

2019
/2020

SIMBA

Sistema inteligente de mantenimiento
basado en el estado real del equipo

Nº Expte: IMDEEA/2019/8

Programa: PROYECTOS DE I+D EN COOPERACIÓN CON EMPRESAS

Resumen de resultados obtenidos

Breve descripción.

En el presente documento se describe un resumen de los resultados obtenidos en el proyecto durante la anualidad 2019-2020.

Realizado por:
AIDIMME



Contenido

1	OBJETIVOS DEL PROYECTO.....	3
2	DESPLIEGUE DE LA INFRAESTRUCTURA DE ADQUISICIÓN DE DATOS.....	5
3	DESARROLLO DEL SISTEMA DE ANÁLISIS DE DATOS.	15
3.1	Aprendizaje no supervisado	19
3.2	Mantenimiento basado en el estado de la máquina	29
3.3	Métodos predictivos	33
3.3.1	Método Support Vector Machine (SVM)	35
3.3.2	Redes neuronales.....	37
4	DESARROLLO DE LA INFRAESTRUCTURA DE COMUNICACIÓN.....	41
5	VALIDACIÓN EN EMPRESAS PILOTO	56
5.1	Interpretación de los datos	57
5.2	Rediseño de la tarjeta de adquisición de datos	62
5.3	Subida de datos y visualización	64
6	Conclusiones	69

1 OBJETIVOS DEL PROYECTO.

El proyecto aborda un tema cuyos primeros planteamientos se hicieron a finales de los años 80, cuando se empezó a hablar del mantenimiento predictivo. Esta disciplina ha evolucionado desde la medición puntual del estado de algunas variables cada cierto tiempo con equipos portátiles, hasta la monitorización en continuo mediante un conjunto de sensores instalados de forma permanente en el equipo a controlar, y el establecimiento de alertas para avisar de un funcionamiento fuera de rango que advierte de un posible fallo en algún componente. De hacerse correctamente, el mantenimiento basado en el estado real del equipo de producción nos ofrece lo mejor de los dos mundos: la minimización de los costes de los recambios y la minimización de los costes de las paradas de la producción.

Bien es cierto que la aplicación de esta tecnología requiere cierta inversión económica, un personal cualificado para la instalación de los sensores, unos instrumentos de análisis matemático, un estudio de las señales de los sensores y una elaboración del modelo matemático predictivo basado en el análisis de los datos con diversas técnicas estadísticas, de redes neuronales y de aprendizaje de máquina.

La exigencia de estos requerimientos han hecho que el mantenimiento basado en las condiciones reales de las máquinas esté reservado a instalaciones muy críticas, o cuya parada supone un coste elevado, y habitualmente aplicado por grandes empresas. Por lo general, este tipo de actuación ha quedado fuera del alcance de la PYME industrial de los sectores tradicionales, tanto por la dificultad técnica y de conocimiento para su aplicación, como por el coste que aparentemente puede suponer el averiguar las condiciones reales de funcionamiento de una máquina e interpretar las mediciones.

Con este proyecto se pretende generar el conocimiento suficiente para que cualquier empresa mínimamente preparada pueda aplicar criterios basados en el estado real de sus máquinas para detectar y predecir funcionamientos no deseados, y anticiparse al fallo realizando la operación de mantenimiento que corresponda. Dada la complejidad del tema, se aplicará inicialmente a dos de los equipos productivos más utilizados en las PYMES del sector metalmeccánico de la Comunitat Valenciana: prensas de estampación en frío y tornos de decoletaje o similares.

Para ello se investigarán las variables que mejor permiten determinar la condición de cada equipo, ya que más allá de las vibraciones existe una panoplia de posibles variables relevantes en cada caso: sonidos de diversas frecuencias, temperaturas, consumo energético, estado de los fluidos, etc. Además se establecerá dónde y cómo deben medirse cada una de las variables definidas. Y una vez se consiga la información significativa en tiempo real se creará un sistema que, con mínima intervención humana, pueda analizar esta información y generar la respuesta adecuada en dos sentidos: el equipo funciona correctamente, o el equipo muestra probabilidades de fallo potencial en alguno de sus elementos, y requiere intervención.

Por tanto el objetivo final del proyecto es desarrollar un sistema inteligente de análisis del funcionamiento de dos clases determinadas de máquinas (prensas de estampación y tornos automáticos), basándose en la información en tiempo real facilitada por un conjunto de sensores que miden diversas variables de los equipos. Este sistema inteligente, ubicado en una plataforma ad-hoc, será accesible a cualquier empresa del sector que siga los protocolos de medición definidos previamente, y los resultados de las predicciones podrán ser visualizados de forma continua por cada empresa usuaria.

Como resultado del análisis realizado por el Sistema Inteligente (SIMBA), se determinará si el estado real observado es un estado normal de funcionamiento del equipo o si, por el contrario, se identifica con un estado de avería de la máquina.

- Adicionalmente, el sistema inteligente observará la evolución temporal del estado real del equipo para determinar si se está produciendo un deterioro, y el margen temporal del mismo. De esta forma se predecirá el probable fallo del equipo para realizar una operación de mantenimiento antes del paro por avería del equipo.

2 DESPLIEGUE DE LA INFRAESTRUCTURA DE ADQUISICIÓN DE DATOS.

En la anualidad 2018/2019, debido a las dificultades encontradas en el desarrollo de los sistemas de medición, no fue posible completar la instalación de los dispositivos desarrollados en las máquinas de las empresas piloto a fecha de junio de 2019, por lo que no se pudieron obtener datos reales que permitiesen validar el procedimiento. Esta tarea se ha completado en la segunda anualidad.

INSTALACIÓN DE SENSORES EN LA EMPRESA PILOTO FACTOR

En esta empresa se seleccionó un torno de decoletaje para instalar los sensores de captura de datos, concretamente el torno Nakamura 2.

Se han instalado los siguientes sensores:

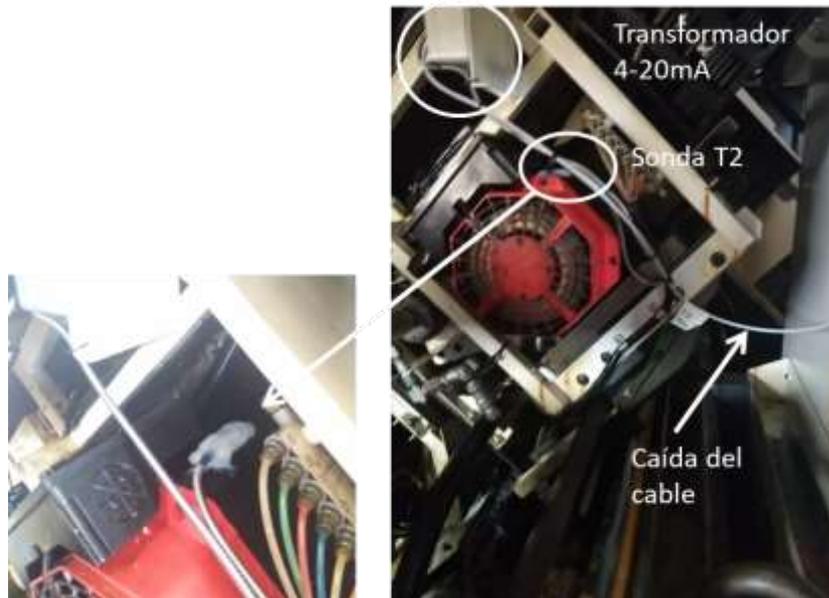
- Temperatura - 6 sondas: identificadas como T2, T3, T5, T7, T8 y T9 en las imágenes siguientes.
- Aceleración - 2 acelerómetros triaxiales: uno de ellos en el contracabezal y otro en la torreta inferior.
- Sonido - 1 micrófono, cercano a los mecanismos de la zona del contrabezal.
- Potencia (corriente) - 3 transformadores: medición del motor del eje Z de la torreta “upper”, medición del motor del eje Z de la torreta “lower” (ambos motores utilizados para operaciones de taladrado), medición del motor del eje X de la torreta “upper” (utilizado para operaciones de tronzado).

En las imágenes siguientes puede verse un ejemplo de cada sensor instalado.

Sondas de temperatura



- La sonda se ha fijado en una parte recta de la carcasa mediante adhesivo y se ha recubierto mediante silicona.
- El transformador de señal de voltaje a 4-20mA, se ha colocado en la parte superior fijado con un tornillo y bridas.
- Al tratarse de un motor con desplazamiento se le ha dado al cable de señal cierta caída para que no se tense en exceso con el movimiento



Acelerómetros



El acelerómetro se ha colocado en una zona donde se traslada el movimiento y vibración del contracabezal de la máquina



Sensores de corriente



- Se han colocado tres sensores de corriente con rango 0-100A, que miden los siguientes motores.
- C1: eje z “upper”
- C2: eje z “lower”
- C3: eje x “upper”

Micrófono

S1. Zona cercana contrazabzal y torreta inferior



INSTALACIÓN DE SENSORES EN LA EMPRESA PILOTO KAMAX

En la empresa KAMAX se ha realizado la instalación de sensores en dos máquinas similares, pero una de ellas con una antigüedad de 10 años y otra nueva. El propósito de la instalación doble es poder comparar datos entre ambas y extraer información de más valor para el objetivo perseguido.

La prensa combinada SP48 CRM, es una máquina que produce tornillos terminados, estándar y especiales, mediante deformación en frío de alambre metálico o alambroón, devanado en rollo.



En ambas máquinas se van a instalar, a priori, los siguientes sensores

- Temperatura: 7 sondas.
 - o 1 en la roscadora
 - o 6 en diferentes zonas de la estampadora
- Aceleración: 2 acelerómetros triaxiales
 - o 1 en la zona del eje principal, en la parte de la fundición.
 - o 1 en la caja de engranajes de la roscadora.
- Sonido: 2 micrófonos (Hasta 20kHz)

Las ubicaciones posibles serían:

- o 1 cercano a la zona de la roscadora.
- o 1 cercano a la zona de la estampadora.

- Potencia (corriente): 2 transformadores
 - o 1 para en consumo del motor principal.
 - o 1 para el consumo del motor de la punteadora (5'5 KW, alterna)

El ordenador y cuadro donde se han ubicado las diferentes placas y tarjetas de lectura de datos, así como la fuente de alimentación de las mismas y de los sensores se ha ubicado en la esquina derecha de la pared situada en frente de la máquina.



Sondas de temperatura

T7, T5. Temperatura en casquillos de la biela (Estampadora)

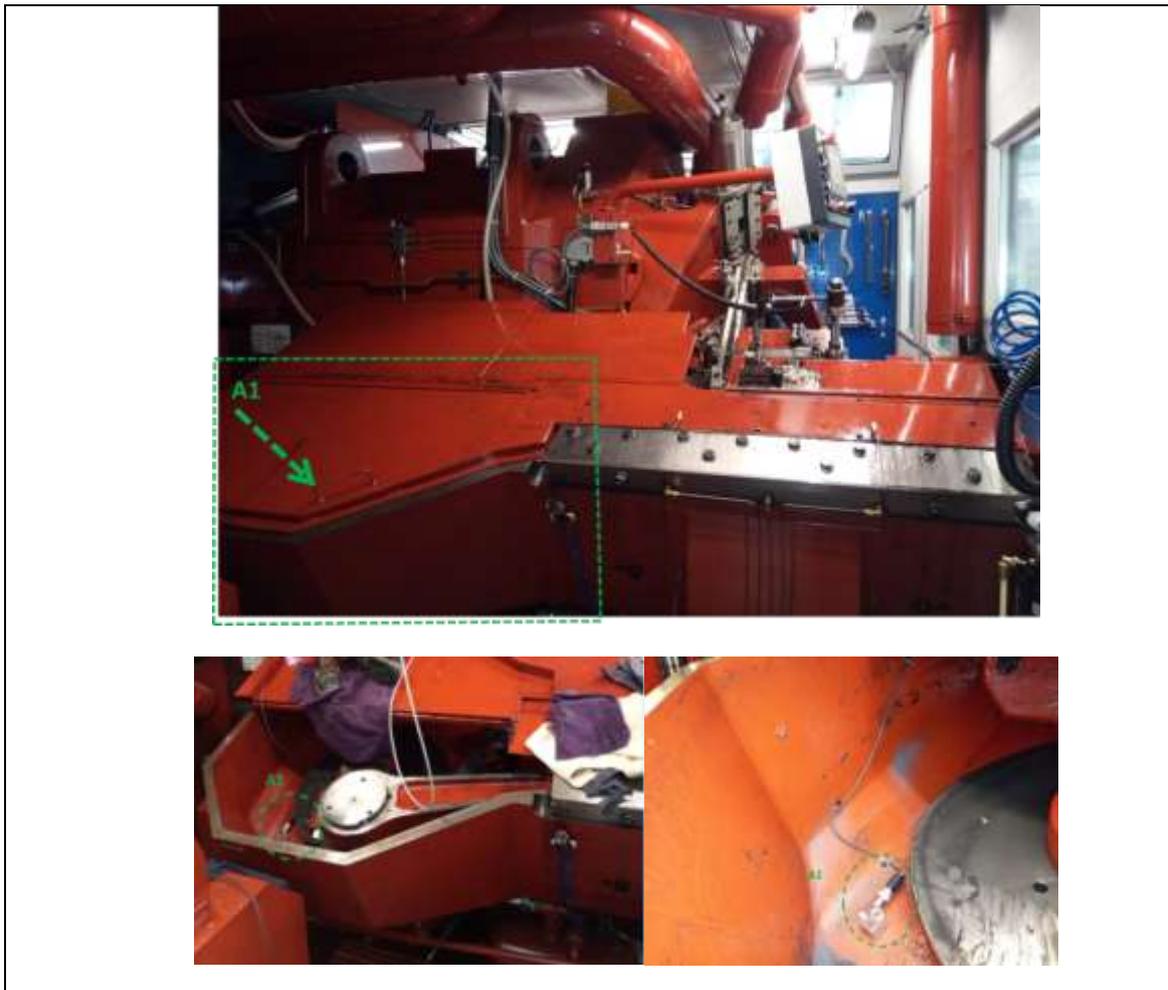
Se han instalado 2 sensores de temperatura en una zona de fundición cercana a los casquillos de la biela, situada bajo el carro de la estampadora. En la siguiente imagen la tapa está cerrada y no se pueden apreciar las sondas, pero si las cajas donde se alojan los transformadores de 4-20mA, necesarios para su lectura.



Acelerómetros

A1. Acelerómetro en la zona de la roscadora

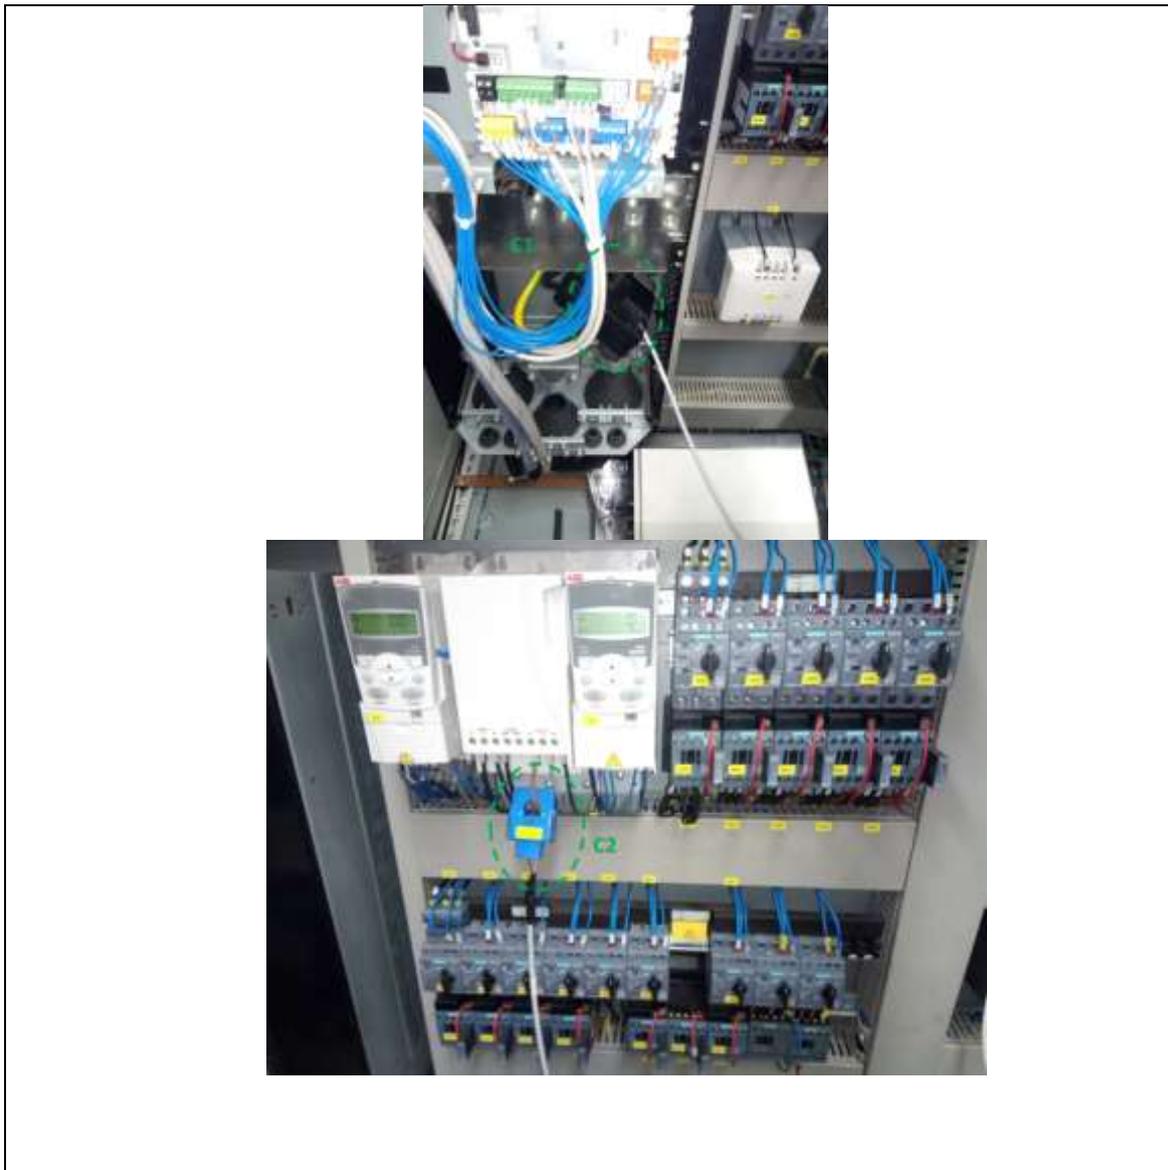
Para detectar problemas de holgura de la biela de la roscadora. Se ha instalado 1 acelerómetro en la caja de engranajes situada en la izquierda, junto a un volante de inercia.



