

03-020

PREDICTIVE MAINTENANCE USING MACHINE LEARNING TECHNIQUES

Guerrero Cano, Manuel; Luque Sendra, Amalia; Lama Ruiz, Juan Ramón; Córdoba Roldán, Antonio

Grupo de investigación TEP 022 Área de Proyectos de Ingeniería. Departamento de Ingeniería del Diseño. Escuela Politécnica Superior. Universidad de Sevilla

Industrial maintenance is a field of engineering with a high impact on costs and manufacturing times for industrial products. This work is part of the work areas of diagnosis and maintenance of industrial processes and explores techniques of detection of incipient anomalies based on automatic learning.

The predictive maintenance aims to predict failures in the machinery, so that repairs can be scheduled without interrupting the production process. It consists of an analysis of the operation of the equipment to detect warning signs that indicate that one of its parts is not working in the correct way. The cost of predictive maintenance is less than that of the corrective, due to the expenses generated by the repair of equipment and downtime due to production stoppage.

Information technologies are giving rise to a new revolution that is called industry 4.0. One of the fields of application is in the improvement of maintenance. By using process and product data, machine learning techniques could be applied to determine when failures can occur. In this paper, supervised and unsupervised learning techniques (parametric and nonparametric) will be explored and their usefulness for their application in predictive maintenance will be discussed.

Keywords: *Machine learning; automatic learning; Industry 4.0; Predictive Maintenance; digital enables*

MANTENIMIENTO PREDICTIVO MEDIANTE TÉCNICAS DE MACHINE LEARNING

El objeto de la presente investigación es innovar en el diseño de producto para el sector del transporte introduciendo en las etapas tempranas de diseño y desarrollo del producto un enfoque neurocientífico.

Para ello se desarrollará una metodología compacta que integre en el proceso de diseño la capacidad de motivar emocionalmente al usuario y crear un vínculo afectivo en la experiencia de uso entre el objeto de diseño y el usuario.

En la propuesta metodológica se considerará la dimensión enactiva del usuario, es decir, se analizará como poder modelar y filtrar la percepción cognitiva y las respuestas procesadas del usuario según su realidad subjetiva en la que se integran las vivencias propias, costumbres y experiencias (affordances). Para ello se hace necesario integrar en la metodología de diseño la neurousabilidad enactiva. Con el objetivo de conseguir adaptar emocionalmente los requerimientos subjetivos del usuario y profundizar en el vínculo afectivo entre usuario-producto

El resultado esperado será poder diseñar y desarrollar un vínculo emotivo afectivo entre el objeto de diseño, el vehículo, para crear experiencias de uso placenteras y satisfactorias que trascenderían más allá de la función de transporte

Palabras clave: *Machine learning; aprendizaje automático; Industria 4.0; mantenimiento predictivo; facilitadores digitales*

Correspondencia: Manuel Guerrero Cano manuel.guerrero.cano@gmail.com



©2019 by the authors. Licensee AEIPRO, Spain. This article is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).

1. Introducción

Cualquier máquina en la industria llegará, eventualmente, a un punto de mal funcionamiento. Ese punto no implica necesariamente un fallo catastrófico, pero es un punto significativo en el cual es evidente que la máquina ya no funciona como debería. En este punto la máquina necesita de alguna actividad de mantenimiento para restaurar su potencial operativo completo.

Según Bangert (2017) existen técnicas, como el Condition Monitoring, para mejorar la identificación de algún tipo de mal funcionamiento de la máquina. La forma más común es observar la medición que proporciona algún sensor. Si el valor leído por el sensor está dentro de unos límites aceptables, entonces se extrapola que la máquina funciona correctamente. Por otro lado, si dicho valor está fuera de los límites, entonces podemos decir que la máquina tiene algún tipo de anomalía y se debe actuar en consecuencia.

Si además tenemos en cuenta que los sistemas de producción complejos pueden contar con miles de piezas y componentes, sujetos a múltiples conexiones e interdependencias físicas y lógicas, el problema de mantenimiento se complica. A este nivel de complejidad el enfoque tradicional de mantenimiento no es válido, como indican Accorsi et al. (2017).

El nuevo paradigma de Industria 4.0 está representando un cambio en la forma de producción en las factorías actuales y es por ello que levanta mucho interés entre académicos y profesionales (Tupa, Simota & Steiner, 2017).

