

2018-
2019

PROACTIV

Monitorización de procesos y actividades en procesos industriales.

Nº Expte: IMDEEA/2018/4

Programa: PROYECTOS DE I+D EN COOPERACIÓN CON EMPRESAS

Resumen de resultados obtenidos en el proyecto

Realizado por:
AIDIMME



GENERALITAT
VALENCIANA

iVACE
INSTITUTO VALENCIANO DE
COMPETITIVIDAD EMPRESARIAL



UNIÓN EUROPEA
Fondo Europeo de
Desarrollo Regional

Una manera de hacer Europa



Contenido

1. Introducción	3
2. Desarrollo de los dispositivos de medición	3
3. Desarrollo de la infraestructura de captura de datos	9
4. Validación en empresas piloto	14
5. Referencias	32

1. Introducción

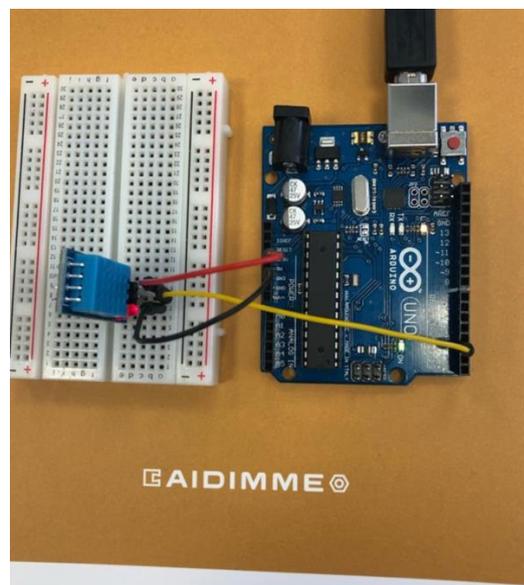
En este documento se recogen los resultados finales obtenidos en el proyecto PROACTIV. Se resumen los resultados del desarrollo de los dispositivos, las pruebas realizadas, la validación en empresas piloto y la plataforma donde se podría volcar los datos obtenidos por los dispositivos.

Por motivos de confidencialidad, se ha eliminado la información sensible tanto referente a conocimiento propio del Instituto como a información perteneciente a las empresas colaboradoras.

2. Desarrollo de los dispositivos de medición

El objetivo de este paquete de trabajo para la segunda anualidad era desarrollar físicamente los dispositivos de medición, cuyo diseño se había realizado en la primera anualidad.

Inicialmente se revisaron los diseños realizados y se hicieron algunas pruebas con nuevos sensores cuyas características parecían mejores que los seleccionados inicialmente, como por ejemplo un sensor que mide temperatura y humedad al mismo tiempo (DHT22). Para realizar las pruebas de sensores se utiliza la plataforma Arduino, dado que su montaje y programación resulta más adecuada para esta evaluación.



Pruebas del sensor DHT22

Durante la anualidad anterior se llegó a la conclusión de que para cubrir el objetivo final propuesto no era necesario desarrollar cinco dispositivos. Se planteó la siguiente opción:

- Dispositivo D1. Medición de la actividad del personal. Considerando las limitaciones legales, contendrá los sensores adecuados para medir las siguientes variables:
 - Movimiento
 - Radiaciones térmicas
 - Tarjetas RFID

- Dispositivo D2. Medición del estado de la máquina y del trabajo realizado por la misma, para definir la eficacia del proceso. Contendrá los sensores adecuados para medir las siguientes variables:
 - Sonido
 - Vibración
 - Variación consumo de energía
 - Variación de temperatura
 - Variación de iluminación
 - Movimiento
 - Humedad ambiental

- Dispositivo D3. Utilizado para el registro de datos estructurados por parte del personal, a través de una interfaz adecuada (Human Machine Interface) y capacidad de comunicación con el sistema de almacenamiento y tratamiento de datos.

- Dispositivo D4. Dispositivo de comunicación inalámbrico para la recogida de los datos del resto de dispositivos y vía *Gateway* mandarlos al sistema externo de gestión de datos.

