

Universidad Internacional de La Rioja (UNIR)

ESIT

Máster Universitario en Industria 4.0

DIGITALIZACIÓN Y MANTENIMIENTO PREDICTIVO EN GRÚAS TORRE



Trabajo Fin de Máster

presentado por: Moreno Moreno, David

Director/a: König, Caroline Leonore

Resumen

Analizando el estado actual del sector de la construcción, la constante necesidad de ser cada vez más competitivos, y la poca influencia del I+D en dicho sector, nace la oportunidad de un proyecto de digitalización de un elemento clave en el mismo, como es la grúa torre.

En el presente trabajo se realiza un diseño de un sistema de digitalización de una grúa torre. Para ello se especifican los principales sensores de los que se extraerá información útil y necesaria para su posterior tratamiento, se diseña una arquitectura de referencia para el Internet Industrial con un patrón de arquitectura de 3 niveles, especificando un Gateway en la capa Edge y un sistema de almacenaje de datos (Big Data) a través de una plataforma IoT en la nube. Posteriormente se diseña un sistema de mantenimiento predictivo donde se analizan los datos de la máquina digitalizada mediante técnicas de Machine Learning con el objetivo de obtener modelos de predicción de fallos de la grúa torre.

Por último, se realiza una prueba de concepto para la detección de fallos en motores a través de modelos de aprendizaje supervisados implementados en Matlab. La prueba demuestra la exactitud y eficacia de los modelos de predicción para anomalías de la máquina.

Palabras clave: Grúa Torre, Mantenimiento Predictivo, IoT, Industria 4.0, Machine Learning

Abstract

Analyzing the current state of construction sector, the constant need to be more competitive, and the little influence of R&D in this sector, the opportunity for a project to digitize a tower crane is detected.

The present work proposes a design of a tower crane digitization system. To fulfill its endeavor, the necessary sensors to extract meaningful data for a subsequent processing are specified, an Industrial Internet Reference Architecture is designed with a three-tier architecture, specifying a Gateway on the Edge level and a Big Data system at the IoT platform at the Cloud level. Afterwards, a predictive maintenance system is designed where the data of the digitized machine is analyzed through Machine Learning techniques in order to obtain failure prediction models for the tower crane.

Finally, a practical proof-of-concept is performed for the detection of engine failures through supervised learning models implemented in Matlab. This proof demonstrates the accuracy and effectiveness of the prediction models for machine anomalies.

Keywords: Tower Crane, Predictive Maintenance, IoT, Industry 4.0, Machine Learning.

Índice de contenidos

1.	Introducción	10
1.1.	Motivación	12
1.2.	Planteamiento del trabajo	12
2.	Contexto y estado del arte	14
2.1.	Estado actual del sector de la construcción	14
2.2.	Tecnologías relevantes en el sector de la construcción	19
2.3.	Construcción 4.0.....	21
2.4.	Tecnologías habilitadoras de industria 4.0.....	25
2.4.1.	Sistemas Ciberfísicos	25
2.4.2.	Ciberseguridad	27
2.4.3.	Paradigmas de computación	28
2.4.4.	Internet de las cosas e Internet de las cosas industrial (IoT & IIoT)	29
2.4.5.	Plataformas de IoT	30
2.4.6.	Tecnologías y protocolos de IoT	31
2.4.7.	Big Data.....	33
2.4.8.	Aprendizaje automático o Machine Learning (ML)	34
2.4.9.	Mantenimiento Predictivo.....	35
2.5.	Conclusiones sobre el estado del arte	41
3.	Descripción general de la contribución del TFM.....	42
3.1.	Objetivos	42
3.2.	Metodología del trabajo	42
3.3.	Descripción general de las partes o componentes de la propuesta	43
4.	Desarrollo específico de la contribución.....	46
4.1.	Señales críticas que monitorizar en la grúa	46
4.2.	Arquitectura de la solución de digitalización.....	48
4.2.1.	Capa de negocio	49
4.2.2.	Capa de uso	50

4.2.3.	Capa funcional.....	50
4.2.4.	Capa de implementación	51
4.3.	Propuesta de implementación	54
4.3.1.	Sensores	54
4.3.2.	Gateway	56
4.3.3.	Router 4G.....	58
4.3.4.	Ordenador Industrial	59
4.3.5.	Plataforma IoT	60
4.3.6.	Aplicaciones informáticas en Cloud	61
4.3.7.	Pequeño material auxiliar	62
4.3.8.	Presupuesto	63
4.4.	Sistema de mantenimiento predictivo.....	67
4.4.1.	Definición del problema a resolver.....	67
4.4.2.	Diseño de la aplicación.....	71
4.4.3.	Propuesta tecnológica del sistema	74
4.4.4.	Prueba de concepto o viabilidad con mantenimiento predictivo	77
5.	Conclusiones y trabajos futuros	90
5.1.	Conclusiones	90
5.2.	Líneas futuras de trabajo	92
6.	Referencias	93
Anexo A.	Hojas de características	99

Índice de figuras

Figura 1. Claves de las revoluciones industriales. Fuente: The Digital Transformation People (2018).....	10
Figura 2. Tecnologías habilitadoras de la Industria 4.0. Fuente: Asociación Clúster de Automoción Navarra (ACAN).....	11
Figura 3. Habilitadores industria 4.0 utilizados en el TFM. Fuente: Propia.....	13
Figura 4. Productividad de la construcción por subsector. Fuente: The McKinsey Institute (2017).....	14
Figura 5. % GDP Construction Sector un Europe. Fuente: EU Open Data Portal.....	15
Figura 6. Contabilidad Nacional Trimestral. Datos Avance (INE). Fuente: Observatorio Nacional de la construcción.....	16
Figura 7. Microdatos. Encuesta de población activa. Fuente: Instituto Nacional de Estadística. (INE).....	17
Figura 8. Evolución anual de millones de toneladas de cemento. Fuente: Observatorio Nacional de la construcción.....	18
Figura 9. Estadística sobre actividades I+D en la industria. Fuente: INE (Noviembre 2019).	19
Figura 10. Partes de una grúa. Fuente: Vega Arias, J. (2007).	20
Figura 11. Motores de una grúa. Fuente: Vega Arias, J. (2007).....	20
Figura 12. El entorno de la construcción 4.0 habilitado por el uso de tecnologías digitales. Fuente: Flávio Craveiro, et al. (2019).....	22
Figura 13. Tres partes de la patente de Karan, R. et al. (2016).....	24
Figura 14. Extracto del estado del arte y oportunidades del Big Data y Analytics en la construcción. Fuente: Bilal, M. (2016).....	24
Figura 15. Arquitectura de un Sistema Ciberfísico. Fuente: Bagheri, B.et al, (2015).	26
Figura 16. Ejemplo de arquitectura de Sistemas Ciberfísicos en una fábrica. Fuente: Bagheri, B.et al. (2015).	27
Figura 17. Ejemplo de infraestructura Cloud, Fog y Edge Computing. Fuente: Cao, H et al. (2019).....	29
Figura 18. Áreas funcionales de una plataforma IoT. Fuente: Lucero (2016).....	30
Figura 19. Arquitectura MQTT. Fuente: Mathworks.....	32

Figura 20. Las 3 Vs del Big Data. Fuente: Philip Russom (2011).	33
Figura 21. Tipos de Machine Learning. Fuente: Kim, K.J. et al. (2019).	34
Figura 22. Mantenimiento correctivo. Fuente: Predictive Maintenance Ebook part 1, Matlab	35
Figura 23. Mantenimiento preventivo. Fuente: Predictive Maintenance Ebook part 1, Matlab	36
Figura 24. Mantenimiento predictivo. Fuente: Lee, W. et al. (2019).	36
Figura 25. Remaining Useful Life. Fuente: Predictive maintenance Ebook part 3, Matlab.	37
Figura 26. Life Time Data. Fuente: Three ways to estimate RUL. Fuente: Baru. A (2018).	38
Figura 27. Run to failure: Three ways to estimate RUL. Fuente: Baru. A (2018).	38
Figura 28. Threshold Data. Fuente: Three ways to estimate RUL. Fuente: Baru. A (2018).	39
Figura 29. Pasos del mantenimiento predictivo. Fuente: Lee, W. et al. (2019).	40
Figura 30. Adquisición y tratamiento de datos. Fuente: Predictive maintenance Matlab	40
Figura 31. Arquitectura e integración de tecnologías. Fuente: Propia.	44
Figura 32. Punto de vista del uso. Fuente: Propia.	50
Figura 33. Arquitectura de control. Fuente: Propia.	53
Figura 34. U-Sense Energy Drives de Weidmüller. Fuente: Weidmüller.	55
Figura 35. U-Sense Smart. Fuente: Weidmüller.	55
Figura 36. Gateway IoT de Weidmüller UC20-WL2000-IoT. Fuente: Weidmüller.	56
Figura 37. Nodos de protocolos de comunicación de Node-RED. Fuente: Propia.	57
Figura 38. Parámetros a configurar nodo AWS de Node-RED. Fuente: Propia.	57
Figura 39. Certificados de seguridad de AWS en nodo de Node-RED. Fuente: Propia.	58
Figura 40. Router IE-SR-4TX-LTE/4G de Weidmüller. Fuente: Weidmüller	59
Figura 41. UV20-B-IPC-2001.01 de Weidmüller.	60
Figura 42. Arquitectura de AWS. Fuente: Guth et al. (2018).	61
Figura 43. Ejemplo de montaje con el hardware seleccionado. Fuente: Propia.	62
Figura 44. Causas por las que un motor eléctrico reduce su vida útil. Fuente: Propia.	71
Figura 45. Dataset con la herramienta AML de Weidmüller. Fuente: Propia	74
Figura 46. Datos de un atributo con la herramienta AML de Weidmüller. Fuente: Propia.	75

Figura 47. Valores estadísticos de un atributo con la herramienta AML de Weidmüller. Fuente: Propia	75
Figura 48. Ejemplo de modelo calculado con la herramienta AML de Weidmüller. Fuente: Propia	76
Figura 49. Comparativa entre los modelos generados por la herramienta AML de Weidmüller. Fuente: Propia	76
Figura 50. Metodología a seguir. Fuente: Propia	78
Figura 51. Etiquetaje de los datos como normal o anómalo. Fuente: Propia	78
Figura 52. Datos importados en Matlab. Fuente: Propia	79
Figura 53. Dataset de los compresores en Matlab. Fuente: Propia	80
Figura 54. Número de instancias y variables. Fuente: Propia	81
Figura 55. Visualización de nuevos atributos calculados. Fuente: Propia.	81
Figura 56. Features Ranking. Fuente: Propia.	82
Figura 57. Resultados Modelo árboles de decisión. Fuente: Propia.....	83
Figura 58. Matriz de confusión y número de instancias modelo árboles de decisión. Fuente: Propia	84
Figura 59. Resultados Modelo K-Nearest Neighbor. Fuente: Propia	84
Figura 60. Matriz de confusión y número de instancias modelo k-Nearest Neighbor. Fuente: Propia	85
Figura 61. Resultados Modelo K-Nearest Neighbor. Fuente: Propia	85
Figura 62. Matriz de confusión y número de instancias modelo Support Vector Machines. Fuente: Propia	86
Figura 63. Métricas calculadas para árboles de decisión, KNN y SVM. Fuente: Propia.	87
Figura 64. Predicción con Tree. Fuente: Propia.	88
Figura 65. Anomalía detectada prediciendo con Tree. Fuente: Propia.	89

Índice de tablas

Tabla 1. Diagrama de Gantt de la planificación del TFM. Fuente: Propia.....	45
Tabla 2. Señales críticas a monitorizar en una grúa. Fuente: Propia	47
Tabla 3. Presupuesto Hardware y software por grúa a digitalizar. Fuente: Propia	63
Tabla 4. Presupuesto Servicios AWS. Fuente: AWS.....	64
Tabla 5. Presupuesto Gestión del proyecto. Fuente: Propia	65
Tabla 6. Presupuesto Total del proyecto. Fuente: Propia.....	65
Tabla 7. Factores causante de las averías en los motores de inducción. Fuente: Merizade, Y. et al. (2017).	68
Tabla 8. Principales averías en el estator. Fuente: Merizade, Y. et al. (2017).....	69
Tabla 9. Principales averías en el rotor. Fuente: Merizade, Y. et al. (2017).	70
Tabla 10. Matriz de confusión. Fuente:Propia.....	83
Tabla 11. Métricas calculadas para los 3 modelos. Fuente: Propia.....	87

1. Introducción

A lo largo de la historia, la industria ha sufrido grandes cambios gracias a la evolución e innovación tecnológica. Tras tres revoluciones industriales, en los últimos años se está experimentando nuevamente otro gran cambio, que indica la llegada de una cuarta. Esta nueva revolución, generó un concepto nuevo, llamado industria 4.0.

En la figura 1 se pueden ver los hitos que han marcado cada una de las cuatro revoluciones industriales.

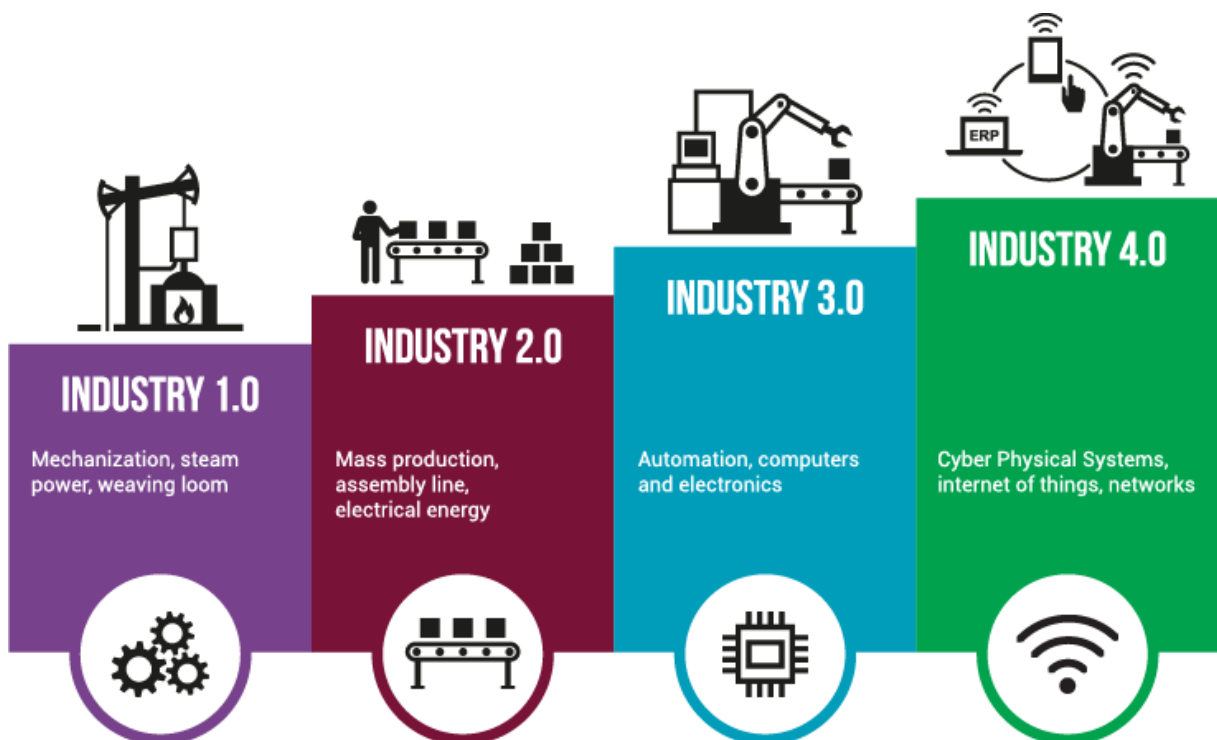


Figura 1. Claves de las revoluciones industriales. Fuente: *The Digital Transformation People* (2018).

En la primera revolución industrial, la máquina de vapor ideada por James Watt fue el gran desarrollo que cambió la industria. Posteriormente con la llegada de la electricidad y el petróleo, se dio la segunda revolución industrial. La industria 3.0, estuvo caracterizada por la implementación de la automatización, ordenadores y electrónica. En el año 2011, nació en Alemania el término Industria 4.0, haciendo referencia principalmente a la transformación digital de la industria. Esta cuarta revolución afecta a todas las industrias y sectores, cambiando la forma de proceder. La industria 4.0, tiene como principal idea explotar el potencial de nuevas tecnologías, con el objetivo final de lograr la interconexión de todos los

actuadores mediante el uso de las mismas, lo que conocemos como tecnologías habilitadoras de la Industria 4.0 (figura 2).

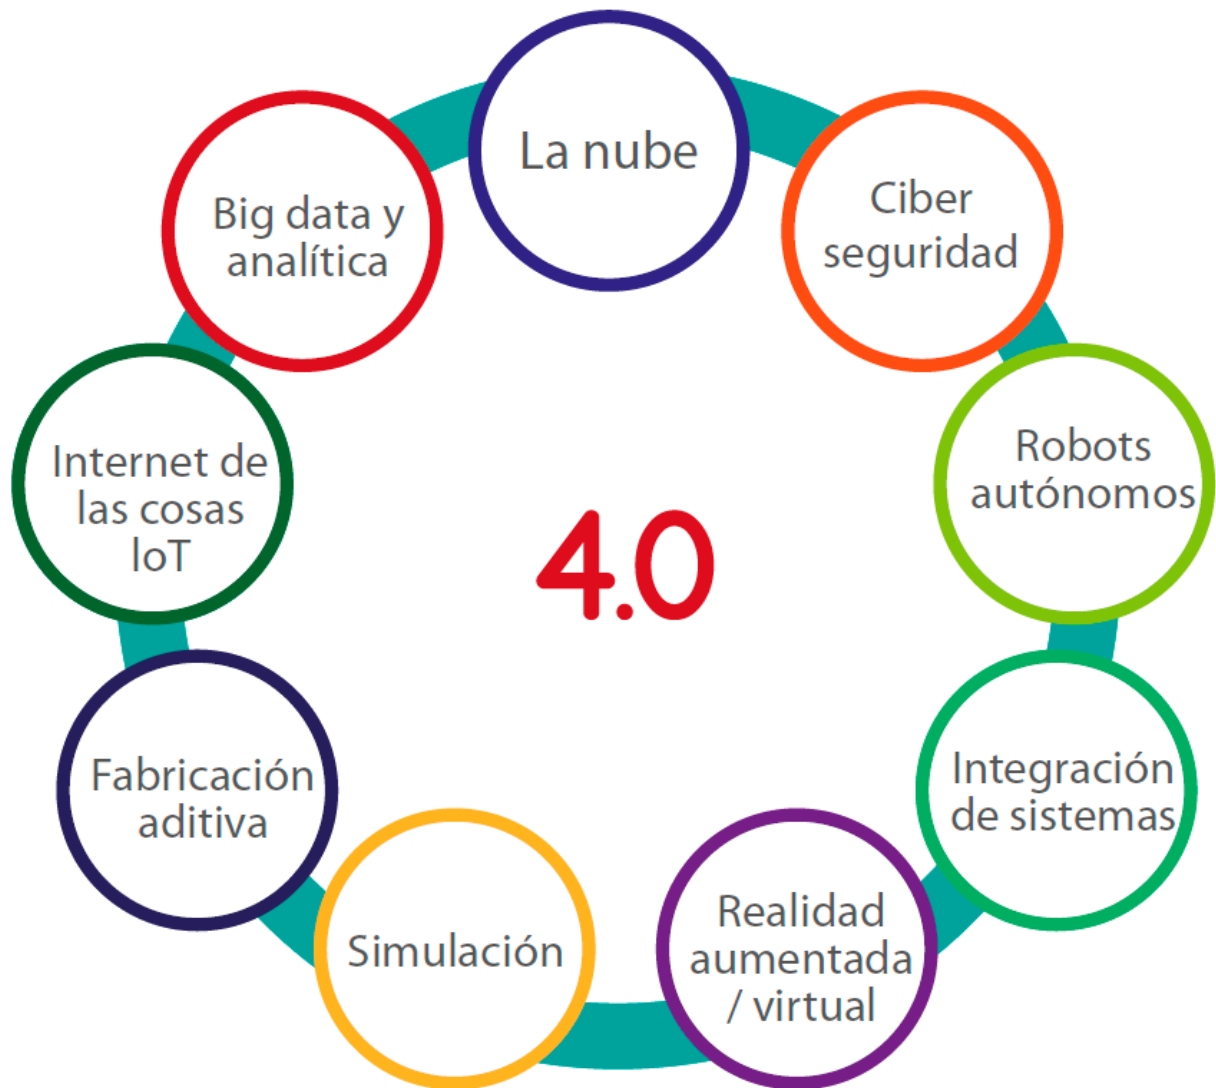


Figura 2. Tecnologías habilitadoras de la Industria 4.0. Fuente: Asociación Clúster de Automoción Navarra (ACAN)

El uso de estas tecnologías permitirá que dispositivos y sistemas colaboren entre ellos, permitiendo mejorar la eficiencia de las fábricas y/o procesos productivos, consiguiendo entre otras cosas una optimización de tiempos, costes, materiales y ahorro energético.

Aplicar el concepto de Industria 4.0, conlleva afrontar nuevos retos y aprovechar todas las ventajas que ofrece el mismo, y es lo que se ha plasmado en este trabajo fin de máster (TFM), donde se ha llevado a cabo la transformación de una grúa, un elemento importante en el sector de la construcción, a la Industria 4.0.

En cualquier tipo de industria o sector, cuando un elemento falla, puede suponer una parada de producción y su consiguiente pérdida económica. La supervisión de estos sistemas puede ayudar a una detección y predicción de averías. Para ello, gracias al uso de tecnologías habilitadoras como el Internet of Things (IoT), se conseguirá que un conjunto de sensores sea integrado en una plataforma IoT, generando información que posteriormente será analizada (Big Data y Analítica), y permitirá establecer un mantenimiento predictivo. Todo ello con el objetivo final de digitalizar una grúa y convertirlo en un elemento más de la industria 4.0.

1.1. Motivación

Ante el gran parque de grúas torre disponibles, nace la necesidad de diferenciarse de la competencia ofreciendo un producto y servicio de una mayor calidad. Dicho servicio, engloba desde una rápida asistencia en caso de avería, hasta incluso ser capaces de prevenirla y anticiparnos a ella mediante herramientas de mantenimiento predictivo.

El modelo de negocio de los fabricantes de grúas es alquilar las mismas a las constructoras, quienes las tienen repartidas a lo largo de todo el mundo. Dado que el sector de la construcción ha sido un sector castigado fuertemente en los últimos años, cada vez se intenta conseguir una reducción de gastos mayor. Dichos gastos, no solo pueden venir dados por unos suministros de materiales más económicos, sino también por una reducción de tiempos de fabricación, donde juegan un papel muy importante los tiempos muertos originados por una avería de maquinaria.

Una grúa es un elemento muy importante en una obra de construcción, por lo que para cumplir los plazos y mantener la calidad en la ejecución, parece esencial su monitorización y funcionamiento. Es aquí donde nace la oportunidad en el sector.

1.2. Planteamiento del trabajo

Para abordar la oportunidad planteada anteriormente, se realizará en primer lugar un estudio del arte de las tecnologías y señales relevantes en una grúa, que describirá el punto de partida de la digitalización de la misma y del presente estudio.

Una vez realizado el paso anterior, el siguiente objetivo será diseñar la solución de digitalización de la grúa, desde el Gateway, donde se recogerán las señales relevantes, hasta su almacenaje y procesado en entorno Cloud. Para ello se estudia la arquitectura de IoT,

dispositivos y tecnologías de comunicaciones adecuadas para resolver la problemática presentada.

Del mismo modo, se presenta un estudio sobre las diferentes opciones de aplicaciones de mantenimiento predictivo de la grúa torre con el fin de diseñar el sistema de Big Data correspondiente a partir de la grúa torre digitalizada.

Esta información almacenada en la plataforma IoT, será tratada mediante técnicas de aprendizaje automático o Machine Learning (ML). La figura 3 muestra un resumen de las tecnologías habilitadoras de la Industria 4.0 más relevantes para el desarrollo de la solución/estudio planteado.

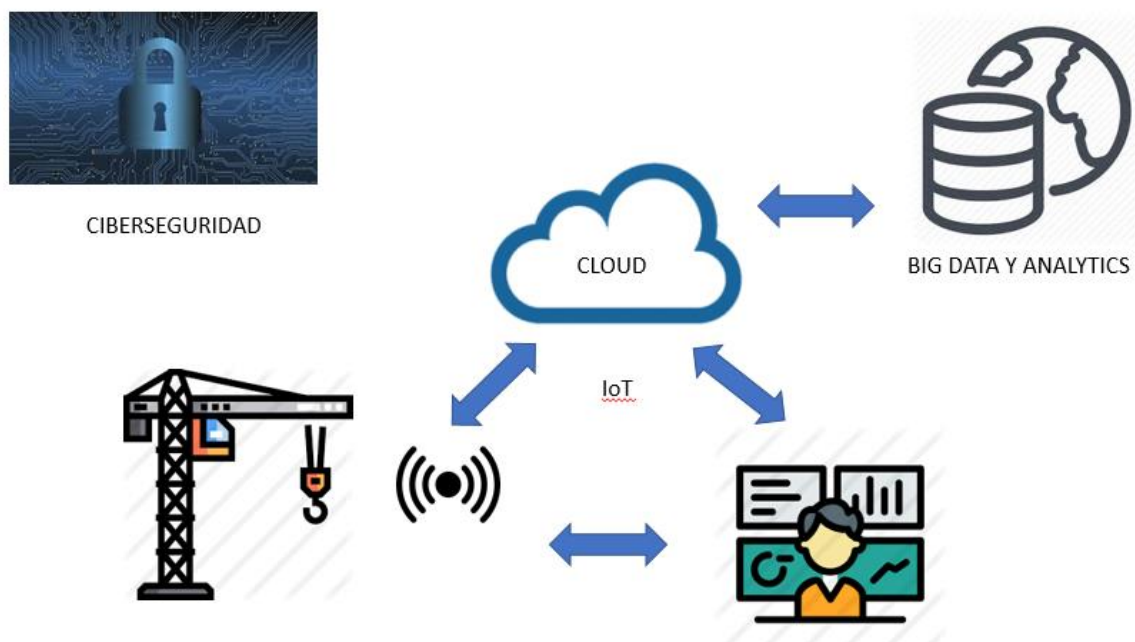


Figura 3. Habilitadores industria 4.0 utilizados en el TFM. Fuente: Propia

Por último, se presenta una prueba de concepto mediante Matlab con el objetivo de probar diferentes algoritmos de mantenimiento predictivo sobre un conjunto de datos similares a los de la grúa torre y que corresponden a un sistema de motores. El objetivo es crear modelos de predicción de los fallos fiables y con alta exactitud.

2. Contexto y estado del arte

2.1. Estado actual del sector de la construcción

La construcción representa el día a día de la actividad moderna del ser humano. Desde edificios donde vivir, oficinas donde trabajar, apoyo al transporte mediante infraestructuras, suministro de agua, energía, ocio, por lo que se podría decir que es uno de los activos más importantes de un país. Afecta al ámbito de vivienda y laboral de la población, y esto hace que se genere hasta el 80% del Producto Interior Bruto (PIB) o Gross Domestic Product (GDP) si atendemos al mercado internacional.

Tomando como definición de construcción general, la construcción de viviendas enteras, edificios de oficinas, tiendas y otros edificios y servicios públicos, edificios agrícolas, etc., o la construcción de obras de ingeniería civil como autopistas, calles, puentes, túneles, ferrocarriles, aeródromos, puertos y otras fuentes de agua proyectos, sistemas de riego, sistemas de alcantarillado, instalaciones industriales, tuberías y líneas eléctricas, instalaciones deportivas, etc. (Hampson, K. 2014), se podría afirmar que la construcción es una actividad fundamental de la sociedad.

La figura 4 muestra la distribución de la actividad de la construcción por subsector según el estudio elaborado en 2017 por The McKinsey Institute.

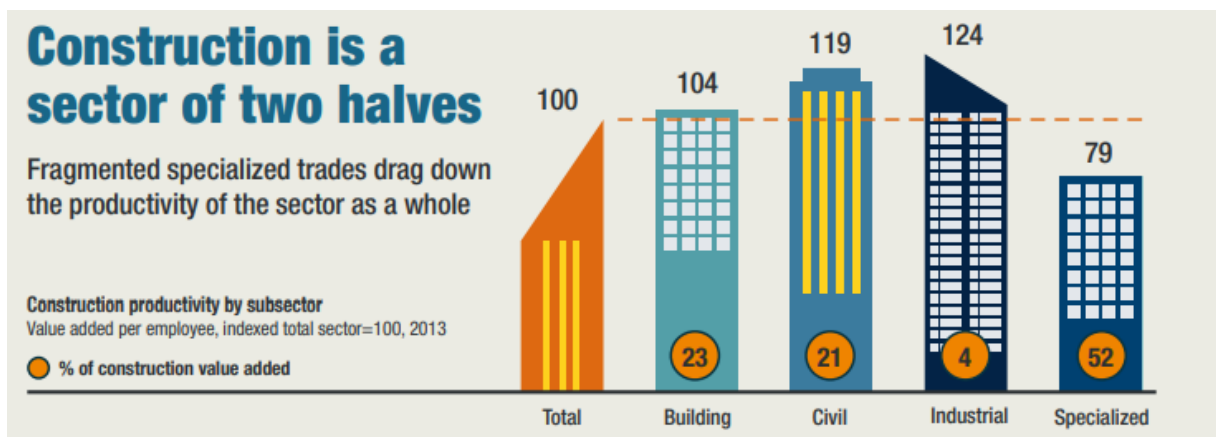


Figura 4. Productividad de la construcción por subsector. Fuente: The McKinsey Institute (2017)

Por todo ello, cabe esperar que el sector de la construcción ha representado un importante porcentaje en el GDP o Producto Interior Bruto (PIB) de un país. Según un estudio publicado por el World Economic Forum, la industria de la construcción actualmente representa un 6% del GDP mundial, y se espera que en el año 2030 sea un 14,7%.

Según The McKinsey Institute (2017) el sector de la construcción representaba el 13% del GDP mundial, y daba empleo al 7% de la población mundial.

A nivel europeo, la construcción es un sector muy importante. Atendiendo a la figura 5, se aprecia el porcentaje del GDP que el sector construcción representa respecto al resto de sectores en los últimos 25 años en Europa. Se aprecia un incremento del sector durante los años 2004 – 2008 seguido de una fuerte caída a partir del año 2009.




