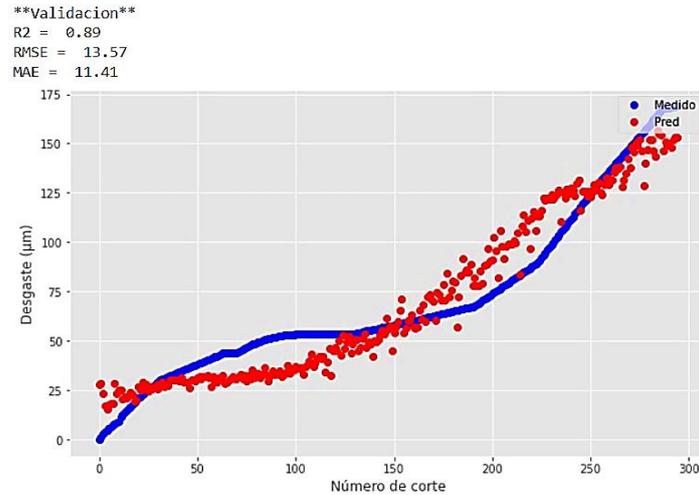


Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Para la validación de c6 se muestra en la Figura 32 la comparación entre el desgaste real y el desgaste predicho con su respectivo R2, RMSE y MAE.

Figura 32

Valores de validación y aproximación entre señales para c6



Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

3.3.4 Se seleccionaron 4 características para las 3 cuchillas

Los resultados de la elección en los menores RMSE para las 3 cuchillas proyectados en la Tabla 21 donde se nota una mejora constante en el proceso.

Tabla 21

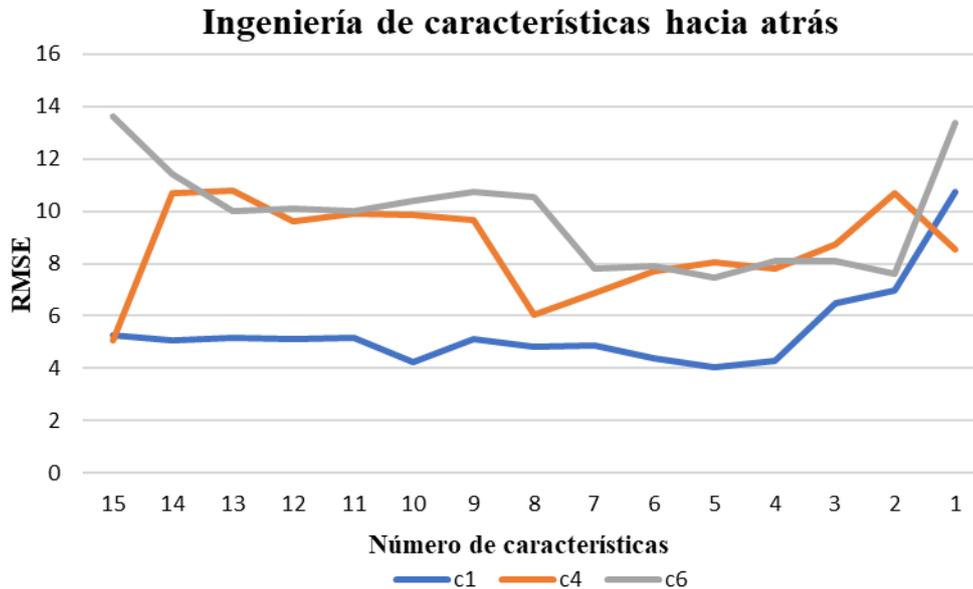
Elección de las menores RMSE en las 3 cuchillas.

NC	RMSE		
	c1	c4	c6
15	5.27	5.07	13.6
14	5.07	10.67	11.43
13	5.16	10.81	10.03
12	5.12	9.6	10.08
11	5.17	9.89	10.02
10	4.25	9.85	10.4
9	5.14	9.67	10.73
8	4.81	6.05	10.56
7	4.88	6.86	7.81
6	4.39	7.72	7.91
5	4.05	8.03	7.47
4	4.29	7.8	8.08
3	6.48	8.75	8.09
2	6.96	10.67	7.59
1	10.76	8.52	13.37

Luego de mostrar la Tabla 21 se verá a continuación la presentación del cuadro completo de los grupos de características para las 3 cuchillas en la Figura 33 de manera independiente por color en la gráfica comparativa lográndose ver los resultados en la investigación para la elección de la mejor lista para representar el menor costo computacional.

Figura 33

Cuadro completo de los grupos de características para las 3 Cuchillas.



3.3.4.1 Última característica

Las características mostradas en la tabla 21 hacen referencia a los conjuntos de características en función a la cantidad de ella para la elección de las más óptimas. Las características provienen de la fuerza y aceleración en los ejes X, Y y Z. La característica con mejor resultado luego de utilizar ingeniería de características hacia atrás se logra el resultado con mejor RMSE siendo la mejor característica 'Fz__variance' (característica extraída de la fuerza en la dirección Z porque es la característica más común considerando en las 3 cuchillas) donde los parámetros C, ϵ , gamma y kernel de la Tabla 22. Además, la tabla muestra que la mayoría de las características seleccionadas se calcularon a partir de la eliminación 1 a 1. En la mayoría de los casos, las características seleccionadas se calculan utilizando únicamente el valor de RMSE y, en menor cantidad de todos los mayores en cada caso (cantidad de características), la elección de las características de toda la investigación se realiza al final con análisis de lograr la reducción del costo computacional.

Tabla 22

Valor de la mejor característica en las 3 cuchillas

Cuchilla	RMSE	C	ϵ	Gamma	Kernel
c1	10.76	0.9	0.004	2.4	SIGMOID
c4	8.52	5.37	0.003	99	RBF
c6	13.37	5720	24.4	2.8	RBF

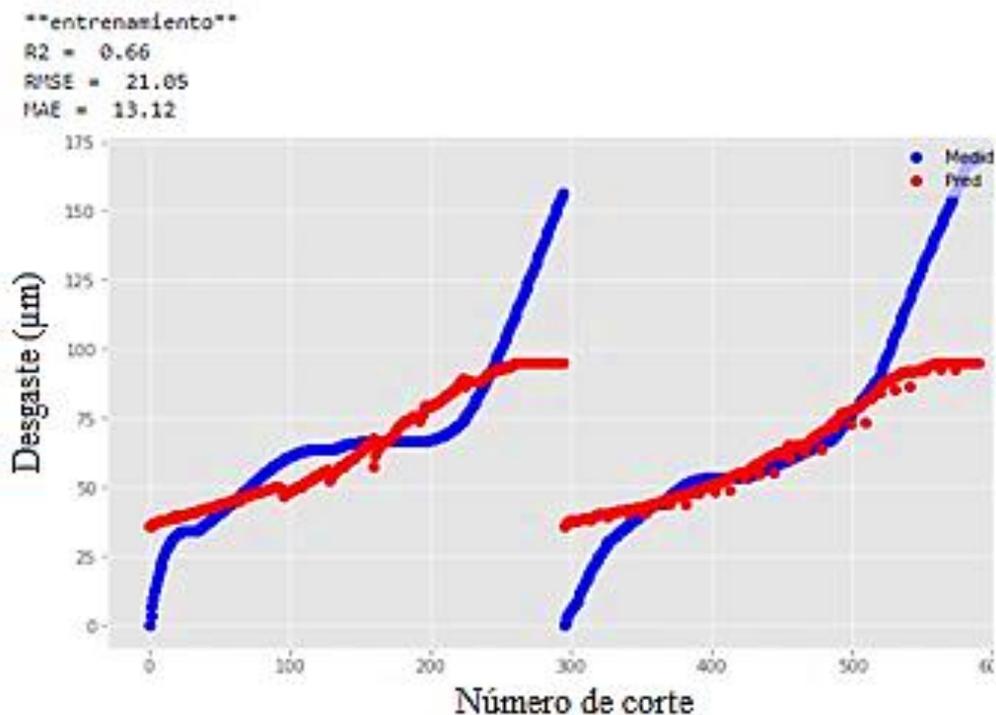
A continuación, se presentan las figuras del entrenamiento y validación para cada cuchilla utilizando la mejor característica y los parámetros C, ϵ , gamma y kernel de la Tabla 22.

Cuchilla c1:

La predicción del entrenamiento usando las cuchillas c4 y c6 se muestra en la Figura 34 con su respectivo R2, RMSE y MAE donde se muestra la relación entre el desgaste real y el desgaste predicho.

Figura 34

Resultados del entrenamiento usando c4 y c6

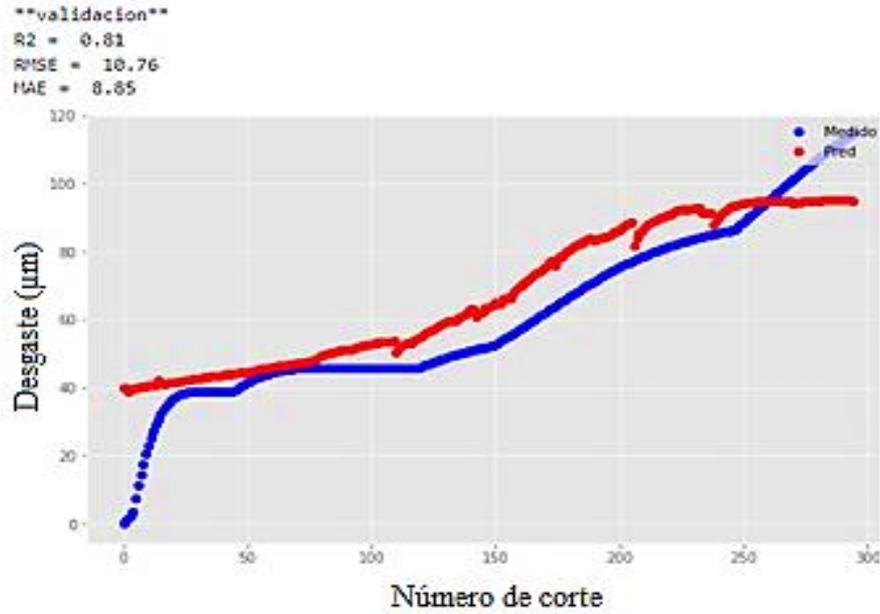


Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Para la validación de c1 se muestra en la Figura 35 la comparación entre el desgaste real y el desgaste predicho con su respectivo R2, RMSE y MAE.

Figura 35

Valores de validación y aproximación entre señales para c1



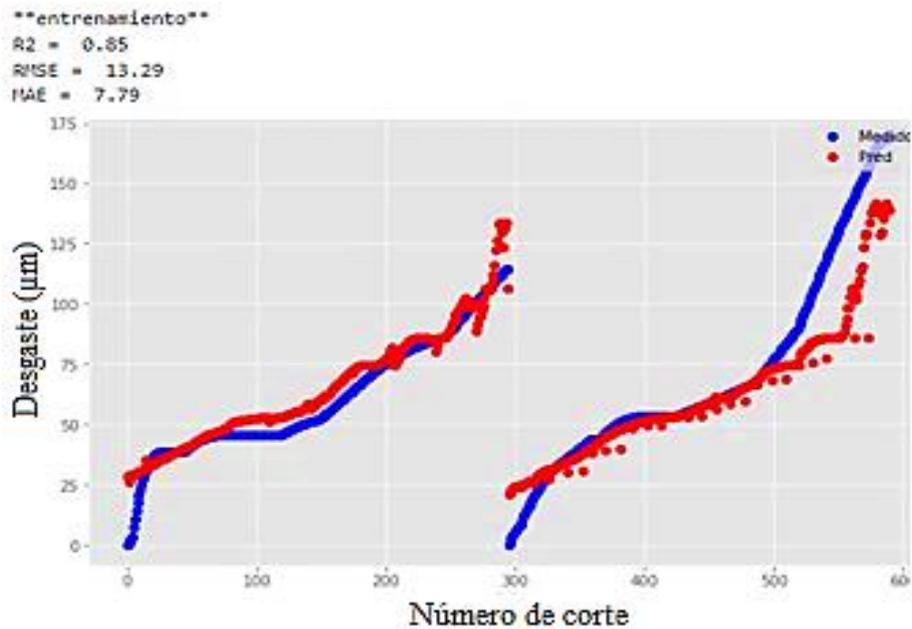
Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Cuchilla c4:

Se utilizaron las cuchillas c1 y c6 para el entrenamiento y en la Figura 36 con su respectivo R2, RMSE y MAE donde se muestra la relación entre el desgaste real y el desgaste predicho.

Figura 36

Resultados del entrenamiento usando c1 y c6

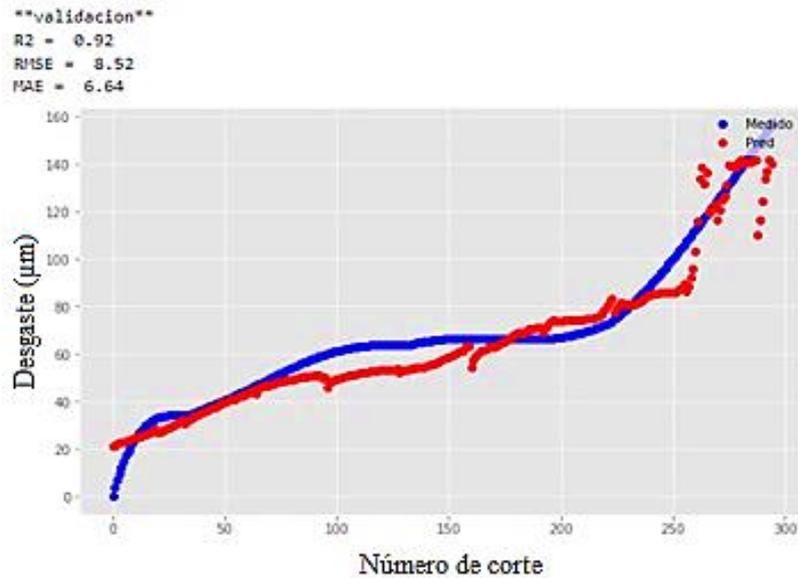


Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Para la validación de c4 se muestra en la Figura 37 la comparación entre el desgaste real y el desgaste predicho con su respectivo R2, RMSE y MAE.

Figura 37

Valores de validación y aproximación entre señales para c4



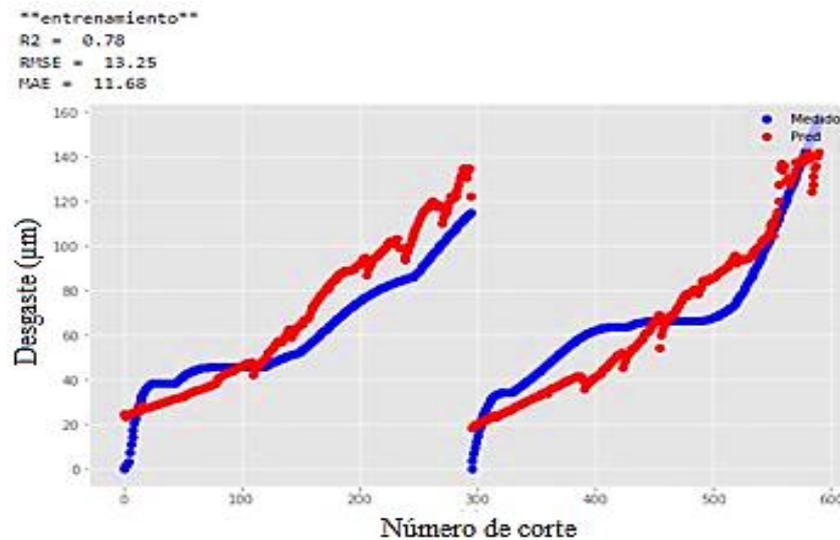
Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Cuchilla c6:

Se utilizaron las cuchillas c1 y c4 para el entrenamiento y en la Figura 38 con su respectivo R2, RMSE y MAE donde se muestra la relación entre el desgaste real y el desgaste predicho.