Los dispositivos D3 y D4 son elementos industriales de uso habitual, que no es necesario desarrollar ya que existen comercialmente. Por tanto, las tareas que se han ejecutado esta anualidad se han centrado en el desarrollo de los dispositivos D1 y D2, cuyos diseños fueron realizados la anualidad anterior.

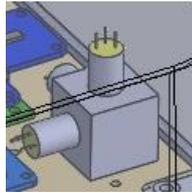
El Dispositivo D1 está compuesto por una tarjeta CORA Z7-10 de la marca Digilent, y una tarjeta de circuito impreso que posee un microprocesador ATmega328P. Adicionalmente se cuenta con una tarjeta de medición de vibraciones mecánicas, otra de medición del sonido con micrófono y una tarjeta adicional de alimentación eléctrica auxiliar.

La tarjeta CORA Z7-10 procesa las señales de los tres acelerómetros y del micrófono, en tanto que la tarjeta de circuito impreso posee un microprocesador ATmega328P con un software hecho a medida, y se conecta a los siguientes dispositivos de medición del proceso.

- Señal de sensor de nivel de iluminación.

- Señal de un sensor magnetómetro.
- Señal de un sensor de humedad relativa.
- Señal de un sensor de la temperatura ambiente.
- Conexión con una tarjeta de red Ethernet.

Los tres acelerómetros son uniaxiales, y se ha diseñado un sistema para que recojan las vibraciones en tres ejes lo más próximos posible, como se muestra en la figura de detalle siguiente.

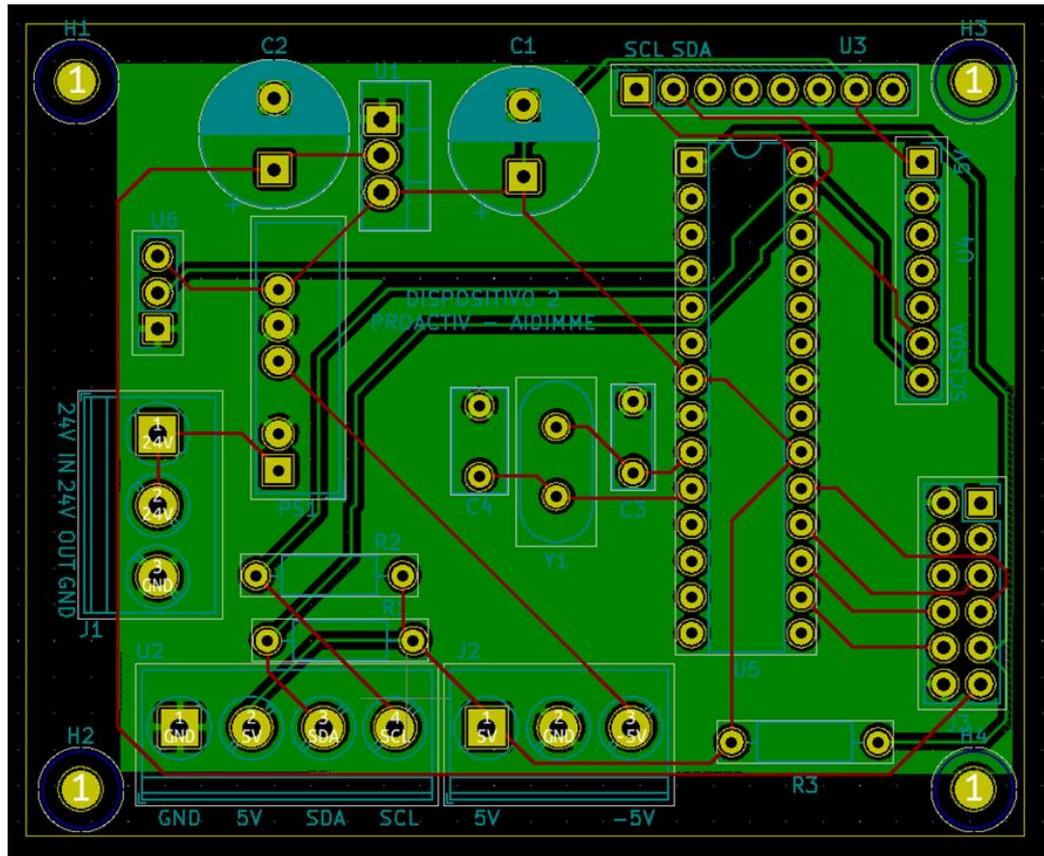


Dispositivo D2 (medición de actividad del personal)

