


UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INGENIERÍA MECÁNICA
SANTIAGO-CHILE



Propuesta de Modelo de Sensorización de Máquinas
Convencionales del Taller MM – SJ para el Pronóstico de
Fallas bajo el paradigma de Industria 4.0

Bernardita Paz Catalán Ramírez

MEMORIA DE TITULACIÓN PARA OPTAR AL TÍTULO DE
INGENIERA CIVIL MECÁNICA

Profesor Guía: Dr. Ing. Jaime Núñez Segovia

Profesor Correferente: Luis Guzmán Bonet

Marzo 2026



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ☒ Memoria o trabajo de título ☐ Tesis de Postgrado

Título del trabajo: Propuesta de modelo de sensorización de máquinas convencionales del Taller MM-SJ para el pronóstico de fallas bajo el paradigma de Industria 4.0

Nombre del candidato(a): Bernardita Paz Catalán Ramírez

Carrera / Grado: Ingeniería Civil Mecánica

Campus: Santiago San Joaquín **Departamento:** Ingeniería Mecánica

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Jaime Núñez Segovia, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

☒ El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

☐ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por (**marcar una opción**):

☐ 6 meses ☐ 12 meses ☐ 2 años ☐ 3 años ☐ 5 años ☐ 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 08/05/2026

Firma:


Dr.-Ing. Jaime Núñez S.

Estudiante o Candidato(a):

Fecha: 07/04/2026

Firma:


B. Catalan

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.

DEDICATORIA

A José Manuel Catalán Ramírez.

RESUMEN

El objetivo general de este trabajo es proponer un modelo de seguimiento de señales de operación de máquinas fresadoras convencionales, compatible con el modelo para el pronóstico de fallas desarrollado para el Taller Metalmecánico del DIMEC San Joaquín, bajo el paradigma de la Industria 4.0.

En primer lugar, se contextualiza el trabajo mediante una revisión exhaustiva del Estado del Arte, en la cual se abordan las principales tecnologías habilitadoras de la Industria 4.0, mantenimiento, y el desarrollo del Mantenimiento Predictivo 4.0. Asimismo, se examinan los algoritmos de Machine Learning con mayor aplicación en este campo, destacando su potencial para la detección temprana de fallas y la estimación de vida útil remanente.

Posteriormente, se definen los elementos que componen el modelo de seguimiento de señales de operación y pronóstico de fallas. Se continúa, con un levantamiento del estado actual del mantenimiento en el Taller Metalmecánico, evaluando su nivel de madurez en tres dimensiones clave. Este diagnóstico permite identificar brechas existentes y proponer mejoras concretas para avanzar en la transformación digital del taller.

En la siguiente etapa, se establecen los requerimientos técnicos necesarios para la implementación del modelo, especificando sensores, protocolos de comunicación y software de gestión, con el fin de asegurar la compatibilidad con la infraestructura digital ya implementada en el taller.

Como última etapa, se desarrolla un plan piloto del modelo de seguimiento de señales en las máquinas fresadoras convencionales, además de verificar la efectividad de la propuesta en condiciones de operación.

Finalmente, se presenta las principales conclusiones y se plantea como línea de trabajo futuro la implementación progresiva del modelo y la incorporación de la etapa predictiva mediante algoritmos de Machine Learning.

ABSTRACT

The general objective of this work is to propose a signal monitoring model for conventional milling machines, compatible with the fault prognosis model previously developed for the Metalworking Workshop at DIMEC San Joaquín, under the Industry 4.0 paradigm.

First, the study is contextualized through a comprehensive state of the art review that addresses the main enabling technologies of Industry 4.0, maintenance, and the development of Predictive Maintenance 4.0. In addition, the machine learning algorithms most widely applied in this field are examined, highlighting their potential for early fault detection and the estimation of remaining useful life.

Subsequently, the elements that compose the signal monitoring and fault prognosis model are defined. The analysis then continues with an assessment of the current state of maintenance at the Metalworking Workshop, evaluating its maturity level across three key dimensions. This diagnosis makes it possible to identify existing gaps and to propose concrete improvements to advance the workshop's digital transformation.

In the next stage, the technical requirements necessary for the implementation of the model are established, specifying sensors, communication protocols, and management software, with the aim of ensuring compatibility with the digital infrastructure already deployed in the workshop.

As a final stage, a pilot plan for the signal monitoring model on conventional milling machines is developed, in addition to verifying the effectiveness of the proposal under operating conditions.

Finally, the main conclusions are presented, and as a line of future work, the progressive implementation of the model and the incorporation of the predictive stage through Machine Learning algorithms are proposed.

GLOSARIO

ASCII: American Standard Code for Information Interchange.

CMMS: Sistema Computarizado de Gestión del Mantenimiento.

CNN: Convolutional Neural Network.

CPS: Sistemas Ciberfísicos.

ERP: Planificación de Recursos Empresariales.

FMECA: Análisis de Modos de Fallo, Efectos y Criticidad.

GBM: Gradient Boosting Machine.

GPU: Unidad de Procesamiento Gráfico.

IA: Inteligencia Artificial.

IoT: Internet de las Cosas.

LAN: Red de Área Local.

LSTM: Long Short-Term Memory.

ML: Machine Learning.

MTBF: Tiempo Medio Entre Fallas.

MTTR: Tiempo Medio de Reparación.

PM4.0: Mantenimiento Predictivo 4.0.

RA: Realidad Aumentada.

RCM: Mantenimiento Centrado en Confiabilidad.

RNN: Red Neuronal Recurrentes.

RUL: Vida Útil Remanente.

SSID: Identificador de Conjunto de Servicio.

SVM: Support Vector Machine.

TCP/IP: Transmission Control Protocol / Internet Protocol.

TMM: Taller Metalmecánico.

WSN: Redes de Sensores Inalámbricos.

XGBoost: Extreme Gradient Boosting.

ÍNDICE

DEDICATORIA.....	ii
RESUMEN.....	iii
ABSTRACT.....	iv
GLOSARIO	v
ÍNDICE.....	vi
ÍNDICE DE FIGURAS	ix
ÍNDICE DE TABLAS.....	x
INTRODUCCIÓN.....	xi
OBJETIVOS	xii
PLAN DE TRABAJO.....	xiii
1.Estado del Arte	15
1.1 Industria 4.0	15
1.2 Tecnologías de la Industria 4.0	16
1.2.1 Big Data	17
1.2.2 Robots	18
1.2.3 Impresión 3D.....	19
1.2.4 Simulación.....	19
1.2.5 Sistemas Ciberfísicos	20
1.2.6 Internet de las Cosas	21
1.2.7 Cloud Computing.....	22
1.2.8 Realidad Aumentada	23
1.2.9 Ciberseguridad	24
1.3 Mantenimiento 4.0	24
1.4 Mantenimiento Predictivo 4.0.....	27
1.5 Modelo de Implementación de Mantenimiento Predictivo 4.0.....	29
1.6 Algoritmos de Machine Learning Aplicados al Mantenimiento Predictivo.	32

1.6.1 Árboles de Decisión y Random Forest	34
1.6.2 Regresión Lineal	35
1.6.3 Gradient Boosting Machine	35
1.6.4 Support Vector Machine	36
1.6.5 Redes Neuronales Recurrentes	37
1.6.6 Long Short-Term Memory	38
1.6.7 Convolutional Neural Networks	38
1.7 Sensores	39
1.7.1 Sensor de Velocidad	42
1.7.2 Sensor de Temperatura	42
1.7.3 Sensores de Presión	43
1.7.4 Sensores de Humedad	43
1.7.5 Sensor de Sonido	44
1.7.6 Sensor de Vibración.....	44
2.Modelo de Seguimiento de Señales y Predicción de Fallas.....	45
2.1 Clasificación del Valor de Activos y Selección de Activos	45
2.2 Modelación de Confiabilidad.....	46
2.3 Selección de ERP/CMMS	50
2.4 Monitoreo del Rendimiento	52
2.5 Selección de Algoritmo Predictivo y/o Basado en Condición	53
2.6 Pronóstico de Posibles Fallas	54
3.Evaluación del Estado Actual del Mantenimiento 4.0 en el Taller MM	56
3.1 Caracterización del Taller Metalmecánico	56
3.2 Evaluación del Mantenimiento.....	58
3.3 Propuesta de Expansión del Modelo de Mantenimiento	63
4.Requerimientos Técnicos	66
4.4 Selección de Algoritmo de Machine Learning.....	71
4.4.1 Algoritmos Propuestos para la Estimación de RUL	72
4.4.2 Criterios de Evaluación y Ponderación	73
4.4.3 Comparación y Análisis de Algoritmos	74
5.Plan Piloto	77

5.1	Clasificación del Valor y Selección de Activos del TMM.....	77
5.2	Modelación de la confiabilidad TMM.....	78
5.3	Implementación de ERP/CMMS en el TMM.....	82
5.4	Monitoreo del Rendimiento en Tiempo Real de Activos del TMM.....	85
5.5	Implementación del Algoritmo Predictivo o de Condición.....	87
5.6	Pronóstico de Posibles Fallas.....	88
5.7	Verificación de la Efectividad	89
CONCLUSIONES.....		91
BIBLIOGRAFÍA.....		93
ANEXOS		101
Anexo 1. Análisis FMECA de Subsistemas		101

ÍNDICE DE FIGURAS

Figura 1: Plan de Trabajo.	xiii
Figura 2: Tecnologías de la Industria 4.0 [3].	17
Figura 3: Diferencias entre nube privada y nube pública [14].	23
Figura 4: Tecnologías de la Industria 4.0 presentes en el Mantenimiento 4.0 [21].	27
Figura 5: Modelo de Seguimiento de Señales de Operación y Pronóstico de Fallas [24].	30
Figura 6: Diagrama esquemático de una entrada y salida de un sensor [47].	39
Figura 7: Matriz de riesgo [57].	50
Figura 8: Arquitectura de red para adquisición de datos para sensores en el taller.	68
Figura 9: Vista del dashboard de la plataforma Fractal.	83
Figura 10: Vista menú principal plataforma Fractal.	84
Figura 11: Sensor Fractal Sense [66].	85

ÍNDICE DE TABLAS

Tabla 1: Categorías de consecuencias por fallas [57].	49
Tabla 2: Categorías de frecuencia [57].	50
Tabla 3: Nivel de madurez y su descripción.	59
Tabla 4: Niveles de madurez de cada dimensión.	59
Tabla 5: Ponderación de criterios de selección para el algoritmo de Machine Learning...	74
Tabla 6: Resultado de comparación de algoritmos.	74
Tabla 7: Activos existentes TMM [64].	78
Tabla 8: Especificaciones técnicas fresadora.	78
Tabla 9: Fallas funcionales y Modo de falla del husillo.	80
Tabla 10: Efectos y consecuencias de posibles modos de falla del husillo.	81
Tabla 11: Jerarquización del riesgo según modos de falla para el husillo.	82
Tabla 12: Especificaciones técnicas Facttal Sense Pulse	86
Tabla 13: Fallas funcionales y Modo de falla del carro longitudinal.	101
Tabla 14: Efectos y consecuencias de posibles modos de falla del carro longitudinal....	102
Tabla 15: Jerarquización del riesgo según modos de falla para el carro longitudinal.	103
Tabla 16: Fallas funcionales y Modo de falla de la ménsula.	103
Tabla 17: Efectos y consecuencias de posibles modos de falla de la ménsula.	104
Tabla 18: Jerarquización del riesgo según modos de falla para la ménsula.	104
Tabla 19: Fallas funcionales y Modo de falla del cabezal vertical.	105
Tabla 20: Efectos y consecuencias de posibles modos de falla del cabezal vertical.	106
Tabla 21: Jerarquización del riesgo según modos de falla para el cabezal vertical.	107

INTRODUCCIÓN

Durante la historia de la humanidad, se ha visto marcada por tres grandes revoluciones industriales. La primera revolución industrial, iniciada en 1784 se caracterizó por la aplicación del vapor a la producción, la segunda en 1870 con la introducción de la electricidad en la producción, y la tercera en 1960 por la automatización, cada una de estas revoluciones ha aportado en un gran avance tecnológico, facilitando el diario vivir de las personas.

En la actualidad, nos encontramos inmersos en la llamada cuarta revolución industrial, que está transformando la forma en que vivimos y nos relacionamos. Esta revolución es la transformación profunda de los sistemas de producción industriales impulsada por tecnologías avanzadas como la digitalización, la automatización, y la interconectividad de las máquinas, por lo que resulta fundamental para las industrias incorporar las tecnologías de la Industria 4.0 en sus procesos para mantener su competitividad en el mercado.

Una herramienta fundamental que contribuye a la transformación digital para la Industria 4.0 son los sensores, dado que facilitan la interconectividad de las máquinas, puesto que estos son los responsables de captar información en tiempo real relevante para posteriormente, hacer un manejo y análisis de toda la información captada para poder conseguir el control de los procesos y el mantenimiento predictivo efectivo.

Hoy en día contar con las tecnologías de la Industria 4.0 es fundamental para mantenerse competitivo. La Universidad Técnica Federico Santa María se caracteriza por “aprendizaje basado en la experiencia” por lo que se hace necesario adoptar tecnologías de la Industria 4.0 dentro del Taller Metalmecánico, campus San Joaquín, para que así los estudiantes de ingeniería puedan adoptar estos conocimientos y competencias dentro de la universidad, es por esto que este trabajo de título propone un modelo de seguimiento de señales y pronóstico de fallas para el taller metalmecánico para que los estudiantes puedan adquirir estos conocimientos en su formación dentro de la universidad que les permitirá tener mejores herramientas para el mundo laboral.

OBJETIVOS

Este trabajo tiene como objetivo general proponer un modelo de seguimiento de señales de operación de máquinas fresadoras convencionales, compatible con el modelo para el pronóstico de fallas desarrollado para el Taller Metalmecánico del DIMEC San Joaquín, bajo el paradigma de la Industria 4.0.

Para cumplir con el objetivo general, se establecen los siguientes objetivos específicos:

- Definir los elementos que componen el modelo de seguimiento de señales de operación y predicción de fallas.
- Evaluar el estado actual del Mantenimiento 4.0 en el Taller Metalmecánico y proponer mejoras para ampliar la transformación digital.
- Definir los requerimientos técnicos de los sensores, protocolos de comunicación y software para el almacenamiento y tratamiento de datos para la incorporación de máquinas fresadoras al modelo.
- Realizar a modo de Plan Piloto, la implementación inicial del modelo, utilizando los equipos, sensores y software disponibles para verificar la efectividad del modelo propuesto.

PLAN DE TRABAJO

Con el fin de cumplir con los objetivos propuestos, se ha desarrollado el siguiente plan de trabajo, que da pauta de una secuencia lógica de las etapas para el desarrollo del trabajo. Este plan propuesto se presenta en la Figura 1:




Figura 1: Plan de Trabajo.

Este plan consta de 5 etapas las cuales se describen a continuación:

1. Estado del Arte. Esta etapa se realiza el Estado del Arte del mantenimiento en la Cuarta Revolución Industrial, además de las tecnologías asociadas a la Industria 4.0 y los algoritmos de Machine Learning utilizados en el Mantenimiento 4.0. Además, se presenta una revisión sobre sensores, considerando los tipos, características y funciones que desempeñan.
2. Definición del Modelo de Seguimiento de Señales de Predicción de Fallas. En esta etapa, se define el Modelo de Seguimiento de Señales y Predicción de Fallas. Se identifican y describen cada elemento que conforma el modelo.
3. Evaluación del estado actual del Mantenimiento 4.0 en Taller MM. En esta etapa se evalúa el estado del mantenimiento en el taller, se establece el nivel de madurez del Mantenimiento 4.0 en tres dimensiones y se determinan las principales falencias, para finalmente proponer mejoras al mantenimiento actual.
4. Requerimientos Técnicos. En este capítulo se definen los requerimientos técnicos necesarios para la implementación del sistema de monitoreo y

predicción de fallas. Se establecen los criterios y las especificaciones técnicas de los sensores a utilizar, los protocolos de comunicación que se emplean para la transmisión de datos, y el software requerido para el almacenamiento y procesamiento de la información recopilada. Además, se propone el algoritmo de Machine Learning óptimo para predecir fallos.

5. Plan Piloto. En esta etapa se lleva a cabo el modelo propuesto en la segunda etapa modo de plan piloto para fresadoras convencionales, y se verifica la efectividad del modelo.

1. Estado del Arte

En este capítulo se presentan los conceptos clave para fundamentar y contextualizar este trabajo. En primer lugar, se expone el origen y la evolución de la Industria 4.0, junto con las tecnologías habilitadoras que la componen. A continuación, se revisa la evolución del mantenimiento industrial desde sus primeras etapas hasta el concepto de Mantenimiento 4.0, destacando las ventajas operacionales de su implementación y su impacto en la eficiencia productiva.

Posteriormente, se continúa con el análisis de los principales algoritmos de aprendizaje automático utilizados en el ámbito del mantenimiento predictivo, tanto supervisados como no supervisados. Finalmente, se presenta una caracterización detallada de los sensores industriales utilizados para la medición de variables críticas en equipos productivos, abordando sus principios de funcionamiento y parámetros técnicos.

1.1 Industria 4.0

El término Industria 4.0 fue introducido por primera vez durante la feria industrial Hannover Messe en 2011 [1] que constituye el comienzo de la cuarta revolución industrial que simboliza la tendencia actual de tecnologías de automatización en la industria manufacturera. Esta revolución tecnológica tiene como principal objetivo la fusión del mundo físico con el mundo digital, mediante la implementación de sistemas ciberfísicos, el Internet de las Cosas, la inteligencia artificial y el análisis masivo de datos.

Este enfoque busca mejorar la productividad, flexibilidad y eficiencia operativa, permitiendo además un alto grado de personalización en las operaciones industriales y de la cadena de suministro. A través de la implementación de tecnologías inteligentes tales como sensores, plataformas de software integradas y sistemas robóticos autónomos, las máquinas adquieren la capacidad de comunicarse entre sí e interactuar de manera autónoma, generando así una visibilidad completa de la cadena productiva en tiempo real. En este contexto, las decisiones operacionales se fundamentan en datos continuamente

actualizados, lo que permite ajustar la asignación de recursos de acuerdo con las variables del entorno operativo [1].

En el ámbito del mantenimiento industrial, la Industria 4.0 ha impulsado mejoras significativas en estrategias como el mantenimiento predictivo. La incorporación de sensores inteligentes, capaces de monitorear variables críticas del proceso productivo, y la utilización de algoritmos de mantenimiento predictivo basados en analítica avanzada de datos permiten detectar tempranamente fallas potenciales en los equipos antes de que estas ocurran. Estudios recientes indican que la aplicación efectiva de estas tecnologías puede reducir los tiempos de detención no programada hasta en un 50% y prolongar la vida útil operativa de los activos en aproximadamente un 40% [2].

Asimismo, la Industria 4.0 habilita la visibilidad en tiempo real a lo largo de toda la cadena de suministro, integrando información sobre niveles de inventario, programas de producción, comportamiento de la demanda, estado de proveedores y rendimiento de equipos. Esto permite optimizar procesos logísticos, mejorar el cumplimiento de pedidos y garantizar el control continuo sobre la calidad del producto.

En este contexto, la implementación de tecnologías propias de la Industria 4.0 representa un cambio paradigmático en la forma de operar y gestionar sistemas productivos, aportando beneficios como el aumento en la disponibilidad y eficiencia de los equipos, una asignación de recursos más precisa y una mejora sustancial en la productividad general del sistema.

1.2 Tecnologías de la Industria 4.0

La Industria 4.0 se sustenta en el desarrollo acelerado y la integración avanzada de diversas tecnologías digitales, las cuales están provocando una profunda transformación en los procesos industriales. Estos cambios impactan significativamente en el diseño, manufactura, gestión y operación de productos y sistemas industriales, marcando un hito fundamental en la evolución histórica de los modelos productivos y de gestión tecnológica.

Dentro del contexto de la Industria 4.0, las tecnologías desempeñan un papel central, operando de forma interconectada y complementaria, generando oportunidades sustanciales para la optimización, la eficiencia y la innovación. Estas tecnologías permiten la creación de entornos de producción altamente flexibles, adaptativos y autónomos, mejorando sustancialmente las capacidades operativas y competitivas de las organizaciones. En la Figura 2 se presentan algunas de las tecnologías más relevantes que impulsan este nuevo paradigma:




Figura 2: Tecnologías de la Industria 4.0 [3].

Las tecnologías clave que sustentan la Industria 4.0 son el Internet de las Cosas (IoT), Big Data, Robots, Impresión 3D, Simulación, Sistemas Ciberfísicos (CPS), Realidad Aumentada (RA), Ciber Seguridad y Computación en la nube.

1.2.1 Big Data

El término Big Data hace referencia a grandes volúmenes de datos que, debido a su variedad, velocidad de generación y complejidad estructural, no pueden ser gestionados de manera eficiente mediante métodos tradicionales de administración de bases de datos. Actualmente es posible almacenar, procesar y analizar estos datos con el objetivo de extraer información relevante para la toma de decisiones informadas [4].

Uno de los primeros desafíos al trabajar con Big Data radica en la selección del método adecuado para el almacenamiento de la información recopilada. Actualmente, existen dos enfoques principales para abordar este aspecto. El primero consiste en almacenar los datos mediante infraestructura física local, como computadores y servidores propios, alternativa que puede implicar altos costos iniciales y limitaciones de escalabilidad. Por otra parte, es posible optar por servicios de almacenamiento en la nube, que ofrecen mayor flexibilidad, escalabilidad y menores costos asociados a infraestructura.