Figura 38

Resultados del entrenamiento usando c1 y c4

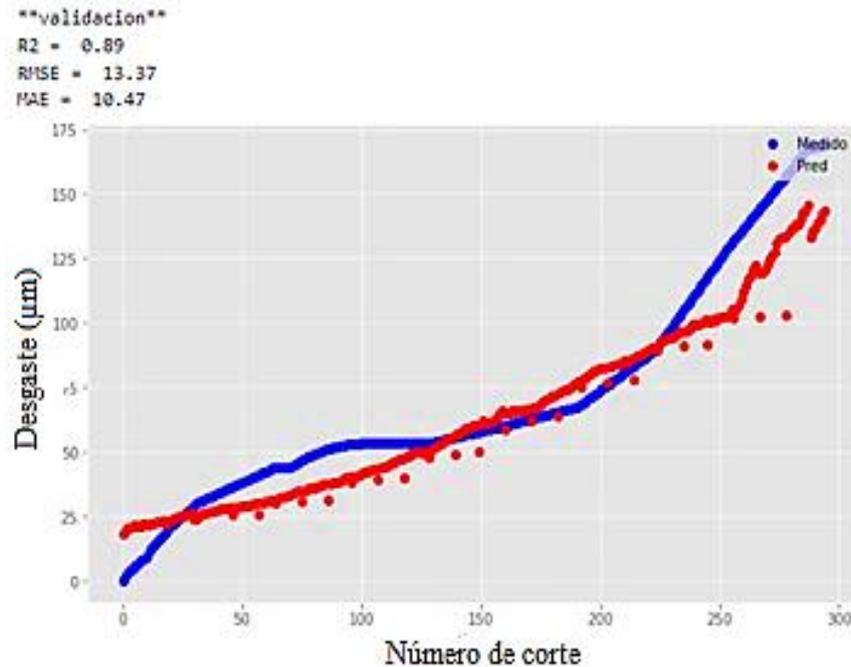


Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Para la validación de c6 se muestra en la Figura 39 la comparación entre el desgaste real y el desgaste predicho con su respectivo R2, RMSE y MAE.

Figura 39

Valores de validación y aproximación entre señales para c6



Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

3.3.4.2 Elección de la lista de características

En este caso para la elección en particular de la Tabla 21, donde el mejor de los 15 casos teniendo como principal restricción el valor de RMSE menor a 10 al utilizar la ingeniería de características hacia atrás y con el mejor margen de acuerdo al proceso que se ha desarrollado durante la investigación donde se eligen las 4 características seleccionadas más importante que son mostradas a continuación:

- 'Vy__fft_aggregated__aggtype_"kurtosis"'
- 'Fz__skewness'
- 'Fz__variance'
- 'Fz__fft_aggregated__aggtype_"skew"'

Se puede observar el mínimo margen de error con la cantidad prudente de características. Se tienen los parámetros C, ϵ , gamma y kernel en la Tabla 23 con el menor RMSE para cada cuchilla.

Tabla 23

Valores de las 4 características seleccionadas para las 3 cuchillas.

Cuchilla	RMSE	C	ϵ	Gamma	Kernel
c1	4.29	5438.7	1.6	0.07	RBF
c4	7.8	8837.9	7.218	0.06	RBF
c6	8.08	1335	0.0003	1	RBF

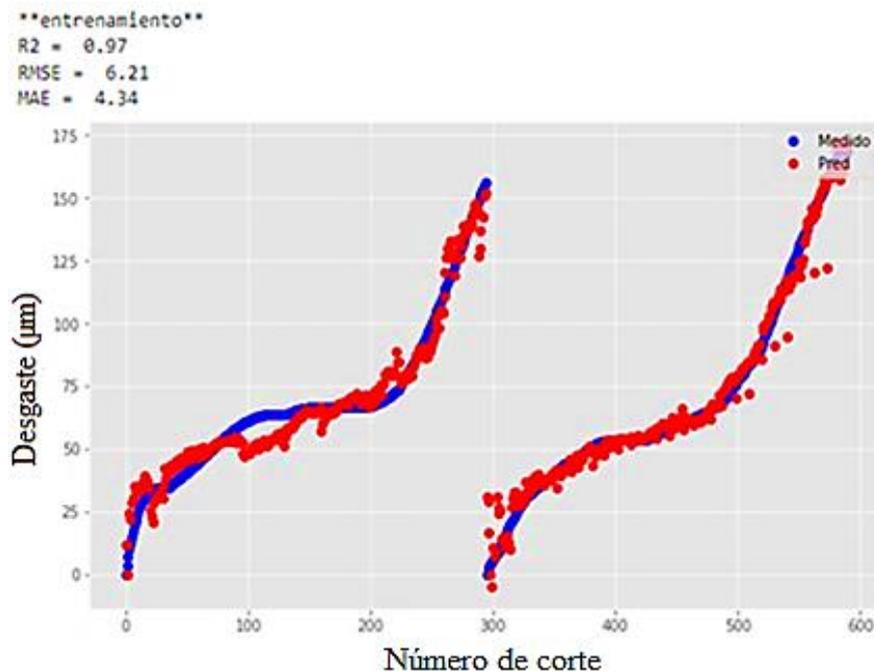
A continuación, se presentan las Figuras del entrenamiento y validación para cada cuchilla utilizando las características de la Tabla 21 y los parámetros de la Tabla 23 para la comparación entre el desgaste real y el desgaste predicho con su respectivo R2, RMSE y MAE utilizando las 4 características seleccionadas.

Cuchilla c1:

La predicción del entrenamiento usando las cuchillas c4 y c6 se muestra en la Figura 40 con su respectivo R2, RMSE y MAE donde se muestra la relación entre el desgaste real y el desgaste predicho.

Figura 40

Resultados del entrenamiento usando c4 y c6

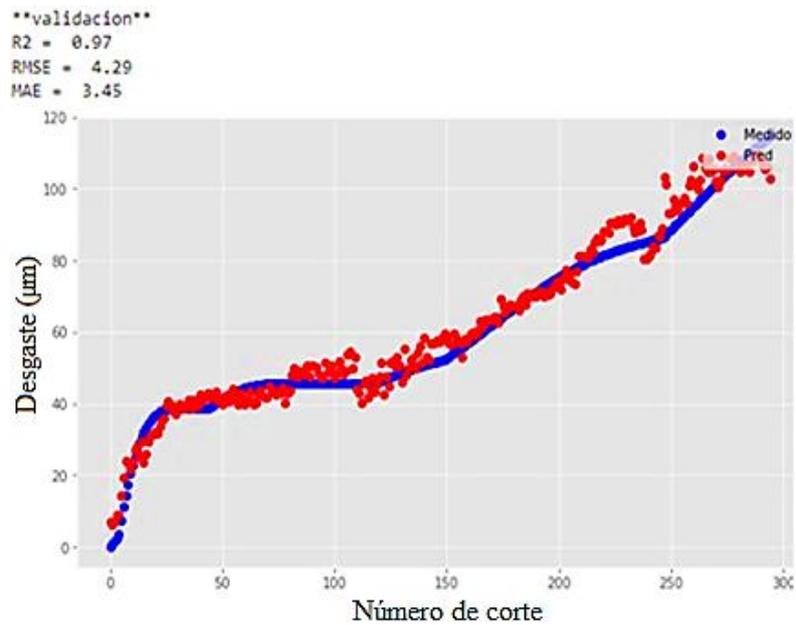


Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Para la validación de c1 se muestra en la Figura 41 la comparación entre el desgaste real y el desgaste predicho con su respectivo R2, RMSE y MAE.

Figura 41

Valores de validación y aproximación entre señales para c1



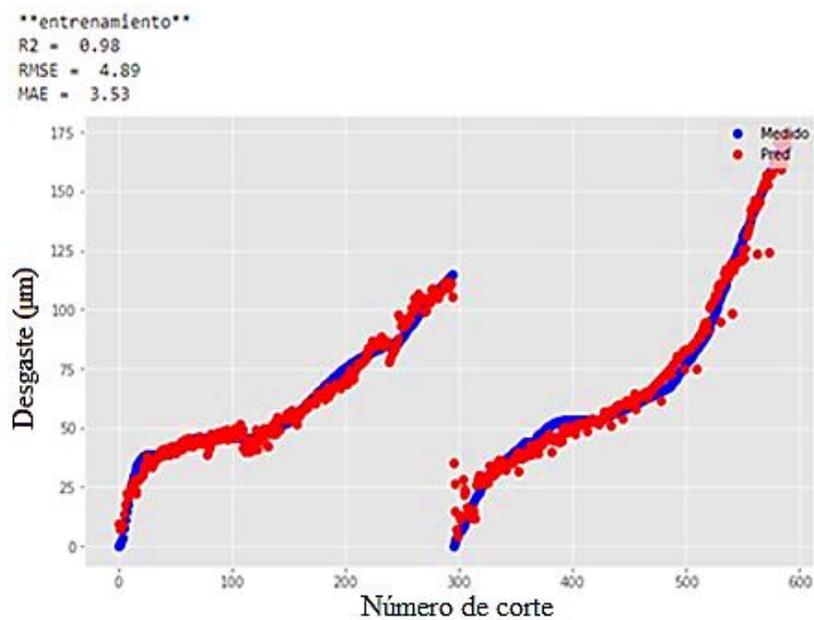
Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Cuchilla c4:

Se utilizaron las cuchillas c1 y c6 para el entrenamiento y en la Figura 42 con su respectivo R2, RMSE y MAE donde se muestra la relación entre el desgaste real y el desgaste predicho.

Figura 42

Resultados del entrenamiento usando c1 y c6

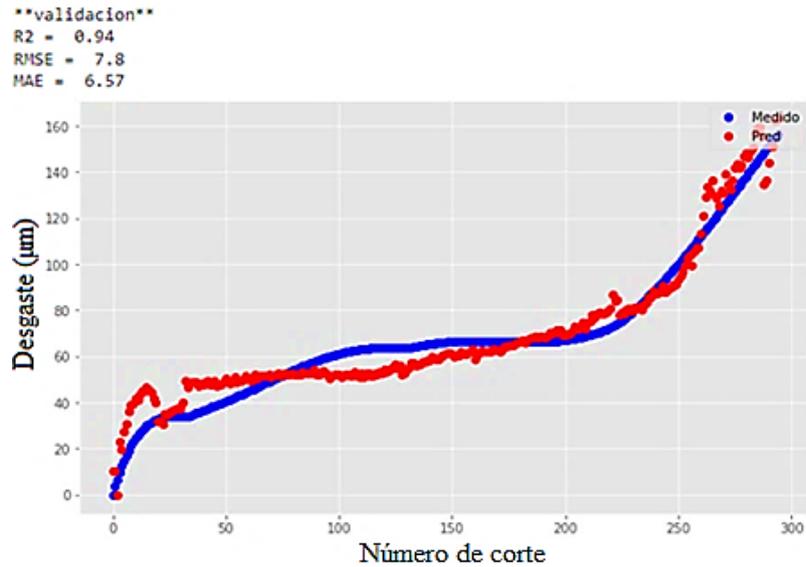


Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Para la validación de c4 se muestra en la Figura 43 la comparación entre el desgaste real y el desgaste predicho con su respectivo R2, RMSE y MAE.

Figura 43

Valores de validación y aproximación entre señales para c4



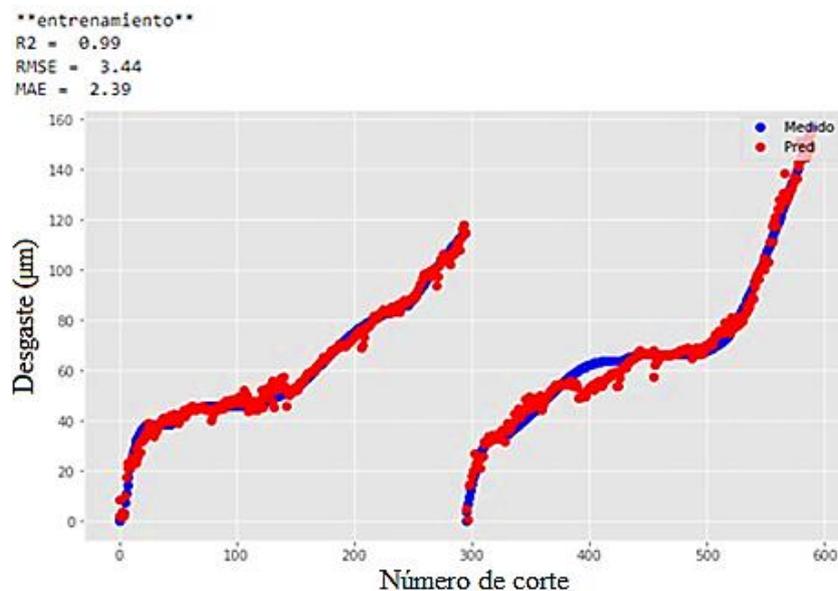
Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Cuchilla c6:

Se utilizaron las cuchillas c1 y c4 para el entrenamiento y en la Figura 44 con su respectivo R2, RMSE y MAE donde se muestra la relación entre el desgaste real y el desgaste predicho.

Figura 44

Resultados del entrenamiento usando c1 y c4

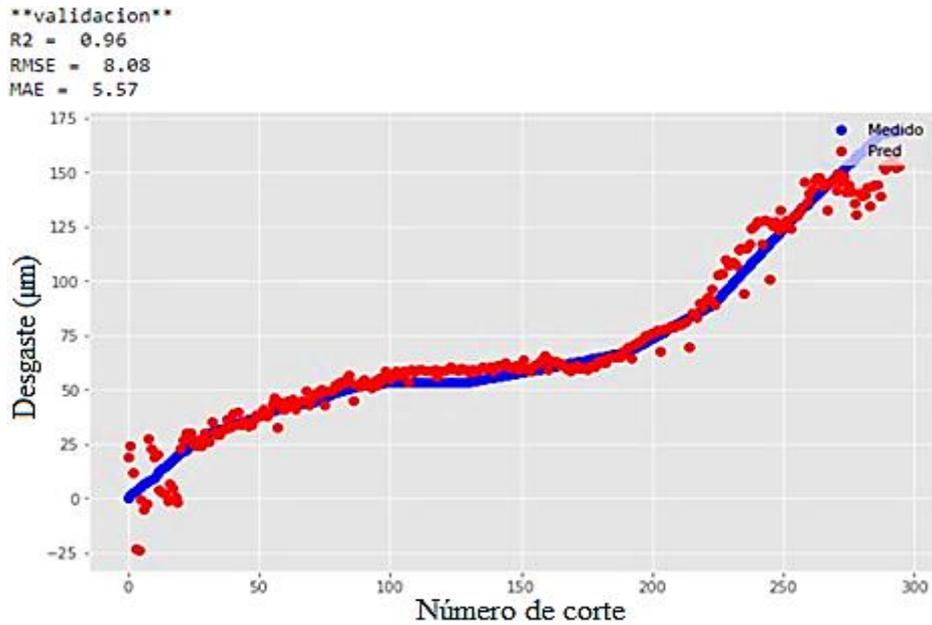


Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

Para la validación de c6 se muestra en la Figura 45 la comparación entre el desgaste real y el desgaste predicho con su respectivo R2, RMSE y MAE.