Figura 5. % GDP Construction Sector un Europe. Fuente: EU Open Data Portal

Repitiendo el mismo ejercicio a nivel de la economía española, se observa la misma tendencia. En 2009 la aportación al PIB rondaba un 10% y se observa una fuerte caída hasta el 5,9% del año 2019 (figura 6).




Figura 6. Contabilidad Nacional Trimestral. Datos Avance (INE). Fuente: Observatorio Nacional de la construcción

Estos datos corroboran que el sector ha sido fuertemente castigado entre los años 2009 y 2014, y se observa una ligera recuperación a partir del año 2015. El impacto de esta caída ha sido más notable en España que en el resto de países de la unión europea (EU), dado que el sector de construcción representa un % importante del PIB de España.

La recesión del sector construcción también puede corroborarse comparando el número de trabajadores en activo en el mismo. La figura 7 muestra el descenso en el número de trabajadores generalizado en todos los sectores desde el 2009 hasta el 2014, destacando el elevado porcentaje de trabajadores en el ámbito de la construcción. Estos años corresponden a los años de mayor recesión en dicho sector y su contribución más baja al PIB del país.




Figura 7. Microdatos. Encuesta de población activa. Fuente: Instituto Nacional de Estadística. (INE)

En dicha figura 7, lo que se analiza es la variación porcentual de empleados en cada sector comparada con el año anterior. Para ello, se tienen en cuenta los cuatro sectores más influyentes en la economía del país, y se aprecia cómo el sector de la construcción es el más castigado en este caso.

Por último, para corroborar todos estos números, y demostrar que el sector presenta una mejoría año a año, pero sin llegar a números de 2009 ó anteriores, se puede analizar la figura 8, donde se muestra el número de millones de toneladas de cemento consumido y su variación anual.

Desde el 2007, el consumo de cemento decrece, y no será hasta 2015 cuando vuelva a presentar una variación de consumo positivos.




Figura 8. Evolución anual de millones de toneladas de cemento. Fuente: Observatorio Nacional de la construcción.

Todos estos datos negativos de los últimos años animarían a pensar que las empresas del sector de la construcción intentarían mejorar la eficiencia a través de la innovación, al igual que sucede en otros sectores, pero se ha podido constatar que no ha sido el caso.

Un informe realizado por la consultoría Roland Berger, desvela que el 93% de los implicados en el sector de la construcción cree que la digitalización afectará al sector, pero sólo el 6% de las mismas está haciendo uso de innovación y tecnología habilitadoras de esta transformación digital. (Berger, R. 2016).

Por otro lado, a nivel local, un estudio elaborado por el Instituto Nacional de Estadística (INE), muestra que el gasto en investigación y desarrollo en España (I+D) en el año 2018, representó el 1,24% del PIB. Si se analiza dicho gasto por sectores (figura 9), el sector de la industria invirtió el 47,3% del total, mientras que el sector de la construcción únicamente concentró el 1,1%.




Figura 9. Estadística sobre actividades I+D en la industria. Fuente: INE (Noviembre 2019).

A estos datos habría que añadir según el mismo estudio, que el gasto en I+D realizado en el 2018 fue de 93,8 millones de euros, la cifra más baja de los últimos diez años, un 38,8% menos que el 2008, donde se destinaron más de 153 millones de euros. (Observatorio industrial de la construcción, 2019).

2.2. Tecnologías relevantes en el sector de la construcción

Una grúa torre es un elemento principal en una obra de construcción, por su capacidad de elevar y trasladar materiales pesados a las diferentes ubicaciones de la obra, donde dichos materiales son utilizados.

A nivel técnico, una grúa torre es un aparato de elevación de funcionamiento discontinuo, destinado a elevar y distribuir las cargas mediante un gancho suspendido de un cable, desplazándose por un carro a lo largo de una pluma. (Vega Arias, J. 2007).

Principalmente, una grúa torre está constituida por un brazo horizontal giratorio, y motores de orientación, elevación y distribución o traslación de la carga. En la figura 10 se aprecian las partes.




Figura 10. Partes de una grúa. Fuente: Vega Arias, J. (2007).

La grúa más genérica y estandarizada en el mercado, está formada por cuatro motores, tal y como está ilustrado en la figura 11.

1. Motor de elevación: permite el movimiento vertical de la carga.
2. Motor de distribución: permite el movimiento del carro a lo largo de la pluma.
3. Motor de orientación: permite el giro 360° de la pluma respecto a la vertical.
4. Motor de translación: permite el movimiento de la base.




Figura 11. Motores de una grúa. Fuente: Vega Arias, J. (2007).

Según la instrucción técnica complementaria MIE-AEM-2 (BOE, 2003), las grúas torre atienden a la siguiente clasificación.

1. **Grúa torre fija:** Aquellas que no pueden desplazarse. Son un tipo muy empleado debido a un coste menor que los otros tipos y a la gran cantidad de carga que soportan.
2. **Grúa torre desplazable:** Aquellas cuyas bases están dotadas de elementos de translación.
3. **Grúa torre desmontable:** Aquella diseñada para soportar frecuentes montajes y desmontajes, así como traslados.
4. **Grúa torre auto desplegable:** Aquella en la que la pluma se monta sobre la parte superior de una torre vertical orientable, donde su parte inferior se une a la base de la grúa a través de un soporte giratorio y que está provista de los accesorios necesarios para permitir un rápido plegado y desplegado de la torre y pluma.
5. **Grúa torre monobloc:** Aquella que no está constituida por un solo bloque.
6. **Grúa torre trepadora:** Grúa torre instalada sobre la estructura de una obra en curso de construcción y que se desplaza de abajo hacia arriba por sus propios medios al ritmo y medida que la construcción progresa.

2.3. Construcción 4.0

La construcción, al igual que otros sectores, ha realizado un camino hacia la digitalización. Esta transformación une el mundo físico con el mundo digital y viceversa, mediante el uso de sensores y controladores, realidad aumentada, fabricación aditiva, Cloud Computing y otras tecnologías habilitadoras. En definitiva, una serie de habilitadores que consiguen que las industrias cambien, mejoren sus procesos productivos y sus modelos de negocio. Dicho sector se enfrenta a desafíos caracterizados por nuevas tecnologías digitales, nuevos sensores, máquinas inteligentes y nuevos materiales. Todo este proceso, es lo que se denomina construcción 4.0. (Berger, R. 2016).

Este nuevo escenario, permitirá a las empresas del sector mejorar su productividad, reducir los retrasos en los proyectos y en definitiva ganar en eficiencia. Según un estudio elaborado por Boston Consulting Group, la digitalización en la construcción en los próximos años supondrá ahorros de costos del 13% al 21% en las fases de ingeniería, y del 10% al 17% en las fases de construcción. (Boston Consulting Group, 2016).

Ahora bien, ¿qué se entiende por construcción 4.0? La figura 12 presenta un resumen de las aplicaciones, conceptos y tecnologías relevantes en los diferentes ámbitos relacionados con la construcción.

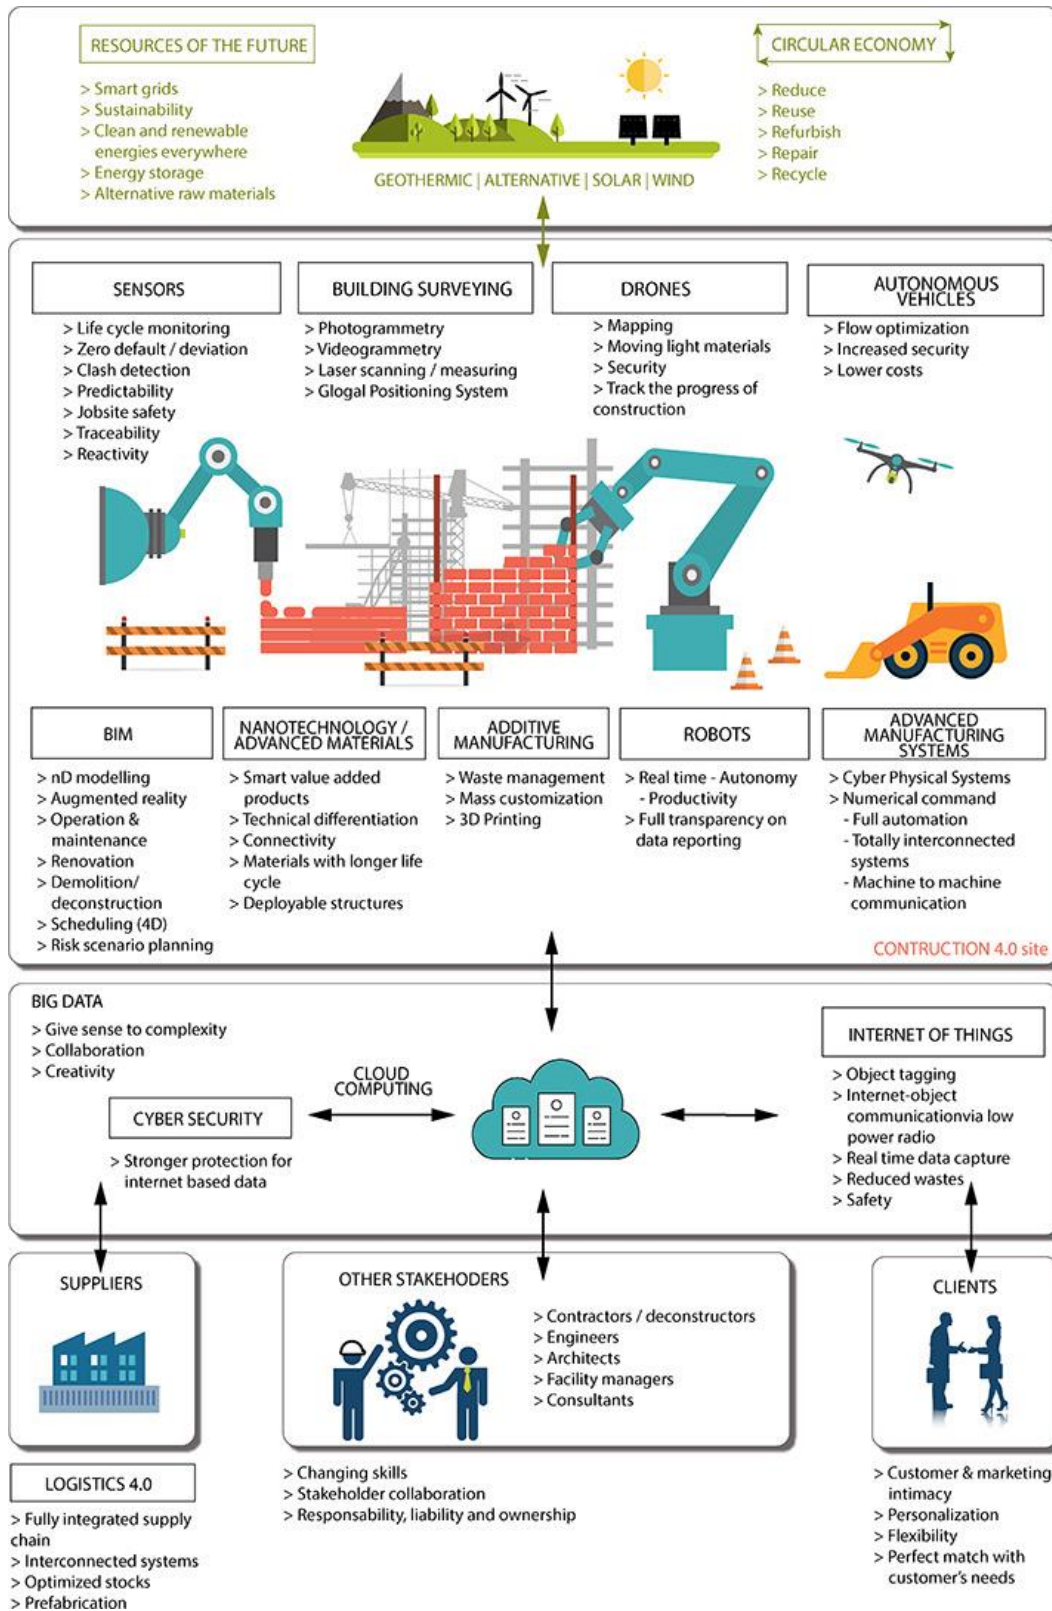


Figura 12. El entorno de la construcción 4.0 habilitado por el uso de tecnologías digitales.

Fuente: Flávio Craveiro, et al. (2019)

La siguiente cuestión que se plantea es realmente, ¿en qué punto se encuentra la construcción 4.0? Según un estudio de Gartner, se estimaba que en 2020 habría un total de 20.415,4 millones de dispositivos IoT instalados, de los cuales 4.381,4 millones tendrían que ver con la industria de la construcción.

Pero ¿cómo puede realmente el IoT beneficiar al sector de la construcción? La llegada de internet y la digitalización al mismo, ayuda a capturar datos en tiempo real, reducir tiempos y ganar en seguridad. Esto sin duda, está transformando la construcción desde el punto de vista de ejecución, mantenimiento y explotación. Del mismo modo, el uso de habilitadores como el IoT, deriva forzosamente en otros como Cloud, Big Data y Analytics, como se plasma en este TFM.

El sector de la construcción es considerado como uno de los más peligrosos en cuanto a accidentes laborales, siendo su tasa el doble que la de otros sectores. Muchos son los factores que los pueden originar, pero el más influyente de todos son las distracciones de los trabajadores. Por ello, varios han sido los estudios para mitigar este tipo de riesgos basándose en arquitecturas IoT. La mayoría de ellos se focalizan de dotar de dispositivos de radiofrecuencia (RF) tanto a los trabajadores como a los lugares peligrosos. Mediante la colocación de dispositivos tipo infrarrojos (IR) y alarmas sonoras, Ung-Kyun Lee, et al. (2008), desarrollaron un sistema seguro de monitorización. De esta manera, cuando un trabajador se aproxima a un lugar peligroso, el sistema emite una alarma sonora alertando del peligro.

Teizer, T., et al. (2015), con la implementación de dispositivos IoT, dotaron de geolocalización mediante sensores RF a los trabajadores y determinaron qué áreas no eran seguras, con el objetivo de identificarlas de manera automática.

Utilizando nuevamente sensores RFID, Chae y Yoshida (2010), diseñaron un sistema IoT donde el objetivo era prevenir las colisiones entre excavadoras y grúas.

Karan, R et al. (2016), dieron un paso más patentando un sistema que englobaba estudios anteriores al que añadieron un nuevo habilitador de la Industria 4.0, Cloud Server. El objetivo no era otro más que toda esa información estuviera en el Cloud, de forma que en cualquier momento pudieran visualizarse estadísticas e incluso tener perfiles de seguridad de los trabajadores. A partir de aquí se presenta una nueva oportunidad, la obtención de conocimiento importante a través del análisis de datos y herramientas de inteligencia de negocio o Business Intelligence (BI).

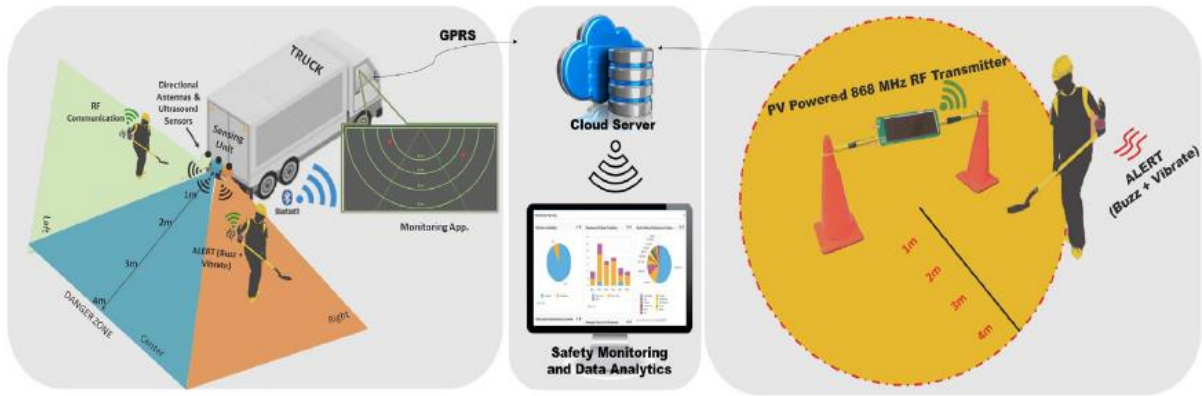


Figura 13. Tres partes de la patente de Karan, R. et al. (2016).

Aquí aparecen dos nuevos conceptos como son las plataformas Cloud (o Cloud Server) y Big Data Analytics. En este sentido, Bilal, M. (2016), realizó un riguroso estudio donde se planteaba el estado actual del Big Data en la construcción, sus oportunidades y las futuras tendencias. En el mismo se remarcaba que, aunque si bien la aplicación de análisis de datos no es nueva en el sector, se encuentra rezagada respecto a otros sectores. Este documento, venía a llenar un vacío ya que hasta el momento no existía ningún estudio sobre este habilitador de la industria 4.0 en el sector de la construcción. En él, un extenso estudio del arte trae un resumen, donde se aprecia el estado actual y las futuras oportunidades del sector (figura 14).

Facility Management	-BIM based indoor localisation [120], FM cost reduction through massive data exploration [121], FM data modelling through BIM [122]	-Big Data Analytics based BIM system for FM activities
Energy Management and Analytics	-Energy simulation software (EnergyPlus) [123], energy management systems [124], Cloud based energy data storage and processing [125], [126] -Appliance event identification using NILM and Wire Spy [127], [128], Energy user classification [111], IOT framework for energy analytics [128]	-Big Data framework for BIM based open energy data persistence -Big Data analytics platform to simulate and optimise energy usage of buildings
Big Data with BIM	-BIM models for building designs [129], [130], [131], [132], BIM models for construction process documentation [133], BIM models for GIS data [134], BIM for MEP conflict resolution [38], BIM open platform [135], BIM via cloud [20], [136], [112], BIM and RFID [114], BIM models for project management data [113], MapReduce savvy BIM data storage and processing [6]	-Big Data enabled IFC-compliant BIM storage system -BIM platform for IOT applications -Open data platform for linking BIM models with external sources -Big Data enabled BIM processing platform to developing applications
Big Data with Cloud Computing	-Cloud based energy data management [125] -Cloud based BIM data management [20] -Cloud enabled BIM design data storage & exploration [112], [137], [136], [138] -SaaS platform for structural MEP analysis [139] -Cloud based BIM system for SMEs [140], [141] -BIM based context-aware computing [142] -Amazon EC2 enabled Google SketchUp [143], [144] -Cloud based e-procurement platform [145]	-A BDA platform to store and process BIM models on cloud for developing domain specific applications.
Big Data with Internet of Things (IOT)	-RFID based construction document retrieval & assets management system [146], [114] -IOT based energy monitoring and analysis system [128], [147] -Urban IOT, a framework for smart cities [148]	-Big Data driven IOT platform for Smart Buildings

Figura 14. Extracto del estado del arte y oportunidades del Big Data y Analytics en la construcción. Fuente: Bilal, M. (2016).

¿Qué papel tiene el Big Data y la analítica de datos? Una construcción se puede dividir en tres partes: la fase de licitación, de ejecución y de explotación. La aplicación de analítica de datos puede beneficiar a cada una de estas etapas.

En la primera fase, muchas compañías utilizan el Big Data y Analytics para tomar decisiones correctas en cuanto a la localización de viviendas. Para ello basan sus estudios en parámetros socioeconómicos. (Ballard-Bloomfield, K. 2019)

En la fase de ejecución es donde más aplicabilidad se le está dando hoy en día al uso de este habilitador de la Industria 4.0. Gracias al mismo se puede estimar los precios de licitación (Zhang, Lee, et al. 2015). El siguiente paso, es predecir los costes y sobrecostes del mismo. Para ello, Trost, S. M. et al. (2003), diseñaron una herramienta basada en Big Data y analítica de datos para calcular los costes reales que iba a tener un proyecto de construcción.

Durante la ejecución de un proyecto, como ya se ha mencionado anteriormente, son múltiples los riesgos de accidente. A través del uso de Machine Learning, se presenta una nueva oportunidad en el sector con el objetivo de aumentar la seguridad de los trabajadores. Con la ayuda del Big Data y Analytics, se crean modelos matemáticos para establecer comportamientos automáticos de los trabajadores en la construcción. (Han, S. et al. 2012).

Una vez finalizada la ejecución de la obra, todos los esfuerzos se centran en el mantenimiento. Por ello, varios son los estudios que hacen hincapié en el uso del Big Data y técnicas de ML para mejorar la eficiencia energética en la edificación. De esta manera, mediante sensores inteligentes cuyos datos son almacenados y tratados, se consigue predecir el consumo energético de un edificio. (Gonzalez-Vidal, A. et al. 2016)

De forma similar, en Miller, C (2017), mediante contadores eléctricos fueron capaces de predecir el uso de edificios no residenciales.

2.4. Tecnologías habilitadoras de industria 4.0

En este apartado se presenta un resumen de las tecnologías habilitadoras relevantes para la digitalización de una grúa torre.

2.4.1. Sistemas Ciberfísicos

Un Sistema Ciberfísico es aquel que permite la gestión entre lo físico y los sistemas de computación. (Baheti, R. 2011).

Antiguamente el control y la monitorización de procesos se hacía de manera local. Hoy en día, en cualquier sector industrial existe una gran cantidad de sensores, sistemas de Big Data, redes y Cloud Computing, lo que ha derivado en tener que preparar las infraestructuras para la implementación de los Sistemas Ciberfísicos.

Una de las características más importantes de un Sistema Ciberfísico, es que es multidisciplinar, por lo que puede ser implementado en cualquier tipo de proceso automatizado. El hecho de unir el mundo físico con el virtual produce varios beneficios, como la reducción de tiempos, de costes, aumenta la eficiencia energética y previene errores. Los Sistemas Ciberfísicos están compuestos por una arquitectura de 5 capas como se observa en la figura 15.

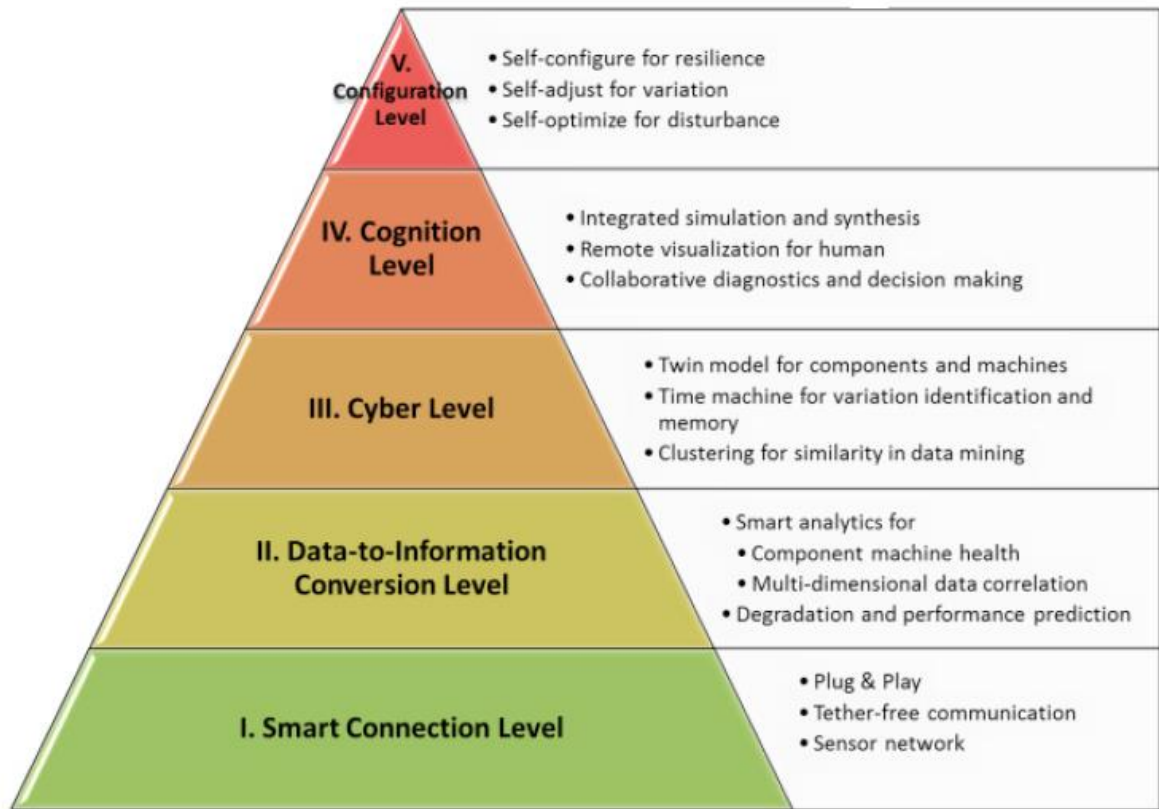


Figura 15. Arquitectura de un Sistema Ciberfísico. Fuente: Bagheri, B.et al, (2015).

A continuación, se explican cada uno de los niveles.

Nivel I: El primer paso en un Sistema Ciberfísico es adquirir valores de máquinas. Dichas medidas pueden ser directamente leídas de los sensores, u obtenidas de controladores o de otros sistemas como ERP, MES, etc...

Nivel II: Se trata de convertir los datos medidos en el nivel I a información útil.

Nivel III: Este nivel actúa como nivel central de información. Como resultado de ello se tendrá un exceso de información, por lo que deberán aplicarse técnicas de análisis.

Nivel IV: Es el nivel de toma de decisiones Es un nivel básico para labores de mantenimiento, y es de gran ayuda el uso de infografías.

Nivel V: En este nivel se realiza la supervisión para hacer que las máquinas se auto adapten y auto configuren.

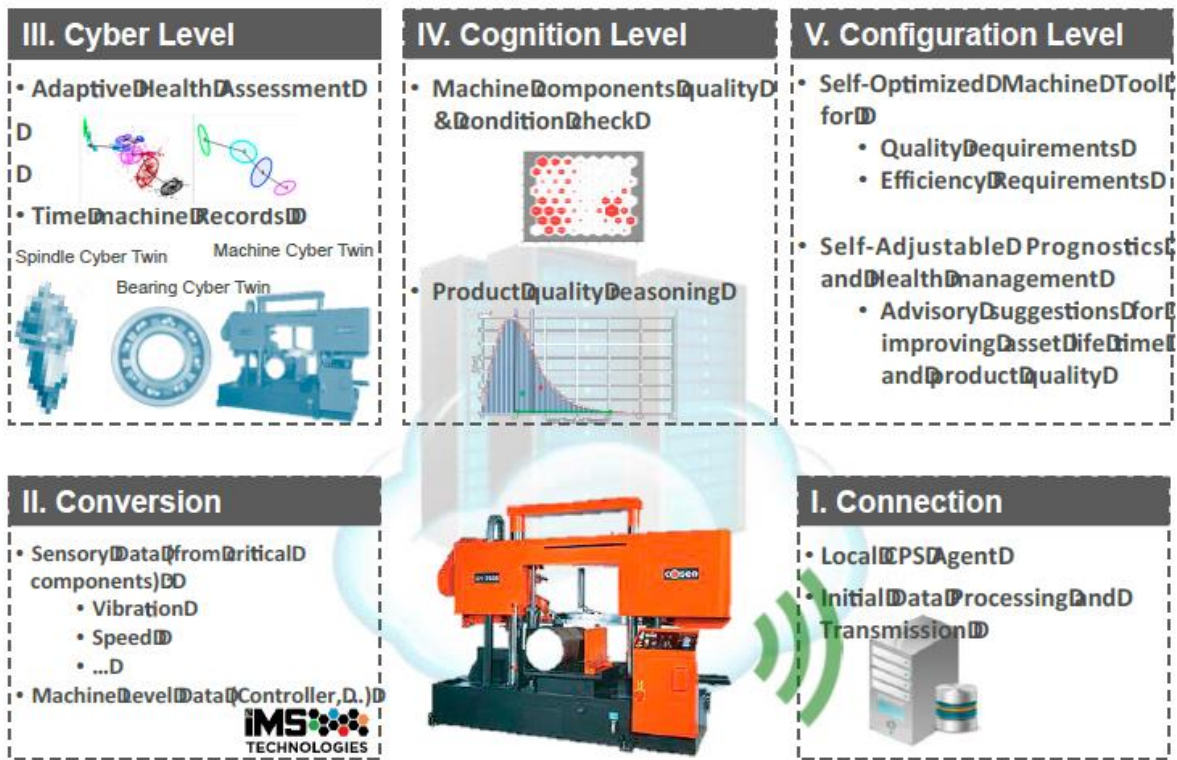


Figura 16. Ejemplo de arquitectura de Sistemas Ciberfísicos en una fábrica. Fuente: Bagheri, B. et al. (2015).

2.4.2. Ciberseguridad

Según el Ministerio de Defensa Español, en su O.M. 10/2013 del 19 de febrero, define la Ciberseguridad Industrial como el conjunto de actividades dirigidas a proteger el ciberespacio contra el uso indebido del mismo, defendiendo su infraestructura tecnológica, los servicios que prestan y la información que manejan.

La entrada en la industria de los Sistemas Ciberfísicos, aparte de grandes ventajas como se mencionaba en puntos anteriores, también ha traído problemática e inseguridades.

Ante la necesidad de tener sistemas más competitivos, cada vez se diseñaron sistemas más abiertos que necesitaban de conexión TCP/IP y esto conllevaba una mayor exposición al exterior. Todo esto derivó en nuevas amenazas que debían ser gestionadas, y aquí entra en juego el término de Ciberseguridad industrial.

El uso de entornos en la nube y la producción globalizada de hoy en día exige que todo ese tráfico de datos esté protegido de forma segura. Por ello, la Ciberseguridad es un área muy importante en cuanto a trabajos de investigación que se están realizando en el ámbito de la Industria 4.0. Así por ejemplo Babiceanu, R., et al. (2019), presentaron un estudio sobre el estado de la ciberseguridad en aplicaciones industriales, y proponían una fabricación basada en redes definidas por software o Software Defined Network (SDN), que permite una mayor heterogeneidad en las redes.

2.4.3. Paradigmas de computación

El continuo desarrollo del Internet de las cosas y su cada vez mayor implementación y, por consiguiente, generación de información, plantea la cuestión de dónde enviarla y tratarla. Es aquí donde nacen nuevos paradigmas de computación que se corresponden con el Cloud (nube), Fog (niebla) y Edge (dispositivo).