Existen diferentes tecnologías que han potenciado la aparición de la cuarta revolución industrial. Así las tecnologías de la información y comunicación (TIC), el Internet de las cosas (IoT), la robótica colaborativa, la computación en la nube, etc., son consideradas tecnologías habilitadoras y, de hecho, se conocen por habilitadores digitales.

En este documento nos centramos en uno de los habilitadores de la cuarta revolución industrial: el Machine Learning. En la primera parte se profundizará en el aprendizaje autónomo orientado al mantenimiento predictivo. Además, veremos los diferentes tipos de mantenimiento que nos podemos encontrar.

En la segunda parte nos centraremos en un caso de estudio. Veremos las bondades y beneficios que aporta el mantenimiento predictivo en una industria real: la planta de embotellado de Aguas de Solán de Cabras.

Para el desarrollo de este trabajo se empezó realizando una revisión bibliográfica, utilizando fuentes internacionales como Scopus, Web of Science y ScienceDirect. La búsqueda se centró en el nuevo paradigma de fábrica inteligente y los habilitadores digitales que hacen posible la cuarta revolución industrial.

Dentro del estudio sobre Industria 4.0, nos hemos centrado en el Machine Learning, por las ventajas que aporta al mantenimiento predictivo.

En el apartado 2 se desarrolla el estado del arte del aprendizaje máquina desde un punto teórico. Desarrollando los tipos de Machine Learning, la aportación al mantenimiento y las ventajas que aporta.

A continuación, en el apartado 3, se expondrán los motivos por los que se ha optado por tomar una estrategia de Machine Learning en una industria real. Aunque la implementación se encuentra en una etapa muy temprana, se ven claramente los beneficios y el potencial que muestra.

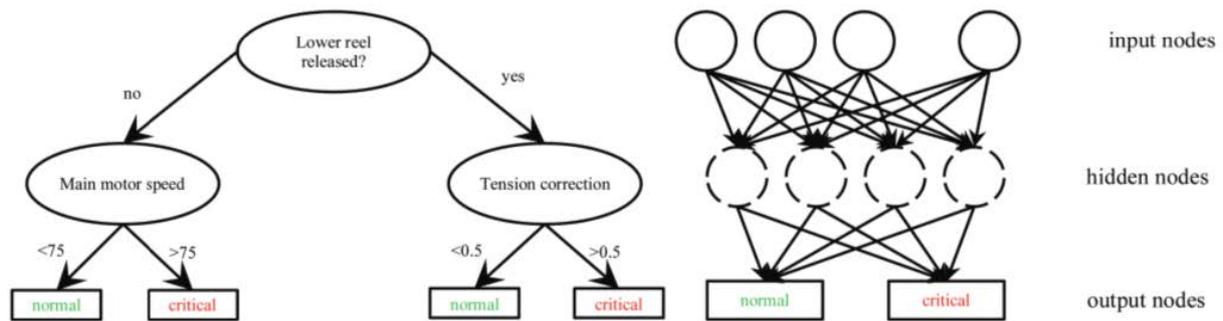
Y por último, en el apartado 4, se presentaran algunas conclusiones y futuros trabajos en la implementación de este tipo de estrategia en un entorno industrial real.

2. Metodología

2.1. Introducción al Machine Learning.

El aprendizaje máquina o aprendizaje automático, más conocido como Machine Learning, usa algoritmos automatizados para determinar resultados descriptivos, predictivos y prescriptivos a partir de un conjunto de datos iniciales (Huddleston & Brown, 2018).

Figura 1: Las 40 tecnologías clave



Ejemplos de algoritmos: árbol de decisión (izq) y red neuronal (dcha). (Accorsi, 2017)

Como en otras muchas disciplinas científicas, en el Machine Learning el objetivo principal es modelar la relación entre un conjunto de variables medidas (entradas) y otro conjunto de variables relacionadas con estas (salidas). Una vez que se ha determinado dicho modelo matemático, es posible predecir el valor de las variables deseadas midiendo las observables. Según Baştanlar & Özuysal (2014), el aprendizaje automático nos proporciona técnicas que pueden construir un modelo de las complejas relaciones entre entradas y salidas, al procesar los datos disponibles y optimizar un criterio de predicción del problema. El proceso automático de creación de modelos se denomina "aprendizaje", los datos utilizados para fines de aprendizaje se denominan "datos de aprendizaje".