Figura 45

Valores de validación y aproximación entre señales para c6



Nota: El desgaste de los datos reales (azul) y de predicción (rojo).

3.3.4.3 Costo computacional

A continuación, se procede a determinar el costo computacional o tiempo de ejecución del código de predicción para 2 listas de características. La primera lista tiene las 4 características obtenidos en la sección anterior (3.3.4.2) y la segunda lista tiene 60 características utilizadas por otras investigaciones como se detalla en la Tabla 27. Es necesario precisar que otras investigaciones mencionan que utilizan solo 10 características, pero esas 10 características las aplican a las señales de fuerza y aceleración. En adelante se utilizará la letra F para hacer referencia a las características ("features" en inglés), como se muestra en la Tabla 24.

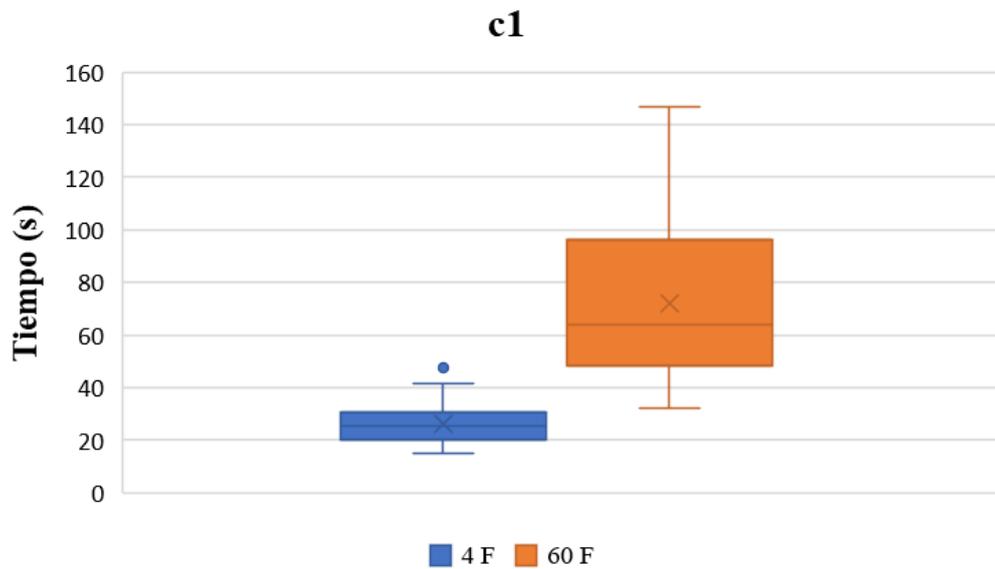
Tabla 24*Comparación entre las listas de 4 y 60 características para la cuchilla c1.*

	c1	
	4 F (s)	60 F (s)
1	14.84847	91.50764
2	24.6555	65.73505
3	24.95967	146.8031
4	25.3915	62.40669
5	33.94888	58.60435
6	47.63669	73.36623
7	27.83036	49.06907
8	31.50674	79.20866
9	16.64653	56.57439
10	41.81016	48.0097
11	27.27014	43.06339
12	26.10098	62.83389
13	34.80758	64.95994
14	22.59507	44.81527
15	22.37139	103.4961
16	15.33346	36.72448
17	22.03098	108.6811
18	18.829	115.7589
19	19.49833	32.33899
20	27.02595	97.97986

La Tabla 24 presenta los resultados de 20 mediciones del tiempo de ejecución para 4 F y 60 F. Dichas mediciones se grafican en la Figura 46 haciendo uso de diagrama de caja (“BoxPlot” en inglés). Para 4 F se muestra una reducción considerable del costo computacional a comparación de 60 F.

Figura 46

Costo computacional para 4 y 60 características para c1.



A continuación, se procede a determinar el costo computacional o tiempo de ejecución del código de predicción para 2 listas de características. La primera lista tiene las 4 características obtenidos en la sección anterior (3.3.4.2) y la segunda lista tiene 60 características utilizadas por otras investigaciones como se detalla en la Tabla 27. Es necesario precisar que otras investigaciones mencionan que utilizan solo 10 características, pero esas 10 características las aplican a las señales de fuerza y aceleración. La letra F como se muestra en la Tabla 25 hace referencia a las características ("features" en inglés).

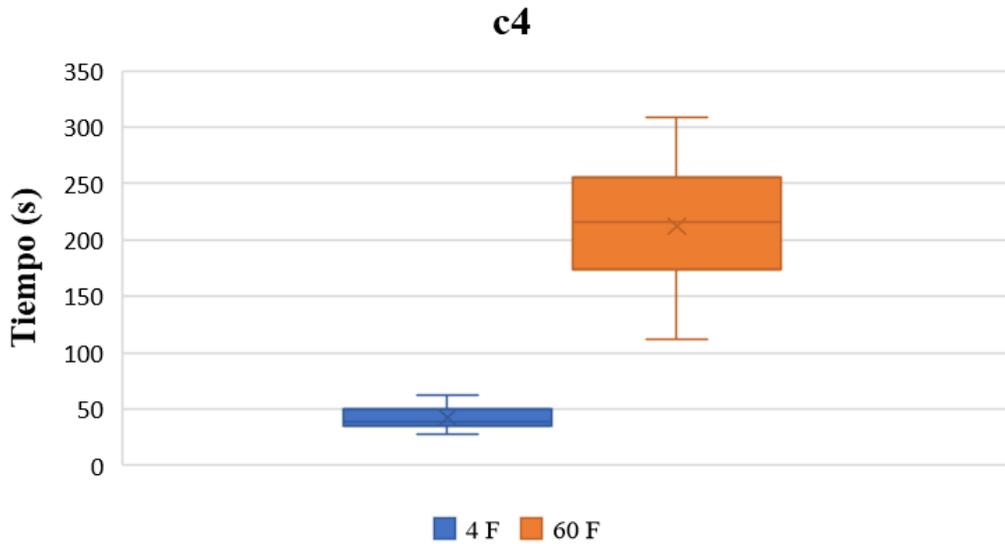
Tabla 25*Comparación entre las 4 y 60 características en la cuchilla c4.*

c4		
	4 F	60 F
1	53.62075	129.0872
2	34.97101	289.9232
3	35.21978	247.3655
4	52.29846	170.3724
5	35.54849	181.8807
6	47.92949	240.5859
7	37.84966	258.5867
8	61.90662	257.8736
9	37.55076	135.9417
10	46.8049	209.7136
11	30.17877	217.8072
12	44.50838	146.3125
13	40.56673	213.4777
14	37.53771	194.2776
15	58.26506	260.9431
16	51.26296	207.6886
17	36.75567	238.6027
18	40.20253	112.1732
19	27.2252	224.2756
20	36.33767	308.3453

La Tabla 25 presenta los resultados de 20 mediciones del tiempo de ejecución para 4 F y 60 F. Dichas mediciones se grafican en la Figura 47 haciendo uso de diagrama de caja (“BoxPlot” en inglés). Para 4 F se muestra una reducción considerable del costo computacional a comparación de 60 F. Es importante destacar que esta reducción es considerablemente mayor que la observada en el caso anterior c1.

Figura 47

Comparación en Boxplot para c4.



A continuación, se procede a determinar el costo computacional o tiempo de ejecución del código de predicción para 2 listas de características. La primera lista tiene las 4 características obtenidos en la sección anterior (3.3.4.2) y la segunda lista tiene 60 características utilizadas por otras investigaciones como se detalla en la Tabla 27. Es necesario precisar que otras investigaciones mencionan que utilizan solo 10 características, pero esas 10 características las aplican a las señales de fuerza y aceleración. La letra F como se muestra en la Tabla 26 hace referencia a las características ("features" en inglés).

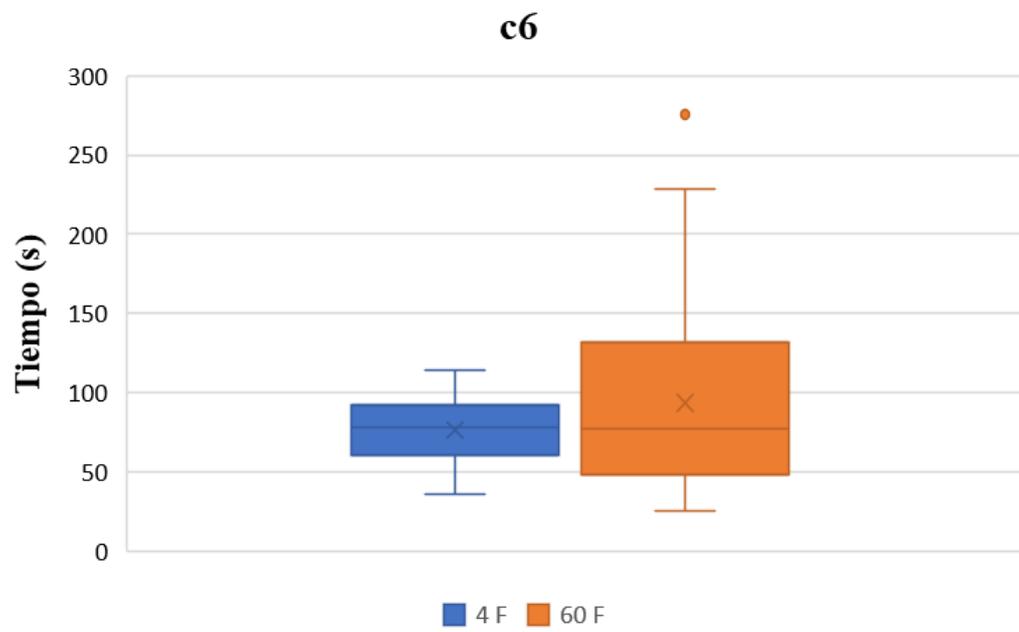
Tabla 26*Comparación entre las 4 y 60 características en la cuchilla c6.*

	c6	
	4 F	60 F
1	99.49665	157.1334
2	86.30023	98.06249
3	101.4107	68.6447
4	69.88229	128.4255
5	76.09754	30.79066
6	69.59314	88.75072
7	47.87497	54.45283
8	100.7554	47.48387
9	79.47249	89.88771
10	56.96584	28.07783
11	113.7609	26.82474
12	93.37045	228.807
13	36.32216	275.5779
14	40.39439	50.51376
15	88.3659	86.60229
16	50.17075	50.68649
17	75.47965	25.73969
18	83.86474	132.4413
19	73.22312	142.5207
20	87.17	60.21653

La Tabla 26 presenta los resultados de 20 mediciones del tiempo de ejecución para 4 F y 60 F, y estos datos se visualizan en la Figura 48 mediante un diagrama de caja ("BoxPlot" en inglés). Para 4 F se muestra una reducción considerable del costo computacional a comparación de 60 F. No obstante, es esencial señalar que esta reducción es significativamente menor en comparación con los casos c1 y c4.

Figura 48

Comparación en Boxplot para c6.



CAPÍTULO IV

IV. DISCUSIÓN DE RESULTADOS

En este capítulo se presentan y describen los comentarios analíticos sobre el desempeño del modelo de aprendizaje automático desarrollado para estimar el desgaste de la cuchilla en una fresadora CNC. Se utilizaron dos métricas para evaluar el rendimiento del modelo: el RMSE y la matriz de consistencia.

El RMSE es una medida de la diferencia entre valores de los desgastes predichos por el modelo y los desgastes medidos. Se busca que este valor sea lo más cercano a cero posible, lo que indicaría que el modelo está haciendo predicciones precisas. Se exploraron características nuevas y se buscaron las mejores de manera manual y automática. La matriz de consistencia, por su parte, verifica la proporción de predicciones correctas en relación a todos los resultados.

En la presente investigación se ha realizado una selección cuidadosa de las características más relevantes y significativas para el modelado y predicción de la cuchilla en una fresadora CNC. Se han utilizado métodos manuales y automáticos de selección de características para determinar cuáles de las 70 características, obtenidas a partir de las series temporales de fuerza y aceleración, son las más importantes para lograr el resultado de reducir el RMSE.

Para la selección manual, se ha realizado una revisión exhaustiva de literaturas especializadas en la materia para determinar qué características son las más relevantes en la predicción del desgaste de la cuchilla. Por otro lado, para la selección automática se han utilizado técnicas de algoritmos de aprendizaje supervisado como el SVR para evaluar la importancia de cada característica en la predicción del desgaste de la cuchilla.

En consecuencia, se han seleccionado un conjunto de características que han mostrado ser más relevantes y significativas para la predicción del desgaste de la cuchilla en la fresadora CNC. Esto ha permitido reducir el número total de características a utilizar en el modelo final y, por tanto, mejorar la eficiencia y precisión de las predicciones.

Tabla 27*Características de investigaciones*

Referencia	Características	NC
Wang et al. (2015)	Mean, RMS, Variance, Kurtosis, Spectral mean, Spectral kurtosis, Wavelet energy, Energy ratio.	8
Wang et al. (2017)	RMS, Variance, Maximun, Skewness, Kurtosis, Peak-to-Peak, Spectral skewness, Spectral kurtosis, Wavelet energy.	9
Wang et al. (2019)	RMS, Variance, Maximum, Skewness, Kurtosis, Peak-to-Peak, Spectral skewness, Spectral kurtosis, Spectral power, Wavelet energy.	10
Zhao et al. (2017)	RMS, Variance, Maximun, Skewness, Kurtosis, Peak-to-Peak, Spectral skewness, Spectral kurtosis, Wavelet energy.	9
Zhao et al. (2018)	RMS, Variance, Maximun, Skewness, Kurtosis, Peak-to-Peak, Spectral skewness, Spectral kurtosis, Spectral power, Wavelet energy.	10
Zhao et al. (2019)	RMS, Variance, Maximun, Skewness, Kurtosis, Peak-to-Peak, Spectral skewness, Spectral kurtosis, Wavelet energy.	9

La Tabla 24 se muestran características utilizadas de otros trabajos de investigación, donde se han utilizado entre 8 y 10 características. Estas características observadas en la Tabla 24 fueron extraídas de la fuerza y aceleración, que también fueron utilizadas para generar la Tabla 7 que se inicia esta investigación con 10 características. Las características utilizadas por otros autores, que se muestran en la Tabla 24, se comparan posteriormente con la lista de características de la Tabla 7. Al comparar las características de otros autores (Tabla 24) con las características de este trabajo (Tabla 7), se observan características repetidas en ambos casos (skewness, variance, PtP, WE, kurtosis, máximo). En este trabajo se buscó ampliar la investigación utilizando características que no habían sido empleadas por otros autores. Específicamente, se utilizó la característica "abs_energy", así como las características "fft_aggregated__aggtype_"kurtosis"" y "fft_aggregated__aggtype_"skew"", además de "minimum".

A diferencia de otros estudios mostrados en la Tabla 24, en los que se utilizaron todas las características de las fuerzas y aceleraciones, en este trabajo se realizó una selección manual y automática de las mejores características con el resultado de reducir el valor del RMSE. Con este enfoque, se buscó obtener un mayor nivel de precisión en la predicción del desgaste de las 3 cuchillas.

