

UNIVERSIDAD DE MATANZAS



DETECCIÓN PREMATURA DE FALLOS EN PROCESOS MECÁNICOS BASADA EN UNA ARQUITECTURA INTELIGENTE

TESIS EN OPCIÓN AL GRADO CIENTÍFICO DE
DOCTOR EN CIENCIAS TÉCNICAS

M. Sc. Alberto Villalonga Jaén

Matanzas, 2020

UNIVERSIDAD DE MATANZAS



DETECCIÓN PREMATURA DE FALLOS EN PROCESOS MECÁNICOS BASADA EN UNA ARQUITECTURA INTELIGENTE

TESIS EN OPCIÓN AL GRADO CIENTÍFICO DE
DOCTOR EN CIENCIAS TÉCNICAS

Autor: M. Sc. Alberto Villalonga Jaén

Tutores: Dr. C. Ramón Quiza Sardiñas

Dr. C. Rodolfo Elías Haber Guerra

Matanzas, 2020

AGRADECIMIENTOS

Me gustaría agradecer a todos los que de una forma u otra han contribuido a la realización de esta tesis en especial a mi tutor Ramón Quiza y al profesor Marcelino Rivas quienes han sido mi guía fundamental y apoyo.

Agradecer también a mi tutor del Centro de Automática y Robótica, Rodolfo Haber, a Fernando Castaño y a Gerardo Beruvides, que junto a mí han dedicado muchas horas a este trabajo.

Agradecer a mis compañeros del CEFAS, profesores del departamento de Mecánica, Química y de la Universidad de Matanzas en general (sería muy extenso mencionarlos a todos) que fueron fuentes de consulta y apoyo.

Por último, pero no menos importante a mi familia que ha hecho posible con su cariño y ayuda hacer más grato el tiempo que hemos estado separados.

SÍNTESIS

El monitoreo de sistemas mecánicos juega un papel clave en la industria contemporánea. Esta tesis doctoral está enfocada hacia el diseño e implementación de una arquitectura cognitiva, para el monitoreo de procesos y sistemas mecánicos, mediante la inclusión de capacidades de autoaprendizaje y autoconfiguración, que permita la supervisión de estados en sistemas mecánicos con el fin de conocer la dinámica global del sistema y así aumentar su eficiencia y disminuir los tiempos de paradas por mantenimiento. La arquitectura se basa en la utilización de diferentes técnicas de aprendizaje automático, agrupadas en diferentes subgrupos tales como: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje por refuerzo. La arquitectura cuenta, además, como capacidad para optimizar la parametrización de los algoritmos utilizados en la modelación, con el objetivo de elevar su eficacia. Para evaluar el desempeño de la arquitectura, la misma se aplicó a dos casos de estudios: el monitoreo de los fallos en cojinetes de rodadura y el pronóstico de la rugosidad superficial generada en un proceso de maquinado. En ambos casos, la arquitectura mostró ser efectiva para el monitoreo de estados de los sistemas a los cuales se aplicó.

TABLA DE CONTENIDO

Introducción	1
Capítulo 1 Marco Teórico Referencial	7
1.1 Nociones generales sistemas de monitoreo de estado	7
1.1.1 Clasificación	10
1.1.2 Estructura conceptual.....	12
1.2 Principales componentes de los sistemas de monitoreo	13
1.2.1 Principales variables mediadas en sistemas de monitoreo de estado...	14
1.2.2 Extracción de rasgos	17
1.2.3 Modelado	20
1.2.4 Toma de decisiones	24
1.3 Arquitecturas de sistemas de monitoreo de estado aplicadas a procesos mecánicos	26
1.4 Extracción de conocimiento.....	31
1.5 Conclusiones parciales del capítulo	33
Capítulo 2 Diseño e Implementación de la Arquitectura	34
2.1 Descripción de la arquitectura.....	34
2.1.1 Descripción general.....	34
2.1.2 Sistema global (servidor)	36
2.1.3 Nodos locales.....	38
2.2 Capacidades de autoconfiguración y autoaprendizaje	40
2.2.1 Autoconfiguración.....	40

2.2.2 Autoaprendizaje.....	49
2.3 Implementación.....	51
2.3.1 Bases de datos.....	52
2.3.2 Visualización.....	54
2.4 Conclusiones parciales del capítulo	56
Capítulo 3 Casos de Estudio.....	58
3.1 Caso de Estudio No. 1: Predicción de fallos en cojinetes de rodamientos mediante el análisis de señales de vibraciones.....	58
3.1.1 Justificación del caso de estudio	58
3.1.2 Instalación experimental.....	59
3.1.3 Implementación de la arquitectura	62
3.1.4 Análisis de los resultados	64
3.2 Caso de Estudio No. 2: Predicción de la rugosidad superficial en un proceso de fresado de acabado	69
3.2.1 Justificación del caso de estudio	69
3.2.2 Implementación de la arquitectura	71
3.2.3 Estudio experimental.....	73
3.2.4 Análisis de los resultados	76
3.2.5 Análisis económico	81
3.3 Conclusiones parciales del capítulo	84
Conclusiones.....	85
Recomendaciones.....	86
Referencias Bibliográficas.....	87

Anexos.....	100
Anexo 1 Ingeniería de software aplicaciones servidor y nodo local	100
Anexo 2 Características técnicas rodamientos Rex ZA2115 2000.....	118
Anexo 3 Características técnicas acelerómetros ICP PCB 353B33.....	120
Anexo 4 Características técnicas dinamómetro Kistler 9257B.	121
Anexo 5 Características técnicas perfilómetro Carl Zeiss Surfcom 130.....	122

INTRODUCCIÓN

La ejecución exitosa de un proceso industrial requiere no solo administrar la mano de obra, la materia prima y la maquinaria de la planta, sino también disponer de la información necesaria para determinar patrones de comportamiento y tomar decisiones de forma precisa, facilitando, además, la detección de situaciones anómalas y su diagnóstico inmediato a través de un seguimiento continuo de las variables del proceso, o sea, disponer de sistemas de fabricación inteligente, logrando con ello una integración más profunda de la información y las tecnologías de fabricación.

En la actualidad, nuestro país se encuentra envuelto en un proceso de actualización de la industria (Mañalich Galvez & Pérez Abreu, 2018), enfrentando grandes retos debido al nivel de envejecimiento que padece su tecnología, sobre todo en la rama de fabricación, lo que incluye muchos procesos que adolecen de sistemas de supervisión y control, lo que se traduce en bajos niveles de productividad y paradas frecuentes por roturas no previstas. Luego de realizado un análisis de la tecnología de supervisión en nuestro país, en los procesos de fabricación (Ramírez Mendoza et al., 2019), se detectó la siguiente **situación problemática**: las roturas imprevistas de piezas o componentes, son un evento frecuente en los sistemas de manufactura de la industria cubana, trayendo consigo, en muchos casos, la parada del proceso productivo con las consecuentes pérdidas económicas, las cuales se agravan al dificultarse la disponibilidad de los repuestos adecuados, dada la naturaleza repentina del fallo.

Durante las últimas décadas, el rápido avance de las Tecnologías de la Información y las Comunicaciones (TIC) ha introducido un sinnúmero de modificaciones en la industria de fabricación actual, orientadas a la digitalización, la personalización y la trazabilidad de procesos, productos y servicios (Qi & Tao, 2019). Aunque nuevos conceptos, como la fabricación inteligente (*smart manufacturing*) o Industria 4.0, se están convirtiendo en paradigmas de la manufactura contemporánea, partes esenciales para implementar exitosamente estas ideas, tales como la conexión de dispositivos (máquinas herramientas, robots, cintas transportadoras, etc.) a nivel de planta y la adquisición de datos de diferentes dispositivos, continúan siendo un reto importante a nivel industrial (Lu & Xu, 2019). Incluso, la supervisión efectiva de dispositivos resulta frecuentemente prohibitiva debido a los elevados costes de interfaces propietarias y la baja estandarización de los protocolos de comunicación soportados por los diferentes elementos de los sistemas.

La arquitectura de un sistema inteligente generalmente está compuesta por múltiples capas que cubren desde la capa de equipo, de detección, de comunicación, y la de procesamiento de la información hasta el control y la auto reconfiguración (Qi & Tao, 2019). A través del monitoreo de condiciones, se puede comprender de manera detallada la dinámica de un proceso y, aplicando una serie de algoritmos, se pueden realizar correcciones sobre los principales parámetros de ajuste con el objetivo de lograr un funcionamiento más eficiente del sistema. También, constituyen una herramienta efectiva para la predicción de la vida útil de un activo en un proceso industrial, y para la consiguiente planificación de una estrategia de mantenimiento eficaz (Shin, Shin, Choi, & Choi, 2016).

El éxito en la implementación de un sistema de monitorización depende, fundamentalmente, de tres factores: la robustez del sistema, la comunicación con la capa física (máquinas a nivel de planta) y el tratamiento de la información. Para ello, se han llevado a cabo estudios avanzados sobre comunicación industrial con el fin de romper el paradigma de que cada máquina tiene su propio protocolo y con el objetivo de desarrollar un sistema que sea compatible con cualquier tipo de máquina y permitir así su uso a nivel de gestión global de los procesos productivos (O'Donovan, Gallagher, Leahy, & O'Sullivan, 2019). No obstante, muchas de las arquitecturas desarrolladas no son accesibles para el usuario. Por ello se recurre al uso de modernos sistemas, mediante arquitecturas que combinen la universalidad y el bajo costo.

De la situación anterior se deduce la existencia del siguiente **problema científico**: ¿Cómo determinar a tiempo los posibles fallos de los componentes críticos en sistemas y procesos mecánicos en ambientes industriales?

Para dar solución a este problema, se plantea la siguiente **hipótesis**: mediante técnicas de inteligencia artificial es posible construir una arquitectura para ser utilizada en la detección prematura de fallos de sistemas y procesos mecánicos.

Consecuentemente, el **objeto de estudio** se enfoca al monitoreo de los procesos mecánicos, mientras que el **campo de acción** lo constituyen las arquitecturas de monitoreo y sus capacidades para la generación, selección y actualización automáticas de los modelos utilizados.

Para validar la hipótesis planteada, se propone como **objetivo general** del presente trabajo: construir una arquitectura inteligente para el desarrollo de sistemas de monitoreo de estados aplicados a sistemas mecánicos en entornos industriales.

En vista a cumplimentar el objetivo anterior, se han trazado las siguientes **tareas**:

1. Revisar críticamente el estado del arte de los conceptos de sistemas de monitoreo de estados aplicados a la industria de fabricación actual, fundamentalmente en sistemas complejos.
2. Implementar librerías para el procesamiento de señales, la modelación, la optimización y el autoaprendizaje, basadas en técnicas de aprendizaje automático.
3. Diseñar una arquitectura de sistema de monitoreo de estados, para aplicaciones prácticas en entornos industriales, que corrija las deficiencias detectadas en la literatura para las soluciones existentes.
4. Implementar una arquitectura dotada de capacidades cognitivas para el aprendizaje y la autoconfiguración de modelos predictivos.
5. Validar la arquitectura propuesta en dos casos de estudio.

La tesis presenta como **novedad científica** fundamental, *la implementación de capacidades cognitivas artificiales que permiten la generación, selección y actualización automáticas de los modelos utilizados por una arquitectura de monitoreo para la predicción de estados en sistemas y procesos mecánicos.*

Como **aporte teórico** fundamental de la tesis se identifica la implementación y validación de capacidades cognitivas artificiales que permiten, a un sistema de monitoreo para procesos mecánicos, la generación, selección y actualización automáticas de los modelos utilizados.

Como **aporte de significación práctica**, se tiene el sistema de monitoreo que, por su grado de flexibilidad, posibilita su introducción práctica bajo diferentes condiciones industriales.

Como **aporte de significación económica y social** se tiene una potencial mejora en el mantenimiento predictivo permitiendo aumentar la vida útil de los componentes de equipos de fabricación y la consiguiente disminución de los efectos negativos de las paradas inesperadas de los procesos productivos.

Para el desarrollo de la investigación se utilizaron diferentes **métodos** científicos. En primer lugar, para la definición de la metodología de la investigación a emplear, se utilizaron el método hipotético-deductivo y el enfoque sistémico, que permitió la integración de resultados de diferentes disciplinas en la solución propuesta. Dentro de los métodos matemáticos, se utilizaron técnicas de modelación y optimización, basadas en inteligencia artificial. El método empírico se utilizó en la validación experimental del funcionamiento de la arquitectura propuesta.

La presente tesis está organizada en introducción, tres capítulos, conclusiones, recomendaciones, referencias bibliográficas y anexos. El Capítulo 1 establece el marco teórico sobre los sistemas de monitoreo de procesos mecánicos así como sus

diversos componentes. El Capítulo 2 explica el diseño y la implementación de la arquitectura propuesta, haciendo hincapié en sus capacidades cognitivas artificiales para la autoconfiguración y el autoaprendizaje. El Capítulo 3 presenta dos casos de estudio donde se valida la aplicación propuesta en situaciones prácticas. Finalmente, se presentan las conclusiones a las que se llegó en el trabajo y las recomendaciones que se hacen para su futura continuación y extensión.

CAPÍTULO 1 MARCO TEÓRICO REFERENCIAL

Este capítulo tiene como objetivo establecer los marcos teóricos fundamentales de la investigación desarrollada, basándose en un análisis crítico de las fuentes bibliográficas actualizadas, sobre temas de monitorización de estados y su aplicación en la industria contemporánea.

1.1 Nociones generales sistemas de monitoreo de estado

El monitoreo de estados (*condition monitoring*, CM), en términos generales, es el proceso de monitoreo de un parámetro, proceso o máquina, a fin de identificar un cambio significativo en el mismo, con el objetivo de prevenir o evitar un fallo. Suele formar parte de una estrategia de mantenimiento predictivo que permite estimar la condición real de un activo, extrayendo información de sus principales variables, para comprender el desgaste real, la degradación y la ocurrencia de cambios en su dinámica, con el propósito de ayudar a la programación de los ciclos de mantenimiento, reajustándolos, cuando se observe una disminución significativa en el rendimiento del equipo, y estableciendo las correspondientes acciones preventivas (Galar & Kumar, 2017).

El CM es una herramienta útil dentro del mantenimiento predictivo pues permite la programación de acciones preventivas y correctivas en el momento óptimo. Además, minimiza el riesgo de fallos inesperados, mejorando así la fiabilidad del equipo y la seguridad de los trabajadores (Swain, Panigrahi, Sahoo, & Panda, 2020). Ya sea enfocado a los procesos de corte, al análisis de sistemas de producción de energía o a

modernas técnicas de fabricación, las aplicaciones del CM brindan un valor agregado a las principales herramientas de mantenimiento (Mohanraj, Shankar, Rajasekar, Sakthivel, & Pramanik, 2020).

Las técnicas de CM más reportadas para aplicaciones en los sectores de fabricación son: análisis y diagnóstico de la vibración; análisis de lubricantes; análisis de emisión acústica; termografía infrarroja; ensayos por ultrasonidos, fuerza, análisis de estado y consumo en motores. En la Tabla 1.1 se presenta un resumen de las aplicaciones de sistemas de monitoreo a diferentes procesos y equipos mecánicos.

Tabla.1.1 Resumen aplicaciones de sistema de monitoreo de estados en procesos mecánicos.

<i>Referencia</i>	<i>Variable medida</i>	<i>Proceso o equipos</i>	<i>Técnicas</i>	<i>Variable monitoreada</i>
(Uekita & Takaya, 2017a)	Emisión acústica	Fresado	Análisis tiempo-frecuencia	Estado de la herramienta
(R. H. L. da Silva, da Silva, & Hassui, 2016)	Emisión acústica	Fresado	Redes neuronales	Estado de la herramienta
(C. Wang, Bao, Zhang, Ming, & Chen, 2019)	Emisión acústica	Fresado	Agrupamiento y análisis temporal	Desgaste de la herramienta
(Klocke, Döbbeler, Pullen, & Bergs, 2019)	Emisión acústica	Taladrado	Análisis frecuencial	Desgaste de la herramienta
(Dutta, Pal, & Sen, 2016)	Emisión acústica	Torneado	Análisis tiempo-frecuencia	Desgaste de la herramienta
(Tang, Soua, Mares, & Gan, 2016)	Emisión acústica	Generadores iolicos	Análisis frecuencial	Estado de las cuchillas

<i>Referencia</i>	<i>Variable medida</i>	<i>Proceso o equipos</i>	<i>Técnicas</i>	<i>Variable monitoreada</i>
(Walsh et al., 2017)	Emisión acústica	Generadores marinos	Análisis tiempo-frecuencia	Estado diferentes componentes del generador
(Hesser & Markert, 2019)	Vibraciones	Fresado	Redes neuronales	Estado de la herramienta
(Dheeraj Simon & Deivanathan, 2019)	Vibraciones	Taladrado	Análisis temporal	Desgaste de la herramienta
(Uekita & Takaya, 2017b)	Vibraciones	Taladrado	Análisis tiempo frecuencia	Excentricidad herramienta
(T. Chen, Wang, Yang, & Jiang, 2019)	Vibraciones	Máquinas rotatorias	Redes neuronales	Estado rodamientos
(Peeters, Antoni, & Helsen, 2020)	Vibraciones	Máquinas rotatorias	Análisis frecuencial	Estado de rodamientos y engranajes
(Kim et al., 2020)	Vibraciones	Máquinas rotatorias	Análisis temporal	Estado de engranajes
(Liu, Zhang, & Carrasco, 2020)	Vibraciones	Generadores iolicos	Análisis tiempo-frecuencia	Estado de los rodamientos
(Kumar, Zhou, Gandhi, Kumar, & Xiang, 2020)	Vibraciones	Máquinas rotatorias	Redes neuronales y análisis tiempo-frecuencia	Estado de rodamientos
(Ghafarizadeh, Lebrun, & Chatelain, 2016)	Temperatura y fuerza de corte	Fresado	Redes neuronales	Acabado superficial
(Prasad, Prabha, & Kumar, 2017)	Temperatura y vibraciones	Torneado	Análisis frecuencial	Desgaste de la herramienta
(Medjaher, Tobon-Mejia, & Zerhouni, 2012)	Analisis de lubricantes	Máquinas rotatorias	Redes bayesianas dinámicas	Vida útil rodamientos

<i>Referencia</i>	<i>Variable medida</i>	<i>Proceso o equipos</i>	<i>Técnicas</i>	<i>Variable monitoreada</i>
(Wakiru, Pintelon, Chemweno, & Muchiri, 2018)	Análisis de lubricantes	Máquinas rotatorias	Árbol de decisiones y Random forest	Salud rodamientos y engranajes
(W. Li & Liu, 2019)	Fuerza	Fresado	Análisis temporal y modelo oculto de Markov	Desgaste de la herramienta
(Shankar, Mohanraj, & Rajasekar, 2019)	Fuerza y emisión acústica	Fresado	Redes neuronales, ANFIS	Desgaste de la herramienta
(Zhu & Zhang, 2019)	Fuerza	Fresado	Modelado matemático	Vida útil, desgaste de la herramienta

1.1.1 Clasificación

Los sistemas de CM poseen varias clasificaciones atendiendo a sus principales características: la presencia o no de sensores, tipo de medición de las variables, la periodicidad en la cual se realizan las mediciones o las técnicas que se empleen para el análisis y la predicción.

Una de las principales características a seleccionar en un sistema de CM es el tipo de medición de las variables a analizar. Atendiendo a este parámetro los métodos de detección se pueden dividir en dos enfoques, directo e indirecto (Sick, 2002). Los métodos directos implican tomar medidas de las variables consideradas directamente del proceso analizado. Estos poseen como principal ventaja la exactitud pues se puede tener siempre acceso al valor real de los parámetros de decisión. Su desventaja principal, es que no siempre se es posible realizar una medición directa o, muchas veces, esta implica o bien una baja frecuencia de muestreo (insuficiente para

caracterizar el estado del sistema) o, incluso, la detención del proceso para realizar las mediciones.

Los métodos indirectos poseen la capacidad de mitigar esta última desventaja, puesto que se basan en establecer una correlación entre las variables captadas con mayor facilidad del proceso y aquellas que caracterizan el estado de sus componentes. Su principal desventaja se encuentra en la exactitud de la predicción, ya que ésta se ve afectada por la calidad en la toma de señales y su procesamiento. Generalmente, es más utilizado el método indirecto pues permite obtener sistemas más robustos y universales, aunque en líneas sencillas, con bajo nivel de producción, se suelen aplicar el monitoreo directo debido a su menor costo de implementación.

Otra característica importante a tener en cuenta en los sistemas de CM es la periodicidad con la que se medirán las variables. Atendiendo a este parámetro, se pueden clasificar en monitoreo en línea (*on-line*) o fuera de línea (*off-line*). El CM fuera de línea generalmente se usa para activos menos críticos o semicríticos donde el escaneo periódico es lo suficientemente bueno como para observar la condición actual. El CM en línea es la medición continua de un activo mediante el análisis en tiempo real de la información obtenida de los sensores instalados en la máquina o proceso lo que permite proporcionar advertencias en tiempo real (Chryssolouris, 2006). Para su selección deben tenerse en cuenta factores como el tipo de proceso, la velocidad del proceso y las características de sus principales componentes. También es importante considerar el costo de implementación puesto que lo sistemas en línea

suelen ser más caros, aunque esto se compensa con la mayor velocidad de respuesta ante las averías imprevistas.

Según otra clasificación, los métodos de monitoreo de estados de máquinas se pueden dividir en dos tipos: basados en modelos y basados en rasgos (L. Wang & Gao, 2006). Los métodos basados en modelos utilizan un modelo computacional preciso para correlacionar los datos de proceso con las posibles situaciones anómalas. Los métodos basados en rasgos se llevan a cabo en dos pasos: uno es la extracción de características de la señal y la otra es la toma de decisiones sobre la base de las características obtenidas, obviando la utilización de un modelo predictivo.

De manera general se puede afirmar que los sistemas de monitoreo de condiciones indirectos, basados en modelo y en línea son más robustos y generalizables, aunque por sus características suelen ser una inversión más costosa.

1.1.2 Estructura conceptual

El esquema genérico para la monitoreo de estado está formado por varios pasos o niveles como se muestra en la Figura 1, estableciéndose los siguientes cinco niveles (Sick, 2002):

1. Procesamiento analógico: está relacionado con la preparación de información sin procesar antes de la digitalización.
2. Procesamiento digital: modifica la información luego de ser digitalizada, a través de la filtración, normalización, linealización y otras técnicas.

3. Extracción de rasgos: condensa la información restante en pocos valores que pueden ser usados como entrada de los modelos.
4. Modelado: estima el estado de los valores obtenidos en el nivel anterior.
5. Toma de decisiones: produce una salida sobre el estado de la máquina o proceso y combina muchos de estos resultados para llegar a una conclusión final.




Figura 1.1 Esquema genérico para la monitoreo de estados

Este esquema ofrece solamente un enfoque general y en la mayoría de las investigaciones publicadas no reportan el uso de todas las etapas en los modelos propuestos. En la actualidad, la mayoría de las publicaciones abordan solo tres niveles: el primero compuesto por una fusión de las tres primeras etapas anteriormente descritas, generando una etapa de procesamiento de señales o extracción de rasgos, seguida por la etapa de modelado y, finalmente, la toma de decisiones (Ning, Wang, Liu, & Jiang, 2012; Z. Zhang, Hu, & He, 2005).

1.2 Principales componentes de los sistemas de monitoreo

Para los sistemas de CM cuatro aspectos poseen vital importancia, pues son los pilares fundamentales que van a permitir obtener un mejor desempeño, basado en una mayor exactitud y fiabilidad en las predicciones. Estos son: la selección de variables a

medir (sensores), las herramientas de procesamiento de señales, la técnica para la construcción del modelo predictivo y la toma de decisiones.

1.2.1 Principales variables mediadas en sistemas de monitoreo de estado

En los procesos mecánicos industriales, los datos se recogen en dos maneras fundamentales: mediante sistemas de medición externos (variables externas) o por sistemas de medición internos (variables internas). Los sistemas de medición externos son canales que se añaden al proceso, puesto que se necesitan medir variables que no eran capturadas inicialmente y, por lo tanto, conllevan una instalación adicional (Goyal, Vanraj, Pabla, & Dhami, 2019). Por su parte, las variables internas son aquellas que forman parte de los canales de medición del proceso en su instalación inicial y son adquirida desde el sistema de controladores CNC/PLC (Xing, Achiche, & Mayer, 2019; Xu, Zhou, & Chen, 2018).

Las variables internas contienen información útil del proceso. Además de ser estandarizadas y fiables, suelen verse menos afectados por interferencias externas tales como la contaminación electromagnética, las virutas de corte, el fluido de corte, el ruido de la maquinaria, etc. Por otra parte, el coste de la captura de datos internos de los sistemas de CNC/PLC es bajo y, normalmente, no se requieren instalaciones adicionales.

En la actualidad, se reportan una gran cantidad de trabajos enfocados al CM basado en variables internas captadas del CNC/PLC (Downey et al., 2016; Latif & Yusof, 2016). Un ejemplo de ello es el sistema de diagnóstico de estados basado en eventos

mediante señales tomadas del CNC de una máquina herramienta propuesto por (Shen, Zhao, Wang, & Fleischer, 2015). La influencia en los fallos se determina mediante los mensajes de alarmas generados por el sistema en correspondencia con las tendencias de las principales variables contenidas en el CNC.

Otras de las variables internas de sumo interés para los sistemas de monitoreo son las variables de consumo eléctrico como corrientes, potencias, voltajes, entre otras, que permiten reducir los niveles de consumo y aumentar la eficiencia energética (Frigerio & Matta, 2014; Langer, Schlegel, Stoldt, & Putz, 2014).

En el monitoreo de procesos mecánicos, en muchas ocasiones, no es suficiente con las variables propias del sistema para detectar el estado de sus principales componentes. Se hace necesario introducir nuevos canales de mediciones para capturar otras señales de interés. Un asunto esencial en los sistemas de monitoreo mediante señales externas es la selección adecuada de las variables de entrada de los modelos predictivos. La Figura 1.5 muestra una revisión de 80 fuentes bibliográficas sobre las señales más utilizadas para el monitoreo basado en sensores externos.

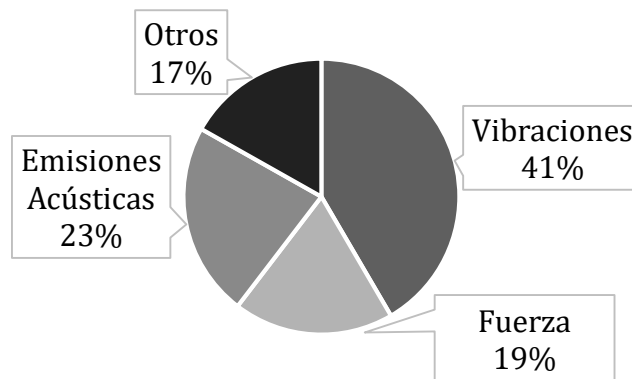


Figura 1.2 Señales externas más usadas para el CM de sistemas mecánicos

El análisis de vibración es uno de los métodos más comúnmente utilizados para el monitoreo, detección y análisis del estado de sistemas y procesos mecánicos en tiempo real o en intervalos de tiempo especificados (Barrios, Montero, Gómez Mancilla, & Marín, 2017). La medición de la vibración es una técnica eficaz, fiable, aunque no permite controlar el estado de la máquina durante los arranques y paradas. La amplitud de la señal de vibración da una indicación de la gravedad del problema, mientras que la frecuencia puede indicar el origen del defecto (Zhong et al., 2019). La extracción de estas señales puede ser considerada como una herramienta valiosa para detectar y diagnosticar el período previo a fallos de las máquinas y equipos. Como factor negativo se destaca que es una señal muy sensible al ruido, por lo que es necesario un tratamiento previo (A. Villalonga, Beruvides, Castaño, & Haber, 2018).