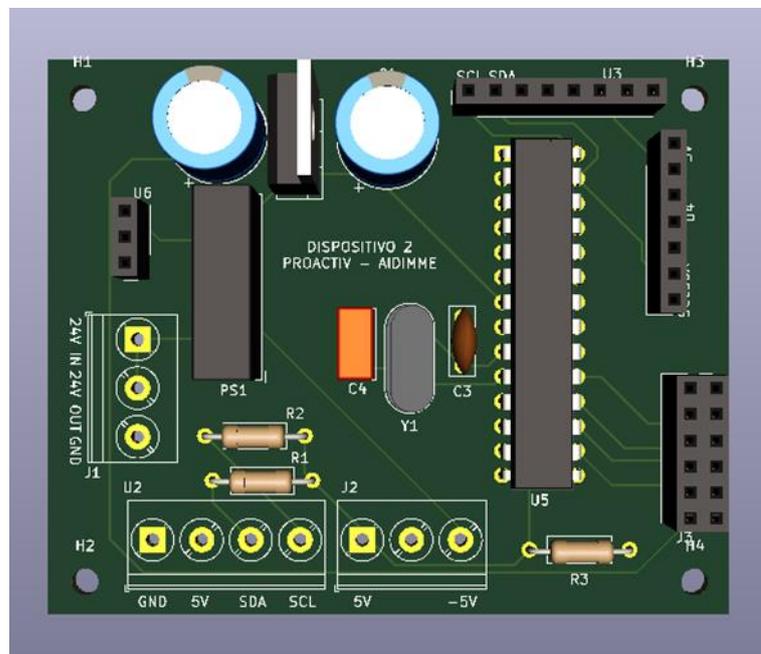
Con este dispositivo se permite al operario identificarse antes de empezar un trabajo mediante el uso de tarjetas de identificación por radiofrecuencia. Además detecta el movimiento del operario y detecta el calor que desprende el cuerpo del operario. Esta tarjeta de circuito impreso posee un microprocesador ATmega328P con un software hecho a medida y se conecta a los siguientes sensores.

- Lector de dispositivos RFID
- Sensor de movimiento de una persona en el puesto de trabajo.
- Sensor de calor despedido por el cuerpo de una persona en el puesto de trabajo.
- Tarjeta de red Ethernet para comunicación de datos.

A continuación aparece el desarrollo de la tarjeta de circuito impreso.



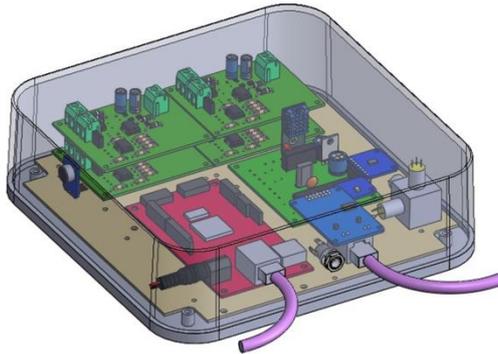
Diseño PCB de KiCAD tarjeta CPU del dispositivo D2



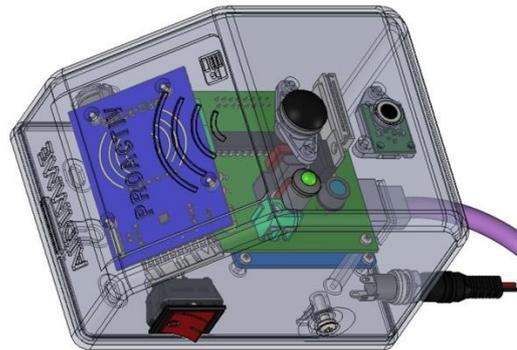
Simulación del montaje de los componentes en la tarjeta fabricada (dispositivo D2)

A partir de estos diseños de PCB se han construido las diversas tarjetas y se han integrado en dos dispositivos compactos cuyo diseño CAD e imágenes reales pueden verse seguidamente, de los que se han fabricado cinco unidades.