En el paradigma del Cloud Computing, es donde tradicionalmente los servidores están instalados en grandes centros de datos. El principal problema reside en la latencia de las comunicaciones debido a las distancias y grandes volúmenes de datos, por ello no es recomendable en aplicaciones donde la respuesta de acción debe ser rápida, como puede ser una fábrica. En cambio, la computación en el Cloud tiene la ventaja de poder proveer capacidad de computación escalable horizontalmente alcanzando grandes capacidades de cálculo.

En una infraestructura Fog, los centros de procesamiento se encuentran más próximos a los dispositivos de campo. De esta forma, este paradigma intenta solventar problemas de comunicaciones con lo que se mejora la latencia y la experiencia de los usuarios.

En cuanto al paradigma de Edge Computing, se podría definir como un hardware con capacidad de cómputo, situado junto a los dispositivos, por ejemplo, en la propia máquina. Este tipo de soluciones se da o bien cuando la latencia es crítica o cuando el envío de una cantidad de datos al Cloud no es práctico o seguro.

En la figura 17 de forma gráfica se puede ver las diferencias entre dichos términos.

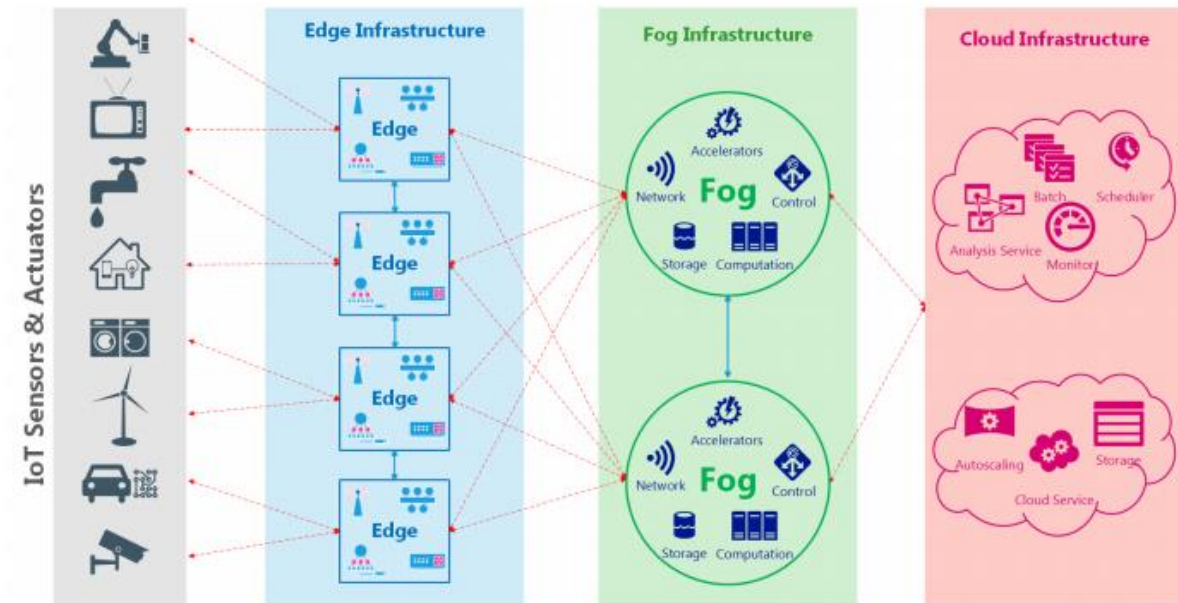


Figura 17. Ejemplo de infraestructura Cloud, Fog y Edge Computing. Fuente: Cao, H et al. (2019)

2.4.4. Internet de las cosas e Internet de las cosas industrial (IoT & IIoT)

El IoT es un habilitador de la Industria 4.0 cuyo objetivo es llevar el uso de internet a objetos del mundo real. Cada vez son más los dispositivos de uso diario que están conectados a internet y que generan gran cantidad de datos.

Pero el concepto de IoT no solo está cambiando el día a día de las personas, sino que también tiene su influencia en la industria, dando origen al Industrial Internet of Things (IIoT). Al igual que en el IoT comercial, en el ámbito industrial cada vez hay más dispositivos conectados a internet que permiten extraer una cantidad de datos mayor con el objetivo de conocer mejor el comportamiento de las máquinas y dispositivos. (Alonso et al. 2020).

El gran volumen de datos que disponen las industrias sugiere que sea necesario el uso de plataformas que sean capaces de gestionarlos.

Los conceptos de IoT e IIoT, comparten tecnologías comunes, como pueden ser uso de sensores, plataformas Cloud, conectividad y analítica de datos. Sin embargo, el IoT se centra más en el usuario final y en la fase de uso de dispositivos, lo que permite al fabricante seguir en contacto con el usuario y ofrecerle servicios nuevos. Por su parte, el IIoT se centra en otra serie de características, y es donde aparecen las principales diferencias entre ambos términos. Los parámetros más importantes son seguridad, interoperabilidad, escalabilidad, precisión, programabilidad, baja latencia, fiabilidad, resiliencia, automatización y comunicación.

2.4.5. Plataformas de IoT

Una plataforma IoT es un conjunto de múltiples capas para estandarizar el desarrollo de soluciones, permitiendo la integración, administración y automatización de dispositivos conectados en el mundo IoT.

La mayoría de las plataformas existentes tienen una funcionalidad similar, por lo que permiten optimizar y automatizar características comunes y esto facilita el desarrollo de aplicaciones. Este hecho es importante, ya que reduce el tiempo de comercialización, inversiones y evita posibles riesgos. Todo ello propicia que la tendencia actual sea utilizar plataformas existentes que permitan utilizar los servicios que ofrecen.

Desde el punto de vista funcional, como se aprecia en la figura 18, una plataforma IoT contiene las siguientes 5 áreas funcionales (Lucero, 2016):

1. Servicios Cloud o de centro de datos
2. Gestión de datos
3. Habilitación de aplicaciones para ayudar al desarrollo
4. Gestión de la conectividad
5. Administración de dispositivos

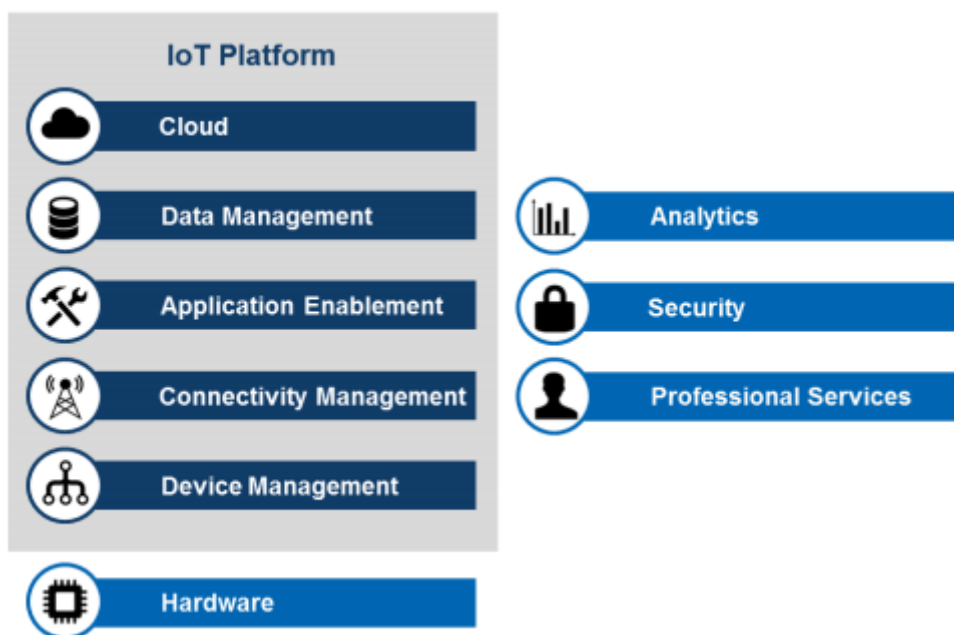


Figura 18. Áreas funcionales de una plataforma IoT. Fuente: Lucero (2016).

Si se hace referencia a los tipos de plataformas, se pueden encuadrar en tres grupos.

Plataformas de propósito general: Son plataformas de los mayores proveedores del mercado, como pueden ser:

1. Azure IoT de Microsoft.
2. AWS IoT de Amazon Web Services.
3. Google IoT Core de Google Cloud Platform.
4. Watson IoT Platform de IBM.

Plataformas industriales: Son plataformas creadas por grandes empresas del sector industrial, con el objetivo de seguir creciendo y sobreviviendo en un mercado tan exigente y cambiante. Se centran más en dar soluciones a un problema en concreto en lugar de vender servicios como las primeras. Se pueden destacar:

1. ThingWorx de PTC.
2. Bosch IoT Suite de Bosch.
3. Predix de General Electric.
4. EcoStruxure Platform de Schneider Electric.
5. MindSphere de Siemens.

Plataformas de código abierto: Este tipo de plataformas se caracterizan por no tener que pagar una licencia para hacer los desarrollos. Las principales son:

1. Fiware.
2. Eclipse IoT.
3. Thingsboard.

2.4.6. Tecnologías y protocolos de IoT

Los dispositivos IoT que generan datos de forma continua, rara vez dan un valor añadido en el lugar de toma de datos. Es por ello que dichas señales deben ser comunicadas para ser tratadas y analizadas, hecho que implica una transmisión de información a través de una red.

La conectividad juega un papel muy importante en el mundo IoT. El modelo ideal de comunicación es aquel que consume poco, tiene un largo alcance y permite transmitir un número elevado de datos.

En cuanto a los protocolos se puede hacer una gran diferenciación entre protocolos propietarios y protocolos abiertos. Los primeros son aquellos que solo permiten la comunicación entre dispositivos específicos, mientras que los segundos mejoran la escalabilidad ya que permiten la comunicación entre dispositivos heterogéneos. Es de entender que en el mundo IoT interesa la implantación de protocolos abiertos.

Otra gran diferencia entre los protocolos sería en función de su jerarquía. Las redes se organizan en niveles o capas para facilitar su diseño. Los dispositivos solo podrán comunicarse con dispositivos en su misma capa y/o niveles superiores o inferiores.

Las principales tecnologías y protocolos en el entorno IoT haciendo referencia a su jerarquía, son:

Tecnologías y protocolos en capas inferiores: IEE802.15.4, Lora y LoraWAN, Bluetooth Low Energy (BLE), Zigbee, Z-wave y RFID.

Tecnologías y protocolos en capas intermedias: Routing Protocol for Low Power and Lossy Networks (RPL), Channel-Aware Routing Protocol (CARP) y 6LoWPAN.

Tecnologías y protocolos en capas superiores: MQTT, CoAP, XMPP, AMQP y DDS.

El más utilizado de todos es Message Queue Telemetry Transport (MQTT), debido a su baja sobrecarga y consumo de energía. En relación con este TFM es interesante explicarlo más en detalle.

MQTT es un protocolo creado en 1999 por IBM y estandarizado para el uso en aplicaciones de IoT. Se basa en la publicación y suscripción de mensajes que son gestionados por un broker. La arquitectura de funcionamiento está compuesta por unos editores que son dispositivos que captan y comunican datos (sensores, Gateways, etc.) y quienes se conectan al broker para enviarlos. Los suscriptores interesados en varios temas se conectan al broker para recibir la información. Por último, los brokers la clasifican y la envían a los interesados (figura 19).

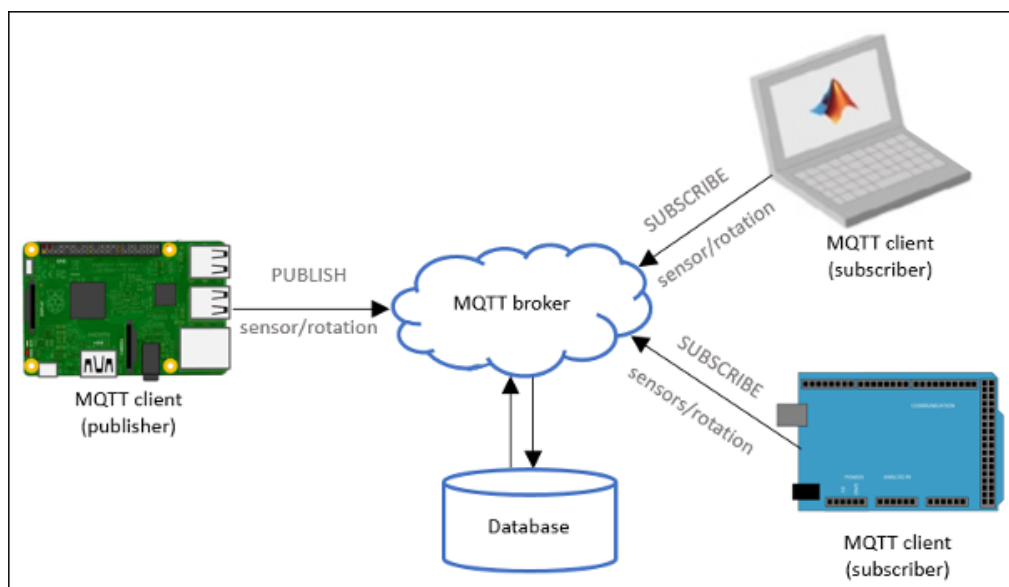


Figura 19. Arquitectura MQTT. Fuente: Mathworks

2.4.7. Big Data

Según Gartner, Big Data son sistemas con prestaciones capaces de gestionar datos que contienen mayor variedad, que se dan en volúmenes crecientes y a una velocidad superior y que no se podrían gestionar en sistemas computacionales convencionales. Es lo que se conoce como las 3 uves del Big Data y que conciernen los diferentes aspectos descritos en la figura 20.

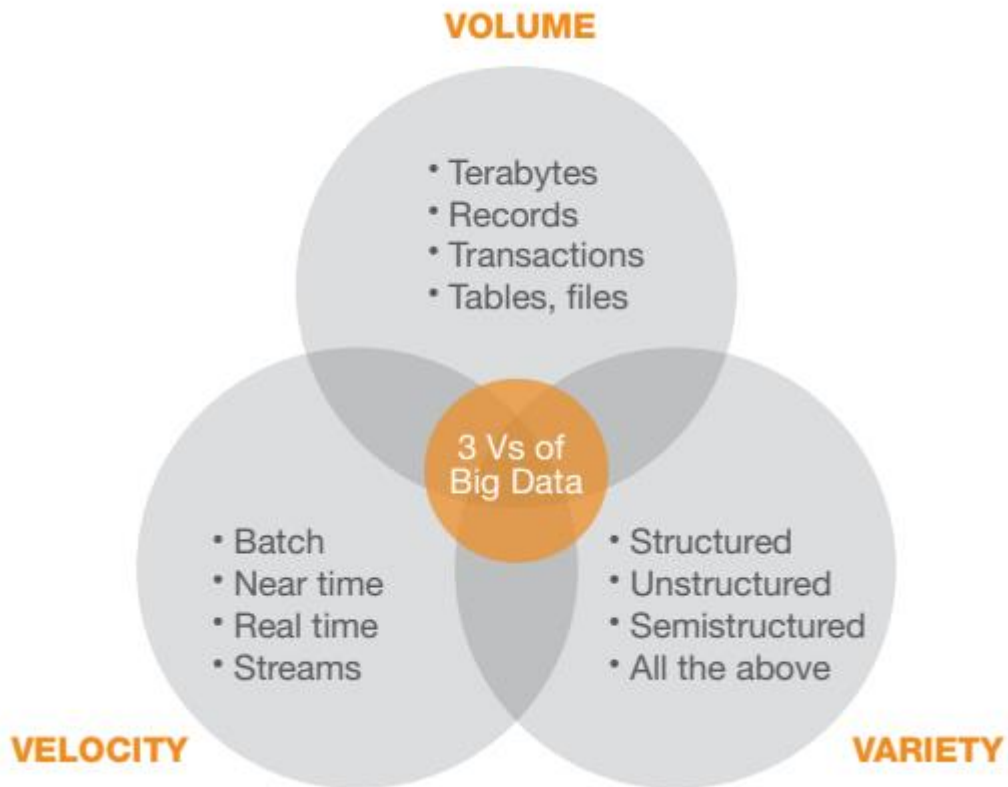


Figura 20. Las 3 Vs del Big Data. Fuente: Philip Russom (2011).

En un principio la cantidad de datos era tal que los ordenadores no eran capaces de procesarla, por lo que se diseñaron nuevas herramientas para tal fin.

Como ejemplo, Mayer-Schönberge (2013) indica en su libro Big Data: “La revolución de los datos masivos, que el telescopio Sloan Digital Sky construido en Nuevo México en el año 2000, en sus primeras semanas de funcionamiento ya había acumulado más datos que en toda la historia de la astronomía”.

Tras almacenar todos los datos, el siguiente paso es analizarlos. De aquí se extrae el siguiente término, Big Data Analytics, que es cómo técnicas de analítica se emplean en el Big Data. Como resultado se puede afirmar que hoy en día los sistemas Big Data se han convertido en

un activo muy importante en las empresas. Toda la información que disponen les permite extraer conclusiones de gran valor para mejorar su eficiencia y centrarse en nuevos objetivos.

2.4.8. Aprendizaje automático o Machine Learning (ML)

El aprendizaje automático o Machine Learning (ML) es una rama de la Inteligencia Artificial (IA) que utiliza algoritmos para encontrar patrones y que de forma automática aprendan y sean capaces de predecir o ayuden a la toma de decisiones. (Murphy, K.P. 2012)

Hay tres grandes grupos para clasificar los algoritmos de ML:

1. Aprendizaje supervisado: Aprenden de clasificaciones previas.
2. Aprendizaje no supervisado: No hay clasificaciones previas y el algoritmo es quien crea patrones.
3. Aprendizaje por refuerzo: Método por prueba y error.

Cada uno de los tres grupos emplea diferentes algoritmos para distintas aplicaciones tal como esta ilustrado en la figura 21.

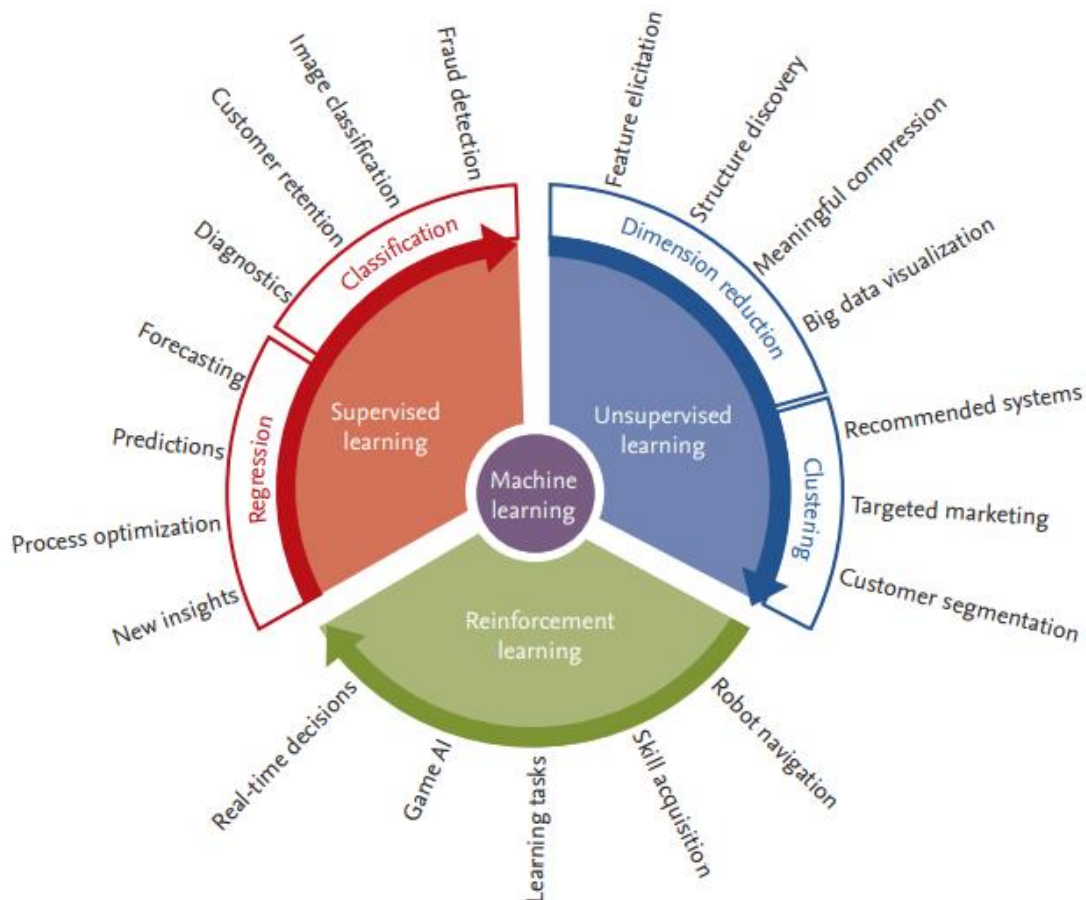


Figura 21. Tipos de Machine Learning. Fuente: Kim, K.J. et al. (2019).

2.4.9. Mantenimiento Predictivo

En este apartado se presenta un resumen de los conceptos relevantes para la implantación de un sistema de mantenimiento predictivo.

2.4.9.1. Estrategias de mantenimiento

En el mantenimiento industrial hay diferentes tipos de mantenimiento, desde el correctivo (o reactivo), que se aplica cuando algún fallo ha ocurrido (figura 22), el preventivo, que se ejecuta bajo unas tareas planificadas, y el predictivo, donde el mantenimiento se realiza en base a una estimación del estado del equipo. (Moblely, R. K. 2002).

Respecto al mantenimiento correctivo, no es aconsejable en sistemas con piezas caras que no pueden arriesgarse a fallar ya que entre otras cosas es más elevado el coste de una reparación.




Figura 22. Mantenimiento correctivo. Fuente: Predictive Maintenance Ebook part 1, Matlab

Muchas compañías realizan el mantenimiento preventivo, realizando tareas periódicas con el objetivo de anticiparse al fallo (figura 23). En este caso el reto está en cuándo proceder al mantenimiento, ya que una de las principales desventajas del mantenimiento preventivo es un alto coste en piezas de recambio, puesto que puedes sustituir un componente, aunque no sea realmente necesario.




Figura 23. Mantenimiento preventivo. Fuente: Predictive Maintenance Ebook part 1, Matlab

Además, mantenimiento preventivo deriva en un aumento de los costes en mantenimiento y producción, puesto que este tipo de tareas conllevan un tiempo no productivo por parada de la máquina.

Por último, el mantenimiento predictivo, estima cuándo una máquina fallará, estableciendo para ello unos límites o condiciones (figura 24). La ventaja de esta estrategia es el ajuste de la frecuencia de mantenimiento de forma que se optimiza la inversión en estos trabajos y en el tiempo productivo.

Este tipo de mantenimiento no sólo es capaz de predecir un fallo, sino que también se pueden clasificar las diferentes anomalías que pueden darse en el equipo, de forma que es posible determinar cuál es el tipo de mantenimiento o recambio a realizar.




Figura 24. Mantenimiento predictivo. Fuente: Lee, W. et al. (2019).

2.4.9.2. Vida útil remanente o Remaining Useful Life (RUL)

Uno de los objetivos del mantenimiento predictivo es sin duda estimar el tiempo de vida remanente de un sistema. El RUL se puede definir como el tiempo que una máquina opera correctamente antes de actuar sobre ella o reemplazarla (figura 25). De esta forma, permite planear los mantenimientos, optimizar los tiempos de operación de los mismos, y eliminar pérdidas de tiempo por acciones no planificadas.




Figura 25. Remaining Useful Life. Fuente: Predictive maintenance Ebook part 3, Matlab.

En función de los datos de los que se dispongan, se pueden utilizar diferentes métodos para calcular el RUL:

1. **Datos de vida útil**: Indican cuánto tiempo tardaron dispositivos iguales en fallar. Se emplea un análisis estadístico denominado Análisis de Supervivencia (o Survival Analysis) que determina la probabilidad de fallo según los ciclos de vida del componente (figura 26).




Figura 26. Life Time Data. Fuente: Three ways to estimate RUL. Fuente: Baru. A (2018).

2. **Historial de fallos:** Partiendo de un histórico de fallos de equipo iguales o similares, podría establecerse el RUL. La figura 27 muestra gráficamente la evolución del estado de la variable observada de un conjunto de máquinas y que constituyen el conjunto de datos histórico para calcular el RUL




Figura 27. Run to failure: Three ways to estimate RUL. Fuente: Baru. A (2018).

3. **Por límite:** Partiendo de un valor límite conocido de una(s) variables(s) que representa anomalías. La figura 28 muestra gráficamente el funcionamiento de esta técnica donde el sistema realiza una predicción del tiempo hasta llegar al valor límite de funcionamiento (Failure threshold).




Figura 28. Threshold Data. Fuente: Three ways to estimate RUL. Fuente: Baru. A (2018).

2.4.9.3. Retos del mantenimiento predictivo

A pesar de que cada vez se habla más de mantenimiento predictivo, todavía son varios los retos a los que debe enfrentarse la industria. Se presentan algunos de ellos:

1. No se dispone de datos suficientes.
2. No se dispone de los datos de fallos para obtener resultados precisos.
3. Se conocen los fallos, pero no cómo predecirlos.
4. No se sabe cómo realizar e implementar el mantenimiento predictivo.

Puesto que la operación de una máquina para la obtención de datos correspondientes a ciertos fallos es muchas veces inviable, la simulación de las condiciones de la máquina a través de software es cada vez más frecuente. El uso de estas herramientas deriva principalmente en dos grandes ventajas tal y como menciona Elhaj, M. et al. (2008). Por un lado, se necesita menos tiempo para obtener resultados sobre fallos, sobre todo aquellos que no pueden provocarse en una máquina real. Por otro lado, permite evaluar el comportamiento de mismos equipos de diferentes modelos o fabricantes, sobre las mismas condiciones de trabajo.

2.4.9.4. Monitorización de máquinas a través de aplicaciones predictivas

El mantenimiento predictivo se basa en el análisis de datos y la creación de modelos de ML, por lo que es aquí donde entran en juego los conceptos anteriormente explicados y que tienen aplicación en este TFM, como son Big Data y Machine Learning. Si bien es verdad, la tendencia es claramente que los sistemas de Machine Learning más sofisticados tiendan hacia modelos de Deep Learning, como lo indican Zhao, R. et al. (2019) en su estudio sobre la aplicación de este término en la monitorización de máquinas.

Para llegar a la implementación de los modelos, se siguen los pasos que se muestran en la figura 29.




Figura 29. Pasos del mantenimiento predictivo. Fuente: Lee, W. et al. (2019).

El primero de ellos es la adquisición de los datos que posteriormente serán tratados para trabajar con datos de calidad (figura 30).




Figura 30. Adquisición y tratamiento de datos. Fuente: Predictive maintenance Matlab

Tras disponer de unos datos de buena calidad y procesados, se establecen límites que indican el correcto funcionamiento o anómalo del equipo. En este punto se está en disposición de entrenar al modelo. Estos modelos se dividen en tres categorías:

1. Modelos de detección de anomalías: Determinan la presencia de anomalías.
2. Modelos de clasificación de anomalías: Detectan anomalías y determinan de qué tipo es.
3. Modelos de predicción de anomalías: En este caso determinan el RUL del equipo a analizar.

Por último, una vez que el modelo ya está entrenado, es necesario desplegarlo en un sistema de información para la predicción en tiempo real. Dichos modelos de ML se pueden desplegar en cualquiera de los paradigmas de computación explicados en el apartado 2.4.3. Según un estudio de O`Donovan, P. et al. (2019), donde comparan el rendimiento de latencia y confiabilidad entre un sistema desplegado en el Cloud o en sistemas descentralizados como Edge y Fog, se informa de la tendencia de desplegar los modelos en estos últimos más cercanas al dispositivo monitorizado. En ellos, se dan tasas de latencia hasta del 99,4% y una tasa de fallos del 0% frente a tasas de fallo que alcanzan hasta el 6,6% en entorno Cloud.

Por ello y dada la más que importante necesidad de minimizar los paros por averías en cualquier tipo de sector, el mantenimiento predictivo juega un papel muy importante hoy en día, minimizando cualquier tipo de coste asociado a un paro de una máquina, permitiendo administrar mejor el stock de inventarios y también mejora la vida útil del equipo. Debido a las grandes ventajas que ofrece, son numerosos los estudios en este sentido y aplicados a muy diversos sectores industriales, como pueden ser turbinas eólicas (Wang, T. et al. 2019), motores eléctricos (Verstraete, D et al. 2017) o máquinas CNN (Zhao, R. et al. 2019).

2.5. Conclusiones sobre el estado del arte

Tras la lectura de diferentes citas bibliográficas se extrae la conclusión que la Industria 4.0 ha llegado al sector de la construcción en menor medida que a otros sectores. Lo que se puede denominar como construcción 4.0, va a ayudar sin duda a mejorar un sector que históricamente ha representado un porcentaje muy elevado del GPD mundial y que tienen una fuerte necesidad de mejora.

Es por ello por lo que, dada la necesidad del sector de ser más eficientes y más competitivos, se brinda una buena oportunidad para el TFM de aplicar tecnologías habilitadoras de la Industria 4.0., para la digitalización y mantenimiento predictivo de una grúa, un componente básico en cualquier obra.

En base al análisis sobre las soluciones existentes y el estado de la tecnología, se ha visto que existen diferentes herramientas que hacen viable implementar el sistema descrito para el sector de las grúas torre.

3. DESCRIPCIÓN GENERAL DE LA CONTRIBUCIÓN DEL TFM

3.1. OBJETIVOS

El objetivo principal de este trabajo fin de máster es digitalizar una grúa torre utilizando habilitadores de la Industria 4.0, monitorizando el funcionamiento de la grúa en tiempo real, e implementando modelos de mantenimiento predictivo y detección temprana de averías. El objetivo es reducir tiempos de parada e incidencias.

El objetivo general se consigue planteando diferentes objetivos específicos:

- Diseñar el despliegue de una arquitectura IoT para digitalizar una grúa.
- Especificar una implementación concreta del sistema diseñado.
- Diseñar un sistema de mantenimiento predictivo.
- Prueba de viabilidad de los algoritmos de mantenimiento predictivo a través de una prueba de concepto.