Sensores de corriente

C1-C2. Sensores de consumo de corriente motores

Se han instalado 2 transformadores de corriente para medir el consumo del motor principal de la máquina y el de la punteadora.



Micrófonos

S1, S2. Zona s de la roscadora y de estampación.

Se ha preparado la instalación para colocar 2 micrófonos. El primero en la zona de la roscadora, y el segundo en la zona de la estampadora.

3 DESARROLLO DEL SISTEMA DE ANÁLISIS DE DATOS.

Dentro de este paquete de trabajo se han desarrollado dos actividades: en primer lugar la evaluación de los sistemas existentes para el análisis de datos, seleccionando los más adecuados para el proyecto; seguidamente los sistemas seleccionados se han validado utilizando para ello los datos recogidos en las empresas piloto. A continuación se muestra un resumen de las actividades realizadas.

En primer lugar se exploran las técnicas de analítica de datos utilizables para la creación de sistemas de mantenimiento predictivo, explicando las técnicas de aprendizaje automático e inteligencia artificial pertinentes, detallándose su funcionamiento, sus ventajas y sus desventajas. Las técnicas exploradas son las siguientes:

- Técnicas de regresión
 - Regresión por mínimos cuadrados
 - Descenso de gradiente
 - Redes neuronales
- Técnicas de clasificación
 - K-Vecinos más cercanos
 - Naive Bayes
 - Máquinas de vectores soporte
 - Redes neuronales
- Técnicas de reducción de dimensionalidad
 - Análisis de componentes principales
 - Análisis del discriminante lineal
- Proyecciones aleatorias
- Extracción de características
- Algoritmos de agrupamiento
 - K-medias
 - Método de la silueta
 - Método del codo
 - DBSCAN
 - Agrupamiento jerárquico

Una vez explicadas las herramientas existentes, se evalúan los posibles casos en los que se puede encontrar un conjunto de datos y qué herramientas se puede utilizar en cada caso para el sistema de mantenimiento predictivo.

En todos los supuestos, vamos a partir de datos tomados por sensores. Este tipo de dato se suele caracterizar por tener una gran densidad, los sensores son capaces de tomar medidas muy rápido, permitiendo un dato o más cada segundo lo que conlleva grandes bases de datos en muy poco tiempo. Estos datos siempre incluyen un campo indicando la fecha y la hora exacta en la que se tomaron, este campo es el que da estructura a las

medidas, pues indica el orden que mantienen las medidas, y será fundamental para el desarrollo de cualquier estrategia.

Las variables que se miden, y por tanto aquellas de las que se dispone de datos son:

- Vibraciones
- Sonido
- Temperatura
- Consumos de energía

Teniendo claros los elementos existentes en el dataset, falta definir el tipo de etiqueta que van a tener los datos. Para esto vamos a desglosar varios supuestos que se pueden presentar y cómo atacar cada uno de esos problemas.

Supuesto 1: Trabajo sin datos de mantenimiento

Este es el caso más directo, en el cuál tenemos un dataset completamente sin etiquetar. Dado que no tenemos un conocimiento que aprender, debemos recaer en el aprendizaje no supervisado. Este es el supuesto en el que nos encontraremos en empresas que no lleven un registro riguroso de mantenimientos, que este conocimiento no sea fácil de obtener (por ejemplo, se toma en papel) o que la dirección no desea facilitarlos por ciertas razones.

En este caso, debido a la gran cantidad de datos que reportan los sensores, se empezará utilizando métodos de reducción de dimensionalidad. Al tratarse de datos no etiquetados, el método PCA o las proyecciones aleatorias pueden ofrecer buenos resultados.

Identificación de estados problemáticos

En esta estrategia, el siguiente paso que puede darse es utilizar un agrupamiento. Podemos utilizar el algoritmo de k-medias, junto con el método de la silueta o bien el método del codo, para obtener un agrupamiento en un número de clases.

Se obtendrá una separación del conjunto de los datos y una forma de clasificar los nuevos datos entrantes dentro de estos. Es importante ahora relacionar cada uno de los estados obtenidos con un significado físico real. Es posible que alguno de ellos se produzca cuando la máquina tiene la necesidad de recibir mantenimiento, incluso es posible que los distintos estados indiquen distintos tipos de mantenimiento.

Si se sigue esta estrategia, es muy posible que haya dos estados mayoritarios muy bien diferenciados: máquina funcionando y máquina parada. El estudio de los estados complementarios es el camino para obtener un buen sistema.

Mantenimiento basado en la condición

Una vertiente diferente es analizar el comportamiento de las variables tras aplicar una reducción de dimensionalidad si procede. Podemos utilizar conceptos estadísticos para analizar la distribución de estas variables, en particular podemos observar cuando las variables se desvían demasiado de sus estados habituales. Se puede configurar un sistema que detecte cuando alguna de las variables se separa más de 2 desviaciones típicas de la media. Si este comportamiento se mantiene en el tiempo, puede significar que la máquina está entrando en un estado anómalo que necesita corrección, teniendo así la posibilidad de notificar el momento en el que se da esta circunstancia.

Supuesto 2: Trabajo con datos de mantenimiento correctivo

En este supuesto, se dispone de un sistema de mantenimiento correctivo y tenemos acceso a los datos generados por éste. Normalmente, este tipo de datos vendrá en una tabla indicando la marca de tiempo que indica el momento de ejecución de los mantenimientos. Además, si los datos fueran suficientemente rigurosos, tendríamos desglosado el tipo de mantenimiento que se realiza. Veamos cómo podemos abordar el problema en función de la calidad de los datos.

Si no se dispone de datos del mantenimiento realizado

En este caso nuestro objetivo será discernir si a la máquina se le ha realizado mantenimiento o no, sin especificar claramente el tipo de mantenimiento realizado. Para hacer esto, y dado que en este supuesto sí tenemos un conocimiento que queremos enseñar a nuestros algoritmos, utilizaremos aprendizaje supervisado. Los datos, serían únicamente una lista con los momentos en los que se han realizado los mantenimientos:

FECHA_HORA

2020-01-15 13:17

2020-01-15 20:45

...

En este caso, para transmitir este conocimiento a etiquetas, podemos utilizar 2 vertientes: clasificación o regresión.

Clasificación

Es el caso más simple, vamos a crear 2 etiquetas: 'correcto' y 'necesita mantenimiento'. Etiquetamos los momentos en los que se realiza un mantenimiento como 'necesita mantenimiento' y el resto como 'correcto'. Esta primera aproximación resulta problemática por dos razones:

- La base de datos está muy desbalanceada, la gran mayoría de los datos serían ‘correcto’ mientras que unos pocos puntuales, caerían en ‘necesita mantenimiento’.
- Aunque consiguiéramos un sistema de clasificación perfecto, el modelo solamente sería capaz de avisarnos cuando ya se ha producido la rotura, por lo que sería completamente inútil desde el punto de vista productivo.

Para solucionar estos dos problemas, vamos a utilizar otra aproximación: Marcamos como ‘necesita mantenimiento’ los momentos indicados por la tabla de mantenimiento y además todos los registros que se encuentren en un rango temporal determinado inmediatamente anterior al marcaje de realización de mantenimiento. De esta forma solucionamos ambos inconvenientes de la aproximación anterior. La longitud del rango temporal dependerá directamente del largo de la vida útil de las piezas, lógicamente deberá ser proporcional, aunque se debe experimentar con un margen para comprobar qué arroja mejores resultados en cada caso.

De esta forma se construye el problema de clasificación binaria que buscábamos. Para este caso serían muy útiles las máquinas de vectores soporte (SVM) o las redes neuronales (NN). Una vez generado el modelo, podemos utilizar clasificar en tiempo real y lanzar un aviso de mantenimiento necesario si el clasificador está devolviendo la etiqueta ‘necesita mantenimiento’ por un tiempo superior a un margen de seguridad seleccionado para evitar falsos positivos.

Regresión

En esta vertiente vamos a utilizar números para transmitir el conocimiento a la algoritmia. En este caso la cantidad que estaremos midiendo será el tiempo de vida útil que le queda a la máquina (o la pieza) hasta la parada. Para calcular este número basta con etiquetar el registro en el que se realiza el mantenimiento como 0, los anteriores, se etiquetarán de manera ascendente indicando el número de segundos restantes hasta el mantenimiento.

Podemos utilizar redes neuronales para solucionar este problema. Configuraremos un sistema de alarma que nos avise cuando la vida útil prevista se encuentre por debajo de cierto umbral por un tiempo superior al límite de seguridad que establezcamos.

Si se dispone de datos del mantenimiento realizado

En este caso, la empresa habría estado clasificando los mantenimientos dependiendo del tipo, por lo que se dispondrá de datos con un aspecto similar al siguiente:

FECHA_HORA	Mantenimiento
2020-01-15 13:17	Cambio de correa
2020-01-15 20:45	Cambio de bobinas
...	...

Utilizaremos los mismos métodos explicados en el apartado anterior, con la diferencia de que ahora nos enfrentamos a un problema de clasificación multiclase, por lo que deberemos elegir de manera correcta la aproximación que utilizamos. Se consideran dos posibilidades:

- Solucionarlo como un problema de clasificación multiclase, para lo que una red neuronal con tantas salidas como clases sería una buena elección.
- Dividir el problema en un clasificador por tipo de mantenimiento. En este caso caeríamos exactamente en generar un clasificador como se describió en el apartado anterior para cada tipo de mantenimiento. De esta forma tendríamos tantos clasificadores como tipos de mantenimiento y cada uno de ellos sabrá adelantar la necesidad de mantenimiento únicamente de su tipo. No todos los clasificadores tienen que ser igual de buenos, por lo que esta aproximación permite compararlos y utilizar únicamente los que ofrezcan buenos resultados, descartando el resto. Podríamos utilizar la estrategia de clasificación o de regresión, tal como se explicó anteriormente.

Supuesto 3: Trabajo con datos de mantenimiento preventivo

En este caso, a pesar de tener datos, no nos resultan útiles (Gian Antonio Susto, 2015), ya que nos encontramos que los datos no guardan conocimiento alguno sobre el estado de la máquina. Es posible que haya alguna rotura puntual anterior a la aplicación del mantenimiento, pero este no es el caso general, pues de serlo, estaríamos ante una política de mantenimiento con un mal desempeño que indicaría los datos más parecidos a los de un mantenimiento correctivo.

Por estas razones, carecemos de conocimiento que enseñar a los algoritmos por lo que se deberían utilizar las mismas estrategias vistas en el supuesto 1, optando por métodos de aprendizaje no supervisado.

3.1 Aprendizaje no supervisado

Seguidamente se muestra los experimentos realizados sobre los datos de las empresas KAMAX y FACTOR con el objetivo de desarrollar los sistemas de mantenimiento predictivo adecuados en cada caso.

Como se ha indicado anteriormente, en la empresa KAMAX se han instalado elementos para realizar las siguientes mediciones:

- Siete mediciones de temperatura
- Dos mediciones de aceleración en tres ejes
- Dos mediciones de sonido
- Dos mediciones de consumo de corriente eléctrica

Los acelerómetros y micrófonos reportan 20 datos (por eje, en el caso de los acelerómetros) divididos en 10 de amplitud y 10 de frecuencia, por lo que los datos de todos los sensores ocupan 174 columnas. Los datos para el análisis mostrado se han tomado durante tres meses, a una frecuencia de 1 segundo por medición, reportando un total de más de 5.000.000 de filas.

Por su lado, en la empresa FACTOR se ha instalado los elementos necesarios para realizar las siguientes mediciones:

- Seis mediciones de temperatura
- Dos mediciones de aceleración en tres ejes
- Una medición de sonido
- Tres mediciones de consumo de corriente eléctrica

Al igual que en KAMAX, los acelerómetros generan 60 variables (20 en cada eje) de la descomposición en serie de Fourier, el micrófono 20 y el resto 1 por sensor

El rango de estudio en FACTOR es mucho menor, ya que para la prueba se ha utilizado alrededor de una semana de recolección. Esto supone un total de cerca de 150 MB de datos que se materializan en unas 400.000 filas.

Únicamente se dispone de datos de mantenimiento preventivo, pero como se indicó en el análisis de los sistemas existentes, estos datos no aportan información de valor para el análisis.

De entrada, sólo se pueden realizar análisis utilizando métodos de aprendizaje no supervisado.

ANÁLISIS DE DATOS

Debido a la magnitud de los datos, estos resultan intratables en un tiempo computacional razonable si no se realiza algún tipo de reducción o compresión. Por ello, el primer paso ha sido realizar una purga de aquellos registros que resulten menos útiles

ya que los sensores obtienen datos 24 horas al día 7 días a la semana independientemente del funcionamiento o la planificación de la planta.

Reducción de dimensionalidad

Una vez observado que el número de filas no puede ser reducido, vamos a trabajar con el número de columnas. Para esta tarea se utilizan métodos conocidos como reducción de dimensionalidad. Las herramientas más potentes que tenemos a nuestra disposición son 3: PCA, LDA y proyecciones aleatorias. El método de proyecciones aleatorias suele utilizarse para elementos de dimensión muy grande, en este caso se considera que no tenemos tantas dimensiones como para tener que utilizarlo por lo que queda descartado. Por su parte, el análisis del discriminante lineal (LDA) se utiliza sobre conjuntos de datos clasificados para maximizar la separabilidad. Siendo que nuestros datos no están etiquetados, no cabe la utilización de este algoritmo.

El análisis de componentes principales (PCA), por el contrario, parece idóneo para esta situación, ya que intentamos maximizar el distanciamiento entre las proyecciones que obtengamos para perder la menor cantidad de información inherente a los datos posible. Además, la dimensión de los datos no es excesivamente grande como para hacer este algoritmo computacionalmente (en este caso sí habríamos optado por las proyecciones aleatorias) y tiene son datos no etiquetados por lo que no hay que maximizar separabilidad (hubiéramos optado por LDA).

Vamos a aplicar el algoritmo sobre los datos. Además, vamos a pedir que se mantenga un 95% de significancia de los datos, es decir, que los autovalores elegidos (en este caso realmente los valores singulares), para formar el espacio vectorial mediante los autovectores, representen el 95% de la suma de los autovalores.

Debido a que todas las variables se mueven en rangos distintos, es necesario utilizar la normalización de datos sobre nuestro conjunto, ya que si no, se verían sobrevaloradas las variables con rangos más altos lo cual estropearía nuestro aprendizaje. Por ello debemos hacer que todas las dimensiones funcionen sobre una misma base, para ello utilizamos la normalización, es decir, sustituimos cada variable x por x_{norm} de la siguiente manera:

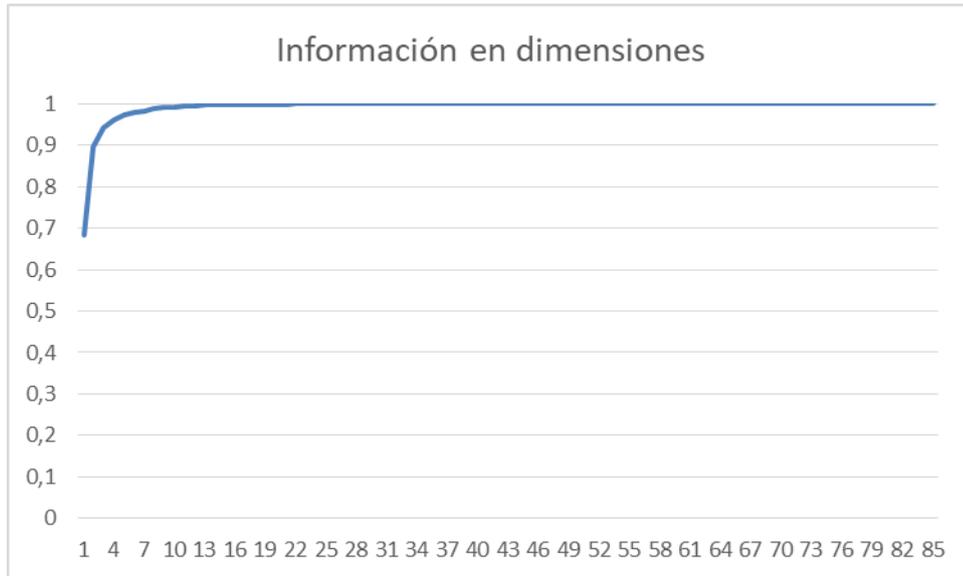
$$x_{norm} = \frac{x - \bar{X}}{\max(X) - \min(X)}$$

Donde X es el conjunto tal que $x \in X$ y \bar{X} es la media del conjunto.

De esta forma todos los datos estarán en el mismo rango, entre -1 y +1 permitiendo que sus dimensiones no afecten a la reducción y por tanto no se pierda información.

Al aplicar PCA en el caso de KAMAX, se consigue la matriz de valores singulares, ordenados de mayor a menor. Con esta podemos plasmar en una gráfica la información

que contiene cada dimensión, basta con obtener el peso que tiene cada valor sobre la suma de todos. Con este simple cálculo hecho, podemos plasmar esta información en una gráfica que nos indique la información que se obtiene eligiendo 1, 2 ,3... u 85 dimensiones. El eje X indica cuantas dimensiones elegimos mientras que el eje Y nos indica la cantidad de información (sobre 1). La gráfica es la mostrada a continuación:



Gráfica de reducción de dimensionalidad con datos de KAMAX

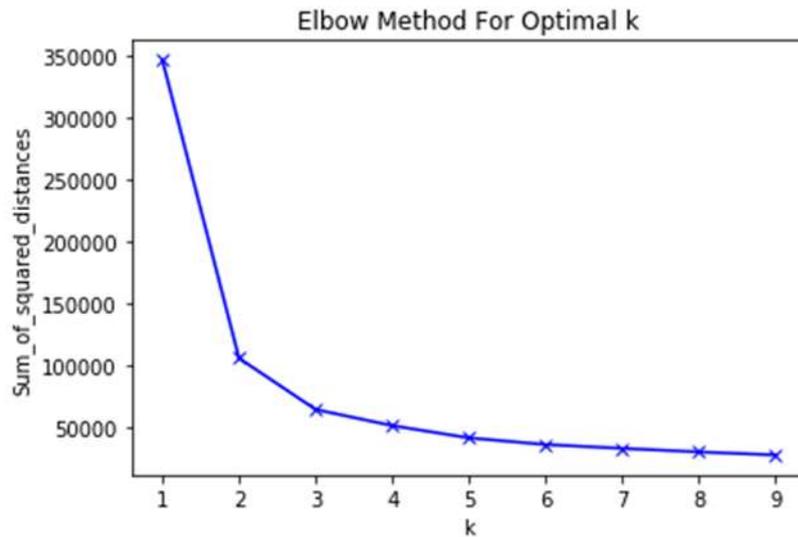
Podemos ver que con sólo 4 dimensiones, ya se supera el umbral del 95 por ciento de información. Esto supone un ahorro de espacio gigantesco pues implica que con un 4.7% de los datos, podemos mantener el 95% de información. Con esta reducción conseguimos que sea mucho más rápido aplicar algoritmos de agrupamiento

Realizando el mismo análisis con los datos de FACTOR, se observa que necesitamos seleccionar 36 dimensiones para mantener el 95% de la información. En este caso, dado el alto resultado en dimensiones, se reducen las exigencias únicamente a que mantengan el 90% de la información. Con esta condición se puede reducir la cantidad de dimensiones a 28. A pesar de no tratarse de una reducción tan drástica como en el caso anterior, hemos conseguido reducir en un 67% la cantidad de datos almacenada y aun así se mantiene el 90% de la información.