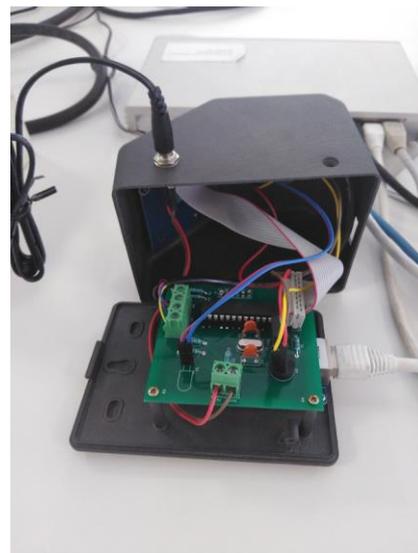
Inicialmente la fabricación de los dispositivos iba a ser subcontratada, pero finalmente se decidió comprar los componentes y fabricarlos internamente.



Diseño CAD del dispositivo D1



Diseño CAD del dispositivo D2



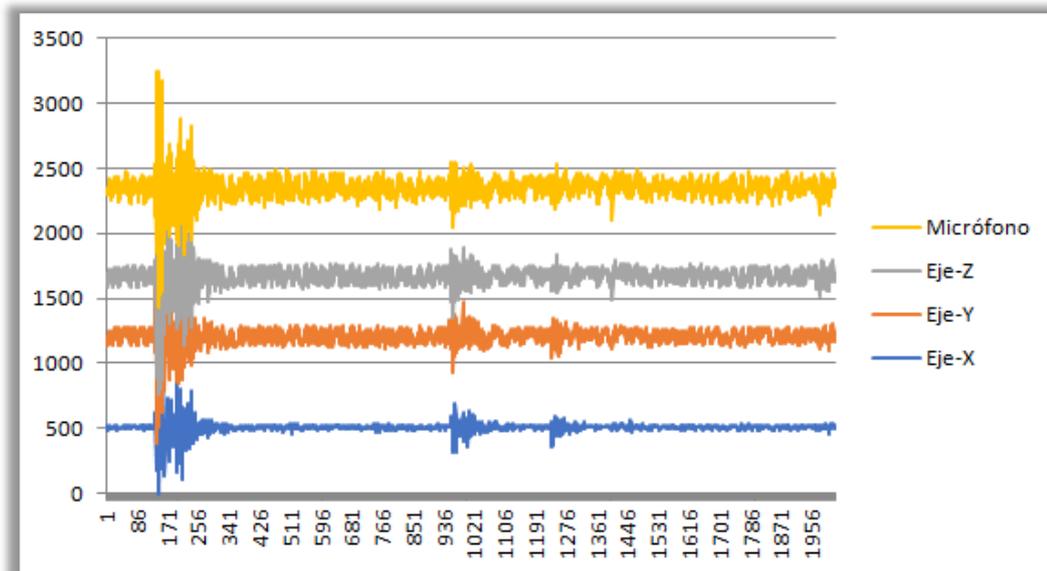
Dispositivo D2 de control de personal



Dispositivo D1 de control de proceso

Se han realizado diversas pruebas en laboratorio para verificar el funcionamiento de las diversas tarjetas desarrolladas y del conjunto integrado.

En la siguiente gráfica se aprecia el resultado de una prueba de laboratorio con el dispositivo de medición de variables de proceso donde se puede observar las señales producidas por los acelerómetros (X, Y, Z) y el micrófono cuando se dieron unos golpes a la caja que contiene las tarjetas y los sensores. El pico más alto se debe al primer golpe, que fue el más fuerte.



Gráfica de vibraciones y sonido

3. Desarrollo de la infraestructura de captura de datos

En la anualidad anterior se realizaron pruebas de concepto de dos plataformas cloud que en principio podían ser adecuadas para desarrollar la infraestructura de captura de datos de los dispositivos desarrollados: AWS y Azure. Ante las facilidades con las que cuenta Azure para la virtualización de una fábrica y el diseño de un sistema SCADA que muestre la evolución en tiempo real de los datos de producción, finalmente se ha optado por esta aplicación.