Una vez almacenados, los datos deben ser procesados para su posterior análisis. En la actualidad, una de las herramientas más utilizadas para este propósito es Hadoop, marco de trabajo que permite el procesamiento distribuido de grandes volúmenes de datos a través de clústeres, optimizando así el rendimiento y la eficiencia del sistema [5].

La etapa final corresponde al análisis de los datos, proceso mediante el cual se identifican patrones, tendencias o correlaciones que permiten extraer valor desde la información disponible. Este análisis puede ser aplicado, por ejemplo, a la predicción del comportamiento de activos físicos, lo cual resulta de gran utilidad para estrategias de mantenimiento predictivo y optimización operativa [5].

Big Data plantea desafíos relevantes en términos de almacenamiento, procesamiento y análisis de información, sin embargo, el desarrollo de tecnologías especializadas ha permitido superar estas barreras y aprovechar el potencial contenido en los datos masivos para generar conocimiento útil y mejorar la toma de decisiones en contextos industriales complejos.

1.2.2 Robots

Los robots, también denominados máquinas inteligentes, se caracterizan por su capacidad para automatizar tareas que anteriormente eran ejecutadas exclusivamente por seres humanos [6]. En el contexto industrial, la tendencia actual se orienta hacia la automatización progresiva de los procesos productivos, siendo los robots uno de los pilares fundamentales para alcanzar dicho objetivo.

Estas máquinas están diseñadas y programadas para ejecutar tareas de forma autónoma o con una mínima intervención humana, lo que contribuye a mejorar la eficiencia operativa, minimizar la incidencia de errores y aumentar la productividad en entornos de alta demanda. En función de sus características técnicas y propósito, existen robots de diversos tipos, tamaños y niveles de complejidad. Entre ellos, se pueden encontrar desde drones utilizados para el escaneo y control de inventarios, hasta robots móviles autónomos destinados a operaciones específicas como pick and place, dentro de líneas de producción automatizadas [7].

1.2.3 Impresión 3D

La impresión 3D, también conocida como manufactura aditiva, es una tecnología que permite la fabricación de piezas mediante la superposición secuencial de capas de material, tomando como base un modelo digital previamente diseñado. A diferencia de los métodos tradicionales de manufactura, este proceso no requiere el uso de moldes, lo que le otorga una mayor flexibilidad y eficiencia en la producción de geometrías complejas [6].

La impresión 3D ofrece ventajas significativas para la reproducción de piezas y objetos cuya fabricación conlleva ciertas dificultades, ya sea por la especificidad y complejidad de su diseño o porque conlleva muchas horas de trabajo. Por lo tanto, la manufactura aditiva se utiliza para prototipar y para producir componentes individuales muy específicos en lotes pequeños o series cortas [8].

1.2.4 Simulación

La simulación de entornos virtuales, también conocida como gemelo digital, consiste en la representación digital de una máquina, proceso o sistema físico, replicando su comportamiento en tiempo real antes de su puesta en marcha [9]. Esta herramienta permite anticipar fallas potenciales, reducir tiempos de implementación y evaluar el desempeño de una operación en un entorno controlado y seguro.

El uso de gemelos digitales facilita a las organizaciones la comprensión, análisis y optimización del rendimiento de productos y sistemas industriales, así como la gestión eficiente de su mantenimiento [9]. Esta tecnología permite disminuir los costos asociados a procesos de prueba y error, al posibilitar la evaluación de configuraciones operacionales o el diseño de nuevos productos mediante simulaciones virtuales, sin comprometer los recursos reales de la planta productiva.

1.2.5 Sistemas Ciberfísicos

Los sistemas ciberfísicos (CPS) son estructuras integradas que combinan componentes físicos y elementos cibernéticos, los cuales interactúan de forma interconectada mediante sensores, tecnologías de computación y redes de comunicación. La adopción de CPS está relacionada con la Industria 4.0, que forma el proceso de combinación de tecnologías y conocimiento, proporcionando autonomía, confiabilidad, sistematicidad y control sin participación humana. Las tendencias tecnológicas clave que subyacen a CPS incluyen Internet de las cosas, Big Data, tecnologías inteligentes, Computación en la nube [10].

Los sistemas ciberfísicos se caracterizan por su capacidad para interactuar con el entorno físico mediante sensores y actuadores, mientras que simultáneamente procesan datos, ejecutan funciones de control y se comunican mediante plataformas digitales. Esta integración permite una gestión más eficiente y precisa en distintos ámbitos de aplicación, tales como la manufactura, la salud, la energía y el transporte y a la vez, procesar datos y comunicarse a través de redes y sistemas cibernéticos

Entre las tecnologías clave que sustentan el funcionamiento de los CPS se encuentran el Internet de las Cosas, el Big Data, la inteligencia artificial y la Computación en la nube. El Internet de las Cosas cumple un rol fundamental, al habilitar la conexión en tiempo real entre los elementos físicos y los sistemas cibernéticos, facilitando la recopilación continua de datos del entorno operativo. Posteriormente, estos datos pueden ser analizados mediante herramientas de Big Data, con el fin de extraer información valiosa para la toma de decisiones.

Por otro lado, la Computación en la nube proporciona la infraestructura necesaria para almacenar y procesar grandes volúmenes de datos generados por los sistemas ciberfísicos. Esto permite acceder a recursos informáticos de manera escalable y eficiente, sin tener que invertir en infraestructuras costosas y de mantenimiento complejo.

1.2.6 Internet de las Cosas

El Internet de las Cosas (IoT) se define como la interconexión de dispositivos físicos a través de redes, ya sean privadas o la red global de Internet, permitiendo que estos objetos sean visibles, interactúen entre sí y compartan información. Estos dispositivos pueden abarcar desde sensores y componentes mecánicos hasta objetos de uso cotidiano, como electrodomésticos o prendas de vestir [11].

En términos funcionales, el IoT se refiere a objetos físicos equipados con sensores, circuitos integrados y capacidades de conectividad, que les permiten recopilar datos del entorno y comunicarse entre ellos o con sistemas remotos. Esta tecnología posibilita una constante recolección y transmisión de datos en tiempo real, lo que habilita una mejor comprensión del entorno operativo y la generación de respuestas automatizadas y adaptativas.

Las aplicaciones del IoT son amplias y abarcan desde entornos domésticos hasta sistemas industriales complejos. En el ámbito industrial, su implementación ha permitido optimizar procesos mediante la integración de sensores conectados que monitorean variables críticas en tiempo real. Estos sensores pueden emitir alertas automáticas ante eventos anómalos, permitiendo a los operadores tomar decisiones correctivas de forma oportuna y con base en información precisa [11].

Dentro del contexto de la Industria 4.0, el IoT cumple un rol fundamental al habilitar la comunicación directa entre dispositivos, equipos y sistemas dentro de una misma planta productiva. Esta capacidad de interacción en tiempo real permite una supervisión continua del estado de operación de los activos, facilitando el monitoreo remoto, la automatización de procesos, la reducción de tiempos de inactividad asociados a mantenimientos imprevistos y la optimización general de la eficiencia productiva.

1.2.7 Cloud Computing

La computación en la nube, también conocida como Cloud Computing, se define como el acceso bajo demanda a recursos informáticos a través de Internet, lo que permite disponer de capacidades de almacenamiento, gestión y procesamiento de datos de manera remota, sin depender de infraestructura física local [12].

Actualmente, el uso de esta tecnología se ha masificado en organizaciones de diversos rubros y tamaños, debido a la versatilidad que ofrece. Su aplicación abarca una amplia gama de servicios, tales como respaldo de información, gestión de correos electrónicos, Big Data y desarrollo de aplicaciones web con acceso remoto para clientes y usuarios [13].

La computación en la nube proporciona ventajas estratégicas clave para las organizaciones industriales. Entre ellas, destaca su elevada flexibilidad, al permitir el acceso remoto a los recursos desde cualquier ubicación con conectividad, favoreciendo así la escalabilidad operativa y el trabajo distribuido. Asimismo, ofrece altos niveles de seguridad, sustentados en infraestructuras avanzadas de protección administradas por equipos especializados en ciberseguridad. Finalmente, la Computación en la nube contribuye a una mayor eficiencia económica, ya que habilita un modelo de costos basado en el consumo efectivo de recursos, evitando inversiones sobredimensionadas en infraestructura física y optimizando la gestión de variaciones en la demanda de capacidad computacional [12], [13].

En cuanto a su infraestructura, existen dos principales modalidades de implementación: la nube privada y la nube pública. La nube privada corresponde a un entorno exclusivo de Computación en la nube destinado a una sola organización. Esta puede ser gestionada internamente por la propia empresa, o bien, ser operada por un proveedor externo especializado en servicios de nube privada [12].

Por otro lado, la nube pública es administrada por un proveedor de servicios que posee, mantiene y actualiza tanto el hardware como el software necesario para el

funcionamiento de la plataforma. Este modelo ofrece acceso compartido a los recursos disponibles, mediante esquemas que garantizan el aislamiento y la seguridad de los datos entre distintos usuarios.

En la Figura 3 se presenta una representación comparativa de los dos modelos de plataforma en la nube. A la izquierda se muestra un entorno de nube privada, donde los recursos están dedicados exclusivamente a una sola organización. A la derecha, se observa el modelo de nube pública, en el cual múltiples empresas comparten una infraestructura común provista por un tercero, manteniendo la separación lógica entre sus datos y operaciones.




Figura 3: Diferencias entre nube privada y nube pública [14].

1.2.8 Realidad Aumentada

La Realidad Aumentada (RA) es una tecnología que permite superponer contenido digital sobre el entorno físico, complementando así la percepción del mundo real con

elementos virtuales [15]. Se basa en sistemas que integran simulación, modelado y virtualización, lo que habilita nuevas formas de diseñar productos y organizar procesos industriales, aportando mayor flexibilidad y dinamismo a lo largo de la cadena productiva.

En entornos industriales, la RA se aplica mediante el uso de dispositivos como lentes inteligentes o equipos móviles, los cuales permiten a los operarios visualizar información relevante en tiempo real. Esta puede incluir datos provenientes de sensores IoT, representaciones digitalizadas de piezas, instrucciones de ensamblaje o reparación, y contenidos de formación técnica, los cuales se proyectan directamente sobre los elementos físicos que se están [16].

1.2.9 Ciberseguridad

La ciberseguridad se ha convertido en un componente esencial para garantizar una implementación segura y efectiva de las tecnologías asociadas a la digitalización industrial. En el contexto de la Industria 4.0, donde convergen múltiples sistemas interconectados mediante plataformas digitales, redes de comunicación e infraestructuras en la nube, la protección frente a amenazas cibernéticas resulta crítica para asegurar la integridad, confidencialidad y disponibilidad de los datos y procesos [17].

La transición hacia modelos de industria inteligente, así como la creciente integración entre los diferentes actores de la cadena de valor a través de Internet, demanda el desarrollo y la aplicación de mecanismos robustos de ciberseguridad en los entornos industriales. Estos mecanismos no solo protegen los activos digitales y físicos frente a accesos no autorizados, sino que también permiten preservar la continuidad operativa, minimizar los riesgos de vulnerabilidad y aumentar la confianza en la adopción de tecnologías emergentes [17].

1.3 Mantenimiento 4.0

La evolución del mantenimiento industrial ha estado estrechamente vinculada al desarrollo de las distintas revoluciones industriales. En sus inicios, el Mantenimiento 1.0 se

caracterizaba por la simplicidad de los equipos y la baja complejidad de las tareas. Las labores de reparación y supervisión eran realizadas principalmente por los mismos operadores, basándose en su experiencia directa y conocimiento empírico del funcionamiento de las máquinas.

Posteriormente, con el avance de la industrialización, se dio paso al Mantenimiento 2.0, donde se produjeron cambios significativos en la forma de adquirir y procesar la información relacionada con el mantenimiento. Las empresas comenzaron a establecer unidades organizativas dedicadas exclusivamente a tareas de mantenimiento y reparación. En este contexto, los datos comenzaron a ser gestionados por personal especializado, y se incorporaron métodos sistemáticos para su documentación y análisis. La información, que anteriormente se almacenaba en la memoria del operario, pasó a registrarse en soportes escritos, permitiendo la aplicación de modelos estadísticos orientados al análisis de tasas de fallas y consumo de repuestos [17].

Con la llegada de la Tercera Revolución Industrial, se produjo una expansión en el uso de tecnologías de la información dentro de los procesos productivos, lo que también impactó directamente en el ámbito del mantenimiento. En esta etapa, las empresas comenzaron a disponer de grandes volúmenes de datos provenientes tanto de la producción como del mantenimiento, facilitando su gestión mediante tecnologías específicas. Se introdujeron los Sistemas de Gestión de Mantenimiento Computarizado (CMMS), junto con el uso de dispositivos electrónicos y computadores que permitieron el control automático de equipos de producción. Como resultado, los datos comenzaron a almacenarse y analizarse mediante sistemas electrónicos de información, lo que incrementó la efectividad del análisis de fallas y optimizó la toma de decisiones [17].

Con la irrupción de la Industria 4.0, surge la necesidad de desarrollar nuevos enfoques, metodologías y herramientas para el mantenimiento, dando lugar al concepto de Mantenimiento 4.0. Este se define como el conjunto de técnicas orientadas a monitorear la condición operativa de los equipos en tiempo real, con el objetivo de predecir fallas inminentes a través del análisis automatizado y del uso de modelos de aprendizaje supervisado y no supervisado. Además, permite prescribir acciones óptimas de mantenimiento, considerando múltiples escenarios y sus posibles interacciones [17].

El Mantenimiento 4.0 se basa en la incorporación de sensores capaces de recopilar datos precisos sobre el estado de operación de los equipos. Esta información es posteriormente analizada para anticipar la ocurrencia de fallas, lo cual permite programar acciones correctivas o preventivas con antelación. Las tecnologías clave que sustentan este enfoque incluyen herramientas de recopilación y análisis de datos, como el IoT, la Computación en la nube, y métodos de análisis predictivo basados en lógica difusa, redes neuronales, algoritmos evolutivos, aprendizaje automático y razonamiento probabilístico. También se consideran tecnologías orientadas a la reparación eficiente de equipos [17].

La integración de tecnologías habilitadoras propias de la Industria 4.0 en los procesos de mantenimiento ha sido clave para avanzar hacia modelos más eficientes y sostenibles. La creciente disponibilidad de datos ha promovido la adopción de tecnologías como IoT y computación en la nube, lo que a su vez ha reforzado la necesidad de aplicar herramientas de Big Data y analítica de datos para la gestión de grandes volúmenes de información y la extracción de patrones ocultos. Además, la impresión 3D se ha incorporado como una solución ágil para la fabricación de repuestos específicos, permitiendo reducir los tiempos de respuesta ante eventualidades [18].

Asimismo, la realidad aumentada ha demostrado un gran potencial en aplicaciones de mantenimiento remoto. Esta tecnología permite la visualización simultánea de entornos virtuales y reales, tanto por parte del operador en terreno como de un asistente remoto. Para ello, se emplean técnicas como visualización óptica, mezcla de video y proyección de imágenes, utilizando dispositivos como tablets, visores montados en cascos o unidades de visualización especializadas, complementadas con sistemas de rastreo [18].

Entre los principales beneficios del Mantenimiento 4.0 se destacan la maximización de la vida útil de los activos, la reducción de tiempos de inactividad no planificada y la optimización de las detenciones programadas. Además, este enfoque contribuye a incrementar la seguridad tanto de los procesos como del personal, reducir el consumo [19] energético y de recursos materiales, y, en consecuencia, generar una disminución significativa en los costos operacionales.

1.4 Mantenimiento Predictivo 4.0

El Mantenimiento Predictivo 4.0 (PM4.0), también denominado mantenimiento inteligente, se define como el conjunto de técnicas instrumentales destinadas a la medición y análisis de variables operativas, con el fin de identificar fallas potenciales en los equipos antes de que estas se materialicen [20]. A diferencia del mantenimiento predictivo tradicional, el Mantenimiento Predictivo 4.0 se apoya en las tecnologías habilitadoras de la Industria 4.0 para automatizar la captura de datos a través de sensores inteligentes, y facilitar su procesamiento y análisis a través de sistemas de información avanzados.

Este enfoque se caracteriza por la integración de sensores, redes de comunicación y herramientas analíticas, lo que permite disponer de datos confiables en tiempo real y generar pronósticos más precisos sobre el comportamiento de los activos. Como resultado, se incrementa la disponibilidad operativa de los equipos y se optimiza la gestión global del mantenimiento industrial.

La Figura 4 muestra un esquema con las principales tecnologías de la Industria 4.0 presentes en el contexto del Mantenimiento 4.0, así como la relación funcional entre ellas.




Figura 4: Tecnologías de la Industria 4.0 presentes en el Mantenimiento 4.0 [21].

El Mantenimiento Predictivo 4.0 representa una evolución hacia un modelo más proactivo, conectado e inteligente, que permite pasar de un enfoque tradicional basado en correcciones reactivas a una gestión predictiva de activos. Esta transformación impacta positivamente en la eficiencia, confiabilidad y rentabilidad de las operaciones industriales [22]. Su fundamento principal es la recopilación masiva de datos mediante sensores instalados en los equipos, los cuales son posteriormente procesados para extraer información útil en tiempo real.

Según Poór, Basl y Zenisek [23], el Mantenimiento Predictivo 4.0 se sustenta en tres pilares fundamentales:

1. Monitoreo de Condición: consiste en la utilización de sensores y dispositivos IoT para recopilar datos operativos del equipo en tiempo real, permitiendo una supervisión continua de su estado.
2. Modelado y Análisis de Datos: a través de técnicas de aprendizaje automático y análisis estadístico, se identifican patrones de comportamiento y se predicen fallas antes de que estas ocurran.
3. Toma de Decisiones Basada en Datos: la información generada permite planificar intervenciones de mantenimiento de forma óptima, minimizando el riesgo de fallas catastróficas y reduciendo tiempos de inactividad.

En la actualidad, el mantenimiento se ha convertido en un factor crítico dentro de la gestión industrial, ya que representa entre un 15% y un 60% del costo total de operación de una planta de manufactura, según el tipo de industria. No obstante, estos costos a menudo no son debidamente identificados ni cuantificados por las organizaciones [22]. En este contexto, la implementación de estrategias predictivas adecuadas se vuelve esencial para reducir costos operativos y mejorar el rendimiento global. Es por esto que se hace esencial tener un mantenimiento adecuado para poder reducir estos costos.

La digitalización de los entornos industriales ha generado un volumen creciente de datos, abriendo nuevas oportunidades para estimar con precisión la vida útil remanente de los activos. Esto permite establecer programas de mantenimiento basados en las

condiciones reales de operación, reduciendo los costos asociados, minimizando los tiempos de parada y mejorando tanto la productividad como la calidad de los procesos [22].

El Mantenimiento Predictivo 4.0 aporta ventajas sustanciales al ciclo de vida de los activos industriales. La capacidad de anticipar con alta fiabilidad la ocurrencia de fallas elimina intervenciones correctivas no programadas, reduce drásticamente los tiempos de inactividad y, en consecuencia, reduce los costos globales de mantenimiento. De forma paralela, la detección temprana de desviaciones operativas incrementa la confiabilidad y la disponibilidad de los equipos, prolongando su vida útil efectiva. Al sustentarse en datos precisos y en tiempo real, este enfoque optimiza la planificación de los recursos técnicos y humanos, racionaliza el uso de repuestos e insumos y refuerza la capacidad de reacción frente a escenarios operacionales complejos, lo que contribuye a una gestión de activos más eficiente y sustentable [22].

1.5 Modelo de Implementación de Mantenimiento Predictivo 4.0

Para proponer un sistema de Mantenimiento Predictivo 4.0, se muestra el modelo de transformación hacia un Mantenimiento Predictivo 4.0 presentado en el libro *Predictive Maintenance 4.0* de Mainnovation y PwC [24], el cual se enfoca en todos los aspectos tecnológicos que se deben abordar de manera progresiva para lograr llegar al estado de madurez de un Mantenimiento Predictivo 4.0.

El modelo que se presenta en la Figura 5, consta de siete pasos en las cuales se detallan las etapas a seguir para una implementación exitosa de un Mantenimiento Predictivo 4.0.




Figura 5: Modelo de Seguimiento de Señales de Operación y Pronóstico de Fallas [24].

A continuación, se presenta cada uno de los siete pasos del modelo de sensorización para el seguimiento de señales de operación y pronóstico de fallas.

1. Clasificación del valor de activos y estudio de viabilidad: consiste en identificar aquellos activos en los que resulta técnica y económicamente viable implementar estrategias de PM4.0, con el propósito de incrementar su confiabilidad operativa. Generalmente, solo los activos clasificados como críticos o de alta relevancia dentro del proceso productivo justifican las inversiones asociadas a esta estrategia. Asimismo, la implementación de PM4.0 debe limitarse a aquellos equipos que permitan la obtención confiable de datos operacionales, condición indispensable para el funcionamiento efectivo del modelo predictivo.
2. Selección de activos para la implementación de Mantenimiento Predictivo 4.0: seleccionar activos, evitando intentar abarcar la totalidad de la planta en una primera instancia. Se recomienda priorizar aquellos equipos que puedan ser integrados en proyectos piloto, permitiendo así evaluar la factibilidad técnica, operativa y económica del modelo. A partir de las lecciones aprendidas en estos

pilotos, se podrá establecer una estrategia de implementación gradual y escalable del Mantenimiento Predictivo 4.0, adaptada a las particularidades de cada tipo de activo.