2.1.1. Tipos de mantenimiento.

Existen varias estrategias de mantenimiento. Susto et al. (2015) determinan que los enfoques más comunes del mantenimiento pueden agruparse en tres categorías principales:

1. **Mantenimiento correctivo:** donde las intervenciones de mantenimiento se realizan solo después de que ocurra algún fallo. Este tipo de mantenimiento es el enfoque más simple y ha sido la manera tradicional de mantenimiento. Sin embargo, es el menos efectivo, ya que el costo de las intervenciones y el tiempo de inactividad asociado después de algún tipo de fallo es elevado. Generalmente mucho mayor que aquellos costes asociados con las acciones correctivas planeadas, tomadas con anticipación y cierto criterio.
2. **Mantenimiento preventivo:** donde las acciones de mantenimiento se llevan a cabo de acuerdo con un programa planificado. La planificación viene dada por el tiempo transcurrido entre intervenciones o por las iteraciones del proceso. Con este enfoque, también conocido como mantenimiento programado, generalmente se evitan los fallos del sistema. El mayor inconveniente de una estrategia de mantenimiento preventivo es que a menudo se realizan acciones correctivas innecesarias, lo que lleva a un uso ineficiente de los recursos y a un aumento de los costes operativos.
3. **Mantenimiento predictivo:** donde el mantenimiento se realiza en base a una estimación del estado de funcionamiento del equipo. Una estrategia de este tipo permite la detección anticipada de fallos potenciales y permite intervenciones de mantenimiento oportunas. El mantenimiento predictivo hace uso de herramientas de predicción basadas

en datos históricos, factores de buen funcionamiento definidos por conocimiento experto, métodos de inferencia estadística, etc. (Krishnamurthy et al., 2005).

En este trabajo nos centramos en el último tipo de mantenimiento. Para llevar a cabo una estrategia de mantenimiento predictivo nos apoyamos en una herramienta que ha surgido gracias a la Industria 4.0: Machine Learning o aprendizaje de máquina.

2.1.2. Clasificación de Machine Learning

El aprendizaje automático está estrechamente relacionado con la inteligencia artificial y el aprendizaje estadístico. Conforme Ma, Zhang & Wang (2014), el Machine Learning incorpora algoritmos y procedimientos desarrollados en los campos anteriormente citados y, debido a esta fusión, el léxico es muy amplio, con muchos sinónimos utilizados para describir los mismos algoritmos, procedimientos y parámetros del modelo.

Los problemas de aprendizaje automático más comunes incluyen:

- Clasificación o reconocimiento de patrones: el problema de enseñar a un clasificador a asignar etiquetas a nuevas muestras sin etiqueta.
- Regresión: el problema de estimar la relación entre salidas y atributos de valor real para hacer predicciones.
- Agrupación en clúster: la tarea de agrupar datos de manera que los ejemplos en el mismo grupo (llamado agrupación) sean más similares entre sí que a los de otros grupos.
- Recomendación: la tarea de priorizar ejemplos basados en los atributos de interés.
- Reducción de la dimensionalidad: el problema de transformar atributos en un espacio de alta dimensión a un espacio de menos dimensiones.
- Análisis de redes: el estudio de explorar asociaciones entre componentes de sistemas para comprender la función biológica de componentes individuales y dilucidar los comportamientos de los sistemas biológicos.
- Estimación de densidad: el problema de estimar la función de densidad de probabilidad para una población en base a los datos observados.

Como McArthur et al. (2018) Indican, un desafío clave es la calidad de los datos. Por lo general, se recopilan datos que con frecuencia carecen de los detalles necesarios para el diagnóstico del problema.

2.1.3. Aportación del Machine Learning al Mantenimiento

Una técnica tradicional de mantenimiento es observar los datos proporcionados por uno, o una serie, de sensores. En cualquier momento del funcionamiento de la máquina podemos comparar el valor del sensor con el valor esperado de un modelo ideal de la máquina. Mediante la nube de valores esperados calculados a partir de un modelo se determina la distribución de probabilidad de las desviaciones en el funcionamiento de la máquina, es decir, qué tan probable es que la medición esté alejada de la expectativa en cierta cantidad (Bangert, 2017).