Por otra parte, la emisión acústica es otra de las señales capturadas para los sistemas de monitoreo, en procesos de fabricación. Existen diversas fuentes de emisión acústica durante los procesos industriales, dentro de los que se incluyen el aumento de la fricción entre las partes, las colisiones y las rupturas (Strantz, Van Hemelrijck, Guillaume, & Aggelis, 2017; Strömbergsson, Marklund, Edin, & Zeman, 2017). Esta variable es ampliamente utilizada en el CM de máquinas rotatorias (Wahyu Caesarendra et al., 2016), ya sea en sus componentes, como los rodamientos (Van Hecke, Yoon, & He, 2016), o en el estado general de la máquina (Liu & Zhang, 2020). La principal ventaja en el uso de la emisión acústica en el monitoreo es su amplio rango de frecuencia, en la mayoría de los casos, muy superior al de las vibraciones de la máquina y los ruidos ambientales (D'Addona et al., 2018).

La fuerza es una variable mayormente utilizada en procesos de corte. Es una variable que aporta mucha información acerca de la dinámica del proceso y del estado de la herramienta (W. Li & Liu, 2019). Las variaciones en esta señal aportan información importante sobre características fundamentales de la herramienta como el desgaste (Shankar et al., 2019; Zhu & Zhang, 2019) y la excentricidad (Susai Mary, Sai Balaji, Krishnakumari, Nakandhrakumar, & Dinakaran, 2019) . Como principal problema, presenta ser una señal que, para su medición, requiere de sensores bastante intrusivos para el proceso.

Además de las señales expuestas, se reporta el uso de otras como la temperatura (J. Huang et al., 2015) o el torque (Oliveira, Guilherme, & Cabral, 2012). Finalmente, en muchos casos se miden múltiples señales simultáneamente. Este enfoque es conocido comúnmente como fusión sensorial y suele producir mejores resultados (Beruvides, Quiza, del Toro, & Haber, 2013).

1.2.2 Extracción de rasgos

Una característica importante a la hora de seleccionar un método para la extracción de rasgos es saber qué tipos de datos se pueden manipular y las características físicas y matemáticas de la señal. Una amplia variedad de técnicas para la extracción de rasgos de señales se ha desarrollado y reportado en la literatura. Estos algoritmos se pueden clasificar en técnicas del dominio de tiempo, del dominio de frecuencia, del dominio de frecuencia y de tiempo, análisis espectral de orden superior y técnicas de aprendizaje automático.

Los enfoques del dominio del tiempo se basan en el análisis de la variación de los datos en función del tiempo. La principal ventaja que proporciona este análisis se encuentra en la garantía de la no ocurrencia de pérdida de información antes de la inspección. Sin embargo, la principal desventaja de este análisis se encuentra cuando se debe procesar un alto volumen de datos, lo que dificultan un diagnóstico claro de los fallos (Benvegnù et al., 2016). Las características se extraen de la representación en el dominio del tiempo de la señal obtenida a través de estadígrafos como el valor medio, la raíz cuadrática media (*root mean square*, RMS), la desviación estándar, el valor máximo, la curtosis, el factor de cresta, el factor de impulso y otros.

El análisis en el dominio de la frecuencia, por su parte, se refiere a la visualización o representación de los datos como una función de la frecuencia, utilizando la señal en el dominio del tiempo obtenida. La ventaja fundamental del análisis en el dominio de la frecuencia, sobre el dominio del tiempo, es su capacidad para identificar y aislar ciertos componentes de frecuencia de la señal que resultan de gran interés (Noël & Kerschen, 2017). El método más elemental y conocido en este grupo es el análisis espectral basado en la transformada rápida de Fourier (*fast Fourier transform*, FFT), que permite aproximar una función periódica arbitraria, dada por una serie temporal de valores $\{x_1, x_2, \dots, x_{N-1}\}$, en otra serie $\{X_1, X_2, \dots, X_{N-1}\}$, mediante la expresión:

$$X_k = \sum_{n=0}^{N-1} x_n e^{-\frac{i2\pi}{N}kn} \quad \text{para } k = 0, 1, \dots, N-1; \quad (1.1)$$

donde cada uno de los términos X_k corresponde a la frecuencia $2\pi kn/N$ (Strain, 2018)

La idea principal del análisis de espectro es detallar el conjunto general y observar detenidamente ciertos componentes de frecuencia de interés y, por lo tanto, extraer las características principales de la señal. La herramienta más utilizada en el análisis de espectro es el espectro de potencia. El espectro de potencia revela cómo se distribuye la energía en las frecuencias y, por lo tanto, es muy útil para identificar fenómenos periódicos.

Una de las principales limitaciones del análisis de señales en el dominio de la frecuencia es su imposibilidad de manejar señales con forma de onda no estacionaria, las cuales son muy comunes en la ocurrencia de fallos en maquinarias industriales. Debido a esta imposibilidad se desarrolló el análisis de tiempo-frecuencia, que investiga las señales en forma de onda tanto en el dominio del tiempo como en el de frecuencia (Wahyu; Caesarendra & Tjahjowidodo, 2017). Se han propuesto técnicas de dominio de tiempo-frecuencia se encuentran: la transformada de Fourier de tiempo corto, la distribución de Wigner-Ville, la transformada de wavelet u onduleta y las transformadas de Hilbert. Entre estas técnicas destaca la transformada discreta de wavelet debido a su fácil implementación y eficiencia computacional.

La transformada de wavelet permite analizar una señal en el dominio tiempo-frecuencia, descartando la información irrelevante mediante procesos de escalado y traslación, mientras que la señal de interés se analiza a diferentes niveles de frecuencias, conocidos como onduletas (*wavelets*)(Seid Ahmed, Arif, & Veldhuis, 2020). La transformada discreta de wavelet, que es más eficiente desde el punto de

vista computacional, se basa en la discretización diádica de la onduleta base, $\psi_{r,s}$, mediante la expresión:

$$W(j,k) = \langle f(t), \psi_{r,s}(t) \rangle = \int_{-\infty}^{+\infty} f(t) \psi^*(2^r t - s) dt ; \quad (1.2)$$

donde $f(t)$ es la señal original y $W(r, s)$ es la correspondiente transformada (Sharma, Tiwari, & Singh, 2019). La función de dilatación de la transformada discreta de wavelet se puede representar como un árbol de filtros de paso alto y bajo, donde cada paso transforma el filtro de paso bajo en componentes de frecuencia más alta y más baja. La señal original se descompone sucesivamente en componentes de resolución más baja, mientras que los componentes de alta frecuencia no se analizan más.

La elección de la herramienta de procesamiento de señales en un sistema de CM depende fundamentalmente del origen y las características físicas que posea la señal a procesar. Cada herramienta es capaz de resaltar cualidades propias de las señales en distintos dominios, por lo que su elección se debe basar, fundamentalmente, en lograr la extracción de los rasgos más distintivos y en la reducción del volumen de datos, permitiendo crear modelos predictivos más ligeros y robustos. Además, debe considerarse el gasto computacional pues muchos de estos sistemas necesitan respuesta en tiempo real.

1.2.3 Modelado

El modelado es el centro de un sistema de CM. En él se estiman los valores del parámetro a monitorear, a partir de los rasgos extraídos de las señales medidas. La

cuestión más importante en la constitución del modelo es cuál herramienta seleccionar para identificar la relación entre las variables dependientes y las independientes.

Tradicionalmente, las técnicas estadísticas, tales como los métodos de regresión factorial o multifactorial, la correlación factorial o multifactorial, entre otras, han sido las más populares en el modelaje y continúan empleándose en la actualidad (Zheng, Dan, Cheng, & Xia, 2019). Sin embargo, la complejidad de los procesos industriales limita el uso de estas técnicas sencillas, debido a las no linealidades y los ruidos presentes en las mediciones, dándole lugar a la introducción de herramientas basadas en inteligencia artificial (IA).

Sin lugar a dudas, hoy en día la técnica de modelado más utilizada basada en IA son las redes neuronales artificiales (*artificial neural network*, ANN) (D'Addona, Matarazzo, de Aguiar, Bianchi, & Martins, 2016; Guo, Li, Yang, Deng, & Lavery, 2015). Entre las redes neuronales más utilizadas se encuentran: el perceptrón multicapa (*multi-layer perceptron*, MLP)(Altobi, Bevan, Wallace, Harrison, & Ramachandran, 2019; Lima-Junior & Carpinetti, 2019), las redes de función de base radial (*radial-basis function*, RBF)(Er & Tan, 2018; Moawad, Elawady, & Sarhan, 2019) y los mapas de autoorganización (*self-organizing maps*, SOM)(D.-W. Huang, Gentili, Katz, & Reggia, 2017) . Su amplio uso está sustentado en su capacidad para absorber las no linealidades presentes en los procesos industriales, así como su capacidad de generalización.

Otra técnica ampliamente aplicada en la industria son los sistemas difusos (Moreno-Cabezali & Fernandez-Crehuet, 2020; Rodríguez-Ramos, da Silva Neto, & Llanes-Santiago, 2018), pero éstos, a su vez, presentan dificultades a la hora de establecer las funciones de pertenencia ya que se requiere de experiencia previa y amplio conocimiento del proceso en cuestión. Debido a esto surgen las técnicas neuroborrosas las cuales mantiene los principios de los primeros, pero agregan el autoentrenamiento que proporcionan las redes neuronales por lo cual éstas ya son capaces de tomar sus propias decisiones. Además, poseen la habilidad de trabajar en áreas que no están claramente definidas, o sea, áreas borrosas. Los sistemas neuroborrosos de inferencia adaptativa (*adaptive neuro-fuzzy inference systems*, ANFIS) parten de un conjunto de datos de entrada y mediante un sistema borroso, conducido por funciones de pertenencia, ajusta los parámetros para determinar su influencia en la salida (Das, Nayak, Sarangi, & Biswal, 2016).

Otra herramienta comúnmente utilizada es el modelo oculto de Markov (*hidden Markov model*, HMM) (Jinbo Li, Pedrycz, & Jamal, 2017; Jianlan Li, Zhang, Zhou, & Lu, 2019; Yan, Chen, & Zhang, 2017) . Las ventajas fundamentales de los HMM son su sencillez en la inicialización y la implementación. No obstante, los HMM contienen típicamente un gran número de parámetros y por tanto necesitan grandes cantidades de información para ser entrenados.

Finalmente, existen técnicas que, en menor medida, son utilizadas en la modelación de procesos industriales. En este grupo podemos destacar a las máquinas de soporte vectorial (*support vector machine*, SVM) (Aoyagi, Wang, Sudo, & Chiba, 2019; Cheng

& Dong, 2019; Manjurul Islam & Kim, 2019) , el soporte vectorial bayesiano, las redes bayesianas (G. Chen & Ge, 2020; Nhat, Venkatesan, & Khan, 2020) y el proceso de jerarquía analítica (Gonzalez, Huang, & Lau, 2015; Meng, Zhu, Gao, He, & Xu, 2019).

1.2.3.1 Parametrización óptima

Las técnicas de modelación basadas en aprendizaje automático contienen parámetros que deben establecerse antes de su ejecución. Los valores de dichos parámetros suelen tener una influencia considerable tanto en la bondad de ajuste de los modelos obtenidos como en su capacidad de generalización. Para mejorar la parametrización de dichos algoritmos se suelen hibridar con técnicas de optimización. Entre las principales técnicas de optimización utilizadas destacan las heurísticas.

Recocido simulado (*simulated annealing, SA*) es una heurística que presenta un gran desempeño en la optimización de modelos (Martin-Diaz, Morinigo-Sotelo, Duque-Perez, Osornio-Rios, & Romero-Troncoso, 2018). En el monitoreo de procesos de fabricación junto a técnicas de modelación como redes neuronales (Mundada & Kumar Reddy Narala, 2018) o SVM (Mia et al., 2018) genera modelos con excelentes desempeños. Otra técnica ampliamente empleada es el enjambre de partículas (*particle swarm optimization, PSO*). En sistemas de monitoreo se suele asociar a la parametrización óptima de SVM (X. Wang, Guan, Hua, Wang, & He, 2019), redes neuronales (Ambekar & Kittur, 2020) y redes bayesianas (K. Zhang, Cheng, & Zhang, 2020).

Los algoritmos genéticos son una de la técnica de optimización más utilizada en procesos de fabricación (Brahimi, Dolgui, Gurevsky, & Yelles-Chaouche, 2019). Su principal ventaja reside en la codificación de las entradas lo que lo hace independiente de su dinámica permitiendo, así, obtener excelentes resultados en entornos industriales. En aplicaciones de monitoreo se pueden encontrar en la parametrización óptima de técnicas como: redes neuronales (Y. Zhang et al., 2020), SVM (K. Li et al., 2018), modelos basados en gemelos digitales (Guerra, Quiza, Villalonga, Arenas, & Castaño, 2019), ANFIS (Deshwal, Kumar, & Chhabra, 2020), entre otros (T. Li, He, Wang, & Zhang, 2020).

Al igual que las herramientas de procesamiento de señales, la elección de una técnica de modelación para generar el modelo predictivo es dependiente de las características propias de las señales del proceso y los requerimientos del sistema. Entre los principales factores a tener en cuenta se encuentran su carga computacional, su capacidad de trabajo con las no linealidades propias de los procesos industriales, el volumen de datos disponible para entrenamiento, entre otros.

1.2.4 Toma de decisiones

La toma de decisiones en entornos industriales se realiza basándose en la experiencia acumulada durante la captura de datos a lo largo del proceso y la precisión de los modelos predictivos. Sin lugar a duda, el correcto funcionamiento del procesamiento de señales y el modelado permite que el proceso de toma de decisiones puede llevarse

a cabo con un alto nivel de precisión y fiabilidad (Boral, Howard, Chaturvedi, McKee, & Naikan, 2020; X. Li, Nassehi, & Epureanu, 2019).

Consta de tres etapas fundamentales: la generación de residuos (diferencia entre la salida real y la estimada por el modelo), la evaluación de esos residuos y la toma de decisión acerca de la condición o estado del proceso. Se agrupan en dos grandes conjuntos métodos estadísticos y técnicas de inteligencia artificial.

Entre los métodos estadísticos dos de las técnicas más empleadas por su sencillez de implementación son: la suma ponderada del cuadrado de los residuos (*weighted sum squared residuals*, WSSR) (Alberto Villalonga, Beruvides, Castaño, Haber, & Novo, 2018) y el método de la razón de verosimilitud generalizado (*generalised likelihood ratio*, GLR) (Mansouri et al., 2018). Estos métodos suelen ser susceptibles a señales con grandes niveles de ruidos. Con el objetivo de mejorar la robustez, es posible utilizar umbrales adaptativos, obtenidos a partir de criterios heurísticos o utilizando funciones matemáticas exactas que permite mejorar su desempeño ante este tipo de señales (Alberto Villalonga et al., 2020).

Entre las técnicas de inteligencia artificial aplicadas a la toma de decisiones destaca la lógica borrosa. Esta permite diseñar etapas de toma de decisiones que pueden hacer frente a la incertidumbre y la imprecisión de las variables medidas del proceso (Fé-Perdomo, Beruvides, Quiza, Haber, & Rivas, 2019). Como inconveniente principal posee la necesidad de tener un amplio conocimiento del proceso para definir las funciones de pertenencia que permita realizar una toma de decisiones eficientes.

1.3 Arquitecturas de sistemas de monitoreo de estado aplicadas a procesos mecánicos

En las últimas décadas, con el creciente desarrollo del hardware y las comunicaciones, el aumento en almacenamiento de los sistemas de gestión de datos, con sistemas de transferencias de datos más rápidos y seguros, así como el desarrollo de protocolos de comunicación alámbricos e inalámbricos más potentes, se han generado una nueva visión de cómo monitorear el estado de los procesos mecánicos de manera global. Es decir, hoy en día, todas las arquitecturas reflejadas en la literatura tienen un concepto enfocado a que tanto el usuario como el fabricante tengan acceso de información del estado de la máquina de manera remota sin tener que interrumpir el funcionamiento de la misma de manera innecesaria.

En la Tabla 1.4 se presenta un resumen de diferentes arquitecturas reportadas en la literatura. Tomando en cuenta aspectos fundamentales como tipo sistema de monitoreo, objetivo y protocolos de comunicaciones. Además, se incorpora una columna donde se presentan de manera crítica las principales debilidades detectadas desde el punto de vista del autor.

Tabla 1.4 Resumen de las arquitecturas globales reportadas en la literatura

<i>Referencia</i>	<i>Objetivo</i>	<i>Esquema de Monitoreo</i>	<i>Protocolo o interfaz de comunicación</i>	<i>Debilidades</i>
(Liao & Lee, 2010)	Diseño de una plataforma de pronósticos reconfigurable que puede desplegarse con rapidez y eficacia para aplicaciones de pronóstico	Watchdog Agent. Reconfiguración basada en reglas de modelos y herramientas de procesamiento de señales.	Ethernet	La reconfiguración se realiza a través de una base de reglas predefinidas y no en la extracción de conocimiento de proceso en tiempo real.
(Edrington, Zhao, Hansel, Mori, & Fujishima, 2014)	Implementa el estándar MTConnect dentro de su MAPPS HMI con un XML estándar en la salida para construir un sistema capaz de recopilar datos	MTConnect Agent.	TCP/IP	El procesamiento de los datos se realiza solo en remoto, lo que propicia una respuesta más lenta y la posible pérdida de datos por interrupciones en la comunicación. No se extrae conocimiento del proceso

<i>Referencia</i>	<i>Objetivo</i>	<i>Esquema de Monitoreo</i>	<i>Protocolo o interfaz de comunicación</i>	<i>Debilidades</i>
(Bellagent e et al., 2014)	Sugiere la adopción de paradigma de la computación en nube para soportar las estaciones inalámbricas	Análisis temporal.	Wi-Fi	Procesamiento en remoto que introduce demora en la predicción, y posibles pérdidas de datos por interrupciones en la comunicación. No se extrae conocimiento del proceso
(J. Chen et al., 2015)	Monitorizar y optimizar los procesos a través de sistemas ciberfísicos (CPS) utilizando grandes volúmenes de información captado del código G	Análisis temporal.	No se describen	Arquitectura poco flexible pues no permite la inclusión de canales de medición extremos. No se extrae conocimiento del proceso
(Fleischmann, Kohl, & Franke, 2016)	Monitoreo de estados en procesos industriales utilizando CPS.	Modelos basados en técnicas de aprendizaje automático	Profinet	No realiza análisis de la información recopilada de campo para mejorar los modelos predictivos.

<i>Referencia</i>	<i>Objetivo</i>	<i>Esquema de Monitoreo</i>	<i>Protocolo o interfaz de comunicación</i>	<i>Debilidades</i>
(A. F. da Silva, Ohta, Santos, & Binotto, 2016)	Monitoreo y control remoto de procesos de manufactura a través de IoT y computación en la nube	Análisis frecuencial	MQTT	El procesamiento de los datos de proceso se realiza en remoto por lo que compromete la velocidad de respuesta en tiempo real. No realiza reparametrización de modelos o extracción de conocimientos.
(Lindeman, Karadogan, Jazdi, Liewald, & Weyrich, 2018)	Monitoreo y control remoto de procesos de manufactura a través de IoT y computación en la nube basado en conocimiento de expertos y reglas	Reconfiguración de modelos predictivos mediante reglas y conocimiento de expertos.	EtherCat, Can Bus, Profibus, OPC-UA	El procesamiento de los datos de proceso se realiza en remoto por lo que compromete la velocidad de respuesta en tiempo real
(Nguyen & Dugenske, 2018)	Monitoreo de estados de máquinas herramientas basada en sensores I2C	Análisis frecuencial	I2C, MQTT	No realiza reparametrización de modelos o extracción de conocimientos del proceso.

<i>Referencia</i>	<i>Objetivo</i>	<i>Esquema de Monitoreo</i>	<i>Protocolo o interfaz de comunicación</i>	<i>Debilidades</i>
(Qian, Zhang, Tian, Si, & Li, 2019)	Monitoreo de condiciones para turbinas de viento basado en aplicaciones en la nube	Técnicas de procesamiento de señales combinadas con modelos predictivos basados en aprendizaje automático	Internet	El procesamiento de los datos de proceso se realiza en remoto por lo que puede comprometer la respuesta en tiempo real. No se reconfiguran los modelos.

De manera general, las arquitecturas analizadas presentan una estructura poco flexible. Realizan las predicciones mediante técnicas de procesamiento de señales que pueden ser pocas efectivas en procesos complejos o con un alto nivel de ruido o de modelos predictivos que se generan antes de iniciar la supervisión y durante esta no son reparametrizados o reconfigurados o este proceso se realiza mediante reglas predefinidas o conocimiento de expertos por lo que pueden no detectar posibles cambios en las dinámicas de los procesos lo que trae consigo la disminución en la exactitud de las predicciones.

Basados en la revisión bibliográfica en este trabajo se propone implementar una arquitectura con capacidad de extraer conocimiento de la información obtenida del proceso que permitirá generar y seleccionar los modelos predictivos y las herramientas de procesamiento de señales mejorando la fiabilidad y el desempeño del sistema.

1.4 Extracción de conocimiento

La extracción de conocimiento en los datos de procesos industriales (*Knowledge Discovery in Databases, KDD*) se basa en el establecimiento de relaciones y patrones que permiten mejorar el proceso de toma de decisiones. Se realiza en cinco etapas fundamentales: selección, procesamiento, transformación, minería de datos e interpretación-evaluación (Kotu & Deshpande, 2019). Una vez generado el conocimiento se deben realizar acciones que permitan mejorar la calidad del proceso analizado. En el caso de los sistemas de monitoreo este puede ser utilizado para mejorar la calidad de predicción de los modelos.

En los procesos de fabricación el procesamiento del conocimiento generado se puede analizar a través de bases de reglas (Schuh, Prote, Luckert, & Hünnekes, 2017), ontologías (Al-Sayed, Hassan, & Omara, 2020), criterio de experto (Adamczyk, Szejka, & Canciglieri, 2020) o aprendizaje por refuerzo (Paraschos, Koulinas, & Koulouriotis, 2020). El aprendizaje por refuerzo presenta la ventaja de además de permitir realizar la toma de decisiones basado en la experiencia adquirida también es capaz de mejorar su selección basado en su proceso de aprendizaje iterativo.

El aprendizaje por refuerzo es una rama del aprendizaje automático que agrupa algoritmos dotados con la capacidad para la toma de decisiones. El sistema aprende a lograr un objetivo en un entorno incierto y potencialmente complejo (Vázquez-Canteli & Nagy, 2019). Este acomete acciones basadas en prueba y error para encontrar el mejor comportamiento. Por cada una de las acciones que realiza obtiene

recompensas o penalizaciones. Su objetivo fundamental es maximizar la recompensa total obtenida interactuando con el ambiente (Mak, Lee, & Park, 2019).

El aprendizaje por refuerzo se clasifica en aprendizaje basado en modelo o aprendizaje libre de modelo. El aprendizaje basado en modelo requiere de un modelo del ambiente, mientras que libre de modelo aprende de su interacción con este. El libre de modelo presenta la ventaja de no necesitar conocimiento previo del proceso. Entre los principales algoritmos de aprendizaje por refuerzo libre de modelo destaca q-learning por su sencillez y desempeño (Nian, Liu, & Huang, 2020).

Q-learning puede identificar una política de selección de acción óptima para cualquier proceso de decisión finito de Markov dado, en un tiempo de exploración finito y una política parcialmente aleatoria. La función denomina "Q" (Ec 1.3) es la encargada de otorgar la recompensa utilizada para proporcionar el refuerzo por cada acción realizada, por lo que se plantea que representa la "calidad" de una acción realizada en un estado determinado (Beruvides, Villalonga, Franciosa, Ceglarek, & Haber, 2018).

$$Q(s,a) \leftarrow Q_t(s,a) + \alpha [R(s,a) + \gamma \max_{a_{t+1}} Q_{t+1}(s_{t+1}, a_{t+1}) - Q(s,a)] \quad (1.3)$$

donde, s_t es el estado en t ; a_t es la acción a realizar; R el valor de recompensa recibido por realizar la acción a_t ; α es el coeficiente de aprendizaje; y γ es el factor de descuento que denota la importancia de la recompensa en el tiempo.

La definición de la recompensa se basa en los diferentes estados a los que se puede acceder y la calidad de las acciones para acceder a estos. Para ello se pueden construir una matriz de recompensas o una ecuación, ambas en función de los estados y las

acciones. Tanto el ajuste de la ecuación como los coeficientes de la matriz de recompensas se definen basados en el conocimiento previo sobre la solución.

1.5 Conclusiones parciales del capítulo

Una vez finalizado el presente capítulo, se ha podido arribar a las siguientes conclusiones parciales:

1. Los sistemas de CM son una poderosa herramienta para el mantenimiento predictivo y tienen una amplia aplicabilidad en la industria moderna.
2. Las principales etapas a tener en cuenta en el diseño de los sistemas de monitoreo de estados son la sensorización, el procesamiento de las señales y el modelo predictivo.
3. La correcta selección de los protocolos de comunicación, el lenguaje de programación y el sistema de base de datos, son requisitos básicos para la implementación efectiva de un sistema robusto y flexible.
4. Las arquitecturas de sistemas de monitoreo de estados reportadas en la literatura presentan un diseño poco flexible, en muchos casos, pues no extraen información de los datos acumulados del proceso lo que permitiría mejorar la parametrización de los componentes del sistema y con ello su desempeño global.

CAPÍTULO 2 DISEÑO E IMPLEMENTACIÓN DE LA ARQUITECTURA

En el presente capítulo se presenta la arquitectura propuesta y sus principales funcionalidades. Se muestra la interconexión entre los distintos elementos (módulos) que la componen y se detalla sobre su composición y funcionamiento interno. También se expone la metodología de diseño seguida para su implementación.

2.1 Descripción de la arquitectura

2.1.1 Descripción general

Dado el análisis de las arquitecturas reportadas en la literatura, y teniendo en cuenta sus ventajas y debilidades, se realizó como primer paso para el diseño e implementación de la arquitectura, la formalización de los principales requisitos:

- El sistema deberá ser capaz de detectar y notificar a los usuarios cuando se produce un fallo de la máquina.
- El sistema deberá ser tolerante a fallos en la red, y recuperar datos cuando se producen interrupciones en la red.
- El sistema global deberá funcionar en un servidor.
- El sistema debe extraer conocimiento del proceso, a través de su constante interacción con el mismo, para determinar el mejor modelo predictivo, aumentando la precisión y fiabilidad del diagnóstico.
- Los datos recogidos estarán a disposición de los clientes para que puedan hacer uso de ellos en su sistema de gestión de la producción.

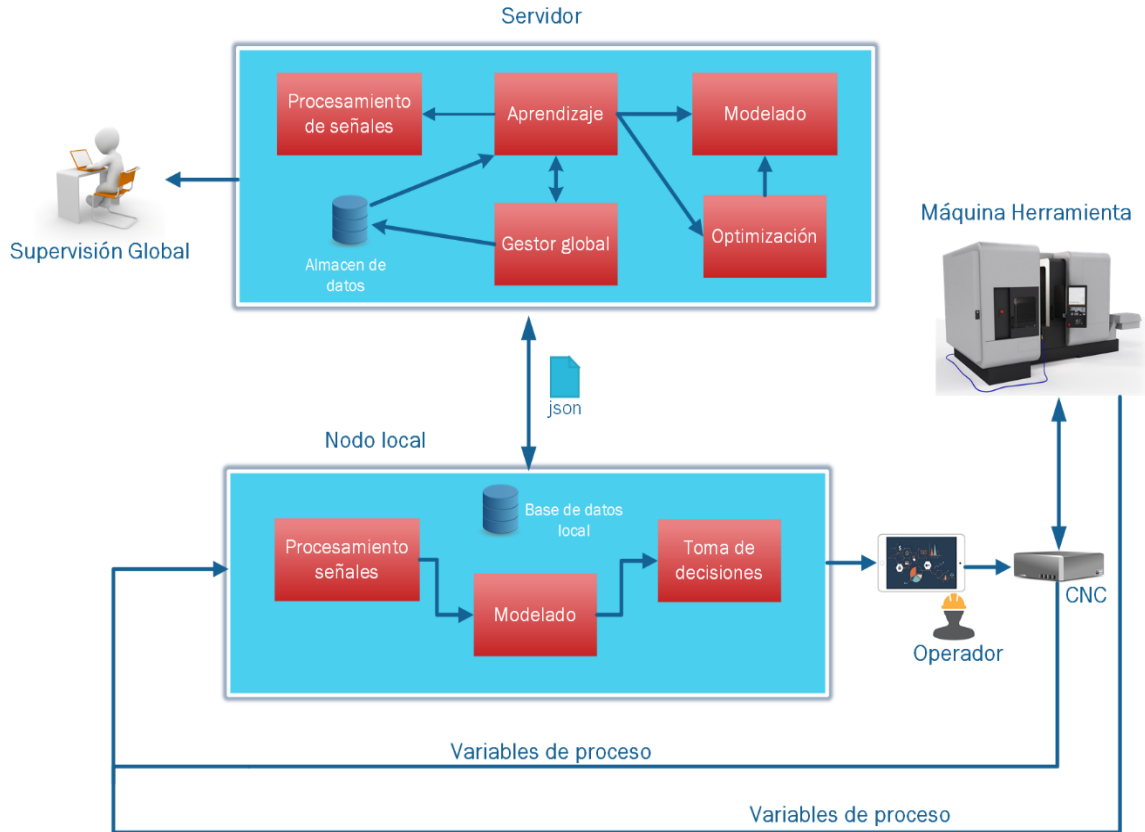


Figura 2.1 Esquema general de la arquitectura propuesta

Atendiendo a los requerimientos anteriores, la arquitectura propuesta se basa en una arquitectura genérica multicliente-servidor (Fig. 2.1). Los clientes son los encargados de monitorizar, en base a eventos y de forma semiautónoma, el funcionamiento y rendimiento de cada elemento de la cadena de producción. El monitoreo del proceso se realiza basado en tres subsistemas fundamentales: procesamiento de señales, modelado y gestión de alarmas y eventos. De esta manera, el sistema local será capaz de recibir los datos del campo, procesarlos, ejecutar un modelo representativo y permitir la toma de decisiones con respecto a la salida estimada por el modelo en comparación con la salida real deseada para el proceso. El servidor es el encargado

del monitoreo de los parámetros globales de rendimiento (*key performance indexes*, KPI's) del sistema, así como de la definición y el control de las metas locales de cada uno de los componentes de la cadena de valor, garantizando, así, la interoperabilidad y permitiendo un aumento en los índices de rendimiento, un incremento en la producción, una reducción de las paradas por roturas, con la consiguiente mejora en la programación de los mantenimientos. Es importante resaltar la extracción de conocimiento del proceso como una característica fundamental de la arquitectura, la cual responde a una de las principales debilidades detectadas en la literatura.