Agrupamiento

KAMAX

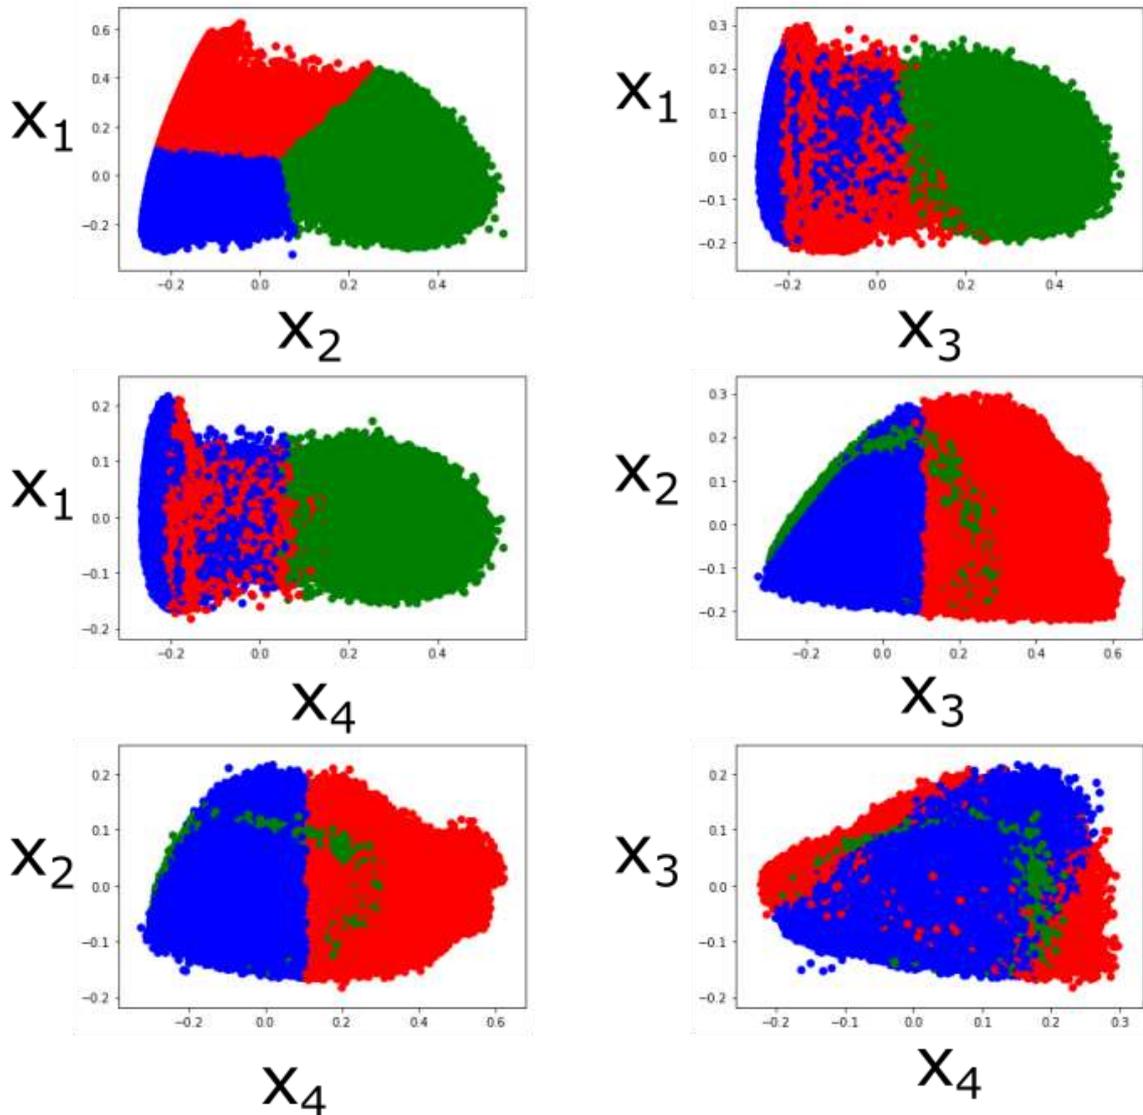
Pasamos ahora aplicar los algoritmos de clustering. Un inconveniente de este método es que se debe indicar el número de clústeres a formar mediante la variable k. Dado que a priori no tenemos idea de la cantidad de grupos que queremos formar, vamos a intentar averiguar cuál es el número que mejor encaja con la forma misma de los datos. Aplicando el método del codo para establecer los grupos a formar, se obtiene la siguiente gráfica:



Número óptimo de clústeres con los datos de KAMAX

Podemos ver que el método del codo nos indica que el valor apropiado para el número de grupos a crear es 3, por lo que procedemos a ejecutar quedándonos únicamente con este valor.

Al tratarse de 4 dimensiones, es imposible que se pueda visualizar el resultado de manera directa, sin embargo, es posible ver las proyecciones de los datos clasificados en los clústeres generados por cada 2 variables, generándose las proyecciones que se muestran a continuación:



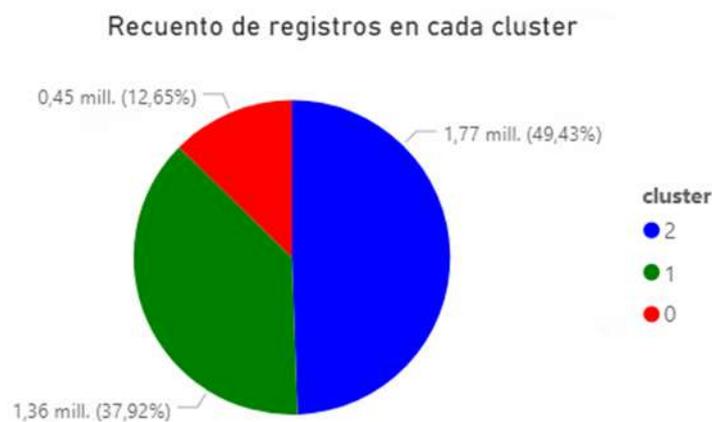
Proyecciones bidimensionales de las cuatro variables de KAMAX

Podemos ver que los datos parecen bastante prometedores, pues en la mayoría de proyecciones se pueden apreciar diferencias claras entre los conjuntos, especialmente en la proyección sobre las variables x_1 y x_2 . Podemos apreciar que la variable x_1 conlleva un peso grande dentro del conjunto pues en todas las proyecciones en las que se encuentra presente se puede separar casi linealmente al menos un conjunto, propiedad que no observamos en las demás proyecciones. Esto se debe a que x_1, x_2, x_3, x_4 resultan las proyecciones sobre los subespacios de mayor a menor significación que nos ha reportado PCA. Esto se ve reflejado en el resultado mostrado por KMEANS. Se puede apreciar también en la proyección en x_3 y x_4 que al ser las variables de menor significancia, no resultan relevantes para la clasificación, por lo que

es muy difícil separar un conjunto de otro en esta proyección. Quedan como casos intermedios las proyecciones que incluyen x_2 que, si bien, realizan un gran trabajo separando los conjuntos rojo y azul, resultan inútiles para diferenciar de estos el conjunto verde.

La existencia de 3 estados es un resultado prometedor. Normalmente es de esperar al menos dos estados distintos: uno que represente la máquina en funcionamiento y otro que haga lo propio con la máquina parada, pues los resultados de sonido, vibraciones, temperatura y corriente resultan diametralmente opuestas en estas dos situaciones. Un tercer estado nos representará algún tipo de estado nuevo.

Una ayuda para entender el significado de cada estado es visualizar el porcentaje de registros que se ha clasificado en cada clúster, esto se muestra en la siguiente gráfica:



Gracias a esta gráfica, entendemos que el estado en el que se encuentra la mayoría del tiempo es azul (2), que ocupa prácticamente la mitad de su tiempo (49.43%). Por su parte, el estado 1 ocupa el 37,9% del tiempo siendo el segundo estado principal. Por último, vemos que el estado 0, el rojo, supone un tiempo marginal que no llega al 13%, este será nuestro candidato de estudio de anomalías.

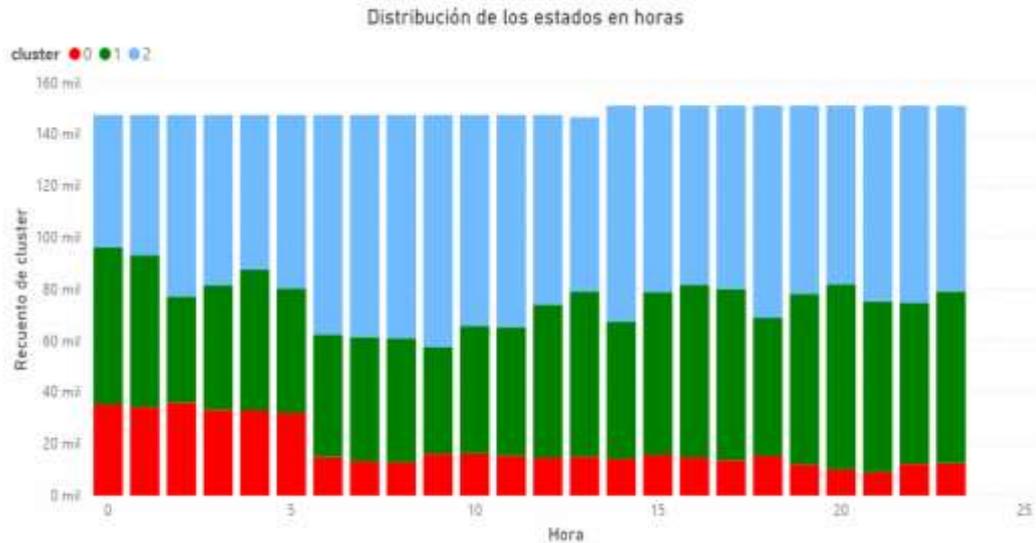
Otra visualización interesante es plasmar estos estados sobre los días de estudio, generando una gráfica que nos permita ver el porcentaje de tiempo dedicado a cada estado durante el tiempo de estudio, esta gráfica se puede ver a continuación:



Porcentaje de tiempo diario que la máquina se encuentra en cada estado

Podemos ver que el azul (representado en azul claro por cuestiones de visibilidad) es mayoritario y se encuentra todos los días, por su parte, el verde, aparece la mayoría de días, pero no todos, ya que hay días como el 31 de enero o el 3 de marzo que nos indican que es posible que la máquina no esté en este estado durante 24 horas seguidas. Por último, el estado rojo aparece también en todos los días aunque con una variabilidad alta.

La última gráfica que tendremos en consideración en este apartado será distribuir a través de las horas del día los resultados obtenidos, en el que se representa el estado azul más claro para facilitar la visualización de la gráfica:

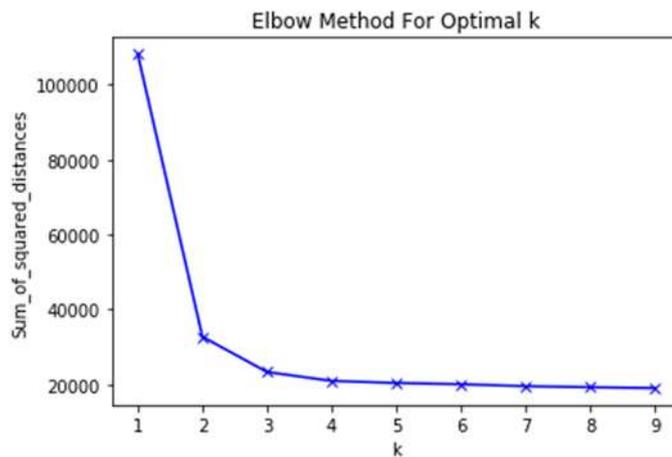


Porcentaje promedio de tiempo que la máquina se encuentra en cada estado a lo largo de un día

En esta gráfica se representa la cantidad de registros que se han captado en cada hora del día. No aparece bajo una inspección simple ninguna información a resaltar ya que no se encuentran grandes diferencias entre los registros a lo largo de las horas.

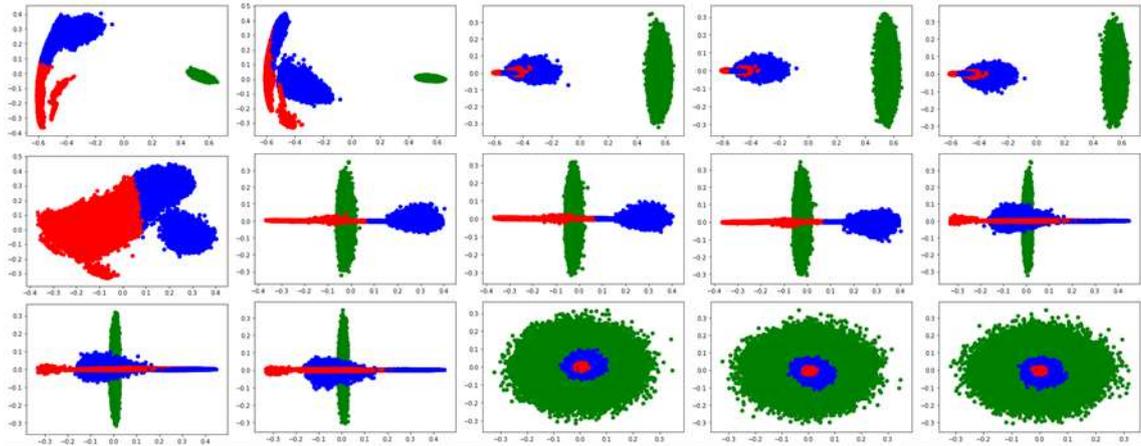
FACTOR

Aplicando el mismo método a los datos de la máquina de FACTOR, se obtienen tres grupos relevantes, al igual que ocurría en el caso de KAMAX, por lo que las conclusiones que extraeremos serán similares.



Número óptimo de clústeres con los datos de FACTOR

Al igual que en el caso anterior, podemos intentar visualizar los grupos formados, sin embargo, al tratarse de 28 variables, tendríamos que visualizar muchas gráficas para ver todos los pares de dimensiones, en particular, hablamos de 378 posibles combinaciones. Seguidamente se muestran únicamente las 15 primeras gráficas, que corresponden con las posibles combinaciones de las 6 primeras variables, que son las más significativas. Se pueden ver a continuación:



Proyecciones bidimensionales de las primeras seis variables de FACTOR

Podemos ver a continuación la distribución de estos estados:

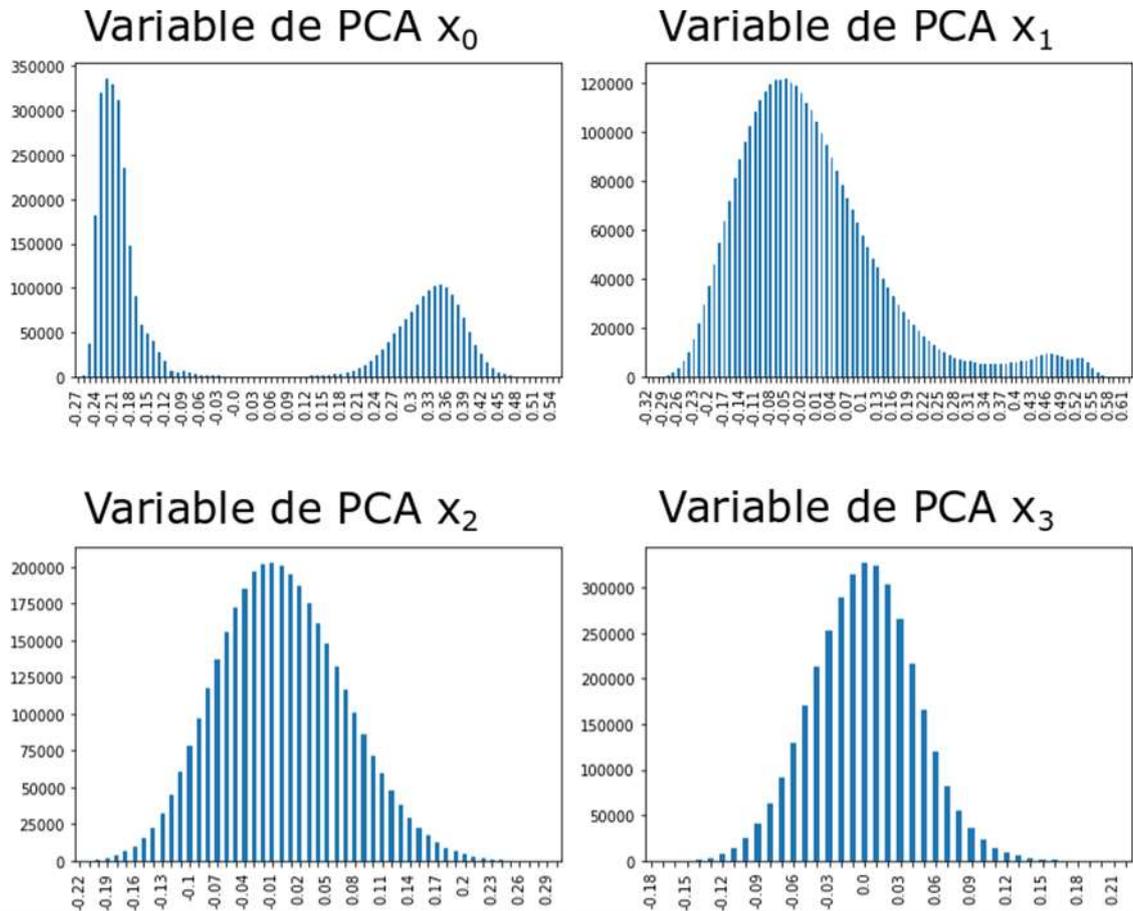


3.2 Mantenimiento basado en el estado de la máquina

Una vez que se dispone de los resultados en cuanto a la clasificación no supervisada de los datos, se puede pasar a buscar maneras de mostrar cuando la máquina se encuentra en un estado no habitual.