A diferencia de los otros trabajos mencionados anteriormente en esta investigación se remueve la tendencia de las señales de fuerza y aceleración antes de obtener las características. En la Tabla 8, se muestra la característica "Fx__abs_energy", para c1 se ve un alejamiento mucho mayor entre los datos y la línea de regresión. Luego en la Tabla 9 para la misma característica en la cuchilla c1, el detrend logra el acercamiento de los datos a la línea de regresión. Por otro lado, se observa en la Tabla 9 que las cuchillas c4 y c6 no tienen una gran diferencia entre los datos y la línea de regresión con respecto a la Tabla 8. En la característica "Fy__maximum", para las 3 cuchillas en la Tabla 8 se observa un pequeño alejamiento entre los datos y la línea de regresión. Luego en la Tabla 9 para la misma característica el detrend realiza una corrección de las imperfecciones logrando la aproximación entre los datos y la línea de regresión. Al comparar la Tabla 8 y la Tabla 9 para la característica "Fx__PtP", se observa que el detrend no ayuda a mejorar la aproximación de los datos a la línea de regresión. Las correcciones que se realizan a las características permiten corregir las imperfecciones con detrend en algunos casos, en otros no se logran mejorar y hay otras que se mantienen iguales antes o después del detrend.

Se muestra en las Tablas 10 y 11 un ejemplo del modelo de predicción utilizando una característica para demostrar que está funcionando correctamente. Los resultados del entrenamiento y la validación para la característica "Fx__abs_energy" son mostrados en las Tablas 10 y 11 respectivamente, donde se observan algunas mejoras reflejadas en las imágenes para cada una de las 3 cuchillas; es decir, se muestran las aproximaciones entre el desgaste medido y el desgaste predicho. Se ha observado que existe una buena correspondencia entre los niveles de desgaste medidos y predichos para la característica "Fx__abs_energy". Sin embargo, es importante destacar que no necesariamente todas las características mostrarán el mismo grado de ajuste entre el desgaste medido y el predicho. Es posible que haya variaciones entre las características analizadas y su relación con el desgaste, lo que requerirá una evaluación cuidadosa de cada una de ellas. Los resultados

donde solo se utiliza una sola característica no muestran una buena predicción y se busca con más características que mejore la predicción del desgaste de la cuchilla.

En el presente estudio, se realizaron dos pruebas con el resultado de evaluar la similitud entre las características obtenidas en ambas pruebas, con el fin de poder seleccionar aquellas que resulten más relevantes y útiles para el análisis posterior. De esta manera, se busca identificar las características más significativas y determinar la cantidad óptima de características. Los resultados de este estudio proporcionan una valiosa información acerca de las características que formarán parte de una lista final, lo que puede contribuir a un entendimiento más profundo del rol de las características utilizadas.

Es necesario realizar una evaluación cuidadosa y minuciosa, utilizando las características y seleccionar solo aquellas que sean relevantes y contribuyen de manera significativa a la precisión del modelo tanto métodos manuales como automáticos de selección de características, con el fin de obtener la mejor lista posible. Este enfoque garantiza que el modelo tenga un rendimiento óptimo y que no se desperdicien recursos en la inclusión de características que no aportan valor a la predicción.

Durante la primera prueba del estudio, se comenzó con la evaluación de una sola característica para determinar su RMSE. Posteriormente, se aumentó gradualmente el número de características y se observó el comportamiento del RMSE en cada cuchilla. Es importante mencionar que, en algunos casos particulares, no se obtuvo un buen resultado, por lo que se decidió no considerar la característica que se había agregado o se reinició el proceso desde cero.

El resultado era reducir el RMSE explorando desde una hasta varias características, hasta que se alcanzara una condición específica ($RMSE < 10$). Para lograr esto, se utilizó la ingeniería de características hacia adelante. En el desarrollo de este estudio, se logró reducir el RMSE notablemente en las primeras seis características analizadas para las 3 cuchillas. Estos resultados son altamente positivos, ya que indican una mejor predicción por la reducción del RMSE. Sin embargo, en la séptima característica, se observó una inestabilidad en los resultados, indicando que la predicción no es tan buena como para las características previas en todas las cuchillas. Esto sugiere que la séptima característica no está contribuyendo de manera efectiva a la reducción del RMSE, y podría estar siendo influenciada por factores no considerados en este estudio. Es importante destacar que estos resultados no disminuyen la relevancia de las seis

características previas, las cuales siguen siendo altamente relevantes para la selección de características.

Durante el análisis de las características, se observó que, en el caso de las cuchillas c1 y c6, los valores del RMSE subieron y bajaron por milésimas ligeramente entre la séptima y la decimoquinta característica. Por otro lado, se encontró que, en el caso de c4, los valores del RMSE subieron y bajaron por milésimas desde la séptima hasta la decimotercera característica, mientras que las características 14 y 15 mostraron un aumento en el valor del RMSE. Estos hallazgos indican que estas dos últimas características no están contribuyendo de manera efectiva a la reducción del RMSE. Es importante mencionar que estos comentarios se refieren a los resultados obtenidos en la primera prueba.

En la segunda prueba, se buscó verificar si las características seleccionadas en la primera prueba eran las únicas relevantes para el modelo y si se podían encontrar otras características que mejorarán aún más su rendimiento. Se comenzó por identificar las características más importantes y se procedió a evaluar el desempeño del modelo al agregar gradualmente más características desde una característica para las diferentes cuchillas (c1, c4 y c6). Se observó una inestabilidad al subir o bajar por milésimas el valor del RMSE desde la octava característica hasta la quinceava característica para c1 y c6. Por otro lado, para la cuchilla c4, se observa una inestabilidad similar, pero solo hasta la catorceava característica. A partir de ahí, se observa un aumento del margen en el valor del RMSE en la decimoquinta característica, lo que indica que los resultados se vuelven menos precisos. Este análisis muestra que el valor del RMSE puede verse afectado por pequeñas variaciones debido a las características, y que los resultados pueden ser menos precisos para algunas cuchillas que para otras.

Con el análisis de los resultados obtenidos en las dos pruebas mencionadas anteriormente, se pudo observar que la cuchilla c4 experimentó un aumento en el valor del RMSE en ambas pruebas, lo que sugiere que la incorporación de ciertas características no fue del todo adecuada para esta cuchilla en particular, lo que indica que a partir de esa cantidad de características la calidad de la predicción empeora o el valor del RMSE aumenta. Por otro lado, la cuchilla c1 mantuvo su valor de RMSE constantemente o varió ligeramente en ambas pruebas, lo que sugiere que la selección de características para esta cuchilla fue efectiva. Del mismo modo en la primera prueba, la cuchilla c6 también se observó que se mantuvieron valores del RMSE similar y constante

logrando una reducción significativa en comparación a la cuchilla c4. En resumen, los resultados indican que la selección de características influyó significativamente en el desempeño del modelo, y que las cuchillas c1 y c6 parecen ser más adecuadas y estables para este aumento de características.

En base a los resultados obtenidos de las 2 pruebas anteriores, se tomó la decisión de seleccionar 15 características para cada cuchilla. Esto se realizó con el resultado de obtener un modelo que permita hacer predicciones precisas; es decir, reducir el valor del RMSE lo máximo posible. Se consideró importante tomar en cuenta tanto las características coincidentes en las 2 pruebas como las características que no lo fueron para cada cuchilla, ya que esto permitiría obtener una visión más completa y detallada de las particularidades de cada una de ellas en el proceso de fresado, ya que se observó que en la primera prueba el valor del RMSE se mantuvo constante en la mayoría de las 3 cuchillas. En la segunda prueba, se observó que el valor del RMSE varió entre las tres cuchillas evaluadas. Aunque en general los valores de RMSE fueron bajos y cercanos entre sí, se encontraron diferencias significativas en el rendimiento de las cuchillas. Al mantener el mismo número de características seleccionadas en ambas pruebas, se pudo evaluar con mayor precisión las diferencias en el comportamiento del RMSE para cada cuchilla entre ambas pruebas. Esto permitió comparar el rendimiento de las cuchillas en ambas pruebas de manera más justa y precisa.

De las dos pruebas se encontró que se repiten siete características para c1, cinco características para c4 y quince características para c6, entonces faltan ocho características para c1, diez características para c4 y ninguna característica para c6 para completar la lista final de 15 características para cada cuchilla. Las características faltantes se completan de las listas que tienen 15 características diferentes o iguales para cada cuchilla, debido a que se considera que estas características podrían no tener un impacto significativo en la reducción del RMSE.

Los resultados del RMSE, C, ϵ , γ y kernel han sido obtenidos para las dos pruebas previamente mencionadas. Para comparar los resultados de las dos pruebas se juntaron todos los RMSE para las tres cuchillas (ver Figura 19), y se logra ver el crecimiento o disminución del valor del RMSE para cada una de las tres cuchillas. En cuanto a la cuchilla c1, se observó el comportamiento prácticamente idéntico del RMSE entre la primera y segunda prueba. Sin embargo, en el caso de la cuchilla c4, se observaron diferencias en el valor del RMSE en las primeras cinco y dos últimas

características entre la primera y segunda prueba. Por otro lado, en la cuchilla c6 no se observaron diferencias en el valor del RMSE entre la primera y segunda prueba.

Además, se decidió mantener el margen de cantidades de características seleccionadas para ambas pruebas, lo que significa que se eligieron 15 características de una sola lista para las tres cuchillas, a fin de asegurarse de que los resultados fueran comparables. Al mantener el mismo número de características seleccionadas como en ambas pruebas, se pudo evaluar con mayor precisión las diferencias en el comportamiento del RMSE para cada una de las cuchillas. Esto se debe a que, al mantener el mismo número de características, se está evaluando el rendimiento de cada cuchilla con la misma cantidad de información relevante en ambas pruebas, lo que permite una comparación más justa y precisa. De esta manera, se pueden identificar las diferencias en el rendimiento de cada cuchilla con mayor confianza y determinar cuál es la cuchilla que ofrece mejores resultados.

Los resultados obtenidos previamente son alentadores, ya que se ha logrado un acercamiento notable entre los desgastes medidos y predichos para las tres cuchillas, lo cual es una buena noticia en comparación con otros trabajos en la misma área. Así mismo se realizó un análisis detallado donde se observó que el valor del RMSE fue menor en la cuchilla c1 en comparación a las otras 2 cuchillas c4 y c6. Sin embargo, es importante destacar que a pesar de la diferencia significativa en los valores de RMSE entre las cuchillas, en general los resultados son positivos por tener el RMSE menor a 10 en los tres casos. Un RMSE menor a 10 indica que el modelo está haciendo predicciones con un error aceptablemente bajo, lo que sugiere que las características seleccionadas y el modelo utilizado son adecuados para la predicción del desgaste.

En la investigación, se procedió a seleccionar un total de 15 características para las tres cuchillas, como se muestra en la Tabla 19, siguiendo los mismos criterios de selección mencionados anteriormente (ver ítem 4.2). Luego de seleccionar la lista de características se observa que se redujo aún más el valor de RMSE para cada cuchilla a comparación de resultados anteriores. Se puede observar en la tabla 20 los valores de C, ϵ , γ y kernel que son usados en la lista de 15 características para cada cuchilla. Al reducir el número de características de 45 a solo 15 características, se logró mejorar considerablemente las predicciones para toda la base de datos (c1, c4 y c6).

En cuanto a las cuchillas individuales, los resultados del entrenamiento y validación se muestran a continuación:

Cuchilla c1:

En relación a la cuchilla c1, se pudo observar que durante el proceso de entrenamiento se logró una aproximación satisfactoria en la cuchilla c6, donde se obtuvo un valor de R^2 de 0.88, lo que indica que el modelo utilizado explica un 88% de la variabilidad de los datos. Además, se obtuvo un valor de RMSE de 12.72, lo que significa que no cumple con el valor máximo de 10, y un valor de MAE de 8.95. Estos resultados sugieren que el modelo utilizado en este estudio logró una buena aproximación de los datos de entrenamiento en la cuchilla c1.

Por otro lado, durante el proceso de validación se pudo obtener una buena aproximación de los desgastes, con un valor de R^2 de 0.95, lo que indica que el modelo utilizado en la validación explica un 95% de la variabilidad de los datos. Además, se obtuvo un valor de RMSE de 5.27 y un valor de MAE de 3.47. Estos resultados son prometedores, ya que este valor de RMSE es mucho menor a 10, que sugieren que el modelo utilizado en este estudio tiene la capacidad de realizar una buena aproximación de los desgastes de la cuchilla c1 en un escenario de validación.

Cuchilla c4:

El análisis de los resultados obtenidos durante el proceso de entrenamiento y validación para la cuchilla c4 reveló una clara diferencia en el desempeño del modelo. Durante la fase de entrenamiento, se observó un alejamiento muy notorio de los valores reales, lo que indica que el modelo aún tiene un buen margen de mejora. Sin embargo, se logró un R^2 de 0.89, lo que indica que el modelo explica el 89% de la variabilidad en los datos, lo que es un buen comienzo. Además, se registró un RMSE de 12.01 y un MAE de 9.23 durante el entrenamiento. Estos valores sugieren que el modelo todavía tiene un margen de error significativo en la predicción de los datos de entrenamiento. Sin embargo, estos errores se redujeron en gran medida durante la fase de validación.

Durante la fase de validación, se logró un buen acercamiento de desgastes entre los datos predichos y los reales. El R^2 aumentó significativamente a 0.96, lo que indica que el modelo ahora explica el 96% de la variabilidad en los datos. Además, el RMSE disminuyó significativamente a 5.07. El MAE también se redujo a 3.04, lo que indica que el modelo está haciendo predicciones más precisas. A pesar del buen resultado, el modelo puede ser refinado aún más para mejorar su capacidad de predicción en futuras pruebas.

Cuchilla c6:

Al analizar los resultados del modelo durante el entrenamiento y la validación, se observan diferentes patrones que indican un comportamiento distinto en cada una de estas fases. Durante el entrenamiento, se observó un completo acercamiento en la cuchilla c1 de los datos, lo que indica una buena capacidad de predicción del modelo para estos valores. Sin embargo, en la cuchilla c4 donde hubo un alejamiento un poco mayor, lo que indica una menor precisión en la predicción para estos datos. A pesar de esto, los valores obtenidos en esta fase fueron un R2 de 0.96, lo que indica que el modelo explica el 96% de la variabilidad en los datos. Además, se registró un RMSE de 5.36 y un MAE de 3.56.

En la fase de validación, se observó una mayor separación entre los desgastes medidos y los predichos que en los casos anteriores. Esto indica que el modelo tiene una menor capacidad de predicción para los datos de validación. Los valores obtenidos en esta fase fueron un R2 de 0.89, un RMSE de 13.57 y un MAE de 11.41, lo que sugiere una precisión baja en la predicción.

Al analizar los valores de RMSE obtenidos de cada cuchilla, se encontró que la cuchilla c4 presentó el menor valor de RMSE entre los desgastes medidos y predichos.

Al utilizar únicamente las 15 características seleccionadas previamente (ver ítem 4.3), se procedió a eliminar una característica a la vez para las tres cuchillas, con el resultado de identificar la lista de características más relevante para la predicción del desgaste. Durante este proceso, se observó que para la cuchilla c1, el valor del RMSE no varió significativamente hasta que se redujeron a 4 características, luego de lo cual se observa un aumento de RMSE progresivamente hasta alcanzar su valor máximo en una sola característica. Para c4, el RMSE crece rápidamente al retirar una característica y luego tiende a disminuir hasta llegar a su mínimo en la octava característica. Al reducir el número de características el RMSE tiende a aumentar. En el caso de la cuchilla c6, se logró reducir el valor del RMSE en el proceso de eliminación de características hasta que se llegó a tener cinco características; luego hay un ligero aumento hasta llegar a tener dos características. Con una sola característica el valor del RMSE aumenta significativamente.