3. Modelado de confiabilidad: se deben utilizar análisis de confiabilidad por tipo de activo para orientar la decisión en la dirección correcta. Se deben hacer preguntas como; ¿Qué datos se necesita para monitorear las causas y fallas? ¿Qué datos sensoriales y qué conjuntos de datos externos necesitas para esto? ¿Cómo son las diversas causas raíz?
4. Diseño del algoritmo de Mantenimiento Predictivo 4.0: seleccionar el algoritmo más adecuado, aspecto fundamental para asegurar la precisión y calidad de las predicciones. Dado su nivel de complejidad técnica, puede ser necesario contar con el apoyo de especialistas en ciencia de datos, quienes serán responsables del desarrollo e implementación de algoritmos de autoaprendizaje capaces de identificar patrones relevantes y extraer información significativa a partir de grandes conjuntos de datos operacionales.
5. Monitoreo del rendimiento en tiempo real: en esta fase el modelo de Mantenimiento Predictivo 4.0 entra en operación efectiva. El algoritmo procesa y analiza continuamente datos provenientes de múltiples fuentes, tales como sensores integrados en los activos, registros históricos de mantenimiento y fallas, y datos ambientales proporcionados por fuentes externas. El propósito de esta etapa es monitorear y presentar de forma visual e intuitiva el desempeño operativo de los activos en tiempo real.
6. Predicción de fallas: el algoritmo comienza a generar predicciones sobre fallas futuras en los activos. Este proceso puede estar acompañado inicialmente por cierto grado de incertidumbre, debido al limitado conocimiento del personal operativo en materia de análisis avanzado de datos. Por esta razón, se recomienda que el sistema de Mantenimiento Predictivo 4.0 opere inicialmente en paralelo con los procedimientos de mantenimiento existentes, sin ejecutar acciones inmediatas basadas únicamente en sus pronósticos. De este modo, se permite una adopción gradual de la metodología predictiva, posibilitando al

personal adquirir progresivamente confianza en las predicciones generadas por el modelo.

7. Prescripción de tareas preventivas: el algoritmo no solo anticipa la ocurrencia probable de fallas, sino que también recomienda de forma proactiva la acción preventiva más adecuada, seleccionándola a partir de un conjunto predefinido de tareas estándar de mantenimiento. Adicionalmente, el sistema puede automatizar la generación de órdenes de trabajo correspondientes, optimizando así la gestión de activos y asegurando una intervención efectiva para evitar fallas operacionales.

1.6 Algoritmos de Machine Learning Aplicados al Mantenimiento Predictivo

El Mantenimiento Predictivo 4.0 constituye una estrategia proactiva orientada a anticipar fallas y a reducir los tiempos de inactividad no planificados mediante el análisis intensivo de datos operativos [20], [22]. En el marco de la Industria 4.0, el PM 4.0 se ha vuelto indispensable para asegurar una alta disponibilidad operacional de los activos y optimizar los costos totales de mantenimiento [20]. En este contexto, los algoritmos de Machine Learning (ML) cumplen un rol fundamental, dado que posibilitan el análisis eficiente de grandes volúmenes de datos generados por diversas variables operativas, tales como vibraciones, temperaturas y señales acústicas, entre otras [22], [25]. Este análisis permite llevar a cabo tareas esenciales como el monitoreo de condición, el diagnóstico temprano de fallas, la estimación de la vida útil remanente (RUL) y la detección de anomalías.

El Machine Learning, entendido como una subdisciplina de la inteligencia artificial, se centra en el desarrollo de sistemas capaces de aprender automáticamente a partir de los datos, incrementando progresivamente la precisión de sus predicciones sin necesidad de una programación explícita [26]. Desde una perspectiva analítica, un algoritmo es una secuencia definida de pasos de procesamiento estadístico [27]. En particular, los algoritmos de ML son entrenados con el fin de identificar patrones y características relevantes dentro de grandes conjuntos de datos, para posteriormente realizar predicciones o tomar decisiones

fundamentadas en información previamente no observada. Por lo tanto, la calidad del algoritmo es determinante para la precisión de las decisiones y predicciones que pueden obtenerse al procesar nuevos datos.

La aplicación del ML al ámbito del mantenimiento permite detectar patrones y tendencias operativas que resultarían imperceptibles o extremadamente difíciles de identificar mediante métodos manuales o tradicionales. De este modo, la utilización de algoritmos de ML en el contexto del mantenimiento predictivo no solo permite identificar fallas potenciales antes de que estas ocurran, sino también determinar con precisión el momento en que podrían presentarse. Este conocimiento posibilita la planificación precisa de intervenciones de mantenimiento, realizándolas en el momento óptimo, lo que evita afectar la disponibilidad operativa del activo [22], [28].

Los algoritmos de ML pueden clasificarse en tres categorías principales: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje por refuerzo. Sin embargo, en el contexto del Mantenimiento Predictivo 4.0, los enfoques supervisados son los que han alcanzado mayor nivel de aplicación y efectividad [29].

El aprendizaje supervisado consiste en entrenar algoritmos con conjuntos de datos etiquetados, donde las variables de entrada corresponden a mediciones de condición como vibración o temperatura y las salidas representan el estado conocido del equipo como “normal” o “falla”. A través de este proceso, el algoritmo ajusta sus parámetros internos hasta aprender relaciones entre entradas y salidas, logrando posteriormente predecir con precisión el comportamiento de nuevos datos [26], [30]. Este enfoque presenta la ventaja de requerir menos datos de entrenamiento que otros métodos y de permitir validar directamente el rendimiento del modelo comparando sus predicciones con los resultados reales.

En el ámbito del mantenimiento predictivo, los algoritmos supervisados más utilizados incluyen árboles de decisión, bosque aleatorio, regresión lineal, Máquinas de Aumento de Gradiente, Support Vector Machine, Redes Neuronales Recurrentes, Long Short- Term Memory y Convulitional Neural Networks. A continuación, se presentan en detalle sus fundamentos y aplicaciones más relevantes en el diagnóstico y pronóstico de fallas.

1.6.1 Árboles de Decisión y Random Forest

Los árboles de decisión corresponden a modelos predictivos cuya estructura está basada en una jerarquía de decisiones secuenciales. Dichos modelos se representan mediante un conjunto organizado de nodos, en donde cada nodo interno corresponde a una prueba lógica aplicada sobre un atributo específico, y sus ramas representan los resultados posibles derivados de esta evaluación. Por su parte, los nodos hoja contienen la etiqueta de clase o el valor predictivo final. El algoritmo construye dicha estructura mediante un proceso iterativo que divide progresivamente el espacio de características en subconjuntos más pequeños y homogéneos, utilizando para ello criterios estadísticos de impureza, tales como el índice de Gini o la entropía, con el objetivo de encontrar particiones óptimas en los datos [31].

En el contexto del PM 4.0, un árbol de decisión podría utilizar, por ejemplo, umbrales definidos sobre variables operativas como vibración, temperatura y horas acumuladas de funcionamiento para diagnosticar el estado actual de un equipo (normal, degradado o en falla). La principal ventaja de este tipo de modelos radica en su alta interpretabilidad, ya que las reglas generadas pueden ser fácilmente comprendidas y utilizadas por los operadores, facilitando la identificación de las condiciones operativas específicas que conducen a la aparición de fallas [30].

El algoritmo de bosque aleatorio (Random Forest) constituye una extensión del modelo de árbol de decisión que mejora significativamente su precisión y robustez mediante la combinación de múltiples árboles individuales. Cada árbol integrante del bosque se entrena sobre un subconjunto aleatorio tanto de las observaciones como de las variables disponibles, utilizando un procedimiento denominado bagging (agregación por muestreo). El resultado final del modelo proviene de la combinación agregada de las predicciones individuales generadas por cada árbol del conjunto [32].

En aplicaciones relacionadas al PM 4.0, el algoritmo Random Forest ha mostrado una alta efectividad tanto para clasificar el estado operativo de equipos industriales (por ejemplo, clasificación binaria entre estado normal y estado de falla, o categorización

específica de tipos de fallas) como también en tareas de regresión, tales como la predicción precisa de RUL. Por ejemplo, en la industria automotriz, estudios empíricos han demostrado que el modelo de Random Forest supera en rendimiento predictivo a otros métodos tradicionales para anticipar fallas en líneas de producción [30].

1.6.2 Regresión Lineal

La regresión lineal es una técnica fundamental de análisis de datos utilizada para predecir el valor de una variable desconocida en función de otra variable relacionada y conocida. El modelo de regresión lineal asume la existencia de una relación lineal entre las variables de entrada (predictores) y la variable de salida (objetivo), modelando esta relación mediante una ecuación lineal. De este modo, la variable dependiente puede expresarse como una función lineal de una o más variables independientes. Por ejemplo, considerando datos históricos de ingresos y gastos, la regresión lineal podría determinar que los gastos corresponden a la mitad de los ingresos, permitiendo así estimar futuros niveles de gasto a partir de proyecciones conocidas de ingresos [33].

En el ámbito del PM 4.0, la regresión lineal se emplea para modelar tendencias de desgaste y para la estimación de la vida útil remanente en función del tiempo y de las condiciones operativas. Por ejemplo, se podría establecer una relación lineal entre las horas de funcionamiento de un equipo y el nivel de vibración medido, lo que permitiría predecir el tiempo restante antes de la ocurrencia de una falla. La técnica ajusta una línea recta (o un hiperplano en el caso de múltiples variables predictoras) a los datos históricos, bajo el supuesto de linealidad entre las características medidas (por ejemplo, parámetros obtenidos de sensores) y la variable objetivo (como la vida útil remanente) [34] .

1.6.3 Gradient Boosting Machine

El algoritmo Gradient Boosting Machine (GBM) es una técnica de algoritmo por conjuntos de modelos (ensamble). Su funcionamiento se basa en la construcción secuencial

de árboles de decisión de poca profundidad, en los cuales cada árbol busca corregir los errores (residuos) cometidos por el conjunto de árboles previamente entrenados. De esta forma, múltiples clasificadores débiles se combinan de manera aditiva para conformar un modelo robusto, en el que cada árbol aporta una corrección parcial y las salidas ponderadas se integran para generar la predicción final [35].

En el contexto de mantenimiento predictivo, los GBM han demostrado ser muy eficaces [34]. Dentro de esta familia de algoritmos destacan implementaciones optimizadas como XGBoost (eXtreme Gradient Boosting), que incorporan mejoras orientadas a acelerar los tiempos de entrenamiento y a incrementar el rendimiento del modelo [36]. Por ejemplo, en un estudio de clasificación de fallas en rodamientos, XGBoost alcanzó 98,2% de precisión [37].

La principal ventaja de este algoritmo es su capacidad para manejar grandes volúmenes de datos industriales y detectar patrones complejos de falla. En aplicaciones de PM4.0 típicas, Gradient Boosting Machine se usa para predecir la probabilidad de fallo de un equipo en un horizonte determinado o estimar la vida remanente de un componente (RUL) aprovechando su poder para modelar relaciones no lineales entre múltiples variables de condición de maquinaria [38].

1.6.4 Support Vector Machine

El Support Vector Machine (SVM) es un algoritmo que puede aplicarse tanto a problemas de clasificación binaria o multiclase como a tareas de regresión. Su principio fundamental consiste en encontrar un hiperplano óptimo que permita separar los datos de distintas clases con el máximo margen posible, es decir, maximiza la distancia entre el hiperplano y los puntos de datos más cercanos de cada clase [39].

En mantenimiento predictivo, SVM ha sido ampliamente aplicado para detectar fallas y clasificar estados de salud de máquinas [40]. Su capacidad para manejar espacios de alta dimensionalidad y procesar datos complejos lo convierte en una herramienta eficaz para diagnosticar condiciones anómalas a partir de señales de vibración, registros acústicos

o imágenes termográficas. Diversos estudios comparativos reportan que SVM presenta un desempeño competitivo en la clasificación de estados de fallo. En particular, una investigación sobre pronóstico de motores, un SVM correctamente ajustado alcanzó la mayor precisión de entre cinco clasificadores probados para distinguir múltiples niveles de degradación [41].

1.6.5 Redes Neuronales Recurrentes

Las redes neuronales recurrentes (RNN) corresponden a un modelo de aprendizaje profundo diseñado específicamente para el procesamiento de datos secuenciales o dependientes del tiempo. A diferencia de las redes neuronales clásicas [34], las RNN incorporan conexiones recurrentes que permiten retroalimentar la salida de las neuronas de un instante temporal como entrada en instantes posteriores, otorgándoles la capacidad de recordar información contextual a lo largo de una secuencia.

En mantenimiento predictivo, las RNN han adquirido relevancia por su habilidad de modelar series temporales de condición de maquinaria y pronosticar la evolución de fallas. Estos modelos resultan especialmente útiles para estimar la degradación y vida remanente de equipos. Por ejemplo, se han empleado RNN para predecir el RUL de componentes considerando secuencias de carga y medida en el tiempo [42], logrando mejorar la precisión de los pronósticos conforme ingresan más datos operativos. Gracias a su estructura recurrente, una RNN puede identificar patrones de fallo graduales y sutiles en señales provenientes de sensores, tales como vibraciones, temperaturas o corrientes eléctricas [43].

En contextos de mantenimiento predictivo, las RNN se utilizan principalmente bajo un esquema de aprendizaje supervisado, lo que implica disponer de conjuntos de datos históricos donde cada secuencia de entrada esté asociada a un resultado específico (por ejemplo, el tiempo restante hasta la falla) [43]. Aunque estos modelos requieren mayor volumen de datos y capacidad computacional en comparación con algoritmos clásicos, su principal ventaja radica en la capacidad de capturar de manera automática dinámicas temporales complejas, lo que los convierte en una herramienta de alto valor para el pronóstico de fallas en entornos industriales.

1.6.6 Long Short-Term Memory

Las Long Short-Term Memory (LSTM) son un tipo de red neuronal recurrente diseñada para trabajar con datos que cambian en el tiempo. A diferencia de las redes tradicionales, las LSTM pueden “recordar” información importante de pasos anteriores y decidir qué conservar o qué descartar, lo que les permite aprender patrones que ocurren a lo largo de secuencias largas. Gracias a esta capacidad, resultan especialmente útiles para analizar series temporales complejas y realizar predicciones basadas en la evolución de los datos [34], [44].

En mantenimiento predictivo, las LSTM han demostrado un desempeño destacado en tareas de pronóstico y detección de anomalías a partir de series de sensores. Dado que muchos procesos industriales generan datos en secuencia temporal como vibraciones en el tiempo, variaciones de temperatura y señales de corriente, este tipo de arquitectura resultan adecuadas para modelar la evolución de dichas señales y anticipar condiciones de falla incipiente [34]. Las LSTM también se aplican en la predicción de fallos de componentes rotativos (motores, turbinas, rodamientos), donde capturan patrones transitorios o recurrentes que preceden a una avería.

Cabe destacar que, si bien las LSTM requieren volúmenes grandes de datos para aprovechar su potencial (necesitan ejemplos de secuencias completas hasta fallo para aprender), cuando se dispone de estos, suelen alcanzar mayor exactitud que enfoques tradicionales en estimar tiempos de falla futuros [45].

1.6.7 Convolutional Neural Networks

Las Convolutional Neural Networks (CNN) son un tipo de modelo de aprendizaje profundo muy efectivo para trabajar con datos en forma de imágenes, señales o series temporales. Su principal ventaja es que pueden identificar automáticamente patrones relevantes en los datos como formas o variaciones en una señal sin necesidad de un preprocesamiento manual complejo [46].

En el mantenimiento predictivo, las CNN se han aplicado con éxito para analizar imágenes de termografía, espectrogramas de sonido o señales de vibración, con el fin de detectar fallas incipientes en equipos. Estos modelos se entrenan con ejemplos etiquetados de estados normales y de falla, aprendiendo a clasificar automáticamente la condición de la máquina.

Diversos estudios han demostrado que las CNN logran altos niveles de precisión en el diagnóstico, aunque suelen requerir grandes volúmenes de datos y recursos de cómputo para su entrenamiento. Aun así, se han utilizado para identificar grietas en piezas, monitorear el estado de rodamientos o clasificar sonidos de maquinaria, mostrando una mejora significativa frente a métodos tradicionales [46].

1.7 Sensores

Un sensor es un dispositivo diseñado para detectar estímulos del entorno físico, los cuales pueden corresponder a propiedades, cantidades o condiciones tales como presión, fuerza, flujo, luz, temperatura, movimiento, humedad, entre otros. Ante la detección de estos estímulos, el sensor responde mediante la generación de una señal eléctrica, como variaciones de voltaje, corriente, capacitancia, resistencia o frecuencia, la cual puede ser transmitida electrónicamente o desplegada de manera legible para su posterior análisis o procesamiento [47]. La Figura 6 muestra el esquema básico de entrada y salida de un sensor.




Figura 6: Diagrama esquemático de una entrada y salida de un sensor [47].

Actualmente, el desarrollo de sensores inteligentes ha ampliado las capacidades tradicionales de medición. Estos dispositivos no solo registran magnitudes físicas, sino que también realizan diagnósticos autónomos, toman decisiones locales y se comunican con otros sistemas mediante protocolos inalámbricos como Wi-Fi, 4G, LPWAN o GPRS. Incorporan microprocesadores integrados que permiten el procesamiento de señales, el almacenamiento de datos y la transmisión eficiente de información sin intervención humana directa [48].

Complementariamente, la red de sensores inalámbricas (WSN) constituyen sistemas compuestos por múltiples nodos de sensores distribuidos espacialmente. Estas redes colaboran de manera autónoma para monitorear variables físicas o ambientales [48]. Una ventaja crítica de las WSN es su capacidad de operar de manera descentralizada, autoorganizarse ante fallos parciales y asegurar la continuidad de transmisión hacia el nodo concentrador o sink, que posteriormente reenvía la información a los sistemas de supervisión remotos [49].

En el contexto de la Industria 4.0, los sensores representan un pilar fundamental al permitir la adquisición de datos en tiempo real sobre el estado de máquinas, productos y ambientes de trabajo. Esto habilita la fabricación inteligente, el seguimiento de inventarios, la optimización de la cadena de suministro y la implementación efectiva de estrategias de mantenimiento predictivo [47].

Dentro del mantenimiento predictivo, los sensores permiten la medición continua de variables críticas como temperatura, presión, velocidad, aceleración, corriente, humedad y sonido. El registro y análisis repetido de estos parámetros posibilita la identificación de patrones de deterioro y la predicción de fallas incipientes, asegurando una gestión más eficiente de los activos industriales [50].

La selección adecuada de sensores es crucial para garantizar mediciones confiables y de alta precisión. Para ello, deben considerarse características técnicas tales como rango de medición, tiempo de respuesta, precisión, resolución, sensibilidad, interfaz de comunicación, tamaño y peso.

Los sensores presentan diferentes tipos de características que se clasifican en estáticas y dinámicas.

Características Estáticas. Son las propiedades que describen el rendimiento del sensor en condiciones estable o sin cambios significativos en las condiciones de medición, las características estáticas más comunes son las siguientes:

- Rango de medición: intervalo de valores que el sensor puede medir de manera precisa.
- Resolución: mínima variación detectable en la magnitud de entrada.
- Precisión: se refiere a la repetibilidad de las medidas del sensor. Un sensor preciso tiene resultados consistentes cuando se mide la misma cantidad bajo las mismas condiciones.
- Exactitud: la exactitud indica cuan cercana esta la medición del sensor al valor real o verdadero de la cantidad medida, se suele expresar en porcentaje.
- Sensibilidad: relación entre la variación de salida y la variación de entrada.
- Temperatura de funcionamiento: se refiere al rango de temperaturas dentro de las cuales el sensor puede operar de manera efectiva sin alterar su rendimiento.

Características Dinámicas. Son las que se relacionan con su capacidad de responder a cambios rápidos o dinámicos en la cantidad medida, a continuación, se presentan las características dinámicas más relevantes en los sensores.

- Tiempo de respuesta: corresponde al tiempo que tarda un sensor en detectar y responder a cambios en la cantidad medida. Esta característica es fundamental en aplicaciones donde se requiere una rápida respuesta del sensor.

Existen diferentes formas de clasificar los sensores, una es en función a la variable a medir o detectar:

1.7.1 Sensor de Velocidad

Un sensor de velocidad es un dispositivo diseñado para medir la velocidad de un objeto en movimiento. Dependiendo de su configuración, puede medir velocidad lineal (desplazamiento en línea recta) o velocidad angular (tasa de rotación) [51].

En el caso de sensores de velocidad lineal, la medición se realiza a lo largo de una trayectoria recta, mientras que los sensores de velocidad angular detectan la rapidez de rotación de un objeto alrededor de un eje. Este tipo de sensores se emplea ampliamente tanto en aplicaciones automotrices como en sistemas de monitoreo de maquinaria industrial, donde resulta crucial controlar las variaciones de velocidad para garantizar un funcionamiento eficiente y seguro.

1.7.2 Sensor de Temperatura

Los sensores de temperatura son dispositivos diseñados para detectar variaciones térmicas en objetos, ambientes o sistemas, y convertir dicha información en señales eléctricas procesables [52].

Existen diversos tipos de sensores de temperatura, entre los cuales destacan: termopares, dispositivos de temperatura resistivos (RTD y termistores), radiadores infrarrojos, dispositivos bimetálicos, sensores de expansión de líquidos y dispositivos de cambio de estado [53].

En la industria, estos sensores cumplen funciones críticas tales como la protección contra sobrecalentamientos de equipos sensibles y el control preciso de la temperatura en entornos que requieren condiciones térmicas específicas. Su correcta integración permite optimizar la confiabilidad operacional y prolongar la vida útil de los componentes [53].

1.7.3 Sensores de Presión

Los sensores de presión son instrumentos que permiten medir la fuerza ejercida por un fluido sobre una superficie y convertirla en señales eléctricas proporcionalmente representativas [52].