Un método directo es el mantenimiento basado en la condición. La filosofía del método se basa en establecer las condiciones en las que se encuentra la máquina cuando funciona en un estado normal, y cuando se detecte un alejamiento de las condiciones normales se entenderá que se está pasando a una condición de funcionamiento anómala, y por tanto se notificará este comportamiento. Es posible que el alejamiento de la normalidad se deba a una causa aleatoria en los propios datos, sin que necesariamente implique un mal funcionamiento de la máquina, por lo que se necesitaría una validación a posteriori de que la desviación detectada es correcta, o no.

Para implementar este tipo de mantenimiento, nos apoyaremos en la estadística. Vamos a trabajar sobre las 4 variables virtuales obtenidas mediante el análisis de componentes principales, que recordemos que al estar normalizadas se mueven entre -1 y +1. Representando las gráficas de frecuencias de estas 4 variables:



Se puede observar que, a excepción de la variable x_0 , todas las variables muestran una gráfica de frecuencias muy similar a una función normal.

Para las variables x_1, x_2, x_3 , utilizaremos como valores habituales los que estén a menos de 2 desviaciones típicas de la media. Por su parte la variable x_0 resulta más complicado, aunque se puede apreciar que esta variable aparece en un patrón que representa 2 funciones normales, por tanto, calcularemos dos medias y dos desviaciones típicas: $\bar{x}_1, \bar{x}_2, \sigma_1, \sigma_2$ de esta forma, los valores etiquetados como normales serán aquellos que se encuentren a menos de $2\sigma_1$ de \bar{x}_1 o a menos de $2\sigma_2$ de \bar{x}_2 , el resto serán tomados como anómalos. Utilizamos Pandas para obtener estos valores, y observamos que:

$$\bar{x}_1 = -0.203 \quad \bar{x}_2 = 0.330$$

$$\sigma_1 = 0.03009 \quad \sigma_2 = 0.05657$$

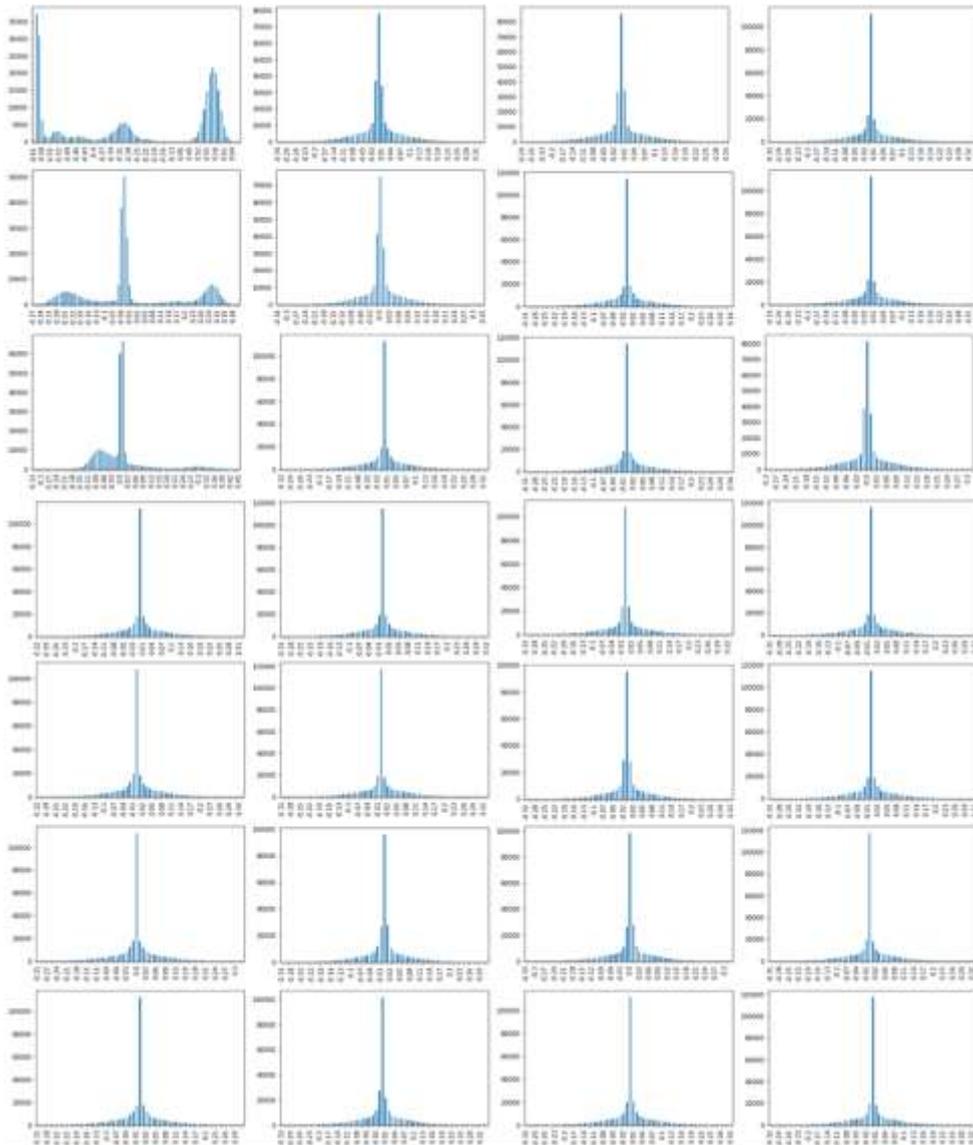
Estos valores se obtienen dividiendo en dos montones los datos: los mayores que cero y los menores. Gracias a Pandas, el código resultante se conforma únicamente de 4 líneas:

```
x_1 = df_reduced[df_reduced[0]<0][0].mean()
x_2 = df_reduced[df_reduced[0]>0][0].mean()
s_1 = df_reduced[df_reduced[0]<0][0].std()
s_2 = df_reduced[df_reduced[0]>0][0].std()
```

Para implementar el monitorizador, al tratarse de comparaciones sencillas entre números este se puede llevar a cabo mediante triggers en la base de datos o mediante algún código que se ocupe de observar la BD constantemente en busca de valores anómalos y envíe una notificación en la forma pertinente al encontrar alguna variable en un valor fuera de los rangos normales durante un tiempo suficiente.

FACTOR

El caso de FACTOR resulta más tedioso, pues recordemos que trabajamos con 28 variables en lugar de 4, de esta forma las gráficas de frecuencias de los datos son las mostradas a continuación:



Gráficas de frecuencia de las 28 variables virtuales de los datos de FACTOR

Al igual que en el caso anterior, vemos que las variables tienen una tendencia clara, en este caso, todas representan una función normal muy acentuada en la media. Difieren de este patrón las variables más significativas, es decir x_0 , x_1 e incluso x_2 , aunque esta última la trataremos como las demás pues la diferencia no es suficientemente grande como para tratarla diferente, al notar los datos agrupados en un solo punto neurálgico.

Las variables x_0 y x_1 se agrupan alrededor de 3 puntos, por lo que realizaremos un análisis parecido al utilizado para la variable x_0 de KAMAX, solo que en este caso, en lugar de utilizar 2 centros, utilizaremos 3, lo que supone 3 medias y tres desviaciones

típicas distintas pero el mismo principio. Obtendremos estas utilizando el mismo método elegido anteriormente gracias a la biblioteca PANDAS.

3.3 Métodos predictivos

A la vista de los resultados de agrupamiento, y dado que se ha obtenido tres estados de funcionamiento en cada uno de los casos piloto, el objetivo será detectar que la máquina se acerca a un estado de anomalía.

Para esta detección de van a utilizar dos técnicas, una directa y una anticipada.

Método directo

En este método se va a realizar una clasificación de cada registro nuevo dentro de los estados que nos ha devuelto el método kmeans. Para esto, resulta sencillo guardar la lista de los 3 centróides generados y dado un dato nuevo, comprobar su distancia a los 3 y asociar este nuevo dato al conjunto asociado. De esta forma, se puede conseguir que cuando comiencen a detectarse datos que se comienzan a clasificar en la clase del estado anómalo, y esta situación se produce durante un periodo de tiempo determinado para asegurar que no es una modificación puntual o debido al ruido, se genere algún tipo de advertencia o aviso.

El principal problema que tiene este método directo, es que el aviso se genera cuando el proceso ya se encuentra en el estado anómalo, lo que no permite tener ninguna forma de anticipación. Si el estado anómalo se identifica con el comienzo del deterioro de una máquina o pieza concreta, este método puede ser útil. Sin embargo, si el significado físico del estado anómalo supone una parada de mantenimiento, por ejemplo, el sistema no reportará información nueva en absoluto haciendo que este sea totalmente inútil. Por esto se plantea el siguiente método al que llamamos método anticipado.

Método anticipado

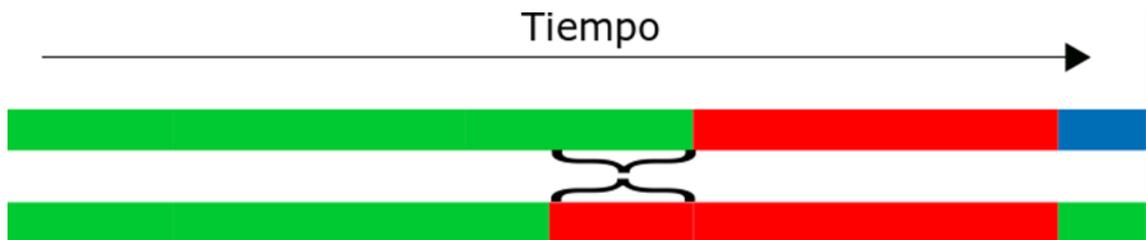
Para definir este método, se va a intentar anticipar la entrada en el estado anómalo previamente a que los datos sean clasificados como tales. Para ello se debe encontrar una forma de comprobar cuáles son las condiciones particulares que se encuentran justo antes del momento de entrar en el estado. El siguiente gráfico explicita el periodo temporal que queremos ser capaces de empezar a predecir:



Detección anticipada de estados anómalos

Para aplicar este método se va a utilizar métodos de aprendizaje supervisado, ya que ahora sí disponemos de la información que queremos transmitir a los algoritmos.

El primer paso es etiquetar correctamente los datos: en este caso se va a cambiar las etiquetas a dos estados: normal y anómalo. El siguiente cronograma muestra el dataset original etiquetado en 3 estados (azul, rojo y verde) y en la parte inferior se muestra un ejemplo de cómo quedará el nuevo dataset para el aprendizaje: El estado rojo pasa a ser anómalo, y el azul y el verde pasan a ser normal, a excepción de todos los datos que se encuentre directamente antes de una etapa anómala, que también serán etiquetados como anómalos.



Re-etiquetado de los estados de funcionamiento de la máquina para poder anticipar la transición de un estado al otro

Con este método, el algoritmo generará un modelo que avisará del estado anómalo antes de que se llegue a él.

Siendo los datos etiquetados mediante categorías, es evidente que tenemos que utilizar algoritmos de clasificación, en particular, algoritmos de clasificación binaria. Los dos candidatos que vamos a probar son las redes neuronales y las máquinas de vectores soporte.

En el caso de las máquinas de vectores soporte, seguiremos utilizando sklearn, pues contiene la clase svm que nos permitirá utilizar estos algoritmos. Por su parte, para las redes neuronales existen diversas librerías conocidas utilizables para este fin, en este caso vamos a usar una de las más famosas y probadas: KERAS.

Keras permite generar redes neuronales de manera sencilla explicitando las capas que esta tiene. Posteriormente se entrenará el modelo y veremos los resultados.

Para comprobar el funcionamiento de los algoritmos, se va a separar el conjunto de entrenamiento en 2 partes, la primera será utilizada para entrenar el modelo, la segunda se utilizará para testear como de buena es la solución obtenida. Una vez con los datos definidos comenzamos a entrenar los algoritmos para posteriormente comprobar su precisión.

3.3.1 Método Support Vector Machine (SVM)

Tal como se explicó anteriormente, los SVM buscan encontrar el subespacio de mayor separación. Se entrena el modelo mediante el código siguiente:

```
from sklearn import svm

clf = svm.SVC()

clf.fit(df_entrenamiento.drop('etiqueta', axis =
1), df_entrenamiento['etiqueta'])
```

Aplicando este código al conjunto de datos disponible (70% del total), se consigue un modelo entrenado, capaz de clasificar adecuadamente cualquier nuevo dato que se le proporcione utilizando el código siguiente:

```
clf.predict(df_test)
```

Este código muestra la clasificación obtenida para la predicción. El último paso será mostrar las estadísticas pertinentes de la predicción para comprobar el funcionamiento de este método. Posteriormente se mostrará este resultado, pero antes cabe introducir uno de los indicadores fundamentales que se va a utilizar para evaluar el funcionamiento de los algoritmos: la matriz de confusión, también conocida como matriz de error, que se explica brevemente.

La matriz de confusión es una matriz definida de la siguiente forma:

$$X_C = \{x_{i,j}\}_{i,j=1}^n$$

Donde $x_{i,j}$ es el número de registros del conjunto de evaluación que pertenecen a la clase j y que el algoritmo ha predicho que pertenecen a la clase i . Es decir, los datos

serán mejores cuanto mayor cantidad de registros se acumulen en la diagonal de la matriz de confusión. Podemos ver la matriz como la siguiente tabla:

		PREDICCIÓN	
		Positivos	Negativos
OBSERVACIÓN	Positivos	Verdaderos positivos (VP)	Falsos negativos (FN)
	Negativos	Falsos positivos (FP)	Verdaderos negativos (VN)

Vamos primero a comprobar el funcionamiento sobre los datos de KAMAX. En este caso obtenemos la siguiente matriz de confusión sobre el conjunto de entrenamiento

[[190184 9561]

[95 301018]]

Esto supone una precisión muy alta, de hecho hablamos de una precisión de 0.980721082622 sobre 1 $[(VP+VN)/DATOS\ TOTAL]$. Un nivel tan alto sobre el conjunto de entrenamiento podría indicar que estamos teniendo sobreajuste (*overfitting*), es decir, un ajuste excesivo a los datos de entrenamiento que implicaría una dificultad para encontrar adaptarse a nuevos datos. Si este fuera el caso, sería necesario aplicar técnicas de regularización para reducir el sobreajuste. Para comprobar si este es el caso, vamos a comprobar los resultados sobre el conjunto de test que hemos reservado y obtendremos las mismas características.

Por tanto, sobre el conjunto de test, obtenemos la siguiente matriz de confusión:

[[81245 6593]

[72 126733]]

Podemos ver que son resultados muy buenos ya que igualmente reportan una precisión muy alta, cercana al 1, en particular 0.9689484399677604. En el Anexo I se puede ver una tabla comparativa de todos los métodos aplicados al conjunto de datos de KAMAX y sus resultados.

Vamos a continuación a ver los resultados arrojados por los algoritmos aplicados a los datos recogidos en la empresa FACTOR. En este caso se ha reducido el número de etiquetados previos a solamente 50 debido a la menor cantidad de datos y la mayor existencia de estados anómalos. Con esto, podemos observar los resultados arrojados al

predecir la clase de los datos sobre el conjunto de entrenamiento mediante la matriz de confusión:

[[3503 1828]

[156 6901]]

En este caso vemos que obtenemos resultados buenos pero no tan preciso como en el caso anterior, en particular la precisión es de 0.8398450113012593 sobre 1. Aun así, con una precisión superior al 80% parecen resultados prometedores, vamos a ver qué se obtiene con el conjunto de test a través de su matriz de confusión:

[[2536 2714]

[236 2640]]

Esto supone un bajón importante de la precisión, que a duras penas supera el 60% marcando 0.6369598385667881 sobre 1, lo que implica que este método no es útil para predecir la clase. Sin embargo, se observa que la precisión en los negativos es muy alta, superior al 90%.

En el anexo II se puede ver una tabla comparativa del funcionamiento de los distintos algoritmos sobre los datos de la empresa FACTOR.

3.3.2 Redes neuronales

Las redes neuronales obligan a definir la arquitectura que tendrán antes de poder entrenarlas. En este caso se debe definir: el número de neuronas de la capa de entrada, el número de neuronas de la capa de salida, el número de capas ocultas y el número de neuronas en ellas:

- El número de neuronas en la capa de entrada viene definido por el número de variables en la capa de entrada.
- El número de neuronas en la capa de salida viene definido por las clases existentes. En este caso, al haber solamente 2 clases, podemos utilizar solamente una neurona, esta mostrará un 0 cuando crea que se trata de la primera clase y un 1 cuando crea que pertenece a la segunda.
- El número de capas ocultas debe ser igual o superior a uno, sin embargo, un número de capas elevado implica tiempos más largos de entrenamiento, por lo que comprobaremos los resultados con 1 y 2 capas ocultas.
- El número de neuronas en ellas. No hay un método para obtener la cantidad óptima, por lo que se probará con 4 y con 8 para ver los resultados.

Seguidamente se monta la red neuronal utilizando Keras.

En el caso de la empresa KAMAX, comenzamos utilizando una sola capa oculta en la que se encuentran 8 neuronas. Una vez más, evaluamos primero sobre el conjunto de entrenamiento y después sobre el conjunto de test para obtener la matriz de confusión. Comenzamos con el conjunto de entrenamiento que arroja la siguiente matriz de confusión:

[[251290 15096]

[3686 230786]]

Lo que arroja una precisión muy alta, del 0.9625003494004288, que una vez más podría indicar sobreajuste. Veamos el conjunto de test:

[[106228 11576]

[1903 94936]]

Que nos muestra que la precisión no varía excesivamente en el conjunto de test, ya que se manifiesta en 0.9372027040248226 sobre 1.

Probamos ahora con 2 capas ocultas, teniendo en ellas 8 neuronas en cada caso y obtenemos sobre el conjunto de entrenamiento:

[[190198 9547]

[93 301020]]

Lo que implica una precisión de 0.9807530278042879

Ahora, sobre el conjunto de test:

[[81233 6605]

[58 126747]]

Que significa una precisión de 0.9689577577652194

Cambiando de empresa a FACTOR, en caso de ejecutar la red neuronal con una capa oculta, conseguimos la siguiente matriz de confusión sobre el conjunto de entrenamiento:

[[4395 936]

[403 6654]]

Que se traduce en una precisión de 0.8919115272844689. Mientras que sobre el conjunto de test, se obtiene la siguiente matriz:

[[37007 15507]

[5854 22903]]

Reduciendo la precisión a 0.7371633177886331.