La arquitectura, de manera general, agrupando las funcionalidades tanto del cliente como del servidor, consta de cinco módulos fundamentales que rigen el funcionamiento:

- Módulo de procesamiento de datos (en el cliente y el servidor)
- Módulo de modelación (en el cliente y el servidor)
- Módulo de aprendizaje (solo en el servidor).

En los siguientes epígrafes se expondrán las características fundamentales de cada uno de estos módulos, profundizándose en su funcionamiento.

2.1.2 Sistema global (servidor)

Sistema global o servidor es el encargado de supervisar al conjunto de nodos locales, a partir de las configuraciones realizadas a nivel de planta. A su vez, éstas podrán ser modificadas en cualquier instante debido a cambios realizados en las diferentes etapas del proceso, lo que garantiza una continua interacción cliente-servidor. De esta

forma, el módulo global podrá cambiar tanto los componentes de los diferentes subsistemas del módulo local como los parámetros de éstos en función del comportamiento del proceso. Para esto, será necesario que el módulo local proporcione al módulo global información sobre el proceso.

La Figura 2.3 muestra el diagrama de interconexión de los distintos subsistemas que componen el módulo global.

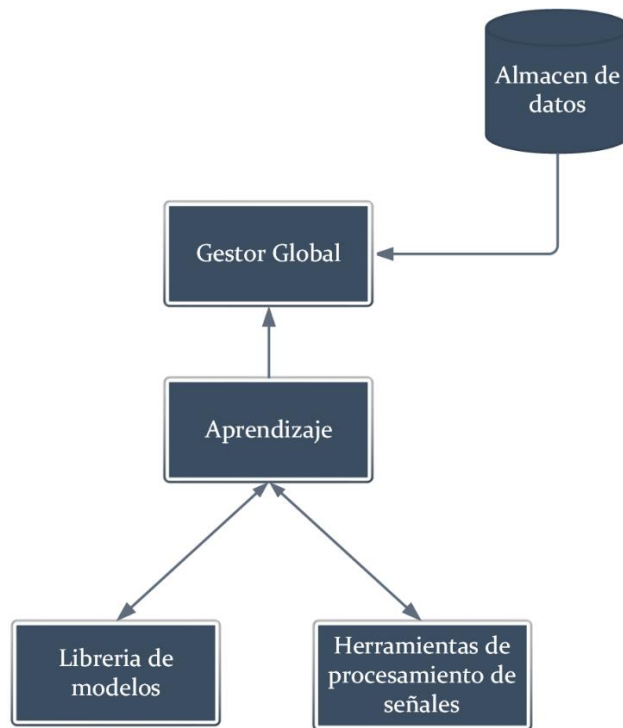


Figura 2.3 Diagrama Sistema global (Servidor)

Este está compuesto por cinco bloques principales:

- Almacén de datos: La información global, proporcionada por cada máquina-componente del proceso conectado al sistema, se almacena en una estructura basada en grandes datos que se utilizará en la fase de aprendizaje, es decir, el

proceso de capacitación para producir un nuevo modelo con una mejor adaptación. Parámetros y capacidad de generalización adecuada. Contiene además, el conjunto de datos seleccionados por criterios de expertos para validar el entrenamiento y los índices de desempeño de los distintos modelos.

- Biblioteca de modelos: Está compuesta por una familia de técnicas de modelado basadas en el algoritmo en aprendizaje automática divididas en dos grandes grupos: técnica de aprendizaje supervisado y no supervisado. Además contiene, técnicas de optimización para la parametrización de los modelos y algoritmos de toma de decisiones.
- Herramientas de procesamiento de señales: Está compuesta por diferentes métodos basados en técnicas temporales, técnicas frecuenciales y técnicas combinadas, para el procesamiento de las señales y la extracción de rasgos.
- Módulo de aprendizaje: Se basa en la aplicación de un algoritmo de aprendizaje por refuerzo, libre de modelo, encargado de determinar las mejores técnicas de procesamientos de señales y el modelo a aplicar en los diferentes módulos locales.
- Gestor global: gestiona lo referente a la sincronización de los módulos internos de la aplicación, así como la comunicación con cada nodo local

2.1.3 Nodos locales

Los nodos locales son los encargados de realizar el monitoreo y diagnóstico del estado de la máquina, teniendo en cuenta los diferentes subsistemas que interactúan con la información de los parámetros de la misma, tales como: temperatura, nivel de

lubricante, engranajes y horas de uso de los componentes, etc. Esta información sensorial es proporcionada por múltiples sensores distribuidos en el proceso o las variables internas capturadas del CNC/PLC. Los datos de proceso se obtienen mediante el sistema de datos de adquisición. La Fig. 2.4 muestra la arquitectura del nodo local y la interacción entre sus módulos.

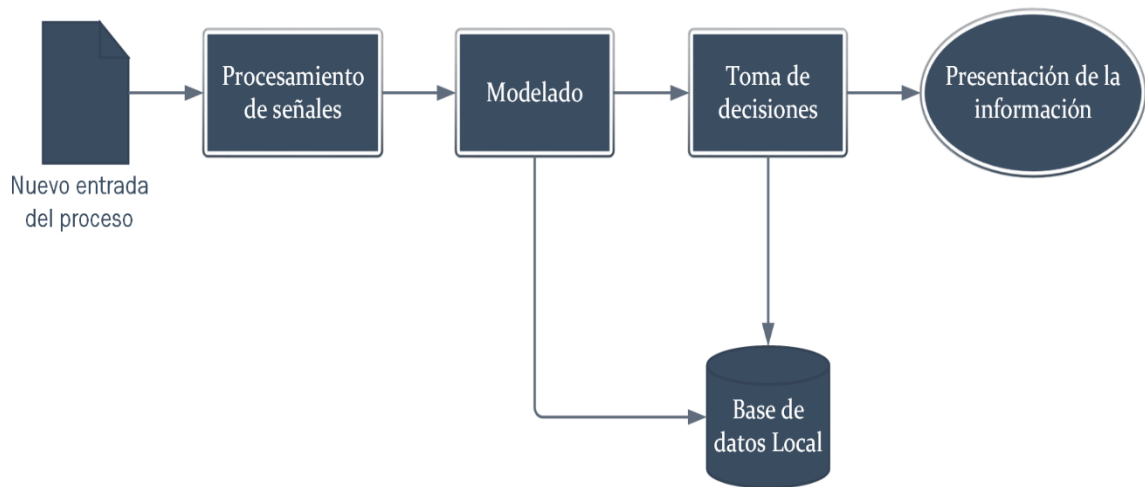


Figura 2.4. Diagrama del nodo local

Están compuestos por cinco bloques principales:

- El módulo de procesamiento de señales contendrá las técnicas definidas por el sistema global para el procesamiento de los datos en cada uno de los elementos del sistema.
- El módulo de modelación contendrá el modelo definido por el servidor, que permita en el momento de la evaluación obtener mejores índices de desempeño según los KPI's definidos para cada componente del sistema.
- La toma de decisiones recibe variables e indica si existe un problema o no, gestionando las posibles alarmas o eventos que pueden ocurrir en un

determinado período de tiempo a través de la utilización de un algoritmo de toma de decisiones compuesto por un umbral adaptativo.

- La base de datos local contiene la información local de la máquina herramienta, la información de eventos, alarmas y fallos ocurridos y las variables de proceso. Además, almacena la información recogida del proceso, la cual es enviada al servidor en intervalos de tiempos definidos, lo que permite garantizar la no ocurrencia de pérdida de la información de campo.
- La presentación de la información se realiza a través de un servicio web compuesto por varios paneles personalizables donde se muestran la información del proceso en cuanto a configuración y variables, así como el estado de sus principales componentes.

2.2 Capacidades de autoconfiguración y autoaprendizaje

2.2.1 Autoconfiguración

La capacidad de autoconfiguración de la arquitectura le brinda la posibilidad de que, con un mínimo de parámetros definidos inicialmente, el sistema sea capaz de funcionar. Esta capacidad aumenta la flexibilidad y la robustez de la arquitectura, debido a que la generación y selección de los modelos predictivos y las herramientas de procesamiento de señales se realizan de manera automática, por lo que no se requiere de conocimientos avanzados en modelación e inteligencia artificial para adaptar el sistema a disímiles procesos. Los parámetros configurables de la arquitectura son los siguientes:

En el servidor:

- Numero de generaciones: Parámetro relacionado con los algoritmos genéticos utilizados en la parametrización óptima de los modelos predictivos (se brinda valor por defecto).
- Tamaño de la población: Parámetro relacionado con los algoritmos genéticos utilizados en la parametrización óptima de los modelos predictivos (se brinda valor por defecto).
- Aprendizaje: Tipo de aprendizaje a utilizar en el modelo predictivo. Puede ser supervisado o no supervisado.
- Épocas de aprendizaje: Parámetro relacionado con el proceso de autoaprendizaje (se brinda valor por defecto).

En el nodo local:

- Servidor: Contiene la dirección IP del servidor.
- Variables: Variables de entradas obtenidas del proceso.
- Salida: Variable de salida.
- Toma de decisiones: Parámetro booleano que activa o no la toma de decisiones.

En el proceso de autoconfiguración se encuentra vinculado a los módulos de modelación y procesamiento de señales. En las figuras A.1.8-A.1.9 y A.1.20 del Anexo 1 se detalla su funcionamiento.

A continuación, se exponen las principales características de los módulos involucrados.

2.2.1.1 Módulo de procesamiento de señales

En el módulo de procesamiento de señales se encuentra contenido un conjunto de técnicas enfocadas en la extracción de rasgos de las señales medidas en los procesos. En el módulo se incluyen técnicas basadas en el dominio del tiempo, el dominio de la frecuencia y dominio tiempo-frecuencia.

Técnicas temporales

Las características de la señal se extraen de la representación en el dominio del tiempo de la señal obtenida a través de su representación mediante estadígrafos. Se implementaron el valor máximo de pico, p_{\max} :

$$p_{\max}(x) = \frac{\max(x) - \min(x)}{2}; \quad (2.1)$$

el valor medio, μ :

$$\mu(x) = \frac{1}{n} \sum_{i=1}^n x_i; \quad (2.2)$$

la desviación estándar, σ :

$$\sigma(x) = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2}; \quad (2.3)$$

la raíz cuadrática media, rms :

$$rms(x) = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}; \quad (2.4)$$

la curtosis, m_4 :

$$m_4(x) = \frac{1}{n\sigma^4} \sum_{i=1}^n (x_i - \mu)^4; \quad (2.5)$$

y la oblicuidad o asimetría, m_3 :

$$m_3(x) = \frac{1}{n\sigma^3} \sum_{i=1}^n (x_i - \mu)^3 \quad (2.6)$$

Técnicas de frecuencia

Para el análisis de señales discretas, como las obtenidas de sensores, en el dominio frecuencial se utiliza la transformada discreta de Fourier (*discrete Fourier transform*, DFT). En la arquitectura propuesta se utilizó, por su eficiencia computacional, para implementar la librería de procesamientos de señales, la transformada rápida de Fourier (*fast Fourier transform*, FFT).

Técnicas de tiempo-frecuencia

El análisis tiempo-frecuencia permite combinar las ventajas de ambas dimensiones. Es utilizado fundamentalmente para analizar datos no estacionarios y no lineales. En la librería de procesamiento de señales se utilizó como técnica de tiempo frecuencia, la transformada discreta de wavelet.

2.2.2.2 Módulo de modelación

En el módulo de modelación está contenida la librería de modelos. Ésta consta en su totalidad de algoritmos de modelación basados en IA pues estos son robustos debido a su capacidad para lidiar con las no linealidades presentes en los sistemas reales (Beruvides et al., 2017). Además, alcanzan grandes niveles de exactitud y repetitividad, así como adaptabilidad y capacidad de inferir nuevos datos. Esta a su vez se encuentra subdividida en tres grupos: aprendizaje supervisado, no supervisado y métodos de optimización.

Aprendizaje supervisado

El aprendizaje supervisado forma parte de una de las principales ramas de la IA, que en la actualidad presenta gran auge, el aprendizaje automático, y agrupa las técnicas que permiten realizar un mapeo de un conjunto de entradas hacia un correspondiente conjunto de salidas basado en pares entrada-salida de ejemplo proporcionados previamente. (Okaro et al., 2019).

En base a características como carga computacional, robustez y desempeño frente a las no linealidades, se eligieron para formar parte de la librería de modelado, las siguientes técnicas de aprendizaje supervisado: las redes neuronales perceptrón multicapa, el algoritmo de agrupamiento k-NN en sus versiones de clasificación y regresión, así como la regresión por mínimos cuadrados ordinarios. A continuación, se presentan los códigos de implementación correspondientes a cada uno de los algoritmos antes mencionados (código 2.1-2.3).

Código 2.1 Pseudocódigo del algoritmo de entrenamiento del MLP

```

algoritmo entrenarMLP
  inicializar pesos aleatoriamente
  iteración = 0
  error_total = 0
  repetir
    para cada elemento en [conjunto de entrenamiento]
      para capa = 1 hasta cantidad_de_capas
        calcular salida_de_cada_neurona
      fin para
      para capa = cantidad_de_capas hasta 1
        calcular error_de_cada_neurona
      fin para
        calcular error_cuadrado
      error_total = error_total + error_cuadrado
    fin para
    iteración = iteración + 1
    si ((iteración < max_iteraciones) y ...
      (error_total > error_deseado))
      actualizar pesos
      actualizar velocidad_de_aprendizaje
    sino
      salir del ciclo
    fin si
  fin repetir
fin algoritmo

```

Código 2.2 Pseudocódigo del algoritmo kNN

```

algoritmo kNN
  repetir
    para cada elemento en [conjunto de entrada]
      calcular distancia entrada - puntos espacio en memoria
    fin para
    organizar distancias hasta k elemento más cercano.
    si (cr)
      determinar clasificación dominante k elementos
      más cercanos con distancia ponderada.
    sino
      Calcular el valor de salida regresión distancia
      ponderada.
    fin si
  fin algoritmo

```

Código 2.3 Algoritmo de entrenamiento (ajuste) de la regresión múltiple

```

algoritmo entrenarRegresion(X[p, n], y[p, 1])
    calcular coeficientes de ajuste
fin algoritmo

```

Aprendizaje no supervisado

Los algoritmos de aprendizaje no supervisado dotan a la arquitectura de una mayor robustez pues en muchos procesos industriales es manifiesta la complejidad para determinar los estados o valores de salida. Estos arrojan una mayor claridad y permiten realizar la toma de decisiones pese a la alta complejidad de medición de las salidas. Entre los algoritmos de aprendizaje no supervisado implementados en la librería de modelación se encuentran: las redes neuronales mapas autorganizados y el algoritmo de agrupamiento *k*-means . En los códigos 2.4 y 2.5 respectivamente se presenta la implementación de estos algoritmos.

Código 2.4: Algoritmo de entrenamiento del SOM

```

algoritmo entrenarSOM
    inicializar pesos aleatoriamente
    iteración = 0
    repetir mientras (iteración < cantidad_de_iteraciones)
        seleccionar una entrada del conjunto de entrenamiento
        determinar la neurona ganadora
        actualizar pesos
        actualizar velocidad_de_aprendizaje
        actualizar distancia_de_vecindad
        iteración = iteración + 1
    fin repetir
fin algoritmo

```

Código 2.5 Algoritmo k-Means.

```

algoritmo k-Means
  inicializar aleatoriamente los centroides.
  inicializar el número máximo de iteraciones.
  reptir
    para cada elemento en [conjunto de entrada]
      agrupar los puntos basados en su cercanía a los
      centroides
      calcular el centroide de cada nuevo cluster
      iteración = iteración + 1
      si ((centroides == old_centroides) o ...
        (iteración < max_iteraciones))
        salir del ciclo
      fin si
    fin para
fin algoritmo

```

Métodos de optimización

Con el objetivo de determinar los valores más convenientes para los parámetros de las técnicas de modelación, en la librería propuesta, éstas se hibridaron con una herramienta de optimización. De este modo, la parametrización se realiza de forma automática y permite obtener valores óptimos (o cercanos al óptimo) para cada uno de los parámetros. Como método de optimización se implementó un algoritmo genético mono-objetivo con selección por torneo (ver código 2.6)

Código 2.6 Algoritmo genético

```

algoritmo ga
  población[0] = generar_aleatoriamente()
  evaluar(población[0])
  para iteración = 1 hasta CANTIDAD_ITERACIONES
    codificar(población[iteración - 1])
    progenitores = selección(población[iteración - 1])
    población[iteración] = cruzamiento(progenitores)
    población[iteración] = mutación(población[iteración])
    decodificar(población[iteración])

```

```

evaluar(población[iteración])
si (convergencia(población[iteración]) <= ...
    LÍMITE CONVERGENCIA)
    salir del ciclo
fin si
fin para
fin algoritmo

```

Toma de decisiones

La toma de decisiones es una etapa fundamental dentro de un sistema de monitoreo de condiciones. Permite mediante el análisis de los valores de proceso y la salida de los modelos predictivos detectar posibles situaciones anómalas y realizar sugerencias a los operadores. En la arquitectura se implementó para la toma de decisiones la técnica *WSSR* con umbrales adaptativos basados en la norma euclidiana y la norma infinita, ecuaciones 2.7 y 2.8

$$\varepsilon_1(t) = \frac{1}{|\mathbf{e}_M|_2 + |\dot{\mathbf{e}}_M|_2} \quad (2.7)$$

$$\varepsilon_2(t) = \frac{1}{|\mathbf{e}_M|_\infty + |\dot{\mathbf{e}}_M|_\infty} \quad (2.8)$$

donde $|\cdot|_\infty$ y $|\cdot|_2$ son la norma infinita y la segunda norma euclidiana respectivamente; \mathbf{e}_M y $\dot{\mathbf{e}}_M$ el vector de los residuos y su derivada en una ventana de tiempo $[t-NT-1, t]$

La utilización de este método con umbrales adaptativos permite aprovechar la información del vector de residuos y su derivada, no sólo para evaluar el grado de

correlación proceso-modelo, sino también para utilizar la tendencia en el vector de residuos en la detección de los estados del proceso.

2.2.2 Autoaprendizaje

El módulo de aprendizaje es el encargado de determinar la configuración de los modelos y la secuencia de procesamiento de la información en cada una de las estaciones de supervisión local, mediante de la experiencia acumulada. Basado en el paradigma de aprendizaje por refuerzo, es capaz de captar nuevos conocimientos sobre el proceso apoyándose en los datos recién adquiridos y la experiencia acumulada en los datos anteriores, dotando al sistema con la capacidad de auto-aprendizaje. En las figuras A.1.10-A.1.11 y A.1.21 se detallan el funcionamiento del mismo.

2.2.2.1 Q-learning

Para la implementación de Q-learning se deben definir los estados a tener en cuenta en el aprendizaje para asignar la recompensa. Para definir los estados se identificaron como parámetros fundamentales, para los algoritmos de aprendizaje supervisado, el error de ajuste del modelo y la complejidad de ejecución de los algoritmos que componen la librería. Para los algoritmos de aprendizaje no supervisado el coeficiente de Silhouette y la complejidad computacional del algoritmo. El error de ajuste es un parámetro fundamental ya que es la medida de la capacidad del modelo para proporcionar valores de salida con mayor exactitud y el coeficiente de Silhouette brinda una medida de calidad de los *clusters* creados. La complejidad de ejecución de

los algoritmos es otro parámetro de gran importancia pues la disminución de la carga computacional permite obtener respuestas con mayor rapidez respetando así las ventanas de tiempo real que puede presentar cada proceso (A. Villalonga, Beruvides, Castaño, & Haber, 2020).

En las Tablas 2.1 y 2.2 se definen las matrices de recompensas para los modelos basados en aprendizaje supervisado y no supervisado respectivamente basadas en los estados expuestos.

Tabla 2.1 Matriz de recompensa para modelos de aprendizaje supervisado.

<i>Error</i>	<i>Complejidad del algoritmo</i> →		
	<i>OLS</i>	<i>MLP</i>	<i>kNN</i>
0-5%	1,00	0,90	0,85
5-10%	0,85	0,80	0,75
10-20%	0,70	0,65	0,60
20-30%	0,60	0,55	0,50
30-40	0,40	0,35	0,30
>40%	0,20	0,10	0,05

Tabla 2.2 Matriz de recompensa para modelos de aprendizaje no supervisado.

<i>Coficiente de Silhouette</i>	<i>Complejidad del algoritmo</i> →	
	<i>SOM</i>	<i>k-Means</i>
1-0.8	1,00	0,95
0.79-0.6	0,85	0,80
0.59-0.3	0,70	0,60
0.29-0.1	0,60	0,50
0.1-0	0,35	0,30
>0	0,20	0,10

Para la asignación de recompensas en la selección de la herramienta de procesamiento de señales se utilizó la siguiente ecuación:

$$R_{p\text{-tool}}(s,a) = \alpha(1 - \beta) - \eta \quad (2.9)$$

donde α es el coeficiente de aprendizaje, η un coeficiente de penalización relacionado con la complejidad computacional de la técnica y β para los modelos de aprendizaje supervisado el mínimo valor de error y para los de aprendizaje no supervisado $1 - CS$ (coeficiente de Silhouette), si el coeficiente de Silhouette es menor que 1 se toma como 0. En el Código 2.7 se muestra el algoritmo de aprendizaje del método Q-learning implementado en la librería.

Código 2.7 Algoritmo de aprendizaje Q-learning

```

1   Inicializar las matrices Q
2   repetir:
3       por cada paso hacer:
4           recibir información del campo
5           evaluar todos los modelos
6           calcular los índices de desempeño
7           actualizar Qmodel
8           actualizar Qp-tool
9           escoger el mejor modelo
10          actualizar la configuración del nodo si es
diferente a la actual
11   hasta que se alcancen las épocas de entrenamiento
12   Terminar

```

2.3 Implementación

Para el diseño e implementación de ambas aplicaciones, se partió de los requisitos del sistema, los cuales permiten determinar un modelo inicial de casos de uso del mismo, aunque no sea definitivo. Dada la posible inclusión en el futuro de nuevos

requerimientos, sirve de punto de partida en el análisis y diseño de la arquitectura del sistema. El proceso de análisis y diseño del software se complementa con la confección de un plan de iteraciones a partir del modelo de casos de uso que permite llevar a cabo el proyecto de una manera eficiente. El procedimiento empleado está acorde al Proceso Unificado Racional (*Rational Unified Process*, RUP). En el Anexo 1 se documenta todo lo referente al proceso de diseño, análisis e implementación de cada aplicación.

2.3.1 Bases de datos

Uno de los requisitos principales que debe garantizar la arquitectura es la persistencia de la información, tanto la generada en la misma como los datos recogidos de la planta. Para ello se implementaron bases de datos tanto en los nodos locales como en el servidor.

Se decidió la utilización de bases de datos relacionales (SQL Server) debido a que no se procesarían en tiempo real grandes volúmenes de datos y por las ventajas que estas ofrecen:

Integridad de datos: A nivel de señales de planta para asegurar que los datos son correctos (tipo, valor), a nivel global para asegurarse de que no hay registros repetidos.

Fácil acceso: Los datos pueden ser obtenidos de una tabla en particular o de un grupo determinado de tablas relacionadas dentro de la base de datos de una manera sencilla y eficiente sin pérdida de información.

2.3.1.1 Almacén de datos (servidor)

El almacén de datos contenidos en el servidor es el encargado de almacenar toda la información recogida de los distintos nodos locales, tanto la referente a las señales de los procesos, como las generadas en el monitoreo de estados. También almacena el estado y la configuración contenida en los diferentes nodos. Está compuesta por ocho tablas. Las tablas *variables* y *eventos_alarmas* almacenan los valores de las variables de cada proceso, así como los estados, los eventos y las alarmas registradas. En relación con estas tenemos cuatro tablas nomencladoras que almacenan la información descriptiva de las variables, los componentes, los procesos, las alarmas y los eventos que pueden ser registrados. Además, consta de dos tablas destinadas a almacenar los datos para el entrenamiento y la validación de los modelos en la etapa de autoconfiguración de la arquitectura. En la Figura 2.5, se muestra el diagrama de entidad relación de la misma.

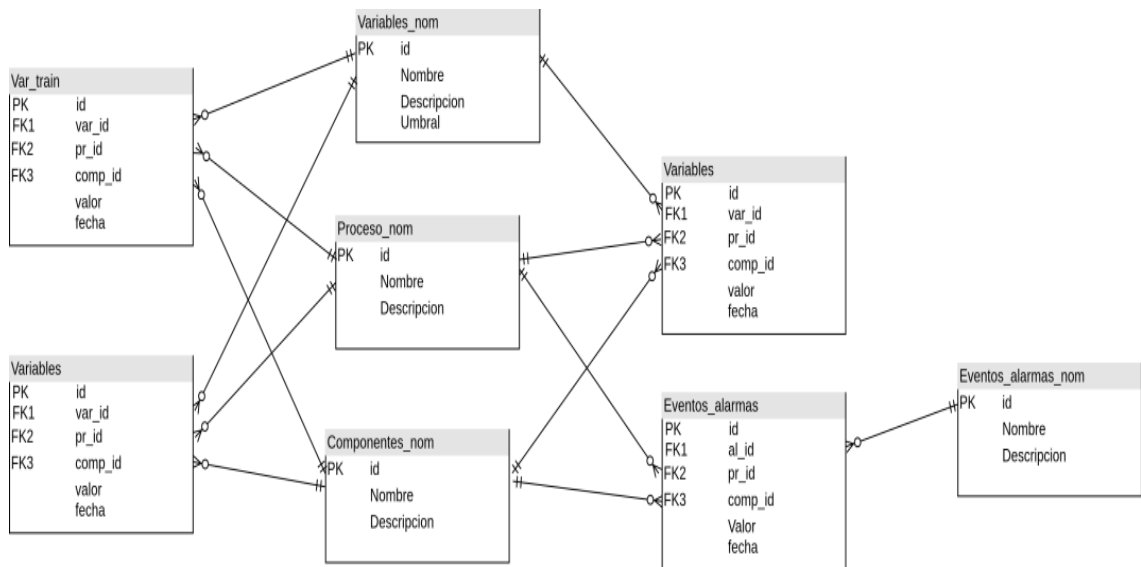


Figura 2.5 Diagrama entidad relación almacén de datos.