El comportamiento del RMSE desde 15 características hasta una característica se presenta en la Tabla 21 y Figura 33. Allí se observa que en las cuchillas c1 y c6 el valor del RMSE no cumple con el requisito de ser menor a 10 para una sola característica, por

lo tanto, una sola característica no es suficiente para lograr una buena predicción. Por ello se elige una mayor cantidad de características.

El resultado final de la investigación consistía en reducir el RMSE. Tras varios intentos, se logró obtener el mejor resultado en las tres cuchillas al utilizar 6, 7 y 8 características. Este resultado también consideraba usar el menor número de características posible que permitiera alcanzar los mejores resultados en la tesis. Finalmente, se logró elegir únicamente 4 características debido a que fueron las más estables y permitieron obtener una reducción en el RMSE con la menor cantidad de características posible con un reducido costo computacional para luego ser comparado con las 60 características y se podría aumentar el número de cálculos para comprobar el tiempo en algoritmos más intensivos, simplemente puedes aumentar el valor en el rango del bucle for, por ejemplo, 10^{**7} o 10^{**8} , dependiendo de cuán intensivos sean tus cálculos. Tener en cuenta que a medida que aumentes la cantidad de cálculos, el tiempo de ejecución también aumentará, lo que te permitirá tener una mejor idea de cuánto tiempo requiere tu código para ejecutarse en condiciones más demandantes.

CAPÍTULO V

V. CONCLUSIONES

En esta sección, se presentan las principales conclusiones obtenidas en la investigación y se resumen los resultados del modelo propuesto para la predicción del desgaste de la cuchilla de una fresadora CNC. Se analizan las respuestas a cada una de las preguntas planteadas en la problemática abordada.

En conclusión, la creación de un diagrama de flujo puede ser una herramienta efectiva para visualizar y comprender el proceso de predicción del desgaste de una cuchilla. Al identificar los componentes de cada parte en el sistema y cómo interactúan entre sí se obtiene una guía que permite un buen control de los pasos a seguir. Sin embargo, es importante tener en cuenta que el éxito de este proceso dependerá de la precisión de los datos recopilados y del análisis realizado para hacer la predicción.

En el primer objetivo indica que se utilizó a detalle la metodología basada en el aprendizaje automático a través de la aplicación de SVR para predecir el desgaste de la cuchilla en una fresadora CNC. El proceso de entrenamiento y validación se realizó varias veces hasta obtener resultados óptimos que permitieran una buena predicción. Además, se comparó el desgaste medido y predicho mediante pruebas de entrenamiento y validación que son mostradas en las figuras para visualizar la efectividad de las predicciones de desgaste. Como resultado, se concluyó que el método utilizado es efectivo para predecir el desgaste de la cuchilla en la fresadora CNC.

En conclusión, el proyecto se enfoca en la implementación de un modelo de aprendizaje automático que pueda predecir el desgaste de la cuchilla en una fresadora CNC a partir de señales adquiridas. La selección de características es un aspecto crítico del proceso, ya que determina la precisión de las predicciones obtenidas mediante el modelo. Por lo tanto, es esencial elegir adecuadamente las características más relevantes para las 3 cuchillas en el proceso de entrenamiento y validación del modelo para lograr obtener 15 características con un RMSE menor a 10 en cada cuchilla. Este enfoque puede ser útil en aplicaciones industriales para mejorar la eficiencia y prolongar la vida útil de las herramientas, lo que a su vez puede mejorar la productividad y reducir costos.

Se concluye que es crucial seleccionar un número óptimo de características de la base de datos en la predicción del desgaste de la cuchilla de una fresadora CNC. Al hacerlo, se puede disminuir el costo de procesamiento computacional, lo que resulta en

un proceso de predicción más eficiente y efectivo. Al seleccionar solo las características más relevantes, se logra reducir la cantidad de datos procesados, lo que disminuye el costo computacional y aumenta la eficiencia del proceso de predicción.

En este proyecto, el objetivo principal es utilizar el aprendizaje automático para aproximar el desgaste medido y el desgaste predicho durante el proceso de fresado CNC. Para lograr la precisión del desgaste de la cuchilla, se debe buscar el mínimo error (RMSE) de predicción. Una de las técnicas utilizadas para mejorar la precisión del desgaste es mediante la selección de características más relevantes. Es decir, después de evaluar varias combinaciones o listas de características, se seleccionaron las cuatro características que permitieron una aproximación del desgaste medido y el desgaste predicho con un RMSE menor a 10. Estas características se consideraron las más relevantes para contribuir de manera significativa a la precisión en la predicción del desgaste. Un fabricante que quisiera predecir el desgaste de la cuchilla de una fresadora CNC podría evaluar si estas 4 características también son relevantes para su equipo y piezas de trabajo.

En conclusión, se utilizó una combinación del preprocesamiento de señales y la implementación del modelo de aprendizaje automático SVR para mejorar la precisión de la aproximación del desgaste medido y el desgaste predicho en el fresado CNC. Los resultados obtenidos demostraron que la implementación de este enfoque fue satisfactoria y eficiente en términos de costo computacional. Los resultados sugieren que el uso de SVR en combinación con técnicas de preprocesamiento y selección de características puede lograr una alta precisión en la predicción de datos en aplicaciones industriales que involucren el fresado CNC y la predicción del desgaste de la herramienta de corte. La optimización exhaustiva de hiperparámetros utilizando la herramienta Optuna y la selección de características mejoraron aún más la precisión del desgaste. Se identificó que el número óptimo de características para la mejor predicción fue de cuatro. En general, este enfoque puede ser útil para mejorar la eficiencia y la rentabilidad en el proceso de fresado CNC, reduciendo los costos asociados con el mantenimiento y reemplazo de herramientas.

Se logra cumplir con el objetivo propuesto en el proyecto del concurso E038-01, con contrato No. 020-2019- FONDECYT-BM-INC.INV financiado por los recursos brindados por el CONCYTEC-FONDECYT, al desarrollar la predicción del desgaste de la cuchilla en una fresadora CNC utilizando algoritmos de aprendizaje automático.

CAPÍTULO VI

VI. RECOMENDACIONES

- ✓ Para implementar una solución eficaz, es esencial considerar varios aspectos clave. En primer lugar, es importante comprender el problema en cuestión y realizar una exploración detallada de los datos disponibles para su uso en la investigación. Además, es fundamental tener claridad sobre el objetivo de la investigación para poder tener un panorama general que permita identificar literatura relevante y útil para el proceso.
- ✓ En vista de que las mediciones de aceleraciones y fuerzas se han demostrado como las variables más importantes para estimar el desgaste de la cuchilla de una fresadora CNC, se recomienda que dichas mediciones se incluyan en el conjunto de datos inicial de futuros proyectos de investigación. Asimismo, se sugiere explorar la posibilidad de incluir otras señales como las ondas ultrasónicas, la presión del fluido de corte, la potencia eléctrica y la temperatura, además de la emisión acústica, que podrían proporcionar resultados aún más precisos.
- ✓ Se podrían mejorar la visualización y análisis de los datos en un sistema de aprendizaje automático, se pueden incorporar diferentes tipos de gráficos, como gráficos de dispersión, de barras, de líneas, de caja y bigotes, y de red.
- ✓ Para mejorar la precisión de las estimaciones, se sugiere explorar la posibilidad de aplicar técnicas avanzadas de aprendizaje automático similares o aprendizaje profundo. Es importante tener en cuenta que la elección del método adecuado dependerá de la naturaleza del problema a resolver y de los datos disponibles.
- ✓ Se recomienda tener como base los antecedentes presentados, existen diversas investigaciones nacionales e internacionales que abordan la predicción de la vida útil de las cuchillas de fresadoras CNC, enfrentando el mismo problema que se presenta en esta investigación. Por lo tanto, se sugiere proponer la implementación integrada de dicha solución a las industrias especializadas en metalmecánica que brindan servicios de fresado CNC, y que puedan incorporarla en sus sistemas. De esta manera, se pueden obtener beneficios significativos para el rendimiento y eficiencia en la producción, lo que a su vez puede traducirse en una mayor competitividad en el mercado.
- ✓ Se recomienda seguir buscando nuevas listas de características y quizás se pueda mejorar la predicción del desgaste de la cuchilla.

- ✓ Se recomienda seguir recolectando datos de desgaste de otras cuchillas en fresadoras CNC para validar y mejorar los modelos de aprendizaje automático de este trabajo.
- ✓ Se sugiere que futuros estudios incluyan un conjunto de datos más amplio y variado, que contemple una cantidad mayor con diferentes tipos de cuchillas y en condiciones de trabajo diferentes. Esto permitirá obtener un modelo más robusto y completo que pueda ser aplicado en diversas situaciones del fresado CNC en la industria metalmecánica.

✓ **Trabajos futuros**

El presente proyecto de tesis sentará las bases para futuras investigaciones y proyectos en el ámbito de la predicción del desgaste en herramientas de corte, lo que contribuirá a mejorar la eficiencia y reducir los costos de los procesos de mecanizado en las fresadoras CNC y en la industria metalmecánica en general. Los conocimientos adquiridos en este proyecto podrán ser utilizados en investigaciones más complejas, empleando métodos avanzados de aprendizaje automático como redes bayesianas o aprendizaje profundo. También se requerirá que se realice estudios experimentales rigurosos y confiables para obtener datos precisos.

CAPÍTULO VII

VII. REFERENCIA BIBLIOGRÁFICAS

- Agrawal, T. (2021). Hyperparameter Optimization Using Scikit-Learn. En T. Agrawal (Ed.), *Hyperparameter Optimization in Machine Learning: Make Your Machine Learning and Deep Learning Models More Efficient* (1st ed. Edición, pp. 31-51). Apress.
https://doi.org/10.1007/978-1-4842-6579-6_2
- Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). Optuna: A Next-generation Hyperparameter Optimization Framework. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2623-2631.
<https://doi.org/10.1145/3292500.3330701>
- Alonso, D. A., Gil, J. E., & Martínez, F. H. (2015). Prototipo de Máquina Fresadora CNC para Circuitos Impresos. *Tekhnê*, 12(1), Art. 1.
- Alpaydin, E. (2022). *Maschinelles Lernen*. De Gruyter. <https://doi.org/10.1515/9783110740196>
- Altintas, Y. (2012). *Manufacturing automation: Metal cutting mechanics, machine tool vibrations, and CNC design* (2nd ed). Cambridge University Press.
https://assets.cambridge.org/97811070/01480/frontmatter/9781107001480_frontmatter.pdf
- Arango, I., & Pineda, F. (2010). Desarrollo de Tecnología para la Fabricación de Máquinas CNC para Corte de Tendidos de Tela para Pequeños Talleres de Confección. *Tecnológicas*, 11.
<https://doi.org/10.22430/22565337.303>
- Arias, V. A., Vargas-Machuca, J., Zegarra, F. C., & Coronado, A. M. (2021). Convolutional Neural Network Classification for Machine Tool Wear Based on Unsupervised Gaussian Mixture Model. *2021 IEEE Sciences and Humanities International Research Conference (SHIRCON)*, 1-4. <https://doi.org/10.1109/SHIRCON53068.2021.9652266>

- Awad, M., & Khanna, R. (2015). Support Vector Regression. En M. Awad & R. Khanna (Eds.), *Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers* (pp. 67-80). Apress. https://doi.org/10.1007/978-1-4302-5990-9_4
- Ayyadevara, V. K. (2018). *Pro Machine Learning Algorithms, A hands-On Approach to Implementing Algorithms in Python and R*. Apress. https://doi.org/10.1007/978-1-4842-3564-5_6
- Bi, D., Li, Y. F., Tso, S. K., & Wang, G. L. (2004). Friction Modeling and Compensation for Haptic Display Based on Support Vector Machine. *IEEE Transactions on Industrial Electronics*, 51(2), 491-500. <https://doi.org/10.1109/TIE.2004.825277>
- Carrillo Rosales, A. J. (2019). Sistema inteligente basado en Machine Learning para la detección de fraude de facturación de agua potable. *Repositorio de Tesis - UNMSM*. <https://cybertesis.unmsm.edu.pe/handle/20.500.12672/11244>
- Casado, F. (2020). *Mecanizado CNC 4.0* (1st ed. Edición). Marcombo 75. https://books.google.com.pe/books?id=ykxOEAAAQBAJ&pg=PA1&dq=mecanizado+cnc+4.0&hl=es&sa=X&ved=2ahUKEwjs4_Tkt8P3AhV1LLkGHb84CTkQ6wF6BAgLEAE#v=onepage&q=vol&f=false
- Casusol, A. J., Zegarra, F. C., Vargas-Machuca, J., & Coronado, A. M. (2021). Optimal window size for the extraction of features for tool wear estimation. *2021 IEEE XXVIII International Conference on Electronics, Electrical Engineering and Computing (INTERCON)*, 1-4. <https://doi.org/10.1109/INTERCON52678.2021.9532759>
- Chariguamán Tapia, W. D., & Jarrin Gualoto, G. P. (2019). *Análisis de la rugosidad superficial por influencia de la velocidad y profundidad de corte en el torneado de AA7075—T6 mecanizado en un torno CNC*. <http://dspace.ups.edu.ec/handle/123456789/17459>
- Christ, M., Braun, N., Neuffer, J., & Kempa-Liehr, A. W. (2018). Time Series Feature Extraction on basis of Scalable Hypothesis tests (tsfresh – A Python package). *Neurocomputing*, 307, 72-77. <https://doi.org/10.1016/j.neucom.2018.03.067>

Códigos de Programación para Torno CNC G y M. (s. f.). [Informativa]. Scribd. Recuperado 17 de diciembre de 2022, de <https://es.scribd.com/document/426167592/Codigos-de-programacion-para-torno-CNC-G-y-M>

Cournapeau, D. (2022, octubre). *scikit-learn: Machine Learning in Python — documentación de scikit-learn - 1.1.3* [Informativa]. scikit-learn. <https://scikit-learn.org/stable/>

De Máquinas y Herramientas. (2015). *Introducción a la tecnología CNC.*

<https://www.demaquinasyherramientas.com/mecanizado/introduccion-a-la-tecnologia-cnc>

Deisenroth, M. P., Faisal, A. A., & Ong, C. S. (2020). *Mathematics for Machine Learning.*

Cambridge University Press.

Denkena, B. (2013). *New Production Technologies in Aerospace Industry: Proceedings of the 4th Machining Innovations Conference, Hannover, September 2013.* Springer Science & Business Media.

[https://books.google.com.pe/books?hl=es&lr=&id=RaDjAAAAQBAJ&oi=fnd&pg=PP5&dq=Denkena,+B.+\(2013,+September\).+New+production+technologies+in+aerospace+industry.+In+The+4th+Machining+Innovations+Conference.+%5Bonline%5D+Springer.+Available+at:+https://aalto.+finna.+fi/Record/alli+\(Vol.+695422\).&ots=gelMZ-A3bc&sig=tYx3RbpcBdbF9t77V5C1MM71Whs&redir_esc=y#v=onepage&q&f=false](https://books.google.com.pe/books?hl=es&lr=&id=RaDjAAAAQBAJ&oi=fnd&pg=PP5&dq=Denkena,+B.+(2013,+September).+New+production+technologies+in+aerospace+industry.+In+The+4th+Machining+Innovations+Conference.+%5Bonline%5D+Springer.+Available+at:+https://aalto.+finna.+fi/Record/alli+(Vol.+695422).&ots=gelMZ-A3bc&sig=tYx3RbpcBdbF9t77V5C1MM71Whs&redir_esc=y#v=onepage&q&f=false)

Duboue, P. (2020). *The Art of Feature Engineering: Essentials for Machine Learning.* Cambridge University Press.