Probamos ahora el caso de utilizar 2 capas ocultas. Sobre el conjunto de entrenamiento obtenemos el siguiente resultado:

[[4164 1167]

[298 6759]]

Que supone una caída ínfima respecto al caso anterior de la precisión: 0.8817403939296093

Evaluando sobre el conjunto de test:

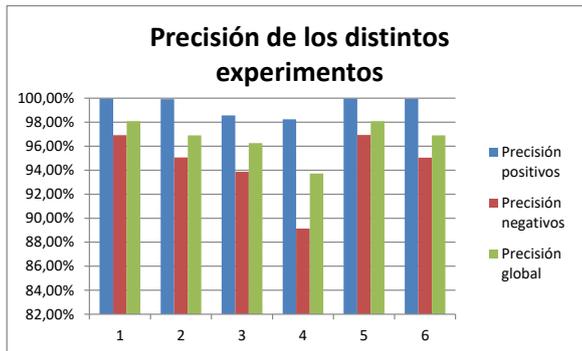
[[32538 19970]

[4143 24620]]

Podemos ver que el resultado cae aún más a 0.7033013005869252

Anexo I – Funcionamiento de los algoritmos sobre los datos de KAMAX

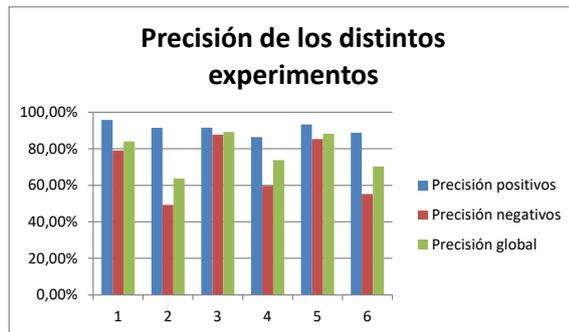
Método	Conjunto	Positivos correctos	Relativo	Negativos correctos	Relativo	Falsos positivos	Relativo	Falsos negativos	Relativo	Precisión positivos	Precisión negativos	Precisión global
SVM	Entrenamiento	190184	37,97%	301018	60,10%	9561	1,91%	95	0,02%	99,95%	96,92%	98,07%
	Test	81245	37,85%	126733	59,04%	6593	3,07%	72	0,03%	99,91%	95,05%	96,89%
Red neuronal 1 capa oculta	Entrenamiento	251290	50,17%	230786	46,08%	15096	3,01%	3686	0,74%	98,55%	93,86%	96,25%
	Test	106228	49,49%	94936	44,23%	11576	5,39%	1903	0,89%	98,24%	89,13%	93,72%
Red neuronal 2 capas ocultas	Entrenamiento	190198	37,97%	301020	60,10%	9547	1,91%	93	0,02%	99,95%	96,93%	98,08%
	Test	81233	37,85%	126747	59,05%	6605	3,08%	58	0,03%	99,93%	95,05%	96,90%



1. SVM-entrenamiento
2. SVM-test
3. Red Neuronal 1 capa – Entrenamiento
4. Red Neuronal 1 capa - Test
5. Red Neuronal 2 capas – Entrenamiento
6. Red Neuronal 2 capas - Test

Anexo II – Funcionamiento de los algoritmos sobre los datos de FACTOR

Método	Conjunto	Positivos correctos	Relativo	Negativos correctos	Relativo	Falsos positivos	Relativo	Falsos negativos	Relativo	Precisión positivos	Precisión negativos	Precisión global
SVM	Entrenamiento	3503	28,28%	6901	55,71%	1828	14,76%	156	1,26%	95,74%	79,06%	83,98%
	Test	2536	31,21%	2640	32,49%	2714	33,40%	236	2,90%	91,49%	49,31%	63,70%
Red neuronal 1 capa oculta	Entrenamiento	4395	35,48%	6654	53,71%	936	7,56%	403	3,25%	91,60%	87,67%	89,19%
	Test	37007	45,54%	22903	28,18%	15507	19,08%	5854	7,20%	86,34%	59,63%	73,72%
Red neuronal 2 capas ocultas	Entrenamiento	4164	33,61%	6759	54,56%	1167	9,42%	298	2,41%	93,32%	85,28%	88,17%
	Test	32538	40,04%	24620	30,29%	19970	24,57%	4143	5,10%	88,71%	55,21%	70,33%



1. SVM-entrenamiento
2. SVM-test
3. Red Neuronal 1 capa – Entrenamiento
4. Red Neuronal 1 capa - Test
5. Red Neuronal 2 capas – Entrenamiento
6. Red Neuronal 2 capas - Test

4 DESARROLLO DE LA INFRAESTRUCTURA DE COMUNICACIÓN

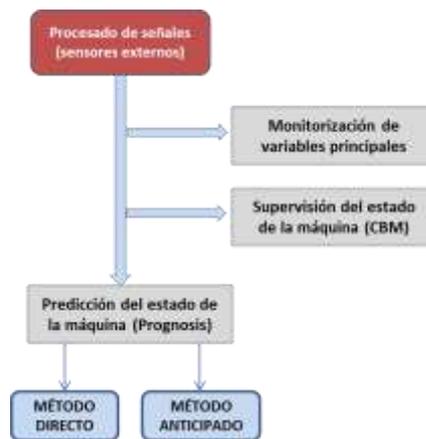
Seguidamente se presentan las especificaciones del sistema de visualización a desarrollar utilizando la plataforma elegida: NEXUS INTEGRA. Una vez definidos estos puntos, se explica el desarrollo realizado para satisfacerlos, y por último se muestran los resultados y visualizaciones obtenidos.

Tal y como se decidió en la anualidad anterior, la opción más interesante de entre la evaluadas resultó ser la utilización de una plataforma como middleware. En particular, se consideró un software desarrollado por Global Omnium que se conoce como NEXUS INTEGRA.

Se trata de una plataforma estructurada en distintos módulos, que generan un software intermedio que actúa de puente entre la adquisición de datos y la analítica, facilitando los procesos más comunes como puede ser la presentación de resultados en paneles de información personalizados o la generación de datasets a partir de los datos adquiridos. A su vez, Nexus tiene una gran cantidad de mecanismos para conectarse a entradas de internet de las cosas industrial (IIoT) entre las que destaca OPC UA, un protocolo que se ha establecido como estándar a día de hoy en soluciones de este tipo.

Se ha decidido desarrollar los elementos básicos del sistema de mantenimiento, pero de forma que sea autónomo, es decir que su funcionamiento no dependa de la intervención humana ya que las empresas donde se instalan los pilotos no pueden asegurar que el personal pueda atender los requerimientos del sistema. Por ello se debe considerar que no hay realimentación al sistema por parte del personal de planta.

Considerando esta situación, la estructura de la aplicación que se desarrolla es la mostrada seguidamente.



Modelo de sistema de mantenimiento desarrollado

Una vez descartada la utilización de fuentes de datos dependientes del entorno (en este caso datos procedentes de sistemas de información externos, y datos introducidos por el personal), el sistema que se plantea sigue buscando como objetivo la predicción del estado de la máquina. Se plantean dos métodos para hacer la predicción, el Directo y el Anticipado, ya explicados anteriormente.

Además, se plantean dos opciones adicionales de supervisión de la máquina:

- Por un lado se presentará la monitorización directa de las variables que se están midiendo en cada máquina, configurando alarmas en cada variable para detectar que se alcanzan valores no admisibles, que obviamente deben ser conocidos y por tanto especificados por el propio fabricante de la máquina.
- Por otro lado se presentará un sistema de mantenimiento basado en el estado de la máquina (CBM), en el cual se calculan automáticamente los valores “normales” de las variables adimensionales a las que se ha reducido el conjunto de todas las variables medidas, con unos límites de control también calculados. Mientras el funcionamiento de la máquina siga siendo “normal”, dentro de los límites de control, el sistema considerará que la máquina funciona correctamente. En el momento se detecte una tendencia en las variables medidas que implique una salida no esporádica de los límites de control, el sistema considerará que la máquina no funciona con normalidad, pasando a un estado “anormal”.

Desarrollo de la aplicación en la plataforma

El desarrollo en este caso está dividido en dos partes claramente diferenciadas. La primera parte incluye todos los cambios y configuraciones necesarios en la plataforma para dar forma a los cuadros de mando y SCADAs pertinentes, aquí se incluye también la configuración de la base de datos, las conexiones con los sensores y la configuración de la API de NEXUS.

Por otra parte, es necesario el desarrollo en los sistemas que se ocupen de gestionar los datos, tratarlos y enviarlos a la aplicación. Este desarrollo es uno de los ejemplos de estructura edge-cloud ocupando la parte edge los dispositivos de recolección y envío de datos, y la parte cloud la ocupa NEXUS integra.

- Edge.

Los sensores conectados a las máquinas mandan la señal tomada a través de cable a las tarjetas CORAZ7, que las procesan mediante las FPGA y después se lo pasan al core de la tarjeta, que está ejecutando Petalinux. Petalinux se ocupa de agrupar varias lecturas y enviarlas a través de Ethernet al ordenador que centraliza la información recibida en una base de datos MySQL. Los datos son tratados mediante Python, que se encarga de ejecutar los algoritmos de machine learning apropiados, además de filtrar los datos que son relevantes y los que no, reduciendo la cantidad de datos a tratar aumentando la eficiencia.

Python es el puente existente entre el edge y el cloud, es responsabilidad suya conectarse con la API de NEXUS Integra y enviarle los datos recolectados, los datos tratados, y los resultados de la clasificación ejecutada para los distintos sistemas predictivos. Tal como se ha explicado en los entregables del PT2, Python hace uso de bibliotecas de aprendizaje automático para los análisis predictivos; en particular, destacan las bibliotecas SKLEARN para la clasificación en grupos y el algoritmo de máquinas de vectores soporte, así como KERAS para las redes neuronales.

- Cloud

La parte cloud está completamente controlada por la plataforma NEXUS Integra. Aquí, el flujo de datos entra siempre por la API que es el único punto de entrada de datos de la aplicación. Estos son enviados al data warehouse de la plataforma, que es un sistema basado en Microsoft SQL Server. Por otra parte, existen datos que son mostrados en tiempo real aunque se almacenan para conservar el histórico, pero se llevan directamente a la interfaz de NEXUS.

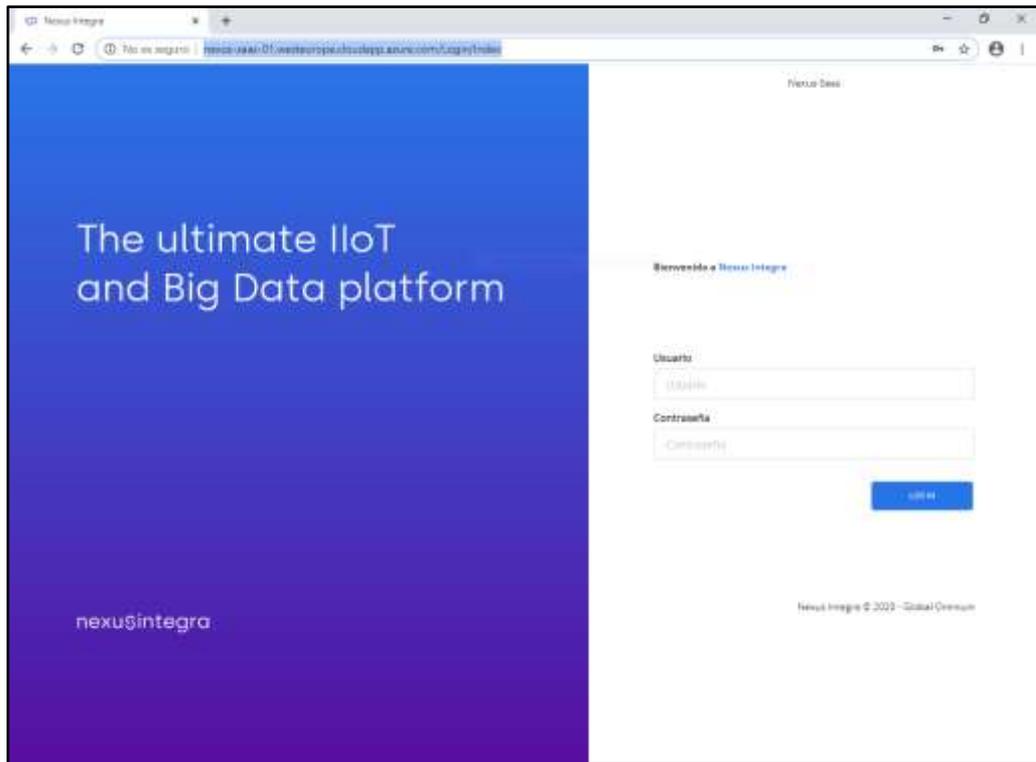
- Cliente

Por último, dado que NEXUS es una aplicación completamente web, se debe acceder a ella mediante un navegador web, esto permite que el cliente sea virtualmente cualquier dispositivo con acceso a internet, desde una Smart TV a un móvil o un ordenador. Esta característica facilita enormemente la integración en cualquier empresa, ya que se puede montar el sistema en cualquier dispositivo y visualizar los datos en la línea de fabricación.

En este resumen no se detallan los sistemas desarrollados para establecer la conexión con NEXUS, para la subida de datos ni para el desarrollo en cloud.

Seguidamente se muestran los cuadros de mando y la presentación de los distintos datos, que se han desarrollado tomando como base la plataforma NEXUS, que es una aplicación completamente web y se permite acceder a ella mediante un navegador web desde cualquier dispositivo con acceso a internet. Para acceder a la plataforma por tanto será necesario poseer unas credenciales de acceso de usuario y contraseña, pudiendo acceder desde cualquier dispositivo a través de la url:

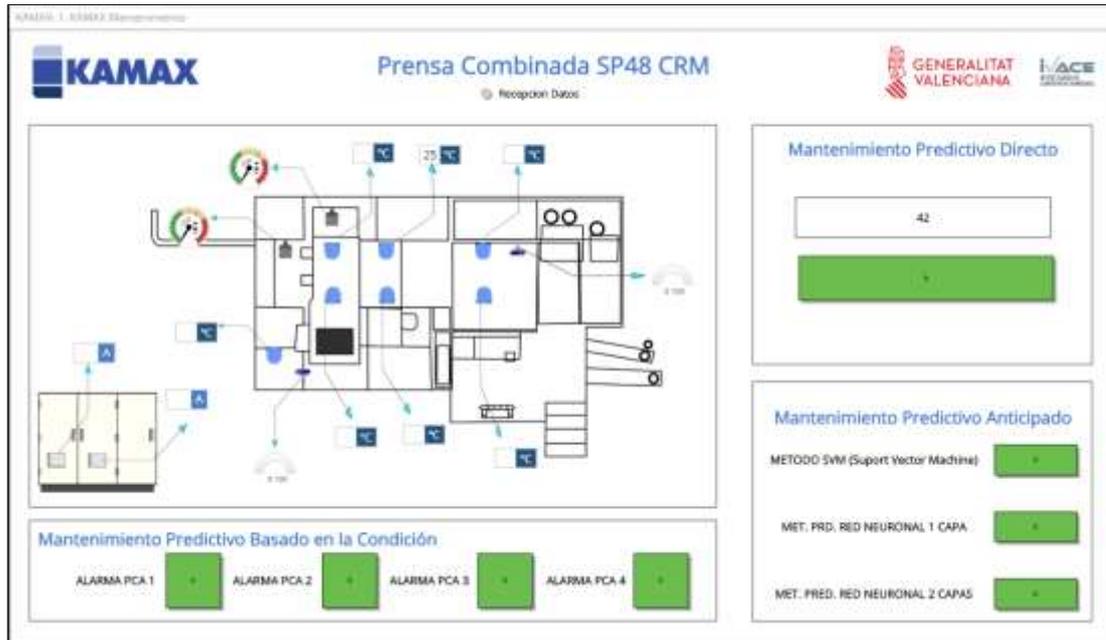
<http://nexus-saas-01.westeurope.cloudapp.azure.com/Login/Index>



Detalle pantalla acceso Nexus Integra.

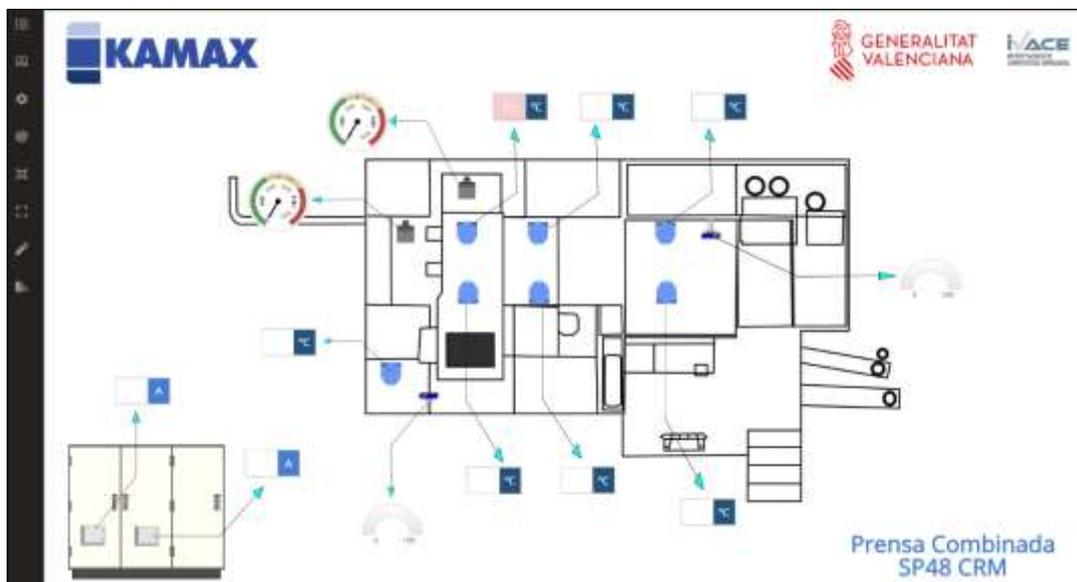
Se han configurado dos Scadas diferenciados para la visualización y análisis de datos, uno para la instalación de KAMAX y otro para instalación de FACTOR. Si bien, en ambos casos los Scadas y la información a mostrar en cada uno de ellos se estructuran de la misma forma. En este documento sólo se muestra una de las dos empresas, ya que las visualizaciones son muy similares

Inicialmente se presenta, un sinóptico en el que se muestra un resumen o visión general del mantenimiento predictivo de la máquina. En ella tendremos concentrada toda la información teniendo por una parte el esquema de sensores de la máquina con información de los mismos en tiempo real y por otro la información del estado de la máquina basado en la condición y en los métodos predictivos directos y anticipados.



Desde este sinóptico general podemos acceder a la información de detalle de cada parte o a los sinópticos correspondientes donde se muestra cada parte de forma ampliada.