Por lo tanto, se puede calcular la probabilidad de desviarse de esa distribución o, a la inversa, utilizar este intervalo de confianza para juzgar si el valor del sensor está demasiado lejos del funcionamiento óptimo. Si tenemos alguno de estos casos, entonces la máquina debe ser revisada. Bangert (2012) apunta como esta información brinda al departamento

encargado del mantenimiento información adicional para diagnosticar problemas, diseñar alguna acción y ejecutar las medidas convenientes.

Sin embargo, Bishop (2006) señala que monitorizando el estado de funcionamiento a menudo se observa que cuando una máquina pasa de un estado de funcionamiento a otro (ambos estados correctos de funcionamiento), se emiten muchas falsas alarmas (falsos positivos). Del mismo modo, nos encontramos con casos de funcionamiento anómalos que no son detectados (falsos negativos) y que son causas potenciales de fallo. Esto se debe a que este enfoque analítico, aunque simple, no puede mantenerse actualizado con condiciones de funcionamiento que cambian rápidamente.

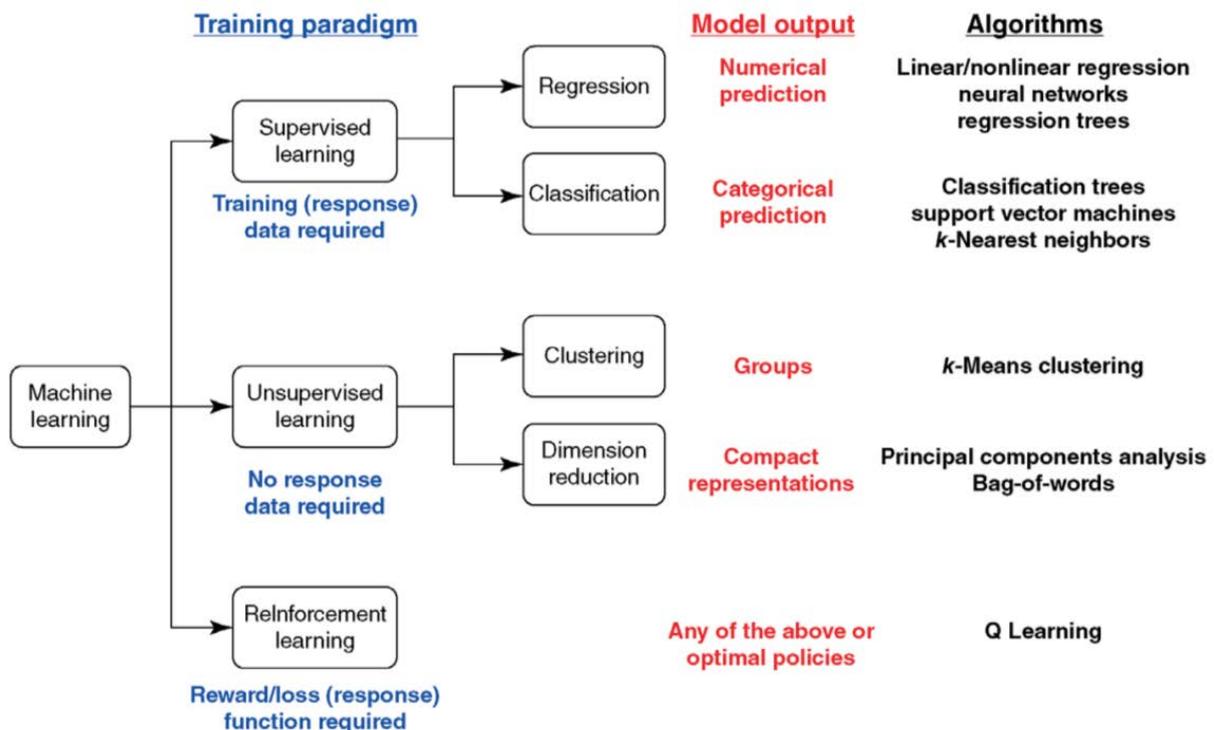
Para evitar los casos de falsos positivos y falsos negativos el Machine Learning dota a los equipos de mantenimiento de herramientas de aprendizaje de máquina capaces de adaptarse a las condiciones de funcionamiento, incluso aquellas que cambian rápidamente.