Los sensores de presión pueden medir la presión de diferentes formas, existen los sensores de presión absoluta, sensores de presión manométrica (o sensores de presión relativa), los sensores de presión relativa normalizada (o de referencia constante) y sensores de presión diferencial [52].

En el ámbito industrial, los sensores de presión son fundamentales para garantizar que ciertos procesos operen dentro de rangos de presión seguros y óptimos. Además, en el mantenimiento predictivo, la monitorización continua de la presión permite anticipar fallas relacionadas con pérdidas, bloqueos o deterioros de componentes hidráulicos o neumáticos [34].

1.7.4 Sensores de Humedad

Un sensor de humedad, también denominado higrómetros, es un dispositivo utilizado para medir y cuantificar la humedad del aire o un objeto (cantidad de agua presente en el aire de un espacio determinado) en ocasiones también puede medir la temperatura del ambiente [53].

Existe una amplia variedad de tipos de sensores de humedad, pero lo más comunes son sensores de humedad relativa, sensores de humedad absoluta y sensores de punto de rocío.

Estos sensores son ampliamente utilizados en sistemas de climatización, control ambiental de inmuebles, agricultura de precisión y en aplicaciones meteorológicas, donde mantener la humedad dentro de rangos óptimos resulta crítico para la conservación de productos y la integridad de estructuras [55].

1.7.5 Sensor de Sonido

Los sensores de sonido, o sensores acústicos, detectan ondas de presión sonora en el ambiente y las convierten en señales eléctricas. Estas señales pueden ser posteriormente procesadas, registradas o utilizadas para generar alarmas [53].

Estos dispositivos tienen aplicaciones que van desde el simple registro de sonido ambiental hasta la detección de anomalías acústicas en entornos industriales o de seguridad, donde los cambios en los patrones de sonido pueden indicar la presencia de fallas mecánicas, intrusiones o eventos críticos [34].

1.7.6 Sensor de Vibración

Los sensores de vibración son dispositivos que miden la cantidad y frecuencia de vibración de un sistema, máquina o pieza. Esta tarea se lleva a cabo mediante la captura de datos relacionados con la aceleración, velocidad o desplazamiento del objeto en cuestión, y se logra gracias a instrumentos específicos como los acelerómetros y los velocímetros [53], [56].

Dado que la aplicación de estos sensores es bastante amplia que va desde laboratorio o industrias es que estos sensores deben ser versátiles en cuanto sensibilidad, rango de medición y de frecuencia.

La medición de la vibración es una herramienta bastante utilizada para identificar, predecir y prevenir fallas de máquinas rotativas, por lo que la implementación de este tipo de sensores es muy utilizada dentro de la industria para conseguir un mantenimiento predictivo dado que permite una revisión efectiva de las condiciones de los equipos evitando fallos inesperados [56].

A partir de la medición de vibración se pueden identificar distintos tipos de fallos característicos como desbalanceo, ejes doblados, fallas en los rodamientos, alteraciones en ruedas dentadas, alguna holgura.

2. Modelo de Seguimiento de Señales y Predicción de Fallas

En el presente capítulo se plantea un modelo para el seguimiento de señales operativas y predicción de fallas, basado en el presentado en la Figura 5. Se describen en detalle las distintas etapas involucradas en este modelo, proporcionando los lineamientos necesarios para su correcta implementación técnica.

La metodología propuesta contempla un proceso estructurado orientado hacia la transición del mantenimiento convencional a un modelo inteligente, alineado con las directrices del paradigma de Mantenimiento 4.0. Este proceso incluye la identificación de los activos que serán objeto de transformación, la realización de estudios de confiabilidad, la selección e instalación de sensores, la adquisición de datos operacionales, el análisis de condición de los equipos, y la predicción de fallas mediante algoritmos de diagnóstico y pronóstico. Todos estos componentes se integran con el Sistema de Gestión de Mantenimiento Computarizado (CMMS), constituyendo una base sólida para la evolución hacia un esquema de Mantenimiento 4.0.

2.1 Clasificación del Valor de Activos y Selección de Activos

Esta etapa tiene por finalidad identificar los activos en los cuales resulta técnica y económicamente viable implementar un modelo de seguimiento de señales de operación y pronóstico de fallas. Para ello, se debe realizar una evaluación que permita determinar qué activos presentan condiciones favorables en términos de criticidad, impacto operativo y disponibilidad de datos.

Se priorizan los activos críticos cuya confiabilidad requiere ser incrementada, así como aquellos donde sea factible la recopilación de datos mediante sensores o registros históricos. La selección debe considerar la capacidad del modelo para generar información relevante que contribuya al análisis y mejora del estado operativo del activo.

La inversión requerida para la implementación debe justificarse en función de los beneficios proyectados, tales como el aumento de la disponibilidad operativa, la reducción

de tiempos de inactividad y la optimización de costos de mantenimiento. Esta relación costo-beneficio constituye un criterio clave en el proceso de selección.

Se recomienda dar preferencia a activos que posean unidades repetidas dentro de la organización, ya que la implementación inicial puede ser replicada con menores ajustes en equipos de características similares.

Finalmente, se sugiere una implementación gradual, iniciando con un plan piloto sobre un conjunto acotado de activos seleccionados. Esta estrategia permite validar el modelo, identificar ajustes necesarios y establecer una base para su posterior escalamiento en el resto de los equipos.

2.2 Modelación de Confiabilidad

Una vez seleccionados los activos críticos, se requiere realizar un análisis detallado para identificar las posibles fallas asociadas a estos equipos. Este análisis implica tanto la identificación de fallas presentes como la anticipación de escenarios potenciales de falla. A partir del conocimiento de las causas raíz y los modos de falla registrados históricamente, es posible determinar con precisión las tecnologías de monitoreo más adecuadas para implementar en los activos seleccionados.

Entre las distintas metodologías disponibles para identificar las fallas, se recomienda emplear el enfoque propuesto por Aguilar, Torres y Magaña [57], el cual combina el Mantenimiento Centrado en Confiabilidad (RCM) con el Análisis de Modo de Fallo, Efectos y Criticidad (FMECA). Esta metodología se fundamenta en los lineamientos establecidos por las normas SAE JA-1011 y SAE JA-1012, y permite una selección precisa de las variables críticas a monitorear, asegurando un enfoque orientado a la mejora de la confiabilidad y el desempeño del activo.

El RCM se define como un proceso cuyo objetivo es determinar las acciones necesarias para asegurar que un activo físico cumpla con sus funciones requeridas. Su aplicación se basa en la evaluación de componentes, funciones y estado operativo; la

identificación de elementos críticos; y la aplicación de técnicas de mantenimiento proactivo y predictivo [58].

Por su parte, el método FMECA se utiliza para priorizar modos de falla a partir de su impacto en los sistemas, componentes o procesos, identificando sus efectos y clasificando su criticidad [58]. La integración de RCM y FMECA permite, por un lado, identificar fallas funcionales relevantes, y por otro, jerarquizar los modos de falla según su impacto, orientando así el monitoreo hacia las variables de mayor relevancia.

Aplicando esta combinación metodológica al activo en estudio, se determinó que las variables operacionales prioritarias a monitorear son temperatura, vibración y tiempo de operación [5].

La metodología propuesta por Aguilar, Torres y Magaña consta de las siguientes etapas:

1. Definición de la intención de diseño: la definición, consiste en comprender la filosofía de operación del proceso o planta, con el propósito de identificar las condiciones bajo las cuales opera el sistema. Se deben considerar tanto los aspectos de diseño como los requerimientos del usuario. La definición debe incluir los parámetros operativos, los equipos involucrados, las rutas del proceso, los parámetros de control, entre otros atributos técnicos relevantes. Esta información proporciona el nivel de detalle necesario para caracterizar el funcionamiento del activo en su contexto operativo.
2. Análisis funcional: el análisis funcional permite establecer las funciones que el activo debe cumplir, lo cual constituye un requisito previo para la identificación de modos de falla. Se deben identificar tanto la función principal como las funciones secundarias, de acuerdo con lo esperado por el usuario y lo definido por el diseño del sistema.
3. Identificación de Modos de falla: el modo de falla se define como la forma específica en la que un activo pierde su capacidad de cumplir una función

establecida. Cada modo de falla debe estar asociado a una acción de mitigación o prevención. Dentro del proceso de gestión del riesgo, estas acciones pueden estar orientadas a desviaciones del proceso, errores humanos u otros factores que comprometan la operación del sistema.

4. Efectos y consecuencias de las fallas: los efectos de una falla se refieren a la forma en que esta se manifiesta en el sistema, tanto a nivel local como en otros subsistemas. Estas manifestaciones pueden incluir variaciones en temperatura, activación de alarmas, dispositivos de seguridad, o síntomas como ruidos anómalos y vibraciones. Las consecuencias deben evaluarse en relación con su impacto en la seguridad de las personas, el medio ambiente y la continuidad de la producción.
5. Jerarquización del riesgo: la jerarquización del riesgo se basa en la combinación de la frecuencia de ocurrencia del modo de falla y la severidad de sus consecuencias. Esta priorización permite identificar las áreas con mayor potencial de mejora, facilitando la asignación eficiente de recursos económicos y humanos tanto en la etapa de evaluación como en la ejecución de acciones correctivas o preventivas.

En la Tabla 1 se muestran los criterios de ocurrencia, en la Tabla 2 se ven los criterios de frecuencia de falla y finalmente en la Figura 7 muestra la matriz de riesgo que se utiliza para la jerarquización de los modos de falla.

Tabla 1: Categorías de consecuencias por fallas [57].

Categoría	Menor a C1	Moderado C2	Grave C3	Catastrófico C4
A las personas				
Seguridad y salud del personal y proveedor y/o contratista	Sin lesiones; primeros auxilios	Atención Médica; Lesiones menores sin incapacidad; efectos a la salud reversibles	Hospitalización; múltiples lesionados, incapacidad parcial o total temporal; efectos moderados a la salud	Una o más fatalidades; Lesionados graves con daños irreversibles; Incapacidad parcial o total permanentes
Al ambiente				
Descargas y Derrames	Derrames y/o descarga dentro de los límites de reporte; contingencia controlable.	Informe a las Autoridades. Derrame significativo en tierra hacia ríos o cuerpos de agua. Efecto local. Bajo potencial para provocar la muerte de peces.	Contaminación de un gran volumen de agua. Efectos severos en cuerpos de agua; mortandad significativa de peces; incumplimiento de condiciones de descarga permitidas; reacción de grupos ambientalistas.	Daño mayor a cuerpos de agua; se requiere un gran esfuerzo para remediación. Efecto sobre la flora y fauna. Contaminación en forma permanente del suelo o del agua.
Producción				
Pérdida de producción, daños a las instalaciones	Menos de una semana de paro. Daños a las instalaciones y pérdida de la producción, menor a 5 millones de pesos	De 1 a 2 semanas de paro. Daños a las instalaciones y pérdida de la producción, hasta 10 millones de pesos	De 2 a 4 semanas de paro. Daños a las instalaciones y pérdida de la producción de hasta 20 millones de pesos	Más de un mes de paro. Daños a propiedades o a las instalaciones; pérdida mayor a 20 millones de pesos

Tabla 2: Categorías de frecuencia [57].

Categoría	Cuantitativo	Cualitativo
Alta	> 1 en 10 años	El evento se ha presentado o puede presentarse en los próximos 10 años
Media	1 en 10 años a 1 en 100 años	Puede ocurrir al menos una vez en la vida de las instalaciones
Baja	1 en 100 años a 1 en 1000 años	Concebible; nunca ha sucedido en el centro de trabajo, pero probablemente ha ocurrido en alguna instalación similar
Remota	< 1 en 1000 años	Esencialmente imposible. No es realista que ocurra




Figura 7: Matriz de riesgo [57].

2.3 Selección de ERP/CMMS

La implementación de un sistema de gestión de mantenimiento asistido por computador (CMMS) o de un sistema de planificación de recursos empresariales (ERP) con módulo específico de mantenimiento constituye una estrategia fundamental para optimizar la gestión de activos físicos en entornos industriales. Estas plataformas permiten planificar y programar de manera eficiente las tareas de mantenimiento, asignar recursos técnicos,

emitir órdenes de trabajo y registrar con trazabilidad las actividades operacionales realizadas.

Además, proporcionan una gestión integrada del inventario de repuestos, ofreciendo visibilidad en tiempo real sobre la ubicación, disponibilidad y movimientos de materiales. Esta funcionalidad facilita una planificación precisa del abastecimiento, la emisión oportuna de órdenes de compra y la optimización del flujo logístico en la cadena de suministro.

Tanto los sistemas CMMS como los ERP permiten un control detallado de los costos asociados al mantenimiento, incluyendo mano de obra, materiales, servicios externos y otros recursos logísticos. Esta capacidad de gestión económica refuerza la transparencia y la precisión en el control presupuestario.

Una ventaja adicional es la centralización de la información histórica del mantenimiento, lo que permite generar informes analíticos orientados a evaluar el rendimiento de los activos, validar la eficacia de las estrategias implementadas y verificar el cumplimiento de los objetivos técnicos establecidos.

En términos funcionales, un CMMS es un sistema informático diseñado específicamente para la administración, planificación y control detallado de las actividades de mantenimiento. Su función principal es asegurar la trazabilidad de las intervenciones, optimizar el uso de los recursos técnicos, gestionar el inventario de repuestos y registrar datos sobre fallas, órdenes de trabajo y costos operativos. Estos sistemas permiten programar mantenimiento preventivo y predictivo, gestionar órdenes en todas sus fases y analizar indicadores clave como el tiempo medio entre fallas (MTBF) y el tiempo medio de reparación (MTTR). Están orientados a cubrir requerimientos técnicos con alta compatibilidad para integrarse con sensores y plataformas de monitoreo en tiempo real.

Por su parte, un ERP es una plataforma integral que centraliza y coordina la información de diversas áreas funcionales de la organización, tales como finanzas, compras, recursos humanos, ventas, inventarios, producción y, en algunos casos, mantenimiento. Su objetivo es proporcionar una visión global del funcionamiento organizacional, facilitando la toma de decisiones estratégicas mediante la automatización y

estandarización de los procesos. Aunque algunos ERP incorporan módulos de mantenimiento, estos suelen tener un alcance funcional más limitado en comparación con los CMMS especializados, especialmente en funciones técnicas como el monitoreo de condición o la integración con tecnologías predictivas.

2.4 Monitoreo del Rendimiento

Una vez implementado el sistema CMMS o ERP, se inicia el proceso de monitoreo del rendimiento de los activos en tiempo real, con la finalidad de recopilar datos operacionales que alimenten las etapas posteriores de análisis predictivo. Estos datos deben almacenarse de forma estructurada y segura en una base de datos centralizada, para su posterior integración con herramientas de análisis de condición o algoritmos de predicción de fallas.

En entornos industriales, los parámetros más comúnmente utilizados en estrategias de mantenimiento predictivo incluyen las vibraciones, el ultrasonido y la termografía.

- Análisis de Vibraciones

El análisis de vibraciones consiste en medir y evaluar las oscilaciones mecánicas de un equipo, las cuales están compuestas por múltiples frecuencias asociadas a componentes internos en movimiento [59]. Esta técnica se considera fundamental para la supervisión y diagnóstico de maquinaria rotativa, y constituye una herramienta base en planes de mantenimiento predictivo y del mantenimiento basado en condición [60].

Mediante el análisis de vibraciones es posible identificar fallas como desequilibrio, desalineación, holguras mecánicas, fricción excesiva, deficiencias en la lubricación, poleas excéntricas, desgaste en rodamientos, fallas en engranajes, fisuras estructurales y cavitación en bombas [59].

- Ultrasonido

El ultrasonido aplicado al mantenimiento se basa en el uso de ondas sonoras de alta frecuencia, fuera del rango audible humano, para detectar y analizar condiciones internas de equipos o estructuras. La técnica emplea transductores que emiten y reciben las ondas, lo que permite evaluar el estado del equipo sin necesidad de desmontarlo [61].

Las aplicaciones industriales más frecuentes del ultrasonido incluyen la detección de fugas, la inspección de rodamientos y la identificación de arcos eléctricos.

- Termografía

La termografía es una técnica de medición basada en la evaluación de las emisiones térmicas de los equipos durante su operación normal. Su utilización no requiere la interrupción del proceso productivo. Las alteraciones de temperatura suelen ser indicativas de fallas incipientes, razón por la cual los fabricantes especifican rangos de operación térmica en sus manuales técnicos [62].

Esta técnica se emplea ampliamente en estrategias de mantenimiento preventivo, mantenimiento predictivo y monitoreo de condición. Al tratarse de una técnica no intrusiva, permite la inspección sin interferir en el funcionamiento del equipo. Entre sus aplicaciones principales se encuentran el monitoreo del estado eléctrico y mecánico de motores eléctricos, la inspección de rodamientos y el soporte al análisis de vibraciones [63].

2.5 Selección de Algoritmo Predictivo y/o Basado en Condición

Esta etapa considera la selección del algoritmo predictivo y/o basado en condición que permita anticipar fallas en los activos monitoreados. Su principal función es analizar datos históricos y en tiempo real para identificar patrones de comportamiento asociados a modos de falla incipientes o desviaciones operacionales relevantes.

El uso de este tipo de algoritmos permite establecer diagnósticos y pronósticos fundamentados en datos, lo que favorece una planificación más estratégica y proactiva de las intervenciones. Como resultado, se reducen los tiempos de inactividad no programada y se optimiza la eficiencia operativa mediante acciones de mantenimiento orientadas a condiciones específicas.

Además de anticipar fallas, estos algoritmos posibilitan la generación de modelos dinámicos de comportamiento de los activos, lo que mejora significativamente la capacidad de toma de decisiones en tiempo real. La incorporación de técnicas de inteligencia artificial y aprendizaje automático, en conjunto con datos obtenidos a través de sensores industriales, ha incrementado la precisión de los pronósticos y ha facilitado la adaptación continua de las estrategias de mantenimiento según el estado operativo real de los equipos. Esta capacidad de respuesta convierte al mantenimiento predictivo en un componente esencial para organizaciones que operan bajo principios de eficiencia, confiabilidad y digitalización propios del paradigma de la Industria 4.0.

2.6 Pronóstico de Posibles Fallas

Una vez ejecutadas las etapas anteriores, el modelo debe estar habilitado para generar predicciones sobre fallas potenciales en los activos. A partir de dichas predicciones, se deben planificar acciones de mantenimiento orientadas a mejorar la confiabilidad y disponibilidad operativa de los equipos.

En ausencia de un software especializado, es posible aplicar una metodología basada en la condición operativa del activo para estimar el momento probable de ocurrencia de una falla. Esta metodología se apoya en datos obtenidos continuamente a través de sensores, los cuales permiten construir representaciones gráficas de las variables monitoreadas en función del tiempo o la frecuencia. La detección de anomalías en estas curvas constituye el punto de partida para el análisis técnico correspondiente y, en caso necesario, la planificación de acciones correctivas [64].

La identificación de anomalías puede realizarse mediante la comparación con registros históricos de fallas o utilizando estándares técnicos que establecen umbrales aceptables para los parámetros monitoreados. Por ejemplo, para la evaluación de la severidad de la vibración en equipos rotativos, se puede emplear la norma ISO 10816, la cual define criterios cuantitativos para determinar el riesgo asociado al nivel de vibración registrado [64].

3. Evaluación del Estado Actual del Mantenimiento 4.0 en el Taller MM

En este capítulo se aborda el estado actual del Mantenimiento del TMM, en primer lugar, se realiza una caracterización del Mantenimiento, estableciendo el estado de avance de la transformación hacia el Mantenimiento 4.0 que se encuentra el taller, luego se evalúa del modelo de transformación aplicado en el taller, identificando los puntos débiles de este y, por último, se presenta una propuesta de expansión del modelo de mantenimiento.

3.1 Caracterización del Taller Metalmecánico

El Taller Metalmecánico del campus San Joaquín funciona como un Learning Factory, orientada a la formación práctica de estudiantes de Ingeniería Civil Mecánica. Este espacio simula un entorno industrial controlado y dispone de una amplia variedad de máquinas y herramientas destinadas a la ejecución de operaciones fundamentales de mecanizado y fabricación.

El TMM cuenta con equipos como tornos, fresadoras, esmeriladoras, taladros de pedestal, rectificadoras y sierras horizontales de huincha. Cada una de estas máquinas cumple un rol esencial en los procesos de formación técnica, pues permiten el desarrollo de habilidades asociadas a la manufactura de piezas metálicas. Por esta razón, resulta prioritario mantener una alta disponibilidad de los equipos, lo que contribuye a la continuidad de las actividades prácticas y a la cobertura total del plan formativo.

Con base en trabajos previos, se realizó un levantamiento de información destinado a caracterizar el sistema de mantenimiento actual del TMM. En general, las tareas de mantenimiento implementadas (con excepción de los tornos recientemente intervenidos) corresponden a acciones correctivas y preventivas, determinadas en función de las condiciones de operación de cada equipo. Las labores preventivas incluyen rutinas periódicas de limpieza y lubricación, realizadas por los instructores encargados de cada estación de trabajo. Asimismo, como parte de las actividades de formación, los estudiantes efectúan tareas de limpieza profunda al finalizar sus prácticas de mecanizado.

No obstante, la mayor proporción de actividades de mantenimiento en el TMM corresponde a intervenciones correctivas. Este tipo de mantenimiento implica la ejecución de reparaciones, sustituciones o ajustes sobre componentes que han presentado una falla funcional. Cuando un equipo deja de operar completamente, se recurre a servicios externos para efectuar las reparaciones necesarias y restablecer su funcionamiento.