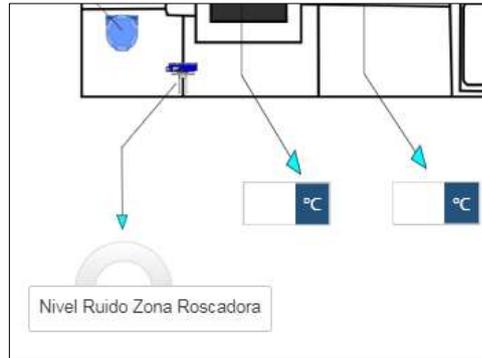
Accediendo al esquema simplificado de la máquina y de la instalación de sensores. En la cada sensor instalado presenta una etiqueta que recibe la información de estos, en tiempo real.



Sinóptico con esquema general de la instalación.

Para los sensores de temperatura y corriente, las etiquetas muestran además del valor que están recibiendo en tiempo real, la unidad de medida de la magnitud.

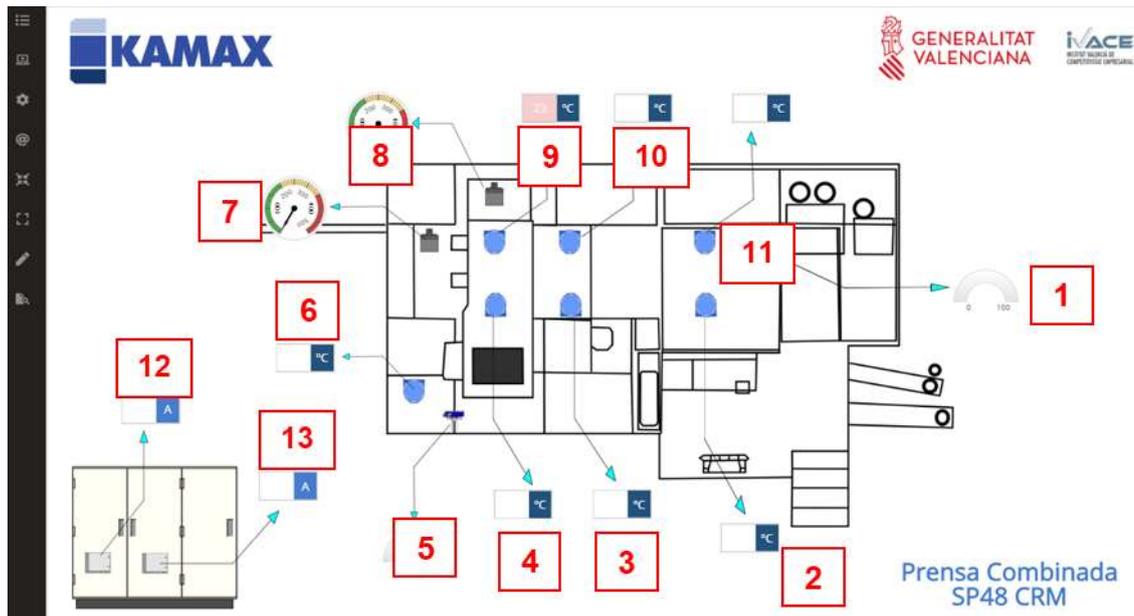
Al pasar sobre cada etiqueta de variable esta nos mostrará una leyenda (tooltip) sobre la variable que se trata y de que zona de la maquina está informado.



Detalle de etiquetas de Variables.

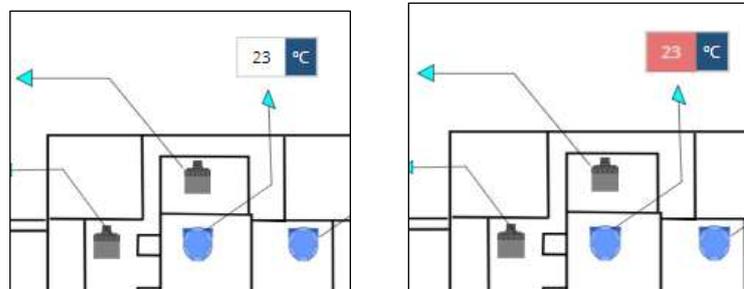
El esquema de la instalación mostrará las variables que se indican en la siguiente leyenda:

1. Nivel de Ruido Zona Estampadora.
2. Temperatura carro de la estampadora parte delantera derecha.
3. Temperatura carro de la estampadora parte trasera derecha.
4. Temperatura casquillo de la biela de la estampadora derecha.
5. Nivel de ruido Zona Roscadora.
6. Temperatura Zona Roscadora.
7. Vibraciones en caja engranajes Roscadora.
8. Vibraciones en rodamiento eje Estampadora.
9. Temperatura casquillo de la biela de la estampadora izquierda.
10. Temperatura carro de la estampadora parte trasera izquierda.
11. Temperatura carro de la estampadora parte delantera izquierda.
12. Corriente total máquina.
13. Corriente motor punteadora.



Sinóptico con esquema general de la instalación.

Estas además, están configuradas con un sistema de alarmas, de tal forma que en caso de superar el valor máximo fijado para cada variable, se mostrará en pantalla a modo de alerta/aviso con un aspecto diferente a la visualización normal, mediante cambio de color y/o parpadeo del mismo.

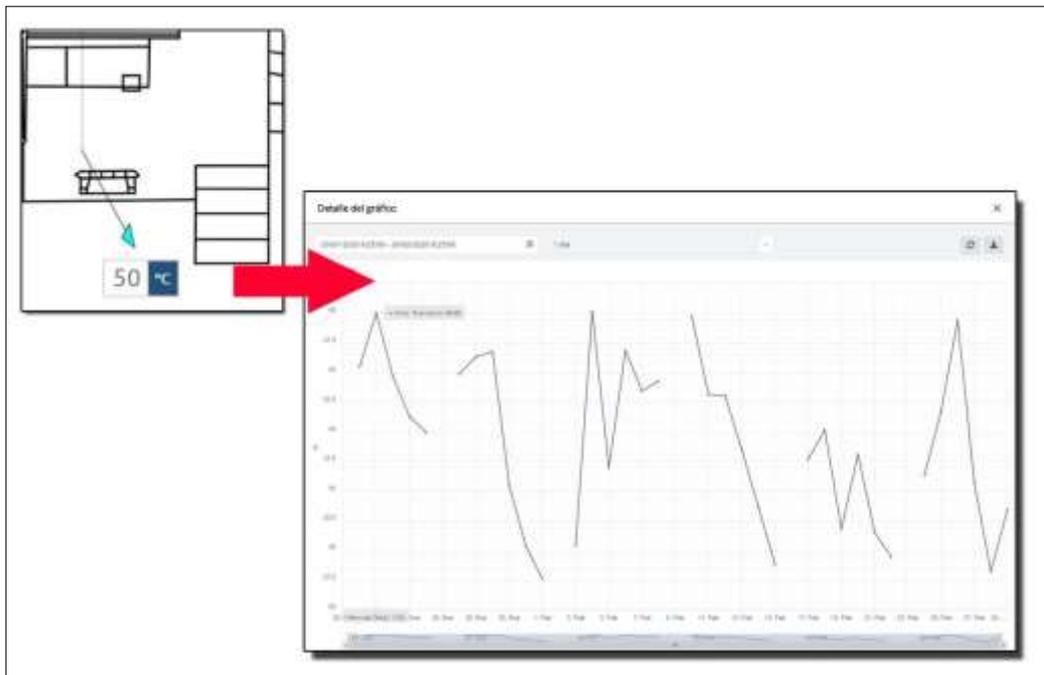


Detalle visualización estado Normal y Alarma.

Para los sensores de vibración (acelerómetros) y de nivel de ruido, se muestran etiquetas de tipo calibre o indicador de nivel, en los que se indican en tiempo real la cantidad de vibraciones y ruido que presenta la zona de la máquina sensorizada.

Con este sinóptico del esquema general de la instalación, se obtienen de una forma sencilla y muy visual, una visión general del estado de la máquina y de las variables controladas.

Cada una de las etiquetas en tiempo real permite acceder a un gráfico detallado de la variable. Para ello solo es necesario pulsar sobre la etiqueta deseada y se abrirá una nueva pantalla en la que poder observar en un gráfico histórico el comportamiento de la variable seleccionada.



Detalle del histórico de variable.

En este gráfico de detalle se puede filtrar la información a mostrar mediante los seleccionables de fecha para seleccionar el rango temporal y el detalle para la unidad en la que mostrar los datos.

Tras este sinóptico con la visión general del estado de la de maquina en tiempo real, tenemos distintos sinópticos en los que se muestran los análisis de datos de mantenimiento.

En cada uno de ellos se aplica un método de análisis predictivo, así tendremos un sinoptico por los siguientes:

- Mantenimiento Predictivo basado en la Condición.
- Mantenimiento Predictivo Directo.
- Mantenimiento Predictivo Anticipado.

Podemos acceder a cualquiera de los sinópticos desde el menú de Lista de sinópticos:



Mantenimiento Predictivo basado en la Condición.

En este sinóptico, se muestran mediante varias gráficas las variables o componentes PCA calculadas (Análisis de componentes principales). En cada una de las gráficas se presentan una serie de líneas rojas que identifican los rangos Normales para cada una de las variables PCA, permitiendo ver a simple vista alguna anomalía en caso de encontrarse fuera de dichos rangos.

Además en caso de mostrar valores NO Normales, se mostrará una Alarma en pantalla para la variable afectada.



Vista general del sinóptico.

En este sinóptico tenemos una vista general de las distintas variables PCA, pero se puede acceder a una vista más detallada de cada gráfico, pulsando en el botón de ampliación de la parte superior del gráfico seleccionada.

Tanto para la vista general como para la vista en detalle del gráfico, es posible hacer cambios en los rangos de fecha así como la segmentación histórica del dato cambiando la unidad temporal en años, meses, días, etc.

Además en la vista principal tendremos por cada una de las variables una alarma visible, de tal modo que en caso de registrarse un valor fuera de los rangos normales, el sistema nos avisara.



Detalle del Grafico de variable.

Para regresar a la vista del sinóptico solamente hay que cerrar la vista de detalle y volveremos a la vista general de las gráficas PCA.

Igualmente es posible la navegación entre sinópticos de tal forma que podemos regresar al sinóptico del esquema general de la instalación, pulsando en el botón 'HOME' de la parte inferior derecha de la pantalla. Esta navegación entre sinópticos es otra de las características destacable de la plataforma Nexus Integra.

Mantenimiento Predictivo Directo.

En este sinoptico nos informa del resultado del analisis predictivo directo.



En esta pantalla se muestra información ampliada del estado predictivo directo mostrando un historico del comportamiento del mismo.

Ademas tenemos visible el estado de la máquina y si existe alguna alarma para el estado de la misma. Pudiendo acceder al visor de alarmas desde la pantalla.

Mantenimiento Predictivo Anticipado.

En este sinoptico nos informa del resultado del analisis predictivo anticipado.



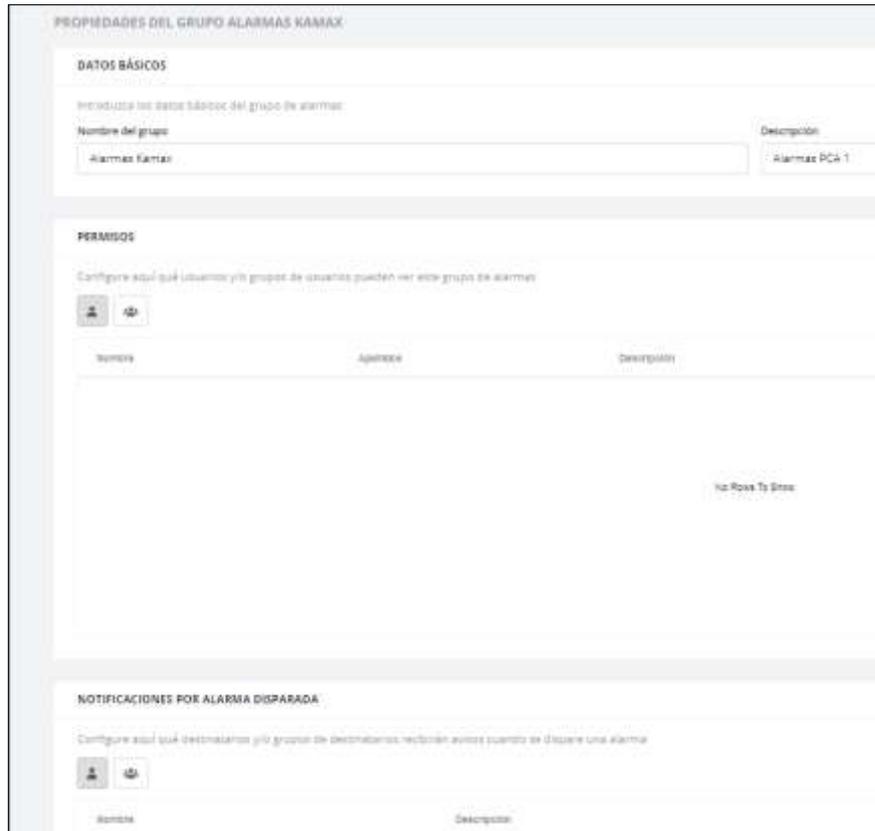
Esta pantalla nos amplia la informacion del estado predictivo anticipado mostrando un historico del comportamiento del mismo, para cada uno de los metodos empleados en cada caso.

Ademas tenemos visible para cada tipo de análisis, si existe alguna alarma para el estado de la máquina pudiendo acceder al visor de alarmas desde la misma pantalla.

Alertas

Para los distintos Sinópticos de Mantenimiento, se han creado una serie de alarmas desde la pantalla de inicio personal.

Desde el módulo de alarmas podemos crear el grupo de alarmas, definir la alarma, definir los permisos de usuarios que pueden visualizar las alarmas y las notificaciones de las mismas, definiendo a que usuarios les llegara un correo electrónico al saltar una alarma.



Además del sistema de avisos mediante envío de notificaciones, se ha empleado en los sinopticos un widget del tipo alarma que nos avisará de forma visual en caso de que alguna de ellas se active.



Detalle de la activación de alarma.

Con este widget de alarma podemos acceder al pulsar sobre el directamente al visor de alarmas y desde ahí acceder al detalle de cada una de las alarmas.

Visor de alarmas

Drag here to edit the groups

Alerta	Grupo	Descripción	Nivel	Estado	F...	Fecha...
<input checked="" type="checkbox"/>	Alerta PC...	PCA fuera de rango normal	High	Activa Reco	24/07/202...	24/07/202...

Detalles del histórico de la alarma Alerta PCA 1

SECUENCIAS

Nombre	Descripción	Fecha	Tipo	Estado inicial	Estado final
<input type="checkbox"/>	Alerta PCA 1 - PCA fuera de rango...	24/07/2020 7:39:54	Cambio de e...		! Activa No Reconocida
<input type="checkbox"/>	Alerta PCA 1 - PCA fuera de rango...	24/07/2020 7:39:54	Pérdida de e...	! Activa No Reconocida	! Activa No Reconocida
<input type="checkbox"/>	Alerta PCA 1 - PCA fuera de rango...	24/07/2020 7:40:08	Error al envi...	! Activa No Reconocida	! Activa No Reconocida
<input type="checkbox"/>	Alerta PCA 1 - PCA fuera de rango...	24/07/2020 11:10:10	Cambio de e...	! Activa No Reconocida	! Activa Reconocida No

5 VALIDACIÓN EN EMPRESAS PILOTO

Finalmente se presenta el diseño de las pruebas a realizar en las empresas donde se desarrollan los pilotos, los desarrollos realizados para poder ejecutar dichas pruebas, y los resultados conseguidos tanto en los pilotos como en el conjunto del proyecto.

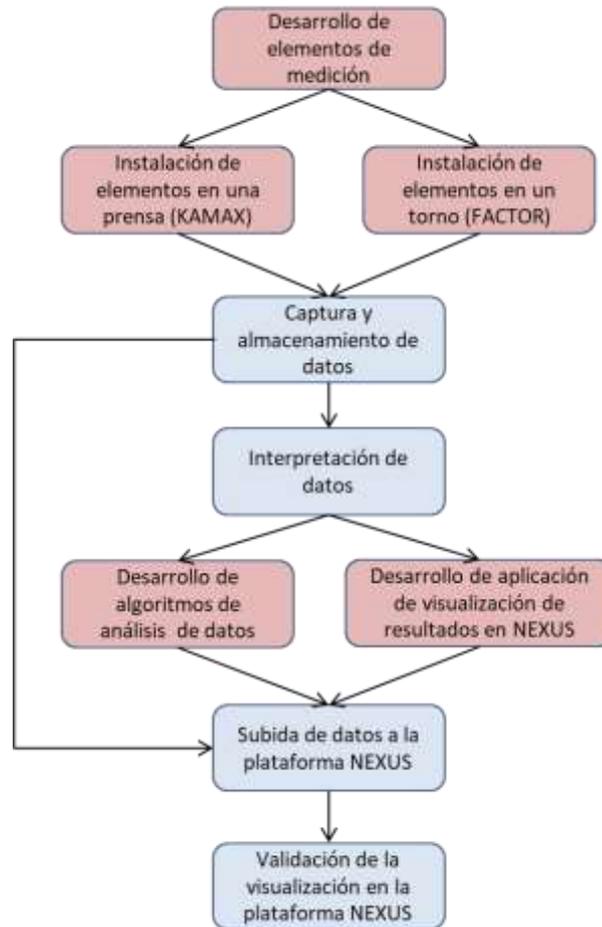
El objetivo de las pruebas piloto en este proyecto es múltiple, ya que se pretende validar todos los desarrollos realizados en el marco del proyecto. Por este motivo existe cierta superposición de tareas en los diferentes paquetes de trabajo, ya que incluso procurando mantener una separación clara entre las tareas de desarrollo y las tareas de validación, posiblemente se haya producido superposiciones involuntarias. En cualquier caso, en el conjunto del proyecto se ha conseguido realizar adecuadamente todas las tareas previstas.

Mediante las instalaciones realizadas en las empresas se persigue validar los siguientes desarrollos:

- Elementos de medición de variables y extracción de la información a una base de datos.
- Algoritmos para mantenimiento basado en el estado del equipo (CBM) y mantenimiento predictivo.
- Aplicación desarrollada sobre la plataforma NEXUS, para visualización de datos y gestión de alertas de funcionamiento y mantenimiento.

Las pruebas que se plantean para realizar las validaciones de dichos desarrollos deben partir del planteamiento original del proyecto, es decir de la integración de los dispositivos de captura, el almacenamiento de los datos y la interpretación de los mismos en tiempo real mediante el sistema de análisis desarrollado, utilizando la aplicación construida en la plataforma seleccionada, NEXUS en este caso.