2.1.4. Beneficios

Hay tres amplias clases o grupos de aprendizaje automático según James et al. (2013), Hastie, Tibshirani & Friedman (2009) y Huddleston & Brown (2009). Esas clases están definidas en función de los datos proporcionados para “enseñar” o “entrenar” los modelos matemáticos o algoritmos de computación:

- Aprendizaje supervisado
- Aprendizaje no supervisados
- Y aprendizaje por refuerzo problemas.

Figura 2: Visión general de los paradigmas de aprendizaje automático: aprendizaje supervisado, no supervisado y reforzado (Huddleston & Brown, 2018)



2.1.4.1. Aprendizaje supervisado

El aprendizaje supervisado es aplicado cuando la variable de salida puede ser obtenida mediante el conjunto de datos utilizados para entrenar el modelo. El objetivo de este tipo de aprendizaje es utilizar las observaciones disponibles para predecir los valores de la variable de salida asociada con nuevas observaciones (James et al., 2013).

2.1.4.2. Aprendizaje no supervisado

Por otro lado, el aprendizaje no supervisado busca identificar estructuras latentes, subyacentes u ocultas en un conjunto de datos. Por este motivo, el aprendizaje no supervisado no requiere una variable de salida etiquetada. Puede haber muchas estructuras latentes en un conjunto de datos, y hay varias tareas de aprendizaje no supervisadas que son bastante comunes (Hastie, Tibshirani & Friedman, 2009).

2.1.4.2. Aprendizaje por refuerzo problemas

Por último, el aprendizaje de refuerzo aborda una categoría muy amplia de problemas en los que las funciones de puntuación o respuesta se aplican de manera iterativa sobre el problema (Huddleston & Brown, 2009).

Estos modelos se pueden entrenar utilizando muestras grandes de datos, ya que el proceso de enseñanza es automatizado, como indican Baştanlar & Özuysal (2014).

2.1.5. Características

Las cantidades observables que se integran en un algoritmo de aprendizaje máquina se denominan "características". El algoritmo aprende mediante el mapeo de estas características con las variables de salida deseadas, ajustando los parámetros del modelo utilizando los datos de entrenamiento disponibles. Por lo tanto, es importante que las características sean relevantes para la predicción de los resultados.

Para algunos problemas de aprendizaje automático, hay miles de funciones que pueden ser usadas para predecir las variables de salida. No obstante, usar todas las funciones disponibles suele no ser el mejor enfoque. Las características que muestran estar ligeramente relacionadas con la variable de salida podrían afectar negativamente el proceso de aprendizaje. Por lo general, ciertas características están fuertemente acopladas entre sí, no proporcionando información adicional y desviando innecesariamente el resultado. Esto puede reducir el rendimiento del entrenamiento, al consumir recursos de cálculo innecesariamente.

El primer paso para seleccionar buenas características en un problema de Machine Learning es usar el criterio de un experto. El experto debe conocer bien el problema y puede seleccionar un conjunto de características suficientemente relevantes para ingresar en el algoritmo de aprendizaje automático. Esto es especialmente importante en la etapa de recopilación de datos, ya que la recopilación de datos de enseñanza puede llevar mucho tiempo y ser muy costosa.

Sin embargo, también se debe prestar atención para no eliminar características potencialmente importantes. Por lo tanto, y como indican Guyon & Elisseeff (2003), es importante tener en cuenta que la selección y extracción de características requiere experiencia y, a menudo, se trata de un proceso iterativo. A medida que se obtiene una visión más profunda del problema de estudio, podría ser necesario agregar o eliminar funciones para mejorar el rendimiento.

3. Resultados. Caso de estudio.

3.1. Machine Learning y Aguas de Solán de Cabras

La norma ISO 55000:2014 considera las instalaciones industriales como un activo de nuestras empresas, el objetivo último del mantenimiento es disponer de instalaciones robustas y confiables para las actividades de fabricación. .