El taller también cuenta con un plan preventivo básico, que contempla inspecciones visuales y aplicación de lubricantes. Muchas de estas tareas se realizan de manera autónoma por los propios instructores, quienes asumen la responsabilidad de mantener sus equipos en condiciones operativas y disponibles para los alumnos. Según lo reportado en [65], se estima que aproximadamente un 80% de las actividades de mantenimiento en el Taller Metalmecánico son de tipo correctivo, un 15% corresponden a mantenimiento preventivo, y un 5% a intervenciones de carácter predictivo. Estas últimas se ejecutan de forma rudimentaria, utilizando únicamente la percepción sensorial humana para detectar signos tempranos de fallas.

Con el objetivo de avanzar hacia un modelo más eficiente, el trabajo de título desarrollado por Jaime Said propuso una estrategia de Mantenimiento Predictivo 4.0 aplicada a dos tornos del taller. Este modelo consideró la incorporación de sensores para monitoreo continuo, el diseño de una arquitectura de adquisición y almacenamiento de datos en tiempo real, y una integración parcial con un sistema de gestión computarizada de mantenimiento (CMMS).

En los tornos seleccionados se instalaron sensores para medir revoluciones por minuto (RPM), temperatura y aceleración. También se añadió un sensor ambiental para registrar la temperatura y humedad relativa en la zona de trabajo. Estos dispositivos están conectados a un sistema que permite visualizar y almacenar los datos obtenidos, lo cual habilita un monitoreo continuo de las variables operativas.

Los datos recopilados son transmitidos en tiempo real a una estación de trabajo mediante un router TP-Link. En esta estación se almacenan y visualizan, lo que permite un análisis permanente del estado de los equipos. La gestión de esta información se realiza a través del software Fractal, una plataforma especializada en mantenimiento que permite

programar órdenes de trabajo de manera automática en función de las condiciones reales de operación.

Para complementar el sistema, se integraron herramientas como Docker y MongoDB Compass, lo cual proporciona una arquitectura escalable para la gestión de datos. Esta estructura permite, además, la futura expansión del modelo a otros equipos del taller.

La implementación alcanzó un nivel funcional que permite el monitoreo en tiempo real con soporte de un CMMS, representando un avance concreto hacia la adopción del paradigma de Mantenimiento 4.0.

3.2 Evaluación del Mantenimiento

Con el propósito de ampliar la implementación del modelo de Mantenimiento Predictivo 4.0, se evalúa la implementación ya realizada. Para ello se establece un diagnóstico claro y fundamentado de la situación actual, resulta necesario realizar una evaluación estructurada del sistema de mantenimiento presente. Esta evaluación determina el nivel de desarrollo del mantenimiento que se ejecuta en el taller, considerando dimensiones técnicas, operativas y tecnológicas, a fin de determinar su grado de alineación con los principios establecidos por las buenas prácticas de gestión de activos y los enfoques emergentes en mantenimiento industrial bajo el paradigma de la Industria 4.0.

La aplicación de este análisis permite establecer una línea base a partir de la cual es posible identificar las principales fortalezas y limitaciones del sistema vigente, así como los factores críticos que condicionan su capacidad de evolución hacia esquemas más estructurados y digitalizados.

Se evaluará el nivel de madurez en la dimensión de sensores, CMMS y predicción para esto en la Tabla 3 se establecen los siguientes niveles de madurez.

Tabla 3: Nivel de madurez y su descripción.

Nivel de madurez		Descripción
1	Inicial	El proceso se encuentra débilmente controlado o no controlado en absoluto.
2	Gestionado	El proceso está parcialmente planificado; el análisis de desempeño depende sobre todo de la experiencia y competencia individuales; la gestión es débil debido a carencias en los sistemas organizativos o técnicos.
3	Definido	El proceso está planificado; se llevan a cabo análisis semicuantitativos periódicos para definir buenas prácticas o procedimientos de gestión; la ejecución del proceso depende de ciertas restricciones derivadas de la organización o de los sistemas técnicos.
4	Implementado	El desempeño del proceso se mide y se detectan las causas de variaciones especiales; se realizan análisis cuantitativos con buen equilibrio frente a los cualitativos; la gestión se sustenta en responsabilidades organizativas claras y sistemas técnicos plenamente funcionales.
5	Óptimo	El proceso se gestiona garantizando la mejora continua; se identifican las causas de defectos y problemas y se actúa para evitar que se repitan en el futuro.

Se evalúan las dimensiones de sensores, CMMS y predicción que son elementos técnicos clave en un modelo de mantenimiento predictivo en el taller y se presentan los resultados en la Tabla 4

Tabla 4: Niveles de madurez de cada dimensión.

Dimensión	Nivel de Madurez
Sensores	4
CMMS	3
Capacidad de predicción	1

A continuación, se describe en detalle cada una de las dimensiones evaluadas y su respectivo nivel de madurez.

La primera dimensión evaluada corresponde a sensores, la cual se ha clasificado en un Nivel de Madurez 4. Esta valoración considera aspectos tales como la robustez de la infraestructura instalada, la continuidad operativa y la calidad de los datos obtenidos. Los sensores instalados en los tornos convencionales del taller permiten la captura en tiempo real de variables críticas relacionadas con el estado de los equipos, como vibraciones mecánicas, temperatura y velocidad de rotación. Los puntos específicos de medición fueron definidos siguiendo criterios técnicos alineados con los modos de falla más relevantes para los componentes monitoreados, asegurando que la implementación garantice la obtención de datos confiables y repetibles.

Los datos capturados se almacenan en una base estructurada que permite su posterior análisis. La arquitectura implementada contempla la digitalización integral de las señales recogidas, organizadas cronológicamente según cada variable medida y cada equipo supervisado. Esto posibilita realizar análisis históricos y evaluar tendencias operativas sin necesidad de efectuar mediciones manuales recurrentes. Asimismo, los registros almacenados en formato digital facilitan su reutilización en procesos analíticos posteriores, ya sea mediante herramientas gráficas o motores de procesamiento automatizados.

El sistema de sensores se encuentra plenamente operativo y no responde a una implementación experimental. La sensorización ha sido instalada de forma permanente en los equipos, operando de manera continua durante sus ciclos de trabajo. Esto garantiza la disponibilidad constante de datos relevantes y con suficiente continuidad temporal para alimentar procesos de análisis estructurados y sustentar decisiones técnicas objetivas. La fiabilidad del sistema elimina la necesidad de validaciones manuales adicionales, y convierte a las señales obtenidas en insumos directos para actividades de monitoreo de condición, análisis de tendencias y evaluación de desempeño.

Desde una perspectiva de gestión, la sensorización representa una fortaleza consolidada en el ecosistema de mantenimiento del taller. Las oportunidades de mejora no se relacionan con los sensores en sí, sino con la capacidad organizacional de aprovechar estos datos mediante integraciones automatizadas o aplicaciones analíticas más avanzadas.

En este sentido, la dimensión de sensorización actúa como un habilitador esencial para futuras estrategias de mantenimiento predictivo y prescriptivo.

En cuanto a la dimensión relacionada con el sistema CMMS, esta ha sido clasificada en el Nivel de Madurez 3. Dicha clasificación se sustenta en que el uso del software Fracttal One supera un nivel básico de implementación y presenta una operatividad estructurada y constante como soporte formal para la planificación y ejecución del mantenimiento, particularmente en los activos seleccionados para el piloto de Mantenimiento 4.0. La plataforma posee una jerarquía estructurada y digitalmente replicada de activos, permite identificar individualmente equipos, componentes principales y subniveles asociados. Además, la plataforma incorpora catálogos de tareas, históricos de órdenes de trabajo y planes preventivos, incluyendo elementos básicos del mantenimiento basado en condición.

Desde un punto de vista operativo, el sistema CMMS permite registrar, ejecutar, cerrar y auditar órdenes de trabajo mediante una interfaz web y dispositivos móviles, asegurando así la trazabilidad documental y el control efectivo de las actividades programadas. No obstante, y pese a estos avances, se observan limitaciones significativas como la ausencia de integración automática entre el CMMS y las fuentes de datos provenientes de los sensores instalados en los equipos. Esta desconexión representa una barrera importante para la automatización total del flujo de trabajo y limita la autonomía del sistema para responder oportunamente ante cambios en la condición real de los activos.

Pese a estas limitaciones, el uso del CMMS representa un avance relevante en la gestión operativa del mantenimiento. La planificación estructurada, la trazabilidad digital y la organización jerárquica de activos justifican su clasificación en el Nivel de Madurez 3. No obstante, para alcanzar un nivel superior será necesario habilitar la integración con sensores, implementar mecanismos de seguimiento de variables de operación y fortalecer la visualización de métricas operativas que permitan una toma de decisiones más autónoma y basada en condición real.

Finalmente, en relación con la dimensión de capacidad de predicción, esta ha sido clasificada en el Nivel de Madurez 1, representando el nivel más básico dentro de la escala utilizada. Esta clasificación se debe fundamentalmente a la inexistencia de herramientas,

metodologías o sistemas capaces de anticipar comportamientos futuros de los activos mediante análisis de datos históricos u operacionales en línea. Aunque existen avances importantes en sensorización y captura estructurada de variables técnicas relevantes, dichas señales aún no han sido procesadas mediante modelos predictivos. En consecuencia, no existe un sistema activo que permita pronosticar fallas o estimar la vida útil remanente de los equipos.

Actualmente, el taller no cuenta con algoritmos de análisis estadístico o modelos de Machine Learning entrenados sobre series temporales de operación. Tampoco se han implementado herramientas que permitan pronosticar deterioros, comportamientos anómalos o patrones repetitivos vinculados al desgaste de componentes. Aunque Fractal One incluye un módulo de predicción basado en inteligencia artificial, esta funcionalidad no se encuentra en uso debido a la falta de datos.

Además, no existe un sistema de generación de alertas automáticas basado parámetros clave derivadas del comportamiento histórico de las máquinas. Las decisiones siguen dependiendo exclusivamente de la interpretación humana de las curvas y registros, sin intervención predictiva ni asistencia computacional. Esta dependencia del juicio experto introduce un alto grado de subjetividad y limita la capacidad de escalar hacia modelos de mantenimiento autónomo o prescriptivo. En el contexto de Industria 4.0, la capacidad predictiva constituye un pilar fundamental para mejorar la disponibilidad, confiabilidad y eficiencia de los activos. La ausencia de estas herramientas posiciona al taller en una fase inicial de desarrollo en materia analítica y predictiva.

La implementación del modelo de mantenimiento bajo el paradigma de Industria 4.0 en el TMM representa un avance significativo en la transición desde un enfoque tradicional hacia una estrategia digitalizada basada en el monitoreo de condiciones. En términos generales, el modelo desarrollado presenta una planificación estructurada, una ejecución técnicamente sólida y una arquitectura funcional que permite evaluar de manera realista los impactos de la incorporación de tecnologías 4.0.

La selección de los activos intervenidos, así como la definición de variables críticas y la elección de sensores para vibración, temperatura y velocidad, reflejan una adecuada comprensión de los modos de falla presentes en el taller. La integración con sistemas de

adquisición, el almacenamiento en bases de datos como MongoDB y la visualización de datos mediante interfaz gráfica permiten construir un sistema replicable y escalable hacia otros equipos.

Por otro lado, la implementación del CMMS Fractal One representa un hito relevante en la digitalización de tareas, planificación de mantenimiento y seguimiento de actividades de mantenimiento. A pesar de que aún no se encuentra integrado con los sensores, su estructura funcional representa una base sólida para futuras automatizaciones.

Sin embargo, la evaluación también revela limitaciones técnicas importantes. La desconexión entre la sensorización y el CMMS impide el funcionamiento autónomo del sistema frente a cambios en las condiciones reales de los equipos. Además, la falta de explotación analítica de los datos disponibles restringe el desarrollo de capacidades predictivas. Finalmente, el alcance actual del modelo es limitado, considerando que solo dos tornos han sido instrumentados, sin extensión a otros equipos críticos del taller.

Finalmente, si bien la implementación fue técnicamente exitosa, la cobertura del modelo es limitada, ya que solo dos tornos han sido instrumentados. La aplicación no se ha extendido a otros equipos críticos del taller.

3.3 Propuesta de Expansión del Modelo de Mantenimiento

La implementación del mantenimiento predictivo bajo el paradigma de Industria 4.0 constituye una estrategia fundamental para la modernización de la gestión de activos en las organizaciones, facilitando una transición desde modelos tradicionales reactivos o preventivos hacia enfoques más eficientes, inteligentes y orientados a la explotación de datos operacionales. Esta metodología se basa en la capacidad para anticipar fallas mediante el monitoreo permanente de variables clave, utilizando sensores, sistemas avanzados de adquisición de datos y algoritmos analíticos capaces de identificar patrones anómalos o tendencias de deterioro antes de que estos se traduzcan en fallas funcionales.

En este contexto, se plantea expandir el modelo de mantenimiento predictivo hacia otros activos del Taller Metalmecánico, esto responde tanto a requerimientos técnicos como

estratégicos, que se enmarcan en el proceso general de transformación digital necesario para la modernización integral de los sistemas de gestión de activos físicos. La incorporación de nuevas máquinas, como fresadoras, las cuales poseen configuraciones mecánicas, modos de operación y patrones de desgaste diferentes a los equipos ya considerados, permite incrementar significativamente la capacidad del modelo para abordar la complejidad inherente al entorno productivo.

Este trabajo busca que el modelo aplicado en la fresadora sea completamente compatible con la arquitectura tecnológica ya presente en el TMM. De esta forma se mantendrá el esquema de sensorización con adquisición de datos en tiempo real mediante hardware local, así como la transmisión de dicha información hacia la base de datos, tal como se ha establecido previamente en los tornos.

Dicha expansión del modelo no persigue únicamente aumentar la cobertura técnica del sistema actual, sino también avanzar hacia la consolidación de un taller inteligente, en el que el monitoreo continuo, la digitalización de procesos y el análisis automatizado de información operativa sean prácticas transversales aplicadas a los activos críticos. Al ampliar la implementación del modelo predictivo, se posibilita extender la infraestructura de sensorización existente, fortalecer las bases de datos operacionales y generar un volumen más robusto de información. Esto último resulta imprescindible para la implementación efectiva de técnicas avanzadas de análisis y algoritmos predictivos con mayor capacidad de generalización.

Por otra parte, una de las principales limitaciones identificadas en la implementación del modelo de mantenimiento basado en condición en el Taller Metalmecánico corresponde a la ausencia de una capacidad predictiva efectiva. Si bien se han logrado avances significativos en términos de sensorización, adquisición de datos y digitalización de actividades mediante un CMMS, el sistema actual carece de mecanismos que permitan anticipar de manera automática la ocurrencia de fallas o estimar la vida útil remanente de los equipos. Esta carencia restringe el paso desde una estrategia basada en condición hacia un verdadero enfoque predictivo, que permita intervenir de forma proactiva en función del riesgo técnico real de cada activo.

Por lo anterior, se propone un algoritmo basado en técnicas de Machine Learning, orientado a dotar al sistema de mantenimiento del taller de una funcionalidad predictiva. La finalidad es avanzar hacia un modelo que no solo registre y monitoree señales operativas, sino que también sea capaz de procesarlas analíticamente, identificar patrones de falla y entregar información útil para la toma de decisiones anticipadas sobre la gestión de activos críticos.

4. Requerimientos Técnicos

En este capítulo se establecen los requerimientos técnicos para la implementación del modelo de sensorización en el Taller Metalmecánico, asegurando su alineamiento y compatibilidad con la infraestructura y las tecnologías ya implementadas.

En primer lugar, se definen los requerimientos de los sensores. A continuación, se describe la arquitectura de adquisición y los protocolos de comunicación necesarios para la captura y el transporte de datos. Posteriormente, se especifican los requerimientos de software y el flujo de datos para su adquisición, almacenamiento, procesamiento y visualización de la información. Finalmente, se presenta el procedimiento de selección del algoritmo de Machine Learning que mejor se ajusta a las necesidades del TMM para el pronóstico de fallas.

4.1 Requerimientos Técnicos de Sensores

Dado que el taller ya cuenta con sensores instalados en otras máquinas, la incorporación de nuevos dispositivos debe preservar la compatibilidad con la infraestructura de red y de adquisición de datos actualmente operativa.

La infraestructura vigente contempla el uso de un router tipo TP-Link para la conformación de una red local (LAN), la transmisión de datos mediante TCP/IP y el almacenamiento de la información proveniente de los sensores en una base de datos MongoDB, gestionada a través de un entorno Docker en un equipo de procesamiento dedicado. En consecuencia, la selección de sensores debe alinearse con estos elementos para permitir su integración sin modificaciones estructurales del sistema.

En este contexto, los sensores seleccionados deberán cumplir con los siguientes requerimientos técnicos mínimos:

- Capacidad de transmisión de datos en red local: los dispositivos deben ser capaces de integrarse a una red LAN preexistente, ya sea mediante conexión cableada (Ethernet) o inalámbrica (Wi-Fi). La elección del medio físico dependerá del tipo de módulo de adquisición utilizado y de la disposición de la máquina dentro del taller.

- Compatibilidad con el protocolo TCP/IP: es imprescindible que los sensores o los módulos intermedios encargados de recolectar sus datos permitan el envío de paquetes mediante el protocolo de red TCP/IP, ya que este es el estándar utilizado para la transmisión hacia el equipo receptor.
- Formato de salida de datos legible: los datos transmitidos por los sensores deben estar estructurados en un formato sencillo y compatible con los sistemas de procesamiento ya implementados. Se privilegia el uso de texto plano codificado en ASCII, con encabezados y delimitadores que faciliten su interpretación por parte de los scripts de adquisición desarrollados en Python.
- Configuración de dirección IP y puerto de destino: los módulos transmisores deben permitir la asignación de una dirección IP fija del equipo receptor, así como la definición de un puerto específico para cada flujo de datos. Esta capacidad es esencial para asegurar la correcta distribución y recepción simultánea de múltiples señales de sensor en la red.
- Compatibilidad eléctrica y mecánica: los sensores deberán operar con niveles de tensión y corriente compatibles con los sistemas de alimentación disponibles en el taller, y permitir una instalación segura y confiable sobre componentes estructurales de la máquina. Asimismo, se recomienda verificar su grado de protección (IP) frente a agentes como virutas metálicas, refrigerantes o polvo.
- Rango de medición adecuado y resolución suficiente: se debe garantizar que los sensores sean capaces de capturar las magnitudes físicas relevantes dentro de los rangos esperados de operación de las fresadoras.

4.2 Arquitectura de Adquisición de Datos y Protocolos de Comunicación

Para poder incorporar sensores en el ecosistema del taller, estos deben ser compatibles con la arquitectura de datos y protocolos de comunicación existentes, para esto es que se tiene el siguiente diagrama de flujo de datos, mostrados en la Figura 8.




Figura 8: Arquitectura de red para adquisición de datos para sensores en el taller

La Figura 8 presenta la arquitectura de red propuesta para la integración de sensores en el entorno del Taller Metalmecánico, bajo un enfoque alineado con los principios de la Industria 4.0

La estructura contempla tres componentes principales: sensores, router y PC, y estos representan el flujo completo de adquisición y transmisión de datos de los sensores, los componentes serán explicados a continuación:

En primer lugar, los sensores, este componente constituye el punto inicial del sistema de monitoreo y se encarga de capturar variables operacionales de interés directamente de la máquina. El sensor se encuentra físicamente instalado en la máquina que se desea monitorear. Para facilitar la integración con el sistema digital, cada sensor está acoplado a un módulo de adquisición electrónica que realiza tareas fundamentales como la digitalización de la señal, el preprocesamiento de los datos y la estructuración del mensaje en formato de texto plano codificado en ASCII.

El formato ASCII (American Standard Code for Information Interchange) es un estándar de codificación que representa caracteres mediante valores numéricos, permitiendo que los datos sean leídos fácilmente por sistemas informáticos como texto legible.

Además, estos módulos poseen conectividad inalámbrica, típicamente mediante Wi-Fi, y se configuran de forma individual a través de una aplicación móvil provista por el fabricante. Esta aplicación permite ingresar parámetros de red como el nombre de la red (SSID), la contraseña, la dirección IP de destino y el número de puerto correspondiente.

El SSID (Service Set Identifier) es simplemente el nombre que identifica a una red Wi-Fi específica, lo que permite a los dispositivos conectarse correctamente al punto de acceso deseado. La transmisión de datos se efectúa en intervalos regulares y en tiempo real, garantizando que la información operativa esté disponible para su análisis sin necesidad de intervención manual.

Continuando con los componentes mostrados en la Figura 8, el router, el cual cumple la función de nodo central en la red local del taller. Su rol principal es gestionar el tráfico de datos que circula entre los sensores y el computador de procesamiento. En este caso, se utiliza un router TP-Link configurado como punto de acceso Wi-Fi, el cual recibe las señales inalámbricas emitidas por los módulos de los sensores.

La comunicación entre los sensores y el router se realiza utilizando el protocolo TCP/IP (Transmission Control Protocol/Internet Protocol), que proporciona un canal de comunicación fiable y estructurado, asegurando que los datos lleguen íntegros a su destino. TCP/IP es el conjunto de reglas más comúnmente utilizado en redes informáticas, y permite que dispositivos diferentes puedan intercambiar datos correctamente.

Este tipo de protocolo es ampliamente utilizado en redes industriales por su estabilidad, compatibilidad y soporte con sistemas informáticos convencionales. La elección de una red Wi-Fi como medio de transmisión permite además una mayor flexibilidad para la instalación física de los sensores, eliminando la necesidad de cableado entre los dispositivos.