3.2. METODOLOGÍA DEL TRABAJO

Para la elaboración del trabajo fin de máster se va a seguir un método de planificación que permita alcanzar los objetivos propuestos. Gracias a tener un planteamiento inicial definido, se realizarán los siguientes pasos:

1. Análisis previo que se centra en el estudio del problema y la investigación de soluciones similares y el estado de la tecnología. En este punto el estudio de la bibliografía juega un papel importante.
2. Definición de requerimientos del sistema a diseñar.
3. Diseño de la solución de digitalización. Realizar la arquitectura IoT y selección de componentes de hardware, software y plataforma IoT a utilizar.
4. Diseño de la aplicación de mantenimiento predictivo para la grúa.
5. Estimación del coste que tendría la implementación propuesta.
6. Realización de una prueba de concepto para ver la viabilidad de utilizar modelos predictivos para la detección de anomalías.
7. Evaluación de resultados.

3.3. DESCRIPCIÓN GENERAL DE LAS PARTES O COMPONENTES DE LA PROPUESTA

Partiendo del concepto de Industria 4.0 y aplicando habilitadores de la misma como IoT, Big Data y mantenimiento predictivo, se va a diseñar una solución de digitalización de un componente imprescindible en el sector de la construcción, como es una grúa.

Una vez digitalizada se tendrá completo acceso a las variables relevantes de la grúa y a su funcionamiento en tiempo real. A continuación será posible diseñar la recolección de datos para posteriormente implementar modelos de predicción de fallos o anomalías como parte de las aplicaciones de mantenimiento predictivo. En este TFM se abarca la creación de un modelo de predicción de fallos a partir de un conjunto de datos similares de un sistema de motores como una prueba de concepto de la parte analítica con métodos de ML.

Alcance y limitaciones

Con el objetivo de digitalizar una grúa y las ventajas que supone esta digitalización, este TFM no pretende realizar un estudio al detalle de todas las técnicas de Machine Learning existentes, sino presentar un ejemplo de implementación de una solución IoT y presentar los beneficios que puede aportar al sector el mantenimiento predictivo.

La principal limitación en la prueba de concepto es el hecho de no tener datos reales de una grúa.

Tecnologías implicadas

Las tecnologías que toman parte en esta propuesta de TFM son IoT, Big Data y Machine Learning. La Ciberseguridad es un cuarto habilitador de la industria 4.0 que debe ser básico en cualquier digitalización que se precie.

Arquitectura, componentes e integración de tecnologías.

La manera en que todos los habilitadores anteriormente mencionados interactúan entre ellos, es la representada en la figura 31.

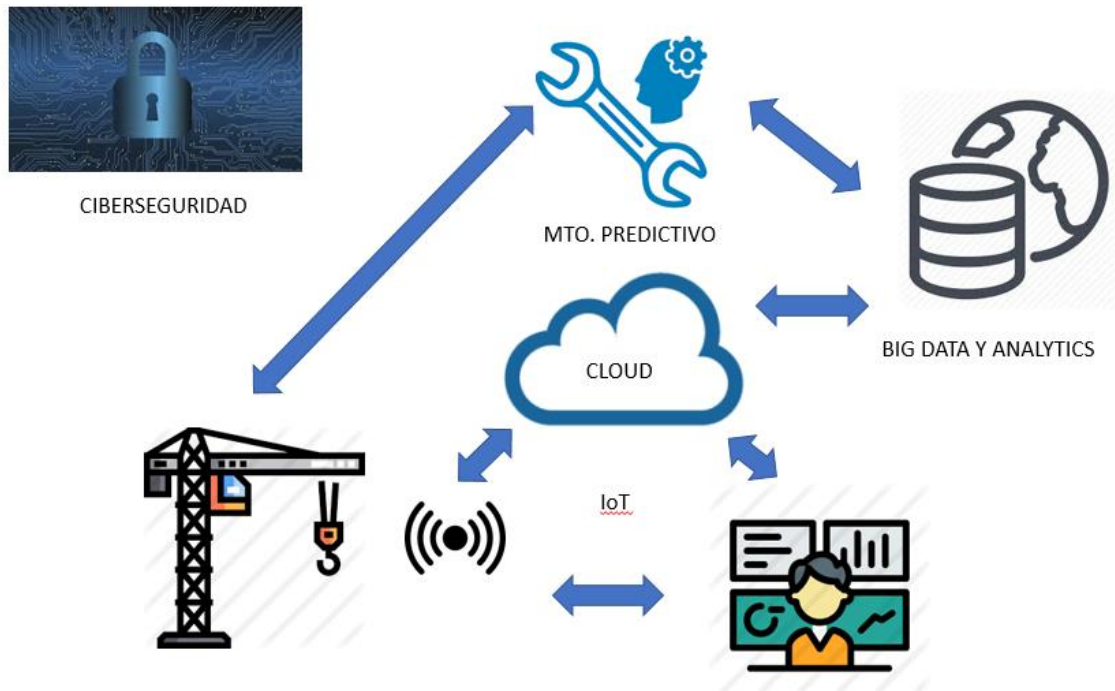


Figura 31. Arquitectura e integración de tecnologías. Fuente: Propia.

Resultados esperados

Se espera poder diseñar una arquitectura IoT con software Open Source, de forma que la solución pueda implementarse en cualquier grúa, y se podría concluir que, en cualquier sector, no solo en el de la construcción. El papel que juega una grúa en cualquier sector es importante.

Respecto al mantenimiento predictivo, se espera obtener modelos de predicción de anomalías a través de la prueba de concepto, que den viabilidad al uso de los mismos.

Planificación general

A continuación, se muestra un diagrama de Gantt de la planificación seguida para la elaboración del TFM.

PLAN DE TRABAJO ELABORACIÓN TFM													
Capítulo	Actividad	SEMANA											
		1	2	3	4	5	6	7	8	9	10	11	12
1	Introducción												
	Motivación												
	Planteamiento del Problema												
	Antecedentes												
	Descripción del Problema												
3	Objetivos												
	General												
	Específicos												
3	Justificación												
2	Contexto y estado del arte												
	Conclusiones del estado del arte												
3	Metodología												
4	Diseño de la solución de digitalización de la grúa												
	Diseñar funcionalmente el sistema de mantenimiento predictivo/detección de anomalías.												
	Descripción general de las partes de la propuesta												
	Desarrollo específico de la propuesta												
	Prueba de concepto con el software de matlab de mantenimiento predictivo												
5	Conclusiones y trabajo futuro												
	Referencias y Bibliografía												
	Anexos												

Tabla 1. Diagrama de Gantt de la planificación del TFM. Fuente: Propia

4. DESARROLLO ESPECÍFICO DE LA CONTRIBUCIÓN

Tras el analizar en el estudio del arte el estado actual del sector, en este capítulo se presenta la aportación al mismo, realizando un análisis del problema y presentando una arquitectura IoT para la solución del mismo.

En cuanto a la arquitectura, se describen los diferentes dispositivos incluidos en ella, y la justificación de su elección en función de las características de los mismos y de los requisitos del sistema, como podrían ser escalabilidad, software abierto u Open Source. A continuación, se incluye una estimación de costes y el retorno de la inversión del proyecto de digitalización de la grúa torre.

Posteriormente se presenta el diseño del mantenimiento predictivo y una prueba de concepto que dará la viabilidad a su implementación.

4.1. SEÑALES CRÍTICAS QUE MONITORIZAR EN LA GRÚA

A la hora de analizar las señales a monitorizar, se podrían dividir en dos grandes grupos. Aquellas que son necesarias para el mantenimiento predictivo, y las que su principal función es ser representadas en la plataforma IoT como información para el operador. Clasificadas como predictivo o informativo en la tabla 2.

En cuanto a las primeras, como ya se mencionó anteriormente, una grúa torre consiste en una torre metálica y cuatro motores que son quienes dan el movimiento a la misma. Es obvio pensar que donde debe prestarse una mayor atención es en los motores.

Un fallo en cualquier de ellos, dejaría inoperativa la grúa, con los consiguientes problemas de retrasos que se verían reflejados en los costes de producción.

Según se recoge en Larrodé E, et al. (1996), los principales motores que se utilizan en una grúa son trifásicos asíncronos y de anillos rozantes. Este tipo de motores son robustos y fiables. Por su parte, los motores de corriente continua rara vez son usados.

Varios estudios hechos en el campo indican que de cara a diseñar y calcular unos correctos modelos de ML para un motor, las señales más importantes a medir para establecer límites de funcionamiento correcto o anómalo son la temperatura, velocidad, vibraciones y consumo (medido en este caso por la intensidad), tal y como indica por ejemplo Drozdowski, P., et al. (2014). A partir de aquí hay otros estudios que determinan y añaden más variables.

Otro componente clave en una grúa es el cable de donde cuelga el gancho que permite alzar las cargas. Para él sería interesante medir el número de ciclos y peso del mismo. De esta forma se podría establecer un límite de RUL para dicho elemento.

Con todo ello, atendiendo a los cuatro motores instalados en las grúas y a otras señales que pueden ayudar a determinar la calidad de los datos, se construye la tabla 2 con las principales señales a monitorizar en una grúa, y el uso de la misma.

Tabla 2. Señales críticas a monitorizar en una grúa. Fuente: Propia

DESCRIPCIÓN		TIPO DE SEÑAL	OBJETIVO
Motor de Elevación	Temperatura	Grados Centígrados	Predictivo
	Velocidad	Revoluciones por minuto (rpm)	Predictivo
	Intensidad	Amperios	Predictivo
	Vibraciones	Frecuencia	Predictivo
Motor de Distribución	Temperatura	Grados Centígrados	Predictivo
	Velocidad	Revoluciones por minuto (rpm)	Predictivo
	Intensidad	Amperios	Predictivo
	Vibraciones	Frecuencia	Predictivo
Motor de Orientación	Temperatura	Grados Centígrados	Predictivo
	Velocidad	Revoluciones por minuto (rpm)	Predictivo
	Intensidad	Amperios	Predictivo
	Vibraciones	Frecuencia	Predictivo
Motor de Translación	Temperatura	Grados Centígrados	Predictivo
	Velocidad	Revoluciones por minuto (rpm)	Predictivo

	Intensidad	Amperios	Predictivo
	Vibraciones	Frecuencia	Predictivo
Grúa en marcha o no		Digital	Informativo
Velocidad del viento		m/s	Informativo
Sobrecarga		Digital	Informativo
Pre-sobrecarga		Digital	Informativo
Ciclos de carga		-	Predictivo
Posicionamiento GPS		-	Informativo
Horas de funcionamiento		Horas	Informativo
Registro movimientos Carro		-	Informativo
Registro movimientos giro		-	Informativo
Posición del gancho		Metros	Informativo
Limitadores de momento		Digital	Informativo
Frenos		Digital	Informativo

4.2. ARQUITECTURA DE LA SOLUCIÓN DE DIGITALIZACIÓN

La elección de una arquitectura u otra supondrá diferentes ventajas e inconvenientes. Uno de los objetivos del TFM es realizar una arquitectura válida para cualquier tipo de grúa y/o fabricante.

Se propone una arquitectura de referencia para el Internet Industrial, (IIRA, del inglés Industrial Internet Reference Architecture), creada por el Consorcio de Internet Industrial o Industrial Internet Consortium (IIC), con el objetivo de facilitar el desarrollo de cualquier sistema.

El IIRA es una arquitectura de referencia para el IIOT que está basada en estándares, orientada a la resolución de problemas y generar valor para el negocio.

La IIRA describe cuatro capas en las que se analizan y resuelven los problemas de cada una de ellas, negocio, uso, funcional e implementación.

4.2.1. Capa de negocio

Trata los problemas orientados al negocio y son de interés para los responsables de las tomas de decisiones. Los conceptos clave en esta capa serán los siguientes:

Actores relevantes:

1. Responsable del departamento de Servicio Asistencia Técnica (SAT) y/o mantenimiento.
2. Cliente final o consumidor.
3. Integrador de sistemas.

Visión:

1. Disponer de un sistema de gestión global de todas las máquinas instaladas, que permita tomar decisiones empresariales con la ayuda de la información extraída de cada grúa.

Valores:

1. Aumentar la eficiencia y mejorar la fiabilidad de la grúa.
2. Reducir costes.
3. Mejorar los tiempos de respuesta en mantenimiento.

Objetivos clave:

1. Reducir costes de mantenimiento.
2. Reducir paradas en obra generadas por una avería en la grúa.
3. Establecer una estrategia empresarial.

Capacidades fundamentales:

1. Predicción de la capacidad de recursos.
2. Analizar la oferta del mercado.
3. Sistema centralizado que notificará las anomalías detectadas con el fin de mejorar los tiempos de respuesta en mantenimiento y atención al sistema.

4.2.2. Capa de uso

A continuación, se aborda cómo se espera que se utilice el sistema. El uso previsto es la implementación de una estrategia de mantenimiento predictivo a través de la digitalización de la grúa.

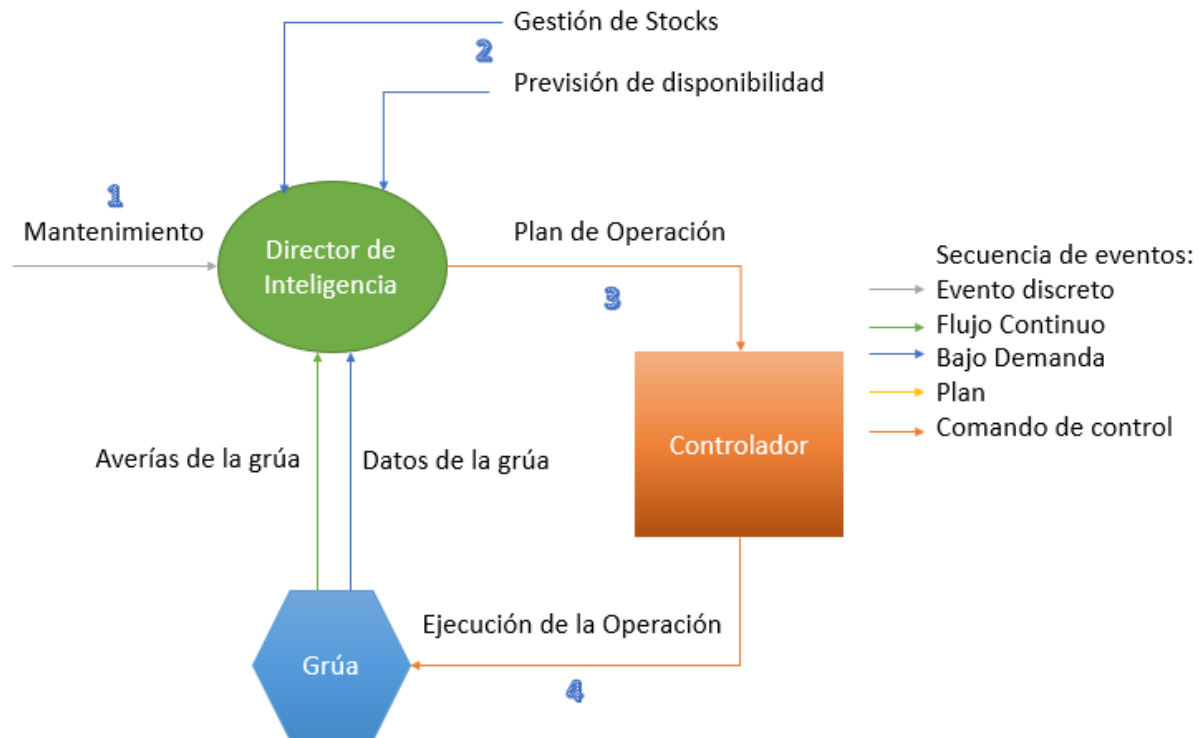


Figura 32. Punto de vista del uso. Fuente: Propia

La figura 32 representa gráficamente las interacciones y flujos de información:

1. El sistema recibe una alerta de mantenimiento.
2. El director de inteligencia recibe información necesaria de otros sistemas, como gestión de stocks y disponibilidad.
3. El director de inteligencia genera un plan de operación.
4. El controlador valida el plan de operación y da la orden correspondiente.

4.2.3. Capa funcional

La capa funcional comprende los siguientes dominios:

Dominio de control:

Se trata del dominio compuesto por los sensores y los controladores, debido a la naturaleza del proyecto estos se situarán en la propia grúa.

Dominio de operaciones:

Este dominio se encarga de supervisar el dominio de control. En él se monitoriza, se pronostica y se diagnostican los diferentes nodos (grúas), para posteriormente gestionar el sistema de la forma más óptima posible.

Dominio de información:

Es el dominio encargado de recopilación de funciones y datos procedentes del resto de dominios, se trata de un dominio centralizado que modela, transforma y analiza los datos para realizar modelos más óptimos para posteriormente comunicarse con el resto de dominios.

Dominio de aplicación:

En este dominio se implementan las interfaces de usuario, en este caso se dividen principalmente en dos, la interfaz de usuario de los gestores, encargada de la programación del sistema, optimizaciones y modificaciones. Y la interfaz de usuario de los administradores, quienes tomarán las decisiones de la compañía.

Dominio de negocio:

En este caso se centra en el ciclo de vida del producto y el sistema de mantenimiento predictivo para reducir al máximo los fallos del sistema, ya que el conjunto precisa de un alto nivel de robustez. Aquí deberán tenerse en cuenta todo tipo de sistemas como recursos empresariales (ERP), herramientas de gestión (CRM), sistemas de fabricación (MES), gestión de activos, pagos, recursos humanos, etc....

4.2.4. Capa de implementación

Para el caso de uso de este TFM, se decide una implementación mediante un patrón de arquitectura de tres niveles (figura 33) De esta forma:

1. En el Edge se recopilan los datos de los nodos finales, en este caso las grúas, donde habrá sensores, Gateways y dispositivo de computación.
2. El nivel de plataforma es donde se reciben y procesan los comandos de control. Aquí se dispondrá del dominio de operación e información. En el de operación se encargaría de todo lo relacionado con el hardware a nivel de actualizaciones de firmware, carga de programas, nuevas apps, páginas web...

Respecto al dominio de información, se trataría todos los datos y analítica de los mismos. Toda esta información será necesaria en el dominio de empresa.

3. El nivel de empresa dará soporte de decisiones mediante reglas y/o lógicas. Del mismo modo. En este nivel se reciben flujos de datos. Estarán los dominios de aplicación y de negocio.

PATRÓN DE ARQUITECTURA

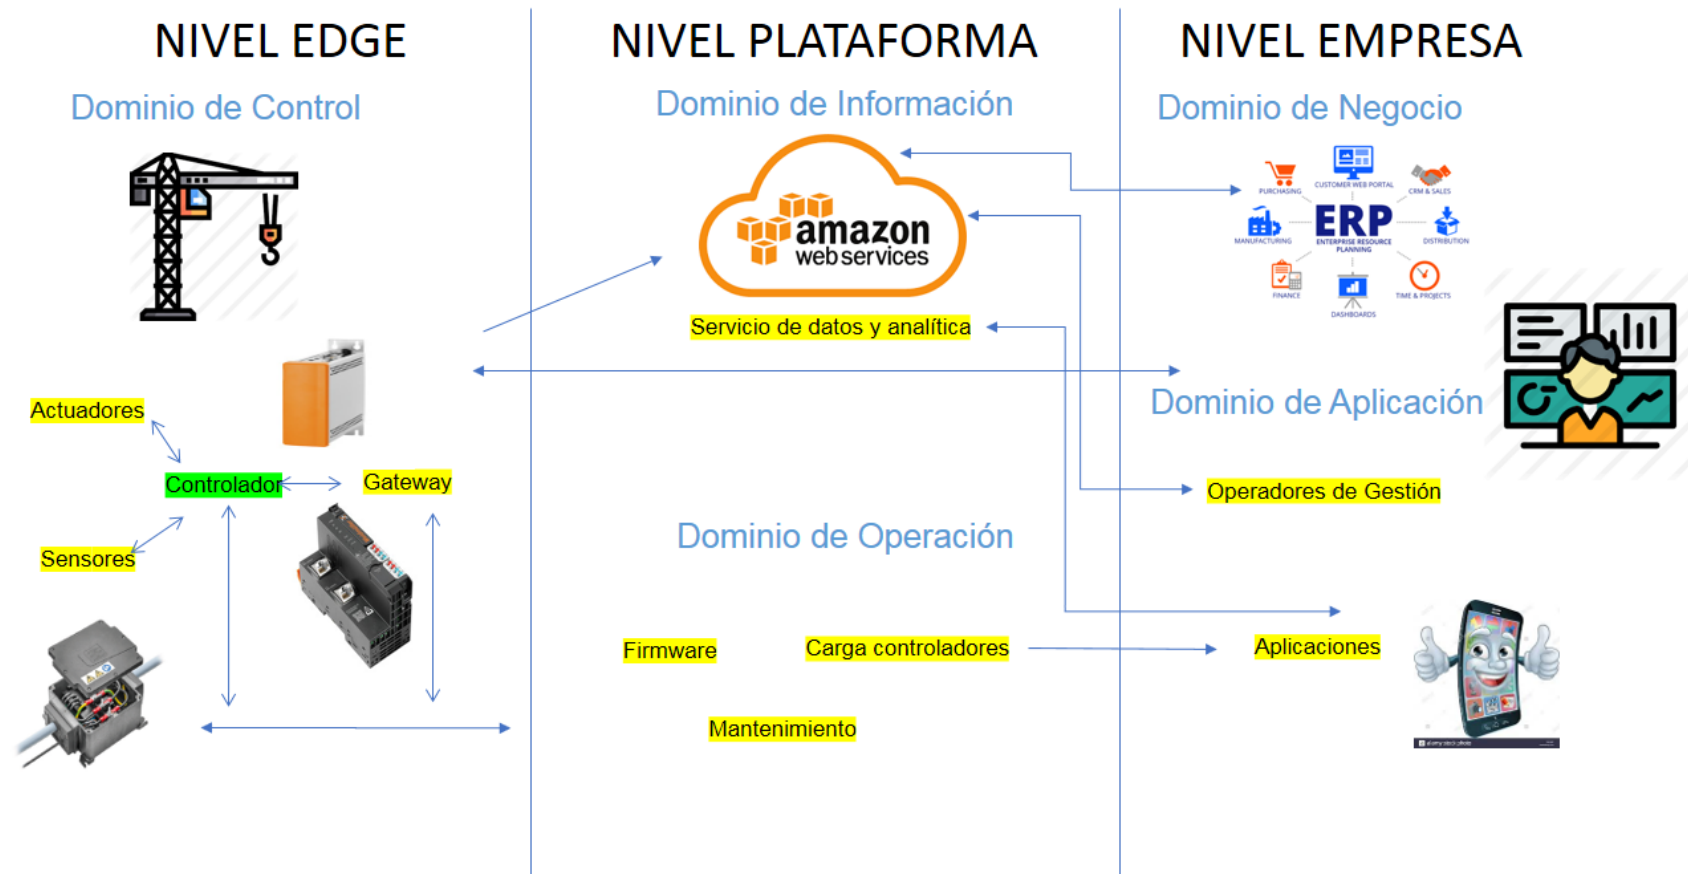


Figura 33. Arquitectura de control. Fuente: Propia

4.3. PROPUESTA DE IMPLEMENTACIÓN

En este apartado se explica el diferente hardware y software que se ha elegido para la implementación de la solución de digitalización.

4.3.1. Sensores

Las diferentes grúas que se han estudiado en el mercado, todas llevan un Controlador Lógico Programable o Programmable Logic Controller (PLC). Este dispositivo es quien controla el funcionamiento de la grúa. De esta manera, algunas de las señales de la tabla 1 se pueden leer del PLC existente o leer de señales físicas, como pueden ser contactores, de cara a monitorizar estados y contar horas de funcionamiento.

Sin embargo, es necesaria la instalación de algunos sensores que no están incluidos en las grúas con el objetivo de realizar el mantenimiento predictivo de los motores.

En base a ello y con el objetivo de intentar clasificar el mayor número posible de anomalías, se han elegido dos sensores que midan entre otras las variables representadas en la tabla 2. Estos sensores son de la marca Weidmüller y tienen unas características industriales, es decir, alto grado de Ingress Protection (IP), protocolo de comunicación robusto como Modbus TCP, y alta durabilidad de baterías, entre otras.

4.3.1.1. Sensor de Energía

El sensor denominado U-Sense Energy Drives (figura 34), permita una fácil colocación en instalaciones tanto nuevas como antiguas. Su comunicación es Modbus RTU ó Modbus TCP, y permite leer las siguientes variables:

1. Identificación del sensor
2. Estado On / Off
3. Número de ciclos
4. Horas de funcionamiento
5. RMS voltaje de cada fase
6. RMS intensidad de cada fase
7. Ángulo de fase por fase
8. Potencia Activa
9. Potencia Reactiva
10. Frecuencia
11. Consumo de energía
12. Diferencia de corrientes entre fases

13. Diferencia de tensión entre fases
14. Comportamiento en el arranque
15. Vibración: Dado por un sensor externo
16. Temperatura interna
17. Entrada analógica para conectar más sensores



Figura 34. U-Sense Energy Drives de Weidmüller. Fuente: Weidmüller

4.3.1.2. Sensor de temperatura y vibraciones

Como se comenta en el apartado anterior, el sensor U-Sense tiene la ventaja de que puede integrar a él más sensores externos, como vibraciones y temperatura. De esta forma, con el U-Sense Smart de Weidmüller se pueden recoger las variables de temperatura y vibraciones y posteriormente podrán leerse desde el Gateway (figura 35).




Figura 35. U-Sense Smart. Fuente: Weidmüller.

4.3.2. Gateway

Como se mencionaba anteriormente, uno de los objetivos del TFM es establecer una arquitectura tipo para cualquier modelo de grúa, por lo que se debe tender a tecnologías Open Source que permitan integrar cualquier tecnología y bus estándar del mercado, en caso de que se lean las señales del PLC.

Con estas premisas se elige un Gateway de IoT que permita leer señales de terceros en diferentes protocolos e incluso tenga la posibilidad de cablear nuevas señales en él mismo. El hecho de que el Gateway sea ampliable en señales permite que el sistema de digitalización diseñado pueda implementarse en máquinas ya antiguas, donde el añadir nueva sensórica no sea un impedimento. De esta manera se consigue que la solución propuesta sirva para diferentes grúas y fabricantes.

El Gateway que se elige es el UC20-WL2000-IoT de Weidmüller, que se muestra en la figura 36.



Figura 36. Gateway IoT de Weidmüller UC20-WL2000-IoT. Fuente: Weidmüller

Dicho Gateway permite la colocación de hasta 64 tarjetas de señales de entradas y salidas digitales, analógicas, temperatura, medidores de energía, contadores, tarjetas de seguridad.

Otra de las ventajas del dispositivo es que dispone de una memoria interna de 32 GB para el almacenaje de datos. En pequeñas aplicaciones podría servir como dispositivo Edge donde podrían ejecutarse aplicaciones predictivas con modelos de ML.

Por otro lado, el dispositivo permite utilizar el paquete de software Node-RED, que es una herramienta diseñada por IBM, basada en flujos para programar de manera visual y conectar diferentes hardwares, APIs y servicios en línea como parte del IoT.

En la figura 37 se puede apreciar la variedad de conectores para integrar los diferentes protocolos de comunicación que permitirán leer y escribir valores de y en terceros dispositivos.



Figura 37. Nodos de protocolos de comunicación de Node-RED. Fuente: Propia

Como se mencionará en capítulos posteriores, la plataforma IoT que se va a utilizar es Amazon Web Services (AWS). En la anterior figura (figura 37) se puede ver un nodo de NodeRed para comunicar mediante MQTT con dicha plataforma. La figura 38 muestra los parámetros generales de la configuración de la comunicación de dicho nodo, mientras la figura 39 muestra la configuración de la seguridad de la comunicación mediante infraestructura de firma digital con certificados digitales.

Connection		Certificates
Name	Gruas	
Type	MQTT Broker	
Client ID	Client ID	
Endpoint	a1fuhd8ew30yta-ats.iot.us-east-2.amazonaws.com	

Figura 38. Parámetros a configurar nodo AWS de Node-RED. Fuente: Propia

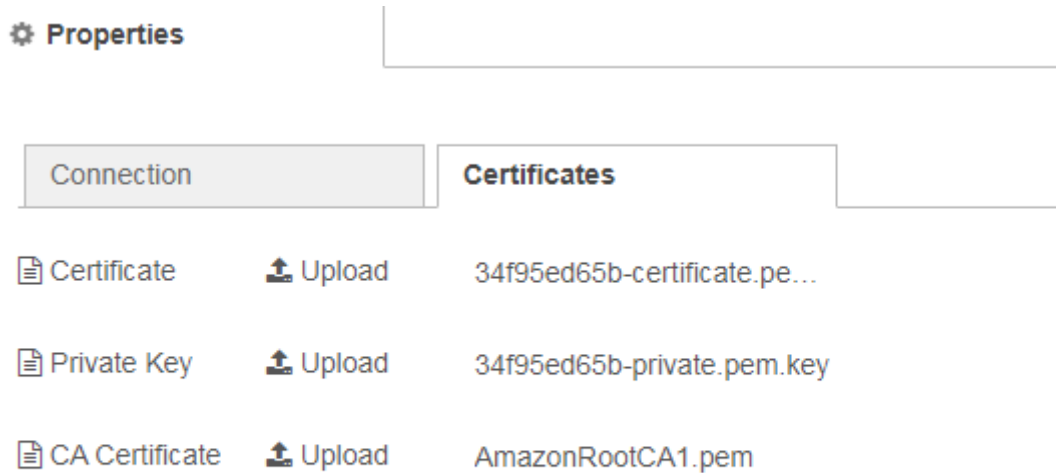


Figura 39. Certificados de seguridad de AWS en nodo de Node-RED. Fuente: Propia

De esta manera con la elección de este Gateway, se cumplen las premisas que se mencionaban con anterioridad, que sea Open Source y permita comunicar de forma segura con cuantos más protocolos estándar del mercado, y que tenga la posibilidad de añadir nuevas señales físicas que sean necesarias de cara a digitalizar una grúa.

4.3.3. Router 4G

Toda grúa debe tener conexión de red al exterior para la comunicación con plataformas IoT. En este caso se ha pensado en la colocación de un router 4G.

Entre la gran variedad de routers disponibles en el mercado con diferentes características, se valoran unas específicas para su integración en un sistema industrial:

1. La posibilidad de operar con diferentes frecuencias en los diferentes continentes.
2. Que sea un router industrial, ya que va a estar ubicado en un cuadro a varias decenas de metros de altura.
3. La necesidad de que permita conexiones seguras mediante Virtual Private Network (VPN).