2.3.1.2 Base de datos local (nodo local)

La base de datos local, alojada en los nodos locales, es la encargada de almacenar de manera temporal la información obtenida de los sensores en el proceso. Permite garantizar la persistencia de los datos y evitar la congestión en la red que propiciaría la transmisión continua de información al servidor. Está compuesta por cuatro tablas. Las tablas *variables* y *eventos_alarmas* se encargan de almacenar las señales recogidas del proceso, el estado de cada uno de sus componentes dictaminados por la monitoreo de estados y los diferentes eventos y alarmas ocurridas. Además, consta con dos tablas nomencladoras donde se almacenan las características del proceso y de las señales adquiridas. En la figura 2.6 se presenta su diagrama entidad relación.

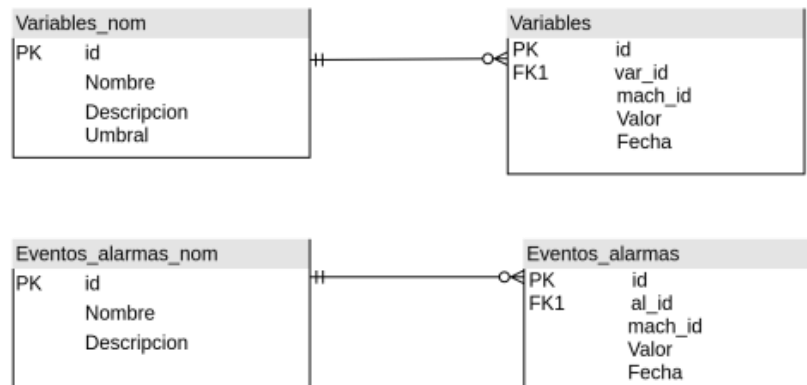


Figura 2.6 Diagrama entidad relación base de datos local.

2.3.2 Visualización

La visualización del sistema se realizó a través de interfaces web. Se decidió el uso de las mismas debido a su independencia de hardware, sistema operativo, facilidad para gestionar sesiones concurrentes y bondades de actualización sin requerir

instalaciones en los clientes. Para el desarrollo se hizo uso de la herramienta de visualización Grafana.

Grafana es una solución de código abierto multiplataforma para ejecutar análisis de datos, extraer métricas de grandes cantidades de datos y monitorear a través de paneles personalizables. Permite un desarrollo sencillo e intuitivo con una interfaz de usuario amigable (ver Fig. A.1.23, Anexo 1). Es de configuración sencilla y presenta compatibilidad con disímiles sistemas gestores de base de datos. En la figura A.1.24 del Anexo 1 se muestra una de las pantallas desarrolladas en uno de los casos de uso presentados en el siguiente capítulo. Debido a su característica multiplataforma se utilizó como interfaz de visualización tanto en los nodos locales como el servidor

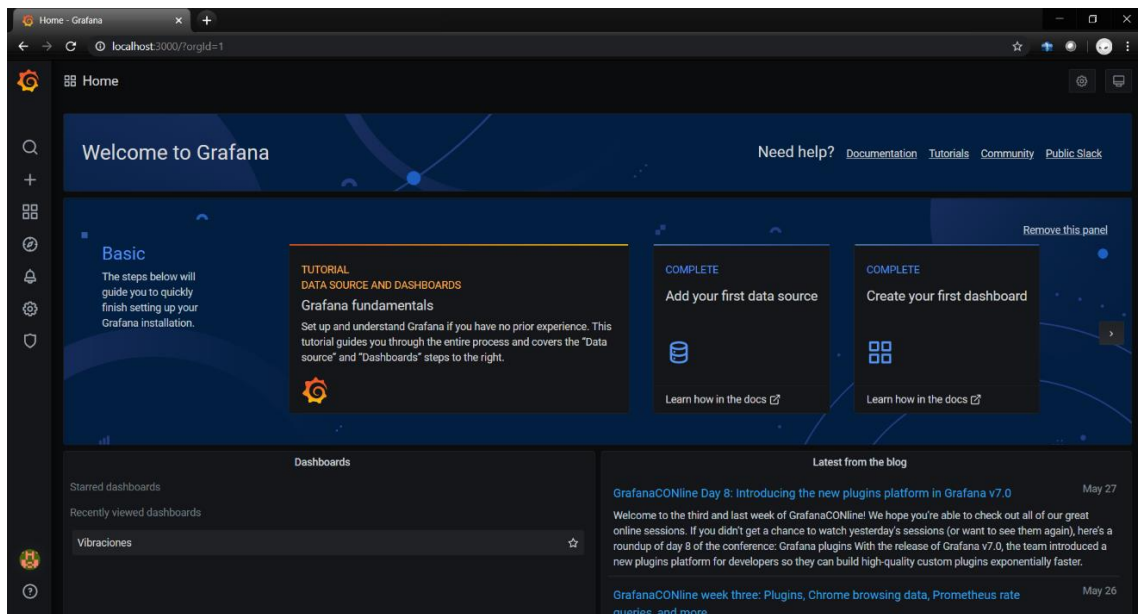


Figura 2.7 Pagina inicial Grafana usuario administrador.

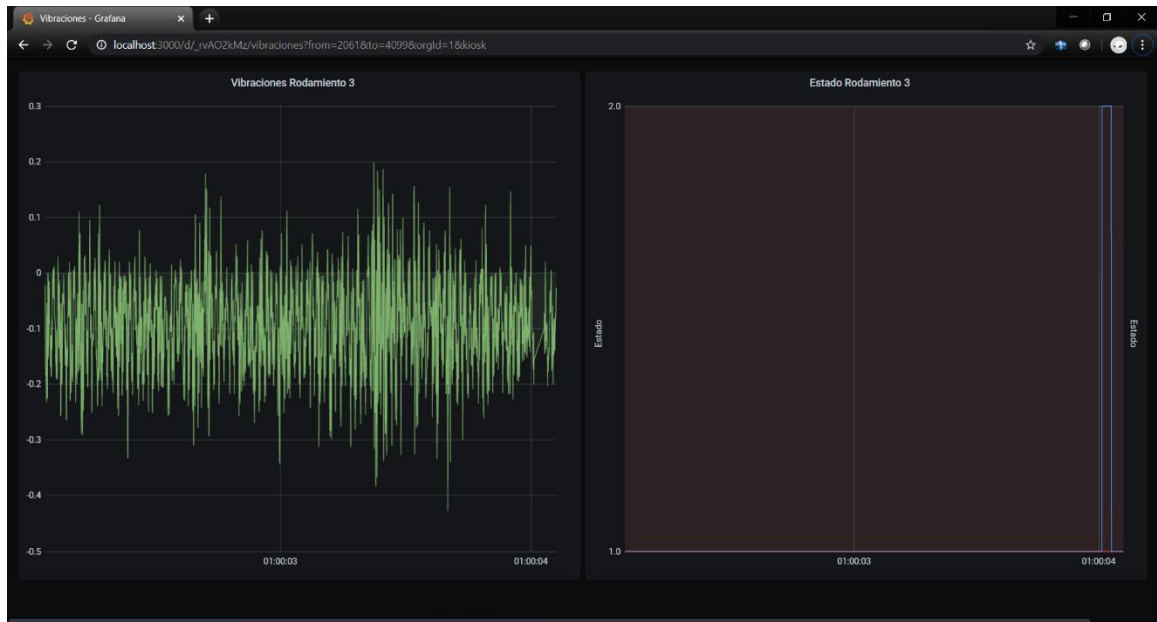


Figura 2.8 Ejemplo de pantalla caso de estudio.

2.4 Conclusiones parciales del capítulo

Una vez finalizado el presente capítulo, se ha podido arribar a las siguientes conclusiones parciales:

1. Se implementó una arquitectura para CM de procesos y sistemas mecánicos, integrada por un componente local y otro componente local. Dicha arquitectura cuenta con una estructura de capas que garantiza la funcionalidad del sistema y es compatible con los protocolos de comunicación industriales en el estado del arte.
2. Se implementaron cada uno de los módulos que componen la arquitectura y que permiten realizar la adquisición de datos, el procesamiento de datos, la modelación, el aprendizaje y la gestión de alarmas y eventos.

3. Se implementaron librerías cuyas funcionalidades garantizan las capacidades de autoconfiguración y autoaprendizaje necesarias para la correcta operación del sistema de manera semiautomática, y que constituyen la principal novedad científica de la presente investigación.

4. Se diseñaron e implementaron las aplicaciones de software que soportan la arquitectura, incluyéndose los sistemas de base de datos y la visualización a través de interfaces web.

CAPÍTULO 3 CASOS DE ESTUDIO

En este capítulo se evalúa el desempeño y la fiabilidad de la arquitectura aplicada a dos casos de estudio sobre sistemas mecánicos. El primer caso de estudio se basa en la detección de fallos en elemento de rodaduras mediante el análisis de señales de vibraciones. El segundo caso de estudio se basa en la predicción de la calidad del acabado superficial en procesos de maquinado a través de los parámetros de corte y la monitoreo de la fuerza de corte.

3.1 Caso de Estudio No. 1: Predicción de fallos en cojinetes de rodamientos mediante el análisis de señales de vibraciones

3.1.1 Justificación del caso de estudio

Los rodamientos son elementos mecánicos, que componen las máquinas rotatorias, los cuales cumplen la función de reducir la fricción entre eje y las piezas conectadas a este. Dada su función son elementos de vital importancia por lo que si estos se averían producen paradas de la máquina, y con ello del proceso productivo en el cual esta se encuentra insertada.

Los rodamientos se componen de 3 partes fundamentales: elementos de rodadura, las jaulas o pistas de rodadura. La mayoría de los fallos que se producen en los rodamientos se pueden clasificar de acuerdo con el elemento dañado. La frecuencia del fallo posee una relación directa, con la geometría del rodamiento y la velocidad relativa de cada pista individual (Cerrada et al., 2018).

Las frecuencias de resonancia asociada a cada elemento que componen el rodamiento se pueden calcular teóricamente. Cada elemento de rodamiento tiene una frecuencia de rotación característica. Con un defecto en un elemento de rodamiento particular, puede ocurrir un aumento en la energía de vibración en la frecuencia de rotación de dicho elemento. Esta frecuencia de defecto se puede calcular a partir de la geometría, de la velocidad de rotación del elemento y del rodamiento.

Debido a las pérdidas que producen las paradas de las máquinas herramienta por averías, la monitoreo de las condiciones de rodamientos en máquina rotatorias ha ganado gran importancia pues permite predecir los posibles fallos de los elementos y con ello la planificación de mantenimientos preventivos, así como la disminución del tiempo de las paradas por roturas(Pan, Hong, Chen, Qin, & Feng, 2019).

A partir de los elementos anteriores, se seleccionó como primer caso de estudio la detección de fallos en cojinetes de rodamiento, mediante el monitoreo de señales de vibraciones. Este caso de estudio se llevó a cabo a partir de datos disponibles en la literatura y su propósito fundamental fue servir de validación al módulo de modelación de la arquitectura propuesta.

3.1.2 Instalación experimental

Los datos considerados para la validación del sistema fueron generados por el Centro de Sistemas Inteligentes para el Mantenimiento (*Intelligent Maintenance Systems, IMS* <<http://www.imscenter.net>>) financiado por la National Science Foundation (NSF).

Los conjuntos de datos experimentales se generan a partir de ensayos en un banco de pruebas de cojinetes especialmente diseñado como se muestra en la Fig. 3.1. La velocidad de rotación se mantuvo constante a 2000 min^{-1} por un motor AC acoplado al árbol a través de correas de transmisión. Una carga radial de $26675,6 \text{ N}$ se aplica sobre el eje y el cojinete a través de un mecanismo de resorte. Se instalaron cuatro rodamientos de doble hilera Rexnord ZA-2115 (en el Anexo 2 se muestran los correspondientes datos técnicos) en el árbol como se muestra en la Figura 3.1. Se instalaron también, en la caja de los cojinetes, acelerómetros de alta sensibilidad de cuarzo ICP PCB 353B33 (en el Anexo 3 se muestran los correspondientes datos técnicos), para la medición de las vibraciones, (dos acelerómetros para cada rodamiento (ejes x e y) para el conjunto de datos 1, un acelerómetro para cada cojinete para los conjuntos de datos 2 y 3). La colocación de los sensores se muestra en la Figura 3.2.




Figura 3.1 Imagen del sistema para la validación de los experimentos

(Qiu, Lee, Lin, & Yu, 2006).




Figura 3.2 Diagrama esquemático del sistema físico (Qiu et al., 2006).

La primera prueba se llevó a cabo durante 35 días hasta que se encontró una cantidad significativa de residuos metálicos en los tapones magnéticos de los rodamientos de pruebas. El muestreo se realiza cada de 10 min y en cada medición se toman 20 480 muestras con frecuencia de muestreo de 20 kHz. Una vez detenidas las mediciones se determinó que se habían producidos fallos en el rodamiento tres en la pista interna y en el rodamiento cuatro en el elemento de rodadura.

La segunda prueba, la cual se realizó bajo las condiciones antes descritas, se llevó a cabo durante 17 días. Las condiciones de muestreo también fueron las mismas que en la prueba antes expuesta. Una vez culminada la prueba se determinó que se había encontrado fallos en la pista externa del rodamiento uno. Por último, se realizó el experimento tres bajo las mismas condiciones tanto de carga como de muestreo durante 30 días y al culminar el mismo se detectaron fallos en la pista externa del rodamiento 4. En todos los casos los fallos ocurren después de exceder la vida útil de los rodamientos que es de más de 100 millones de revoluciones.

Para llevar a cabo el estudio se consideraron los 3 casos antes expuestos:

- Caso 1 se corresponde con fallos en la pista interna del rodamiento 3.
- Caso 2 se corresponde con el fallo en la pista externa del rodamiento 1.
- Caso 3 se corresponde con el fallo en la pista externa del rodamiento 4.

3.1.3 Implementación de la arquitectura

Para la implementación de la arquitectura en este caso de estudio, se utilizó como nodo local una computadora de placa reducida Raspberry Pi Model B+ con un procesador Cortex-A53 (ARMv8) 64-bit SoC, 1GiB de RAM, sistema operativo Raspbian. En dicho nodo se instaló la base de datos de las mediciones de vibraciones de los rodamientos con el correspondiente sistema de comunicación, simulando una toma de señales de un sistema real. Como servidor, se utilizó una computadora portátil MSI GE63 7RD con un procesador i7, sistema operativo Ubuntu 18.04 y 16 GiB de RAM (ver Fig. 3.3).

Para la selección de los conjuntos de entrenamiento y validación, contenidos en el almacén de datos en el servidor, se utilizó el método *hold-out*, tomándose, de modo aleatorio, el 67% de las muestras para el entrenamiento y el 33% para la validación.

Este caso de uso está dirigido a validar principalmente el desempeño de las librerías de modelos y de herramientas de procesamiento de señales. Lo que justifica la selección una base de datos experimental bien documentada y referenciada en la

literatura. Paso inicial antes de someter la arquitectura a una validación con procesos reales.




Figura 3.3 Sistema nodo-servidor caso de estudio de monitoreo del estado de los rodamientos

El servidor se configuró con los parámetros mostrados en la Tabla 3.1.

Tabla 3.1 Parámetros del nodo del servidor en el estudio de caso de estudio de monitoreo del estado de los rodamientos

<i>Parámetro</i>	<i>Valor</i>
Número de generaciones en el algoritmo genético	500
Tamaño de población en el algoritmo genético	100
Tipo de aprendizaje	Supervisado
Épocas de aprendizaje	100

3.1.4 Análisis de los resultados

Al ejecutarse el proceso de aprendizaje, la configuración generada fue: preprocesamiento de las señales por transformada wavelet, tomándose como wavelet madre (db4) y $n=1$, combinada con los estadígrafos: valor de pico, RMS, curtosis y la desviación estándar de los coeficientes de la onduleta obtenidos. Modelado por red neuronal perceptron multicapa con retropropagación de errores, una capa oculta con 22 neuronas, 10^4 épocas para el entrenamiento, función transferencial de la capa oculta tangente hiperbólica, capa de salida lineal, capa de salida con una neurona, tasa de aprendizaje $\mu = 10^{-3}$ y gradiente mínimo de 10^{-7} .

En las Figuras 3.4-3.6 se muestran las salidas del modelo de monitoreo basado en condiciones para cada uno de los casos planteados. Además, la Tabla 3.2 muestra los índices de desempeño en cada situación, la cantidad de elementos en el conjunto de validación, los falsos positivos y negativos y el por ciento de aceptación del sistema. Se debe destacar que la mayoría de los errores en la predicción se agrupan en la zona de transición; debido a que en el análisis de los datos del sistema no se incluyó una etapa de clasificación de pre-fallos o alerta por fallo inminente, pero se puede concluir que esto se debe a que el modelo es sensible a esta etapa por lo que se demuestra que su relación directa con las componentes dinámicas del sistema modelado. Durante las épocas de aprendizaje no se produjo cambio de modelo.

Tabla 3.1 Resumen del comportamiento del sistema en los tres casos analizados en el monitoreo del estado de los rodamientos

	<i>Situación 1</i>	<i>Situación 2</i>	<i>Situación 3</i>
Verdaderos Positivos(TP)	150	187	69
Falsos Positivos(FP)	42	15	47
Verdaderos negativos(TN)	537	486	182
Falsos Negativos(FN)	4	12	0
Taza de éxito (hR) [%]	93,7	96,1	84,2
Valores Predichos Positivos(PPV)	0.78	0.93	0.59
Valores Predichos negativos(NPV)	0.99	0.98	1.00

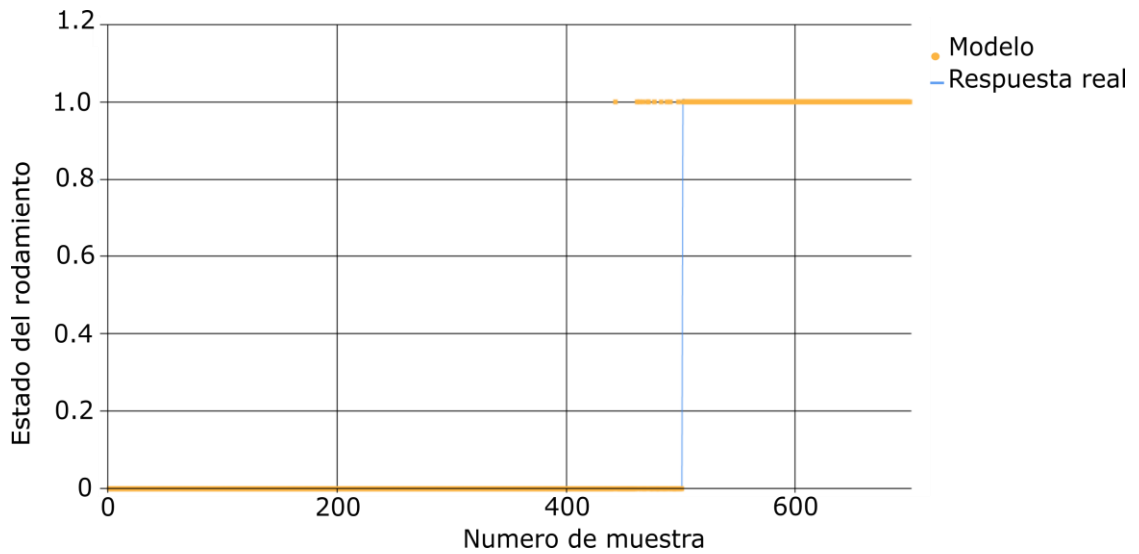


Figura 3.4 Comportamiento del modelo para el caso o situación 1

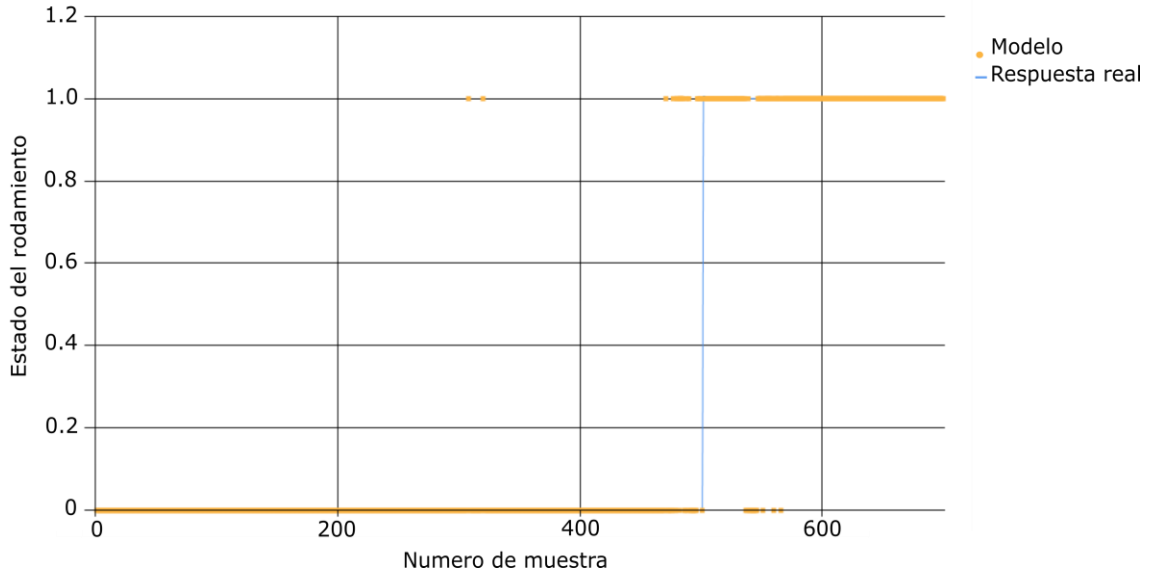


Figura 3.5 Comportamiento del modelo para el caso o situación 2




Figura 3.6 Comportamiento del sistema para el caso o situación 3

Como se plantea anteriormente, la mayoría de las falsas predicciones se concentran en la zona de transacción entre el estado de funcionamiento correcto y el fallo (Fig. 3.4, 3.5 y 3.6). Esta situación se produce fundamentalmente por su cercanía a la

zona de ruptura, en cual la dinámica de los rodamientos experimenta mayores cambios, reflejados en su señal de vibración. Esta zona es de vital interés pues permite detectar cuando el rodamiento se encuentra en la transición y así poder llevar a cabo acciones de mantenimiento predictivo para aumentar su vida útil o simplemente realizar el cambio antes de que su rotura ocasione otras roturas en componentes de mayor importancia propiciando paradas y reparaciones de mayor duración.

A través del módulo de gestión de eventos y alarmas haciendo uso de un umbral adaptativo se puede realizar la detección de esta zona de transición. El algoritmo de toma decisiones se configura para que realizar un análisis en una ventana compuesta por 20 muestras y hacer uso de la norma Euclidiana. En las figuras 3.7-3.9 se observa como la zona de alarma definida mediante el algoritmo de umbral adaptativo permite aislar la zona de transición facilitando así su detección por el sistema.

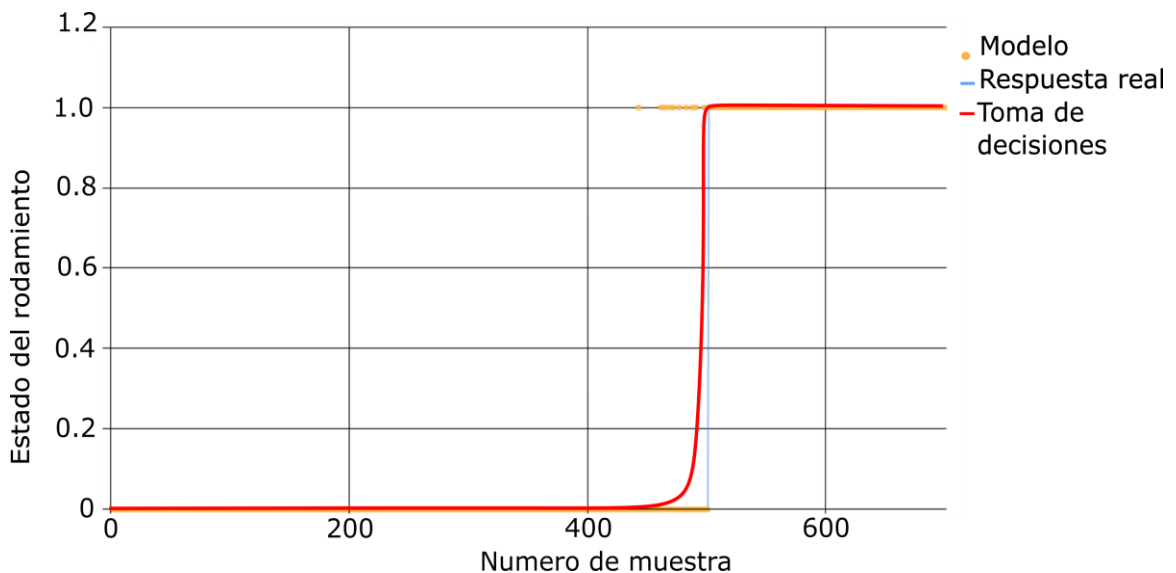


Figura 3.7 Comportamiento del modelo para el caso o situación 1

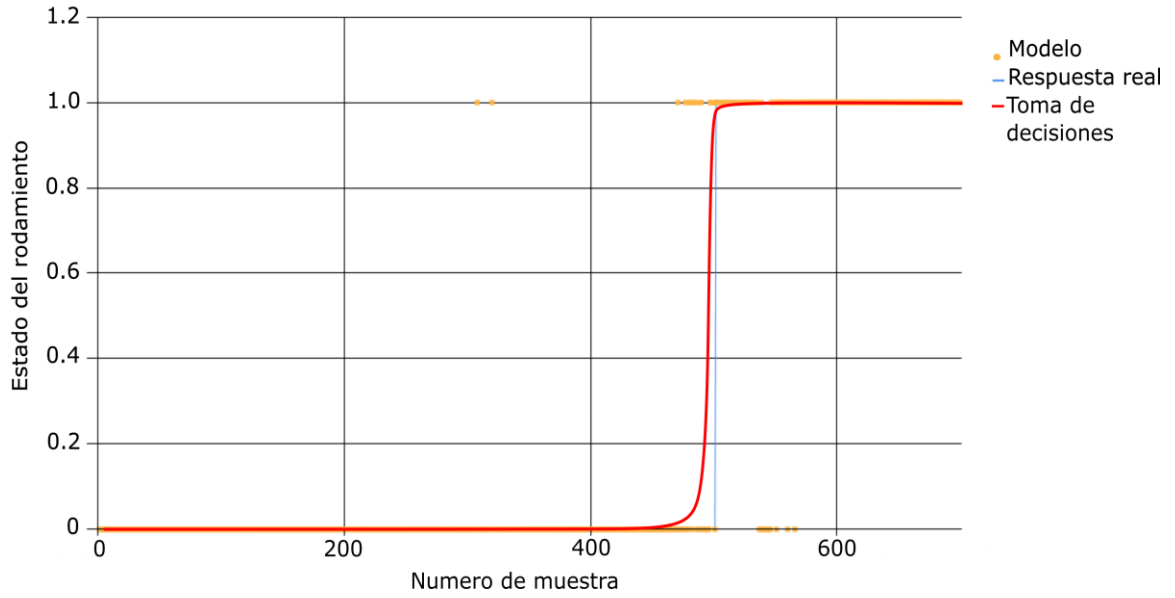


Figura 3.8 Comportamiento del modelo para el caso o situación 1




Figura 3.9 Comportamiento del modelo para el caso o situación 3.

3.2 Caso de Estudio No. 2: Predicción de la rugosidad superficial en un proceso de fresado de acabado

3.2.1 Justificación del caso de estudio

La calidad del acabado superficial es un parámetro de gran importancia en la fabricación y su impacto crece, a medida que aumenta la demanda de aplicaciones de vanguardia dirigidas hacia estándares de mayor precisión. La rugosidad superficial desempeña un papel fundamental en grandes conjuntos de piezas y productos con formas complejas, ya que afecta en gran medida su funcionamiento. Varias propiedades mecánicas y químicas de la pieza, como la conducción térmica, la conducción eléctrica, la resistencia a la corrosión (Xiao et al., 2018), la fricción, resistencia al desgaste, resistencia a la fatiga, capacidad de lubricación e incluso la estabilidad de la fabricación se encuentran relacionados con la rugosidad superficial obtenida en un proceso de maquinado (Çolak, Kurbanoglu, & Kayacan, 2007). Sin embargo, la relación de la calidad superficial con los atributos antes mencionados aún no se encuentra completamente detallada, debido a la influencia de una serie de variables físicas que son difíciles o casi imposible de medir directamente a través un proceso experimental. En consecuencia para poder expresar esta relación, se suele recurrir a otros métodos o técnicas, generalmente el uso de modelado analítico o numérico (Karkalos, Galanis, & Markopoulos, 2016).