Esta solución desplegará las estaciones y dispositivos que simularán las líneas de producción de la fábrica mediante el acelerador de soluciones de la Factoría Conectada. Las comunicaciones se basarán en el estándar OPC UA.

Sistema de comunicación

Para el proceso de comunicación entre los dispositivos desarrollados y la plataforma Azure, lo que en terminología del proyecto se denominaba dispositivo D4, se selecciono inicialmente el dispositivo Flexy 205 de la firma eWon. Tal y como se indica en las especificaciones del producto, el dispositivo es capaz de comunicarse con diferentes plataformas Cloud y más concretamente con la plataforma de Azure, pudiendo adquirir datos de numerosas redes industriales y los puede reenviar utilizando los siguientes protocolos

- OPC UA,
- Modbus,
- MQTT,
- SNM

Sin embargo durante la integración con la plataforma Cloud se han encontrado los siguientes problemas principales.

- Problema de validación de certificados SSL. Con el fin de proporcionar comunicaciones cifradas así como mecanismos de autenticación basados en sistemas criptográficos avanzados se pretendía utilizar Certificados SSL según el estándar x509. Al realizar diversas pruebas, resulta imposible utilizar este tipo de certificado, por lo que Azure no permite la conexión segura.
- El segundo problema es la falta de integración con la plataforma Factoría Conectada de Azure. Para el correcto funcionamiento del sistema, el Gateway necesita tener integrado el módulo OPC Publisher IoT Edge junto con el módulo OPC Proxy. El Gateway Flexy 205 carece de dichos módulos por lo que no se integra con la plataforma Azure Factoría Conectada.

Tras el descarte del dispositivo Flexy 205 por los motivos indicados, se escoge el dispositivo EdgeGate de la empresa Softing.



Fuente: <https://data-intelligence.softing.com/products/iot-gateways/edgegate/>

Protocolos soportados por el dispositivo para el intercambio de datos.

- OPC UA (Server, 60,000 items in total),
- MQTT (Publisher, up to 1,000 topics)

Plataformas Cloud

- Microsoft Azure Connected Factory,
- Microsoft Azure IoT Hub,
- IBM Watson IoT Hub,
- General Electric Predix,
- Amazon AWS

El mayor inconveniente de este dispositivo es el coste, ya que su precio es cuatro veces superior al Flexy 205.

Las pruebas realizadas resultan satisfactorias y se consigue el enlace entre los dispositivos y la plataforma Azure.

Desarrollo de la infraestructura de captura de datos

Utilizando las funcionalidades de la plataforma Azure – Factoría Conectada, se consigue desarrollar un sistema que permite insertar máquinas supervisadas en una línea de fabricación, controlar la eficiencia de la línea en conjunto y de cada máquina supervisada, y que permite analizar los datos IoT almacenados en la nube con el fin de obtener la información necesaria para mejorar la eficiencia productiva.

En este caso se ha diseñado una línea de fabricación genérica dado que ya estaba formateada en la plataforma, pero que incluye dos máquinas supervisadas pertenecientes a una de las empresas piloto. La supervisión consiste en la medición de

las variables directamente relacionadas con la eficiencia productiva, en este caso el número de piezas fabricadas, las paradas de máquina y la calidad resultante (rendimiento, disponibilidad y calidad de cada máquina).