Con estas premisas se elige el router IE-SR-4TX-LTE/4G de Weidmüller (figura 40) Este router permite hasta 10 conexiones Open VPN, tiene un rango de temperatura extendido de -30°C...70°C, e incluso hace Gateway de Modbus TCP/RTU, en caso de necesitar integrar un equipo de tercero en este protocolo.



Figura 40. Router IE-SR-4TX-LTE/4G de Weidmüller. Fuente: Weidmüller

4.3.4. Ordenador Industrial

Dada la función itinerante de una grúa torre, se considera adecuado la colocación de un Ordenador industrial o PC industrial, con el objetivo de tener la información en entorno local. De esta manera el almacenaje de la información no depende únicamente de la plataforma IoT. En caso de pérdida de comunicación el salvado de información se llevaría a cabo de forma local. Otra ventaja es la posibilidad de un preprocesado de información en el Edge y enviar al Cloud información sintetizada para su posterior análisis con aplicaciones analíticas desde la plataforma.

Por otro lado, la instalación de un PC Industrial también permitirá el despliegue de las aplicaciones de detección de anomalía mediante modelos de Machine Learning en entorno local, siguiendo el paradigma computacional de tipo Edge.

Se ha elegido el modelo UV20-B-IPC-2001.01 de Weidmüller como PC industrial de acuerdo con los requerimientos descritos (figura 41). Este dispositivo es un PC industrial con Windows 10 IoT, 4 GB de RAM y 60 GB de disco duro.



Figura 41. UV20-B-IPC-2001.01 de Weidmüller

4.3.5. Plataforma IoT

La elección de una u otra plataforma tendrá sus ventajas e inconvenientes. Tras la explicación de los diferentes tipos de plataformas dada en el punto 2.4.5., y volviendo a tener en cuenta el objetivo de estandarizar lo máximo posible, se decide utilizar una plataforma de propósito general como Amazon Web Services IoT (AWS).

El hecho de esta decisión viene dado por las ventajas que ofrecen este tipo de plataformas con servicios propios que facilitan la integración de cualquier instalación, a diferencia de las plataformas de código abierto que son más laboriosas o las plataformas industriales que tienen su principal objetivo en satisfacer y cubrir unas necesidades específicas del propio fabricante en la mayoría de los casos.

En la figura 42 se muestra la arquitectura de AWS. En ella, a diferencia de otras plataformas, se habla del concepto de cosas (Things), que engloba a sensores, actuadores y dispositivos. El bloque middleware viene representado por Message Broker, Thing Shadows, Rules Engine y los componentes de seguridad. Por último, en la capa de aplicación, Amazon proporciona diferentes servicios.

La arquitectura de AWS responde a sus cinco pilares básicos:

1. **Excelencia operativa**
2. **Seguridad:** Basándose en proteger la información y los sistemas. Sus principales objetivos son la confidencialidad e integridad de la información.
3. **Fiabilidad**
4. **Eficacia de rendimiento:** Los objetivos principales son la optimización de recursos.
5. **Optimización de costos:** Evitar gastos innecesarios.

AWS orienta al cliente final al correcto diseño de una arquitectura basándose en los objetivos en cuanto a estos cinco pilares.




Figura 42. Arquitectura de AWS. Fuente: Guth et al. (2018).

4.3.6. Aplicaciones informáticas en Cloud

El objetivo de recoger datos y almacenarlos en una plataforma IoT no es otro que extraer información a través de ellos. Dicha información resultará muy valiosa para la empresa y servirá para respaldar y mejorar el proceso de toma de decisiones. En este sentido, las plataformas IoT que se mencionaban con anterioridad disponen de la posibilidad de realizar diferentes aplicaciones con este fin. Para tener una visión global de la empresa, se consideran básicas de aplicación las siguientes:

1. Diseño de Dashboards: De esta forma de manera gráfica e intuitiva se podrá visualizar el estado actual de todo el parque instalado de grúas. Se podría tener acceso a cada una de ellas para ver los parámetros más importantes y a nivel de empresa mostrar indicadores claves de rendimiento o Key Performance Indicator (KPI).
2. Aplicaciones de Machine Learning: Como se ha mencionado en capítulos anteriores, el objetivo de este tipo de herramientas es utilizar algoritmos para encontrar patrones

y que de forma automática aprendan y sean capaces de predecir o ayuden a la toma de decisiones. (Murphy, K.P. 2012)

3. Business Intelligence (BI): Este concepto engloba a todos los anteriores, ya que es necesaria la recogida de datos, su integración y análisis, y por último su visualización. El objetivo final es ayudar a la empresa en la toma correcta de decisiones, que derivará en una mejora del rendimiento empresarial. El BI ayudará a la generación de informes, mantenimiento predictivo, toma de decisiones prescriptivas, control de stocks...

4.3.7. Pequeño material auxiliar

Hay que señalar que será necesario la utilización de pequeño material de cara a recoger las señales correspondientes que se citaban en la tabla 2. De esta manera:

1. Fuente de alimentación.
2. Switch comunicaciones
3. Relés
4. Bornas de carril

En la figura 43 se observa un montaje tipo con todo el hardware mencionado en los apartados anteriores, donde se observan los siguientes dispositivos de izquierda a derecha, relés, Gateway con tarjetas, switch, router, fuente de alimentación, bornas de carril y PC Industrial.



Figura 43. Ejemplo de montaje con el hardware seleccionado. Fuente: Propia.

4.3.8. Presupuesto

A continuación, se detalla el presupuesto de la aplicación. Es necesario mencionar que dicho presupuesto puede sufrir variaciones, sobre todo dado por el pequeño material a instalar, así como por el tráfico y almacenamiento de datos, que se verá aumentado en el tiempo a medida que el parque de grúas instalado siga creciendo.

El presupuesto se divide en diferentes partes que se presenta en formato tabla:

1. En la tabla 3 se muestra un presupuesto del material necesario a instalar por máquina.
2. En la tabla 4 se muestra un presupuesto por la implementación de la plataforma AWS.
3. En la tabla 5 se muestra un presupuesto de implantación y gestión del proyecto y mantenimiento a 10 años.

Tabla 3. Presupuesto Hardware y software por grúa a digitalizar. Fuente: Propia

DESCRIPCIÓN	COSTE UNITARIO	UNIDADES	TOTAL
U-Sense Energy Drives Weidmüller	150€	4	600€
U-Sense Smart Weidmüller	150€	4	600€
Gateway UC20-WL2000-IoT Weidmüller	300€	1	300€
Router 4G - IE-SR-4TX-LTE/4G Weidmüller	495€	1	495€
PC Industrial UV20-B-IPC-2001.01 Weidmüller	600€	1	600€
Pequeño material (bornas, relés, switch, Fuente de alimentación, cableado, etiquetado...)	300€	1	300€
Programación y configuración de la solución (Gateway, Router, IPC)	40 horas * 50€ /hora		2000€
Tarjeta SIM 4G *	6€ mensuales		
TOTAL, MATERIALES			4895€

El coste de la Tarjeta SIM 4G, es un coste anual de 72€ que deberá imputarse a la solución todos los años. A pesar de ser necesaria por equipo que se digitalice, es un coste fijo que debe ser contabilizado en la tabla 4, ya que son costos anuales.

Tabla 4. Presupuesto Servicios AWS. Fuente: AWS

DESCRIPCIÓN	COSTE UNITARIO	TOTAL
Tarjeta SIM 4G *	6€ / mensuales	72€/ año
Servidores Virtuales EC2 Amazon	0,0929 USD / hora	67,82 USD / Mes (Calculo con 730 horas mensuales) 813,84 USD / año
Almacenamiento S3	0,024 USD /GB mes	0,12 USD /5GB mes 1,44 USD / año
Dynamo DB, base de datos NoSQL	203,40 USD iniciales 57,95 USD / 100 GB mes	203,40 USD iniciales 695,4 USD año
Análisis de Datos		5000€ /año
TOTAL		1510,68 USD / año + 5000€ /año

Aplicando el cambio actual de 1 USD = 0,83€, se puede indicar que el coste anual de la suscripción de AWS sería entorno a los 6250€ anuales.

A esto habría que añadir los 72€ por equipo que se monte de consumo de datos por la tarjeta SIM.

Por último, queda pendiente realizar la tabla 5, donde se incluyen los gastos de gestión del proyecto.

Tabla 5. Presupuesto Gestión del proyecto. Fuente: Propia

DESCRIPCIÓN	COSTE UNITARIO	TOTAL
Consultoría, desarrollo e implementación	160 horas * 50€/hora	8000 €
Hora personal interno (3 personas)	160 horas * 25€/hora * 3 personas	12000€
TOTAL		20000€

Las 3 personas implicadas en el proyecto tienen los siguientes perfiles:

1. Ingeniero industrial especialista en electricidad.
2. Ingeniero informático. Supervisará también la parte de telecomunicaciones.
3. Analista de datos. Desarrollo de herramientas de mantenimiento predictivo y Business Intelligence.

Con estos presupuestos se puede calcular el coste del proyecto para una máquina digitalizada. Evidentemente, cuanto mayor sea el número de máquinas, la repercusión del coste total del proyecto en ellas será menor.

Tabla 6. Presupuesto Total del proyecto. Fuente: Propia

DESCRIPCIÓN	TOTAL
Coste de material por máquina	4895€
Tarjeta SIM 4G *	72€/ año
Plataforma IoT AWS	6250€
Consultoría del proyecto	20000€
TOTAL	
	31217€

El costo directo de cada máquina instalada por año es de 4967€.

Una vez calculada la inversión para la implementación del proyecto, el siguiente paso es calcular la ganancia. En este caso vendría dada por el ahorro en mantenimiento y pérdida de horas de producción.

El primer valor tras consultar a varias empresas del sector es complicado de obtener, ya que son datos que no divulgan por motivos comerciales. No obstante, y como cita. en su tesis doctoral Florez, M. (2015), el costo de mantenimiento anual de una grúa torre, depende de la marca y modelo, pero tras su estudio realizado, podría concluirse que el coste medio anual es de 7000€.

Respecto a la cuantía que supone que la máquina esté parada, según el software Generador de precios de Cype Ingenieros, para una grúa de 40 metros y 1000 kilogramos de carga, el alquiler mensual sería de 1.460€.

De esta manera, en un año, se podría concluir que el alquiler anual sería de $1460\text{€} / \text{mes} * 12 \text{ meses} = 17.520\text{€} / \text{año}$

En un año formado por 52 semanas, trabajando 5 días laborales, 5 horas diarias, da una cantidad de 1.300 horas anuales. Teniendo en cuenta un 10% de días que la grúa no opere por festivos, transporte..., se van a realizar los cálculos con 1.170 horas anuales.

Si se tiene en cuenta el alquiler anual y las horas de trabajo, da un valor de alquiler/horas anuales = $17.520\text{€} / 1.170 \text{ horas} = 15\text{€} / \text{hora}$. Por tanto, se puede concluir, que por cada hora que la máquina esté parada por avería, implica un coste de 15€.

A este coste habría que añadir otros derivados de la parada de la máquina, los cuales no pueden ser cuantificados. Este tipo de costes por ejemplo serían, penalizaciones por retraso en entrega de la obra, tiempo que están parados los trabajadores porque la grúa no funciona, materiales como el cemento que pueden estropearse si se detecta una anomalía en la grúa y no puede operar...

Una vez presentados los anteriores presupuestos, el siguiente paso es calcular el ROI, que viene dado por la siguiente fórmula:

$$\text{ROI} = (\text{Ganancia} - \text{Inversión}) / \text{Inversión};$$

En ella, la ganancia vendrá dada por el ahorro que se obtendrá al ejecutar el proyecto. Como se indicaba anteriormente, al no poder cuantificar de manera exacta los costes que implican una avería, no se podrá calcular de forma exacta la ganancia.

Sin embargo, se puede hacer una estimación. Para ello como se mencionaba con anterioridad, un mantenimiento medio anual de 4 visitas (mínimo 3 anuales según la norma

UNE 58-101-92) a la grúa tiene un coste estimado de 7000€, lo que viene a ser 1.750€ por visita. Con la ejecución del proyecto de digitalización de la grúa, esos 4 mantenimientos preventivos podrían convertirse en sólo uno, optimizando recambios y tiempos de avería. De ahí ya habría una ganancia de 5.250€ por grúa.

Si comparamos esta ganancia con los costes directos por grúa antes explicados, se obtiene una ganancia directa de $5.250€ - 4.967€ = 283 € / grúa$.

La implantación del proyecto se ha mencionado que eran 26.250€, por lo que se necesitarán $26.250€ / 283€ = 90$ grúas digitalizadas para amortizar el coste del proyecto.

Todos estos datos son sin tener en cuenta la ganancia dada por los costos no cuantificados de tener la máquina parada ya explicados anteriormente.

4.4. SISTEMA DE MANTENIMIENTO PREDICTIVO

La implantación de la arquitectura propuesta tiene como objetivo diseñar un sistema de mantenimiento predictivo.

Las principales ventajas de diseñar e instalar un sistema de estas características son reducir costes, evitar paradas innecesarias, reducir averías fatales, alargar la vida útil de los dispositivos y equipos y aumentar la productividad.

4.4.1. Definición del problema a resolver.

Desde el punto de vista eléctrico el principal mantenimiento de una grúa son los 4 motores, de las cuales disponen la mayoría de ellas. Por ello se entiende de vital importancia implementar un sistema de mantenimiento predictivo sobre los motores.

Son varios los factores que contribuyen al deterioro de un motor eléctrico, teniendo en cuenta que puede verse altamente influenciado en función del uso y condiciones ambientales donde se instale.

Según Merizalde, Y. et al. (2017), se puede hacer una primera clasificación del origen de las averías de los motores en función de las cinco categorías mostradas en la tabla 7, que abarcan desde factores ambientales, de operaciones, del propio equipo, de tipo humano y por temas eléctricos.

Tabla 7. Factores causante de las averías en los motores de inducción. Fuente: Merizade, Y. et al. (2017).

Factores ambientales	Factores de operación	Equipamiento	Factores humanos	Factores eléctricos
Temperatura	Vibraciones	Envejecimiento	Mala selección del motor	Transitorios debidos a cortocircuitos, fluctuaciones, armónicos...
Humedad	Sobrecarga	Calidad	Mal uso	Sobretensión
Óxido	Demasiados arranques	Defectos de diseño	Falta de mantenimiento	Bajo voltaje
Ventilación	Alineamiento	Defectos de fabricación	Mantenimiento erróneo	Tensión desequilibrada
Suciedad	Resonancia del sistema		Recambios inadecuados	Armónicos
Objetos extraños	Fricción del estator y rotor		Lubricación	Instalación eléctrica defectuosa

Las dos principales partes de un motor son el estator y el rotor. En las tablas 8 y 9 se analizan los principales fallos de estas partes desde el punto de vista eléctrico y mecánico.

Tabla 8. Principales averías en el estator. Fuente: Merizade, Y. et al. (2017).

ESTATOR			
Averías eléctricas		Averías mecánicas	
Factores para las averías	Averías	Averías	Factores para las averías
Vibración de los bobinados	Movimiento radial y tangencial Destrucción de la sujeción del bobinado Daño de aislamiento Cortocircuito	Ruido y vibraciones electromagnéticas Daño en el núcleo debido a la fricción con el estator Sobrecalentamiento	Mal funcionamiento
Fallo de aislamiento	Cortocircuito entre las fases y la tierra	Pérdida del núcleo Destrucción de sujeción de bobinado Disminución del rendimiento	Sobrecalentamiento
Alineación	Perforación y destrucción del aislamiento Tensión entre bobinado y tierra Descarga de corrientes a tierra	Montaje erróneo Daño durante el rebobinado Excesivo sobrecalentamiento	Mantenimiento
Transitorios	Destrucción del aislamiento	Sobrecalentamiento	Falta de ventilación

Tabla 9. Principales averías en el rotor. Fuente: Merizade, Y. et al. (2017).

ROTOR			
Averías eléctricas		Averías mecánicas	
Factores para las averías	Averías	Averías	Factores para las averías
Vibración de los bobinados	Movimiento radial y tangencial Destrucción de la sujeción del bobinado Daño de aislamiento Cortocircuito	Rotura Fallo en los rodamientos Fricción con el estator Estrés térmico y centrífugo Estrés en las palas y varillas	Fallos dinámicos
Fallo de aislamiento	Cortocircuito entre las fases y la tierra	Ruido electromagnético y vibraciones Daño del núcleo debido a la fricción con el estator Fallo en los rodamientos Huecos de corriente	Mal funcionamiento estático y dinámico
Fallos electromagnéticos	Desplazamiento, desviación y estrés de las varillas.	Montaje erróneo Daño durante el rebobinado Excesivo sobrecalentamiento	Mantenimiento
Fallos magnéticos	Varillas rotas Ruido Vibraciones	Fallo en los rodamientos	Sobrecalentamiento
		Sobrecalentamiento	Falta de ventilación

	Fallo en el giro Fallo en rodamientos Fricción con el estator	Ruido electromagnético y vibraciones Daño del núcleo debido a la fricción con el estator Fallo en los rodamientos Huecos de corriente	Cojinetes
--	---	--	-----------

Con todo ello se puede concluir que los principales motivos por los que se ve acortada la vida útil de un motor son los representados en la figura 44.

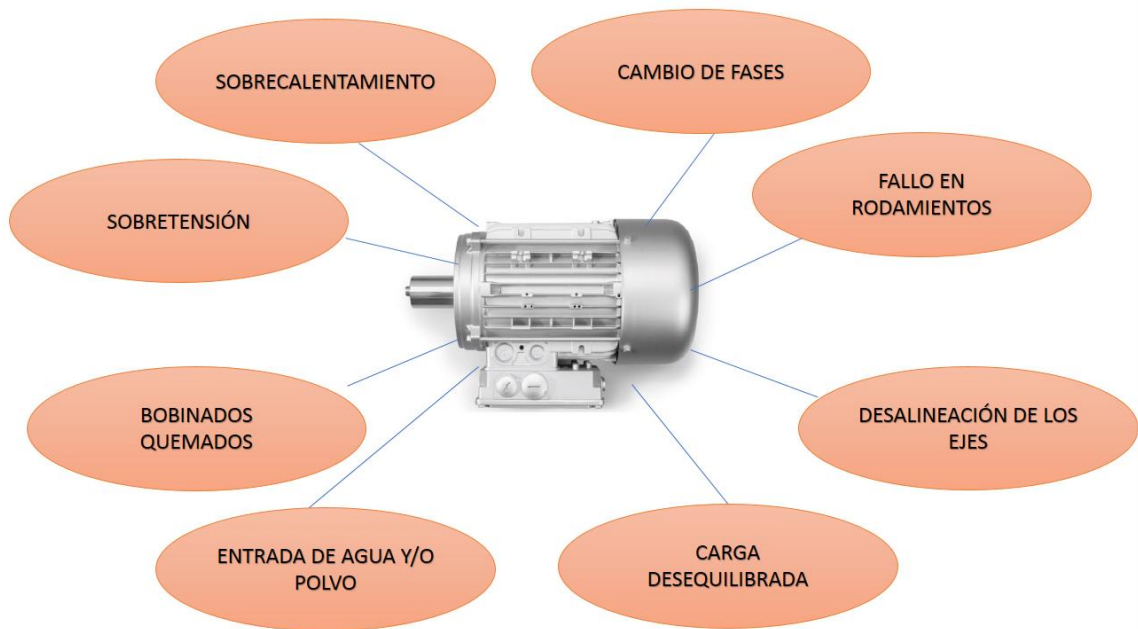


Figura 44. Causas por las que un motor eléctrico reduce su vida útil. Fuente: Propia

4.4.2. Diseño de la aplicación

El objetivo es implementar un sistema de monitorización del estado de la máquina para detectar mal funcionamientos de una forma temprana y de forma automática.

Puesto que cada máquina proporciona un conjunto de variables (véase tabla 2) se trata de un análisis de datos multivariantes. Dado que los datos sensoriales son secuenciales y tienen una evolución temporal, se trata además de un análisis de datos en series temporales. El problema resultante es complejo, detectar diferentes estados en datos multivariantes con

evolución temporal. Dadas estas características, los datos que analizar son de alta dimensionalidad.

Para la resolución se propone la implementación de modelos de Machine Learning que son capaces de analizar datos de alta dimensionalidad y alta complejidad. Existen básicamente tres aplicaciones que se detallan a continuación:

1. **Reconocimiento de fallos:** A partir de un conjunto de datos correspondiente a los diferentes estados de la máquina (normal y anomalía) se entrena un modelo con una técnica de ML supervisada. El modelo reconoce automáticamente si la máquina está en un estado normal o uno de los estados de fallos tipificados. Se trata de un problema de clasificación con múltiples clases (clasificación multiclase).

Como modelos de Machine Learning supervisados que se podrían utilizar para la implementación de este tipo de aplicación se pueden citar: Support Vector Machine (SVM) (Vapnik VM 1998), Red neuronal, Decision Tree (Quinlan, J.R. 2003) ó Random Forest (Breiman, L. 2001).

1. Ventajas:

- ❖ Reconoce automáticamente los diferentes fallos.
- ❖ Óptimo para gestionar el mantenimiento predictivo y la intervención / recambio necesario.
- ❖ Para cada fallo se sabe cuál es la intervención.

2. Inconvenientes:

- ❖ Cierta dificultad para obtener los datos de la máquina correspondiente a los diferentes fallos.
- ❖ Necesario disponer de datos correspondiente a los diferentes fallos.
- ❖ Necesaria taxonomía de fallos y posibilidad de reproducir estos estados. (Véase información en tabla 8 y 9).
- ❖ La cantidad de fallos puede ser alta y compleja de reproducir.

Esto puede ser perjudicial o peligroso utilizando una máquina real. A veces es necesario recurrir a simulaciones.

2. **DetECCIÓN DE ANOMALÍAS:** A partir de un conjunto de datos correspondiente al estado normal de la máquina se entrenan modelos de Machine Learning para reconocer una desviación lo suficientemente significativa del estado normal y que representan anomalías.

Para la detección de anomalías mediante técnicas no supervisadas (Chandola, V. et al. 2009), se pueden citar los siguientes algoritmos: One-class SVM, Autoencoders, Isolation Forest, Local outlier factor etc....

La detección de la anomalía se basa en la distancia calculada de la observación respecto al modelo base. Si dicha distancia supera un límite (outlier threshold) la observación es considerado un caso de anomalía.

1. Ventaja:

- ❖ La adquisición de datos es relativamente fácil (solo hace falta captar datos en estado normal).

2. Inconveniente:

- ❖ No proporciona detalle sobre el fallo detectado (solo si es anomalía o no).
- ❖ Necesario un experto para diagnosticar la máquina o planificar la intervención de mantenimiento.

Es útil para la monitorización en tiempo real del estado de la máquina, prevención de fallos en estado temprano y evitar averías mayores.

3. **Cálculo del tiempo restante de la vida útil (RUL)**: A partir de la monitorización del estado se puede extrapolar cuánto tiempo de vida útil le queda a la máquina.

Se utilizan modelos de predicción (modelos supervisados) que predicen el valor de una variable numérica, por ejemplo, tiempo de vida útil restante (Ran, Y, et al. 2019).

Modelos supervisados de regresión serían: SVM, Red neuronal, Decision Tree, Random Forest, etc.

Sin embargo, es necesario disponer de datos correspondientes a los diferentes estados de degradación para poder crear modelos de predicción del RUL. En el caso de un fabricante de grúas es difícil disponer de estos datos a medio plazo, aunque una recogida sistemática de los mismos durante un periodo prolongado de tiempo podría proporcionar un conjunto de datos para implementar este tipo de modelo (objetivo a medio plazo).

Conclusión: Analizando las diferentes opciones parece más viable implementar un modelo de detección de anomalías, puesto que la adquisición de datos es menos compleja. La aplicación de reconocimiento de fallo se debería implementar después de unos experimentos exhaustivos para generar conjuntos de datos correspondientes

a los diferentes fallos (requiere dedicación y participación de expertos, p.ej. fabricante de maquinaria/ o del componente). Esta aplicación sería factible a medio plazo.

Por último, para el cálculo del tiempo restante de vida útil (RUL) es necesario disponer de un conjunto de datos representativo de los diferentes estados de degradación. Por tanto, después de recoger sistemáticamente datos durante un tiempo largo de funcionamiento de la máquina o su generación a través de simulaciones, sería posible crear dicha aplicación analítica a medio/largo plazo.

4.4.3. Propuesta tecnológica del sistema

En el mercado existen diferentes herramientas para la implementación de las aplicaciones anteriormente descritas. Algunas de ellas están pensadas para mercados específicos dependiendo del fabricante y otras son más generalistas.

Si se habla de las primeras se podría citar la herramienta de Machine Learning de Weidmüller. El fabricante alemán de componentes eléctricos y dispositivos electrónicos centra su principal foco de negocio en fabricantes de maquinaria, por lo que su herramienta dispone de modelos más enfocados a este tipo de aplicaciones.

Este tipo de herramientas están pensadas para expertos en el proceso que se está analizando, sin necesidad de tener conocimientos específicos de científico de datos. La herramienta en primer lugar permite analizar y tratar datos de forma rápida e intuitiva. Se visualizan rápidamente todo el conjunto de datos (figura 45).

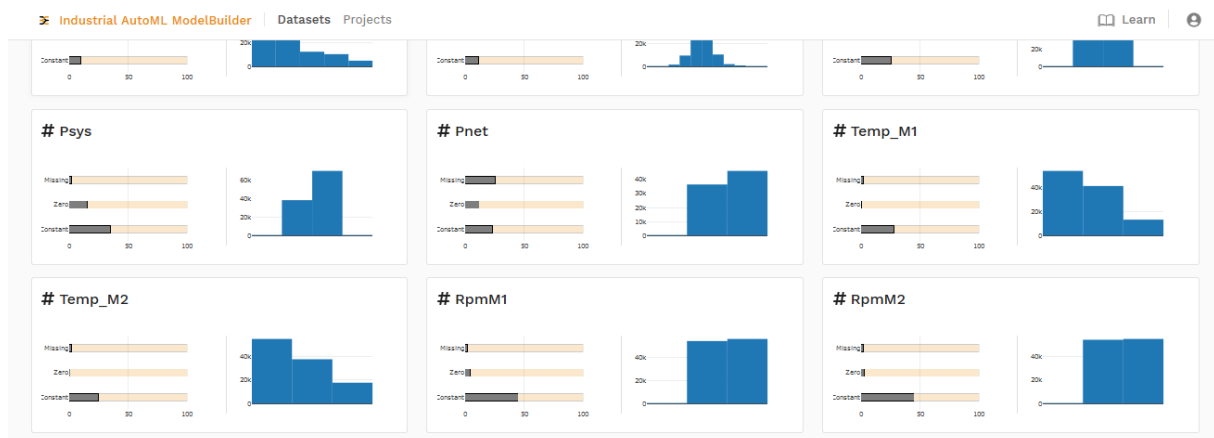


Figura 45. Dataset con la herramienta AML de Weidmüller. Fuente: Propia

De forma individual, permite acceder a los datos de cada atributo y ver valores estadísticos de los mismos y consultar la evolución de la señal en un rango de tiempo (figuras 46 y 47).



Figura 46. Datos de un atributo con la herramienta AML de Weidmüller. Fuente: Propia

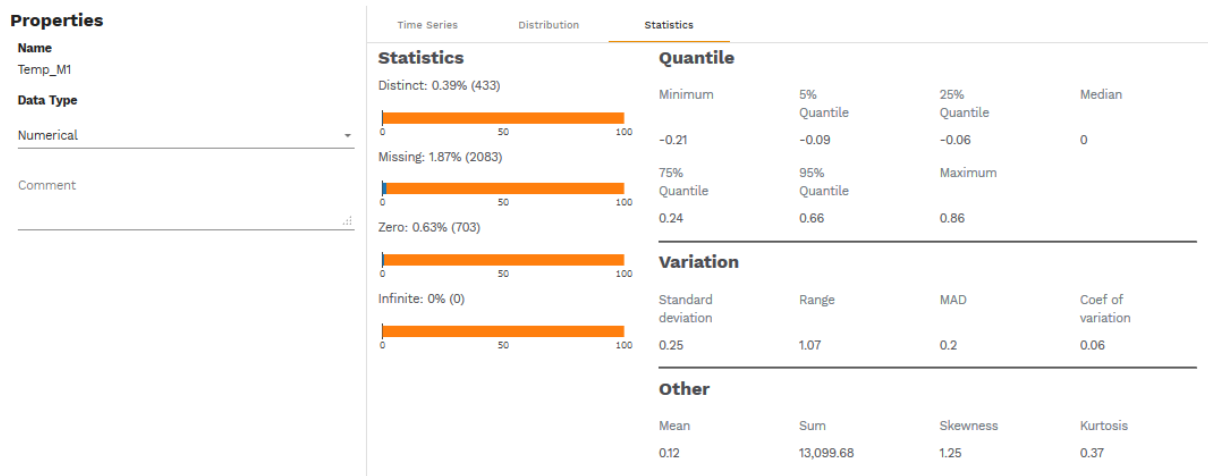


Figura 47. Valores estadísticos de un atributo con la herramienta AML de Weidmüller.

Fuente: Propia

Además de los atributos que se dispongan en el conjunto de datos, permite crear otra serie de atributos derivados mediante funciones matemáticas. Entre estas funciones se distinguen las transformaciones correspondientes al dominio del tiempo o el dominio de frecuencia. Las primeras corresponden a los siguientes atributos estadísticos:

1. Media.
2. Desviación estándar.
3. Media cuadrática (RMS).
4. Kurtosis.
5. Sesgo (Skewness).

A partir de aquí, se seleccionan los atributos que se consideren importantes para el proceso y se generan diferentes modelos en función de las características elegidas por el experto. De

los diferentes modelos generados, se indican la técnica seguida, el % de anomalías detectadas, el % de falsos positivos, qué peso tiene cada uno de los atributos seleccionados para calcular el modelo, así como los tiempos de ejecución y entrenamiento (figura 48).