Ferguson, M., Bhinge, R., Park, J., Lee, Y. T., & Law, K. H. (2018). A Data Processing Pipeline for Prediction of Milling Machine Tool Condition from Raw Sensor Data. *Smart and sustainable manufacturing systems*, 2, 10.1520/SSMS20180019.

<https://doi.org/10.1520/SSMS20180019>

- geeks. (2021, junio 29). How to check the execution time of Python script ? [Informativa].
GeeksforGeeks. <https://www.geeksforgeeks.org/how-to-check-the-execution-time-of-python-script/>
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media, Inc.
- Haynes, G. (2016). *Milling Machines & Milling Operations-Second Edition: The Fundamentals of Conventional and CNC Milling* (Prensa cibernética). CYBER PRESS. https://cloudflare-ipfs.com/ipfs/bafykbzacec3zaywbnqcqzvgo7mm7n5gy5wsa7544ubdch266knaullz5bmsvm?filename=George%20Haynes%20-%20Milling%20Machines%20%26%20Milling%20Operations-Second%20Edition_%20The%20Fundamentals%20of%20Conventional%20and%20CNC%20Milling-Cyber%20Press%20%282016%29.pdf
- Heller Máquina-Herramienta, S.L. (s. f.). *Fresadora CNC Helfer F4 CNC - Metalmecánica— Fresadora CNC* [Empresarial]. Metalmecanica. Recuperado 23 de enero de 2023, de <http://www.interempresas.net/MetalMecanica/FeriaVirtual/Producto-Fresadora-CNC-Helfer-F4-CNC-49510.html>
- Kaneko, H. (2021). Support vector regression that takes into consideration the importance of explanatory variables. *Journal of Chemometrics*, 35(4), e3327.
<https://doi.org/10.1002/cem.3327>
- Kelly, J. F., & Hood, D. P. (2010). *Build Your Own CNC Machine*. Apress.
- Kibria, G., Jahan, M. P., & Bhattacharyya, B. (2019). *Micro-electrical discharge machining processes. Technologies and Applications* (Springer). J. Paulo Davim, Department of Mechanical Engineering, University of Aveiro, Aveiro, Portugal.
<https://doi.org/10.1007/978-981-13-3074-2>
- Kotu, V., & Deshpande, B. (2018). *Data Science: Concepts and Practice*. Morgan Kaufmann.

- Kubat, M., & Kubat. (2021). *An Introduction to Machine Learning*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-81935-4>
- Li, X., Lim, B. S., Zhou, J. H., Huang, S., Phua, S. J., Shaw, K. C., & Er, M. J. (2009). Fuzzy Neural Network Modelling for Tool Wear Estimation in Dry Milling Operation. *Annual Conference of the PHM Society*, 1(1), Art. 1.
<http://www.papers.phmsociety.org/index.php/phmconf/article/view/1403>
- Liu, C., Zhang, L., Niu, J., Yao, R., & Wu, C. (2020). Intelligent prognostics of machining tools based on adaptive variational mode decomposition and deep learning method with attention mechanism. *Neurocomputing*, 417, 239-254.
<https://doi.org/10.1016/j.neucom.2020.06.116>
- Liu, H., Liu, Z., Jia, W., Lin, X., & Zhang, S. (2020). A novel transformer-based neural network model for tool wear estimation. *Measurement Science and Technology*, 31(6), 065106.
<https://doi.org/10.1088/1361-6501/ab7282>
- Mejía-Ugalde, M. (2014). Teclado con protocolo de comunicación universal aplicado a máquina de CNC. *Ingeniería, Investigación y Tecnología*, 15(2), 209-220.
[https://doi.org/10.1016/S1405-7743\(14\)72211-5](https://doi.org/10.1016/S1405-7743(14)72211-5)
- Mishra, P. (2019). *PyTorch Recipes: A Problem-Solution Approach*. Apress.
[https://books.google.com.pe/books?hl=es&lr=&id=X5OFDwAAQBAJ&oi=fnd&pg=PR5&dq=Mishra,+P.+\(2019\).+PyTorch+Recipes:+A+Problem-Solution+Approach.+Apress.&ots=XdPXK24nUH&sig=T35rDV_WjE3t5QKmgZz01MQl6ho&redir_esc=y#v=onepage&q=Mishra%2C%20P.%20\(2019\).%20PyTorch%20Recipes%3A%20A%20Problem-Solution%20Approach.%20Apress.&f=false](https://books.google.com.pe/books?hl=es&lr=&id=X5OFDwAAQBAJ&oi=fnd&pg=PR5&dq=Mishra,+P.+(2019).+PyTorch+Recipes:+A+Problem-Solution+Approach.+Apress.&ots=XdPXK24nUH&sig=T35rDV_WjE3t5QKmgZz01MQl6ho&redir_esc=y#v=onepage&q=Mishra%2C%20P.%20(2019).%20PyTorch%20Recipes%3A%20A%20Problem-Solution%20Approach.%20Apress.&f=false)
- Muhammad, I. U. (2022, febrero 27). Eliminación de tendencias de series temporales: Estadísticas básicas y análisis de datos [Estadísticas Apuntes de conferencias, MCQ en línea]. *Basic Statistics and Data Analysis*. <https://itfeature.com/time-series-analysis-and-forecasting/detrending-of-time-series>

Narváez Encalada, P. R. (2021). *Construcción de una máquina CNC de tres ejes, para minimizar los problemas medioambientales*. <http://repositorio.ucsg.edu.ec/handle/3317/16240>

Nelson, M. J., & Hoover, A. K. (2020). Notes on Using Google Colaboratory in AI Education. *Proceedings of the 2020 ACM Conference on Innovation and Technology in Computer Science Education*, 533-534. <https://doi.org/10.1145/3341525.3393997>

Nixon, M., & Aguado, A. (2019). *Feature Extraction and Image Processing for Computer Vision* (ELSEVIER, 1-FOURTH). Academic Press.

[https://books.google.com.pe/books?hl=es&lr=&id=KcW-](https://books.google.com.pe/books?hl=es&lr=&id=KcW-DwAAQBAJ&oi=fnd&pg=PP1&dq=Nixon,+M.,+%26+Aguado,+A.+(2019).+Feature+extrac)

[DwAAQBAJ&oi=fnd&pg=PP1&dq=Nixon,+M.,+%26+Aguado,+A.+\(2019\).+Feature+extrac](https://books.google.com.pe/books?hl=es&lr=&id=KcW-DwAAQBAJ&oi=fnd&pg=PP1&dq=Nixon,+M.,+%26+Aguado,+A.+(2019).+Feature+extrac)
[tion+and+image+processing+for+computer+vision.+Academic+press.&ots=10mD7uWE3](https://books.google.com.pe/books?hl=es&lr=&id=KcW-DwAAQBAJ&oi=fnd&pg=PP1&dq=Nixon,+M.,+%26+Aguado,+A.+(2019).+Feature+extrac)
[U&sig=qPNKHWRkcht2jpZVi-](https://books.google.com.pe/books?hl=es&lr=&id=KcW-DwAAQBAJ&oi=fnd&pg=PP1&dq=Nixon,+M.,+%26+Aguado,+A.+(2019).+Feature+extrac)

[cePZ2PLns&redir_esc=y#v=onepage&q=Nixon%2C%20M.%2C%20%26%20Aguado%2C%](https://books.google.com.pe/books?hl=es&lr=&id=KcW-DwAAQBAJ&oi=fnd&pg=PP1&dq=Nixon,+M.,+%26+Aguado,+A.+(2019).+Feature+extrac)
[20A.%20\(2019\).%20Feature%20extraction%20and%20image%20processing%20for%20c](https://books.google.com.pe/books?hl=es&lr=&id=KcW-DwAAQBAJ&oi=fnd&pg=PP1&dq=Nixon,+M.,+%26+Aguado,+A.+(2019).+Feature+extrac)
[omputer%20vision.%20Academic%20press.&f=false](https://books.google.com.pe/books?hl=es&lr=&id=KcW-DwAAQBAJ&oi=fnd&pg=PP1&dq=Nixon,+M.,+%26+Aguado,+A.+(2019).+Feature+extrac)

Núñez Reiz, A., Armengol de la Hoz, M. A., & Sánchez García, M. (2019). Big Data Analysis y Machine Learning en medicina intensiva. *Medicina Intensiva*, 43(7), 416-426.

<https://doi.org/10.1016/j.medin.2018.10.007>

Orozco, M. (2020). Recent (Dis)similarity Measures Between Histograms for Recognizing Many Classes of Plant Leaves: An Experimental Comparison. En D. A. T. Burgos, M. A. Vejar, & F. Pozo (Eds.), *Advances in Computer and Electrical Engineering* (pp. 180-203). IGI Global. <https://doi.org/10.4018/978-1-7998-1839-7.ch008>

PHM society. (2010, mayo 18). 2010 PHM Society Conference Data Challenge [Data Challenge]. *Competition*. https://phmsociety.org/phm_competition/2010-phm-society-conference-data-challenge/

Preprocesamiento de datos en Machine Learning | 6 pasos para el preprocesamiento de datos.

(s. f.). [Educativa]. Preprocesamiento de datos en Machine Learning. Recuperado 14 de

enero de 2023, de <https://es.education-wiki.com/es.education-wiki.com/1053656-data-preprocessing-in-machine-learning>

Raschka, S., & Mirjalili, V. (2019). *Python Machine Learning: Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow 2, 3rd Edition*. Packt Publishing Ltd.
<https://books.google.com.mx/books?hl=es&lr=&id=sKXIDwAAQBAJ&oi=fnd&pg=PP1&dq=Python+Machine+Learning:+Machine+Learning+and+Deep+Learning+With+Python,+Scikit-Learn,+and+TensorFlow+2,+Third+Edition&ots=V9IjqUTILq&sig=mBl16KbFjSzwzgeOxqtpH7gUSy4#v=onepage&q=Python%20Machine%20Learning%3A%20Machine%20Learning%20and%20Deep%20Learning%20With%20Python%2C%20%20Scikit-Learn%2C%20and%20TensorFlow%202%2C%20Third%20Edition&f=false>

Robotics and CNC. (2020). *¿Cómo funciona una máquina CNC? | Censa Industrial*.
<https://censaindustrial.com/como-funciona-una-maquina-cnc/>

ROMI Máquinas España S.A. (s. f.). *Torno CNC Romi C 510—Plástico y Caucho - Torno CNC [Empresarial]*. ROMI TRADICION EN INNOVAR. Recuperado 23 de enero de 2023, de <http://www.interempresas.net/Plastico/FeriaVirtual/Producto-Torno-CNC-Romi-C-510-61179.html>

Sandvik Coromant. (s. f.). *Desgaste en los filos*. Recuperado 13 de julio de 2022, de <https://www.sandvik.coromant.com/es-es/knowledge/materials/pages/wear-on-cutting-edges.aspx>

Sebastián Pérez, M. Á., & Luis Pérez, C. J. (2013). *PROGRAMACIÓN DE MÁQUINAS-HERRAMIENTA CON CONTROL NUMÉRICO* (1st ed. Edición). Editorial UNED.
[https://books.google.com.pe/books?hl=es&lr=&id=sCxDAgAAQBAJ&oi=fnd&pg=PA118&dq=%C3%81ngel,+S.+P.+M.,+%26+Javier,+L.+P.+C.+\(2013\).+Programaci%C3%B3n+de+m%C3%A1quinas-](https://books.google.com.pe/books?hl=es&lr=&id=sCxDAgAAQBAJ&oi=fnd&pg=PA118&dq=%C3%81ngel,+S.+P.+M.,+%26+Javier,+L.+P.+C.+(2013).+Programaci%C3%B3n+de+m%C3%A1quinas-)

- herramienta+con+control+num%C3%A9rico.+Editorial+UNED.&ots=lsZRhr8g-
&sig=9SeQtwmThS0mWkhdk8jH1dkOt0U&redir_esc=y#v=onepage&q&f=false
- Simeone, O. (2018). A Very Brief Introduction to Machine Learning With Applications to Communication Systems. *IEEE Transactions on Cognitive Communications and Networking*, 4(4), 648-664. <https://doi.org/10.1109/TCCN.2018.2881442>
- Suh, S.-H., Kang, S. K., Chung, D.-H., & Stroud, I. (2008). *Theory and Design of CNC Systems*. Springer Science & Business Media.
- Taladro CNC ProArc Drill+ 1020, 1640 Tipo Mesa. (2021). [Productos y Servicios]. *Codinter Colombia*. <https://www.codinter.com/co/producto/taladro-cnc-proarc-drill-1020-1640-tipo-mesa/>
- TecnoEdu. (s. f.). *Programación de máquinas de CNC con códigos G&M* [Informativa]. TecnoEdu Tecnología Educativa S.A. Recuperado 29 de diciembre de 2022, de <https://tecnoedu.com/CNC/GM.php>
- Teti, R., Jemielniak, K., O'Donnell, G., & Dornfeld, D. (2010). Advanced monitoring of machining operations. *CIRP Annals*, 59(2), 717-739. <https://doi.org/10.1016/j.cirp.2010.05.010>
- TRESDE. (2019, abril 22). *Todo sobre las máquinas CNC*. <https://tresde.pe/todo-sobre-las-maquinas-cnc/>
- Wang, J., Li, Y., Zhao, R., & Gao, R. X. (2020). Physics guided neural network for machining tool wear prediction. *Journal of Manufacturing Systems*, 57, 298-310. <https://doi.org/10.1016/j.jmsy.2020.09.005>
- Wang, J., Wang, P., & Gao, R. X. (2015). Enhanced particle filter for tool wear prediction. *Journal of Manufacturing Systems*, 36, 35-45. <https://doi.org/10.1016/j.jmsy.2015.03.005>
- Wang, J., Xie, J., Zhao, R., Zhang, L., & Duan, L. (2017). Multisensory fusion based virtual tool wear sensing for ubiquitous manufacturing. *Robotics and Computer-Integrated Manufacturing*, 45, 47-58. <https://doi.org/10.1016/j.rcim.2016.05.010>

- Wang, J., Yan, J., Li, C., Gao, R. X., & Zhao, R. (2019). Deep heterogeneous GRU model for predictive analytics in smart manufacturing: Application to tool wear prediction— ScienceDirect. *ELSEVIER*, 111, 14. <https://doi.org/10.1016/j.compind.2019.06.001>
- Wang, P., & Gao, R. X. (2015). Adaptive resampling-based particle filtering for tool life prediction. *Journal of Manufacturing Systems*, 37, 528-534. <https://doi.org/10.1016/j.jmsy.2015.04.006>
- Webmaster. (2019, octubre 26). ¿Cómo funciona una máquina CNC? *Censa Industrial*. <https://censaindustrial.com/como-funciona-una-maquina-cnc/>
- Wei-Meng, L. (2019). *Python Machine Learning*. John Wiley & Sons. https://books.google.com.pe/books/about/Python_Machine_Learning.html?id=IUbduAEACAAJ&redir_esc=y
- Wu, X., Li, J., Jin, Y., & Zheng, S. (2020). Modeling and analysis of tool wear prediction based on SVD and BiLSTM. *The International Journal of Advanced Manufacturing Technology*, 106(9), 4391-4399. <https://doi.org/10.1007/s00170-019-04916-3>
- Youssef, H., & El-Hofy, H. (2020). *Non-Traditional and Advanced Machining Technologies*. CRC Press.
- Zegarra, F. C., Vargas-Machuca, J., & Coronado, A. M. (2022). Tool wear and remaining useful life (RUL) prediction based on reduced feature set and Bayesian hyperparameter optimization. *Production Engineering*, 16(4), 465-480. <https://doi.org/10.1007/s11740-021-01086-8>
- Zhang, X., Lu, X., Li, W., & Wang, S. (2021). Prediction of the remaining useful life of cutting tool using the Hurst exponent and CNN-LSTM. *The International Journal of Advanced Manufacturing Technology*, 112(7), 2277-2299. <https://doi.org/10.1007/s00170-020-06447-8>

Zhao, R., Wang, D., Yan, R., Mao, K., Shen, F., & Wang, J. (2018). Machine Health Monitoring Using Local Feature-Based Gated Recurrent Unit Networks. *IEEE Transactions on Industrial Electronics*, 65(2), 1539-1548. <https://doi.org/10.1109/TIE.2017.2733438>

Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., & Gao, R. X. (2019). Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 115, 213-237. <https://doi.org/10.1016/j.ymssp.2018.05.050>

Zhao, R., Yan, R., Wang, J., & Mao, K. (2017). Learning to Monitor Machine Health with Convolutional Bi-Directional LSTM Networks. *Sensors*, 17(2), Art. 2. <https://doi.org/10.3390/s17020273>

ANEXOS

Anexo 1. Glosario de términos

A continuación, se presentan algunas definiciones de términos presentes en la Tesis:

Aprendizaje automático. - Es un subcampo de la inteligencia artificial (IA) que es un término amplio que se refiere a sistemas o máquinas que imitan la mente humana, se enfoca en diseñar sistemas que aprenden o mejoran el rendimiento en función de los datos no estructurados logrando intentar entender por sí mismo.