En este sentido, el mantenimiento predictivo es una excelente herramienta para la gestión de activos y situaciones anormales de funcionamiento de las instalaciones industriales. Se utilizará el Machine Learning para impulsar el mantenimiento predictivo integral, con tecnologías de inteligencia artificial disruptivas.

Se pretende llevar cabo un piloto en la planta de embotellado de Aguas de Solán de Cabras, ubicada en Beteta (Cuenca). Donde equipos antiguos y nuevos coexisten en un entorno bastante dinámico en el que se implementan nuevas tecnologías y modernizaciones para mejorar la productividad y la eficiencia.

La aplicación se implantará en una máquina de llenado de chorro libre Modulfill del fabricante alemán Krones. La solución asignada se llevará a cabo de forma autónoma (aprendizaje no supervisado). Sin embargo, si no hay una coincidencia con una situación pasada, deberemos dotar al sistema del algún tipo de razonamiento de sentido común para intentar adivinar qué situación actual coincide con los eventos detectados (según las medidas proporcionadas por los sensores y categorizadas por los algoritmos de aprendizaje automático).

Figura 3: Llenadora Krones



Máquina rotativa compuesta por diversas partes móviles.

Una vez determinada una única hipótesis, esa se usa para la búsqueda de la solución más adecuada. Debido a la criticidad de la máquina, las acciones propuestas por el sistema se presentarán al operador, quien finalmente decidirá cómo proceder para abordar la situación. Además, este proceso se utilizará para actualizar la base de casos conocidos.

El procedimiento empírico permitirá evaluar el mejor ajuste del sistema a los requisitos de los expertos con experiencia variable, mejorando la capacidad de aprendizaje del sistema y el aumento general del rendimiento de la plataforma.

El contexto de la aplicación propuesta proporciona un escenario excelente para desarrollar casos de uso para el mantenimiento predictivo y mejorar el rendimiento obtenido con las metodologías existentes actualmente basadas en el mantenimiento correctivo y preventivo.

Sin embargo, las barreras actuales para adoptar un mantenimiento predictivo son el alto nivel de habilidad del algoritmo y el esfuerzo requerido en las etapas iniciales para adoptar tal tipo de solución.

Hoy en día, Aguas de Solán de Cabras dispone del departamento de Ingeniería de Activos Industriales (IAI) que gestiona el mantenimiento y al personal de mantenimiento de la fábrica, además de diversas subcontratas.

Basándose en la filosofía Lean Manufacturing, IAI se encarga de satisfacer la disponibilidad de las máquinas para mejorar el OEE global de la planta año tras año. Por este motivo, los tiempos muertos de producción tienen un costo asociado que se pretende minimizar con soluciones de Machine Learning.

3.1.1. Beneficios del aprendizaje autónomo en Solán de Cabras

La Gestión de mantenimiento o GMAO se realiza a través de un paquete de software ERP (JD Edwards, Oracle). No se registran datos relacionados con el mantenimiento y solo se almacenan los informes de mantenimiento que reflejan los problemas y eventos diarios existentes. Mediante Machine Learning se ayudará al equipo de mantenimiento a comenzar una estrategia de mantenimiento predictivo.

Debido a la situación del centro de producción (el centro productivo de Solán de Cabras se encuentra situado en la serranía de Cuenca), el stock de seguridad actualmente es superior a instalaciones semejantes, pero mejor situadas geográficamente (con mayor número de proveedores en la zona y mejor situada logísticamente). Este stock se establece en base a la experiencia del personal mantenimiento (si bien se empieza a trabajar con análisis de criticidad) y trata de lograr la mejor compensación entre minimizar los activos inmovilizados y tener el número máximo de piezas de repuesto para evitar tiempos de inactividad prolongados en la producción. El mantenimiento predictivo ayudará a optimizar el ciclo de vida de la maquinaria, optimizando el stock en el almacén.

Para las piezas más caras y otras con largos plazos de entrega, la política existente en el grupo Mahou-San Miguel es tener al menos una en stock en una de las fábricas del grupo. Así que prediciendo la rotura de los equipos y los plazos de entrega no será necesario tener gran cantidad de inmovilizado en el almacén.