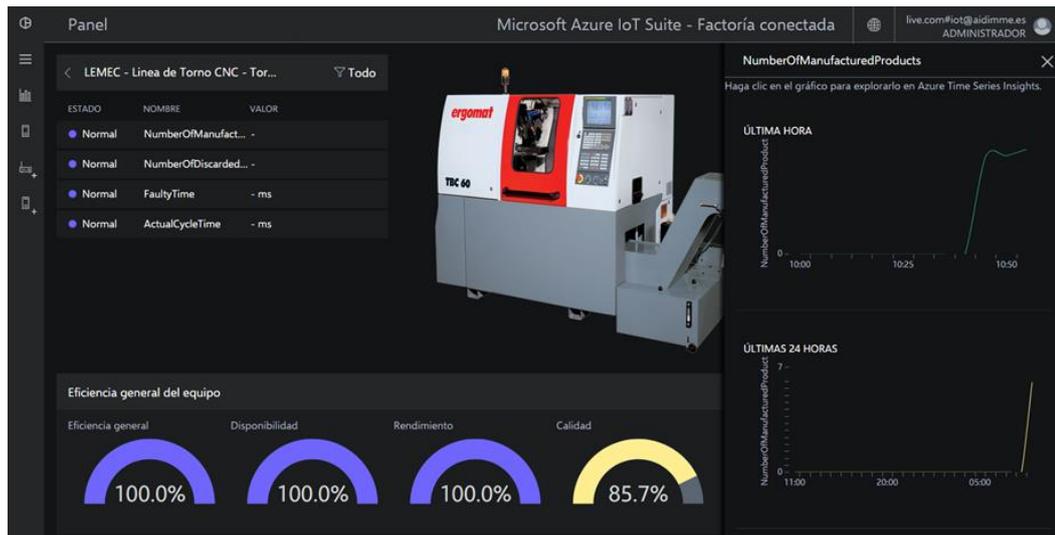
Para realizar estas pruebas se han recogido y subido los datos generados por los sensores de medición directa instalados en el piloto, utilizando el dispositivo Edge Gate conectado al controlador que gestiona el proceso de captura de datos (ver instalación del piloto en PT 4).

A continuación se muestra una serie de capturas de pantalla que describen el funcionamiento del sistema.

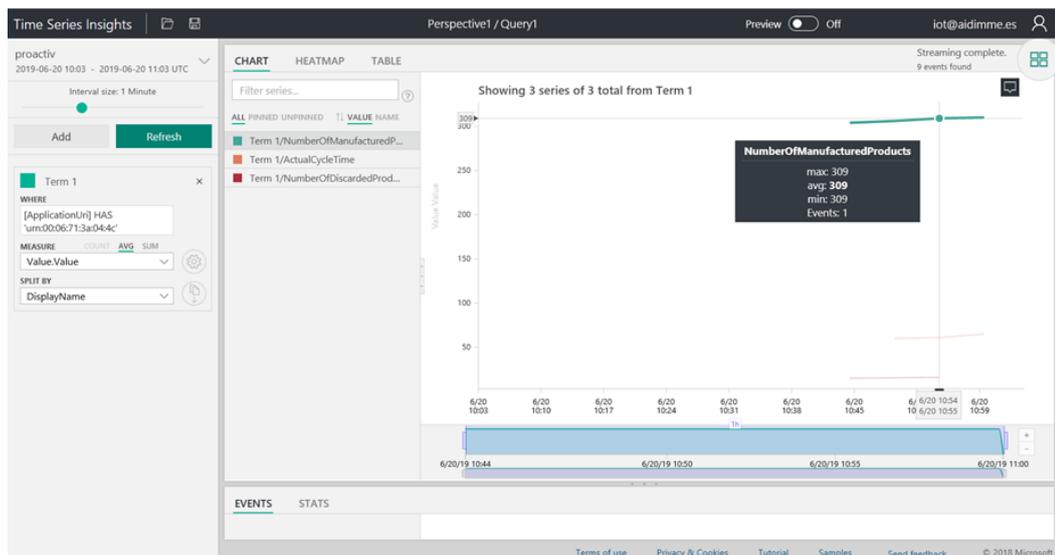


En esta imagen se puede apreciar el torno CNC (naranja) y la prensa de estampación (azul), que son las máquinas supervisadas. El color naranja indica que existe algún error de medición en el torno (en este caso debido a que no se había definido correctamente el rendimiento de la máquina).