El ultimo componente mostrado en la Figura 8 es el computador, el cual representa el punto final de la red de adquisición de datos y constituye el núcleo del sistema de monitoreo y análisis. Está conectado al router mediante un cable Ethernet, lo que asegura una conexión estable y de alta velocidad. Este equipo está configurado para escuchar en múltiples puertos TCP, cada uno de los cuales corresponde a un sensor o conjunto de sensores determinados, lo que permite una identificación clara del origen de cada flujo de datos.

Una vez recibidos, los datos pueden ser visualizados en tiempo real a través de entornos de desarrollo como Python o plataformas de visualización. Además, este computador puede ejecutar sistemas de almacenamiento y procesamiento más avanzados, como bases de datos, sin que esto afecte la arquitectura de comunicación previamente

establecida. El computador también actúa como centro de configuración, permitiendo verificar el funcionamiento del sistema, ajustar parámetros operativos y exportar los datos recopilados para análisis externos.

4.3 Requerimientos de Software y Flujo de Datos

Una vez que los datos provenientes de los sensores instalados en las máquinas del Taller Metalmecánico son transmitidos a través de la red local inalámbrica y recibidos por el computador, se inicia una nueva etapa correspondiente al manejo, tratamiento y almacenamiento de la información. Esta fase resulta crítica dentro del modelo de monitoreo bajo el paradigma de Mantenimiento 4.0, ya que establece la base para la visualización, análisis y diagnóstico predictivo de las condiciones operativas de las máquinas.

El computador ha sido configurado como nodo final de la arquitectura de red y se encuentra conectado al router mediante una conexión Ethernet, lo cual garantiza una comunicación estable, de alta velocidad y libre de interferencias electromagnéticas. En su configuración, el equipo está programado para escuchar múltiples puertos TCP donde cada puerto corresponde a un sensor o conjunto de sensores definidos. Esto permite recibir en tiempo real los flujos de datos que provienen desde los módulos de adquisición instalados en las fresadoras y otras máquinas.

Los datos llegan codificados en texto plano bajo el estándar ASCII. Este formato facilita la interpretación directa de la información, ya que no requiere decodificación compleja ni estructuras propietarias.

Para el tratamiento de estos datos, se emplea un script desarrollado en Python, lenguaje de programación ampliamente utilizado en el ámbito del análisis de datos industriales debido a su versatilidad, legibilidad y amplia biblioteca de herramientas. El script en Python cumple la función de capturar los datos entrantes desde los puertos TCP, interpretar el contenido del mensaje, separar cada variable de acuerdo con su etiqueta y convertir los datos desde texto plano a tipos numéricos manejables.

Este script se ejecuta dentro de un contenedor de Docker, una plataforma de virtualización ligera que permite encapsular aplicaciones junto con su entorno de ejecución. Docker asegura que el comportamiento del script sea replicable y consistente, independiente del sistema operativo o hardware en el cual se ejecute. Esto ofrece una gran ventaja en términos de portabilidad y escalabilidad del sistema, especialmente si se considera una futura expansión del modelo a otras máquinas del taller.

Una vez estructurados, los datos se envían a una base de datos no relacional MongoDB, instalada localmente en el computador de procesamiento. MongoDB permite almacenar grandes volúmenes de información en estructuras flexibles, sin requerir un esquema fijo de tablas como en las bases de datos relacionales. Esta característica es especialmente útil para registrar datos provenientes de sensores, los cuales pueden variar en frecuencia, tipo o estructura. En la configuración actual, cada entrada en la base de datos contiene información como el tipo de variable medida, el valor registrado, la máquina de origen y una marca temporal, permitiendo realizar consultas, análisis históricos y visualización de tendencias.

4.4 Selección de Algoritmo de Machine Learning

La incorporación de técnicas de Machine Learning constituye un paso decisivo para consolidar el Mantenimiento Predictivo 4.0, en tanto permite transformar los datos de los sensores en pronósticos de falla confiables y accionables. El éxito de este enfoque depende, en gran medida, de una selección de un algoritmo adecuado, sustentada metodológicamente y coherente con el contexto operativo del Taller Metalmecánico.

Para poder dar un paso en la implementación del modelo de mantenimiento para el TMM es que esta sección se va a centrar en seleccionar un algoritmo de ML adecuado para el pronóstico de fallas dentro de los equipos del taller en base a una metodológica sólida para la implementación de algoritmos que optimicen la gestión del mantenimiento dentro del taller.

El objetivo analítico se orienta a la estimación de la vida útil remanente (RUL), entendida como el tiempo estimado que resta antes de que un activo o componente alcance un estado de falla o pierda su funcionalidad. Para abordar esta tarea, se considerarán inicialmente los algoritmos más utilizados en la industria para este propósito.

La selección del algoritmo se basa en criterios como la complejidad de los datos, los recursos computacionales disponibles, facilidad de uso y otros criterios relevantes para una correcta selección que se alinee con la infraestructura y necesidad del TMM.

4.4.1 Algoritmos Propuestos para la Estimación de RUL

Con el fin de obtener una correcta selección de algoritmo coherente con los objetivos del Mantenimiento Predictivo 4.0, se consideran las familias de métodos con mayor validación en la industria para la estimación del RUL [29]. En términos generales, los enfoques se agrupan en dos categorías: (i) aprendizaje automático, y (ii) aprendizaje profundo.

- i. Algoritmos basados en aprendizaje automático. Esta familia de algoritmos comprende técnicas orientadas a identificar relaciones y patrones en datos históricos y de operación, generando modelos predictivos robustos con costos de implementación moderados. Dentro de esta clasificación se consideran los algoritmos de Random Forest, Regresión Lineal, Gradient Boosting Machine (GBM) y Support Vector Machine (SVM).
- ii. Algoritmos basados en aprendizaje profundo. Se caracterizan por utilizar redes neuronales con múltiples capas para aprender representaciones jerárquicas y complejas de los datos. Los algoritmos más utilizados que se considerarán son Redes Neuronales Recurrentes (RNN), Long Short-Term Memory (LSTM) y Convolutional Neural Networks (CNN).

4.4.2 Criterios de Evaluación y Ponderación

Con el objeto de asegurar que la selección del algoritmo de ML se ajuste a los requerimientos operacionales y tecnológicos del TMM, se establecen criterios de evaluación explícitos y un esquema de ponderación que refleje su importancia relativa. La decisión se abordará como un problema de toma de decisiones multicriterio mediante suma ponderada, a partir de los criterios definidos a continuación.

- a. Precisión /exactitud: capacidad del modelo para estimar el RUL con un error bajo y mínima dispersión.
- b. Robustez frente al ruido y condiciones variables: qué tan bien mantiene el rendimiento cuando los datos contienen ruido, outliers o cambios de condiciones operativas.
- c. Cantidad de datos necesarios: volumen mínimo de datos requeridos para un entrenamiento adecuado.
- d. Dependencia de datos etiquetados: grado en que el algoritmo necesita datos con RUL u observaciones de falla reales para su entrenamiento.
- e. Tipo de datos soportados: capacidad para operar con series de datos multivariadas, señales crudas de sensores y/o datos tabulares preprocesados.
- f. Requerimientos computacionales: Recursos de hardware y tiempo necesarios para entrenamiento validación y despliegue en producción.
- g. Escalabilidad: capacidad para manejar grandes volúmenes de datos o funcionamiento en tiempo real.
- h. Facilidad de uso: simplicidad de implementación, configuración y operación del algoritmo.
- i. Compatibilidad con la infraestructura existente: integración con el sistema de adquisición, y procesamiento de datos ya implementado.

Una vez definidos los criterios de selección del algoritmo, se determina su importancia relativa. Para ello, se elabora la Tabla 5, que asigna a cada criterio un

porcentaje de importancia y sirve como base para evaluar el grado de cumplimiento de cada criterio.

Tabla 5: Ponderación de criterios de selección para el algoritmo de Machine Learning.

	Criterio	Peso (%)
a	Precisión/ Exactitud	18
b	Robustez ante el ruido y condiciones	14
c	Cantidad de datos necesarios	8
d	Dependencia de datos etiquetados	7
e	Tipo de datos soportados	12
f	Requerimientos computacionales	8
g	Escalabilidad	8
h	Facilidad de uso	10
i	Compatibilidad con infraestructura	15

4.4.3 Comparación y Análisis de Algoritmos

De acuerdo con los criterios establecidos en la sección anterior, cada algoritmo se evaluó mediante una escala de 1-4 (siendo 1 un desempeño bajo y 4 un desempeño alto) para reflejar cada criterio. La Tabla 6 presenta los resultados asignados a cada algoritmo con el criterio.

Tabla 6: Resultado de comparación de algoritmos.

	a	b	c	d	e	f	g	h	i	Resultado
Random Forest	3	3	3	3	2	3	3	4	4	3.13
Regresion Lineal	2	2	4	3	2	4	3	4	4	2.97
Gradient Boosting Machine	3	3	3	3	2	3	3	3	4	3.13
SVM	2	2	4	3	2	4	3	4	4	2.97
Long Short-Term Memory	4	3	1	2	4	1	3	2	2	2.66
Redes Neuronales Recurrentes	3	2	2	2	3	2	2	2	2	2.3
Convolutional Neural Networks	4	3	1	2	4	1	3	2	2	2.66

En cuanto a los resultados en la Tabla 6, es posible establecer los siguientes comentarios:

- Random Forest: opción equilibrada y confiable para estimar la RUL, ofrece buenos resultados iniciales y maneja con solidez datos con ruido y valores atípicos.

Funciona adecuadamente con volúmenes de datos medianos, no requiere hardware especializado, presenta tiempos de entrenamiento moderados e inferencia rápida. Si bien no modela de forma nativa la secuencia temporal y se integra con facilidad a la infraestructura existente, con una interpretabilidad operativa razonable.

- Regresión Lineal: modelo sencillo que puede estimar el RUL en sistemas con relaciones claramente lineales entre variables y degradación. Es fácil de implementar, interpretar y requiere pocos datos y recursos, aunque es sensible al ruido y pierde precisión en entornos industriales complejos o con relaciones no lineales. Funciona bien con datos tabulares, pero necesita procesamiento adicional para manejar secuencias o dependencias temporales.
- Gradient Boosting Machine: ofrece alta precisión en datos tabulares y, con buenas características temporales. Manejan bien el ruido y los valores atípicos, aunque requieren un ajuste cuidadoso para evitar sobreajuste. Funcionan mejor con datos tabulares y necesitan preprocesamiento para señales o secuencias. Son supervisados, por lo que dependen de etiquetas de calidad. Aunque su ajuste es más complejo, cuentan con bibliotecas que facilitan su implementación. Escalan bien a grandes volúmenes de datos y se integran fácilmente a sistemas existentes sin requerir hardware especializado.
- SVM: alcanza buena precisión en RUL cuando las relaciones no son lineales y los datos son pequeños o medianos, especialmente usando kernels adecuados. Es sensible al ruido y requiere ajuste cuidadoso de parámetros. Funciona bien con datos tabulares, pero necesita procesamiento adicional para secuencias. Su entrenamiento puede ser costoso en grandes volúmenes, aunque la inferencia suele ser rápida, y se integra fácilmente sin requerir infraestructura especial.
- LSTM: logra muy buena precisión en RUL al detectar patrones temporales y degradación en datos secuenciales, especialmente con señales crudas y multivariadas. Sin embargo, requiere gran cantidad de datos y etiquetas precisas, además de conocimientos técnicos y alto poder de cómputo, generalmente con unidad de procesamiento gráfico (GPU). Aunque puede integrarse a sistemas

existentes, suele implicar la incorporación de nuevas herramientas y hardware especializado.

- RNN: ofrecen buen rendimiento en series de datos cortas y pueden manejar información secuencial y multivariable, pero presentan limitaciones para capturar dependencias largas. Son más inestables y propensas al sobreajuste si no se aplican técnicas de regularización, y requieren un volumen moderado de datos con etiquetas de calidad para predecir el RUL. Aunque sigue siendo más costosas que los modelos clásicos y necesitan entornos y herramientas especializadas para su implementación, lo que puede implicar ajustes en la infraestructura existente.
- CNN: pueden lograr alta precisión en la estimación de RUL al detectar patrones locales en señales crudas o transformadas, aunque requieren un preprocesamiento adecuado para evitar aprender información irrelevante. Funcionan mejor con grandes volúmenes de datos y corren riesgo de sobreajuste si las muestras son limitadas. Son versátiles y adaptables a distintos formatos, pero no capturan dependencias temporales prolongadas sin combinarse con otros modelos. Su implementación demanda conocimientos especializados y recursos de hardware, aunque su integración es posible con ajustes en la infraestructura.

En base a los resultados obtenidos en la Tabla 6, las mejores opciones de algoritmo para implementar en el taller son Random Forest y Gradient Boosting Machine.

5. Plan Piloto

En este capítulo se propone un plan piloto para la implementación del modelo de sensorización dentro del TMM de la Universidad Técnica Federico Santa María en el Campus San Joaquín, llevando a cabo el modelo propuesto en el capítulo 2.

En primer lugar, se presenta la situación actual del taller metalmecánico, para contextualizar, luego se identifican los equipos presentes, luego se determinan los equipos donde es conveniente implementar el modelo, luego se presenta el modelado de confiabilidad por medio de un análisis FMECA, donde se determinan las variables a monitorear en los equipos.

Luego se sugiere el CMMS a utilizar para el modelo, además de sugerir la instalación de sensores, el algoritmo predictivo. Finalmente se verifica la efectividad del modelo.

5.1 Clasificación del Valor y Selección de Activos del TMM

En primera instancia, se recopila información sobre los activos presentes en el TMM que son aptos para la implementación del modelo de Mantenimiento 4.0. El TMM cuenta con una variedad de equipos y herramientas esenciales para los procesos de manufactura por arranque de viruta y soldadura, incluyendo fresadoras, tornos, rectificadoras, taladros, sierras, esmeriles y maquinaria CNC.

Para la elección de equipos, se tiene en consideración aquellos activos de mayor importancia donde sea factible instalación de sensores para el seguimiento de señales de operación, por lo que no se considerarán las máquinas de soldadura. Asimismo, actualmente dos tornos del taller cuentan con sensores de aceleración, RPM y temperatura, instalados en el marco de implementación de Mantenimiento 4.0.

En la Tabla 7 se encuentran los activos existentes en el TMM, junto con sus cantidad y tipo de activo correspondiente.

Tabla 7: Activos existentes TMM [64].

Activo	Cantidad	Tipo de activo
Fresadora	5	Fresadora de 4 [kW]
Torno	10	Torno 3,5 [kW]
	1	Torno 7,5 [kW]
Rectificadora	1	Rectificadora Cilíndrica
	1	Rectificadora Tangencial
Taladros	4	Taladros de 4 [HP]
Sierra	1	Sierra horizontal
Esmeril	4	Esmeril de pedestal
CNC	1	Centro de mecanizado CNC

De los activos presentados en la Tabla 7, las fresadoras se identifican como los equipos más viables para la aplicación del plan piloto propuesto, debido a su relevancia operativa y a la factibilidad de técnica.

A continuación, en la Tabla 8 se presentan las especificaciones técnicas de la fresadora universal.

Tabla 8: Especificaciones técnicas fresadora.

SKAND	
Nombre	Fresadora universal
Modelo	XW6134
Número de serie	201004022
Peso	2200 kg
Potencia del motor	4 kW
RPM máxima	1800

5.2 Modelación de la confiabilidad TMM

Con el objetivo de determinar los parámetros operacionales a monitorear, se recurre al análisis FMECA presentado en el capítulo 2. Para llevar a cabo un estudio detallado de la

fresadora convencional, dicho análisis se estructura en función de sus principales subsistemas: husillo, carro longitudinal, ménsula y cabezal vertical.

Para cada uno de estos subsistemas, se identifica la función principal que permite definir el marco del análisis funcional y establecer la relación entre los modos de falla, sus efectos y las variables críticas asociadas.

- Husillo: entregar a la herramienta de corte la velocidad de rotación seleccionada dentro del rango de velocidades definido por el fabricante de la fresadora, manteniendo un giro estable bajo las condiciones de carga de corte normales y sin superar los niveles de vibración aceptables para el cabezal.
- Carro longitudinal: permitir el desplazamiento controlado de la mesa a lo largo del eje X en todo el recorrido útil establecido para la máquina, con una precisión de posicionamiento compatible con las tolerancias de mecanizado especificadas por el fabricante y por el taller, y sin movimientos bruscos, atascos ni holguras apreciables, soportando la carga máxima de pieza admisible para la fresadora.
- Ménsula: soportar el peso de la mesa, del carro longitudinal y de la pieza de trabajo hasta la carga máxima admisible indicada por el fabricante, permitiendo el ajuste vertical del conjunto sin desplazamientos espontáneos ni pérdidas de posición y manteniendo la perpendicularidad y el alineamiento especificados entre la mesa, la columna y el husillo durante el mecanizado.
- Cabezal vertical: posicionar verticalmente el husillo respecto de la pieza y permitir su descenso controlado a lo largo del eje Z en todo el recorrido útil disponible, de modo de ajustar la profundidad de corte con la resolución y precisión de posicionamiento indicadas por el fabricante, y sin variaciones inesperadas de posición, atascos ni holguras apreciables durante el mecanizado.

Una vez identificados los subsistemas principales de la fresadora, se procede a su análisis individual, presentando en cada caso las fallas funcionales, los modos de falla, los efectos, las consecuencias asociadas y la criticidad correspondiente. Dado que los resultados obtenidos para el carro longitudinal, la ménsula y el cabezal vertical no evidencian niveles de criticidad elevados, el análisis FMECA de dichos subsistemas se incluye en el Anexo. A continuación, se exponen los resultados del análisis correspondiente al husillo, el cual concentra los modos de falla con mayor impacto en la operación de la máquina.

Para el husillo, se identifican las fallas funcionales y modos de fallos asociados, los cuales se presentan en la Tabla 9.

Tabla 9: Fallas funcionales y Modo de falla del husillo.

Falla Funcional	Modo de Falla	
Pérdida total de transmisión al husillo	1.1.1	Desgaste en ruedas dentadas
	1.1.2	Dientes fracturados en ruedas dentadas
	1.1.3	Correa de transmisión suelta o dañada
Sistema de selección de velocidades no permite mantener la velocidad	1.2.1	Acumulación de viruta o partículas en el interior de la caja
	1.2.2	Palanca de selección desconectada o desajustada
El conjunto husillo-transmisión no mantiene la rigidez y alineación requeridas en el mecanizado	1.3.1	Desgaste irregular de engranajes que provoca juego y golpes
	1.3.2	Poleas desalineadas
	1.3.3	Falta de lubricación en rodamientos o engranes del husillo

Una vez identificados los posibles modos de falla que pueden derivar en la pérdida de funcionalidad del husillo, es necesario establecer los efectos y consecuencias asociadas a cada uno de ellos. Estos resultados se presentan en la Tabla 10.

Tabla 10: Efectos y consecuencias de posibles modos de falla del husillo.

Modo de Falla	Efectos de la falla	Consecuencia de la falla
Desgaste en ruedas dentadas	Juego excesivo y pérdida de contacto efectivo entre engranajes, con disminución progresiva de la velocidad y el par entregado al husillo, acompañados de ruidos anormales.	Paros frecuentes de la fresadora, disminución de la capacidad de arranque de viruta y aumento de tiempos de ciclo, puede derivar en daño mayor de la caja de velocidades y necesidad de intervención correctiva prolongada.
Dientes fracturados en ruedas dentadas	Golpes, interrupción parcial o total del giro. Puede provocar parada del husillo o dañar componentes adyacentes.	Parada súbita del husillo durante el mecanizado, con riesgo de rotura de herramienta y daño de la pieza, además de posible afectación de otros engranajes. Genera paro de la máquina hasta el reemplazo de componentes.
Correa de transmisión suelta o dañada	Deslizamiento de la correa, reducción de velocidad y potencia transmitida, rotación inestable o intermitente.	Interrupciones repetitivas del proceso y pérdida de productividad, acabado superficial deficiente. Puede ocasionar sobrecarga en el motor y en rodamientos
Acumulación de viruta o partículas en el interior de la caja	Obstrucción mecánica, dificultad o imposibilidad de engranar una velocidad. Cambios bruscos o saltos entre velocidades.	Imposibilidad de utilizar ciertas velocidades y pérdida de flexibilidad operativa, con disminución de la disponibilidad por paradas no planificadas. En casos severos, bloqueo de la caja y necesidad de desmontaje completo para limpieza y reparación.
Palanca de selección desconectada o desajustada	El sistema no responde al accionamiento. La velocidad seleccionada no se engrana o se cambia de forma inestable durante el mecanizado.	Selección errónea o inestable de la velocidad de corte, generando piezas erróneas, desgaste acelerado de herramientas y reprocesos. Provoca pérdida de confiabilidad del equipo y mayores costos de operación.
Desgaste irregular de engranajes que provoca juego y golpes	Transmisión con sacudidas, variaciones de velocidad instantánea, incremento de vibración y ruido, y deterioro del acabado superficial de la pieza.	Incremento significativo de vibraciones y ruidos, piezas con tolerancias fuera de rango y rechazo de producción, además de aceleración del deterioro de rodamientos y elementos de transmisión.
Poleas desalineadas	Cargas radiales adicionales sobre rodamientos, vibración persistente del husillo y pérdida de precisión dimensional en el mecanizado.	Degradación progresiva de la precisión de la fresadora y afectando la calidad de las piezas, junto con mayor frecuencia de intervenciones de mantenimiento y reducción de la vida útil del husillo y su transmisión.
Falta de lubricación en rodamientos o engranes del husillo	Aumento de fricción, temperatura y ruido en la zona de husillo/caja de velocidades, desgaste acelerado de componentes y riesgo de agarrotamiento o falla catastrófica del conjunto.	Sobrecalentamiento y posible agarrotamiento del husillo, con parada prolongada de la máquina, sustitución de rodamientos/engranajes y elevados costos de reparación.