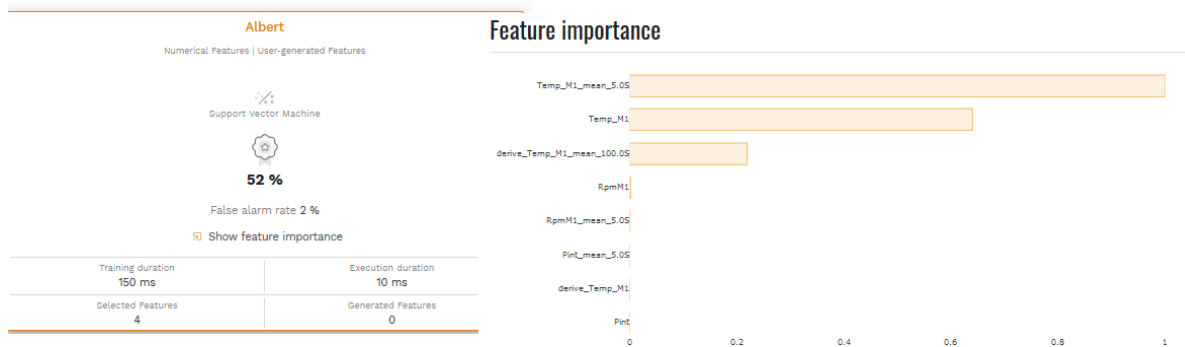


Figura 48. Ejemplo de modelo calculado con la herramienta AML de Weidmüller. Fuente: Propia

En una primera parte de tratamiento de datos, el experto marcará en el conjunto de datos diferentes anomalías detectadas en el proceso, y posteriormente la herramienta creará modelos donde habrá detectado más anomalías por técnicas supervisadas y de forma gráfica se hace una comparativa entre los diferentes modelos (figura 49).




Figura 49. Comparativa entre los modelos generados por la herramienta AML de Weidmüller. Fuente: Propia

La creación de los modelos tendría lugar en un entorno Cloud, donde se registran los datos, como puede ser la plataforma IoT, y el despliegue en este caso sería conveniente hacerlo en la capa Edge, como podría ser el PC industrial que se mencionaba anteriormente o incluso el Gateway de IoT con capacidad de procesamiento para ello.

En cuanto a las aplicaciones más generalistas, se podría mencionar la de Matlab con su Predictive Maintenance Toolbox y que es la elegida para realizar la prueba de concepto.

El procedimiento es similar a la herramienta de Weidmüller anteriormente descrita, se procesan los datos, se añaden nuevas características a través de transformaciones del dominio de tiempo o frecuencia, se marcan condiciones de anomalía o límites de fallos y se calculan los modelos.

4.4.4. Prueba de concepto o viabilidad con mantenimiento predictivo

El objetivo de esta prueba es testear diferentes algoritmos utilizados en las aplicaciones de mantenimiento predictivos con el toolbox de mantenimiento predictivo de Matlab.

Se partirá de un conjunto de datos de un compresor con dos motores. Este conjunto de datos fue obtenido en la Hannover Messe de 2018 en el stand de la empresa Weidmüller, quienes disponían de un compresor para provocar diferentes fallos y anomalías y comprobar cómo su herramienta de Machine Learning era capaz de detectar de forma automática los diferentes estados anómalos de funcionamiento. Por ello, en dicho conjunto hay diferentes tipos de mediciones y estados catalogados como normales y anómalos.

De esta manera, una vez creado y elegido el modelo de ML más adecuado, se aplicará sobre los datos originales y se realizará una predicción de las instancias marcadas originales no catalogadas, dando en este caso como resultado la predicción de los estados 1 (estado normal) ó 2 (anomalía).

Finalmente, se hará una comprobación visual con el estado de predicción.

Metodología seguida:

Los pasos que se van a seguir son los graficados en la figura 50.

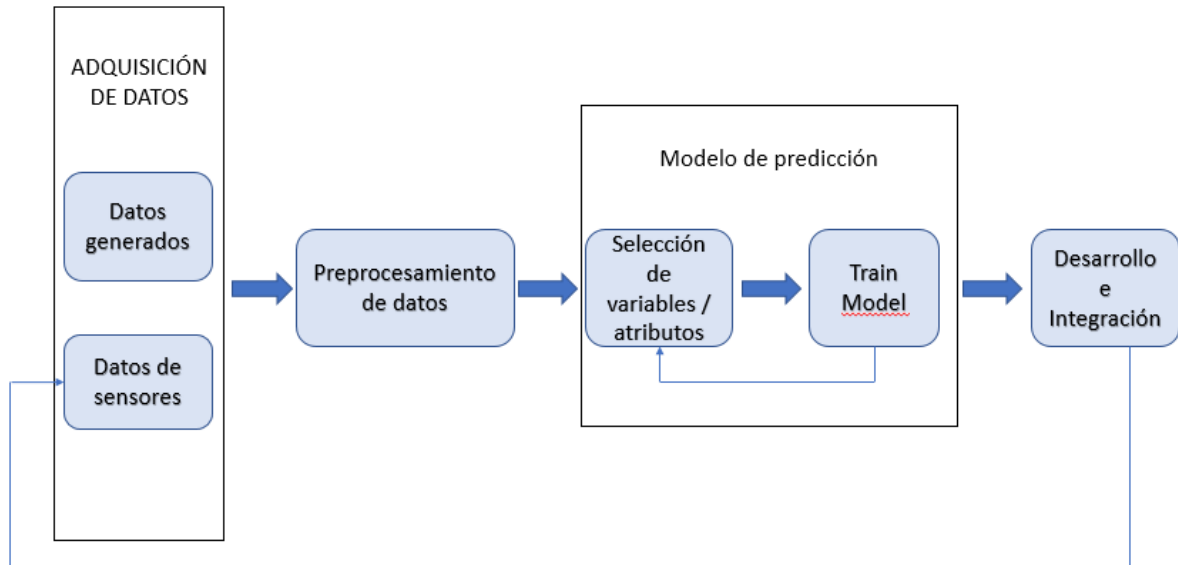


Figura 50. Metodología a seguir. Fuente: Propia

4.4.4.1. Preprocesamiento de los datos

1. Preparación de los datos: Partiendo del conjunto de datos original, se hace una primera clasificación de lo que se considera como funcionamiento anómalo o correcto. En la figura 51 se aprecia cómo de forma gráfica e intuitiva se pueden etiquetar estados normales (color verde) y anormales (color rojo) en el proceso.




Figura 51. Etiquetaje de los datos como normal o anómalo. Fuente: Propia

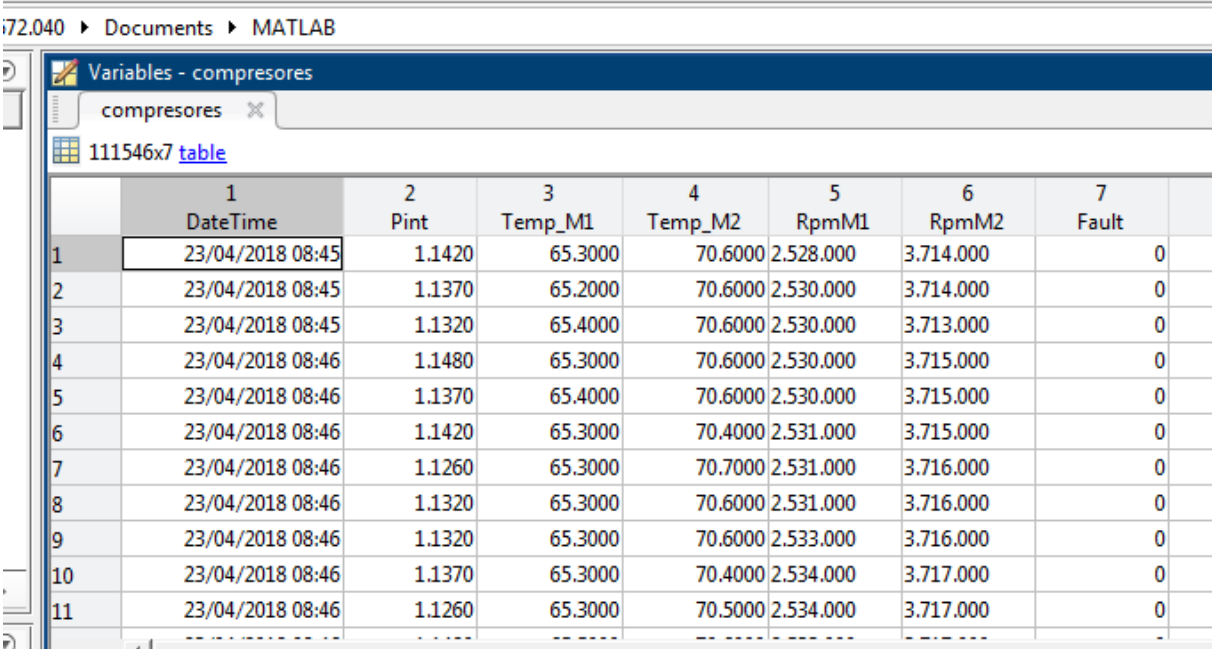
La gráfica anterior resulta muy útil para el experto del proceso a la hora de distinguir el estado normal o de anomalía.

2. El siguiente paso es preprocesar los datos y selección de variables. En el preprocesamiento es necesario eliminar datos erróneos o que tengan valores no

correctos, como por ejemplo vacíos. A continuación, es necesario seleccionar las variables que se consideren importantes en el proceso para determinar posibles anomalías y la clasificación de las mismas. En esta prueba de concepto es la variable fault (normal o anormal) etiquetada por el experto del área, que indica el estado de la máquina (condition indicator) que será estado normal o anomalía. Por ello, el conjunto de datos está compuesto por los siguientes 5 atributos y el campo fault que sirve como indicar de estado:

1. Presión del circuito dada en bares.
2. Temperatura del motor número 1 dada en grados centígrados.
3. Velocidad del motor número 1 dada en revoluciones por minuto (rpm).
4. Temperatura del motor número 2 dada en grados centígrados.
5. Velocidad del motor número 2 dada en revoluciones por minuto (rpm).
6. Con el paso 1 anteriormente mencionado, se establece una nueva variable estado o fault, con los siguientes valores:
 - 0: No etiquetado
 - 1: Estado Normal
 - 2: Anomalía

Una vez preparados los datos, se importan en Matlab (figura 52).



	1 DateTime	2 Pint	3 Temp_M1	4 Temp_M2	5 RpmM1	6 RpmM2	7 Fault
1	23/04/2018 08:45	1.1420	65.3000	70.6000	2.528.000	3.714.000	0
2	23/04/2018 08:45	1.1370	65.2000	70.6000	2.530.000	3.714.000	0
3	23/04/2018 08:45	1.1320	65.4000	70.6000	2.530.000	3.713.000	0
4	23/04/2018 08:46	1.1480	65.3000	70.6000	2.530.000	3.715.000	0
5	23/04/2018 08:46	1.1370	65.4000	70.6000	2.530.000	3.715.000	0
6	23/04/2018 08:46	1.1420	65.3000	70.4000	2.531.000	3.715.000	0
7	23/04/2018 08:46	1.1260	65.3000	70.7000	2.531.000	3.716.000	0
8	23/04/2018 08:46	1.1320	65.3000	70.6000	2.531.000	3.716.000	0
9	23/04/2018 08:46	1.1320	65.3000	70.6000	2.533.000	3.716.000	0
10	23/04/2018 08:46	1.1370	65.3000	70.4000	2.534.000	3.717.000	0
11	23/04/2018 08:46	1.1260	65.3000	70.5000	2.534.000	3.717.000	0

Figura 52. Datos importados en Matlab. Fuente: Propia

A la hora de trabajar este conjunto de datos, se seleccionan únicamente las instancias etiquetados como estado normal o anomalía (según la columna fault), puesto que se utilizarán algoritmos supervisados para la creación del modelo. El conjunto de datos reducido constituye el conjunto de datos para el entrenamiento del modelo.

En la figura 53 se puede ver un análisis exploratorio de los datos con una visualización de los datos graficados en Matlab.

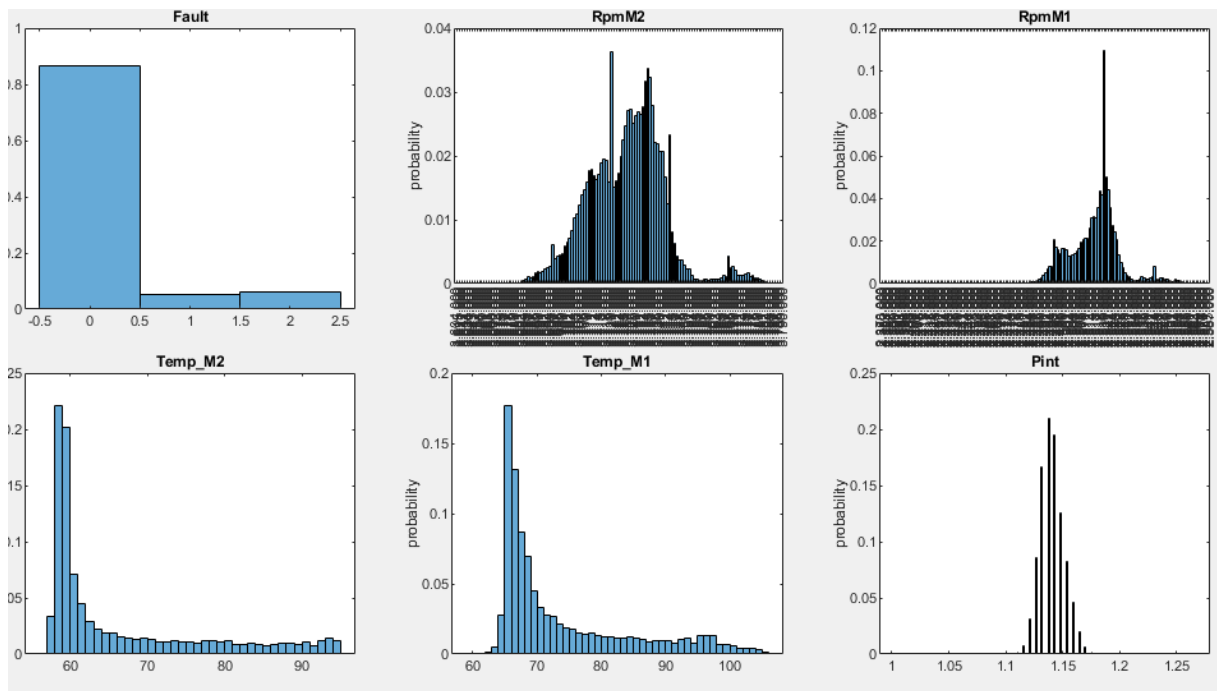


Figura 53. Dataset de los compresores en Matlab. Fuente: Propia

A partir de los atributos originales, se calculan atributos derivados, como la media y la desviación estándar. Para ello, el toolbox de Matlab dispone de una app denominada Diagnostic Feature Designer. (figura 55).

Primero se importa todo el dataset, que está formado por 6 atributos, entre ellos la variable de condition indicator (Fault), y comprende en total 10.463 instancias (figura 54).

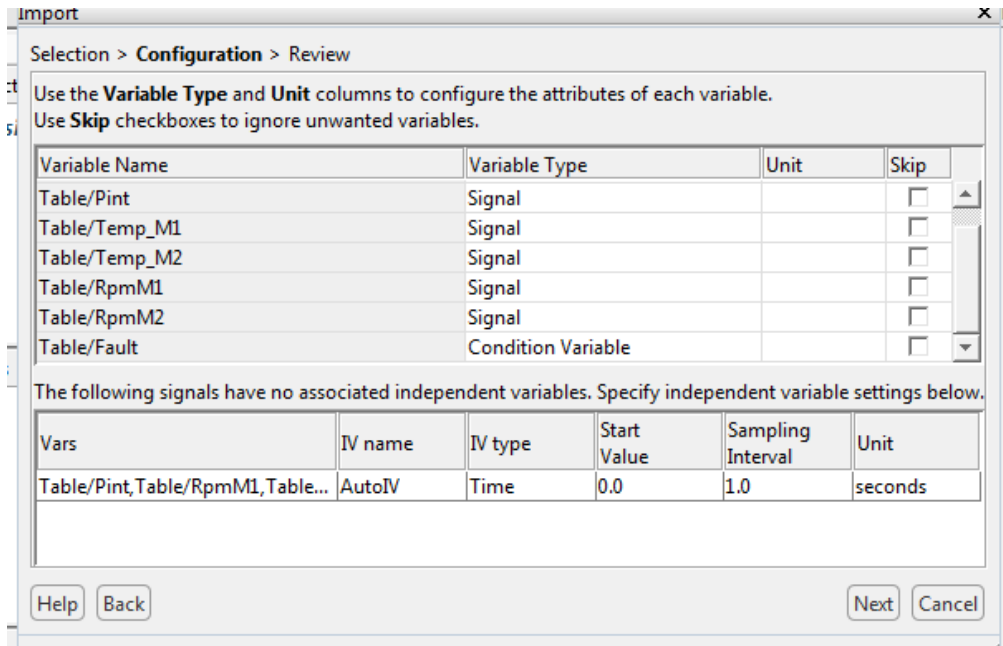


Figura 54. Número de instancias y variables. Fuente: Propia

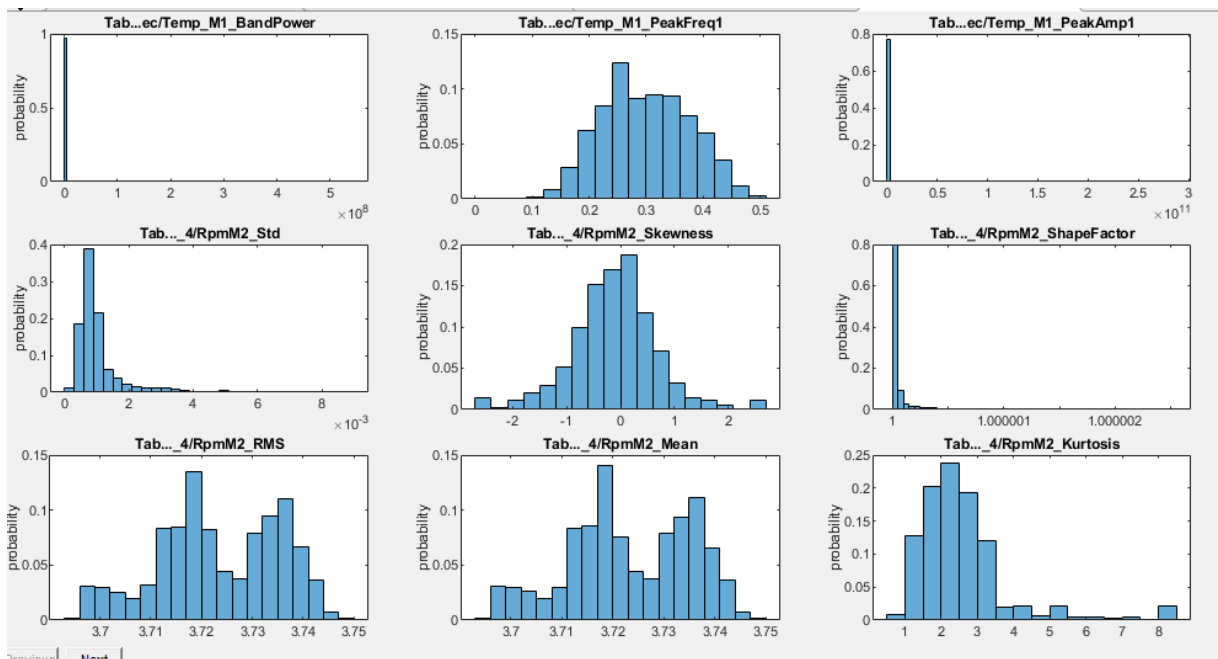


Figura 55. Visualización de nuevos atributos calculados. Fuente: Propia.

Del conjunto de atributos calculados, se crea un ranking que ayuda a determinar cuál de ellos es más relevante para la predicción de la variable Fault (figura 56).

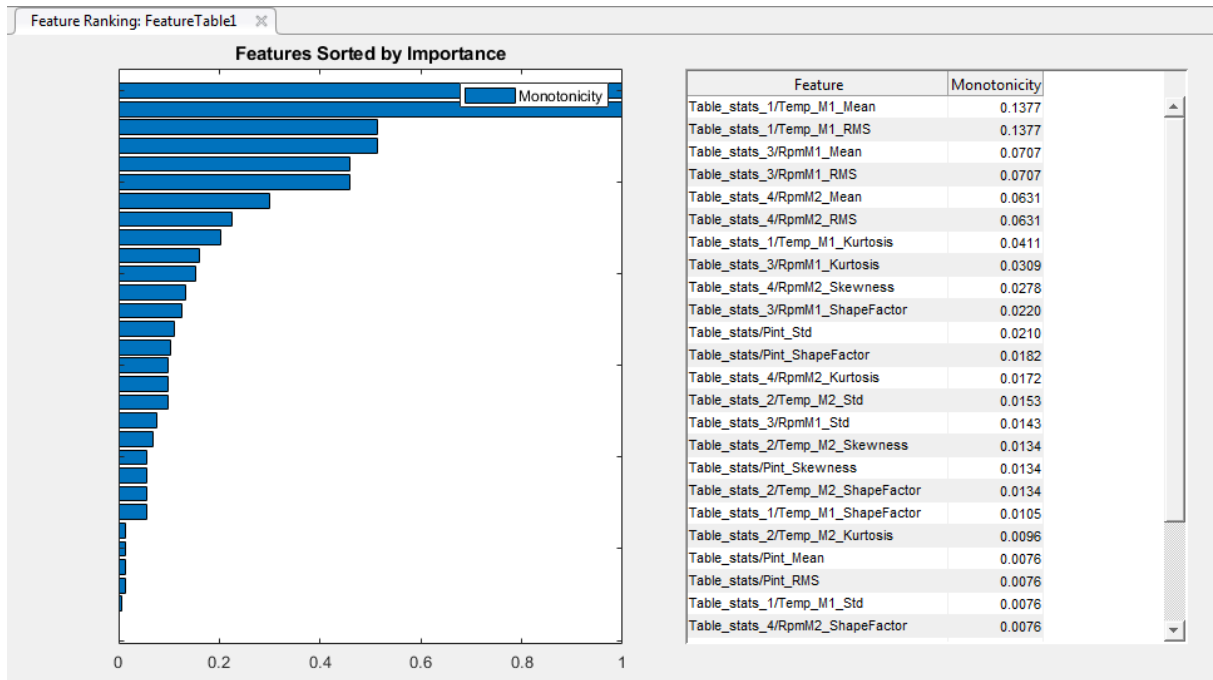


Figura 56. Features Ranking. Fuente: Propia.

4.4.4.2. Creación del modelo de predicción:

En este caso se han elegido los 5 atributos originales que se exportan para ser utilizados en la app de Matlab denominada Classification Learner y que implementa diferentes algoritmos de aprendizaje supervisado.

Siguiendo el esquema de la figura 50, se entrenan los diferentes modelos de predicción a partir de los atributos. En este caso se entrenarán 3 modelos diferentes mencionados con anterioridad en el apartado 4.4.2, árboles de decisión, K-Nearest Neighbor (KNN) y Support Vector Machine (SVM). Los tres modelos son de clasificación supervisada y se ha utilizado validación cruzada (Cross Validation). Esta técnica consiste en dividir el total de las muestras en dos conjuntos, realizar el análisis en uno de ellos y validarlo en el otro conjunto. (Schaffer, C. 1993). Este procedimiento se repite 5 veces, y finalmente se muestra un valor de exactitud en % (Accuracy), que determinará cuanto de preciso es el modelo calculado.

A continuación, se muestran los resultados obtenidos con cada uno de los tres modelos, analizando diferentes métricas de clasificación a través de la matriz de confusión:

Árboles de decisión:

Los resultados son los que se observan en la figura 57. El modelo tiene una exactitud promedia del 98,9%.

Model 1: Trained	
Results	
Accuracy	98.9%
Total misclassification cost	119
Prediction speed	~680000 obs/sec
Training time	0.70605 sec
Model Type	
Preset: Fine Tree	

Figura 57. Resultados Modelo árboles de decisión. Fuente: Propia

En la figura 58 se observa la matriz de confusión y el número de instancias por clase. Cabe señalar que la matriz de confusión tiene la estructura dada por la tabla 10, diferenciando los tipos de errores en la clasificación.

Tabla 10. Matriz de confusión. Fuente: Propia

Clase predicha		
Clase real	A	b
A	(TP)	(FN)
B	(FP)	(TN)

La matriz de confusión describe los casos de clasificación como:

- Verdaderos positivos (TP): número de instancias positivas clasificadas correctamente.
- Falso positivo (FP): número de instancias negativas clasificadas incorrectamente.
- Verdadero Negativo (TN): número de instancias negativas clasificadas correctamente.
- Falso Negativo (FN): número de instancias positivas clasificadas incorrectamente.




Figura 58. Matriz de confusión y número de instancias modelo árboles de decisión. Fuente: Propia

Según la figura 58, el modelo de árboles de decisión tiene una precisión (True Positive rate) para la clase 1 del 99,1% y para la clase 2 del 98,6%.

K-Nearest Neighbor (KNN):

En este caso en la figura 59 se observa que tras entrenar este modelo, la exactitud promedio es del 98,7%.

Results	
Accuracy	98.7%
Total misclassification cost	135
Prediction speed	~240000 obs/sec
Training time	0.76019 sec
Model Type	
Preset: Fine KNN	

Figura 59. Resultados Modelo K-Nearest Neighbor. Fuente: Propia

En cuanto a su matriz de confusión y número de instancias por clase, se observa en la figura 60 que se obtienen una precisión para la clase 1 del 98,9% y del 98,4% para la clase 2.




Figura 60. Matriz de confusión y número de instancias modelo k-Nearest Neighbor. Fuente: Propia

Support Vector Machine (SVM):

En este caso se obtienen los resultados mostrados en la figura 61.

Results	
Accuracy	82.3%
Total misclassification cost	1855
Prediction speed	~86000 obs/sec
Training time	54.031 sec

Model Type	
Preset:	Linear SVM

Figura 61. Resultados Modelo K-Nearest Neighbor. Fuente: Propia

Respecto a su matriz de confusión, se obtiene una precisión del 78,6% para la clase 1 y del 87,0% para la clase 2.




Figura 62. Matriz de confusión y número de instancias modelo Support Vector Machines.

Fuente: Propia

A partir de estos datos obtenidos y basándose en su matriz de confusión, se calculan cuatro métricas de evaluación de la calidad del modelo de ML para cada uno de los cuatro modelos de clasificación, que se presentan en la tabla 11 y se visualizan en la figura 63.

Las cuatro métricas que calcular son las siguientes:

1. **Exactitud o Accuracy**: Viene determinada por la siguiente ecuación:

$$Accuracy = \frac{TP + TN}{P + N}$$

Donde P y N son el total de instancias positivas (P) y negativas (N)

2. **Precisión**: Es el porcentaje de predicciones en una clase que son ciertas. Viene representando por la siguiente ecuación:

$$Precisión = \frac{TP}{TP + FP}$$

3. **Exhaustividad o recall**: Es la proporción de instancias clasificadas correctamente. Se representa mediante la siguiente ecuación:

$$Recall = \frac{TP}{TP + FN}$$

4. **Coefficiente de correlación de Mathew (MCC)**: Es el coeficiente de correlación entre las clasificaciones observadas y predichas. Está métrica tiene en cuenta clases no balanceadas. El rango de valor es entre -1 y 1. 1 corresponde a una predicción

perfecta, 0 una predicción aleatoria y -1 una predicción completamente incorrecta. Sigue la siguiente ecuación:

$$MCC = \frac{TP * TN - FP * FN}{\sqrt{(TP + FP) * (TP + FN) * (TN + FP) * (TN + FN)}}$$

Tabla 11. Métricas calculadas para los 3 modelos. Fuente: Propia

MODELO	EXACTITUD	PRECISIÓN	RECALL	MCC
Árboles de decisión	98,9%	98,9%	99,1%	97,69%
KNN	98,7%	98,78%	98,92%	97,38%
SVM	82,3%	88,5%	78,57%	65,08%

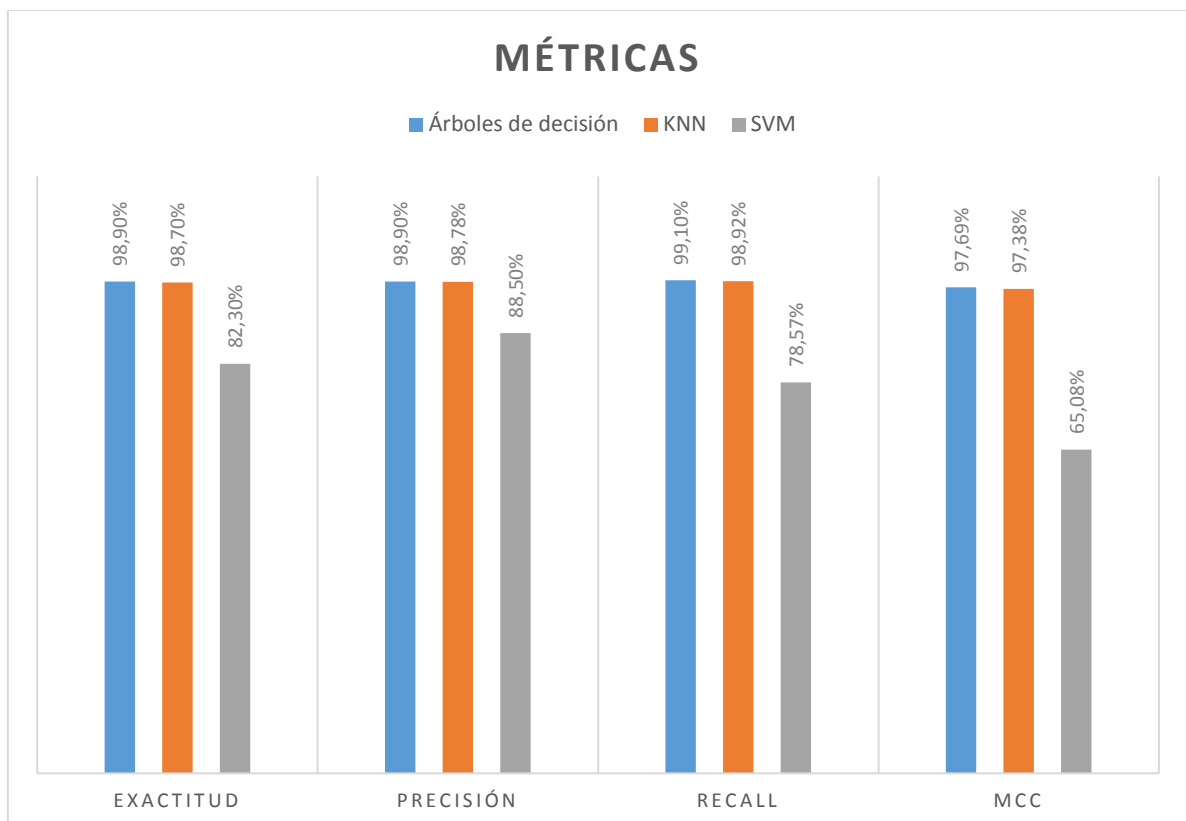


Figura 63. Métricas calculadas para árboles de decisión, KNN y SVM. Fuente: Propia.