Aprendizaje No Supervisado. - Es una de las técnicas de aprendizaje automático que consiste en aprender de los datos etiquetados que el algoritmo debe tratar de comprender por sí mismo.

Aprendizaje Supervisado. - Es una rama del aprendizaje automático, siendo un método de análisis de datos que utiliza algoritmos que aprenden iterativamente de los datos de entrenamiento para permitir que las computadoras encuentren o deduzcan la información oculta sin tener que programar explícitamente dónde buscar.

Árboles de decisión. - Es un mapa de posibles resultados de una serie de decisiones relacionadas siendo un modelo de predicción permitiendo que un individuo o una organización.

Característica. – Es una propiedad medible de una serie temporal.

Control Numérico Computarizado (CNC). - Es el control automático de una máquina herramienta para realizar tareas mecánicas específicas.

Red neuronal convolucional (CNN). – Es uno de los algoritmos de aprendizaje profundo más efectivos que aprende directamente de los datos, porque es un modelo de programación poderoso que sin necesidad de extraer características manuales que básicamente permite modelos de clasificación o patrones de imágenes para reconocer objetos, caras y escenas al asignar automáticamente la entrada con una etiqueta apropiada para la clase a la que pertenece.

Desgaste. – Es la pérdida progresiva del material, debido a un modo de contacto o sin que éste se presente por el tiempo de vida.

Foxconn. - Principalmente un fabricante de productos electrónicos a sus clientes que son empresas líderes en tecnología de los Estados Unidos, Europa y Japón.

Fresadora. - Máquina provista de fresas que sirve para labrar metales

Fricción. - Es la fuerza que existe entre dos superficies en contacto que se opone al movimiento relativo entre ambas superficies (fuerza de fricción dinámica).

Google Colaboratory (Colab). - Es un servicio gratuito que combina las funciones de Jupyter Notebooks con máquinas virtuales alojadas en Google y hardware de alta gama.

Modelo de mezcla gaussiana (GMM). - Este algoritmo permite determinar las distintas categorías probabilísticas de modelos bien entrenados para tratar de modelar los datos que provienen de varios grupos.

Hiperparámetros. – Los parámetros ajustables y configurables en algoritmos de aprendizaje que permiten controlar el proceso de entrenamiento de un modelo de datos reales.

Husillo. – Eje rotatorio que cuenta con un accesorio que sujeta a la herramienta de corte en la fresadora.

Mecanizado. - Proceso de elaboración mecánica de piezas en distintas formas y acabados para distintos tipos de máquinas (tornos, fresadoras, etc.).

Optimización bayesiana. – Es una técnica basada en el teorema de Bayes para buscar de forma eficiente el mínimo global.

Optuna. – Es un entorno de trabajo que permite la búsqueda de hiperparámetros de forma automática.

The Prognostics and Health Management Society (PHM Society). - La Sociedad de Pronósticos y Gestión de la Salud.

Python. - Es un lenguaje de programación con alto nivel comprendido para leer y escribir debido a su alta similitud del lenguaje humano, además del código que se utiliza para desarrollar aplicaciones de todo tipo.

Error cuadrático medio (RMSE). – Es la medición de cantidad de error de métricas más comunes utilizadas para regresión que existe entre 2 conjuntos de datos

Servomotor. – Es un motor eléctrico auxiliar para aumentar automáticamente la energía disponible cuando controla tanto en posición, fuerza y aceleración.

Series temporales. – A lo largo del tiempo varían los valores de la variable, recibe el nombre de serie temporal o cronológica teniendo una continuidad de datos en intervalos iguales o desiguales.

Descomposición de valores singulares (SVD). - En álgebra lineal es una matriz real o compleja en una factorización de la misma con muchas aplicaciones en estadística y otras disciplinas, ayudando a reducir los conjuntos de datos que contienen un gran número de valores.

Red neuronal basada en transformador (TBNN). – Esta red neuronal se utiliza en datos secuenciales para aprender dependencias a largo plazo

Velocidad de corte. – Es un término de fabricación que también se conoce como la velocidad instantánea relativa cuando las máquinas, como las fresadoras y las torneadoras, se enfrentan al material que se va a eliminar, es decir, la velocidad cortante.

Vida Útil. - Es el periodo de tiempo que se espera utilizar un equipo o pieza.

Anexo 2. Código de los algoritmos de la tesis

```
pip install --quiet optuna
```

```
from google.colab import drive  
drive.mount('/content/gdrive/')
```

```
import pandas as pd  
import numpy as np  
import matplotlib  
import matplotlib.pyplot as plt  
import seaborn as sns  
import optuna  
from pandas import DataFrame  
from pandas import Series  
from optuna.samplers import TPESampler  
from sklearn import preprocessing  
from sklearn import decomposition  
from sklearn.manifold import LocallyLinearEmbedding, Isomap  
from sklearn.model_selection import train_test_split  
from sklearn.metrics import r2_score, mean_squared_error, mean_absolute_error  
from sklearn.svm import SVR  
from sklearn.ensemble import RandomForestRegressor  
from sklearn.gaussian_process import GaussianProcessRegressor, kernels
```

```
#Ploting styles
```

```
#styles: 'fivethirtyeight', 'classic', 'ggplot', 'seaborn-notebook'
```

```
#styles: 'seaborn-poster', 'bmh', 'grayscale', 'seaborn-whitegrid'
```

```
matplotlib.style.use('ggplot')
```

```
%matplotlib inline
```

```
pd.set_option('display.max_columns', None)
```

```
#print(plt.style.available)
```

```
#Ruta de la lectura de datos
```

```

path_data = "/content/gdrive/My Drive/SHORTCUTS/Data-Original_fresa/"

#Direccionamiento
#Escoger el tamaño de la serie temporal
#'100': Toda la serie temporal
#'100d': Toda la serie temporal + detrend
#'100d_T': Toda la serie temporal + detrend + Corte
tam = '100d_T'

# Lectura de datos
datos_c1_ = pd.read_excel(path_data+'tp_c1'+ '_' +tam+'.xlsx','1').join(pd.read_csv(path_d
ata+'c1_wear.csv'))
datos_c4_ = pd.read_excel(path_data+'tp_c4'+ '_' +tam+'.xlsx','1').join(pd.read_csv(path_d
ata+'c4_wear.csv'))
datos_c6_ = pd.read_excel(path_data+'tp_c6'+ '_' +tam+'.xlsx','1').join(pd.read_csv(path_d
ata+'c6_wear.csv'))

# Considerando sólo las N primeras filas de 315
N = 295
datos_c1 = datos_c1_.copy(deep=True).iloc[:N]
datos_c4 = datos_c4_.copy(deep=True).iloc[:N]
datos_c6 = datos_c6_.copy(deep=True).iloc[:N]

# Elimina primera columna correspondiente al número de fila
datos_c1.drop(datos_c1.columns[0],axis=1,inplace=True)
datos_c4.drop(datos_c4.columns[0],axis=1,inplace=True)
datos_c6.drop(datos_c6.columns[0],axis=1,inplace=True)

# Eliminando columnas no usadas
datos_c1.drop(['cut','flute_2','flute_3','flute_1'], inplace=True, axis=1)
#datos_c1.drop(['Unnamed: 0'], inplace=True, axis=1)
datos_c4.drop(['cut','flute_2','flute_3','flute_1'], inplace=True, axis=1)
#datos_c4.drop(['Unnamed: 0'], inplace=True, axis=1)

```

```
datos_c6.drop(['cut','flute_2','flute_3','flute_1'], inplace=True, axis=1)
#datos_c6.drop(['Unnamed: 0'], inplace=True, axis=1)
```

```
# Eliminando columnas con NaN
```

```
datos_c1.dropna(axis='columns', inplace=True)
```

```
datos_c4.dropna(axis='columns', inplace=True)
```

```
datos_c6.dropna(axis='columns', inplace=True)
```

```
datos_c1['Max_VB'] = datos_c1['Max_VB']-48.893
```

```
datos_c4['Max_VB'] = datos_c4['Max_VB']-31.41635516
```

```
datos_c6['Max_VB'] = datos_c6['Max_VB']-62.78864802
```

```
#Función para combinar las tres bases (c1, c4 y c6).
```

```
#Se logra dividir en entrenamiento y validación.
```

```
#Esta función tiene como entrada el tipo de base que será la validación.
```

```
def Datos_train_test(cx):
```

```
    if cx == 'c1':
```

```
        # c4 + c6 -> c1
```

```
        datos_train = datos_c4.append(datos_c6)
```

```
        datos_test = datos_c1
```

```
    if cx == 'c4':
```

```
        # c1 + c6 -> c4
```

```
        datos_train = datos_c1.append(datos_c6)
```

```
        datos_test = datos_c4
```

```
    if cx == 'c6':
```

```
        # c1 + c4 -> c6
```

```
        datos_train = datos_c1.append(datos_c4)
```

```
        datos_test = datos_c6
```

```
    return datos_train,datos_test
```

```

def metricas(y, y_pred):
    R2 = round(r2_score(y, y_pred) , 2)
    RMSE = round(mean_squared_error(y, y_pred)**(1/2.0) , 2)
    MAE = round(mean_absolute_error(y, y_pred) , 2)
    return(R2, RMSE, MAE)

def objective_svr(trial):
    # X_train, X_valid = X_train_s[name], X_valid_s[name]
    params = {
        'kernel' : trial.suggest_categorical('kernel', ['rbf', 'linear', 'sigmoid']),
        'C' : trial.suggest_loguniform('C', 1e-4, 1e4),
        'epsilon' : trial.suggest_loguniform('epsilon', 1e-4, 1e3),
        'gamma' : trial.suggest_loguniform('gamma', 1e-4, 1e3),
    }

    m_svr = SVR(**params)
    m_svr.fit(X_train, y_train)
    y_pred_test = m_svr.predict(X_test)
    r2, rmse, mae = metricas(y_test, y_pred_test)
    return rmse

# Elegir la base de entrenamiento y validación
cx='c1'
datos_train,datos_test=Datos_train_test(cx)

# Definiendo datos de entrenamiento y validación
X_train_ = datos_train.copy()
y_train = X_train_.pop('Max_VB')
X_test_ = datos_test.copy()
y_test = X_test_.pop('Max_VB')

```

```

#Preprocesamiento
#Extrae nombres de las columnas
nombres_X = X_train_.columns.tolist()

#Define escalador
scalerX = preprocessing.MinMaxScaler()
#scalerX = preprocessing.StandardScaler()
#scalerX = preprocessing.RobustScaler()
#scalerX = preprocessing.QuantileTransformer(n_quantiles=250, random_state=0)

scalerX = scalerX.fit(X_train_)

X_train_s = scalerX.transform(X_train_)
X_test_s = scalerX.transform(X_test_)

X_train_s = pd.DataFrame(X_train_s, columns=nombres_X)
X_test_s = pd.DataFrame(X_test_s, columns=nombres_X)

lista = X_train_s.columns.tolist()

def genera_list_feat(lista_t, feat_sel):
    lista_total = lista_t.copy()
    for j in feat_sel:
        lista_total.remove(j)

    nueva_lista = []
    for k in lista_total:
        nueva_lista = nueva_lista + [feat_sel + [k]]
    return(nueva_lista)

lista_features_ffe=genera_list_feat(lista,feat_selec)
lista_features_ffe[:5]

```

```

# Ingeniería de características hacia adelante

df_rmse = pd.DataFrame()
df_parm = pd.DataFrame()
dict_study = { }
optuna.logging.disable_default_handler()
counter = 1
for i in lista_features_ffe:
    print("<<<<  " + str(counter) + " " + str(i) + "  >>>>")
    X_train, X_test = X_train_s[i], X_test_s[i]
    study = optuna.create_study(direction='minimize', sampler=TPESampler(multivariate=True))
    study.optimize(objective_svr, n_trials=300)
    df_rmse = df_rmse.append({'feature': str(i), 'RMSE': study.best_value}, ignore_index=True)
    df_parm = df_parm.append(study.best_params, ignore_index=True)
    dict_study[str(i)] = study.trials_dataframe()
    counter = counter + 1

```

```

# Ingeniería de características hacia atrás
# Lista de características seleccionados
# En el caso que se inicie dejar como: feat_selec=[ ]
feat_selec=[ ]

# lista_features_ffe=genera_list_feat(lista,feat_selec)
# lista_features_ffe[:5]

```

```

df_rmse = pd.DataFrame()
df_parm = pd.DataFrame()
dict_study = { }
optuna.logging.disable_default_handler()

counter = 1
# for i in lista_features_ffe:

```

```

i=feat_selec
print("<<< " + str(i) + " " + str(i) + " >>>")
X_train, X_test = X_train_s[i], X_test_s[i]
study = optuna.create_study(direction='minimize', sampler=TPESampler(multivariate=True))
df_parm = df_parm.append(study.best_params, ignore_index=True)
dict_study[str(i)] = study.trials_dataframe()
counter = counter + 1

#Costo computacional
plt.figure(figsize=(16,4))
plt.plot(df_rmse.RMSE,'bo')
plt.xlabel('Feature')
plt.ylabel('RMSE')

min(df_rmse.RMSE)

df_rmse[df_rmse.RMSE < 8]

index_fs = (df_rmse.loc[(df_rmse.RMSE == min(df_rmse.RMSE)), "feature"]).index[0]
index_fs

df_rmse.iloc[index_fs]

df_rmse.iloc[index_fs][1]

df_parm.iloc[index_fs].to_dict()

name_fs = lista_features_ffe[index_fs]
X_train_fs = X_train_s[name_fs]
X_test_fs = X_test_s[name_fs]

m_svr = SVR(**(df_parm.iloc[index_fs].to_dict()))

```

```
m_svr.fit(X_train_fs, y_train)
y_pred_train = m_svr.predict(X_train_fs)

y_pred_test = m_svr.predict(pd.DataFrame(X_test_fs))
```

```
plt.figure(figsize=(10,6))
plt.plot(y_train,'bo')
plt.plot(y_pred_train,'ro')
plt.legend(['Medido','Pred'], loc='upper right')
plt.xlabel("Número de corte")
plt.ylabel("Desgaste (µm)")
```

```
R2, RMSE, MAE = metricas(y_train, y_pred_train)
print("**Entrenamiento**")
print('R2 = ', R2)
print('RMSE = ', RMSE)
print('MAE = ', MAE)
```

```
plt.figure(figsize=(10,6))
plt.plot(y_test,'bo')
plt.plot(y_pred_test,'ro')
plt.legend(['Medido','Pred'], loc='upper right')
plt.xlabel("Número de corte")
plt.ylabel("Desgaste (µm)")
R2, RMSE, MAE = metricas(y_test, y_pred_test)
```

```
print("**Validación**")
print('R2 = ', R2)
print('RMSE = ', RMSE)
print('MAE = ', MAE)
```

Anexo 3. Matriz de consistencia

Tesista: Jaime Jair Paima Sahuma

Tesis: Predicción del desgaste de la cuchilla en una fresadora CNC utilizando algoritmos de machine learning.