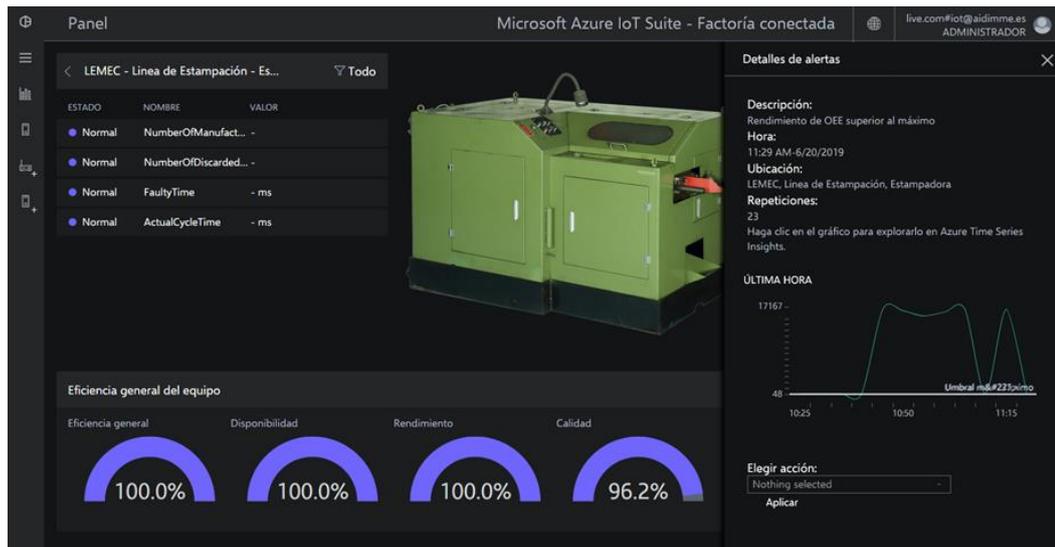
La parte inferior de la pantalla muestra datos asociados al conjunto de la línea supervisada (torno y prensa), en este caso datos asociados a la eficiencia general de la línea (OEE) y sus componentes.



En la figura superior, al entrar en una de las máquinas, se observa el detalle de los indicadores asociados a la misma, en dos periodos temporales distintos (una hora y 24 horas).



En la figura anterior se muestra con más detalle el número de productos fabricados en tiempo real.



En la imagen anterior se muestra una información equivalente, pero en este caso de la prensa de estampación.

Como puede apreciarse los indicadores están al 100% debido a que en el piloto no se ha conectado el controlador al ERP de la empresa, y por tanto no se dispone de datos teóricos de fabricación (tiempos de ciclo o disponibilidad teórica) que permitan calcular el porcentaje de eficiencia real alcanzado en la orden de fabricación en curso. El indicador de calidad sí que se puede calcular sin más información ya que sólo depende de las piezas defectuosas, dato del que sí se dispone.

4. Validación en empresas piloto

El propósito de la validación en las empresas piloto es verificar la viabilidad de realizar el control del proceso únicamente con las mediciones que aportan los dispositivos desarrollados, sin necesidad de tener que intervenir de ninguna forma en el propio proceso.

La validación requiere los siguientes pasos:

- Instalar en alguna/s máquinas de las empresas piloto un sistema que mida de forma directa las variables necesarias para tener el proceso bajo control, es decir conocer en tiempo real el rendimiento del proceso (piezas fabricadas por unidad de tiempo), la disponibilidad (tiempo consumido en paradas imprevistas) y la calidad del producto.
- Plantear un modelo predictivo que relacione las variables medidas por los dispositivos (medidas indirectas) con las variables medidas de forma directa indicadas anteriormente
- Instalar los dispositivos desarrollados en las máquinas de los pilotos y verificar que el modelo predictivo planteado funciona correctamente

En la pasada anualidad se comenzaron a montar los sistemas para medir de forma directa dos procesos de fabricación en la empresa LEMEC y un proceso en la empresa PROFILTEK. En esta anualidad se ha finalizado el montaje y la instalación de los sistemas en ambas empresas.

INSTALACIÓN EN LEMEC

En la máquina de estampación (conformado en frío), se deseaba contar el número de piezas fabricadas, así como el tiempo que tarda la máquina en fabricarlas. Se dispone de un control de las microparadas y de las paradas más largas. Se cuentan piezas mediante señales que proporciona la misma máquina. A demás se mide el consumo eléctrico de la máquina. Se ha incluido un terminal HMI (pantalla táctil) para que el operario pueda visualizar la producción e interactuar con el sistema de control (declarar motivos de paradas, reportar calidad...).