Con todos estos datos se determina que el mejor modelo es el de árboles de decisión, con una exactitud del 98,9%. Las métricas precisión y recall aportan más detalle sobre la predicción del modelo. La precisión de un 98,9% informe que las predicciones son altamente precisas al ser las predicciones ciertas. La métrica de recall (exhaustividad) informa que el modelo es capaz de reconocer con un 99.1% los diferentes estados.

4.4.4.3. Despliegue del modelo de Machine Learning:

El siguiente paso será utilizar el modelo de ML creado con el conjunto de datos de validación, es decir, los datos no etiquetados con el valor 0 en la columna Fault. El objetivo de predecir los dos estados como 1 (estado normal) ó 2 (anomalía) con el árbol de decisión, que ha reportado los mejores resultados en la fase de entrenamiento del modelo.

Para ello se utiliza el modelo entrenando con la función $y_{fit} = A.predictFcn(B)$ de Matlab donde:

- A es el nombre del modelo, en nuestro caso Tree.
- B es el nombre del dataset, en nuestro caso compresores. Este debe tener las mismas columnas y nombres que el fichero que se utilizó para entrenar el modelo.

Por tanto, queda de la siguiente manera: $y_{fit} = Tree.predictFcn(compresores)$.

En la figura 64 se puede observar el resultado obtenido una vez aplicado el modelo Tree al conjunto de datos de validación.




Figura 64. Predicción con Tree. Fuente: Propia.

En la Figura 65 se observa un caso concreto de detección de anomalía. Antes de que la temperatura de ambos motores aumente, el atributo fault está a 1, que es estado normal.

Cuando la temperatura sube se observa como el modelo de predicción funciona correctamente al cambiar a 2 (anomalía).




Figura 65. Anomalía detectada prediciendo con Tree. Fuente: Propia.

4.4.4.4. Conclusión:

En esta prueba de concepto se ha podido verificar los diferentes pasos de creación de una aplicación analítica para la predicción de fallos en un conjunto de datos sensoriales de una máquina industrial. Los resultados de predicción del modelo de ML han sido muy buenos y el modelo correspondiente se ha obtenido tras realizar un entrenamiento iterativo con diferentes algoritmos. En el despliegue del modelo se ha podido comprobar la eficacia del modelo al verificar la verdadera detección de anomalías en el proceso con datos no vistos por el modelo durante el proceso de creación.

La prueba de concepto también ha sido útil para comprobar el componente experimental y el proceso iterativo de la creación de las aplicaciones de Machine Learning. Esta observación coincide con la metodología iterativa del estándar CRISP-DM para el desarrollo de proyectos de análisis de datos.

5. Conclusiones y trabajos futuros

5.1. CONCLUSIONES

Tal y como se recoge en la introducción, el principal problema que aborda este proyecto es digitalizar una grúa torre. Para ello se ha realizado un diseño del sistema de digitalización, explicando y especificando una arquitectura IoT, incluyendo los sensores, actuadores, Gateway, plataforma y aplicaciones de mantenimiento predictivo.

Gracias al desarrollo del estudio del arte en el sector de la construcción, se identifica que a pesar de los graves problemas que viene sufriendo el sector en los últimos años, las partidas de I+D destinadas al mismo son muy bajas. En concreto, en este tipo de máquinas se ha visto un vacío importante al no haber nada de este tipo implementado. Cabe recordar que todos los sectores apuestan fuerte por la I+D en busca de digitalizarse y conseguir beneficios en el desarrollo de su actividad. El apostar en este sentido, implica diferenciarse de la competencia.

Las principales contribuciones obtenidas tras la realización de este TFM son las siguientes:

1. Se han aplicado diferentes habilitadores de la industria 4.0 como IoT, Ciberseguridad, Cloud y Big Data y Analytics para resolver el problema expuesto anteriormente. Tal y como se explica en el apartado 4, tras analizar las señales críticas de una grúa, se ha diseñado un sistema de digitalización a nivel de hardware y software y una posterior valoración económica.
2. Posteriormente como se explica en el apartado 4.4, se ha diseñado un sistema de mantenimiento predictivo, que mediante técnicas de Machine Learning permitirá resolver los problemas planteados. Del mismo modo se han presentado dos soluciones comerciales diferentes, como son la herramienta de Machine Learning de Weidmüller, y el toolbox de mantenimiento predictivo de Matlab.
3. Finalmente se ha realizado una prueba de concepto con Matlab para la creación de modelos de predicción. Para ello como se explica en el apartado 4.4.4, se han probado diferentes algoritmos de clasificación por técnicas supervisadas como árboles de decisión, Support Vector Machine y K-Nearest Neighbor.

Con esta prueba de concepto se han obtenido resultados muy exactos, con métricas de calidad elevadas y posteriormente se ha podido comprobar la validez del modelo de predicción realizando un despliegue del mismo sobre un conjunto de datos de validación

Teniendo en cuenta estos resultados, se puede considerar a juicio del autor, que ha quedado demostrado en el desarrollo del TFM que han sido alcanzados los objetivos específicos planteados en el apartado 3:

1. Objetivo específico 1: Diseñar el despliegue de una arquitectura IoT para digitalizar una grúa. Este objetivo **se considera alcanzado** ya que, tal y como queda reflejado en el apartado de 4.2 de la memoria y según los resultados obtenidos, se ha realizado una arquitectura de referencia para el Internet Industrial (IIRA), atendiendo a las cuatro capas principales, negocio, uso, funcional e implementación, planteando para ello un patrón de arquitectura de tres niveles.
2. Objetivo específico 2: Especificar una implementación concreta del sistema diseñado. Este objetivo **se considera conseguido** ya que, tal y como queda reflejado en el apartado de 4.3 de la memoria y según los resultados obtenidos, se han especificado los sensores necesarios para la toma de señales críticas dentro de una grúa, las cuales a través de un Gateway se han integrado en una plataforma Cloud. Además, se han especificado los dispositivos para una computación Edge.
3. Objetivo específico 3: Diseñar un sistema de mantenimiento predictivo. Este objetivo **se considera cubierto**, ya que como queda reflejado en el apartado 4.4 de la memoria y según los resultados obtenidos, se plantean los problemas a resolver con las tablas 7 y 8, y se presentan diferentes herramientas de Machine Learning.
4. Objetivo específico 4: Prueba de viabilidad de los algoritmos de mantenimiento predictivo a través de una prueba de concepto. Este objetivo **se considera alcanzado**, ya que tal y como queda reflejado en el apartado 4.4 de esta memoria y según los resultados obtenidos, se han entrenado diferentes algoritmos y se ha creado un modelo de predicción cuya validez ha sido testada sobre un conjunto de valores obteniendo resultados muy satisfactorios.

Por consiguiente, se puede concluir que el objetivo principal, que es digitalizar una grúa torre utilizando habilitadores de la Industria 4.0, monitorizando el funcionamiento de la grúa en tiempo real, e implementando modelos de mantenimiento predictivo y detección temprana de averías para reducir tiempos de parada e incidencias, ha sido alcanzado tras la realización de este TFM.

5.2. LÍNEAS FUTURAS DE TRABAJO

Este trabajo que se ha expuesto sirve de base inicial para la implantación de una plataforma IoT y de los elementos de Machine Learning necesarios para la mejora de los mantenimientos predictivos de grúas torre. A continuación, se citan una serie de puntos en los que se podría seguir investigando:

1. Desarrollo de todas las soluciones de mantenimiento predictivo, creando para ello más modelos.
2. Tal y como se mencionaba en el apartado 2.4.9.2 se podría realizar la predicción del tiempo de vida restante de los motores y otros componentes de una grúa.
3. A partir de los datos, crear un sistema de gestión inteligente de mantenimiento. El mismo podría constar desde la creación de rutas para los técnicos, hasta un sistema que, a partir de las predicciones obtenidas por los modelos entrenados, se integre con otras herramientas de gestión empresarial para la gestión del mantenimiento e incluso el pedido automatizado de piezas de repuestos.
4. Desarrollo de modelos de predicción con datos reales de los motores de una grúa.
5. Aplicar Business Intelligence (BI) a todos los ámbitos de la empresa con el objetivo de respaldar y reforzar el proceso de toma de decisiones. El uso de BI por ejemplo para análisis prescriptivo, determinando qué valores deben ser modificados para mejorar ciertos indicadores clave de desempeño o Key Performance Indicator (KPI). Otro uso del BI podría ser optimizar el negocio del alquiler de grúas en función de sus KPIs correspondientes u ofrecer un servicio de monitorización online.

6. REFERENCIAS

- Alonso, R. S., Sittón-Candanedo, I., García, Ó., Prieto, J., & Rodríguez-González, S. (2020). An intelligent Edge-IoT platform for monitoring livestock and crops in a dairy farming scenario. *Ad Hoc Networks*, 98, 102047.
- Amazon Web Services <https://aws.amazon.com/es/>
- Angelopoulos, A., Michailidis, E. T., Nomikos, N., Trakadas, P., Hatziefremidis, A., Voliotis, S., & Zahariadis, T. (2020). Tackling Faults in the Industry 4.0 Era—A Survey of Machine-Learning Solutions and Key Aspects. *Sensors*, 20(1), 109.
- Arrieta, C. J. G. (2010). Aproximación al mantenimiento eléctrico predictivo de un motor impulsor de una bomba centrífuga utilizando inteligencia artificial. *INGE CUC*, 6(1), 103-118.
- Babiceanu, R. F., & Seker, R. (2019). Cyber resilience protection for industrial internet of things: A software-defined networking approach. *Computers in Industry*, 104, 47-58.
- Bagheri, B., Yang, S., Kao, H. A., & Lee, J. (2015). Cyber-physical systems architecture for self-aware machines in industry 4.0 environment. *IFAC-PapersOnLine*, 48(3), 1622-1627.
- Baheti, R., & Gill, H. (2011). Cyber-physical systems. The impact of control technology, 12(1), 161-166.
- Ballard-Bloomfield, K., D. Brook, How can big data enable more efficient and effective location decisions and planning? - area development, (2018) <https://www.areadevelopment.com/corporate-site-selection-factors/Q3-2018/big-data-efficienteffective-location-decisions-and-planning.shtml> (accessed May 30, 2019).
- Bell, R. N., McWilliams, D. W., O'donnell, P., Singh, C., & Wells, S. J. (1985). Report of large motor reliability survey of industrial and commercial installations. I. *IEEE Transactions on Industry applications*, 21(4), 853-864.
- Berger, R. (2016). Think act-digitization in the construction industry-building Europe's road to «Construction 4.0.». Roland Berger GMBH, Munich, Germany.
- Bierzynski, K., Escobar, A., & Eberl, M. (2017, May). Cloud, fog and edge: Cooperation for the future? In 2017 Second International Conference on Fog and Mobile Edge Computing (FMEC) (pp. 62-67). IEEE.

- Bilal, M., Oyedele, L. O., Qadir, J., Munir, K., Ajayi, S. O., Akinade, O. O., ... & Pasha, M. (2016). Big Data in the construction industry: A review of present status, opportunities, and future trends. *Advanced engineering informatics*, 30(3), 500-521.
- Breiman, L. Random forests. *Machine Learning* 45, 5–32 (2001).
- BOE 2003, Instrucción técnica complementaria MIE-AEM-2
<https://www.boe.es/buscar/pdf/2003/BOE-A-2003-14326-consolidado.pdf>
- Buyya, R., & Dastjerdi, A. V. (Eds.). (2016). *Internet of Things: Principles and paradigms*. Elsevier.
- CAMINOS, C. Y. P. ANÁLISIS TÉCNICO Y FINANCIERO DE LAS MÁQUINAS DE ELEVACIÓN.
- Cao, H., Wachowicz, M., Renso, C., & Carlini, E. (2019). Analytics everywhere: generating insights from the internet of things. *IEEE Access*, 7, 71749-71769.
- Chae, S., & Yoshida, T. (2010). Application of RFID technology to prevention of collision accident with heavy equipment. *Automation in construction*, 19(3), 368-374.
- Chakraborty, S., Gebraeel, N., Lawley, M., & Wan, H. (2009). Residual-life estimation for components with non-symmetric priors. *IEEE Transactions*, 41(4), 372-387.
- Chan B (2018) IoT vs. Industrial IoT: 10 Differences That Matter. URI: <https://www.iotforall.com/iot-vs-industrial-iot-differences-that-matter/>. Cited 8.7.2018.
- Chandola, V., Banerjee, A., & Kumar, V. (2009). Anomaly detection: A survey. *ACM computing surveys (CSUR)*, 41(3), 1-58.
- Chopra, R. (2020, February 19). *Rohit Chopra*. The Digital Transformation People. <https://www.thedigitaltransformationpeople.com/channels/the-case-for-digital-transformation/introduction-industry-4-0>
- de Soto, B. G., Agustí-Juan, I., Hunhevicz, J., Joss, S., Graser, K., Habert, G., & Adey, B. T. (2018). Productivity of digital fabrication in construction: Cost and time analysis of a robotically built wall. *Automation in Construction*, 92, 297-311.
- Drozdowski, P., & Duda, A. (2014). Influence of magnetic saturation effects on the fault detection of induction motors. *Archives of Electrical Engineering*, 63(3).
- Elhaj, M., Gu, F., Ball, A. D., Albarbar, A., Al-Qattan, M., & Naid, A. (2008). Numerical simulation and experimental study of a two-stage reciprocating compressor for condition monitoring. *Mechanical Systems and Signal Processing*, 22(2), 374-389.

Gardel Sotomayor, P. E. (2013). Aportaciones al mantenimiento predictivo de motores de inducción mediante una metodología de diagnóstico basada en el uso combinado de técnicas estadísticas y redes neuronales artificiales.

Generador de precios, CYPE Ingenieros

http://www.generadordeprecios.info/obra_nueva/Actuaciones_previas/Andamios_y_maquinaria_de_elevacion/Gruas_torre/Alquiler_de_grua_torre.html#gsc.tab=0

Gerbert, P., Castagnino, S., Rothballer, C., Renz, A., & Filitz, R. (2016). Digital in Engineering and Construction: The Transformative Power of Building Information Modeling. BCG-The Boston Consulting Group.

González-Vidal, A., Moreno-Cano, V., Terroso-Sáenz, F., & Skarmeta, A. F. (2016). Towards energy efficiency smart buildings models based on intelligent data analytics. *Procedia Computer Science*, 83, 994-999.

Guth, J. et al. (2018). Internet of Everything: Algorithms, Methodologies, Technologies and Perspectives. Singapore: Springer Singapore.

Hampson, K., Kraatz, J. A., & Sanchez, A. X. (Eds.). (2014). R&D investment and impact in the global construction industry. Routledge.

Han, S., Lee, S. H., & Peña-Mora, F. (2012). A machine-learning classification approach to automatic detection of workers' actions for behavior-based safety analysis. In *Computing in Civil Engineering (2012)* (pp. 65-72)

Higgs, PA, Parkin, R, Jackson, M, Al-Habaibeh, A, Zorriassatine, F, & Coy, J. "A Survey on Condition Monitoring Systems in Industry." *Proceedings of the ASME 7th Biennial Conference on Engineering Systems Design and Analysis*. Volume 3. Manchester, England. July 19–22, 2004. pp. 163-178.

Gartner. (2017, February 7). Gartner. <https://www.gartner.com/en/newsroom/press-releases/2017-02-07-gartner-says-8-billion-connected-things-will-be-in-use-in-2017-up-31-percent-from-2016>

Kanan, R., Elhassan, O., & Bensalem, R. (2018). An IoT-based autonomous system for workers' safety in construction sites with real-time alarming, monitoring, and positioning strategies. *Automation in Construction*, 88, 73-86.

Kim, K. J., & Tagkopoulos, I. (2019). Application of machine learning in rheumatic disease research. *The Korean journal of internal medicine*, 34(4), 708.

Larrodé, E., Pellicer, E. L., & de Marco, A. M. (1996). Grúas. Reverte.

- Lee, U. K., Kim, J. H., Cho, H., & Kang, K. I. (2009). Development of a mobile safety monitoring system for construction sites. *Automation in Construction*, 18(3), 258-264.
- Lee, W. J., Wu, H., Yun, H., Kim, H., Jun, M. B., & Sutherland, J. W. (2019). Predictive maintenance of machine tool systems using artificial intelligence techniques applied to machine condition data. *Procedia CIRP*, 80, 506-511.
- Li, Z., Wang, K., & He, Y. (2016). Industry 4.0-potentials for predictive maintenance. *Advances in Economics, Business and Management Research*.
- Liu, B., Lin, J., Zhang, L., & Kumar, U. (2019). A dynamic prescriptive maintenance model considering system aging and degradation. *IEEE Access*, 7, 94931-94943.
- Lucero, S. (2016). IoT platforms: enabling the Internet of Things. Estados Unidos: IHS Technology. <https://cdn.ihs.com/www/pdf/enabling-IOT.pdf>
- Mantenimiento predictivo con MATLAB*. (n.d.). MATLAB & Simulink. Retrieved February 6, 2021, from https://es.mathworks.com/campaigns/offers/predictive-maintenance-with-matlab.confirmation.html?ab_test=b_version
- MATLAB Documentation - MathWorks España*. (n.d.). Mathworks. Retrieved February 6, 2021, from <https://es.mathworks.com/help/supportpkg/raspberrypi/ref/publish-and-subscribe-to-mqtt-messages.htm>
- Mayer-Schönberger, V., & Cukier, K. (2013). *Big data: A revolution that will transform how we live, work, and think*. Houghton Mifflin Harcourt.
- Merizalde, Y., Hernández-Callejo, L., & Duque-Perez, O. (2017). State of the art and trends in the monitoring, detection and diagnosis of failures in electric induction motors. *Energies*, 10(7), 1056.
- Miller, C., & Meggers, F. (2017). Mining electrical meter data to predict principal building use, performance class, and operations strategy for hundreds of non-residential buildings. *Energy and Buildings*, 156, 360-373.
- Mobley, R. K. (2002). *An introduction to predictive maintenance*. Elsevier.
- MQTT - The Standard for IoT Messaging*. (n.d.). MQTT. Retrieved February 6, 2021, from <https://mqtt.org/>
- Murphy, K. P. (2012). *Machine learning: a probabilistic perspective*. MIT press.
- Node-RED. (n.d.). Node-RED. Retrieved February 6, 2021, from <https://nodered.org/>
- Norma UNE 58-101-92 <https://www.boe.es/buscar/doc.php?id=BOE-A-2003-14326>

- Observatorio industrial de la construcción. El sector de la construcción. Informe 2019
<http://www.observatoriodelaconstruccion.com/informes/detalle/informe-sobre-el-sector-de-la-construccion-2019>
- O'Donovan, P., Gallagher, C., Leahy, K., & O'Sullivan, D. T. (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.
- O.M. 10/2013 del 19 de Febrero https://www.ccn-cert.cni.es/publico/seriesCCN-STIC/series/400-Guias_Generales/401-glosario_abreviaturas/index.html
- Perspectives, G. C., & Economics, O. (2013). *Global Construction 2025. A global forecast for the construction industry to 2025*. London: Global Construction Perspectives and Oxford Economics
- Quinlan, J.R.: C4.5: Programs for Machine Learning by J. Ross Quinlan. *Machine Learning* 16(3), 235–240 (1993)
- Reinventing Construction: A Route to Higher Productivity, The McKinsey Institute, February 2017
- Russom, P. (2011). Big data analytics. TDWI best practices report, fourth quarter, 19(4), 1-34.
- Schaffer, C. (1993). Selecting a classification method by cross-validation. *Machine Learning*, 13(1), 135-143.
- Sigma <http://web.sigma.net/nota/418/qu-es-un-erp-y-cmo-puede-transformar-una-agencia-de-viajes.html>
- Taleb, T., Samdanis, K., Mada, B., Flinck, H., Dutta, S., & Sabella, D. (2017). On multi-access edge computing: A survey of the emerging 5G network edge cloud architecture and orchestration. *IEEE Communications Surveys & Tutorials*, 19(3), 1657-1681.
- Teizer, J., & Cheng, T. (2015). Proximity hazard indicator for near miss location recording and mapping of workers-on-foot interactions with construction equipment and geo-referenced hazard areas. *Automation in Construction*, 60, 58-73.
- Trost, S. M., & Oberlender, G. D. (2003). Predicting accuracy of early cost estimates using factor analysis and multivariate regression. *Journal of construction Engineering and Management*, 129(2), 198-204.
- Vapnik VN. *Statistical Learning Theory*. New York: John Wiley & Sons; 1998
- Vega Arias, J. (2007). Grúa torre. El Cid Editor. <https://elibro-net.ehu.idm.oclc.org/es/ereader/eHu/34446?page=5>

- Verstraete, D.; Ferrada, A.; Droguett, E.L.; Meruane, V.; Modarres, M. Deep learning enabled fault diagnosis using time-frequency image analysis of rolling element bearings. *Shock Vib.* 2017, 2017, 5067651.
- Wang, T., Han, Q., Chu, F., & Feng, Z. (2019). Vibration based condition monitoring and fault diagnosis of wind turbine planetary gearbox: A review. *Mechanical Systems and Signal Processing*, 126, 662-685.
- Weidmüller Machine Learning
https://www.weidmueller.com/int/company/press/trade_press_news/machine_learning_easy_to_use_without_expert_knowledge_in_data_science.jsp
- World Economic Forum, Geneva, Switzerland,
http://www3.weforum.org/docs/Future_Scenarios_Implications_Industry_report_2018.pdf (2018), Accessed 8th Aug 2018
- World Economic Forum Shaping the future of construction - future scenarios and implications for the industry
- Zhang, Y., Luo, H., & He, Y. (2015). A system for tender price evaluation of construction project based on big data. *Procedia Engineering*, 123, 606-614.
- Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., & Gao, R. X. (2019). Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 115, 213-237.


Anexo A. Hojas de características

En este apartado se incluyen las hojas de características de los dispositivos propuestos en el apartado 4.3 de la memoria.

U-Sense Energy Drives de Weidmüller:

u-sense energy drives – the Motor Visualisation Box

Weidmüller u-sense energy drives enables the simple integration of an electric motor into IIoT – both in an existing electrical infrastructure and in new or existing data networks. With u-sense energy drives, electrical values of a single- or three-phase consumer can be determined. In combination with other hardware and software products, a continuous data communication from sensor to cloud can be established.



Picture 6: Simple Industrial IoT integration of electric motors

3.1 Simple and fast Integration

Due to the robust and user-friendly connection technology, u-sense energy drives can be integrated particularly quickly into existing infrastructures. The housing system is protected according to IP65 and allows for use in almost all areas of an industrial plant. A separate power supply ensures the constant availability of the system, so that data can be transmitted at any time without time delay.





2.2 Reliable data communication

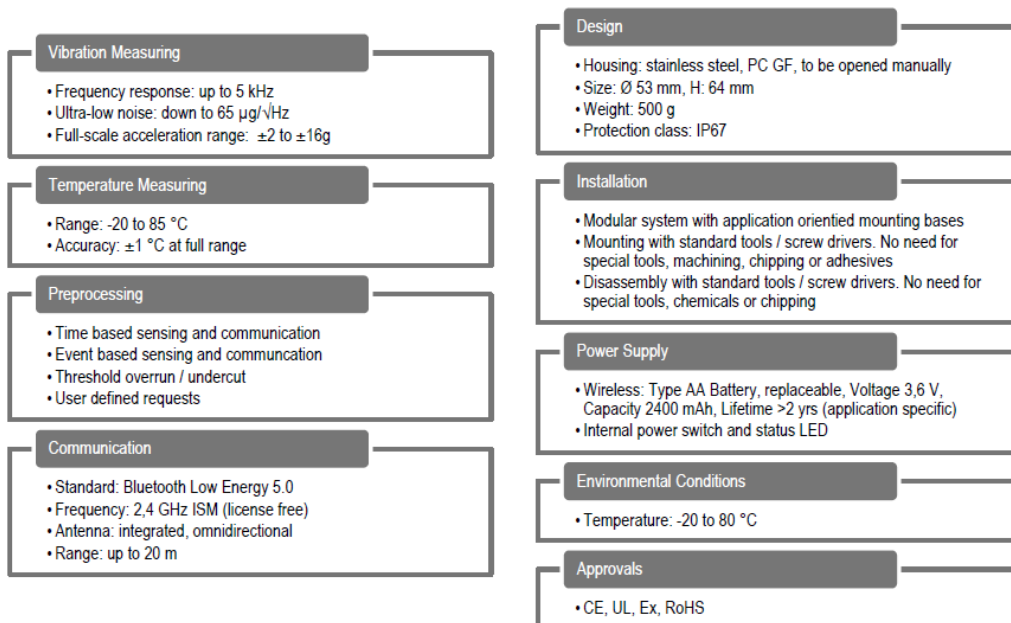
Data communication is via Modbus RTU protocol and RS485 bus line according to IEC 61158, ensuring reliable transmission even over long distances, which further facilitates the integration of u-sense energy drives into existing infrastructures. In combination with the IIoT controller u-control 2000 and the visualisation software u-create PROCON-WEB, the communicated data can be visualised locally with an on-premise solution. Both products are part of the Weidmüller u-mation product portfolio. Furthermore, the conversion of the data into an OPC UA protocol is also possible. This standard enables data exchange within a platform-independent and service-oriented architecture.

2.3 Comprehensive condition monitoring and data pre-processing

u-sense energy drives records all relevant electrical states of an electric motor and makes the information available in the IIoT network. Standard industrial sensors are used to record the current and voltage characteristics with an accuracy of 3 % at a sampling rate of 1 kHz. Further status information can be acquired by connecting additional sensors to the integrated analogue and digital sensor inputs. The integrated control module processes and digitalises the recorded statuses. In this way, the following electrical quantities can be determined:

- Plant identification
- On and off status
- On and off cycles
- Hours of operation
- RMS voltage of each phase
- RMS current of each phase
- Phase angle of each phase
- Active power (calculated)
- Reactive power (calculated)
- Voltage frequency
- Energy consumption
- Difference in currents between phases (calculated)
- Difference in voltage between phases (calculated)
- Start-up behaviour
- Vibration mm/s, RMS (external analogue sensor)
- Digital Analogue Input (external sensors)
- Internal temperature

Sensor de Temperatura y Vibraciones de Weidmüller:



Gateway UC20-WL2000-IoT de Weidmüller:

Hoja técnica



UC20-WL2000-IOT

Weidmüller Interface GmbH & Co. KG

Klingenbergstraße 26

D-32758 Detmold

Germany

www.weidmueller.com

Imagen de producto



En las modernas aplicaciones de IoT, la tecnología de automatización debe ser cada vez más potente y adaptable. u-mation ofrece un programa de componentes de hardware perfectamente coordinado, diseñado para la puesta a punto de tus máquinas y sistemas para el futuro. u-control 2000 es uno de los sistemas de control más compactos y avanzados del mercado y constituye la pieza central de nuestro programa de hardware. u-control 2000 es la base para poder usar cualquiera de nuestras soluciones de ingeniería: u-create web, studio e IoT. El diseño modular del controlador se basa en el sistema de E/S remoto u-remote y permite ampliar la instalación según las necesidades para incluir otros componentes de la familia u-mation.

Datos generales para pedido

Versión	Controller, IP20, u-control 2000 web, IoT Controller, Basado en web, incl. herramienta de ingeniería u-create IoT (nodo rojo)
Código	1334990000
Tipo	UC20-WL2000-IOT
GTIN (EAN)	4050118138290
Cantidad	1 Pieza



Hoja técnica

UC20-WL2000-IOT

Weidmüller Interface GmbH & Co. KG
Klingenbergstraße 26
D-32758 Detmold
Germany

www.weidmueller.com

Datos técnicos

Dimensiones y pesos

Altura	120 mm	Altura (pulgadas)	4.724 inch
Anchura	52 mm	Anchura (pulgadas)	2.047 inch
Medida de fijación, altura	128 mm	Peso neto	232 g
Profundidad	76 mm	Profundidad (pulgadas)	2.992 inch

Alimentación

Consumo de corriente desde I _{ENTRADA} (segmento de alimentación de la cabecera de bus de campo), tip.	116 mA	
Consumo de corriente desde I _{ENTRADA} (segmento de alimentación de la cabecera de bus de campo), tip.	nominal	116 mA
	máx.	116 mA
	mín.	0 mA
Corriente de alimentación del sistema, máx.	4.000 mA	
Corriente de alimentación para I _{ENTRADA} (línea de corriente de entrada)	máx.	5.000 mA
	nominal	5.000 mA
	mín.	0 mA
Corriente de alimentación para I _{ENTRADA} (línea de corriente de entrada) , máx.	5 A	
Corriente de alimentación para I _{SALIDA} (línea de corriente de salida)	máx.	5.000 mA
	nominal	5.000 mA
	mín.	0 mA
Corriente de alimentación para I _{SALIDA} (línea de corriente de salida) , máx.	5 A	
Tensión de alimentación para salidas	24 V DC +20 %/ -15 %	
Tensión de alimentación y entradas	24 V DC +20 %/ -15 %	

Datos de conexión

Tipo de conexión PUSH IN

Datos del sistema

Conexión	2 conectores RJ45	Entorno de programación	basado en la Web con nodo RED
Herramienta de ingeniería	u-create web	Interfaz	2x Ethernet TCP/IP, 1x Micro USB
Interfaz para la configuración	Micro USB 2.0	Memoria (Flash)	4 GB, 32 GB via microSD
Número máx. de módulos	64	Procesador	Dual Core ARM Cortex A9, 624 MHz, 512 Mbyte RAM
Reloj en tiempo real	Alimentado por batería	Tipo de módulo	Control
Velocidad de transmisión bus de backplane, máx.	48 Mbit		

Datos generales

Carril TS 35 Grado inflamabilidad según UL 94 V-0

Clasificaciones

ETIM 6.0	EC001603	ETIM 7.0	EC001603
eClass 9.1	27-24-26-08	eClass 10.0	27-24-26-07
eClass 11.0	27242607		

Fecha de creación 29 de noviembre de 2020 17:25:22 CET

Weidmüller 

Hoja técnica

UC20-WL2000-IOT

Weidmüller Interface GmbH & Co. KG
Klingenbergstraße 26
D-32758 Detmold
Germany

www.weidmueller.com

Datos técnicos

Homologaciones

Homologaciones



ROHS Conformidad
UL File Number Search E141197

Descargas

Datos de ingeniería	STEP
Notificación de cambio de producto	Release-Notes - IoT
Software	u-link VPN-Client - Version 2.0.194 Current Firmware file for UC20 IoT Archiv Firmware files UC20-WL2000-IOT
Documentación del usuario	u-link Technical User Guide MANU UC20 XL2000 DE MANU UC20 XL2000 EN UC20-WL2000-IOT Supported modules list

Router IE-SR-4TX-LTE/4G de Weidmüller:

Hoja técnica



IE-SR-4TX-LTE/4G-EU

Weidmüller Interface GmbH & Co. KG
Klingenbergstraße 26
D-32758 Detmold
Germany

www.weidmueller.com



Routeres de seguridad industrial de Weidmüller

- Integración sencilla de subredes con intervalos de dirección IP idénticos mediante NAT 1:1
- Mantenimiento seguro y remoto sencillos con el servicio de acceso remoto u-link de Weidmüller
- Conexión de red preparada para el futuro con enrutamiento estático y dinámico
- Mayor seguridad de la red gracias al cortafuegos de inspección de estado, el forwarding de puertos/IP y la segmentación de red
- Comunicación segura a través de Internet mediante IPsec y OpenVPN
- Conexión a Internet fiable, incluso sin acceso a Internet in situ, gracias al módem celular 4G/LTE integrado
- Máxima flexibilidad gracias a las interfaces Fast Ethernet y Gigabit Ethernet que disponen de 2 a 6 puertos.