En los proceso de manufactura, el acabado superficial se ve influenciado fundamentalmente por los parámetros de la maquina (parámetros de corte) como

son la velocidad de avance, la velocidad de corte y la profundidad de corte, así como por la geometría de la herramienta y la fuerza de corte que reflejan la dinámica del corte, el estado de la herramienta y la máquina en general (Ramana & Aditya, 2017). La correcta selección de los parámetros a incluir en el modelo es una tarea complicada debido a que la influencia de éstos varía en las diferentes operaciones de maquinado, y, a su vez, para los distintos materiales (Kumar Khare, Agarwal, & Srivastava, 2018).

El modelado y la predicción del acabado superficial, dado a que es un tema de gran importancia en la industria de fabricación, se encuentra altamente documentado en la literatura científica. Diversas técnicas de modelado son aplicadas, desde la utilización de modelos matemáticos empíricos y estadísticos (Han, Zhu, Zheng, & Wang, 2019; Wen, Li, Gao, & Yi, 2016), hasta la aplicación de técnicas más avanzadas basadas en inteligencia artificial (Papandrea, Frigieri, Maia, Oliveira, & Paiva, 2020; Thankachan et al., 2019). Los modelos matemáticos suelen tener menor complejidad y una buena exactitud de ahí a su amplia utilización, mientras los generados a través de técnicas de aprendizaje automático son de más difícil comprensión, aunque permiten obtener exactitudes mayores al modelado matemático en la mayoría de casos (Matras, Zębala, & Machno, 2019).

Teniendo en cuenta la complejidad de este proceso, se tomó como segundo caso de estudio, el monitoreo indirecto de la rugosidad superficial en un proceso de fresado convencional a través de la medición de las señales de fuerza de corte.

3.2.2 Implementación de la arquitectura

La arquitectura se implementó tal como se muestra en la Fig. 3.10. Como elemento operacional de la misma se utilizó un centro de maquinado Kondia HS1000, con sistema de CNC Siemens 840D, de arquitectura abierta (Fig. 3.11). Para la medición de la fuerza de corte, a la plataforma de maquinado se acopló un dinamómetro Kistler 9257B, con un intervalo de medición de -5 a 5 kN en los ejes x y y , y de -5 a 10 kN en el eje z , una frecuencia natural de $3,5$ kHz; y una rigidez mayor de 1 kN/mm en cada uno de los ejes. En el Anexo 4 se detallan las características técnicas del dinamómetro.

El nodo local se implementó a partir de un ordenador de placa reducida Raspberry Pi modelo B+, con procesador Cortex-A53 (ARMv8) 64-bit SoC, 1 GiB de RAM y sistema operativo Raspbian (ver Fig. 3.12). La comunicación con el CNC del centro de maquinado se llevó a cabo por protocolo Profibus, mediante un módulo de comunicación RS-485 de Cooking Hack (ver Fig. 3.12).

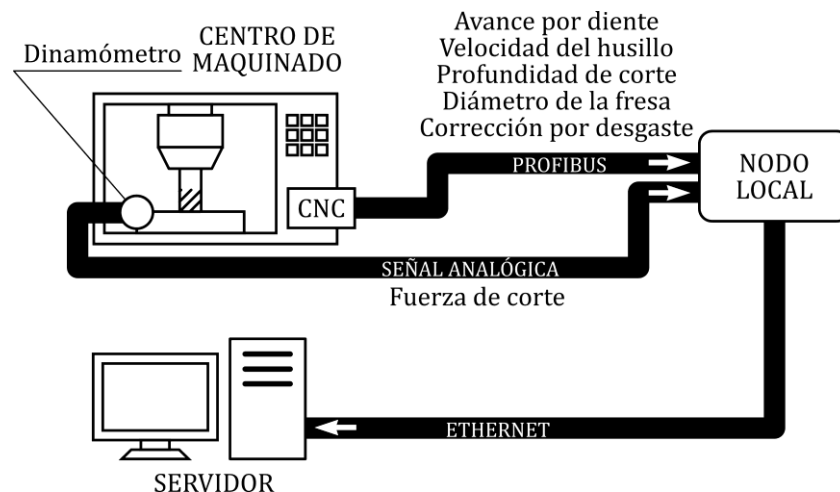


Figura 3.10 Esquema de la implementación de la arquitectura para el monitoreo indirecto de la rugosidad superficial en el fresado

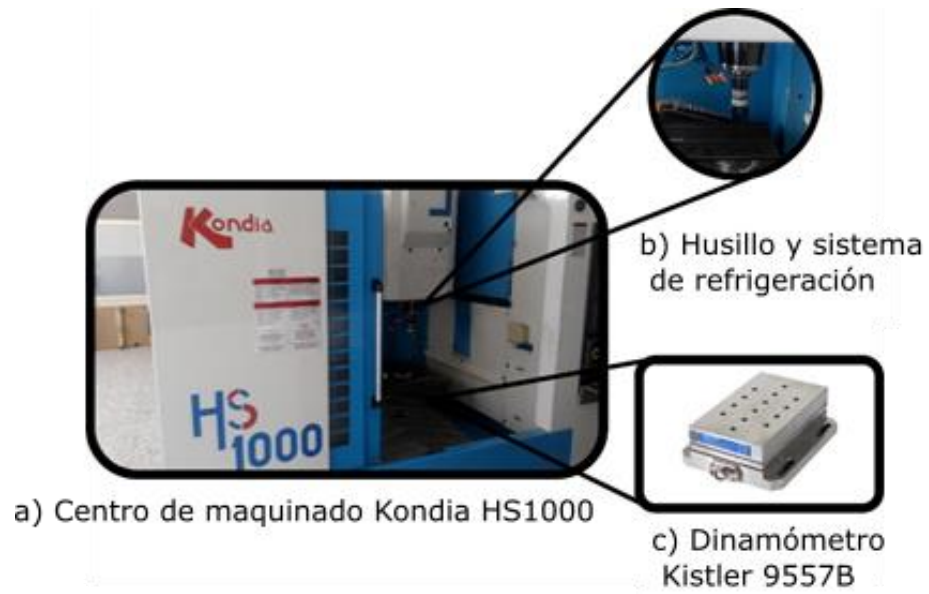


Figura 3.11 Centro universal de maquinado y equipamiento sensorial para la medición de fuerzas de corte.




Figura 3.12 Nodo local de la arquitectura para el monitoreo indirecto de la rugosidad superficial en el fresado

El servidor se implementó sobre una computadora HP, con procesador i7 y 16 GiB de RAM, con sistema operativo Ubuntu 18.04 (ver Fig. 3.13). La comunicación entre el nodo local y el servidor se realizó a través de Ethernet.



Figura 3.13 Servidor de la arquitectura para el monitoreo indirecto de la rugosidad superficial en el fresado

3.2.3 Estudio experimental

El estudio experimental se llevó a cabo mediante el fresado de aleación de aluminio AL7075-T6, bonificada, en probetas de (170 × 100 × 25) mm. Este material es utilizado ampliamente en aplicaciones de automoción y aeronáuticas. La composición química se determinó mediante un espectrómetro de emisión óptica ARL easySpark, y los correspondientes resultados se muestran en la Tabla 3.3.

Tabla 3.3 Composición química del material maquinado (aleación de aluminio A7075-T6) en monitoreo indirecto de la rugosidad superficial en el fresado

<i>Elemento</i>	<i>Composicion en masa [%]</i>	<i>Precisión [%]</i>
Aluminio, Al	Matriz	---
Zinc, Zn	5,88	0,07
Cobre, Cu	1,91	0,02
Magnesio, Mg	2,25	0,02
Cromo, Cr	0,22	0,01
Hierro, Fe	0,25	0,01
Manganeso, Mn	0,27	0,01
Silicio, Si	0,14	0,01

Las propiedades mecánicas se midieron en una máquina Shimadzu Autograph AGX-V, mediante una prueba de tracción según ASTM B557M. La dureza se midió en un durómetro Ernst AT130D, según la norma ASTM E10. En la Tabla 3.4 se muestran los valores determinados.

Tabla 3.4 Propiedades mecánicas del material maquinado (aleación de aluminio A7075-T6) en el monitoreo indirecto de la rugosidad superficial en el fresado

<i>Propiedad</i>	<i>Valor medido</i>
Módulo de elasticidad, E [GPa]	72
Tensión de rotura, σ_U [MPa]	535
Tensión de fluencia σ_F [MPa]	474
Dureza, HB	140

Como herramientas de corte se utilizaron fresas de vástago marca Sandvik, de tipo CoroMill Pura. Todas de material grado GC1620, correspondientes a carburo de wolframio (WC) de grano fino, con recubrimiento de nitruro de titanio-aluminio ((Ti,Al)N) de capa fina. El ángulo de la hélice, en todas ellas, es de 30°; el ángulo de

ataque axial de $13,5^\circ$; y el ángulo de ataque radial de $10,5^\circ$. Se utilizaron cuatro modelos de herramientas correspondientes a los cuatro diámetros experimentales, cuyas principales características técnicas se ofrecen en la Tabla 3.5.

Tabla 3.5 Características de las herramientas de corte utilizadas en el monitoreo indirecto de la rugosidad superficial en el fresado

<i>Código de la fresa</i>	<i>Diámetro de la fresa, D [mm]</i>	<i>Radio del filo, r_E [mm]</i>	<i>Longitud útil axial máxima, a_{P-MAX} [mm]</i>
R216.T4-06030BAS10N 1620	6	0,5	10
R216.T4-08030BAS12N 1620	8	0,5	12
R216.T4-10030CAS14N 1620	10	1,0	14
R216.T4-12030CAS16N 1620	12	1,0	16

Como variables seleccionadas para el monitoreo, además de la fuerza de corte en el plano xy , F_{xy} (la cual depende tanto de las variables controladas como de factores aleatorios o no controlados), se tomaron el diámetro de la herramienta, D ; el avance por diente, f_z ; la profundidad de corte radial, a_e , velocidad de giro, n ; y la corrección de la geometría de la herramienta por el desgaste, ρ . En la Tabla 3.6 se muestran los intervalos considerados para cada una de las variables.

Se maquinaron tanto regiones convexas (islas), como cóncavas (cavidades) (ver Fig. 3.14), todas con una profundidad total de 10 mm. La rugosidad de la superficie, R_a , se midió con el perfilómetro de punta (*stylus*) Carl Zeiss Surfcom 130, con detección por transformador diferencial lineal variable, radio de punta de $2 \mu\text{m}$, fuerza de medición de $0,7 \text{ mN}$ y resolución de $1/64000$ del intervalo de medición. (El resto de los datos técnicos se muestran en el Anexo 5.)

Tabla 3.6 Condiciones experimentales para el monitoreo indirecto de la rugosidad superficial en el fresado

<i>Variables independientes</i>	<i>Niveles experimentales</i>			
	1	2	3	4
Diámetro de la herramienta, D [mm]	6	8	10	12
Avance por diente, f_z [μm]	25	50	75	100
Profundidad de corte radial, a_e [mm]	2	3	4	5
Velocidad de giro del husillo, n [min^{-1}]	16 000	18 000	20 000	22 000
Corrección de la herramienta, ρ [μm]	-42	-21	21	42




Figura 3.14 Geometría de las piezas utilizadas en los experimentos para el monitoreo indirecto de la rugosidad superficial en el fresado

3.2.4 Análisis de los resultados

A partir de los valores experimentales de rugosidad superficial, con los correspondientes parámetros del proceso y las señales de fuerza medidas, se ajustaron los modelos de predicción. Para ello, el nodo del servidor se ajustó a los parámetros mostrados en la Tabla 3.7.

Tabla 3.7 Parámetros del nodo del servidor en el estudio de caso del monitoreo indirecto de la rugosidad superficial

<i>Parámetro</i>	<i>Valor</i>
Número de generaciones en el algoritmo genético	500
Tamaño de población en el algoritmo genético	100
Tipo de aprendizaje	Supervisado
Épocas de aprendizaje	100

Durante el proceso de autoconfiguración, la arquitectura arrojó, como modelo con mejor desempeño para la supervisión, una red neuronal perceptrón multicapa con retropropagación de errores, con una capa oculta de 28 neuronas, entrenada con 10^4 épocas. Como función de transferencia de la capa oculta se utilizó la tangente hiperbólica, mientras que para la capa de salida, se utilizó la función lineal. La velocidad de aprendizaje utilizada fue igual a 10^{-3} y el gradiente mínimo, a 10^{-7} . Para el preprocesamiento de la señal medida de fuerza de corte, se escogió el estadígrafo temporal raíz cuadrática media.

Tabla 3.8 Índices de desempeño para los conjuntos de validación

<i>Índice de desempeño</i>	<i>Conjunto de entrenamiento</i>	<i>Conjunto de validación</i>
MAE	0,0012	0,0031
SSE	0,015	0,027
ERM (%)	1,43	2,45
NNSE (%)	2,05	4,26
FPE (%)	1,06	2,72

Para el análisis del comportamiento de las predicciones, fueron considerados cinco índices: la suma de errores cuadrados (SSE), el ruido de la suma de errores cuadrados (NSSE), el error relativo medio (ERM), el error medio absoluto (MAE) y el error de predicción final (FPE).

En la Tabla 3.8 se muestran los valores de dichos índices, para los conjuntos de validación y de entrenamiento, respectivamente. Aunque, como cabría esperar, los resultados son ligeramente mejores para el conjunto de entrenamiento, los valores obtenidos para el conjunto de validación son también de muy alta calidad, lográndose predicciones con un error muy inferior al de los valores predichos.




Figura 3.15 Comportamiento del modelo de rugosidad superficial, para el conjunto de entrenamiento

En la Fig. 3.15 se muestran los resultados cuando se realiza la validación de la arquitectura con en el conjunto de entrenamiento. Como se puede observar, existe

una elevada coincidencia entre los valores modelados (predichos) y la respuesta real (observados) por la arquitectura. Esto está en total correspondencia con los valores de lo índices de desempeño anteriormente analizados.

De forma similar, la Fig. 3.16 representa el comportamiento del modelo con el conjunto de validación. Cabe destacar, que los índices de desempeño considerados presentaron un comportamiento que define la alta calidad de los modelos predictivos obtenidos. El valor de probabilidad del modelo para predecir la rugosidad superficial es de 0,7820; en consecuencia, la hipótesis de los residuos procedentes de la misma distribución no puede ser rechazada con el nivel de confianza mayor que 95%. El error final en la predicción es del 2,72% y un MAE por debajo de 0,01 mostrándose un buen ajuste.

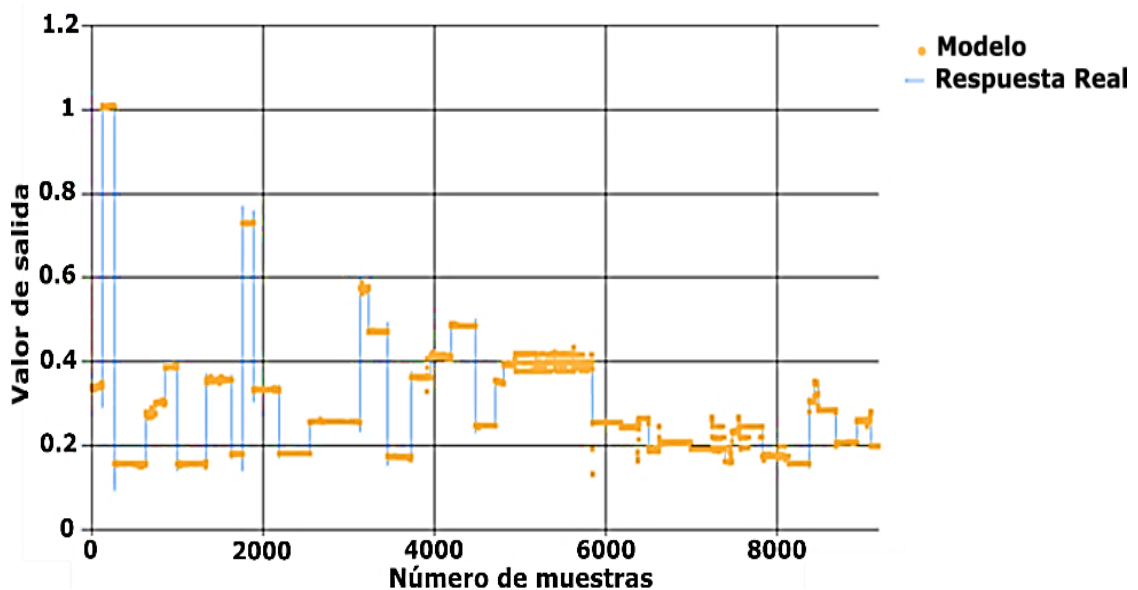


Figura 3.16 Comportamiento del modelo de rugosidad superficial, para el conjunto de validación

Finalmente, un análisis importante, desde el punto de vista de aplicación práctica de la arquitectura propuesta, es la eficiencia computacional y de comunicación de la misma. En la Tabla 3.9 se muestran los principales indicadores de la carga computacional y de red, para el caso de estudio No. 2.

Como se puede ver, el único proceso con un alto requerimiento temporal es el entrenamiento del modelo. No obstante, como este proceso se ejecuta fuera de línea (*offline*), y en un servidor, no afecta el rendimiento del sistema. De hecho, se pudiera lograr un mejor rendimiento si se utilizara un hardware de mayores prestaciones, incluso, un enfoque de computación en la nube, para la modelación.

Tabla 3.9 Evaluación de la eficiencia computacional y de comunicación de la arquitectura en el caso de estudio de monitoreo indirecto de la rugosidad superficial en el fresado

<i>Proceso</i>	<i>Tipo</i>	<i>Tiempo de ejecución [s]</i>
Entrenamiento y optimización de los modelos	Fuera de línea	2546
Descarga de los modelos al nodo local	Fuera de línea	2,5
Preprocesamiento de las señales en el nodo local	En línea	0,003
Evaluación de los modelos en el nodo local	En línea	0,008

Por su parte, el tiempo de los procesos en línea (*online*), es decir, el preprocesamiento y la evaluación de las señales en el nodo local, requieren menos de 10 ms por paquete, lo que garantiza la respuesta en tiempo real para la inmensa mayoría de los procesos mecánicos.

3.2.5 Análisis económico

Con el objetivo de evaluar la introducción práctica de la arquitectura propuesta, para el caso de estudio considerado, se realizó un análisis de factibilidad económica de la misma. Para ello, se utilizó como criterio el valor actual neto (*VAN*) de la arquitectura, tras un período de tres años, que se eligió por ser un estimado conservador de la vida útil y la caducidad de los componentes de hardware del sistema.

El costo de implementación del sistema se determinó como la suma de los costos de inversión inicial, Z_0 , y de consumo eléctrico, Z_{EL} , del mismo. El costo de inversión inicial, por su parte, se calculó como la suma del costo de equipamiento, Z_{EQ} , y del costo de know-how, Z_{KH} . El cálculo del costo de equipamiento se resume en la Tabla 3.10.

Tabla 3.10 Costo y consumo eléctrico de los componentes de hardware de la arquitectura implementada para el monitoreo indirecto de la rugosidad superficial en el fresado

<i>Elemento de hardware</i>	<i>Costo [\$]</i>	<i>Consumo [W]</i>
Ordenador HP i7	310,00	500
Raspberry Pi B+ y ADC Pi	52,00	10
Módulo de comunicación RS-485	98,00	2
Misceláneas de comunicación	64,00	25
<i>Total</i>	<i>524,00</i>	<i>537</i>

Por su parte, el costo de know-how se estimó en un 25% del anterior:

$$Z_{KH} = 0,25Z_{EQ} = 0,25 \cdot \$524,00; \quad (3.1)$$

$$Z_{KH} = \$131,00.$$

La inversión inicial resulta, entonces, en:

$$Z_0 = Z_{EQ} + Z_{KH} = \$524,00 + \$131,00; \quad (3.2)$$

$$Z_0 = \$655,00.$$

El costo anual de electricidad, por otro lado, se determina a partir del consumo total del equipamiento, e_{TOT} , considerado para 2 287,6 h al año y con un costo unitario, $\zeta_{EL} = 0,12 \text{ \$/kW}\cdot\text{h}$):

$$Z_{EL} = 2\,287,6 \cdot \frac{e_{TOT}}{1000} \cdot \zeta_{EL} = 2\,287,6 \cdot \frac{537}{1000} \cdot 0,12; \quad (3.3)$$

$$Z_{EL} = \$147,39.$$

La ganancia anual por la introducción del sistema, Y , en concepto de ahorro por piezas defectuosas, se determina como la cantidad de piezas rechazadas anualmente por fallos en la calidad superficial en la operación considerada, N_R , y el costo unitario de cada pieza, ζ_P :

$$Y = N_R \zeta_P. \quad (3.4)$$

Con el propósito de evaluar la factibilidad económica de posibles escenarios, se determinó el VAN para diferentes combinaciones de cantidad de rechazos y de costos unitarios, según la expresión:

$$VAN = \sum_{i=1}^3 \frac{Y - Z_{EL}}{(1 + \lambda)^i} - Z_0; \quad (3.5)$$

donde λ es la tasa anual de retorno que, para las disposiciones bancarias nacionales se tomó como $\lambda = 0,12$.




Figura 3.17 Nomograma de valor actual neto para las diferentes combinaciones de cantidad de piezas rechazadas y costo unitario de las mismas

En la Figura 3.17 se muestra el nomograma de VAN en función de los valores de cantidad de piezas rechazadas y costo unitario de las mismas. Como se puede observar, la curva roja ($VAN = 0$) muestra el límite de factibilidad económica de la introducción de la arquitectura. Así, por ejemplo, para una cantidad de rechazos anuales de piezas con un valor de \$5,00 (punto 1), el VAN es negativo lo que indica que la inversión no es factible. Por el contrario, para un rechazo de 100 piezas anuales,

con un valor unitario de \$15,00 (punto 2), el VAN, al cabo de tres años será mayor que cero (\$2 593,75), lo que garantiza la factibilidad de la introducción de la arquitectura, para estas condiciones.

3.3 Conclusiones parciales del capítulo

Una vez finalizado el presente capítulo, se ha podido arribar a las siguientes conclusiones parciales:

1. La arquitectura presenta un buen desempeño en el monitoreo de estados de rodamientos en máquinas rotatorias avalado por índices que superaron el 90% de exactitud en la detección de los fallos.
2. La arquitectura demostró un buen desempeño en la predicción del acabado de piezas en procesos de maquinado obteniéndose un error de las predicciones de la rugosidad superficial menor del 3%.
3. La arquitectura mostró eficiencia computacional y de comunicación, garantizando su implementación en la mayoría de los sistemas mecánicos de fabricación.
4. El análisis del valor actual neto permite evaluar la factibilidad económica de la introducción de la arquitectura bajo diferentes condiciones prácticas.

CONCLUSIONES

Una vez cubiertas las diferentes etapas para el diseño, implementación y validación de la arquitectura, se arribaron a las siguientes conclusiones:

1. La arquitectura diseñada e implementada, gracias a su capacidad de autoaprendizaje, demostró efectividad en el monitoreo indirecto y la detección de fallos, en procesos y sistemas mecánicos, debido a los altos niveles de precisión en sus predicciones.
2. La arquitectura, gracias a su capacidad de autoconfiguración, demostró robustez y flexibilidad, lo que permite su aplicación efectiva en diferentes procesos y sistemas mecánicos con un mínimo de acciones de configuración.
3. Las librerías de procesamiento de señales y de modelación con parametrización óptima, basada en técnicas de aprendizaje automático, permitieron generar modelos predictivos con altos índices de desempeño.
4. El funcionamiento de la arquitectura mostro una alta eficiencia computacional y de comunicación, especialmente para las tareas a ejecutar en línea, lo que garantiza la predicción en tiempo real de las variables monitoreadas, para la mayor parte de los procesos y sistemas mecánicos.

RECOMENDACIONES

Basadas en las conclusiones obtenidas y para la extensión futura del presente trabajo, se realizan las siguientes recomendaciones:

1. Desplegar la arquitectura en entornos industriales, donde se pueda seguir valorando su efectividad técnica y factibilidad económica.
2. Enriquecer la biblioteca de modelos y de preprocesamiento de señales con nuevas técnicas, que aumenten la versatilidad de la arquitectura.
3. Dotar a la arquitectura de nuevas funcionalidades que le permitan realizar análisis avanzados a nivel de gestión de sistemas.

REFERENCIAS BIBLIOGRÁFICAS

- Adamczyk, B. S., Szejka, A. L., & Canciglieri, O. (2020). Knowledge-based expert system to support the semantic interoperability in smart manufacturing. *Computers in Industry, 115*, 103161. doi:10.1016/j.compind.2019.103161
- Al-Sayed, M. M., Hassan, H. A., & Omara, F. A. (2020). CloudFNF: An ontology structure for functional and non-functional features of cloud services. *Journal of Parallel and Distributed Computing, 141*, 143-173. doi:10.1016/j.jpdc.2020.03.019
- Altobi, M. A. S., Bevan, G., Wallace, P., Harrison, D., & Ramachandran, K. P. (2019). Fault diagnosis of a centrifugal pump using MLP-GABP and SVM with CWT. *Engineering Science and Technology, an International Journal*. doi:10.1016/j.jestch.2019.01.005
- Ambekar, M., & Kittur, J. (2020). Multiresponse optimization of friction stir welding process parameters by an integrated WPCA-ANN-PSO approach. *Materials Today: Proceedings, 27*, 363-368. doi:10.1016/j.matpr.2019.11.152
- Aoyagi, K., Wang, H., Sudo, H., & Chiba, A. (2019). Simple method to construct process maps for additive manufacturing using a support vector machine. *Additive Manufacturing, 27*, 353-362. doi:10.1016/j.addma.2019.03.013
- Barrios, M. L. R., Montero, F. E. H., Gómez Mancilla, J. C., & Marín, E. P. (2017). Application of Lock-In Amplifier on gear diagnosis. *Measurement, 107*, 120-127. doi:10.1016/j.measurement.2017.05.015
- Bellagente, P., De Dominicis, C. M., Depari, A., Flammini, A., Rinaldi, S., Sisinni, E., & Vezzoli, A. (2014). WLAN-enabled Sensor Nodes for Cloud-based Machine Condition Monitoring. *Procedia Engineering, 87*, 1290-1293. doi:10.1016/j.proeng.2014.11.683
- Benvegnù, A., Laurent, S., Meneghini, M., Quéré, R., Roux, J. L., Zanoni, E., & Barataud, D. (2016). Continuous time-domain RF waveforms monitoring under overdrive stress condition of AlGaIn/GaN HEMTs. *Microelectronics Reliability, 64*, 535-540. doi:10.1016/j.microrel.2016.07.122
- Beruvides, G., Castaño, F., Haber, R. E., Quiza, R., Villalonga, A. (2017). Coping with Complexity When Predicting Surface Roughness in Milling Processes: Hybrid Incremental Model with Optimal Parametrization. *Complexity, 2017*, 11. doi:10.1155/2017/7317254
- Beruvides, G., Quiza, R., del Toro, R., & Haber, R. E. (2013). Sensing systems and signal analysis to monitor tool wear in microdrilling operations on a sintered tungsten-copper composite material. *Sensors and Actuators A: Physical, 199(0)*, 165-175. doi:10.1016/j.sna.2013.05.021

- Beruvides, G., Villalonga, A., Franciosa, P., Ceglarek, D., & Haber, R. E. (2018). Fault pattern identification in multi-stage assembly processes with non-ideal sheet-metal parts based on reinforcement learning architecture. *Procedia CIRP*, 67, 601-606. doi:10.1016/j.procir.2017.12.268
- Boral, S., Howard, I., Chaturvedi, S. K., McKee, K., & Naikan, V. N. A. (2020). A novel hybrid multi-criteria group decision making approach for failure mode and effect analysis: An essential requirement for sustainable manufacturing. *Sustainable Production and Consumption*, 21, 14-32. doi:10.1016/j.spc.2019.10.005
- Brahimi, N., Dolgui, A., Gurevsky, E., & Yelles-Chaouche, A. R. (2019). A literature review of optimization problems for reconfigurable manufacturing systems. *IFAC-PapersOnLine*, 52(13), 433-438. doi:10.1016/j.ifacol.2019.11.097
- Caesarendra, W., Kosasih, B., Tieu, A. K., Zhu, H., Moodie, C. A. S., & Zhu, Q. (2016). Acoustic emission-based condition monitoring methods: Review and application for low speed slew bearing. *Mechanical Systems and Signal Processing*, 72-73, 134-159. doi:10.1016/j.ymsp.2015.10.020
- Caesarendra, W., & Tjahjowidodo, T. (2017). A Review of Feature Extraction Methods in Vibration-Based Condition Monitoring and Its Application for Degradation Trend Estimation of Low-Speed Slew Bearing. *Machines*, 5. doi:10.3390/machines5040021
- Cerrada, M., Sánchez, R.-V., Li, C., Pacheco, F., Cabrera, D., Valente de Oliveira, J., & Vásquez, R. E. (2018). A review on data-driven fault severity assessment in rolling bearings. *Mechanical Systems and Signal Processing*, 99, 169-196. doi:10.1016/j.ymsp.2017.06.012
- Chen, G., & Ge, Z. (2020). Robust Bayesian networks for low-quality data modeling and process monitoring applications. *Control Engineering Practice*, 97, 104344. doi:10.1016/j.conengprac.2020.104344
- Chen, J., Yang, J., Zhou, H., Xiang, H., Zhu, Z., Li, Y., . . . Xu, G. (2015). CPS Modeling of CNC Machine Tool Work Processes Using an Instruction-Domain Based Approach. *Engineering*, 1(2), 247-260. doi:10.15302/J-ENG-2015054
- Chen, T., Wang, Z., Yang, X., & Jiang, K. (2019). A deep capsule neural network with stochastic delta rule for bearing fault diagnosis on raw vibration signals. *Measurement*, 148, 106857. doi:10.1016/j.measurement.2019.106857
- Cheng, F., & Dong, J. (2019). Monitoring tip-based nanomachining process by time series analysis using support vector machine. *Journal of Manufacturing Processes*, 38, 158-166. doi:10.1016/j.jmapro.2019.01.011
- Chryssolouris, E. L. K. E. (2006). *Manufacturing Systems: Theory and Practice*: Springer-Verlag New York.