Por otro lado, mediante el mantenimiento predictivo también se prevé mejorar el ratio de consumo energético. Anticipándose al mal funcionamiento de los equipos se evitará que las máquinas funcionen en regímenes de trabajo fuera de los límites, que por lo general, conllevan un mayor consumo de energía. La eficiencia energética tiende a aumentar a lo largo de los años debido a la sustitución de equipos antiguos por equipos nuevos y más eficientes.

Aunque aún no se disponen de suficientes datos para mostrar resultados, las expectativas sobre una estrategia de mantenimiento predictivo mediante Machine Learning son muy prometedoras.

4. Discusión y Conclusiones

En la primera parte de este artículo hemos visto qué es el aprendizaje automático y qué aporta al mantenimiento predictivo. Gracias al Machine Learning aplicado al mantenimiento predictivo se puede pronosticar el punto futuro de fallo de la máquina, o de un componente de la máquina, que se encuentre monitorizando.

El objetivo es adelantarse al fallo de tal forma que se puedan llevar a cabo las medidas necesarias. De este modo, el tiempo muerto del equipo se minimiza y el tiempo de vida de la máquina se maximiza.

En la segunda parte se discute el beneficio que este tipo de estrategia aporta a una empresa como Solán de Cabras. Algunos de los beneficios son:

- Optimización de los costes de mantenimiento.
- Disminución de fallos de funcionamiento.
- Reducción de stock de las piezas de repuesto.
- Aumento de tiempo medio de funcionamiento de la maquinaria sin paradas.

Aunque se ha expuesto un caso particular, estos beneficios son extrapolables a cualquier industria.

Entre otros, uno de los objetivos es que los trabajos desarrollados en Solán de Cabras puedan ser exportados a otros centros de fabricación del grupo Mahou-San Miguel.

5. Referencias bibliográficas

- Accorsi, R., Manzini, R., Pascarella, P., Patella, M., & Sassi, S. (2017). Data mining and machine learning for condition-based maintenance. *Procedia Manufacturing*, 11, 1153-1161.
- Bangert, P. (2012). Optimization for industrial problems. *Springer Science & Business Media*.
- Bangert, P. (2017, May). Smart condition monitoring using machine learning. *SPE Intelligent Oil and Gas Symposium*. Society of Petroleum Engineers.
- Baştanlar, Y., & Özuysal, M. (2014). Introduction to machine learning. *miRNomics: MicroRNA Biology and Computational Analysis* (pp. 105-128). Humana Press, Totowa, NJ.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Guyon I, Elisseeff A (2003) An introduction to variable and feature selection. *J Mach Learn Res* 3:1157–1182
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). The elements of statistical learning: data mining, inference, and prediction, *Springer Series in Statistics*.
- Huddlestone SH, Brown DE (2009) A statistical threat assessment. *IEEE Trans. Syst. Man Cybern. A Syst. Hum.* 39(6): 1307–1315.
- Huddlestone, S. & Brown, G (2018). Machine Learning. *Informatics Body of Knowledge*, 231-273

- ISO 55000:2014: Asset management - Overview, principles and terminology. Disponible en: <https://www.iso.org/standard/55088.html>
- Krishnamurthy, L., Adler, R., Buonadonna, P., Chhabra, J., Flanigan, M., Kushalnagar, N., ... & Yarvis, M. (2005). Design and deployment of industrial sensor networks: experiences from a semiconductor plant and the north sea. *Proceedings of the 3rd international conference on Embedded networked sensor systems* (pp. 64-75). ACM.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning. *New York: springer*. Vol. 112, p. 18.
- Ma, C., Zhang, H. H., & Wang, X. (2014). Machine learning for big data analytics in plants. *Trends in plant science*, 19(12), 798-808.
- McArthur, J. J., Shahbazi, N., Fok, R., Raghubar, C., Bortoluzzi, B., & An, A. (2018). Machine learning and BIM visualization for maintenance issue classification and enhanced data collection. *Advanced Engineering Informatics*, 38, 101-112.
- Susto, G. A., Schirru, A., Pampuri, S., McLoone, S., & Beghi, A. (2015). Machine learning for predictive maintenance: A multiple classifier approach. *IEEE Transactions on Industrial Informatics*, 11(3), 812-820.
- Tupa, J., Simota, J. & Steiner, F. (2017). Aspects of risk management implementation for Industry 4.0. *Procedia Manufacturing*, 11, 1223–1230