El diseño de las experiencias piloto se muestra en el siguiente esquema.



En rojo se han indicado los desarrollos realizados y que ya han sido detallados anteriormente. Seguidamente se detallan las acciones más importantes indicadas en los recuadros azules: se detalla el significado de los datos leídos, ya que las lecturas de los sensores deben ser interpretadas para poderlas volcar en la plataforma y que se puedan entender por los usuarios; se describe el rediseño de la placa de captura de datos a partir de la experiencia adquirida y finalmente se recoge la visualización de los datos en tiempo real y seguidamente se extraen las conclusiones oportunas.

5.1 Interpretación de los datos

Cada armario eléctrico de los construidos e instalados en las empresas para la lectura de datos de los sensores y extracción de los mismos a la base de datos contiene el siguiente material eléctrico:

- dos tarjetas CORA Z7-10 de la marca DIGILENT
- ocho tarjetas de acondicionamiento de señal diseñadas por AIDIMME,
- dos tarjetas de alimentación eléctrica diseñadas por AIDIMME,

- dos transformadores electrónicos MEANWELL de 220V a 5V para alimentar a las tarjetas CORA Z7-10,
- un conmutador (SWITCH) de puertos de red de área local, y
- un transformador MEANWELL de 220V a 24V para alimentar a las tarjetas de acondicionamiento de señal, al conmutador (SWITCH) y a las tarjetas de alimentación eléctrica.

Cada tarjeta CORA Z7-10 tiene nueve entradas de señal analógica que se aprovechan para conectar las señales de diversos sensores (tanto de temperatura como de intensidad o de vibración). Todas las entradas de señal analógica de la primera tarjeta CORA Z7-10 son aprovechadas y se utilizan las primeras ocho entradas de señal analógica de la segunda tarjeta CORA Z7-10, para un total de diecisiete entradas.

Seguidamente se muestra como caso especial la medición de las vibraciones y el significado de los datos capturados

Caso especial de las vibraciones (P0, P1, P2, P3)

Los acelerómetros (X, Y, Z) y el micrófono están conectados a sus respectivas tarjetas electrónicas de acondicionamiento de señal con salida de tensión de 1 voltio que fueron diseñadas por AIDIMME. Cada tarjeta CORA Z7-10 se conecta a un acelerómetro (X, Y, Z) y a un micrófono montados en una máquina. Por lo tanto, el armario está ideado para dos máquinas distintas. Toda señal de vibración que sale de una tarjeta electrónica de acondicionamiento de señal tiene una media de 0,5 voltios, es decir, cuando no existe una vibración se observa una tensión de 0,5 voltios que se conoce como la masa flotante. Al producirse una vibración, aparecen excursiones de la tensión por encima y por debajo de la media de 0,5 voltios, donde la excursión positiva puede llegar a subir hasta una tensión de 1,0 voltios y la excursión negativa puede llegar a descender hasta 0,0 voltios. Las salidas de estas tarjetas electrónicas de acondicionamiento de señal se conectan directamente a los puertos de entrada de señal analógica a digital sin ninguna resistencia de entrada de 50 ohmios (que sólo se emplea para los sensores con transmisor de intensidad de 4 a 20 miliamperios). Estos sensores de vibración se conectan a ambas tarjetas CORA Z7-10, empleando los puertos P0 (acelerómetro en el eje X), P1 (acelerómetro en el eje Y), P2 (acelerómetro en el eje Z) y P3 (micrófono) que están reservados para las tarjetas electrónicas de acondicionamiento de señal con salida de tensión de 1 voltio y que tienen los siguientes límites (que son debidos al divisor de tensión del circuito de protección).

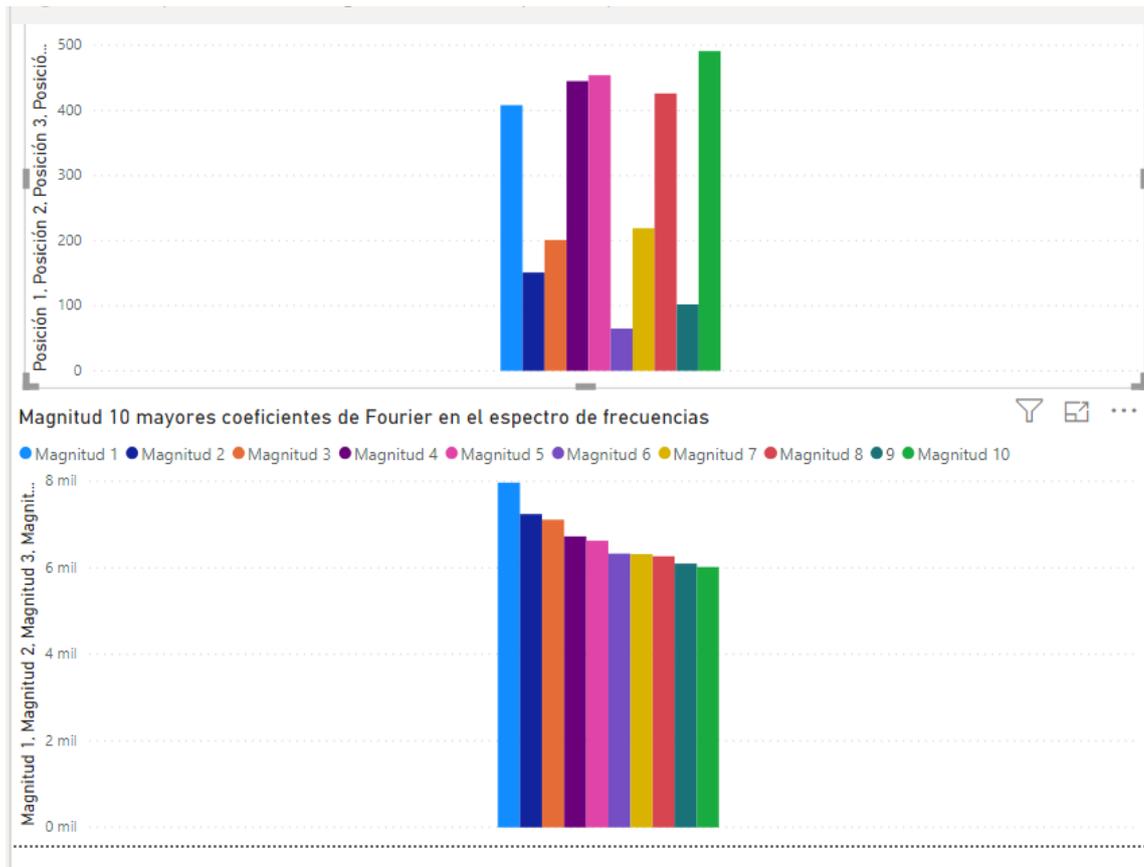
- Valor mínimo observable = 0,0 voltios
- Valor máximo observable = 0,3012 voltios

El valor mínimo observable se representa con el valor decimal (analogico_min = 0).

El valor máximo observable se representa con el valor decimal (analogico_max = 1233).

El rango de entrada es de (1233 – 0).

El sistema de adquisición de datos emplea una frecuencia de muestreo de 2939 muestras por segundo para cada una de las señales de vibración (P0, P1, P2 y P3). Se toma un conjunto de 1024 muestras para cada una de las señales de vibración (P0, P1, P2 y P3) y se calcula la transformada rápida de Fourier (FFT) para obtener la magnitud del espectro de la señal de vibración, cuyo eje horizontal tiene unidades de frecuencia (2393 Hz/1024) y cuyo eje vertical tiene unidades de potencia (voltios al cuadrado). La intención del análisis de frecuencia es determinar la presencia de una o varias frecuencias de vibración. Para estos efectos se identifican los diez picos más altos y se presenta una lista compuesta por la magnitud y la posición (en orden decreciente de magnitud, empezando por la mayor magnitud). La magnitud tiene unidades de potencia (voltios al cuadrado) y la posición es un escalar de 0 a 511 que debe multiplicarse por una constante (2393 Hz/1024) para convertirse en la frecuencia del pico en unidades de ciclos por segundo (Hz). Este proceso se repite cada segundo de forma indefinida. Por lo tanto, el archivo de resultados contiene la lista de los diez picos (magnitud y posición) que se genera una vez por segundo, como puede verse en la figura siguiente.

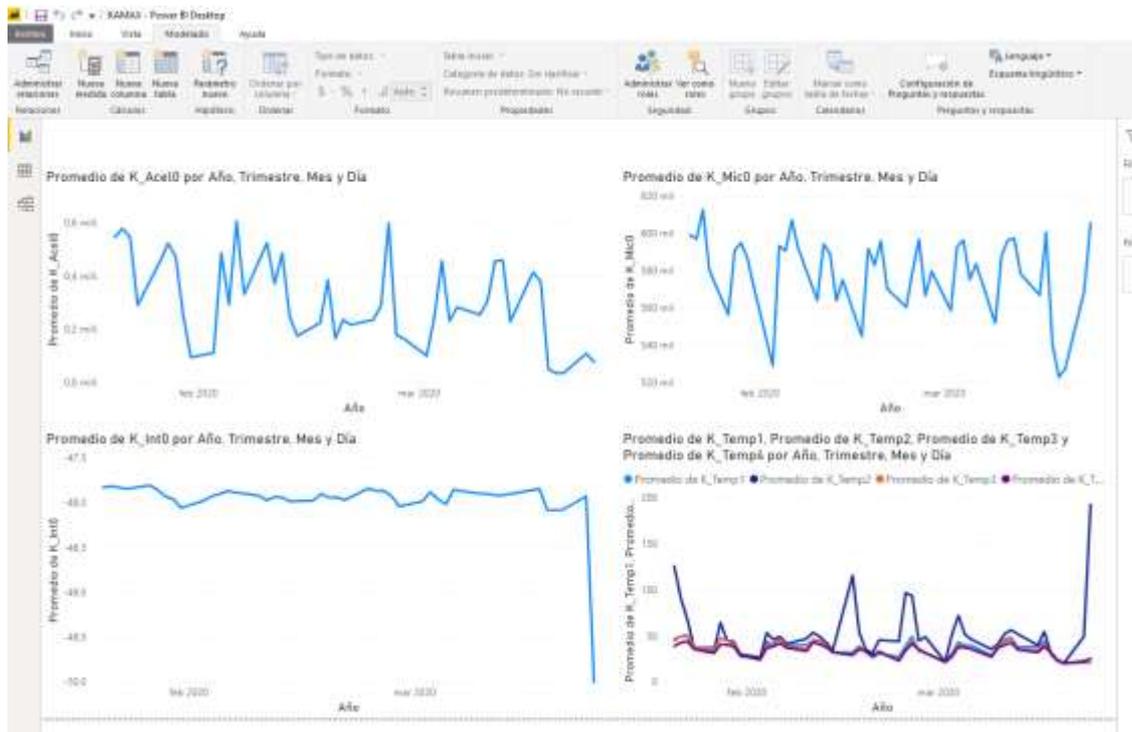


Posición y magnitud de los diez primeros armónicos de la señal de vibración (KAMAX)

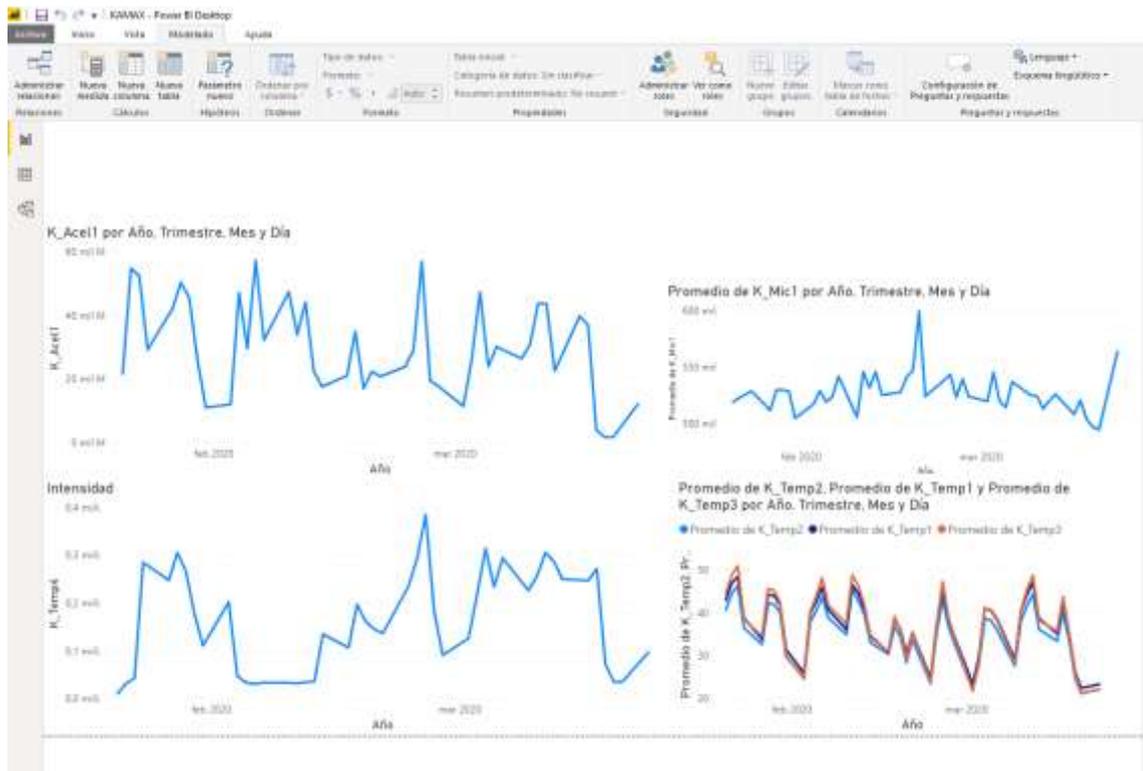
Reducción de dimensionalidad de los valores recogidos por los acelerómetros.

Para simplificar la visualización e interpretación de los datos de vibración, se han reducido los datos recogidos por los acelerómetros en cada eje. Como se ha indicado anteriormente, cada segundo se recogen 20 datos por eje, las frecuencias de vibración de los diez primeros armónicos, y la magnitud de los mismos en cada frecuencia. De entrada las frecuencias de vibración no son interpretables directamente, salvo que se hayan hecho estudios previos para conocer los orígenes de dichas vibraciones, que no es el caso. Por tanto, se ha sumado la magnitud de los diez armónicos, independientemente de su frecuencia, para obtener un único valor que representa la magnitud de la vibración total en cada eje. De esta forma se dispone de un valor único de fácil interpretación desde el punto de vista de su visualización.

Con esta simplificación, se pueden representar gráficamente las cuatro magnitudes que se están recogiendo en cada máquina: vibración, consumo, temperatura y sonido. En los gráficos siguientes, realizados a partir de los datos brutos presentados mediante la aplicación Power BI, se puede ver la variación de esas magnitudes en una de las prensas de KAMAX.



Valores brutos de vibración, sonido, intensidad de corriente y cuatro sensores de temperatura en la prensa de KAMAX, correspondiente a una de las tarjetas de adquisición de datos



Valores brutos de vibración, sonido, intensidad de corriente y cuatro sensores de temperatura en la prensa de KAMAX, correspondiente la segunda de las tarjetas de adquisición de datos

5.2 Rediseño de la tarjeta de adquisición de datos

A partir de la experiencia adquirida se elaboraron las especificaciones de diseño de una tarjeta de adquisición de datos que permita realizar una captura de las cuatro variables que se han medido en el proyecto (vibración, temperatura, consumo y sonido), pero que sea compacta y se pueda replicar con facilidad y a un coste razonablemente bajo. Una vez definidas las especificaciones, se entregaron a un proveedor (ROMOVI) para que diseñase el circuito, lo trasladase a una PCB y montase los componentes. No fue posible validar el comportamiento de la tarjeta desarrollada en las instalaciones piloto en el periodo de ejecución del proyecto, estando prevista la instalación y prueba a partir de septiembre de 2020 y contando con la colaboración de las empresas.

Tras evaluar la funcionalidad de los dispositivos construidos inicialmente y la complejidad que supone intentar medir las vibraciones en el dominio de la frecuencia, se decidió que al replantear el diseño de las tarjetas de adquisición de datos, éstas proporcionasen únicamente la magnitud de la vibración en tres ejes.

Dado que para realizar esta medición no se requiere realizar las transformadas rápidas de Fourier (FFT), no es necesario utilizar un elemento de procesado de datos de alta velocidad tal como las FPGA, y por tanto no se requiere emplear las tarjetas CORA. Esta circunstancia permite simplificar mucho todo el sistema de adquisición de datos, ya que mediante un microcontrolador de alta velocidad “estándar” se puede gestionar todo el sistema de adquisición de datos, compactando mucho la tarjeta necesaria.

Otra ventaja de utilizar un micro estándar es que puede funcionar en un rango de temperaturas muy amplio, entre -40°C y 80°C . Esto permite el trabajo en ambientes industriales relativamente agresivos. El micro elegido ha sido el *STM32L4R9ZI Cortex-M4F 120MHz 640Kb RAM*

A partir del rango de las variables medidas en las pruebas realizadas, se han seleccionado los sensores para medir todos los parámetros, y son los siguientes:

- HTS221: Sensor de temperatura
- ACS781xLR: Sensor de corriente analógico
- ISM330DHCX: Acelerómetro de 3 ejes, con giroscopio integrado
- MP23ABS1: Micrófono multibanda analógico MEMS

Utilizando estos componentes, se debe proporcionar una salida de datos con protocolo MODBUS, de forma que se pueda conectar a cualquier elemento de control industrial para la lectura de datos, bien sea PLC o PC.

El proveedor entregó el prototipo mostrado en la imagen siguiente, realizada junto a un teclado de ordenador para apreciar su tamaño, aunque como se ha indicado no ha sido posible validarlo en condiciones de funcionamiento real, estando prevista dicha validación próximamente.