- Çolak, O., Kurbanoglu, C., & Kayacan, M. C. (2007). Milling surface roughness prediction using evolutionary programming methods. *Materials & Design*, 28(2), 657-666. doi:10.1016/j.matdes.2005.07.004
- D'Addona, D. M., Conte, S., Lopes, W. N., de Aguiar, P. R., Bianchi, E. C., & Teti, R. (2018). Tool Condition Monitoring of Single-point Dressing Operation by Digital Signal Processing of AE and AI. *Procedia CIRP*, 67, 307-312. doi:10.1016/j.procir.2017.12.218
- D'Addona, D. M., Matarazzo, D., de Aguiar, P. R., Bianchi, E. C., & Martins, C. H. R. (2016). Neural Networks Tool Condition Monitoring in Single-point Dressing Operations. *Procedia CIRP*, 41, 431-436. doi:10.1016/j.procir.2016.01.001
- da Silva, A. F., Ohta, R. L., dos Santos, M. N., & Binotto, A. P. D. (2016). A Cloud-based Architecture for the Internet of Things targeting Industrial Devices Remote Monitoring and Control. *IFAC-PapersOnLine*, 49(30), 108-113. doi:10.1016/j.ifacol.2016.11.137
- da Silva, R. H. L., da Silva, M. B., & Hassui, A. (2016). A probabilistic neural network applied in monitoring tool wear in the end milling operation via acoustic emission and cutting power signals. *Machining Science and Technology*, 20(3), 386-405. doi:10.1080/10910344.2016.1191026
- Das, S., Nayak, B., Sarangi, S. K., & Biswal, D. K. (2016). Condition Monitoring of Robust Damage of Cantilever Shaft Using Experimental and Adaptive Neuro-fuzzy Inference System (ANFIS). *Procedia Engineering*, 144, 328-335. doi:10.1016/j.proeng.2016.05.140
- Deshwal, S., Kumar, A., & Chhabra, D. (2020). Exercising hybrid statistical tools GA-RSM, GA-ANN and GA-ANFIS to optimize FDM process parameters for tensile strength improvement. *CIRP Journal of Manufacturing Science and Technology*. doi:10.1016/j.cirpj.2020.05.009
- Dheeraj Simon, G., & Deivanathan, R. (2019). Early detection of drilling tool wear by vibration data acquisition and classification. *Manufacturing Letters*, 21, 60-65. doi:10.1016/j.mfglet.2019.08.006
- Downey, J., O'Sullivan, D., Nejmen, M., Bombinski, S., O'Leary, P., Raghavendra, R., & Jemielniak, K. (2016). Real Time Monitoring of the CNC Process in a Production Environment- the Data Collection & Analysis Phase. *Procedia CIRP*, 41, 920-926. doi:10.1016/j.procir.2015.12.008
- Dutta, S., Pal, S. K., & Sen, R. (2016). Progressive tool flank wear monitoring by applying discrete wavelet transform on turned surface images. *Measurement*, 77, 388-401. doi:10.1016/j.measurement.2015.09.028

- Edrington, B., Zhao, B., Hansel, A., Mori, M., & Fujishima, M. (2014). Machine Monitoring System Based on MTCConnect Technology. *Procedia CIRP*, 22, 92-97. doi:10.1016/j.procir.2014.07.148
- Er, P. V., & Tan, K. K. (2018). Machine vibration analysis based on experimental modal analysis with radial basis functions. *Measurement*, 128, 45-54. doi:10.1016/j.measurement.2018.06.013
- Fé-Perdomo, I. I., Beruvides, G., Quiza, R., Haber, R., & Rivas, M. (2019). Automatic Selection of Optimal Parameters Based on Simple Soft-Computing Methods: A Case Study of Micromilling Processes. *IEEE Transactions on Industrial Informatics*, 15(2), 800-811. doi:10.1109/TII.2018.2816971
- Fleischmann, H., Kohl, J., & Franke, J. (2016). A Modular Architecture for the Design of Condition Monitoring Processes. *Procedia CIRP*, 57, 410-415. doi:10.1016/j.procir.2016.11.071
- Frigerio, N., & Matta, A. (2014). Energy Efficient Control Strategy for Machine Tools with Stochastic Arrivals and Time Dependent Warm-up. *Procedia CIRP*, 15, 56-61. doi:10.1016/j.procir.2014.06.040
- Galar, D., & Kumar, U. (2017). Chapter 4 - Data and Information Fusion From Disparate Asset Management Sources. In D. Galar & U. Kumar (Eds.), *eMaintenance* (pp. 179-234): Academic Press.
- Ghafarizadeh, S., Lebrun, G., & Chatelain, J.-F. (2016). Experimental investigation of the cutting temperature and surface quality during milling of unidirectional carbon fiber reinforced plastic. *Journal of Composite Materials*, 50(8), 1059-1071. doi:10.1177/0021998315587131
- Gonzalez, R., Huang, B., & Lau, E. (2015). Process monitoring using kernel density estimation and Bayesian networking with an industrial case study. *ISA Transactions*, 58, 330-347. doi:10.1016/j.isatra.2015.04.001
- Goyal, D., Vanraj, Pabla, B. S., & Dhami, S. S. (2019). Non-contact sensor placement strategy for condition monitoring of rotating machine-elements. *Engineering Science and Technology, an International Journal*, 22(2), 489-501. doi:10.1016/j.jestch.2018.12.006
- Guerra, R. H., Quiza, R., Villalonga, A., Arenas, J., & Castaño, F. (2019). Digital Twin-Based Optimization for Ultraprecision Motion Systems With Backlash and Friction. *IEEE Access*, 7, 93462-93472. doi:10.1109/ACCESS.2019.2928141
- Guo, Y., Li, K., Yang, Z., Deng, J., & Laverty, D. M. (2015). A novel radial basis function neural network principal component analysis scheme for PMU-based wide-area power system monitoring. *Electric Power Systems Research*, 127, 197-205. doi:10.1016/j.epsr.2015.06.002

- Han, J., Zhu, J., Zheng, W., & Wang, G. (2019). Influence of metal forming parameters on surface roughness and establishment of surface roughness prediction model. *International Journal of Mechanical Sciences*, *163*, 105093. doi:10.1016/j.ijmecsci.2019.105093
- Hesser, D. F., & Markert, B. (2019). Tool wear monitoring of a retrofitted CNC milling machine using artificial neural networks. *Manufacturing Letters*, *19*, 1-4. doi:10.1016/j.mfglet.2018.11.001
- Huang, D.-W., Gentili, R. J., Katz, G. E., & Reggia, J. A. (2017). A limit-cycle self-organizing map architecture for stable arm control. *Neural Networks*, *85*, 165-181. doi:10.1016/j.neunet.2016.10.005
- Huang, J., Zhou, Z., Liu, M., Zhang, E., Chen, M., Pham, D. T., & Ji, C. (2015). Real-time measurement of temperature field in heavy-duty machine tools using fiber Bragg grating sensors and analysis of thermal shift errors. *Mechatronics*, *31*, 16-21. doi:10.1016/j.mechatronics.2015.04.004
- Karkalos, N. E., Galanis, N. I., & Markopoulos, A. P. (2016). Surface roughness prediction for the milling of Ti-6Al-4V ELI alloy with the use of statistical and soft computing techniques. *Measurement*, *90*, 25-35. doi:10.1016/j.measurement.2016.04.039
- Kim, Y., Park, J., Na, K., Yuan, H., Youn, B. D., & Kang, C.-s. (2020). Phase-based time domain averaging (PTDA) for fault detection of a gearbox in an industrial robot using vibration signals. *Mechanical Systems and Signal Processing*, *138*, 106544. doi:10.1016/j.ymsp.2019.106544
- Klocke, F., Döbbeler, B., Pullen, T., & Bergs, T. (2019). Acoustic emission signal source separation for a flank wear estimation of drilling tools. *Procedia CIRP*, *79*, 57-62. doi:10.1016/j.procir.2019.02.011
- Kotu, V., & Deshpande, B. (2019). Chapter 1 - Introduction. In V. Kotu & B. Deshpande (Eds.), *Data Science (Second Edition)* (pp. 1-18): Morgan Kaufmann.
- Kumar, A., Zhou, Y., Gandhi, C. P., Kumar, R., & Xiang, J. (2020). Bearing defect size assessment using wavelet transform based Deep Convolutional Neural Network (DCNN). *Alexandria Engineering Journal*, *59*(2), 999-1012. doi:10.1016/j.aej.2020.03.034
- Kumar Khare, S., Agarwal, S., & Srivastava, S. (2018). Analysis of Surface Roughness during Turning Operation by Taguchi Method. *Materials Today: Proceedings*, *5*(14, Part 2), 28089-28097. doi:10.1016/j.matpr.2018.10.050
- Langer, T., Schlegel, A., Stoldt, J., & Putz, M. (2014). A Model-based Approach to Energy-saving Manufacturing Control Strategies. *Procedia CIRP*, *15*, 123-128. doi:10.1016/j.procir.2014.06.019

- Latif, K., & Yusof, Y. (2016). New Method for the Development of Sustainable STEP-Compliant Open CNC System. *Procedia CIRP*, 40, 230-235. doi:10.1016/j.procir.2016.01.110
- Li, J., Pedrycz, W., & Jamal, I. (2017). Multivariate time series anomaly detection: A framework of Hidden Markov Models. *Applied Soft Computing*, 60, 229-240. doi:10.1016/j.asoc.2017.06.035
- Li, J., Zhang, X., Zhou, X., & Lu, L. (2019). Reliability assessment of wind turbine bearing based on the degradation-Hidden-Markov model. *Renewable Energy*, 132, 1076-1087. doi:10.1016/j.renene.2018.08.048
- Li, K., Wang, L., Wu, J., Zhang, Q., Liao, G., & Su, L. (2018). Using GA-SVM for defect inspection of flip chips based on vibration signals. *Microelectronics Reliability*, 81, 159-166. doi:10.1016/j.microrel.2017.12.032
- Li, T., He, T., Wang, Z., & Zhang, Y. (2020). SDF-GA: a service domain feature-oriented approach for manufacturing cloud service composition. *Journal of Intelligent Manufacturing*, 31(3), 681-702. doi:10.1007/s10845-019-01472-1
- Li, W., & Liu, T. (2019). Time varying and condition adaptive hidden Markov model for tool wear state estimation and remaining useful life prediction in micro-milling. *Mechanical Systems and Signal Processing*, 131, 689-702. doi:10.1016/j.ymsp.2019.06.021
- Li, X., Nassehi, A., & Epureanu, B. I. (2019). Degradation-aware decision making in reconfigurable manufacturing systems. *CIRP Annals*, 68(1), 431-434. doi:10.1016/j.cirp.2019.04.065
- Liao, L., & Lee, J. (2010). Design of a reconfigurable prognostics platform for machine tools. *Expert Systems with Applications*, 37(1), 240-252. doi:10.1016/j.eswa.2009.05.004
- Lima-Junior, F. R., & Carpinetti, L. C. R. (2019). Predicting supply chain performance based on SCOR® metrics and multilayer perceptron neural networks. *International Journal of Production Economics*, 212, 19-38. doi:10.1016/j.ijpe.2019.02.001
- Lindemann, B., Karadogan, C., Jazdi, N., Liewald, M., & Weyrich, M. (2018). Cloud-based Control Approach in Discrete Manufacturing Using a Self-Learning Architecture. *IFAC-PapersOnLine*, 51(10), 163-168. doi:10.1016/j.ifacol.2018.06.255
- Liu, Z., & Zhang, L. (2020). A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings. *Measurement*, 149, 107002. doi:10.1016/j.measurement.2019.107002

- Liu, Z., Zhang, L., & Carrasco, J. (2020). Vibration analysis for large-scale wind turbine blade bearing fault detection with an empirical wavelet thresholding method. *Renewable Energy*, *146*, 99-110. doi:10.1016/j.renene.2019.06.094
- Lu, Y., & Xu, X. (2019). Cloud-based manufacturing equipment and big data analytics to enable on-demand manufacturing services. *Robotics and Computer-Integrated Manufacturing*, *57*, 92-102. doi:10.1016/j.rcim.2018.11.006
- Mak, K. K., Lee, K., & Park, C. (2019). Applications of machine learning in addiction studies: A systematic review. *Psychiatry Research*, *275*, 53-60. doi:10.1016/j.psychres.2019.03.001
- Manjurul Islam, M. M., & Kim, J.-M. (2019). Reliable multiple combined fault diagnosis of bearings using heterogeneous feature models and multiclass support vector Machines. *Reliability Engineering & System Safety*, *184*, 55-66. doi:10.1016/j.ress.2018.02.012
- Mansouri, M., Hajji, M., Trabelsi, M., Harkat, M. F., Al-khazraji, A., Livera, A., . . . Nounou, M. (2018). An effective statistical fault detection technique for grid connected photovoltaic systems based on an improved generalized likelihood ratio test. *Energy*, *159*, 842-856. doi:10.1016/j.energy.2018.06.194
- Mañalich Gálvez, I., & Pérez Abreu, Y. (2018). Industria, competitividad e innovación: desafíos para Cuba. *Economía y Desarrollo*, *159* (1), 42- 60.
- Martin-Diaz, I., Morinigo-Sotelo, D., Duque-Perez, O., Osornio-Rios, R. A., & Romero-Troncoso, R. J. (2018). Hybrid algorithmic approach oriented to incipient rotor fault diagnosis on induction motors. *ISA Transactions*, *80*, 427-438. doi:10.1016/j.isatra.2018.07.033
- Matras, A., Zębala, W., & Machno, M. (2019). Research and Method of Roughness Prediction of a Curvilinear Surface after Titanium Alloy Turning. *Materials*, *12*(3), 502.
- Medjaher, K., Tobon-Mejia, D. A., & Zerhouni, N. (2012). Remaining Useful Life Estimation of Critical Components With Application to Bearings. *IEEE Transactions on Reliability*, *61*(2), 292-302. doi:10.1109/TR.2012.2194175
- Meng, Q.-Q., Zhu, Q.-X., Gao, H.-H., He, Y.-L., & Xu, Y. (2019). A novel scoring function based on family transfer entropy for Bayesian networks learning and its application to industrial alarm systems. *Journal of Process Control*, *76*, 122-132. doi:10.1016/j.jprocont.2019.01.013
- Mia, M., Morshed, M. S., Kharshiduzzaman, M., Razi, M. H., Mostafa, M. R., Rahman, S. M. S., . . . Kamal, A. M. (2018). Prediction and optimization of surface roughness in minimum quantity coolant lubrication applied turning of high hardness steel. *Measurement*, *118*, 43-51. doi:10.1016/j.measurement.2018.01.012

- Moawad, N. M., Elawady, W. M., & Sarhan, A. M. (2019). Development of an adaptive radial basis function neural network estimator-based continuous sliding mode control for uncertain nonlinear systems. *ISA Transactions*, *87*, 200-216. doi:10.1016/j.isatra.2018.11.021
- Mohanraj, T., Shankar, S., Rajasekar, R., Sakthivel, N. R., & Pramanik, A. (2020). Tool condition monitoring techniques in milling process — a review. *Journal of Materials Research and Technology*, *9*(1), 1032-1042. doi:10.1016/j.jmrt.2019.10.031
- Moreno-Cabezali, B. M., & Fernandez-Crehuet, J. M. (2020). Application of a fuzzy-logic based model for risk assessment in additive manufacturing R&D projects. *Computers & Industrial Engineering*, *145*, 106529. doi:10.1016/j.cie.2020.106529
- Mundada, V., & Kumar Reddy Narala, S. (2018). Optimization of Milling Operations Using Artificial Neural Networks (ANN) and Simulated Annealing Algorithm (SAA). *Materials Today: Proceedings*, *5*(2, Part 1), 4971-4985. doi:10.1016/j.matpr.2017.12.075
- Nguyen, V., & Dugenske, A. (2018). An I2C based architecture for monitoring legacy manufacturing equipment. *Manufacturing Letters*, *15*, 67-70. doi:10.1016/j.mfglet.2017.12.018
- Nhat, D. M., Venkatesan, R., & Khan, F. (2020). Data-driven Bayesian network model for early kick detection in industrial drilling process. *Process Safety and Environmental Protection*, *138*, 130-138. doi:10.1016/j.psep.2020.03.017
- Nian, R., Liu, J., & Huang, B. (2020). A review On reinforcement learning: Introduction and applications in industrial process control. *Computers & Chemical Engineering*, *139*, 106886. doi:10.1016/j.compchemeng.2020.106886
- Ning, Q., Wang, T., Liu, L., & Jiang, Y. (2012). Research on CNC Machine Tools Integration Condition Monitoring System and Its Information Exchange Technology. In Y. Zhang (Ed.), *Future Wireless Networks and Information Systems: Volume 2* (pp. 441-450). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Noël, J. P., & Kerschen, G. (2017). Nonlinear system identification in structural dynamics: 10 more years of progress. *Mechanical Systems and Signal Processing*, *83*, 2-35. doi:10.1016/j.ymsp.2016.07.020
- O'Donovan, P., Gallagher, C., Leahy, K., & O'Sullivan, D. T. J. (2019). A comparison of fog and cloud computing cyber-physical interfaces for Industry 4.0 real-time embedded machine learning engineering applications. *Computers in Industry*, *110*, 12-35. doi:10.1016/j.compind.2019.04.016
- Okaro, I. A., Jayasinghe, S., Sutcliffe, C., Black, K., Paoletti, P., & Green, P. L. (2019). Automatic fault detection for laser powder-bed fusion using semi-supervised

- machine learning. *Additive Manufacturing*, 27, 42-53. doi:10.1016/j.addma.2019.01.006
- Oliveira, R. S., Guilherme, R. F., & Cabral, L. C. (2012). Influence of operational parameters on a hand-operated torque standard machine. *Measurement*, 45(10), 2413-2418. doi:10.1016/j.measurement.2011.09.028
- Pan, Y., Hong, R., Chen, J., Qin, Z., & Feng, Y. (2019). Incipient fault detection of wind turbine large-size slewing bearing based on circular domain. *Measurement*, 137, 130-142. doi:10.1016/j.measurement.2019.01.033
- Papandrea, P. J., Frigieri, E. P., Maia, P. R., Oliveira, L. G., & Paiva, A. P. (2020). Surface roughness diagnosis in hard turning using acoustic signals and support vector machine: A PCA-based approach. *Applied Acoustics*, 159, 107102. doi:10.1016/j.apacoust.2019.107102
- Paraschos, P. D., Koulinas, G. K., & Koulouriotis, D. E. (2020). Reinforcement learning for combined production-maintenance and quality control of a manufacturing system with deterioration failures. *Journal of Manufacturing Systems*, 56, 470-483. doi:10.1016/j.jmsy.2020.07.004
- Peeters, C., Antoni, J., & Helsen, J. (2020). Blind filters based on envelope spectrum sparsity indicators for bearing and gear vibration-based condition monitoring. *Mechanical Systems and Signal Processing*, 138, 106556. doi:10.1016/j.ymssp.2019.106556
- Prasad, B. S., Prabha, K. A., & Kumar, P. V. S. G. (2017). Condition monitoring of turning process using infrared thermography technique – An experimental approach. *Infrared Physics & Technology*, 81, 137-147. doi:10.1016/j.infrared.2016.12.023
- Qi, Q., & Tao, F. (2019). A Smart Manufacturing Service System Based on Edge Computing, Fog Computing, and Cloud Computing. *IEEE Access*, 7, 86769-86777. doi:10.1109/ACCESS.2019.2923610
- Qian, P., Zhang, D., Tian, X., Si, Y., & Li, L. (2019). A novel wind turbine condition monitoring method based on cloud computing. *Renewable Energy*, 135, 390-398. doi:10.1016/j.renene.2018.12.045
- Qiu, H., Lee, J., Lin, J., & Yu, G. (2006). Wavelet filter-based weak signature detection method and its application on rolling element bearing prognostics. *Journal of Sound and Vibration*, 289(4-5), 1066-1090. doi:10.1016/j.jsv.2005.03.007
- Ramana, M. V., & Aditya, Y. S. (2017). Optimization and influence of process parameters on surface roughness in turning of titanium alloy. *Materials Today: Proceedings*, 4(2, Part A), 1843-1851. doi:10.1016/j.matpr.2017.02.028
- Ramírez Mendoza, M., Brook Kindelán, M., & Estrada Pérez, K. (2019). Breve historia de la automática en Cuba. Paper presented at the *II Convención Científica*

Internacional de la Universidad Central “Marta Abreu” de Las Villas, Santa Clara (Cuba).

- Rodríguez-Ramos, A., da Silva Neto, A. J., & Llanes-Santiago, O. (2018). An approach to fault diagnosis with online detection of novel faults using fuzzy clustering tools. *Expert Systems with Applications, 113*, 200-212. doi:10.1016/j.eswa.2018.06.055
- Schuh, G., Prote, J.-P., Luckert, M., & Hünnekes, P. (2017). Knowledge Discovery Approach for Automated Process Planning. *Procedia CIRP, 63*, 539-544. doi:10.1016/j.procir.2017.03.092
- Seid Ahmed, Y., Arif, A. F. M., & Veldhuis, S. C. (2020). Application of the wavelet transform to acoustic emission signals for built-up edge monitoring in stainless steel machining. *Measurement, 154*, 107478. doi:10.1016/j.measurement.2020.107478
- Shankar, S., Mohanraj, T., & Rajasekar, R. (2019). Prediction of cutting tool wear during milling process using artificial intelligence techniques. *International Journal of Computer Integrated Manufacturing, 32*(2), 174-182. doi:10.1080/0951192X.2018.1550681
- Sharma, S., Tiwari, S. K., & Singh, S. (2019). Diagnosis of gear tooth fault in a bevel gearbox using discrete wavelet transform and autoregressive modeling. *Life Cycle Reliability and Safety Engineering, 8*(1), 21-32. doi:10.1007/s41872-018-0061-9
- Shen, B., Zhao, S., Wang, J., & Fleischer, J. (2015). An Improved Case-based Reasoning for Fault Diagnosis of CNC Machine Tool. *Journal of Information and Computational Science, 12*(8), 2939-2949. doi:10.12733/jics20105987
- Shin, K., Shin, N., Choi, S., & Choi, S. (2016, 16-19 Oct. 2016). *Systems engineering approach to designing smart condition monitoring systems for smart manufacturing (ICCAS 2016)*. Paper presented at the 2016 16th International Conference on Control, Automation and Systems (ICCAS).
- Sick, B. (2002). On-line and indirect tool wear monitoring in turning with artificial neural networks: a review of more than a decade of research. *Mechanical Systems and Signal Processing, 16*(4), 487-546. doi:10.1006/mssp.2001.1460
- Strain, J. (2018). Fast Fourier transforms of piecewise polynomials. *Journal of Computational Physics, 373*, 346-369. doi:10.1016/j.jcp.2018.06.076
- Strantza, M., Van Hemelrijck, D., Guillaume, P., & Aggelis, D. G. (2017). Acoustic emission monitoring of crack propagation in additively manufactured and conventional titanium components. *Mechanics Research Communications, 84*, 8-13. doi:10.1016/j.mechrescom.2017.05.009

- Strömbergsson, D., Marklund, P., Edin, E., & Zeman, F. (2017). Acoustic emission monitoring of a mechanochemical surface finishing process. *Tribology International*, *112*, 129-136. doi:10.1016/j.triboint.2017.03.031
- Susai Mary, J., Sai Balaji, M. A., Krishnakumari, A., Nakandhrakumar, R. S., & Dinakaran, D. (2019). Monitoring of drill runout using Least Square Support Vector Machine classifier. *Measurement*, *146*, 24-34. doi:10.1016/j.measurement.2019.05.102
- Swain, S., Panigrahi, I., Sahoo, A. K., & Panda, A. (2020). Adaptive tool condition monitoring system: A brief review. *Materials Today: Proceedings*, *23*, 474-478. doi:10.1016/j.matpr.2019.05.386
- Tang, J., Soua, S., Mares, C., & Gan, T.-H. (2016). An experimental study of acoustic emission methodology for in service condition monitoring of wind turbine blades. *Renewable Energy*, *99*, 170-179. doi:10.1016/j.renene.2016.06.048
- Thankachan, T., Soorya Prakash, K., Malini, R., Ramu, S., Sundararaj, P., Rajandran, S., . . . Jothi, S. (2019). Prediction of surface roughness and material removal rate in wire electrical discharge machining on aluminum based alloys/composites using Taguchi coupled Grey Relational Analysis and Artificial Neural Networks. *Applied Surface Science*, *472*, 22-35. doi:10.1016/j.apsusc.2018.06.117
- Uekita, M., & Takaya, Y. (2017a). Tool condition monitoring for form milling of large parts by combining spindle motor current and acoustic emission signals. *The International Journal of Advanced Manufacturing Technology*, *89*(1), 65-75. doi:10.1007/s00170-016-9082-6
- Uekita, M., & Takaya, Y. (2017b). Tool condition monitoring technique for deep-hole drilling of large components based on chatter identification in time–frequency domain. *Measurement*, *103*, 199-207. doi:10.1016/j.measurement.2017.02.035
- Van Hecke, B., Yoon, J., & He, D. (2016). Low speed bearing fault diagnosis using acoustic emission sensors. *Applied Acoustics*, *105*, 35-44. doi:10.1016/j.apacoust.2015.10.028
- Vázquez-Canteli, J. R., & Nagy, Z. (2019). Reinforcement learning for demand response: A review of algorithms and modeling techniques. *Applied Energy*, *235*, 1072-1089. doi:10.1016/j.apenergy.2018.11.002
- Villalonga, A., Beruvides, G., Castaño, F., & Haber, R. (2018, 15-18 May 2018). *Industrial cyber-physical system for condition-based monitoring in manufacturing processes*. Paper presented at the 2018 IEEE Industrial Cyber-Physical Systems (ICPS).
- Villalonga, A., Beruvides, G., Castaño, F., & Haber, R. E. (2020). Cloud-Based Industrial Cyber–Physical System for Data-Driven Reasoning: A Review and Use Case on an Industry 4.0 Pilot Line. *IEEE Transactions on Industrial Informatics*, *16*(9), 5975-5984. doi:10.1109/TII.2020.2971057

- Villalonga, A., Beruvides, G., Castaño, F., Haber, R. E., & Novo, M. (2018). Condition-based Monitoring Architecture for CNC Machine Tools based on Global Knowledge. *IFAC-PapersOnLine*, 51(11), 200-204. doi:10.1016/j.ifacol.2018.08.259
- Villalonga, A., Negri, E., Fumagalli, L., Macche, M., Castaño, F., & Haber, R. E. (2020). *Local Decision Making based on Distributed Digital Twin Framework*. Paper presented at the IFAC World Congress Berlin, Alemania.
- Wakiru, J., Pintelon, L., Chemweno, P., & Muchiri, P. N. (2018). A decision tree-based classification framework for used oil analysis applying random forest feature selection. *J. Appl. Sci. Eng. Technol. Dev.*, 3, 90-100.
- Walsh, J., Bashir, I., Garrett, J. K., Thies, P. R., Blondel, P., & Johanning, L. (2017). Monitoring the condition of Marine Renewable Energy Devices through underwater Acoustic Emissions: Case study of a Wave Energy Converter in Falmouth Bay, UK. *Renewable Energy*, 102, 205-213. doi:10.1016/j.renene.2016.10.049
- Wang, C., Bao, Z., Zhang, P., Ming, W., & Chen, M. (2019). Tool wear evaluation under minimum quantity lubrication by clustering energy of acoustic emission burst signals. *Measurement*, 138, 256-265. doi:10.1016/j.measurement.2019.02.004
- Wang, L., & Gao, R. X. (2006). *Condition Monitoring and Control for Intelligent Manufacturing*. Springer London: Springer-Verlag London Limited.
- Wang, X., Guan, S., Hua, L., Wang, B., & He, X. (2019). Classification of spot-welded joint strength using ultrasonic signal time-frequency features and PSO-SVM method. *Ultrasonics*, 91, 161-169. doi:10.1016/j.ultras.2018.08.014
- Wen, L., Li, X., Gao, L., & Yi, W. (2016). Surface roughness prediction in end milling by using predicted point oriented local linear estimation method. *The International Journal of Advanced Manufacturing Technology*, 84(9), 2523-2535. doi:10.1007/s00170-015-7884-6
- Xiao, M., Shen, X., Ma, Y., Yang, F., Gao, N., Wei, W., & Wu, D. (2018). Prediction of Surface Roughness and Optimization of Cutting Parameters of Stainless Steel Turning Based on RSM. *Mathematical Problems in Engineering*, 2018, 15. doi:10.1155/2018/9051084
- Xing, K., Achiche, S., & Mayer, J. R. R. (2019). Five-axis machine tools accuracy condition monitoring based on volumetric errors and vector similarity measures. *International Journal of Machine Tools and Manufacture*, 138, 80-93. doi:10.1016/j.ijmachtools.2018.12.002
- Xu, G., Zhou, H., & Chen, J. (2018). CNC internal data based incremental cost-sensitive support vector machine method for tool breakage monitoring in end milling.