Finalmente, se realiza la jerarquización del riesgo, con el objetivo de identificar los modos de falla que presentan un mayor impacto operativo. Este análisis permite determinar qué variables resultan relevantes de monitorear para mitigar el riesgo asociado a dichos fallos. Los resultados se presentan en la Tabla 11.

Tabla 11: Jerarquización del riesgo según modos de falla para el husillo.

Modo de fallo	Frecuencia	Consecuencia		R=FxC
		Personas	Medio ambiente	
1.1.1	3	2	1	6
1.1.2	2	3	1	6
1.1.3	4	2	1	8
1.2.1	3	2	1	6
1.2.2	3	2	1	6
1.3.1	2	2	1	4
1.3.2	3	2	1	6
1.3.3	3	3	1	9

En este caso, los modos de falla más críticos identificados corresponden a la correa de transmisión suelta o dañada y a la falta de lubricación en rodamientos o engranajes del husillo.

A partir del análisis FMECA realizado, se concluye que las variables más convenientes de monitorear en tiempo real para la fresadora son la vibración y la temperatura, ya que estos parámetros presentan una alta incidencia en la detección de los efectos y consecuencias asociadas a los modos de falla más relevantes.

5.3 Implementación de ERP/CMMS en el TMM

Para la implementación del ERP/CMMS se propone dar continuidad al sistema ya utilizado en los tornos. En consecuencia, el software seleccionado para la gestión del mantenimiento es Fracttal, dado que existe un convenio vigente con esta empresa que otorga acceso a la plataforma y a sus herramientas de gestión para su uso en el TMM.

Fracttal es una plataforma digital de gestión de mantenimiento y activos físicos, desarrollada bajo un enfoque completamente basado en la nube y concebida para responder

a los desafíos del paradigma de Mantenimiento 4.0. Su propósito principal es integrar en un mismo entorno digital todas las actividades relacionadas con la administración de activos, desde la planificación y ejecución de órdenes de trabajo hasta el control de inventarios, repuestos, costos, recursos humanos y reportes de desempeño. La solución se distingue por estar diseñada para ser utilizada desde diferentes dispositivos (teléfonos, tablets, computadores), lo que permite que tanto técnicos como supervisores accedan de manera ágil a la información operativa desde dispositivos móviles, incluso en condiciones de trabajo sin conectividad, asegurando así continuidad y trazabilidad en los procesos.

A diferencia de un CMMS tradicional, Fracttal no se limita a la programación de rutinas preventivas, sino que habilita un mantenimiento basado en condición, integrando información proveniente de sensores con la gestión administrativa y estratégica de los activos. En términos de beneficios concretos, la implementación de Fracttal ha demostrado aportar a la reducción de los costos globales de mantenimiento gracias a la optimización de recursos, al incremento de la disponibilidad operativa de los equipos y a la disminución de las fallas recurrentes.

Además, Fracttal se caracteriza por su interfaz intuitiva. Una vez iniciada la sesión, la pantalla principal corresponde al dashboard que centraliza indicadores y accesos a los módulos de la plataforma, como se muestra en la Figura 9.




Figura 9: Vista del dashboard de la plataforma Fracttal.

Como se observa en la Figura 9 desde el dashboard se visualiza las órdenes de trabajo ya sean en revisión en proceso, finalizadas y atrasadas, además de otras métricas importantes como severidad de las fallas, tareas planificadas vs no planificadas, lo cual facilita una evaluación rápida del estado del mantenimiento cuando se dispone de poco tiempo para el análisis.

En la parte superior derecha podemos acceder al menú principal el cual se ve como en la Figura 10 desde el cual es posible ingresar a los módulos de almacenes, tareas, monitoreo, automatizador ente otro, permitiendo gestionar el mantenimiento de manera ordenada y eficiente.




Figura 10: Vista menú principal plataforma Fractal.

5.4 Monitoreo del Rendimiento en Tiempo Real de Activos del TMM

Para el monitoreo en tiempo real de la fresadora, es necesaria la instalación de sensores para medir las variables críticas establecidas en la sección 5.2. En esta parte es fundamental que los sensores sean compatibles con el ecosistema actual del taller.

Para la instalación de sensores se contemplan dos alternativas. La primera consiste en replicar el enfoque aplicado en los tornos que es contratar a la empresa Technomechanics, que ejecutó la instrumentación previa, para realizar la instalación. Esta opción garantiza la interoperabilidad con la red del TMM y la comunicación confiable de los sensores con el router y la estación de procesamiento

La segunda opción es efectuar la instalación de sensores por cuenta propia, manteniendo la compatibilidad con la arquitectura vigente, según lo establecido en la sección 5.2 las variables más críticas para la fresadora con vibraciones y temperatura.

La Figura 11 muestra una alternativa de sensor para las variables críticas a medir.



Figura 11: Sensor Fractal Sense [66].

El sensor Fractal Sense Pulse representa una solución robusta y eficaz para la incorporación de variables clave como vibración y temperatura dentro de sistemas de monitoreo basados en el paradigma de Mantenimiento 4.0. Este dispositivo ha sido diseñado específicamente para entornos industriales, destacándose por su capacidad de operación autónoma, comunicación inalámbrica y facilidad de integración en arquitecturas de red preexistentes.

Desde una perspectiva funcional, el dispositivo combina medición de vibración (a través de velocidad RMS en mm/s) con medición de temperatura mediante el sensor DS18B20, lo que permite obtener información crítica del estado dinámico de componentes rotativos y condiciones térmicas de operación.

Las especificaciones técnicas del sensor Fractal Sense Pulse son las mostradas en la Tabla 12.

Tabla 12: Especificaciones técnicas Fractal Sense Pulse

Fractal Sense Pulse	
Sensor vibración rango	0- 25,4 mm/s
Sensor temperatura	-55 a 125°C
Comunicación	Ethernet TCP/IP y Wi-Fi
Conexión	RJ45

Una de las principales ventajas del Fractal Sense Pulse es su capacidad de transmisión de datos vía Wi-Fi utilizando el protocolo TCP/IP, lo que permite su incorporación directa en la red local inalámbrica ya configurada en el taller. Esta característica lo vuelve plenamente compatible con la infraestructura establecida, la cual contempla un router TP-Link como punto de acceso y un computador de procesamiento local encargado de recibir los datos. Al operar sobre el mismo tipo de red y protocolo, no requiere reconfiguraciones significativas ni dispositivos intermedios adicionales, facilitando su instalación y mantenimiento.

Asimismo, el sensor cumple con los requerimientos técnicos asociados a formato de salida en texto plano, posibilidad de configurar dirección IP, SSID y puerto de destino, y soporte para alimentación autónoma. Estos elementos aseguran una comunicación eficiente

y una integración transparente con los scripts de adquisición de datos desarrollados en Python, los cuales están implementados en contenedores Docker para estandarizar su ejecución y procesamiento dentro del sistema ya operativo en el taller. En este sentido, el Fracttal Sense Pulse entrega su información en un formato directamente interpretable por el software actual, lo que reduce la necesidad de preprocesamiento adicional o conversión de protocolos.

Una ventaja adicional de emplear sensores como el Fracttal Sense Pulse radica en su alta compatibilidad nativa con la plataforma Fracttal, el sistema CMMS que actualmente está siendo utilizado en el Taller Metalmecánico. Al tratarse de un dispositivo desarrollado por la misma empresa, la integración entre hardware y software se realiza de forma fluida y directa, permitiendo que los datos provenientes de los sensores se sincronicen automáticamente con los módulos de gestión de mantenimiento, activos y planificación de intervenciones de la plataforma. Esta interoperabilidad reduce significativamente los tiempos de configuración, evita problemas de compatibilidad entre distintos proveedores y facilita la trazabilidad de las variables monitoreadas en los activos del taller.

Se recomienda la opción del uso del sensor Fracttal Sense Pulse, puesto que cumple con las especificaciones técnicas requeridas en el taller y además es completamente compatible con la plataforma Fracttal.

5.5 Implementación del Algoritmo Predictivo o de Condición

En el marco de la implementación de un modelo de Mantenimiento 4.0, uno de los elementos clave es la incorporación de herramientas analíticas que permitan anticipar fallas en los activos mediante el análisis de datos operacionales. Para ello, se plantea como alternativa inicial el aprovechamiento de las funcionalidades disponibles en la plataforma Fracttal, actualmente utilizada como sistema de gestión de mantenimiento computarizado (CMMS) en el Taller Metalmecánico. Fracttal cuenta con módulos inteligentes que permiten la integración de datos de sensores, así como capacidades analíticas para el seguimiento del estado de los activos, generación automática de órdenes de trabajo y emisión de alertas.

Sin embargo, si bien Fracttal incorpora ciertos elementos de inteligencia artificial y automatización, su enfoque está principalmente orientado a la gestión del mantenimiento más que al análisis avanzado para la predicción de fallas específicas. La plataforma destaca por facilitar la planificación, trazabilidad y control de actividades de mantenimiento correctivo y preventivo, pero no proporciona herramientas avanzadas de modelamiento algorítmico que permitan estimar, por ejemplo, la vida útil remanente de componentes, detectar patrones ocultos de degradación o realizar clasificación de condiciones anómalas en base a datos históricos.

Por este motivo, una segunda opción con mayor potencial en términos de predicción es la incorporación de un algoritmo de Machine Learning externo al ecosistema de Fracttal. Este enfoque permite aplicar técnicas avanzadas de aprendizaje supervisado o no supervisado sobre las variables adquiridas por los sensores (como vibración, temperatura y RPM), con el objetivo de construir modelos que aprendan del comportamiento histórico de los equipos y sean capaces de anticipar condiciones de falla.

El desarrollo e integración de un algoritmo de ML ofrece un enfoque más profundo y flexible para abordar el mantenimiento predictivo, permitiendo adaptar el modelo a los datos específicos del taller, reentrenar con nuevas observaciones y generar métricas de rendimiento personalizadas.

5.6 Pronóstico de Posibles Fallas

Una vez los datos provenientes de los sensores se transfieren a Fracttal, se pueden generar alertas de órdenes de trabajo para tareas de mantenimiento, alertas en tiempo real por condiciones que permiten la gestión integral del mantenimiento dentro del software. Sin embargo, para esto es necesario implementar el modelo en las fresadoras para poner a cabo este paso.

5.7 Verificación de la Efectividad

Una vez formulado el modelo en las secciones anteriores, esta etapa se orienta a verificar su efectividad a través de un plan piloto, con foco en la evaluación de su factibilidad técnica. Esta verificación es clave para determinar la viabilidad de implementación del modelo de sensorización propuesto en el Taller Metalmecánico, asegurando su compatibilidad con la infraestructura existente y su coherencia con los objetivos del mantenimiento bajo el paradigma de Industria 4.0.

La evaluación de la factibilidad técnica considera distintos aspectos clave del modelo. Cada uno de estos elementos es analizado en función de su capacidad para operar de forma confiable en el entorno real del TMM, sin interferir con las rutinas productivas ni comprometer la seguridad o trazabilidad de los datos.

- Compatibilidad física: el sensor Fractal Sense Pulse ha sido diseñado para su uso en máquinas rotativas, presentando dimensiones y características constructivas que permiten su instalación sin interferir con las rutinas de operación ni comprometer la seguridad del personal. Cuenta con sistemas de fijación adecuados y una estructura resistente frente a las condiciones propias del entorno del taller, como la exposición a polvo, vibraciones mecánicas y variaciones de temperatura.
- Compatibilidad de comunicación: el sensor Fractal Sense Pulse es completamente compatible con la infraestructura de adquisición de datos existente en el Taller Metalmecánico. Su configuración permite la integración directa con el computador de procesamiento, utilizando los mismos protocolos de comunicación ya implementados en el taller (Wi-Fi y TCP/IP). Esto garantiza que la información generada por el sensor sea transmitida y procesada de forma continua, sin requerir ajustes en la red ni incorporación de equipos adicionales.
- Compatibilidad técnica: el sensor cumple con los requerimientos técnicos necesarios para su instalación en fresadoras convencionales, en el contexto de un modelo de monitoreo basado en condición. Los rangos de medición que ofrece se ajustan a las magnitudes típicamente presentes en este tipo de máquinas, lo que

permite capturar información representativa del estado operativo sin necesidad de modificaciones adicionales en la configuración o en el entorno físico de la máquina.

- Integración con el CMMS: al tratarse de un sensor desarrollado por la misma empresa proveedora del software Fractal, su integración con el sistema de gestión de mantenimiento es nativa. Esto permite vincular directamente los datos de condición al activo correspondiente, generar alertas automáticas en función de umbrales configurados y asociar eventos a órdenes de trabajo, tareas planificadas o reportes. Esta interoperabilidad facilita la trazabilidad entre las variables monitoreadas y la gestión operativa del mantenimiento en el Taller Metalmecánico.

A partir de los aspectos evaluados, se concluye que la factibilidad técnica del modelo propuesto es favorable. Su implementación puede llevarse a cabo de manera eficiente, sin interferir con las operaciones actuales del Taller Metalmecánico, y con plena compatibilidad con la infraestructura digital existente. Asimismo, el modelo aporta un valor concreto a la gestión de activos, al habilitar el monitoreo en tiempo real de variables críticas y sentar las bases para el desarrollo de estrategias de mantenimiento predictivo.

CONCLUSIONES

La propuesta de un modelo de sensorización de máquinas fresadoras convencionales en el Taller Metalmecánico San Joaquín constituye un avance relevante en la gestión del mantenimiento orientado al pronóstico de fallas. Al desarrollarse bajo el paradigma de la Industria 4.0, esta iniciativa representa un paso decisivo hacia la digitalización de los procesos de mantenimiento dentro del taller. Asimismo, la propuesta se encuentra plenamente alineada con la infraestructura tecnológica previamente implementada en los tornos, asegurando coherencia y continuidad en la estrategia de transformación digital del TMM.

La definición de los elementos que conforman el modelo permite establecer de manera detallada cada una de las etapas del proceso de sensorización en las máquinas fresadoras, las cuales sirven de base para el plan piloto. Asimismo, la evaluación del estado actual del mantenimiento en el Taller Metalmecánico permite identificar su nivel de madurez, lo cual permite proponer mejoras acordes a la realidad del taller y coherentes con los requerimientos de la transformación digital.

La definición de los requerimientos técnicos de los sensores, protocolos de comunicación y software establece un estándar orientado a garantizar la compatibilidad, la calidad de la información y la posibilidad de escalar y replicar el modelo en otras máquinas del taller. A su vez, la ejecución del plan piloto asociado a la propuesta permite evaluar la factibilidad técnica de la implementación, confirmando la viabilidad del modelo.

Es importante señalar que, al tratarse de una propuesta, el alcance de este trabajo se enfocó principalmente en la definición y validación técnica del modelo de sensorización. La etapa predictiva, asociada a la aplicación de algoritmos de Machine Learning, requiere de la recopilación de datos operacionales en condiciones reales para ser evaluada con mayor profundidad y puesta a prueba de manera efectiva, por lo que puede ser abordado con mayor detalle en trabajos de título futuros.

Este trabajo presenta una propuesta sólida para la implementación de un modelo de sensorización en las fresadoras del Taller Metalmecánico, constituyendo un avance significativo en la transformación digital del mantenimiento hacia un enfoque de Mantenimiento Predictivo 4.0. Se recomienda dar continuidad a la implementación del modelo en estas máquinas, con el fin de consolidar un sistema integral de monitoreo y análisis que no solo optimice la gestión de activos, sino que también potencie la formación académica de los estudiantes, alineándola con las competencias de la Cuarta Revolución Industrial.

BIBLIOGRAFÍA

- [1] S. Pfeiffer, «The Vision of “Industrie 4.0” in the Making—a Case of Future Told, Tamed, and Traded», *Nanoethics*, vol. 11, n.º 1, pp. 107-121, abr. 2017, doi: 10.1007/s11569-016-0280-3.
- [2] Z. M. Çinar, A. A. Nuhu, Q. Zeeshan, O. Korhan, M. Asmael, y B. Safaei, «Machine learning in predictive maintenance towards sustainable smart manufacturing in industry 4.0», *Sustainability (Switzerland)*, vol. 12, n.º 19, oct. 2020, doi: 10.3390/su12198211.
- [3] Realidad Profesional, «Uno, dos, tres, cuatro: la nueva Revolución Industrial», *Revista del Consejo Profesional de Ciencias Económicas de la Provincia de Buenos Aires y su Caja de Seguridad Social*, Buenos Aires, 31 de diciembre de 2021. Accedido: 28 de abril de 2025. [En línea]. Disponible en: https://reprodigital.com.ar/nota/653/uno_dos_tres_cuatro_la_nueva_revolucion_industrial
- [4] N. Elgendy y A. Elragal, «Big data analytics: A literature review», en *Advances in Data Mining. Applications and Theoretical Aspects (ICDM 2014)*, Petra Perner, Ed., Charm: Springer, 2014, pp. 214-227. doi: 10.1007/978-3-319-08976-8_16.
- [5] D. R. Espinoza Venegas, «Plan de Transformación de una Maestría Convencional al Paradigma de Cuarta Revolución Industrial en la Dimensión de Procesos de Mantenimiento», Memoria de titulación (Ingeniero Civil Mecánico), Universidad Técnica Federico Santa María, Santiago, 2020. Accedido: 6 de agosto de 2022. [En línea]. Disponible en: <https://repositorio-usm-cl.usm.idm.oclc.org/bitstream/handle/11673/50006/3560902038972UTFSM.pdf?sequence=1&isAllowed=y>
- [6] A. I. Basco, G. Beliz, D. Coatz, y P. Garneró, *Industria 4.0: Fabricando el Futuro*. Buenos Aires, Argentina: Banco Interamericano de Desarrollo (BID), 2018. doi: 10.18235/0001229.

- [7] M. Ekici, A. Ç. Seçkin, A. Özek, y C. Karpuz, «Warehouse Drone: Indoor Positioning and Product Counter with Virtual Fiducial Markers», *Drones*, vol. 7, n.º 1, p. 3, ene. 2023, doi: 10.3390/drones7010003.
- [8] T. DebRoy *et al.*, «Additive manufacturing of metallic components – Process, structure and properties», *Prog Mater Sci*, vol. 92, pp. 112-224, mar. 2018, doi: 10.1016/j.pmatsci.2017.10.001.
- [9] A. Fuller, Z. Fan, C. Day, y C. Barlow, «Digital Twin: Enabling Technologies, Challenges and Open Research», *IEEE Access*, vol. 8, pp. 108952-108971, 2020, doi: 10.1109/access.2020.2998358.
- [10] R. Alguliyev, Y. Imamverdiyev, y L. Sukhostat, «Cyber-physical systems and their security issues», *Comput Ind*, vol. 100, pp. 212-223, sep. 2018, doi: 10.1016/j.compind.2018.04.017.
- [11] A. Al-Fuqaha, M. Guizani, M. Mohammadi, M. Aledhari, y M. Ayyash, «Internet of Things: A Survey on Enabling Technologies, Protocols, and Applications», *IEEE Communications Surveys & Tutorials*, vol. 17, n.º 4, pp. 2347-2376, 2015, doi: 10.1109/COMST.2015.2444095.
- [12] P. Mell y T. Grance, «The NIST Definition of Cloud Computing», National Institute of Standards and Technology (NIST), 2011. [En línea]. Disponible en: <https://csrc.nist.gov/publications/detail/sp/800-145/final>
- [13] M. Armbrust *et al.*, «A View of Cloud Computing», *Commun ACM*, vol. 53, n.º 4, pp. 50-58, 2010, doi: 10.1145/1721654.1721672.
- [14] Akamai Technologies, «Akamai», ¿Qué es una plataforma en la nube? Accedido: 24 de octubre de 2024. [En línea]. Disponible en: <https://www.akamai.com/es/glossary/what-is-a-cloud-platform>
- [15] R. T. Azuma, «A Survey of Augmented Reality», *Presence: Teleoperators and Virtual Environments*, vol. 6, n.º 4, pp. 355-385, 1997, doi: 10.1162/pres.1997.6.4.355.