PROBLEMA	OBJETIVOS	VARIABLES	METODOLOGÍA
Problema General	Objetivo General	Variable independiente:	Enfoque de investigación: Cuantitativo Alcance de Investigación: RMSE < 10 Diseño de la investigación: No experimental Predictivo Técnica de recolección de información: - Revisión documental - Descarga de base de datos - Análisis de resultados de series temporales Instrumento de recolección de datos: - Ficha Documental de Investigación - Bases de datos informáticas - Algoritmos de predicciones
¿Cómo predecir en un tiempo óptimo el desgaste de la cuchilla de una fresadora CNC?	Utilizar las señales que se obtienen durante el proceso de fresado en un algoritmo de aprendizaje automático para realizar la predicción del desgaste de la cuchilla de una fresadora CNC con un reducido costo computacional.	Datos de Fuerza, Aceleración y Emisión Acústica de la cuchilla de una Fresadora CNC.	
Problemas Específicos	Objetivos Específicos		
¿Cómo extraer grupos de características de la fuerza, aceleración y emisión acústica de la cuchilla?	Implementar un modelo de aprendizaje automático a partir de las señales adquiridas de la cuchilla en una fresadora CNC para seleccionar los grupos de características.		
¿De qué manera se puede disminuir el costo de procesamiento computacional en la predicción del desgaste de la cuchilla en la fresadora CNC?	Seleccionar una cantidad óptima de características de la base de datos para lograr disminuir el costo de procesamiento computacional en la predicción del desgaste de la cuchilla en una fresadora CNC.	Variable dependiente: Predicción del desgaste.	
¿Cómo predecir el desgaste de la cuchilla en el tiempo y la reducción del costo computacional?	Implementar un modelo de aprendizaje automático con los datos de la cuchilla en una fresadora CNC para la predicción del desgaste de la cuchilla en el tiempo y la reducción del costo computacional.		
¿Cómo seleccionar el mínimo error de predicción en los datos de la cuchilla de la fresadora CNC?	Realizar las predicciones del desgaste original y del desgaste corregido de la cuchilla en una fresadora CNC para la verificación final y encontrar el mínimo error de predicción.		

Anexo 4. Presupuesto de la tesis

Tabla 28

Presupuesto de la tesis

CUADRO DE PRESUPUESTO				
Criterio	Concepto	Cantidad	Precio unitario	Monto total
Bienes				
	Laptop	1	S/ 3,820.00	S/ 3,820.00
	Impresora	1	S/ 400.00	S/ 400.00
	Papel bond A4	1 millar	S/ 20.00	S/ 20.00
	USB	1	S/ 35.00	S/ 35.00
Servicios				
	Electricidad	6	50	S/ 300.00
	Internet	6	100	S/ 600.00
	Fotocopia	100	S/ 0.20	S/ 20.00
	Manteniendo de computadora	1	S/ 120.00	S/ 120.00
Subvención del investigador				
	Tesista	10	S/ 800.00	S/ 8,000.00
TOTAL				S/ 13,315.00

Anexo 5. Contrato del financiamiento



UNIVERSIDAD NACIONAL
TECNOLÓGICA DE LIMA SUR

“Año del Bicentenario del Perú: 200 años de independencia”

CONTRATO DE LOCACIÓN DE SERVICIOS N°121-UNTELS-2021

Conste, por el presente documento, el Contrato de Locación de Servicios que celebra, de una parte, la Universidad Nacional Tecnológica de Lima Sur, con RUC N° 20502245032 con domicilio real en Av. Bolívar s/n Sector 3, Grupo 1 Mz. A. Sub. Lote 03 distrito de Villa el Salvador - Lima, debidamente representada por el Ing. CORZO SOTELO PORFIRIO identificado con DNI N° 06034081, encargado con Resolución de Comisión Organizadora N° 019-2020-UNTELS 31/01/2020 en su calidad de Director General de Administración de la UNTELS, a quien en adelante se le denominará LA ENTIDAD, y, de otra parte, Sr. JAIME JAIR PAIMA SAHUMA, identificado con DNI N° 73478926, RUC N° 10734789262, y con domicilio, Mz. A Lt. 14 Sector 3 Grupo 9, distrito Villa el Salvador, Provincia y distrito Lima, quien en adelante se le denominará EL LOCADOR, en los términos y condiciones siguientes:

CLÁUSULA PRIMERA. - OBJETO DEL CONTRATO

La Universidad Nacional Tecnológica de Lima Sur es una Institución de Derecho Público Interno creada por Ley N° 27413, con sede en el distrito de Villa El Salvador provincia y departamento de Lima.

El presente contrato tiene por objeto contratar el SERVICIO DE UN TESISISTA, bajo la modalidad de SERVICIO DE CONSULTORÍA INDIVIDUAL y bajo el marco de las normas de contrataciones del BANCO MUNDIAL y de la ENTIDAD, para el logro de metas operativas (cumplimiento de hitos) en la ejecución del SUB-PROYECTO “Hacia la manufactura avanzada: gemelos digitales y análisis de datos de una máquina herramienta” en adelante el VICEPRESIDENCIA DE INVESTIGACION, CONTRATO N° 020-2019-FONDECYT-BM-INC.INV “INCORPORACIÓN DE INVESTIGADORES” de LA ENTIDAD requiere contar con los servicios de un (a) TESISISTA para desempeñar las siguientes funciones:

- A. Desarrollo y comparación de modelos de machine learning para la predicción de desgaste en máquinas CNC.
- B. Uso de algoritmos tales como random forest y XG Boost para comparar su desempeño en una base de datos experimental. Inicialmente se trabajará en la reducción de dimensionalidad de los datos, los cuales están en torno a los 10 GB.
- C. Codificación de los features, dado que dichos algoritmos no pueden procesar series temporales de manera directa.
- D. Entrenamiento de los algoritmos y se analizarán los resultados obtenidos, y las conclusiones.

PRIMER PRODUCTO:

Informe mensual de avance de actividades correspondiente al mes de Abril 2021.

SEGUNDO PRODUCTO:

Informe mensual de avance de actividades correspondiente al mes de Mayo 2021.

TERCER PRODUCTO:

Informe mensual de avance de actividades correspondiente al mes de Junio 2021.

CUARTO PRODUCTO:

Informe mensual de avance de actividades correspondientes al mes de Julio 2021.

QUINTO PRODUCTO:

Informe mensual de avance actividades correspondientes al mes de Agosto 2021.

SEXTO PRODUCTO:

Informe mensual de avance actividades correspondientes al mes de Septiembre 2021.

SÉPTIMO PRODUCTO:

Informe mensual de avance de actividades correspondientes al mes de Octubre 2021.

OCTAVO PRODUCTO:

Informe mensual de avance actividades correspondientes al mes de Noviembre 2021.

NOVENO PRODUCTO:

Informe mensual de avance actividades correspondientes al mes de Diciembre 2021.

EL LOCADOR declara tener la preparación, conocimiento y experiencia para brindar los servicios requeridos y efectuar las acciones que requiere LA ENTIDAD.

CLÁUSULA SEGUNDA. - NATURALEZA DEL CONTRATO

El presente contrato es de naturaleza civil y obliga a EL LOCADOR a realizar dicho servicio en forma personal y presencial, en los lugares que señale LA ENTIDAD.





www.untehs.edu.pe

Av. Bolívar S/N, sector 3, grupo 1, mz A, sub lote 3
Villa El Salvador - Lima - Perú
(01) 715 8878



UNIVERSIDAD NACIONAL TECNOLÓGICA DE LIMA SUR

“Año del Bicentenario del Perú: 200 años de independencia”

EL LOCADOR declara que el presente contrato lo suscribe libre y voluntariamente, sin limitación alguna, y manifiesta que está debidamente inscrito en el Registro de Contribuyentes y que, por tanto, su RUC tiene vigencia.

Igualmente, las partes dejan claramente establecido que éste es un Contrato de Locación de Servicios efectuado al amparo de los artículos N° 1764, 1765, 1766, 1767, 1768, 1769 y 1770 del Código Civil. En tal sentido, entre las partes no hay relación de trabajo susceptible de la aplicación del Decreto Legislativo N.° 276 y su reglamento aprobado por Decreto Supremo N.° 005-90-PCM, ni ninguna norma que rige a los servidores de la actividad privada. Está regido por las normas de la Ley de Presupuesto General de la República y el Código Civil, en lo que es aplicable.

Queda establecido por las partes que entre ellas no hay relación laboral o Contrato de Trabajo, así como no hay dependencia laboral de **EL LOCADOR** con **LA ENTIDAD**, toda vez que su actividad la realiza en forma autónoma.

Las partes convienen que para el cumplimiento de sus fines **EL LOCADOR** puede utilizar a terceros con aceptación de **LA ENTIDAD**; éstos no tienen relación directa ni indirecta con **LA ENTIDAD** y, por tanto, corresponde **EL LOCADOR** atender las obligaciones que deriven con sus dependientes.

Las partes contratantes convienen y aceptan que, para la verificación, calificación y conformidad de servicio, será del **CONTRATO N° 020-2019-FONDECYT-BM-INC.INV “INCORPORACIÓN DE INVESTIGADORES”** quien lo realice, con su personal específicamente señalado para el efecto, verifique el cumplimiento del servicio materia de este contrato.

CLÁUSULA TERCERA. - VIGENCIA Y RESOLUCIÓN DEL CONTRATO

El presente contrato tendrá eficacia anticipada Del 01 de abril al 31 de diciembre del 2021; sin embargo, antes del vencimiento de dicho plazo, cualquiera de las partes podrá darle término al contrato por incumplimiento de las obligaciones contractuales, siendo que en el caso de **EL LOCADOR**, este podrá también ponerle fin a la prestación de servicio por justo motivo antes del vencimiento del plazo estipulado y siempre que no cause perjuicio a **LA ENTIDAD**. Asimismo, **LA ENTIDAD** podrá resolver unilateralmente el contrato antes del vencimiento del plazo sin mediar causal de incumplimiento alguna, teniendo derecho **EL LOCADOR** al reembolso de los gastos efectuados y a la retribución de los servicios prestados efectivamente a la fecha de resolución contractual conforme lo establece el artículo 1769° del código civil.

CLÁUSULA CUARTA. - OBLIGACIONES

Siendo **LA ENTIDAD** una Institución dedicada a la enseñanza, investigación y proyección a la comunidad, **EL LOCADOR** se obliga a no efectuar actos que contravengan o lesionen las normas, reglamentos y disposiciones que rigen a la Institución o las que emanen de sus autoridades legítimas. En todo caso, **EL LOCADOR** se obliga a adecuar el cumplimiento de sus servicios, materia de este contrato, a dicha normatividad. El coordinador administrativo será contratado, como mínimo con dedicación del 100% de participación en el Sub proyecto, constituyendo 40 horas semanales de manera continua y presencial.

EL LOCADOR es responsable ante la Universidad por los daños y perjuicios que por negligencia, acción u omisión cause a **LA ENTIDAD**. Igual obligación asume si el daño lo efectúan sus dependientes.

La información obtenida por **EL LOCADOR** dentro del cumplimiento de sus obligaciones, así como sus informes y toda clase de documentos que produzca, relacionados con la ejecución de sus actividades serán confidenciales, no pudiendo ser divulgados, en cumplimiento del Artículo 1.° de la Ley 27588 y Decreto Supremo N.° 019-2002-PCM.

CLÁUSULA QUINTA. - DE LOS HONORARIOS

Las partes convienen que los honorarios pactados ascienden a la suma de **S/ 7,200.00 (SIETE MIL DOSCIENTOS Y 00/100 SOLES)** que será abonada en su Código de Cuenta Interbancario (CCI), según cronograma mensualizado fijado, por **LA ENTIDAD**, previa presentación del correspondiente recibo por honorarios e informe de actividades, así como la conformidad de servicio del **CONTRATO N° 020-2019-FONDECYT-BM-INC.INV “INCORPORACIÓN DE INVESTIGADORES”**.

- Primer Producto S/ 800.00
- Segundo Producto S/ 800.00
- Tercer Producto S/ 800.00
- Cuarto Producto S/ 800.00
- Quinto Producto S/ 800.00
- Sexto Producto S/ 800.00
- Séptimo Producto S/ 800.00
- Octavo Producto S/ 800.00
- Noveno Producto S/ 800.00

CLÁUSULA SEXTA. - DEL PAGO DE TRIBUTOS

EL LOCADOR, en cada oportunidad, otorgará los recibos correspondientes, donde conste el RUC con arreglo a ley, de cuyo valor se retendrán los porcentajes correspondientes por el impuesto o impuestos que resulten aplicables a este tipo de contratación.



www.untels.edu.pe

Av. Bolívar S/N, sector 3, grupo 1, mz A, sub lote 3
Villa El Salvador - Lima - Perú
(01) 715 8878



**UNIVERSIDAD NACIONAL
TECNOLÓGICA DE LIMA SUR**

“Año del Bicentenario del Perú: 200 años de independencia”

CLÁUSULA SÉPTIMA.- VALIDEZ DE NOTIFICACIONES

EL LOCADOR señala como su domicilio, el indicado en la introducción de este contrato, donde válidamente se le efectuaran todas las citaciones, comunicaciones y notificaciones a que hubiera lugar, reconociendo EL LOCADOR como válidas, las citadas comunicaciones que le lleguen a su domicilio aludido, salvo que con anterioridad hubiera comunicado a LA ENTIDAD, variación domiciliaria dentro de la ciudad de Lima.

CLÁUSULA OCTAVA.- SOMETIMIENTO CONVENCIONAL DE COMPETENCIA

Asimismo las partes contratantes declaran libre y voluntariamente que todo litigio o controversia, derivados o relacionados con este acto jurídico, será resuelto vía trato directo o mediante el uso de los mecanismos alternativos de resolución de conflictos establecidos en las normas vigentes y en todo caso de no solucionarse por estas vías; ambas partes se someten a la jurisdicción y competencia de los jueces y tribunales civiles de la provincia de Lima adscritos al Poder Judicial, renunciando expresamente al fuero de sus respectivos domicilios.

En señal de conformidad, las partes contratantes firman el presente contrato por triplicado en la ciudad de Villa El Salvador, al 12 de abril de 2021.



Director General de Administración de la UNTELS
Ing. CORZO SOTELO PORFIRIO
DNI N° 06034081

Sr. Jaime Jair Paima Sahuma
DNI N° 73478926