- Engineering Applications of Artificial Intelligence*, 74, 90-103. doi:10.1016/j.engappai.2018.05.007
- Yan, Z., Chen, J., & Zhang, Z. (2017). Using hidden Markov model to identify oscillation temporal pattern for control loops. *Chemical Engineering Research and Design*, 119, 117-129. doi:10.1016/j.cherd.2017.01.011
- Zhang, K., Cheng, G., & Zhang, W. (2020). Evaluation of roundness error uncertainty by a Bayesian dynamic model. *Measurement*, 155, 107565. doi:10.1016/j.measurement.2020.107565
- Zhang, Y., Pan, G., Chen, B., Han, J., Zhao, Y., & Zhang, C. (2020). Short-term wind speed prediction model based on GA-ANN improved by VMD. *Renewable Energy*, 156, 1373-1388. doi:10.1016/j.renene.2019.12.047
- Zhang, Z., Hu, Q., & He, Z. (2005). Fuzzy Support Vector Machine and Its Application to Mechanical Condition Monitoring. In J. Wang, X. Liao, & Z. Yi (Eds.), *Advances in Neural Networks – ISNN 2005: Second International Symposium on Neural Networks, Chongqing, China, May 30 - June 1, 2005, Proceedings, Part I* (pp. 937-942). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Zheng, W., Dan, D., Cheng, W., & Xia, Y. (2019). Real-time dynamic displacement monitoring with double integration of acceleration based on recursive least squares method. *Measurement*, 141, 460-471. doi:10.1016/j.measurement.2019.04.053
- Zhong, J., Zhong, S., Zhang, Q., Liu, S., Peng, Z., & Maia, N. (2019). Real-time three-dimensional vibration monitoring of rotating shafts using constant-density sinusoidal fringe pattern as tri-axial sensor. *Mechanical Systems and Signal Processing*, 115, 132-146. doi:10.1016/j.ymsp.2018.05.049
- Zhu, K., & Zhang, Y. (2019). A generic tool wear model and its application to force modeling and wear monitoring in high speed milling. *Mechanical Systems and Signal Processing*, 115, 147-161. doi:10.1016/j.ymsp.2018.05.045

ANEXOS

Anexo 1 Ingeniería de software aplicaciones servidor y nodo local

Tabla A1.1 Funciones relacionadas con la comunicación.

Ref.	Característica	Riesgo	Prioridad	Categoría
R1.1	Establecer conexión desde Nodos locales y servidor	Crítico	Crítico	Evidente
R1.2	Garantizar una comunicación estable con el servidor.	Crítico	Crítico	Evidente
R1.3	Sincronización entre los dispositivos de la red.	Crítico	Secundario	Evidente
R1.4	Interrumpir la conexión por parte de los nodos locales	Crítico	Crítico	Evidente

Tabla A1.2 Funciones relacionadas con la supervisión.

Ref.	Característica	Riesgo	Prioridad	Categoría
R2.1	Adquirir variables de los dispositivo de la red.	Ordinario	Importante	Evidente
R2.2	Obtener el estado de los procesos conectados a los nodos locales	Ordinario	Importante	Evidente
R2.3	Adquirir las variables de los elementos del campo.	Crítico	Importante	Evidente
R2.4	Determinar el estado de los procesos conectados a los nodos locales	Crítico	Importante	Evidente

Tabla A1.3 Funciones relacionadas con el control.

Ref.	Característica	Riesgo	Prioridad	Categoría
R3.1	Parametrizar los Nodos locales	Crítico	Critico	Evidente
R3.2	Extracción de conocimiento de la información obtenida del campo.	Crítico	Critico	Evidente

Tabla A1.4 Funciones asociadas con la actualización de las bases de datos.

Ref.	Característica	Riesgo	Prioridad	Categoría
R4.1	Mantener actualizado el estado de cada dispositivo de la red en la bases de datos.	Crítico	Importante	Evidente
R4.2	Registro de eventos y alarmas en las bases de datos.	Crítico	Importante	Evidente
R4.3	Registrar los valores de las variables adquiridas del campo en la bases de datos local.	Crítico	Importante	Evidente




Figura A.1.1 Casos de uso actor tiempo



Figura A.1.2 Casos de uso actor tiempo

Casos de uso Aplicación Nodo local

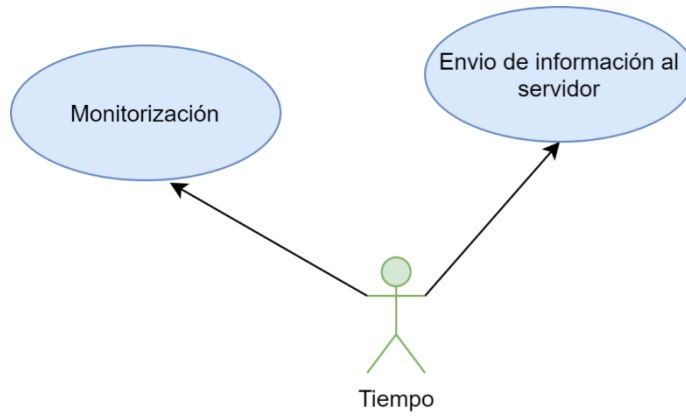


Figura A.1.3 Casos de uso actor tiempo

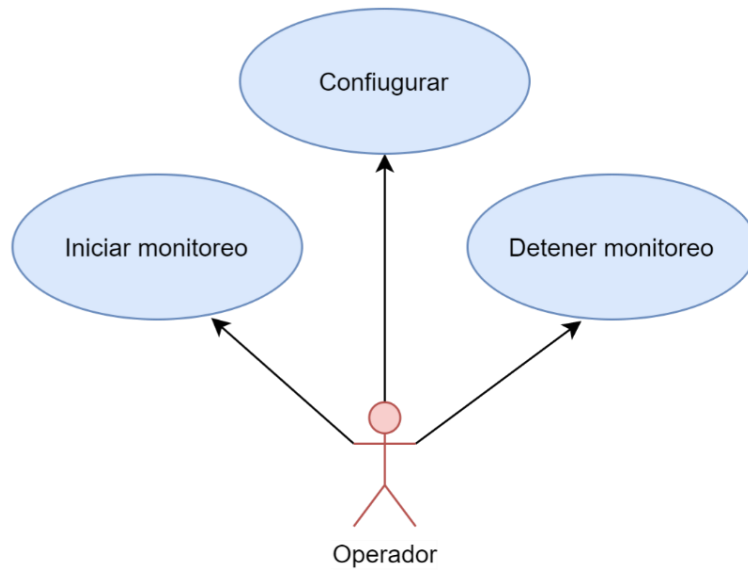


Figura A.1.4 Casos de uso actor operador




Figura A.1.5 Casos de uso actor servidor

Casos de uso Aplicación Servidor

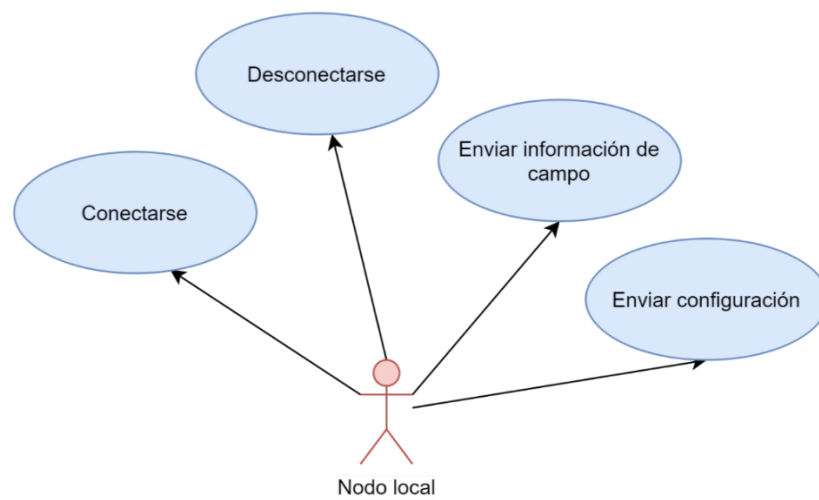


Figura A.1.6 Casos de uso actor nodo local

Tabla A.1.5 Descripción casos de uso aplicación Nodo local

Caso de uso:	Monitoreo
Actores:	Tiempo
Propósito:	Leer los valores de las variables del proceso para realizar la monitoreo.

Tipo:	Alto Nivel
Resumen	Obtener las variables del proceso según el tiempo de muestreo que tiene definida cada una para realizar la monitoreo de estados del proceso.
Referencias Cruzadas:	Funciones: R2.3, R2.4, R4.2
Caso de uso:	Envío de información al servidor
Actores:	Tiempo
Propósito:	Enviar información actualizada del proceso al servidor
Resumen:	Enviar cada un intervalo de tiempo definido la información del proceso contenida en la base de datos local.
Tipo:	Alto Nivel
Referencias Cruzadas:	Funciones: R4.2 y R4.3
Caso de uso:	Iniciar monitoreo
Actores:	Operador
Propósito:	Inicializar el proceso de monitoreo
Resumen:	El operador indica al sistema que debe comenzar el proceso de monitoreo
Tipo:	Alto Nivel
Referencias Cruzadas:	Función: R2.3, R2.4, R4.2
Caso de uso:	Detener monitoreo
Actores:	Operador
Propósito:	Detener el proceso de monitoreo

Resumen	Realizar la detención del proceso de monitoreo debido a actividades de mantenimiento o actualizaciones del sistema.
Tipo:	Alto Nivel
Referencias Cruzadas:	Funciones: R2.3, R2.4, R4.2
Caso de uso:	Configurar
Actores:	Operador
Propósito:	Configurar los parámetros del sistema referentes a las características del proceso
Resumen	Modificar el archivo de configuración que contiene la información referente a las características del proceso como son: variables a monitorizar, protocolo de captura de datos, tiempo de muestreo, etc.
Tipo:	Alto Nivel
Referencias Cruzadas:	Funciones: R2.3, R2.4, R4.2
Caso de uso:	Actualizar configuración
Actores:	Servidor
Propósito:	Mantener la mejor configuración para realizar un monitoreo eficiente y preciso.
Resumen:	Actualizar los parámetros del sistema de monitoreo como son: herramientas de procesamiento de señales, modelo predictivo y toma de decisiones, para realizar un monitoreo eficiente y preciso
Tipo:	Alto Nivel

Referencias	Funciones: R3.2
Cruzadas:	

Tabla A.1.6 Descripción casos de uso aplicación Servidor

Caso de uso:	Conectarse
Actores:	Nodo local
Propósito:	Conectar un nodo local
Resumen:	Se realiza la conexión de un nodo local
Tipo:	Alto Nivel
Referencias	Funciones: R1.1, R1.2 y R1.3
Cruzadas:	
Caso de uso:	Desconectarse
Actores:	Nodo local
Propósito:	Notificar la desconexión del sistema
Tipo:	Alto Nivel
Referencias	Funciones: R1.14.
Cruzadas:	
Caso de uso:	Enviar información de campo
Actores:	Nodo local
Propósito:	Envío de información actualizada del campo.
Resumen	Envío de información actualizada del campo para guardarla en el almacén de datos y realizarle el proceso de aprendizaje.
Tipo:	Nivel Alto

Referencias Cruzadas:	Función: R3.1
Caso de uso:	Enviar configuración
Actores:	Nodo local
Propósito:	Enviar la configuración actualizada de sus componentes
Resumen	Enviar la configuración actualizada de los componentes de los nodos locales ante una conexión inicial o cambios de parámetros de los mismos.
Tipo:	Nivel Alto
Referencias Cruzadas:	Función: R3.2

Tabla A.1.7 Casos de uso Ciclo 1

Casos de Uso		Aplicación
1	Iniciar Monitoreo	Nodo local
2	Detener Monitoreo	Nodo local
3	Monitoreo	Nodo local

Tabla A.1.8 Casos de uso Ciclo 2

Casos de Uso		Aplicación
1	Configurar	Nodo local
2	Conectarse	Servidor
3	Desconectarse	Servidor
4	Enviar configuración	Servidor

Tabla A.1.9 Casos de uso Ciclo 3

Casos de Uso		Aplicación
1	Enviar información de campo	Servidor
2	Enviar información al servidor	Nodo local
3	Actualizar configuración	Nodo local

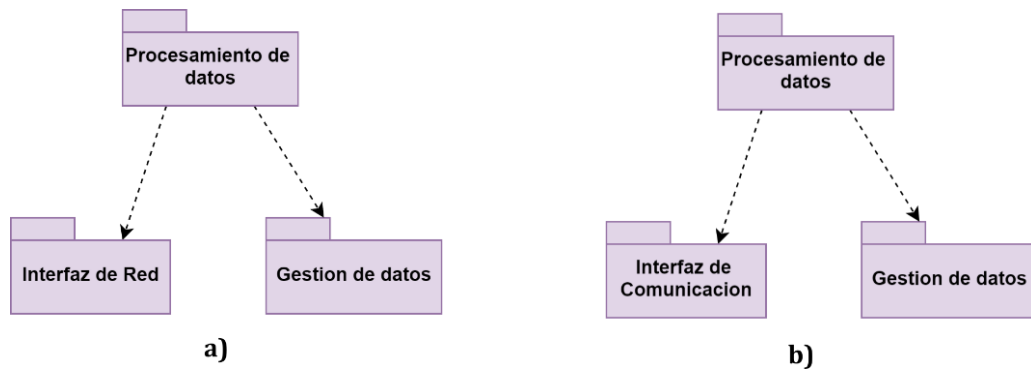


Figura A.1.7 Arquitectura de software. a) Servidor b) Nodo local

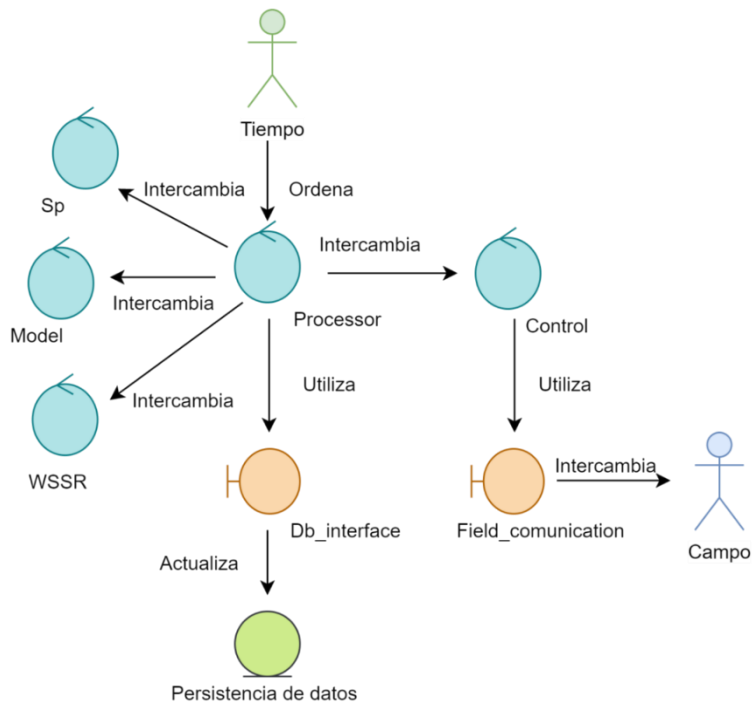


Figura A.1.8 Diagrama de clases caso de uso monitoreo

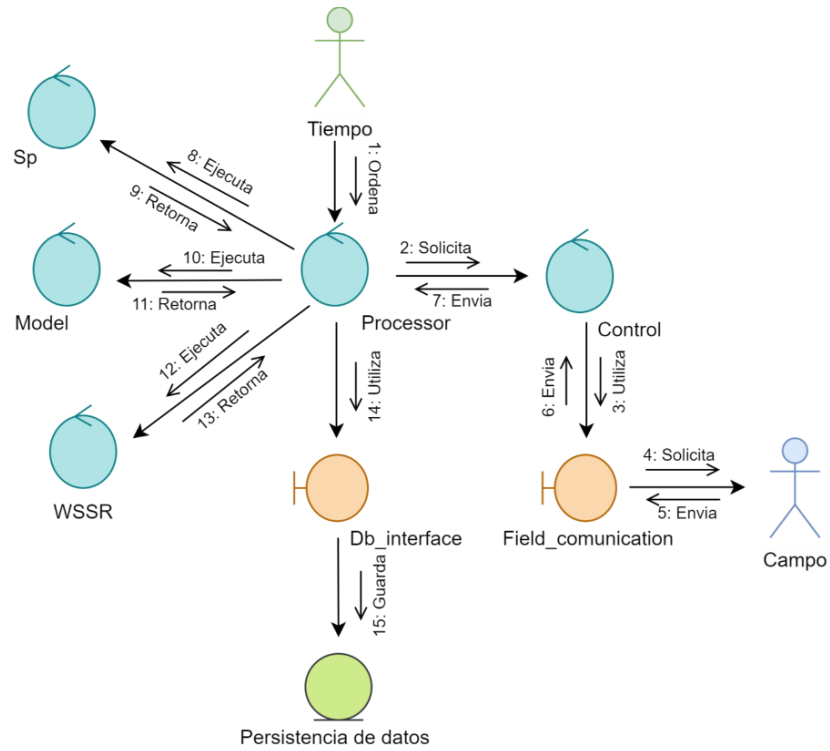


Figura A.1.9 Diagrama de colaboración caso de uso monitoreo.

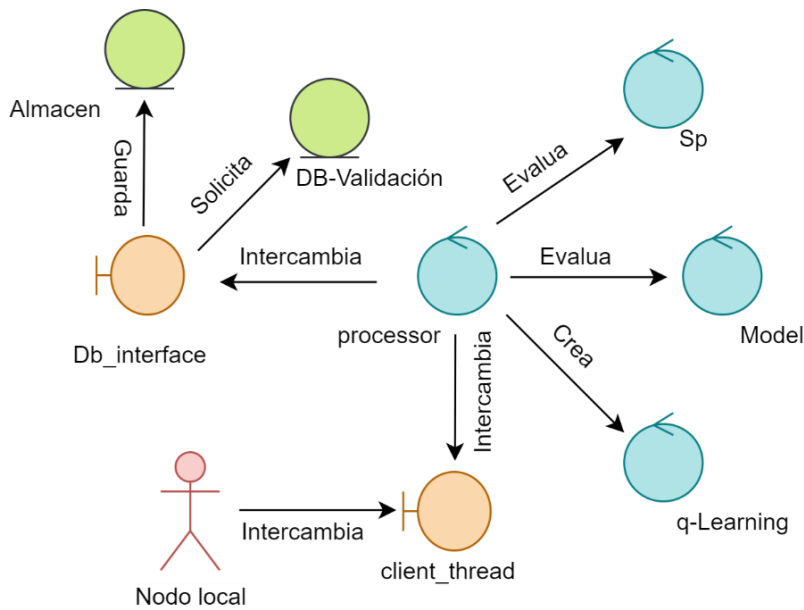


Figura A.1.10 Diagrama de clases caso de uso enviar configuración

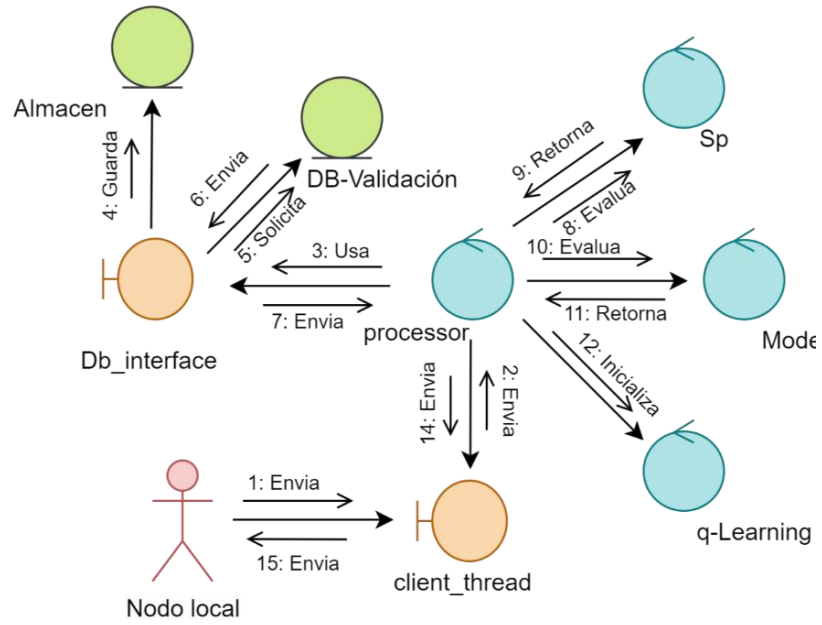


Figura A.1.11 Diagrama de colaboración caso de uso enviar configuración

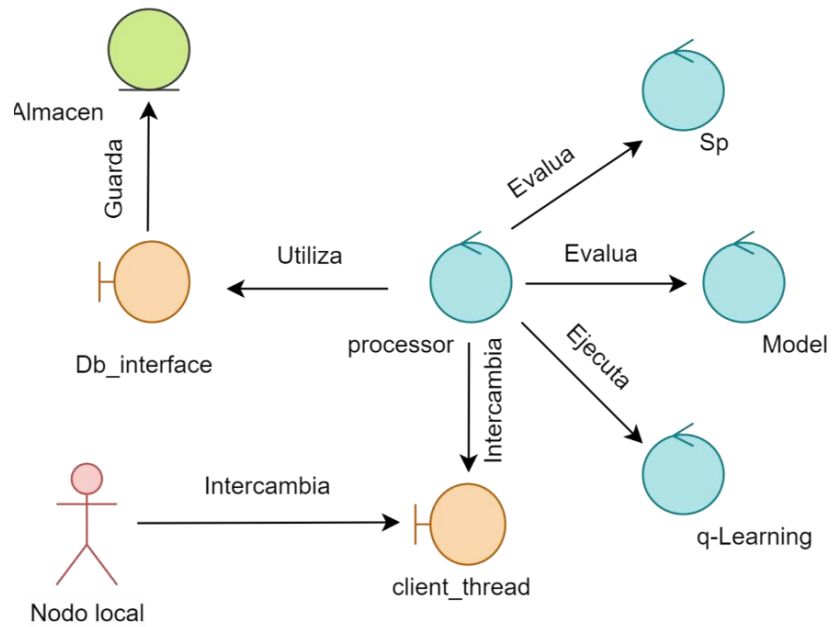


Figura A.1.12 Diagrama de clases caso de uso enviar información de campo

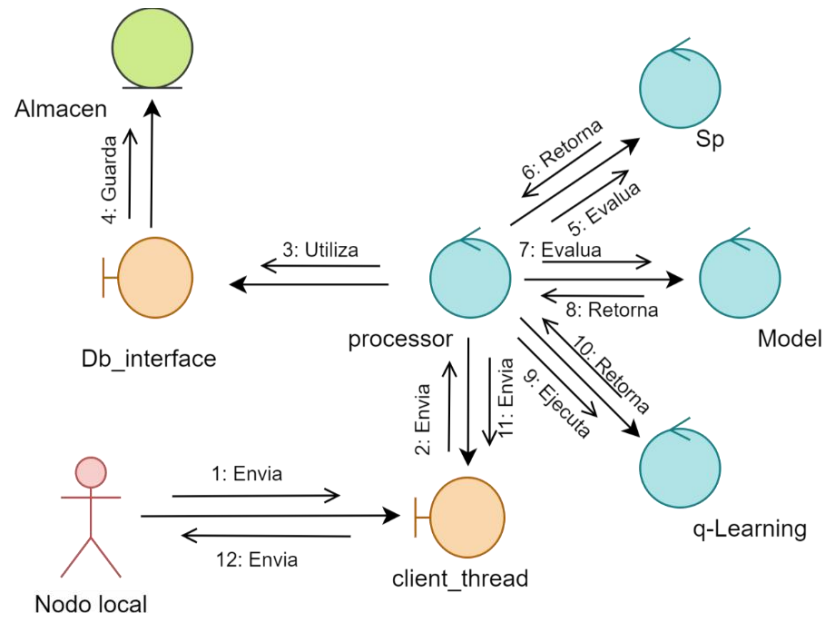


Figura A.1.13 Diagrama de colaboración caso de uso enviar información de campo

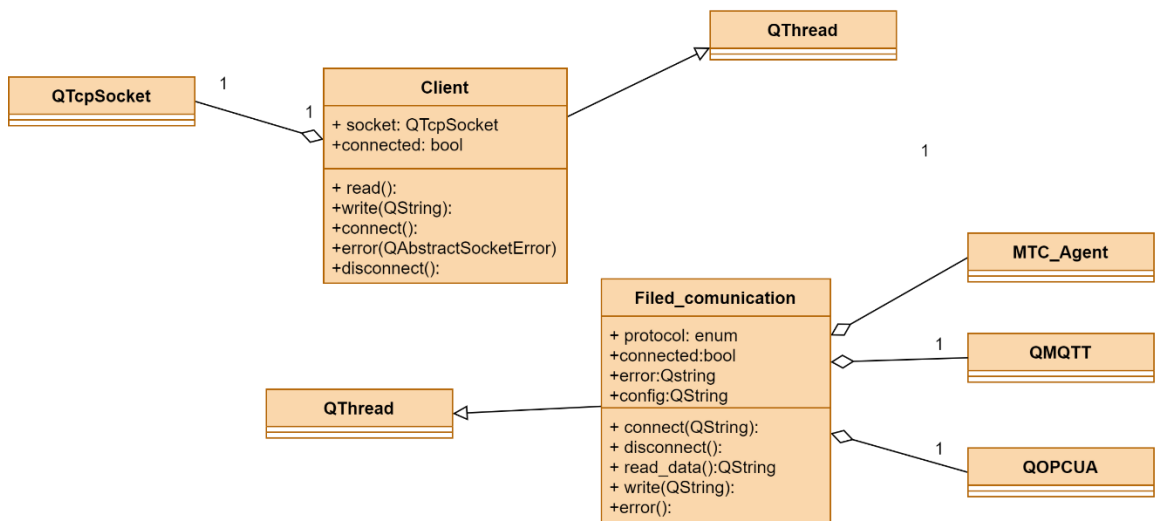


Figura A.1.14 Diagrama de clases de diseño asociado al subsistema interfaz de red aplicación nodo local

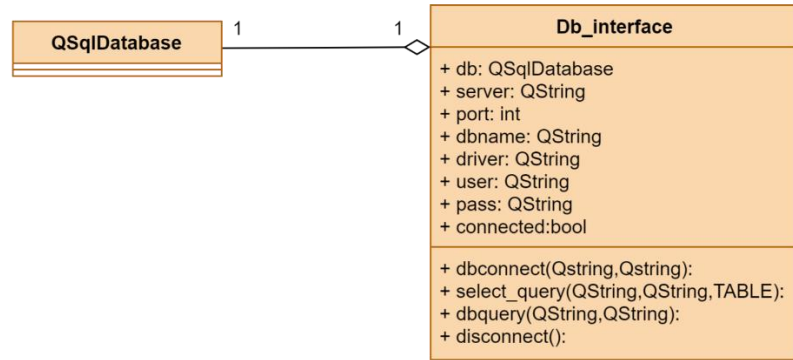


Figura A.1.15 Diagrama de clases de diseño asociado al subsistema gestión de datos aplicación nodo local.