- [16] R. Palmarini, J. A. Erkoyuncu, R. Roy, y H. Torabmostaedi, «A systematic review of augmented reality applications in maintenance», *Robot Comput Integr Manuf*, vol. 49, pp. 215-228, 2018, doi: 10.1016/j.rcim.2017.06.002.
- [17] M. Jasiulewicz-Kaczmarek, S. Legutko, y P. Kluk, «Maintenance 4.0 technologies – new opportunities for sustainability driven maintenance», *Management and Production Engineering Review*, vol. 11, n.º 2, pp. 74-87, jun. 2020, doi: 10.24425/mper.2020.133730.
- [18] C. Franciosi, A. Voisin, S. Miranda, y B. Iung, «Integration of I4.0 technologies with maintenance processes: What are the effects on sustainable manufacturing?», *IFAC-PapersOnLine*, vol. 53, n.º 3, pp. 1-6, 2020, doi: 10.1016/j.ifacol.2020.11.001.
- [19] M. Jasiulewicz-Kaczmarek y A. Gola, «Maintenance 4.0 Technologies for Sustainable Manufacturing - An Overview», *IFAC-PapersOnLine*, vol. 52, n.º 10, pp. 91-96, 2019, doi: 10.1016/j.ifacol.2019.10.005.
- [20] J. Bokrantz, A. Skoogh, C. Berlin, T. Wuest, y J. Stahre, «Smart Maintenance: a research agenda for industrial maintenance management», *Int J Prod Econ*, vol. 224, p. 107547, jun. 2020, doi: 10.1016/j.ijpe.2019.107547.
- [21] C. Ynzunza, J. Izar, M. Larios, F. Aguilar, J. Bocarando y Y. Acosta, «Tendencias de la gestión de los activos y el mantenimiento predictivo en la industria 4.0: Potencialidades y beneficios», *Revista de Aplicaciones de la Ingeniería*, vol. 4, n.º 11, pp. 30–43, jun. 2017. [En línea]. Disponible en: https://www.ecorfan.org/bolivia/researchjournals/Aplicaciones_de_la_Ingenieria/vol4_num11/Revista_Aplicaciones_de_la_Ingenieria_V4_N11.pdf.
- [22] T. Zonta, C. A. da Costa, R. da Rosa Righi, M. J. de Lima, E. S. da Trindade, y G.-P. Li, «Predictive maintenance in the Industry 4.0: A systematic literature review», *Comput Ind Eng*, vol. 150, p. 106889, dic. 2020, doi: 10.1016/j.cie.2020.106889.
- [23] P. Poor, J. Basl, y D. Zenisek, «Predictive Maintenance 4.0 as next evolution step in industrial maintenance development», en *Proceedings - IEEE International Research Conference on Smart Computing and Systems Engineering, SCSE 2019*, Institute of

- Electrical and Electronics Engineers Inc., mar. 2019, pp. 245-253. doi: 10.23919/SCSE.2019.8842659.
- [24] PwC y Mainnovation, «Predictive Maintenance 4.0: Predict the unpredictable», jun. 2017. Accedido: 6 de mayo de 2025. [En línea]. Disponible en: <https://www.pwc.nl/nl/assets/documents/pwc-predictive-maintenance-4-0.pdf>
- [25] T. P. Carvalho *et al.*, «A systematic literature review of machine learning methods applied to predictive maintenance», *Comput Ind Eng*, vol. 137, p. 106024, 2019, doi: 10.1016/j.cie.2019.106024.
- [26] T. M. Mitchell, *Machine Learning*. New York, NY, USA: McGraw-Hill, 1997.
- [27] C. M. Bishop, *Pattern Recognition and Machine Learning*. New York, NY, USA: Springer, 2006.
- [28] G. A. Susto, A. Schirru, S. Pampuri, S. McLoone, y A. Beghi, «Machine Learning for Predictive Maintenance: A Multiple Classifier Approach», *IEEE Trans Industr Inform*, vol. 11, n.º 3, pp. 812-820, 2015, doi: 10.1109/TII.2014.2349359.
- [29] C. Ferreira y G. Gonçalves, «Remaining Useful Life prediction and challenges: A literature review on the use of Machine Learning Methods», 1 de abril de 2022, *Elsevier B.V.* doi: 10.1016/j.jmsy.2022.05.010.
- [30] V. Gunasegaran y V. Muralidharan, «Fault Diagnosis of Spur Gear System through Decision Tree Algorithm Using Vibration Signal», *Mater Today Proc*, vol. 22, pp. 3232-3239, 2020, doi: 10.1016/j.matpr.2020.03.283.
- [31] J. R. Quinlan, *C4.5: Programs for Machine Learning*. San Mateo, CA, USA: Morgan Kaufmann, 1993.
- [32] L. Breiman, «Random forests», *Mach Learn*, vol. 45, n.º 1, pp. 5-32, 2001, doi: 10.1023/A:1010933404324.
- [33] G. James, D. Witten, T. Hastie, y R. Tibshirani, *An Introduction to Statistical Learning*, 2.^a ed. New York, NY, USA: Springer, 2021.

- [34] Y. Lei, N. Li, L. Guo, N. Li, T. Yan, y J. Lin, «Machinery health prognostics: A systematic review from data acquisition to RUL prediction», *Mech Syst Signal Process*, vol. 104, pp. 799-834, 2018, doi: 10.1016/j.ymssp.2017.11.016.
- [35] J. H. Friedman, «Greedy Function Approximation: A Gradient Boosting Machine», *The Annals of Statistics*, vol. 29, n.º 5, pp. 1189-1232, 2001, doi: 10.1214/aos/1013203451.
- [36] T. Chen y C. Guestrin, «XGBoost: A Scalable Tree Boosting System», en *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD)*, 2016, pp. 785-794. doi: 10.1145/2939672.2939785.
- [37] C. Xiang, Z. Ren, P. Shi, y H. Zhao, «Data-Driven Fault Diagnosis for Rolling Bearing Based on DIT-FFT and XGBoost», *Complexity*, vol. 2021, pp. 1-13, 2021, doi: 10.1155/2021/4941966.
- [38] G. Ke *et al.*, «LightGBM: A Highly Efficient Gradient Boosting Decision Tree», en *Advances in Neural Information Processing Systems (NeurIPS)*, 2017, pp. 3146-3154.
- [39] C. Cortes y V. Vapnik, «Support-Vector Networks», *Mach Learn*, vol. 20, n.º 3, pp. 273-297, 1995, doi: 10.1007/BF00994018.
- [40] A. Widodo y B.-S. Yang, «Support vector machine in machine condition monitoring and fault diagnosis», *Mech Syst Signal Process*, vol. 21, n.º 6, pp. 2560-2574, 2007, doi: 10.1016/j.ymssp.2006.12.007.
- [41] R. Khelif, B. Chebel-Morello, S. Malinowski, E. Laajili, F. Fnaiech, y N. Zerhouni, «Direct Remaining Useful Life Estimation Based on Support Vector Regression», *IEEE Transactions on Industrial Electronics*, vol. 64, n.º 3, pp. 2276-2285, mar. 2017, doi: 10.1109/TIE.2016.2623260.
- [42] F. O. Heimes, «Recurrent Neural Networks for Remaining Useful Life Estimation», en *2008 International Conference on Prognostics and Health Management (PHM)*, 2008, p. 1. doi: 10.1109/PHM.2008.4711422.

- [43] L. Zhang, X. Li, W. Wang, y E. Zio, «A review on deep learning in prognostics and health management», *IEEE Access*, vol. 7, pp. 162415-162438, 2019, doi: 10.1109/ACCESS.2019.2950985.
- [44] S. Hochreiter y J. Schmidhuber, «Long Short-Term Memory», *Neural Comput*, vol. 9, n.º 8, pp. 1735-1780, 1997, doi: 10.1162/neco.1997.9.8.1735.
- [45] S. Zheng, K. Ristovski, A. Farahat, y C. Gupta, «Long Short-Term Memory Network for Remaining Useful Life Estimation», en *2017 IEEE International Conference on Prognostics and Health Management (ICPHM)*, 2017. doi: 10.1109/ICPHM.2017.7998311.
- [46] O. Janssens, V. Slavkovikj, R. Van de Walle, y S. Van Hoecke, «Convolutional Neural Network Based Fault Detection for Rotating Machinery», *J Sound Vib*, vol. 377, pp. 331-345, 2016, doi: 10.1016/j.jsv.2016.05.027.
- [47] M. Javaid, A. Haleem, R. P. Singh, S. Rab, y R. Suman, «Significance of sensors for industry 4.0: Roles, capabilities, and applications», 1 de enero de 2021, *KeAi Communications Co.* doi: 10.1016/j.sintl.2021.100110.
- [48] F. Civerchia, S. Bocchino, C. Salvadori, E. Rossi, L. Maggiani, y M. Petracca, «Industrial Internet of Things monitoring solution for advanced predictive maintenance applications», *J Ind Inf Integr*, vol. 7, pp. 4-12, sep. 2017, doi: 10.1016/j.jii.2017.02.003.
- [49] S. Sharma, R. K. Bansal, y S. Bansal, «Issues and challenges in wireless sensor networks», en *Proceedings - 2013 International Conference on Machine Intelligence Research and Advancement, ICMIRA 2013*, Institute of Electrical and Electronics Engineers Inc., oct. 2014, pp. 58-62. doi: 10.1109/ICMIRA.2013.18.
- [50] S. R. Maroto Cantillo, «Desarrollo de aplicaciones basadas en WSN», Universitat Politècnica de València (UPV), Valencia, 2010.
- [51] S. Namuduri, B. N. Narayanan, V. S. P. Davuluru, L. Burton, y S. Bhansali, «Review—Deep Learning Methods for Sensor Based Predictive Maintenance and

- Future Perspectives for Electrochemical Sensors», *J Electrochem Soc*, vol. 167, n.º 3, p. 037552, feb. 2020, doi: 10.1149/1945-7111/ab67a8.
- [52] D. Sehrawat y N. S. Gill, «Smart Sensors: Analysis of Different Types of IoT Sensors», en *2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI)*, Tirunelveli: IEEE, abr. 2019, pp. 523-528. doi: 10.1109/ICOEI.2019.8862778.
- [53] J. Fraden, *Handbook of Modern Sensors: Physics, Designs, and Applications*, 5.^a ed. Cham, Switzerland: Springer, 2016. doi: 10.1007/978-3-319-19303-8.
- [54] C. J. Yeager y S. S. Courts, «A Review of Cryogenic Thermometry and Common Temperature Sensors», *IEEE Sens J*, vol. 1, n.º 4, pp. 352-360, 2001, doi: 10.1109/7361.983476.
- [55] G. Korotcenkov, *Handbook of Humidity Measurement: Methods, Materials, and Technologies. Volume 3: Sensing Materials and Technologies*. Boca Raton, FL: CRC Press, Taylor & Francis Group, 2020.
- [56] A. K. S. Jardine, D. Lin, y D. Banjevic, «A review on machinery diagnostics and prognostics implementing condition-based maintenance», *Mech Syst Signal Process*, vol. 20, n.º 7, pp. 1483-1510, 2006, doi: 10.1016/j.ymssp.2005.09.012.
- [57] J. R. Aguilar-Otero, R. Torres-Arcique, y D. Magaña-Jiménez, «Análisis de modos de falla, efectos y criticidad (AMFEC) para la planeación del mantenimiento empleando criterios de riesgo y confiabilidad», *Ciencia Ed. (IMIQ)*, vol. 25, n.º 1, pp. 15-26, 2010.
- [58] L. Alberto. Mora Gutiérrez, *Mantenimiento: planeación, ejecución y control*, 1.^a ed. México: Alfaomega Grupo Editor, S.A. de C.V., 2009.
- [59] J. Rosales, «Análisis de vibraciones: qué es y como se realiza», *Fractal*. Accedido: 18 de mayo de 2025. [En línea]. Disponible en: <https://www.fractal.com/es/mantenipedia/que-es-el-analisis-de-vibraciones>

- [60] Preditec, «Mantenimiento predictivo: análisis de vibraciones», Preditec. Accedido: 18 de mayo de 2025. [En línea]. Disponible en: <https://www.preditec.com/mantenimiento-predictivo/analisis-de-vibraciones/>
- [61] J. Rosales, «¿Qué es el Análisis de Ultrasonido?», Fracttal. Accedido: 18 de mayo de 2025. [En línea]. Disponible en: <https://www.fracttal.com/es/mantenipedia/que-es-el-analisis-de-ultrasonido>
- [62] W. Olarte, M. Botero, y B. Cañón, «TÉCNICAS DE MANTENIMIENTO PREDICTIVO UTILIZADAS EN LA INDUSTRIA», *Scientia et Technica*, vol. 16, n.º 45, pp. 223-226, ago. 2010, doi: <https://doi.org/10.22517/23447214.355>.
- [63] A. Vedan, «Termografía en el mantenimiento predictivo», TRACTIAN. Accedido: 28 de mayo de 2025. [En línea]. Disponible en: <https://traction.com/es/blog/termografia-en-el-mantenimiento-predictivo>
- [64] J. S. Said Merino, «MODELO DE MEJORAMIENTO DE PROCESOS DE GESTIÓN DE MANTENIMIENTO DE ACTIVOS EN EL PARADIGMA DE LA INDUSTRIA 4.0», Universidad Técnica Federico Santa María, Santiago, 2024.
- [65] F. J. Gómez, «PROPUESTA DE SISTEMA DE GESTIÓN DE MANTENIMIENTO PARA TALLER METALMECÁNICO UTFSM CAMPUS SAN JOAQUÍN», Universidad Técnica Federico Santa María, Santiago, 2017. [En línea]. Disponible en: <http://hdl.handle.net/11673/40907>
- [66] Fracttal, «Dispositivos Fracttal Sense», Fracttal. Accedido: 7 de agosto de 2025. [En línea]. Disponible en: <https://www.fracttal.com/es/dispositivos-fracttal-sense>

ANEXOS

Anexo 1. Análisis FMECA de Subsistemas

Tabla 13: Fallas funcionales y Modo de falla del carro longitudinal.

Falla Funcional	Modo de Falla	
Imprecisión de la manivela	2.1.1	Desgaste de componentes
	2.1.2	Juego en husillo
	2.1.3	Desalineación en las guías
El carro se traba o se atasca durante el recorrido	2.2.1	Presencia de viruta
	2.2.2	Falta de lubricación en las guías
	2.2.3	Desgaste de rodamientos
El carro no mantiene la rigidez y alineación requeridas durante el mecanizado	2.3.1	Desgaste en rieles lineales
	2.3.2	Desalineación de guías
El carro no se desplaza al accionar el sistema	2.4.1	Rotura del husillo
	2.4.2	Presencia de viruta
	2.4.3	Sistema desacoplado

Tabla 14: Efectos y consecuencias de posibles modos de falla del carro longitudinal.

Modo de Falla	Efectos	Consecuencia de la falla
Desgaste de componentes	Juego en el sistema de avance. Requiere más giro para generar movimiento.	Pérdida progresiva de precisión. Riesgo de errores dimensionales en piezas mecanizadas. Mayor tiempo de ajuste manual.
Juego en husillo	Movimiento libre sin desplazamiento inmediato.	Inestabilidad del posicionamiento.
Desalineación en las guías	El carro se desvía de la trayectoria recta.	Genera piezas poco precisas.
Presencia de viruta	Bloqueo puntual del movimiento. Avance interrumpido.	Operación discontinua. Riesgo de deterioro si se fuerza el sistema.
Falta de lubricación en las guías	Aumento de fricción. Avance brusco o detenido.	Sobreesfuerzo de componentes mecánicos, reducción de vida útil del sistema de guiado.
Desgaste de rodamientos	Movimiento forzado o interrumpido. Ruidos anormales.	Movimiento no lineal del carro. Presencia de vibración
Desgaste en rieles lineales	Juego en el desplazamiento. Inestabilidad durante el mecanizado.	Vibración continua, deterioro acelerado de la calidad superficial, imposibilidad de mantener tolerancias ajustadas.
Desalineación de guías	Contacto puntual en lugar de lineal, distribución irregular de cargas, fricción variable.	Vibración excesiva, ruido metálico, esfuerzos laterales adicionales sobre rodamientos, desgaste acelerado.
Rotura del husillo	Imposibilidad total de desplazar el carro.	Falla crítica que detiene completamente la operación.
Presencia de viruta	Sistema atascado.	Imposibilidad de continuar el proceso.
Sistema desacoplado	Giro de la manivela sin respuesta. Ausencia total de transmisión al husillo.	Carro sin movimiento.

Tabla 15: Jerarquización del riesgo según modos de falla para el carro longitudinal.

Modo de fallo	Frecuencia	Consecuencia		R=FxC
		Personas	Medio ambiente	
2.1.1	Media	Menor	Menor	3
2.1.2	Media	Menor	Menor	3
2.1.3	Baja	Menor	Menor	2
2.2.1	Alta	Moderada	Menor	8
2.2.2	Media	Moderada	Menor	6
2.2.3	Media	Menor	Menor	3
2.3.1	Media	Moderada	Menor	6
2.3.2	Baja	Moderada	Menor	4
2.4.1	Baja	Moderada	Menor	4
2.4.2	Media	Moderada	Menor	6
2.4.3	Baja	Menor	Menor	2

Tabla 16: Fallas funcionales y Modo de falla de la ménsula.

Falla Funcional	Modo de Falla	
La ménsula no permite desplazamiento del carro longitudinal sobre el eje Y	3.1.1	Presencia de virutas
	3.1.2	Desgaste de rodamientos
	3.1.3	Falta de lubricación en las guías
La ménsula presenta movimiento irregular o trabas durante el avance.	3.2.1	Desgaste desigual de las guías
	3.2.2	Presencia de virutas
	3.2.3	Falta de lubricación en las guías

Tabla 17: Efectos y consecuencias de posibles modos de falla de la ménsula.

Modo de Falla	Efectos	Consecuencia de la Falla
Presencia de virutas	Obstrucción mecánica en las guías. Bloqueo parcial o total del movimiento.	Interrupción del avance. Desgaste localizado si se fuerza el desplazamiento. Posible daño a guía.
Desgaste de rodamientos	Aumento del esfuerzo requerido para desplazar el carro. Giro irregular. Posible desviación o inclinación del eje Y.	Movimiento inestable y con esfuerzo elevado. Posibilidad de inclinación del conjunto, afectando la calidad del mecanizado. Vibraciones
Falta de lubricación en las guías	Avance forzado o detenido. Ruidos y vibraciones.	Desgaste acelerado de guías. Paros recurrentes por trabas. Reducción de vida útil de componentes.
Desgaste desigual de las guías	Fricción variable a lo largo del recorrido. Movimiento con tirones. Inclinación o desviación del carro.	Trayectorias asimétricas. Pérdida de precisión. Afecta paralelismo y geometría de mecanizado.
Presencia de virutas	Interferencias puntuales durante el avance. El carro vibra, se detiene o se desliza con dificultad.	Paros intermitentes que afectan la continuidad del mecanizado. Riesgo de desalineación. Aumento del esfuerzo físico y posibilidad de dañar guías.
Falta de lubricación en las guías	Fricción irregular. Avance con resistencia variable. Aumento de temperatura por rozamiento seco.	Movimiento inestable durante el mecanizado. Vibraciones excesivas.

Tabla 18: Jerarquización del riesgo según modos de falla para la ménsula.

Modo de fallo	Frecuencia	Consecuencia		R=FxC
		Persona	Medio ambiente	
3.1.1	Media	Moderada	Menor	6
3.1.2	Baja	Menor	Menor	2
3.1.3	Media	Moderada	Menor	6
3.2.1	Media	Menor	Menor	3
3.2.2	Media	Moderada	Menor	6
3.2.3	Media	Moderada	Menor	6

Tabla 19: Fallas funcionales y Modo de falla del cabezal vertical.

Falla Funcional	Modo de Falla	
El cabezal no permite el desplazamiento vertical controlado (eje Z)	4.1.1	Presencia de virutas
	4.1.2	Husillo del eje Z trabado o deformado
El cabezal presenta desplazamiento irregular o saltos durante el avance vertical	4.2.1	Falta de lubricación
	4.2.2	Desgaste desigual en las guías del cabezal
	4.2.3	Presencia de virutas
El cabezal pierde alineación vertical	4.3.1	Holgura excesiva entre el cabezal y la columna
	4.3.2	Desgaste asimétrico en las superficies de guiado

Tabla 20: Efectos y consecuencias de posibles modos de falla del cabezal vertical.

Modo de Falla	Efectos de la falla	Consecuencia de la falla
Presencia de virutas	Interferencia mecánica en las guías, generando bloqueo parcial o total del movimiento. Puede producir rayado en superficies de contacto o desgaste localizado.	Paro parcial o total del avance vertical. Riesgo de daño a guías si se fuerza el desplazamiento.
Husillo del eje Z trabado o deformado	Imposibilidad de accionar el avance vertical. Pérdida total de función. Posible daño al sistema si se fuerza.	Inhabilita completamente el uso del eje Z. Interrumpe la producción. Puede generar daños en motor o transmisión si se intenta accionar. Alto impacto en disponibilidad operativa.
Falta de lubricación	Aumento de fricción entre superficies, avance duro o imposible.	Posible sobrecalentamiento. Deterioro acelerado de guías y rodamientos.
Desgaste desigual en las guías del cabezal	Movimiento no uniforme del cabezal, con zonas de mayor y menor fricción que producen tirones y pequeños saltos durante el avance.	Avance con vibraciones y pérdida de suavidad, afectando la precisión del mecanizado en profundidad.
Presencia de virutas	Obstáculos intermitentes durante el recorrido. Avance con tirones, ruidos mecánicos y riesgo de rayado.	Avance errático, inseguro. Ruidos, interferencias, dificultad en el descenso fino. Riesgo de dañar herramientas si el cabezal desciende con tirones.
Holgura excesiva entre el cabezal y la columna	Aparición de juego entre el cabezal y la columna, provocando oscilación e inclinación del cabezal durante el desplazamiento y el mecanizado.	Errores de perpendicularidad y variaciones en el acabado superficial, con aumento del riesgo de rotura de herramienta y generación de defectos dimensionales en las piezas.
Desgaste asimétrico en las superficies de guiado	El desplazamiento vertical se realiza con una componente de desviación lateral debido al desgaste desigual de las superficies de guiado.	El cabezal se desplaza con desviación lateral, comprometiendo la precisión del eje Z, dificultando la calibración del equipo y generando necesidad de retrabajo o descarte de piezas por fuera de tolerancia.

Tabla 21: Jerarquización del riesgo según modos de falla para el cabezal vertical.

Modo de fallo	Frecuencia	Consecuencia		R=FxC
		Personas	Medio ambiente	
4.1.1	Media	Moderada	Menor	6
4.1.2	Baja	Moderada	Menor	4
4.2.1	Media	Moderada	Menor	6
4.2.2	Media	Moderada	Menor	6
4.2.3	Media	Moderada	Menor	6
4.3.1	Baja	Grave	Menor	6
4.3.2	Media	Moderada	Menor	6