Placa de adquisición de datos desarrollada

5.3 Subida de datos y visualización

Es importante remarcar que las necesidades y situaciones específicas de los pilotos demostrativos en las empresas son distintas de las que encontramos en las pruebas realizadas en un entorno controlado con los datos recolectados en estático. En particular se identifican las siguientes necesidades específicas a solventar para la implantación de los pilotos:

- **Entrenamientos:** En el entorno de la prueba piloto no se dispone de tiempo para entrenamientos así como tampoco existe capacidad para ello pues la subida de datos es ejecutada en el sistema edge. Los entrenamientos son costosos tanto a nivel de tiempo, lo que imposibilitaría reflejar los datos en tiempo real, y son costosos a nivel computacional también por lo que se requeriría de un sistema potente instalado en la empresa, lo que difiere del objetivo del proyecto. Por estas razones, los entrenamientos tendrán que ser ejecutados fuera de la empresa y, una vez, generado el modelo, este se guardará y se llevará al sistema instalado en la empresa, que deberá ser capaz de leerlo y utilizarlo.
- **Detección de paros:** Se entiende que el sistema debe de ser un sistema completamente autónomo que funcione sin interacción humana de por medio. Fallos en los datos pueden producir excepciones en el código traducándose en que el sistema se para y no se reactiva lo que implicaría mucho tiempo de funcionamiento perdido con su consecuente pérdida de datos. Para evitar esto, se van a utilizar dos mecanismos de control:
 - **Activos:** Se utilizarán sistemas de control de excepciones de forma que si existen datos erróneos o se produce alguna excepción por fallo comunicativo de algún tipo, el código ignore el error y se dedique a seguir con la siguiente instrucción, o bien trate de ejecutar la orden rechazada hasta que esta sea ejecutada.
 - **Pasivos:** Será necesario crear sistemas de notificación que aseguren la comunicación constante, y en caso de no recibir datos durante cierto tiempo, NEXUS debería ser capaz de identificar los momentos en los que se corta la cadena de datos.
- **Cortes de alimentación:** Una problemática recurrente en los polígonos industriales son los cortes energéticos puntuales. Estos apagan los sistemas que necesitan ser reiniciados. La utilización de sistemas SAI como los instalados en las empresas para asegurar el suministro de energía, tanto a los armarios eléctricos donde se procesan las señales, como al PC que recibe los datos, solventa este problema.

En la documentación detallada del proyecto se especifican las herramientas desarrolladas para subir datos a la plataforma NEXUS, donde se ha desarrollado la aplicación de visualización. Primero se muestra cómo subir datos históricos ya almacenados, los problemas encontrados y cómo se han solucionado, y seguidamente

se muestra como se realiza la subida de datos en tiempo real con sus dificultades asociadas.

Finalmente se muestra el resultado obtenido tras la realización de las pruebas piloto mediante el sistema de análisis y visualización construido sobre la plataforma NEXUS. El acceso al sistema se puede realizar a través de cualquier dispositivo de visualización con conexión a Internet, aunque las pruebas se han realizado en un PC de sobremesa.

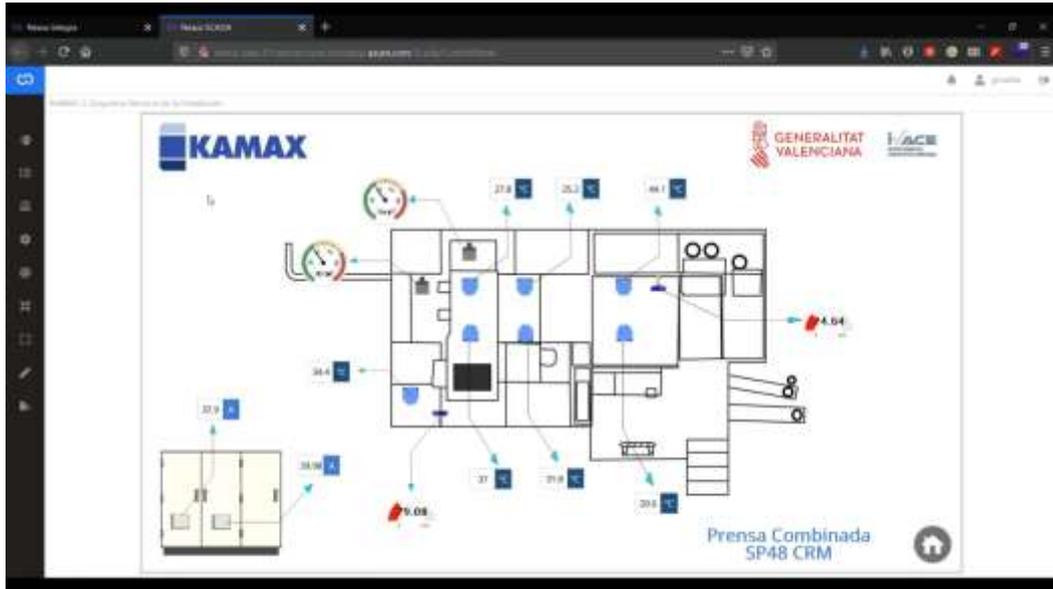
En el vídeo adjunto a la documentación detallada, puede verse el proceso completo de acceso a la plataforma, y la navegación por los diferentes elementos de la aplicación construida. Seguidamente se muestran algunas imágenes estáticas en las que se aprecian las diferentes vistas de la aplicación con los datos que en ese momento se podían visualizar.



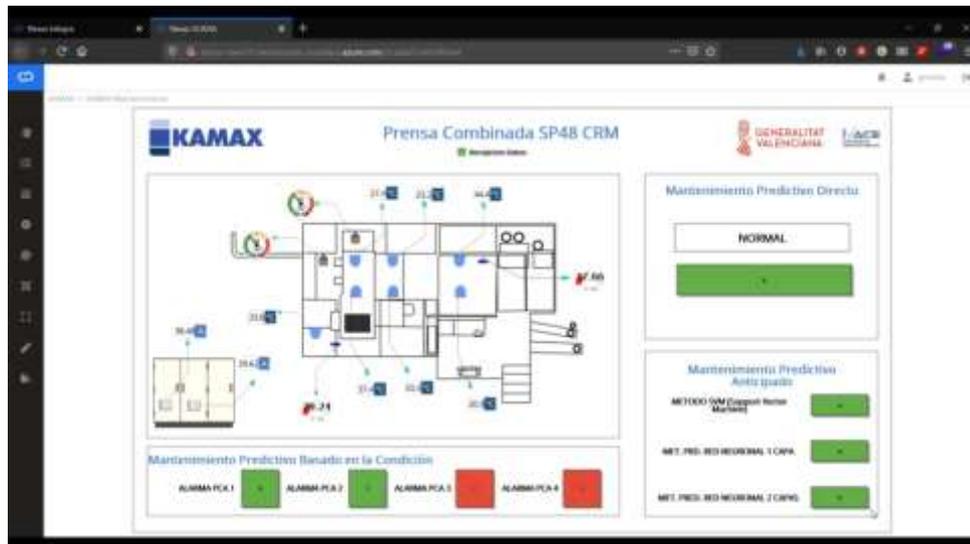
Vista principal de la aplicación

En la vista principal puede apreciarse el esquema de la máquina en el que se indican la posición de los sensores instalados y su valor instantáneo. Si algún valor estuviese fuera de los límites establecidos como normales, se vería de color rojo. En la parte inferior se muestra la situación de cada una de las cuatro variables utilizadas para el mantenimiento basado en el estado de la máquina (CBM). Estas variables, que no representan una magnitud física real sino que son resultado de reducir la dimensionalidad de todas las variables medidas, se miden continuamente y en el momento alguna variable excede los límites de control calculados salta una alarma en el panel y el recuadro pasa a rojo. En la parte derecha aparecen los dos métodos de

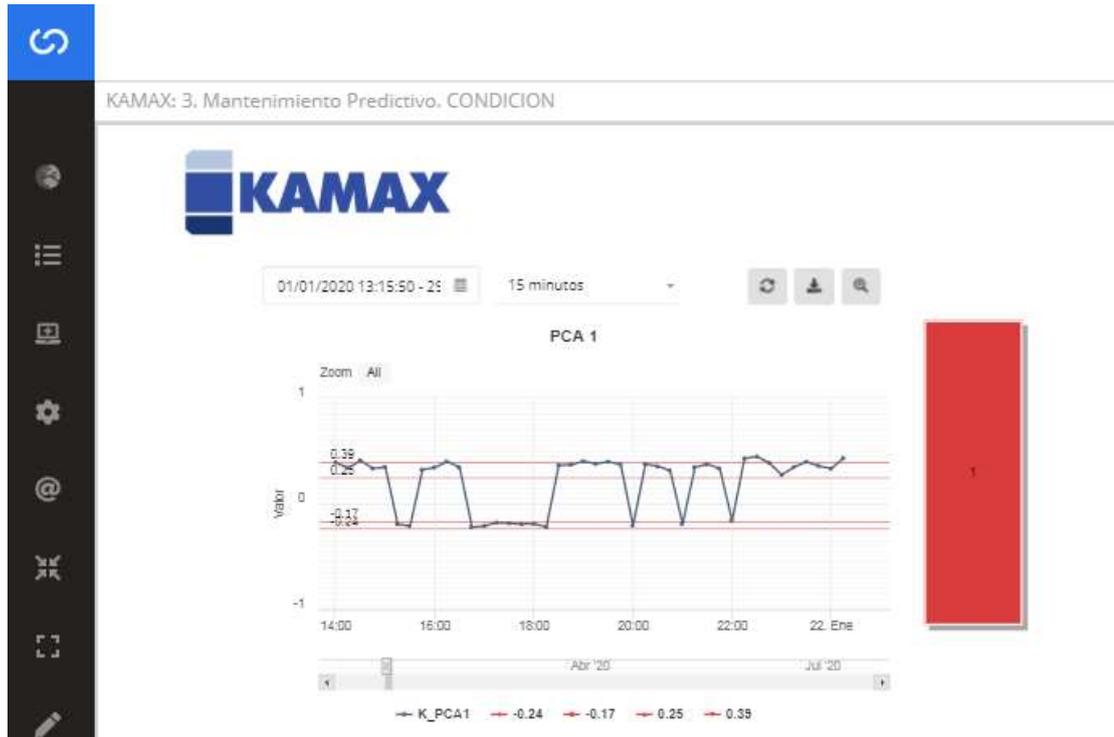
mantenimiento predictivo desarrollados: la parte superior derecha corresponde al mantenimiento predictivo directo, es decir que advierte mediante el cambio de color (de verde a rojo) de si la máquina está en el estado habitual o si ha cambiado de estado; en la parte inferior derecha se muestra el denominado mantenimiento predictivo anticipado, que muestra mediante el cambio de color si existe una tendencia de los datos que predice un futuro cambio de estado, utilizándose los tres métodos indicados (SVM, Red Neuronal de una capa y Red neuronal de dos capas).



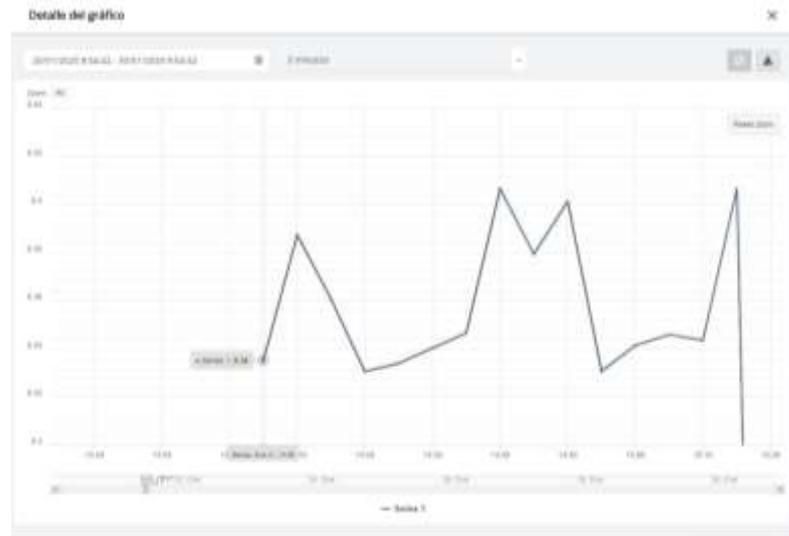
Vista del esquema de la máquina con el valor y posición de cada medida (SCADA)



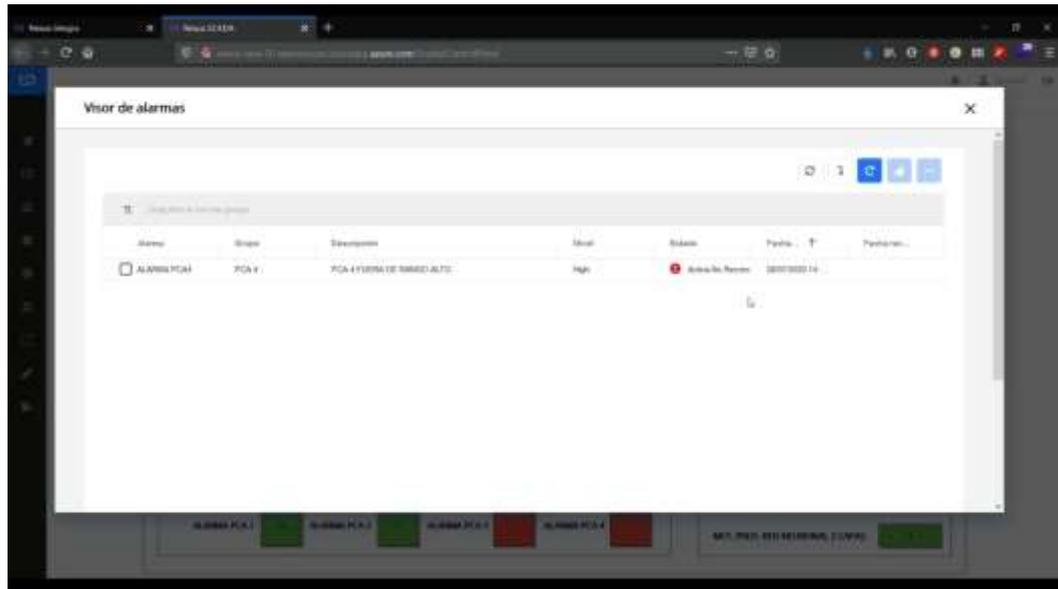
Vista general con dos alarmas encendidas en el CBM



Pantalla de detalle del histórico de la variables PCA1 del CBM, habiendo superado el límite de control en varias ocasiones



Pantalla de detalle del histórico de una variable de las medidas en la aplicación



Pantalla de detalle de la alarma creada en la variable PCA4 del CBM, al superar el límite de control

6 Conclusiones

Una vez realizadas todas las tareas previstas en el proyecto, y a la vista de las actividades desarrolladas y los resultados obtenidos, se extraen las siguientes conclusiones principales:

- Se demuestra la viabilidad de utilizar una plataforma IoT para el control del funcionamiento de máquinas y la gestión del mantenimiento predictivo en las mismas, siempre que se pueda desarrollar aplicaciones de visualización mediante herramientas de configuración integradas en la propia plataforma. En este caso, la plataforma NEXUS INTEGRA cumple estos requisitos.
- Para desarrollar un sistema de mantenimiento predictivo basado en el aprendizaje supervisado, que es el que mayor información puede aportar, es imprescindible disponer de un amplio histórico de las incidencias que aparecen en la máquina, y que debe ser recogido durante el mismo periodo de tiempo que se hace la captura automática de datos de funcionamiento. Dado que las averías en máquinas y procesos no suelen ser frecuentes, se requieren periodos de tiempo muy prolongados de captura de datos, entre 12 y 24 meses dependiendo del tipo de máquina. En el proyecto, al no disponer de tal cantidad de datos, no se ha podido plantear un predictivo mediante aprendizaje supervisado.
- Como alternativa al predictivo anterior, se ha desarrollado el método de aprendizaje no supervisado, el cual clasifica los datos que se adquieren automáticamente en “grupos homogéneos”. Cada grupo de clasificación responde a un estado diferente de la máquina, caracterizado porque el conjunto de variables medidas tienen valores asimilables. En este caso el problema que se plantea es identificar qué significa físicamente cada uno de los grupos o estados de la máquina, es decir si hay un estado de funcionamiento “normal”, un estado de funcionamiento “en vacío”, otro estado de funcionamiento “defectuoso”, etc. Esta asociación no es evidente y se requiere un análisis profundo de los momentos temporales en los que la máquina alcanza cada estado, y en colaboración con la empresa identificar qué es lo que está sucediendo en el proceso y que sea diferente a otro de los estados posibles.
- Desde el punto de vista predictivo, si se realiza una clasificación por estados (aprendizaje no supervisado), el sistema detecta cuándo los datos indican que la máquina pasa de un estado a otro. Dependiendo del significado físico de los estados, esta información puede ser relevante o no. En cualquier caso, se puede desarrollar un método que permita anticipar el cambio de estado mediante el análisis del comportamiento de las variables en un determinado periodo de tiempo anterior al cambio de estado. De esta forma se puede anticipar el próximo cambio de estado, si realmente se encuentra alguna tendencia de cambio en estas variables.

- Otro sistema que puede implementarse sin disponer de datos complementarios de incidencias es el de Mantenimiento Basado en la Condición (CBM). En este caso se trata de establecer, con un conjunto de datos de pocas semanas de funcionamiento normal de la máquina, cuál es el valor normal de las variables medidas y unos límites estadísticos de control. Mientras las mediciones que se hacen se mantengan en esos límites, se considera que el proceso funciona normalmente. En el momento aparecen tendencias en los datos que llevan a salirse de los límites de control, se reporta una alerta que debe ser revisada por personal de mantenimiento de la empresa, ratificando que existe alguna posible anomalía, o que ha sido una falsa alarma. En cualquier caso, es posible que la anomalía no aparezca inmediatamente y que el problema aparezca en un futuro más o menos cercano.
- En el ámbito de la extracción, almacenamiento y transmisión de datos, la primera conclusión que se puede extraer es que si la medida de las vibraciones se hace en el ámbito de la frecuencia (medir la frecuencia y magnitud de los armónicos principales de la vibración en cada momento), se debe disponer de estudios previos en el mismo tipo de máquina que indiquen el significado de la vibración en determinadas frecuencias (por ejemplo, hay bastante bibliografía sobre vibraciones en motores eléctricos). Si no se dispone de esa información previa es extremadamente complejo interpretar resultados, aunque eso no obsta para que los datos puedan ser analizados con técnicas de ML.
- A partir de la conclusión anterior, es más conveniente, en general, medir vibraciones en el ámbito del tiempo (medir simplemente la magnitud de la vibración), lo cual simplifica mucho los elementos de medición.
- La instalación de los elementos de medición en diferentes puntos de la máquina, y el transporte de la señal hasta el sistema de procesamiento se ha realizado mediante cableado tradicional. Este sistema es muy seguro en cuanto a calidad de las señales y continuidad de las mediciones, aunque requiere un elevado tiempo de instalación y un coste importante en cables especiales (resistentes a la flexión y al aceite). Convendría explorar la posibilidad de realizar una transmisión de datos inalámbrica, aunque dependiendo de la cantidad de datos a transferir y del consumo de energía de los elementos de adquisición y transmisión, esta opción puede ser inviable.
- Otra opción que se podría explorar es el desarrollo de nodos Edge Computing que realizasen un procesamiento previo de los datos recogidos “en bruto”, incluso con software de IA integrado. Esto reduciría la dimensionalidad de los datos y la necesidad de transmitir cantidades elevadas de información.