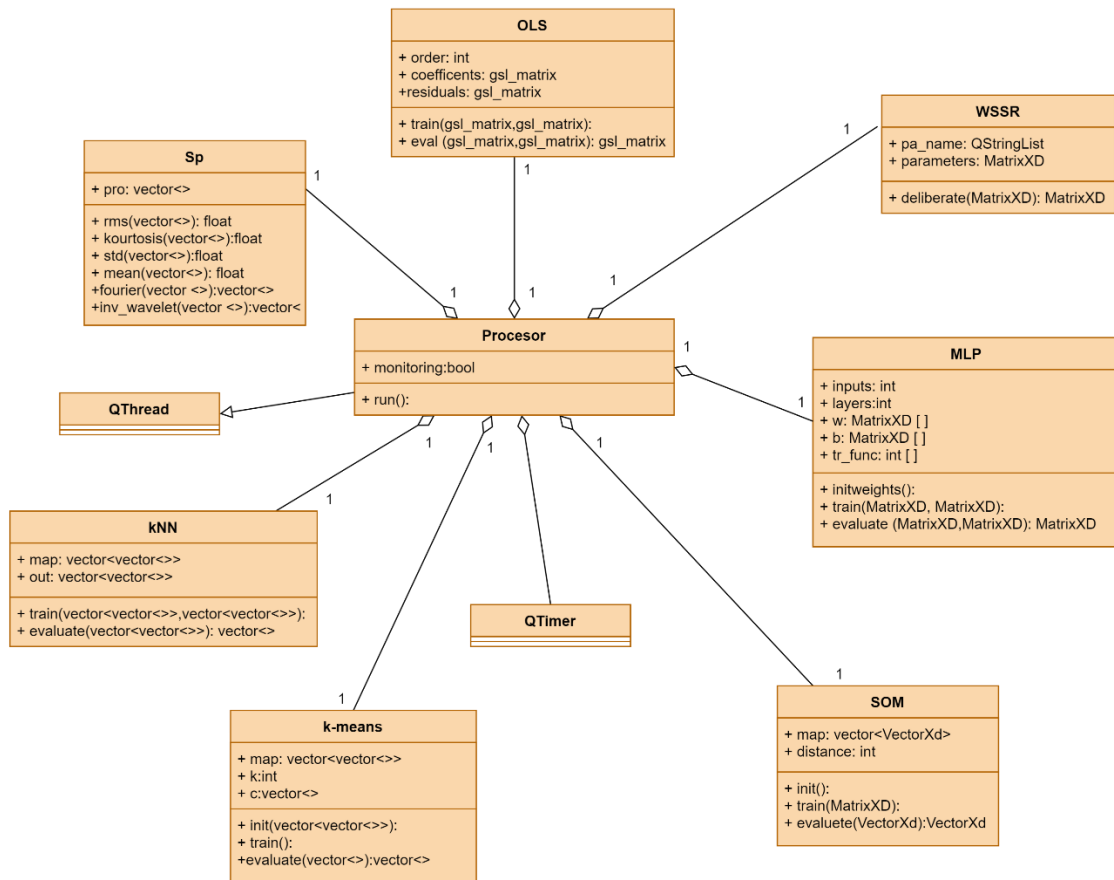


Figura A.1.16 Diagrama de clases de diseño asociado al subsistema procesamiento de datos aplicación nodo local.

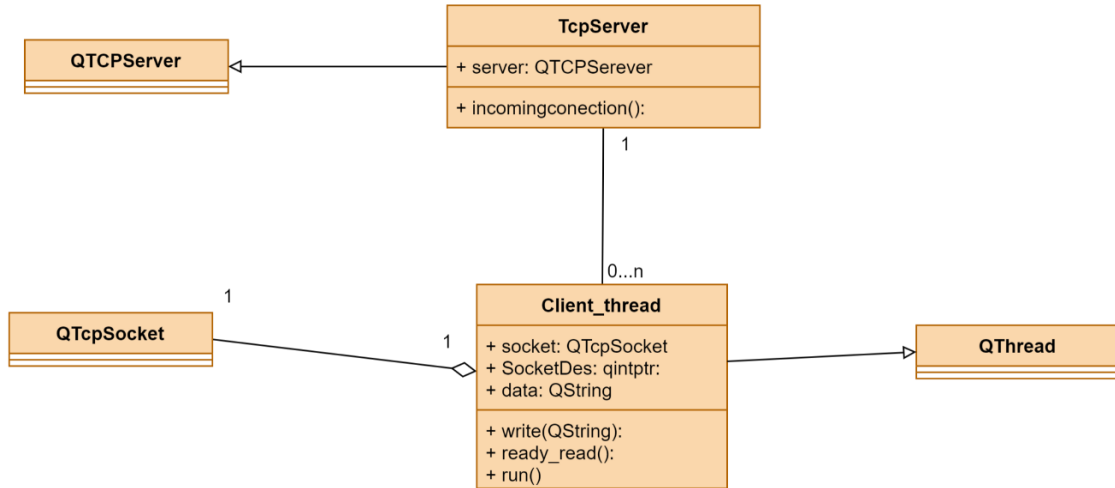


Figura A.1.17 Diagrama de clases de diseño asociado al interfaz de red servidor.

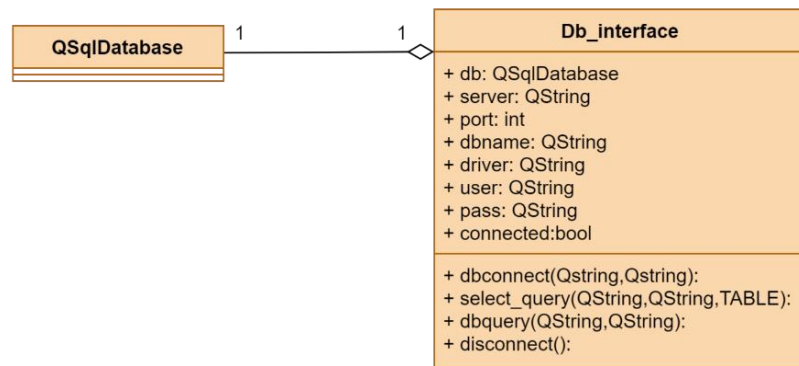


Figura A.1.18 Diagrama de clases de diseño asociado al subsistema gestión de datos aplicación servidor.

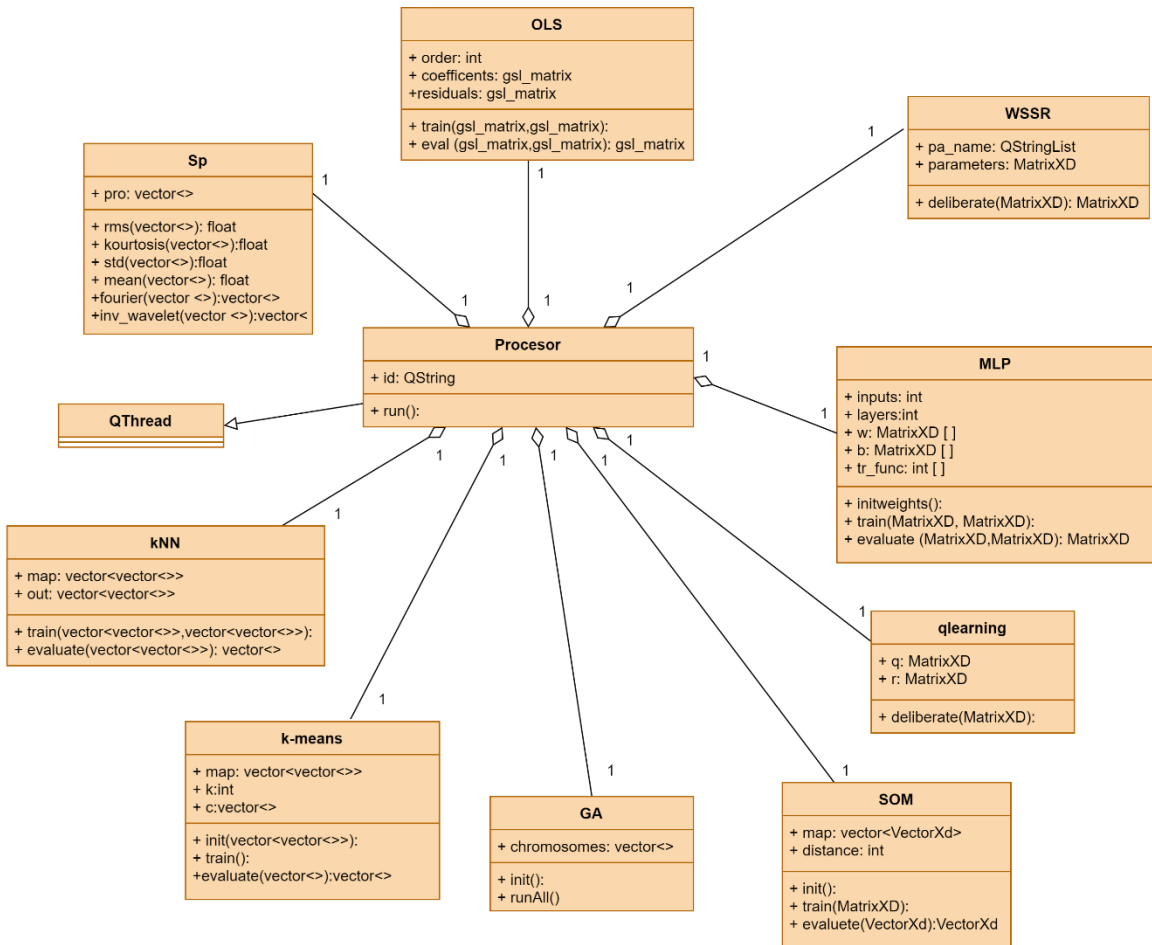


Figura A.1.19 Diagrama de clases de diseño asociado al subsistema procesamiento de datos aplicación nodo local.

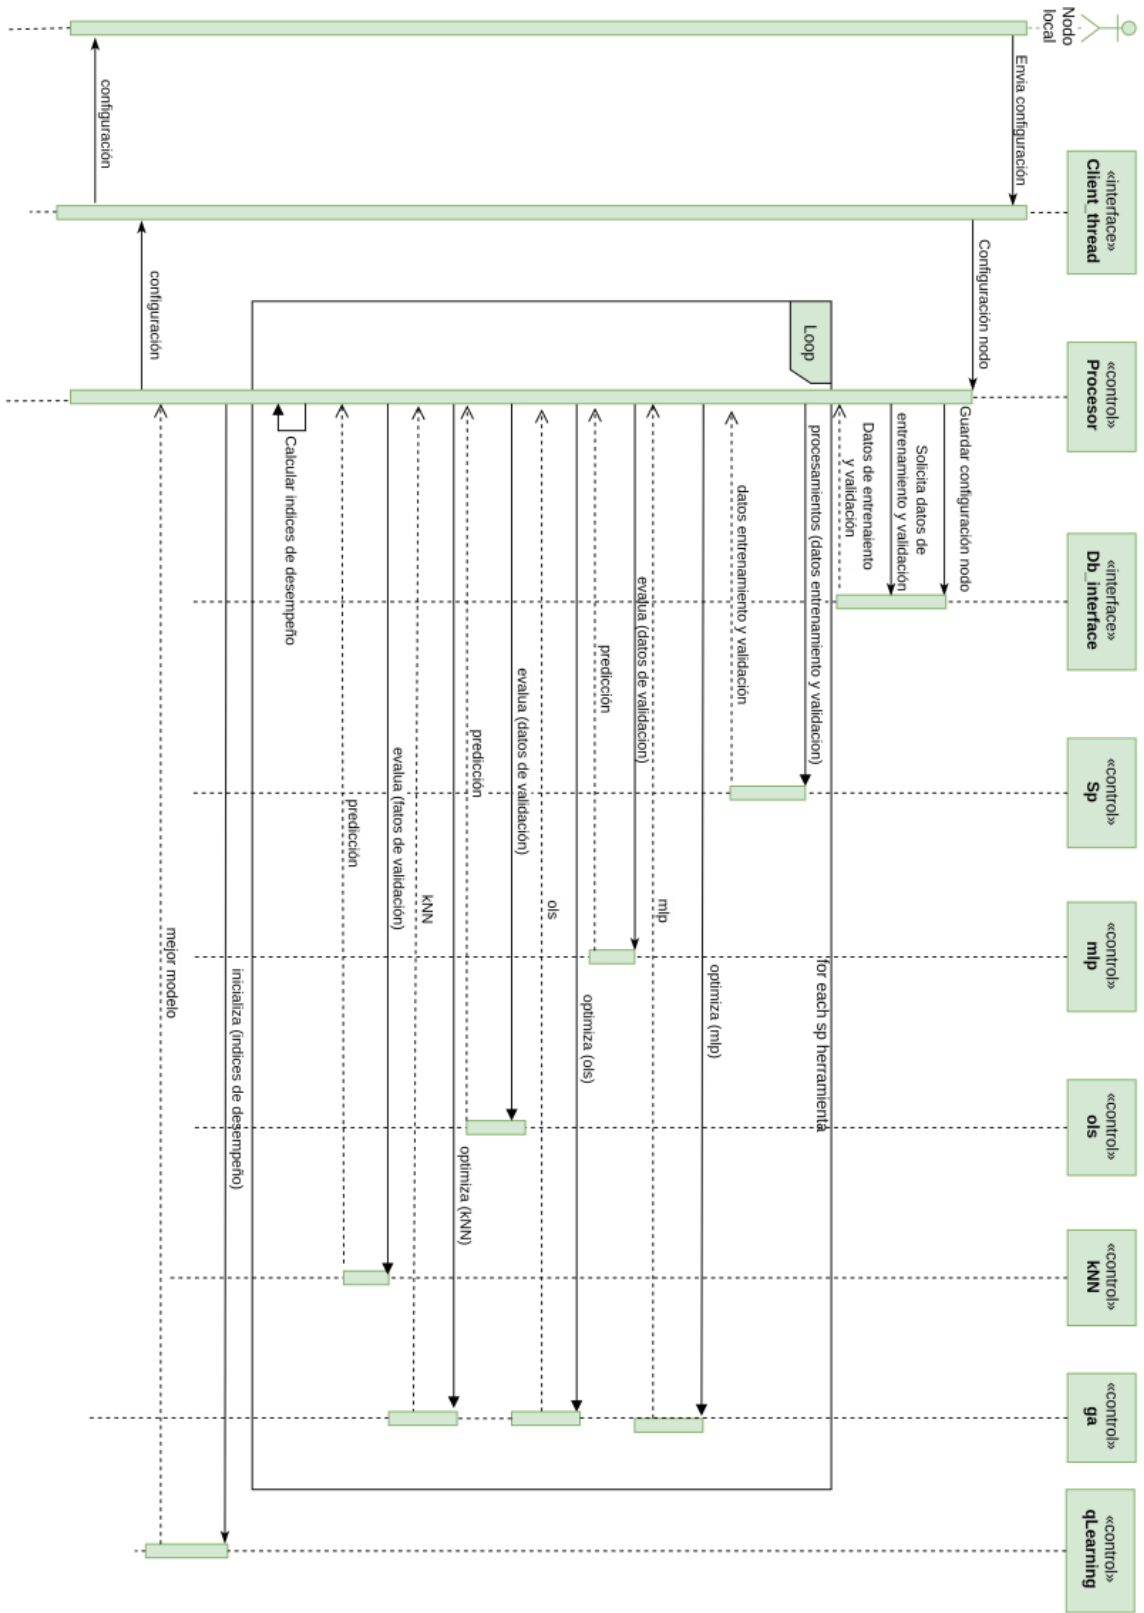


Figura A.1.20 Diagrama de secuencia caso de uso enviar configuración.

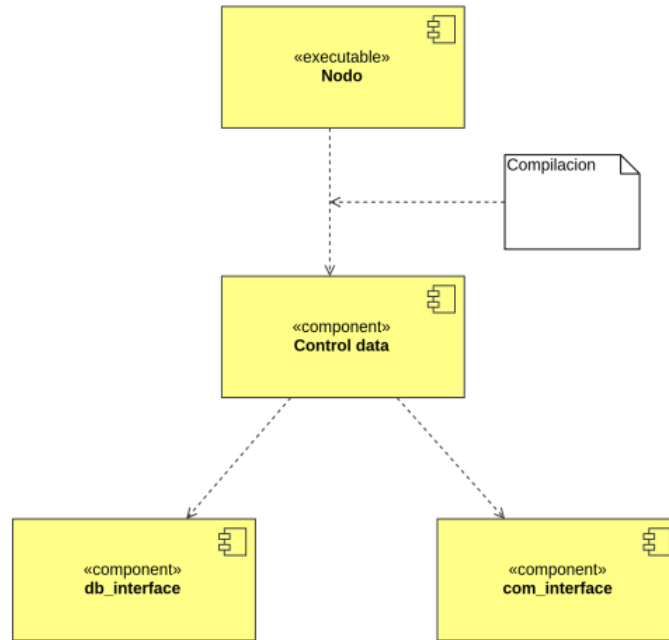


Figura A.1.22 Diagrama entidad relación almacén de datos.




Figura A.1.23 Diagrama entidad relación almacén de datos.

Anexo 2 Características técnicas rodamientos Rex ZA2115 2000.

Base to Centerline Height	2 1/4 in
Distance Between Bolt Holes	6 1/4 in
Mounting Pad Length	8 3/8 in
Length Through Bore	3 1/8 in
Mounting Pad Width	2 1/2 in
Mounting Bolt Size	5/8 in
Mounting Pad Height	1 3/8 in
Overall Housing Height	4 9/16 in
Locking Collar Outside Diameter	2 7/8 in
Inner Ring Hub Diameter	2 5/16 in
Distance from Housing Cast Face to Locking Feature Face	11/16 in
Mounting Bolt Hole Slot Length	1 in
Basic Dynamic Load Rating	28890 lbf
Basic Static Load Rating	33200 lbf
Grease Fitting Size	1/8 in NPT
Lubrication Type	Exxon Ronex MP
Maximum Speed	4050 rpm
Maximum Temperature (°F (°C))	225 (107)
Microlock Kit	ML2
Replacement Insert	2115U
Replacement Seal Kit	ZS6
Setscrew Torque (in-lbs)	325

Shaft Diameter	1 15/16 in
Shaft Locking Collar Kit	SC6
Size Code	6
Threaded Cover Kit	TC6
Type of Seal	Clearance Seal
Vibration Frequency Fundamental Train	0.0072
Vibration Frequency Inner Ring Defect	0.1617
Vibration Frequency Outer Ring Defect	0.1217
Vibration Frequency Roller Spin	0.0559

Anexo 3 Características técnicas acelerómetros ICP PCB 353B33.

Performance	ENGLISH	SI
Sensitivity(± 5 %)	100 mV/g	10,19 mV/(m/s ²)
Measurement Range	± 50 g pk	± 491 m/s ² pk
Frequency Range(± 5 %)	1 to 4000 Hz	1 to 4000 Hz
Frequency Range(± 10 %)	0,7 to 6500 Hz	0,7 to 6500 Hz
Frequency Range(± 3 dB)	0,35 to 12,000 Hz	0,35 to 12,000 Hz
Resonant Frequency	≥ 22 kHz	≥ 22 kHz
Broadband Resolution(1 to 10,000 Hz)	0,0005 g rms	0,005 m/s ² rms
Non-Linearity	≤ 1 %	≤ 1 %
Transverse Sensitivity	≤ 5 %	≤ 5 %
Environmental		
Overload Limit(Shock)	± 10,000 g pk	± 98,100 m/s ² pk
Temperature Range(Operating)	-65 to +250 °F	-54 to +121 °C
Temperature Response	See Graph	See Graph
Base Strain Sensitivity	0,0002 g/με	0,002 (m/s ²)/με
Electrical		
Excitation Voltage	18 to 30 VDC	18 to 30 VDC
Constant Current Excitation	2 to 20 mA	2 to 20 mA
Output Impedance	≤ 100 ohm	≤ 100 ohm
Output Bias Voltage	7,5 to 11,5 VDC	7,5 to 11,5 VDC
Discharge Time Constant	0,5 to 2,0 sec	0,5 to 2,0 sec
Settling Time(within 10% of bias)	<25 sec	<25 sec
Spectral Noise(1 Hz)	320 μg/√Hz	3139 (μm/s ²)/√Hz
Spectral Noise(10 Hz)	70 μg/√Hz	687 (μm/s ²)/√Hz
Spectral Noise(100 Hz)	18 μg/√Hz	177 (μm/s ²)/√Hz
Spectral Noise(1 kHz)	6,4 μg/√Hz	63 (μm/s ²)/√Hz
Physical		
Sensing Element	Quartz	Quartz
Sensing Geometry	Shear	Shear
Housing Material	Titanium	Titanium
Sealing	Welded Hermetic	Welded Hermetic
Size (Hex x Height)	0,75 in x 0,93 in	19,1 mm x 23,6 mm
Weight	0,95 oz	27 gm
Electrical Connector	10-32 Coaxial Jack	10-32 Coaxial Jack
Electrical Connection Position	Side	Side
Mounting Thread	10-32 Female	10-32 Female

Anexo 4 Características técnicas dinamómetro Kistler 9257B.

Range	F_x, F_y, F_z	kN	-5 ... 5 ¹⁾
F_z for F_x and $F_y \leq 0,5 F_z$	F_z	kN	-5 ... 10 ²⁾
Calibrated partial range 1	F_x, F_y	N	0 ... 500
	F_z	N	0 ... 1 000
Calibrated partial range 2	F_x, F_y	N	0 ... 50
	F_z	N	0 ... 100
Overload	F_x, F_y, F_z	kN	-7,5/7,5
	F_z for F_x and $F_y \leq 0,5 F_z$	kN	-7,5/15
Threshold		N	<0,01
Sensitivity	F_x, F_y	pC/N	$\approx -7,5$
	F_z	pC/N	$\approx -3,7$
Linearity, all ranges		%FSO	$\leq \pm 1$
Hysteresis, all ranges		%FSO	$\leq 0,5$
Cross talk		%	$\leq \pm 2$
Rigidity	c_x, c_y	kN/ μ m	>1
	c_z	kN/ μ m	>2
Natural frequency	$f_n(x, y, z)$	kHz	$\approx 3,5$ ⁴⁾
Natural frequency (mounted on flanges)	$f_n(x, y)$	kHz	$\approx 2,3$ ⁴⁾
	$f_n(z)$	kHz	$\approx 3,5$ ⁴⁾
Operating temperature range		°C	0 ... 70
Capacitance	F_x, F_y, F_z	pF	≈ 220
Insulation resistance (20 °C)		Ω	$> 10^{13}$
Ground insulation		Ω	$> 10^8$
Protection class EN60529		-	IP67 ³⁾
Weight		kg	7,3
Clamping area	mm	100x170	
Connection		Fischer flange, 9 pol. neg.	

Anexo 5 Características técnicas perfilómetro Carl Zeiss Surfcom 130.

Traversing unit		Surfcom 130A			
Traversing length, Measuring range	50 mm				
Straightness accuracy	0.3 μm / 50 mm (bandwidth)				
Tracing speed	0.3 / 0.6 / 1.5 / 3.0 mm/s				
Reverse speed	1 mm/s				
Adjusting range in sampling direction	50 mm manual				
Range of leveling adjustment	$\pm 1^\circ$				
Evaluation length	max. 48 mm with 0.1 mm step				
Number of sampling lengths	1 to 150, selectable				
Number of sampled data points	max. 32767				
Pickup system					
Measuring ranges	8, 80, 800 μm				
Resolution	Range / 64000				
Detection principle	LVDT				
Measuring force	0.7 mN				
Radius of stylus	2 μm				
Data processing					
Profile type	R, P, W, Wc, Wec and DIN 4776				
Filter type	Gaussian DIN 4777, DIN 4776, Phase correct 2RC, 2RC				
Roughness filter cutoff value λc	0.008 / 0.025 / 0.08 / 0.25 / 0.8 / 2.5 / 8 mm				
Waviness filter cutoff value λt	0.008 / 0.025 / 0.08 / 0.25 / 0.8 / 2.5 / 8 mm				
Magnification	Horizontal 1 – 2000, Auto Vertical 50 – 100,000, Auto				
Tilt correction method of profile	Flat mean line, First half, Latter half, Beginning & end, Curved mean line, Spline and N.C. (no correction)				
Roughness parameters	Ra, Rq, Ry (RzDIN), Rp, Rv, Rc, R3z, RzISO, Rt, RmaxDIN, PC, S, R Δ A, R Δ q, R λ a, R λ q, Ir, RsK, Rku, tp, tp2, Rmr, R8c, Rk, Rpk, Rvk, Mr1, Mr2, Vo, K, CNOMO-Parameters, ISO, DIN, ASME, JIS				
Profile parameters	RzJ, Pt, TILT A, Step height, AVH, Hmax, Hmin, AREA				
Waviness parameters	Wt, Wa, Wem, Wea, Wsm, ...				
Averaged parameters output	possible for up to 100 times				
OK/NG tolerance result output of parameters	possible				
Measuring graphs	Profile curves, Abbott's bearing curve, Amplitude density curve, Fourier analysis				
Interruption interpolation	possible				
Teaching / playback function	possible				
Units	μm , μinch selectable				
Display unit	6.5 in. colour graphic LCD (touch-screen)				
Printing	50 mm width graphic print on 60 mm thermal paper				
Data output & input	RS-232C				
IC memory card storage	measuring conditions & measured data in a card				
Miscellaneous					
Power supply	100 / 110 / 120 / 127 / 220 / 240 V ($\pm 10\%$, 50/60 Hz). (Battery: optional)				
Power consumption	approx. 35 VA				
Dimensions, weight	Width = 650 mm Depth = 410 mm Height = 125 mm Weight approx. 6 kg				
Standard accessories	Calibration & stylus check specimen and tools				
Ambient Requirements					
Humidity	30% to 80%				
Permissible ambient temperature	+10 $^\circ\text{C}$ to +30 $^\circ\text{C}$ (50 $^\circ\text{F}$ to 86 $^\circ\text{F}$)				
Temperature ranges in which the specified accuracies are guaranteed	18 $^\circ\text{C}$ to 22 $^\circ\text{C}$ (68 $^\circ\text{F}$ to 71.6 $^\circ\text{F}$)				