Datos generales para pedido

Versión	Security/NAT/VPN/U-link Router, con módem de múltiples bandas integrado (4G/3G/2G), Modelo para la UE, Fast Ethernet, 4x RJ45 10/100BaseT(X), IP30, -30 °C...70 °C
Código	2751280000
Tipo	IE-SR-4TX-LTE/4G-EU
GTIN (EAN)	4050118899962
Cantidad	1 Pieza

Hoja técnica

IE-SR-4TX-LTE/4G-EU

Weidmüller Interface GmbH & Co. KG
Klingenbergstraße 26
D-32758 Detmold
Germany

www.weidmueller.com

Datos técnicos

Dimensiones y pesos

Altura	134,5 mm	Altura (pulgadas)	5,295 inch
Anchura	29,9 mm	Anchura (pulgadas)	1,177 inch
Peso neto	213 g	Profundidad	94,8 mm
Profundidad (pulgadas)	3,732 inch		

Temperaturas

Temperatura de almacenamiento	-20 °C...85 °C	Temperatura de servicio	-30 °C...70 °C
Humedad	5 – 90% (sin condensación)		

VPN

IPsec	Configurable como servidor o cliente IPsec	OpenVPN	Configurable como servidor o cliente OpenVPN (capa 2 y 3). Autenticación mediante certificado X.509. Conexiones de túnel a través de proxy HTTP. Máximo 10 configuraciones de cliente o servidor diferentes
u-link	Abrir el servicio de acceso remoto basado en VPN mediante nube u-link Weidmüller		

Modos de funcionamiento

Puente transparente	Router IP	Enrutamiento IP (IPv4, nivel 3) con cortafuegos SPI (inspección de paquete con estado). Enrutamiento estático o dinámico. Soporta RIPv2 / OSPF
	Switch de 4 puertos con filtrado adicional en capa 2	

Características de gestión

Configuración de dispositivo	Explorador web (HTTP/HTTPS), SNMP v1/v2c/v3, Herramienta Windows	Función de control	SNMP v1/v2c/v3, Syslog
Gestión de dirección IP	Estático, Cliente DHCP, Servidor DHCP (basado en grupos), Retransmisión DHCP	Funciones de seguridad	Cortafuegos de inspección con estado IPv4 (paquetes entrantes/salientes). Enmascaramiento NAT, NAT 1:1, IP forwarding, Forwarding de puertos
Gestión de sincronización de tiempo	Cliente NTP	Compatibilidad con protocolo industrial	Modbus/TCP slave

Condiciones del entorno

Humedad	5 – 90% (sin condensación)	Temperatura de almacenamiento, max.	85 °C
Temperatura de almacenamiento, min.	-20 °C	Temperatura de servicio, max.	70 °C
Temperatura de servicio, min.	-30 °C		

Datos técnicos

Conformidad con los requisitos de CEM y homologaciones

Norma de seguridad	SELV según la norma EN 62368-1, EN 62311	Normas EMC	EN 55032, EN 55024, EN 61000-6-2, EN 61000-6-4
Radiofrecuencia	EN 301 489-1, EN 301 489-52, EN 301 511, EN 301 908-1, EN 301 908-2	Shock	según IEC 60068-2-27
Vibración	según IEC 60068-2-6		

Garantía

Período	3 años
---------	--------

Interfaces

Botón "Reset"	Restablecimiento de ajustes de fábrica	Conexión para antenas externas	1x SMA hembra
Conexión serie		Entradas digitales	1x, Separación galvánica, "VPN-initiate": establece una conexión VPN preconfigurada (entrada 24 V), "Cut": desconecta físicamente (enlace caído) el puerto WAN (entrada 24 V), Reglas de filtro de paquete preconfiguradas de desencadenador (entrada de 24 V)
Indicador LED	1x RS-485, 2 conductores, Separación galvánica, 1 borne de 3 polos extraíble Alimentación: indica el estado del suministro de alimentación, el proceso de inicio y el proceso de actualización del firmware, Estado: indica el estado del sistema, VPN: indica el estado del túnel VPN, LTE/4G: indica el estado de la conexión de radio móvil, Port LED: Link/ACT, Speed (RJ45 port)	Número de puertos	4x RJ45 10/100BaseT(X)
Número de ranuras de tarjeta SCM	1	Número de ranuras de tarjeta SIM	1
Puertos RJ45	10/100BaseT(X), auto negotiation, Modo Half Duplex/Full Duplex, Conexión Auto MDI/MDI-X	Tipo de ranura de tarjeta SCM	Tarjeta inteligente (formato ID-000), Almacenamiento y recuperación de la configuración mediante Smart Card (tarjeta de memoria)
Tipo de ranura de tarjeta SIM	Mini-SIM (formato ID-000)		

Tensión de alimentación

Conexión	1 bloque de bornes de 4 polos, extraíbles	
Consumo de corriente	Tensión	24 V
	Corriente	0,8 A
Protección de polaridad	Sí	
Rango de tensión de alimentación	Tipo de tensión	DC
	Tensión, mín.	19,2 V
	Tensión, máx.	28,8 V
Tensión de alimentación	24 V DC, 1 sola entrada	

Fecha de creación 27 de noviembre de 2020 16:56:27 CET

Datos técnicos

Datos técnicos

Material capotas	Plástico	Tipo de montaje	Carril DIN
Tipo de protección	IP30	Velocidad	Fast Ethernet

Interfaz de radio móvil

Banda de frecuencia	EMEA, LTE: B1 (2100), B3 (1800), B7 (2600), B8 (900), B20 (800DD), UMTS/WCDMA: B1 (2100), B8 (900), GSM/GPRS/EDGE: B3 (1800), B8 (900)		
Modo de funcionamiento	Conexión permanente, Control de conexión manual mediante interfaz web		
Módulo wireless	multi-band modem (4G/3G/2G)		
Potencia de emisión	LTE: +23 dBm +2.7/-2.7 dB (Power Class 3), WCDMA : 24 +1/-3 dBm (Power Class 3), GSM900: 33 ± 2 dBm (Power Class 4), GSM1800: 30 ± 2 dBm (Power Class 1)		
Velocidad de transmisión de radio móvil	Categoría LTE	CAT 4	
	Velocidad de descarga, máx.	150 Mbps	
	Velocidad de carga, máx.	50 Mbps	

Clasificaciones

ETIM 6.0	EC001478	ETIM 7.0	EC001478
eClass 9.0	19-17-01-03	eClass 9.1	19-17-01-03
eClass 10.0	19-17-04-05	eClass 11.0	19170405

Homologaciones

Homologaciones



ROHS

Conformidad

Ordenador Industrial UV20-B-IPC-2001.01 de Weidmüller:

Hoja técnica



UV20-B-IPC-2001.01

Weidmüller Interface GmbH & Co. KG
Klingenbergstraße 26
D-32758 Detmold
Germany

www.weidmueller.com



El sistema IPC 2000 compacto es un PC industrial sin ventilador apto para el montaje en pared o en carril.

Equipado con dos conexiones Ethernet de 10/100/1000 Mbps, conexión USB 3.0, conexión USB 2.0 y salida de vídeo DVI, este dispositivo permite conectar todo tipo de sistemas, tanto nuevos como existentes. Para el almacenamiento de datos, el equipo IPC 2000 puede equiparse con discos duros SSD de hasta 120 GB y una ranura para tarjeta CFast protegida con una solapa delantera. Equipado con el procesador Intel Celeron J1900 de cuatro núcleos de 64 bits a 2 GHz, 4 GB de RAM y el sistema Windows 10 IoT Enterprise 2019 opcional, este equipo polivalente puede utilizarse para una amplia gama de aplicaciones.

Datos generales para pedido

Versión	PC industrial, IP20
Código	2676370000
Tipo	UV20-B-IPC-2001.01
GTIN (EAN)	4050118750201
Cantidad	1 Pieza

Hoja técnica

UV20-B-IPC-2001.01

Weidmüller Interface GmbH & Co. KG
Klingenbergstraße 26
D-32758 Detmold
Germany

www.weidmueller.com

Datos técnicos

Dimensiones y pesos

Altura	185 mm	Altura (pulgadas)	7,283 inch
Anchura	48 mm	Anchura (pulgadas)	1,89 inch
Peso	1.050 g	Peso neto	1.050 g
Profundidad	182 mm	Profundidad (pulgadas)	7,165 inch

Temperaturas

Temperatura de almacenamiento	-10 °C ... +60 °C	Temperatura de servicio	0 °C ... +50 °C
Humedad	80 % de humedad relativa (sin condensación)		

Datos generales

Sistema de funcionamiento	Windows 10 IoT Enterprise LTSC 2019 64bit - Entry	Tensión de alimentación	24 V DC (18-32 V DC) isolated
Tipo de protección	IP20		

Datos del sistema

Interfaces anteriores	2 x Ethernet 10/100/1000 MBit/s (RJ45), 2x USB 2.0, 1x USB 3.0, 1x DVI-D, 1x RS232 (DB9M)	Interfaces en la parte delantera	1x Cfast slot
Memoria	60 GB mSATA SSD	Memory (RAM)	4 GB, DDR3
Procesador	Intel® Celeron® J1900 - Quad Core 2.0 GHz (2.42 GHz Burst)	Sistema de funcionamiento	Windows 10 IoT Enterprise LTSC 2019 64bit - Entry

Homologaciones

Homologaciones



ROHS	Conformidad
UL File Number Search	E141197

Descargas

Homologación/certificado/documento de conformidad	Declaration of Conformity - UV20-B-IPC-20XX.XX
Documentación del usuario	QGUI UV20 IPC20XX

Relés de Weidmüller:

Hoja técnica



TRP 24VDC 1CO

Weidmüller Interface GmbH & Co. KG

Klingenbergstraße 26

D-32758 Detmold

Germany

www.weidmueller.com

Imagen de producto



Similar a la ilustración

- 1 contacto conmutado
- Material de contacto: AgNi
- Entrada multitenión única de 24 V a 230 V CU
- Tensiones de entrada de 5 V CC a 230 V CU con señalización de color: CA: rojo, CC: azul, CU: blanco

Datos generales para pedido

Versión	TERMSERIES, Módulo de relé, Número de contactos: 1, Contacto conmutado AgNi, Tensión de mando nominal: 24 V DC $\pm 20\%$, Intensidad permanente: 6 A, PUSH IN
Código	2618000000
Tipo	TRP 24VDC 1CO
GTIN (EAN)	4050118670837
Cantidad	10 Pieza

Hoja técnica

TRP 24VDC 1CO

Weidmüller Interface GmbH & Co. KG
Klingenbergstraße 26
D-32758 Detmold
Germany

www.weidmueller.com

Datos técnicos

Dimensiones y pesos

Altura	89,4 mm	Altura (pulgadas)	3,52 inch
Anchura	6,4 mm	Anchura (pulgadas)	0,252 inch
Peso neto	28,2 g	Profundidad	87,8 mm
Profundidad (pulgadas)	3,457 inch		

Temperaturas

Temperatura de almacenamiento	-40 °C...85 °C	Temperatura de servicio	-40 °C...60 °C
Humedad	5-95% de humedad relativa, T _a = 40°C, sin condensación		

Datos nominales UL

Altitud de funcionamiento	≤ 2000 m, sobre el nivel del mar	Temperatura ambiente (funcionamiento), máx.	60 °C
Sección del conductor AWG, mín.	AWG 26	Sección de conexión AWG, máx.	AWG 14
Tipo de conductor	conductor de cobre rígido, conductor de cobre flexible	Grado de polución	2

Lado de mando

Conexión de protección	Diodo antiparalelo, Protección de polaridad	Corriente de conexión/desconexión, tipo.	7,5 mA / 1 mA DC
Indicador de estado	LED verde	Intensidad nominal DC	11,5 mA
La tensión de la bobina del relé de repuesto varía con respecto a la tensión nominal de alimentación de control	No	Potencia nominal	280 mW
Tensión de conexión/desconexión, tipo.	16 V / 3 V DC	Tensión de la bobina del relé de repuesto	24 V DC
Tensión de mando nominal	24 V DC ± 20 %		

Lado de carga

Frecuencia de conex. máx. con carga nom.	0,1 Hz	Intensidad de conexión	20 A / 20 ms
Intensidad permanente	6 A	Potencia de conexión mínima	1 mA @ 24 V, 10 mA @ 12 V, 100 mA @ 5 V
Potencia de conmutación AC (óhmica), máx.	1500 VA	Potencia de conmutación DC (óhmica), máx.	144 W @ 24 V
Retardo de conexión	≤ 6 ms	Retardo en la desconexión	≤ 16 ms
Tensión de conex. DC, max.	250 V	Tensión de conexión nominal	250 V AC

Datos de contacto

Tipo de contacto	1 Contacto conmutado (AgNi)	Vida útil mecánica	5 x 10 ⁶ conmutaciones
------------------	-----------------------------	--------------------	-----------------------------------

Datos generales

Carril	TS 35
Pulsador de prueba	No
Indicador de posición del interruptor mecánico	No
Color	negro

Hoja técnica

TRP 24VDC 1CO

Weidmüller Interface GmbH & Co. KG
Klingenbergstraße 26
D-32758 Detmold
Germany

www.weidmueller.com

Datos técnicos

Componente de índice de inflamabilidad UL94	Componente	Caja
	Índice de inflamabilidad UL94	V-0
	Componente	Clip de retención
	Índice de inflamabilidad UL94	V-0
	Componente	Pulsador
	Índice de inflamabilidad UL94	V-0

Coordinación de aislamiento

Categoría de sobretensión	III	Distancia en el aire y de fuga entrada - salida	≥ 5,5 mm
Grado de polución	2	Resistencia a tensiones dieléctricas de contacto abierto	1 kV _{eff} / 1 min
Resistencia a tensiones eléctricas de carril	4 kV _{eff} / 1 Min.	Resistencia a tensiones eléctricas, entrada/salida	4 kV _{eff} / 1 Min.
Sobretensión de choque fijo	6 kV (1,2/50 μs)	Tensión nominal	300 V
Tipo de protección	IP20		

Información adicional sobre homologaciones/normas

Normas	EN 50178, EN 55011, EN 61000-6-1, 2, 4	Núm. de certificación (DNVGL)	TAA00001E5
N.º de certificado (cULus)	E141197		

Datos de conexión

Técnica de conexión de conductores	PUSH IN	Longitud de desaislado, conexión nominal	9 mm
Sección de embornado, conexión nominal	1,5 mm ²	Sección de embornado, mín.	0,14 mm ²
Sección de embornado, máx.	2,5 mm ²	Sección de conexión del conductor AWG, mín.	AWG 26
Sección de conexión del conductor AWG, máx.	AWG 14	Sección de conexión del conductor, rígido, mín.	0,14 mm ²
Sección de conexión del conductor, rígido, máx.	2,5 mm ²	Sección de conexión del conductor, rígido, mín. (AWG)	AWG 26
Sección de conexión del conductor, rígido, máx. (AWG)	AWG 14	Sección de conexión del conductor, flexible, mín.	0,14 mm ²
Sección de conexión del conductor, flexible, máx.	2,5 mm ²	Sección de conexión del conductor, flexible, mín. (AWG)	AWG 26
Sección de conexión del conductor, flexible, máx. (AWG)	AWG 14	Sección del conductor, flexible con terminales tubulares DIN 46228/4, mín.	0,15 mm ²
Sección del conductor, flexible con terminales tubulares DIN 46228/4, máx.	1,5 mm ²	Sección de conexión del conductor, flexible, term. tub. (DIN 46228-1), mín.	0,15 mm ²
Sección de conexión del conductor, flexible, term. tub. (DIN 46228-1), máx.	1,5 mm ²	Terminal tubular doble, mín.	0,5 mm ²
Terminal tubular doble, máx.	1 mm ²	Dimens. caña destornillador	0,4 x 2,0 mm

Clasificaciones

ETIM 6.0	EC001437	ETIM 7.0	EC001437
ECLASS 9.0	27-37-16-01	ECLASS 9.1	27-37-16-01
ECLASS 10.0	27-37-16-01	ECLASS 11.0	27-37-16-01

Homologaciones

Homologaciones



ROHS Conformidad
UL File Number Search E141197

Switch IE-SW-EL08-8TX de Weidmüller:

Hoja técnica



IE-SW-EL08-8TX

Weidmüller Interface GmbH & Co. KG
Klingenbergstraße 26
D-32758 Detmold
Germany

www.weidmueller.com



Características de la serie EcoLine de switches no gestionados

- Amplia variedad de número de puertos y tipos de soportes que permite todo tipo de aplicaciones (de 5 a 24 puertos)
- Modelos compatibles con conexiones Gigabit Ethernet que incluyen el soporte Jumbo Frame para aplicaciones con alta demanda de ancho de banda y latencia
- Sistema adecuado para el uso en entornos industriales exigentes gracias al diseño robusto y al amplio intervalo de temperatura de servicio de -40 °C hasta 75 °C.
- Funcionamiento fiable gracias a las entradas de tensión redundantes, al relé de fallo y al diagnóstico mediante indicadores LED

Datos generales para pedido

Versión	Switch de red, unmanaged, Fast Ethernet, Número de puertos: 8x RJ45, IP30, -40 °C...75 °C
Código	2682140000
Tipo	IE-SW-EL08-8TX
GTIN (EAN)	4050118692570
Cantidad	1 Pieza

Hoja técnica

IE-SW-EL08-8TX

Weidmüller Interface GmbH & Co. KG

Klingenbergstraße 26
D-32758 Detmold
Germany

www.weidmueller.com

Datos técnicos

Dimensiones y pesos

Altura	95 mm	Altura (pulgadas)	3,74 inch
Anchura	41 mm	Anchura (pulgadas)	1,614 inch
Peso neto	540 g	Profundidad	90 mm
Profundidad (pulgadas)	3,543 inch		

Temperaturas

Temperatura de almacenamiento	-40 °C...85 °C	Temperatura de servicio	-40 °C...75 °C
Humedad	5 hasta 95% (sin condensación)		

Conformidad medioambiental del producto

REACH SVHC	Lead 7439-92-1
------------	----------------

Condiciones del entorno

Altitud de funcionamiento	≤ 2000 m	Humedad	5 hasta 95% (sin condensación)
Temperatura de almacenamiento, max.	85 °C	Temperatura de almacenamiento, min.	-40 °C
Temperatura de servicio, max.	75 °C	Temperatura de servicio, min.	-40 °C

Conformidad con los requisitos de CEM y homologaciones

Caída libre	De conformidad con la norma IEC 60068-2-31	Norma de seguridad	UL 61010-1, UL 61010-2-201
Normas EMC	EN 55032, EN 55024, CISPR 32, FCC Part 15 Subpart B Class A, IEC 61000-4-2 ESD: Contact: 4 kV; Air: 8 kV, IEC 61000-4-3 RS: 80 MHz bis 1 Ghz: 3 V/m, IEC 61000-4-4 EFT: potencia: 0,5 kV; señal: 0,5 kV, IEC 61000-4-5 Surge: Power: 0,5 kV; Signal: 1 kV, IEC 61000-4-6 CS: 3 Vrms	Shock	según IEC 60068-2-27
Vibración	según IEC 60068-2-6		

Garantía

Período	5 años
---------	--------

Interfaces

Indicador LED	Power LED: PWR1, PWR2, Port LED: LNK/ACT, 10/100M (RJ45 port)	Número de puertos	8x RJ45
Puertos RJ45	10/100BaseT(X), auto negotiation, Modo Half Duplex/Full Duplex, Conexión Auto MDI/MDI-X		

MTBF

MTBF	1.390.019 hrs	Base de datos	Telcordia SR332
------	---------------	---------------	-----------------

Hoja técnica

IE-SW-EL08-8TX

Weidmüller Interface GmbH & Co. KG
Klingenbergstraße 26
D-32758 Detmold
Germany

www.weidmueller.com

Datos técnicos

Propiedades de switch

Tamaño de la memoria de paquetes	448 kbit	Tamaño de la tabla MAC	1 K
Ancho de banda placa base	1,6 Gbps		

Tecnología

Comunicación de datos	Store and Forward	Control de flujo	Control de flujo IEEE 802.3x
Norma	IEEE 802.3 for 10BASE-T, IEEE 802.3u for 100BASE-TX, IEEE 802.3x para el control de flujo		

Tensión de alimentación

Conexión	1 bloque de bornes de 4 polos, extraíbles		
Consumo de corriente	Tensión	24 V DC	
	Corriente	0,14 A	
Protección contra sobretensión	Sí		
Protección de polaridad	Sí		
Rango de tensión de alimentación	Tipo de tensión	DC	
	Tensión, mín.	12 V	
	Tensión, máx.	48 V	
	Tipo de tensión	AC	
	Tensión, mín.	18 V	
	Tensión, máx.	36 V	
Tensión de alimentación	24 V DC, 24 V AC, 2 entradas redundantes		

Datos técnicos

Material capotas	Metal	Switch	unmanaged
Tipo de montaje	Carril DIN	Tipo de protección	IP30
Velocidad	Fast Ethernet		

Clasificaciones

ETIM 6.0	EC000734	ETIM 7.0	EC000734
ECLASS 9.0	19-17-01-06	ECLASS 9.1	19-17-01-06
ECLASS 10.0	19-17-04-02	ECLASS 11.0	19-17-04-02

Homologaciones

Homologaciones



ROHS	Conformidad
UL File Number Search	E141197

Fuente PROMAX3 240W 24V 10A de Weidmüller:

Hoja técnica



PRO MAX3 240W 24V 10A

Weidmüller Interface GmbH & Co. KG

Klingenbergstraße 26
D-32758 Detmold
Germany

www.weidmueller.com



PROMax ofrece diferentes soluciones para una automatización exigente.

Nuestras fuentes de alimentación conmutadas PROMax, duraderas y de alto rendimiento, están diseñadas para responder a requerimientos especialmente exigentes. PROMax resuelve con fiabilidad sobrecargas continuas de hasta 20% o picos breves de 300% que se producen a altas temperaturas en el armario de distribución. También ofrece alta capacidad suministro (Power Boost) y plena potencia en un amplio rango de temperaturas. Nuestras fuentes de alimentación conmutadas se pueden utilizar en todo el mundo, además de ser aptas para lugares de espacio reducido gracias a su mínima anchura. Junto con nuestro UPS, los módulos de diodos y/o los módulos capacitivos CAP, puedes crear soluciones de suministro de corriente adaptadas a tus necesidades.

Datos generales para pedido

Versión	Alimentación de corriente, fuente de alimentación conmutada, 24 V
Código	1478180000
Tipo	PRO MAX3 240W 24V 10A
GTIN (EAN)	4050118286120
Cantidad	1 Pieza

Hoja técnica

PRO MAX3 240W 24V 10A

Weidmüller Interface GmbH & Co. KG
Klingenbergstraße 26
D-32758 Detmold
Germany

www.weidmueller.com

Datos técnicos

Dimensiones y pesos

Altura	130 mm	Altura (pulgadas)	5,118 inch
Anchura	60 mm	Anchura (pulgadas)	2,362 inch
Peso neto	1.322 g	Profundidad	125 mm
Profundidad (pulgadas)	4,921 inch		

Temperaturas

Temperatura de almacenamiento	-40 °C...85 °C	Temperatura de servicio	-25 °C...70 °C
Humedad a temperatura de servicio	5...95 % (sin condensación)		

Conformidad medioambiental del producto

REACH SVHC	Lead 7439-92-1
------------	----------------

Datos nominales UL

Altitud de funcionamiento	3000 m, 3000-6000 m deriva, @ 6000 m 75 % de carga	Núm. de certificación (cURus)	E255651
---------------------------	--	-------------------------------	---------

Entrada

Consumo de corriente AC	0,35A @ 3*500 VAC / 0,4A @ 3*400 VAC	Consumo de corriente DC	0,35 A @ 800 V DC / 0,6 A @ 450 V DC
Fusible de entrada (interno)	Sí	Fusible previo recomendado	3 - 5 A, car. C, interruptores automáticos
Gama de tensión de entrada DC	450...800 V DC (max. 500 V DC acc. to UL508)	Intensidad de conexión	máx. 15A
Protectores de sobretensión, entrada	Varistor	Rango de tensión de entrada AC	3 x 320...3 x 575 V AC / 2 x 360...2 x 575 V AC
Sistema de conexión	Conexión brida-tornillo	Tensión nominal de entrada	3 x 400...3 x 500 V AC (amplio rango de entrada)
Zona de frecuencia AC	45...65 Hz		

Salida

Conmutado paralelo	sí, máx. 5	Corriente de salida nominal para U _{nominal} 10 A @ 60 °C	
Potencia de salida	240 W	Protección contra tensión inversa	Sí
Rizado residual, picos de tensión de desconexión	< 50 mVss @ U _{Nenn} , Full Load	Sistema de conexión	Conexión brida-tornillo
Tensión de salida	24 V	Tensión de salida	22,5...29,5 V (ajustable con potenciómetro)
Tensión de salida, max.	29,5 V	Tensión de salida, min.	22,5 V
Tensión de salida, observacione	(ajustable con potenciómetro)	Tensión nominal de salida	24 V DC ± 1 %

Datos técnicos

Datos generales

Categoría de sobretensión	III	Corriente de descarga a tierra, máx.	3,5 mA
Deriva térmica	> 60°C / 75% @ 70°C	Factor de potencia (aprox.)	> 0.85 @ 3*400 V AC
Grado de eficiencia	91.5%	Indicador de servicio	LED rojo/verde y relé (≥21,6 V DC LED verde, relé on / ≤20,6 LED rojo, relé off)
Limitación de intensidad	> 120 % I _N	MTBF	>500.000h (25°C, IEC 61709 (SN29500))
Posición de montaje, instrucciones de montaje	Horizontal en un carril TS35. 50 mm de espacio en parte superior e inferior para circ. de aire. Se pueden montar en línea sin espacio intermedio.	Protección contra cortocircuito	Si
Protección contra tensión inversa de la carga	30...35 V DC	Temperatura de servicio	-25 °C...70 °C
Tiempo de puenteado de fallo de CA @ I _{nominal}	mín. 20 ms	Versión especial de la capota	Metal, resistente a la corrosión

Coordenadas de aislamiento

Categoría de sobretensión	III	Clase de protección	I, con conexión de tierra
Grado de polución	2	Humedad a temperatura de servicio	5...95 % (sin condensación)
Tensión de aislamiento entrada /salida	4 kV		

EMC / choque / vibración

Emisión de ruidos de conformidad con la norma EN55032	Clase B	Prueba de resistencia a interferencias según	EN 55024, EN 55032, IEC61000-3-2,-3, IEC61000-4-2,-3,-4,-5,-6,-8,-11
Resistencia a la vibración según IEC 60068-2-6	2,3 g	Resistencia al impacto según IEC 60068-2-27	30 g en todas las direcciones

Seguridad eléctrica (normas aplicadas)

Equipamiento eléctrico de las máquinas	según EN60204	Equipos electrónicos con componentes electrónicos	según EN50178 / VDE0160
Protección contra corrientes peligrosas	Según VDE 0106-101	Separación segura / protección frente a choques eléctricos	VDE0100-410 / según DIN57100-410
Transformadores de seguridad para fuentes de alimentación conmutadas	Conforme a la norma EN 61558-2-16		

Datos de conexión (entrada)

Sección de conexión del conductor AWG/kcmil , máx.	10	Sección de conexión del conductor AWG/kcmil , mín.	26
Sección de conexión del conductor, flexible , máx.	4 mm ²	Sección de conexión del conductor, flexible , mín.	0,22 mm ²
Sección del conductor, rígido , máx.	6 mm ²	Sección del conductor, rígido , mín.	0,18 mm ²
Sistema de conexión	Conexión brida-tornillo		

Datos de conexión (salida)

Número de bornes	8 (+, -, 11, 13, 14)	Sección de conexión del conductor AWG/kcmil , max.	10
Sección de conexión del conductor AWG/kcmil , min.	26	Sección de conexión del conductor, flexible , max.	4 mm ²
Sección de conexión del conductor, flexible , min.	0,22 mm ²	Sección del conductor, rígido , máx.	6 mm ²
Sección del conductor, rígido , mín.	0,18 mm ²	Sistema de conexión	Conexión brida-tornillo

PA52_7 Señalización

Carga de contacto (CNA)	max. 30 V DC / 1 A	Contacto libre de potencial	Si
Indicador de servicio	LED rojo/verde y relé (≥21,6 V DC LED verde, relé on / ≤20,6 LED rojo, relé off)		

Homologaciones

Instituto (GERMLLOYD)	GERMLLOYD	Instituto (cULus)	CULUS
Instituto (cULusEX)	CULUSEX	Instituto (cURus)	CURUS
N.º de certificado (cULus)	E258476	N.º de certificado (cULusEX)	E470829
Núm. de certificación (GERMLLOYD)	TAA00000TT	Núm. de certificación (cURus)	E255651

Clasificaciones

ETIM 6.0	EC002540	ETIM 7.0	EC002540
ECLASS 9.0	27-04-07-01	ECLASS 9.1	27-04-07-01
ECLASS 10.0	27-04-07-01	ECLASS 11.0	27-04-07-01

Homologaciones

Homologaciones



ROHS	Conformidad
UL File Number Search	E258476