La segunda máquina a monitorizar, se trata de un torno CNC de decoletaje que fabrica piezas a partir de unas barras de metal, que van alimentando la máquina. Unas herramientas de corte mecanizan la barra y la van cortando para ir produciendo piezas. Se desea saber:

- Tiempo entre cambio de barras.
- Número de piezas.
- Tiempo de fabricación de cada pieza.
- Paradas y micro paradas.

La máquina dispone de una señal luminosa para indicar si está en marcha, parada o sustituyendo pieza. Se usarán optoacopladores para adecuar la señal luminosa a una señal que pueda procesar el autómatas.

En el torno se aloja el armario eléctrico principal de la instalación. En este armario se encuentran los siguientes elementos:

- CPU Omron NJ101
- Cabecera de entradas y salidas
- Tarjetas de entradas digitales
- Tarjetas de entradas analógicas
- Switch industrial
- DC Power
- Protecciones eléctricas.
- Relés de acoplamiento de señal
- Bornes de distribución



Armario de control instalado en el torno



Pantalla HMI para reporte de actividad en el torno

En la estampadora se extraen las señales de

- Pieza fabricada
- Corriente de las 3 fases (R, S, T)

La señal de marcha-paro se obtendrá mediante software, temporizando la señal de pieza. De este modo no es necesario capturar señales de las balizas de la máquina.

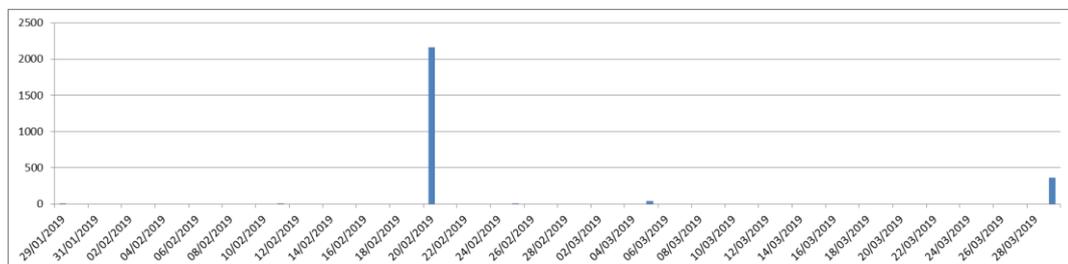


Armario de control de la estampadora con pantalla HMI integrada

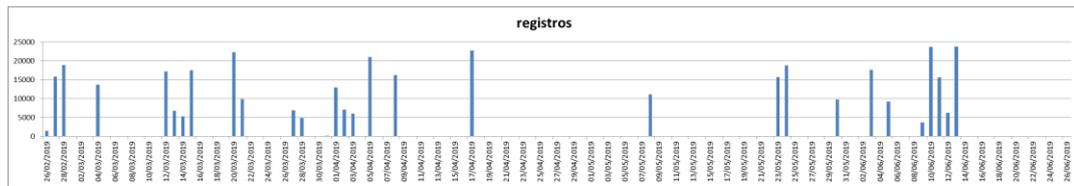
Mediante estos elementos se puede controlar en ambas máquinas:

- La tasa de producción del proceso
- La duración de las paradas y micro-paradas no previstas que tiene la máquina y el motivo de las paradas prolongadas (siempre que el operario lo reporte)
- La calidad de las piezas fabricadas (control del lote) siempre que el operario lo reporte.

Una vez instalado el sistema se comienza a registrar datos, aunque se depende mucho de la carga de trabajo existente en cada máquina. De hecho en el primer trimestre de este año, el torno sólo trabajó dos días.



Días en los que se recogen datos en el torno



Días en los que se recogen datos en la estampadora

INSTALACIÓN EN PROFILTEK

El proceso sobre el que se monta el presente piloto es el corte y ajuste final de las dimensiones del cristal de una mampara de baño, antes de pasar al proceso de templado del mismo. Éste proceso se lleva cabo en una máquina denominada bilateral compuesta por un alimentador de cristales, una cinta transportadora que mueves los cristales a través de 22 muelas de pulido que dan las dimensiones finales.

En la sección se encuentran dos máquinas bilaterales. En la primera se ajustan las dimensiones del ancho del cristal, y en la segunda se ajustan las dimensiones del largo.

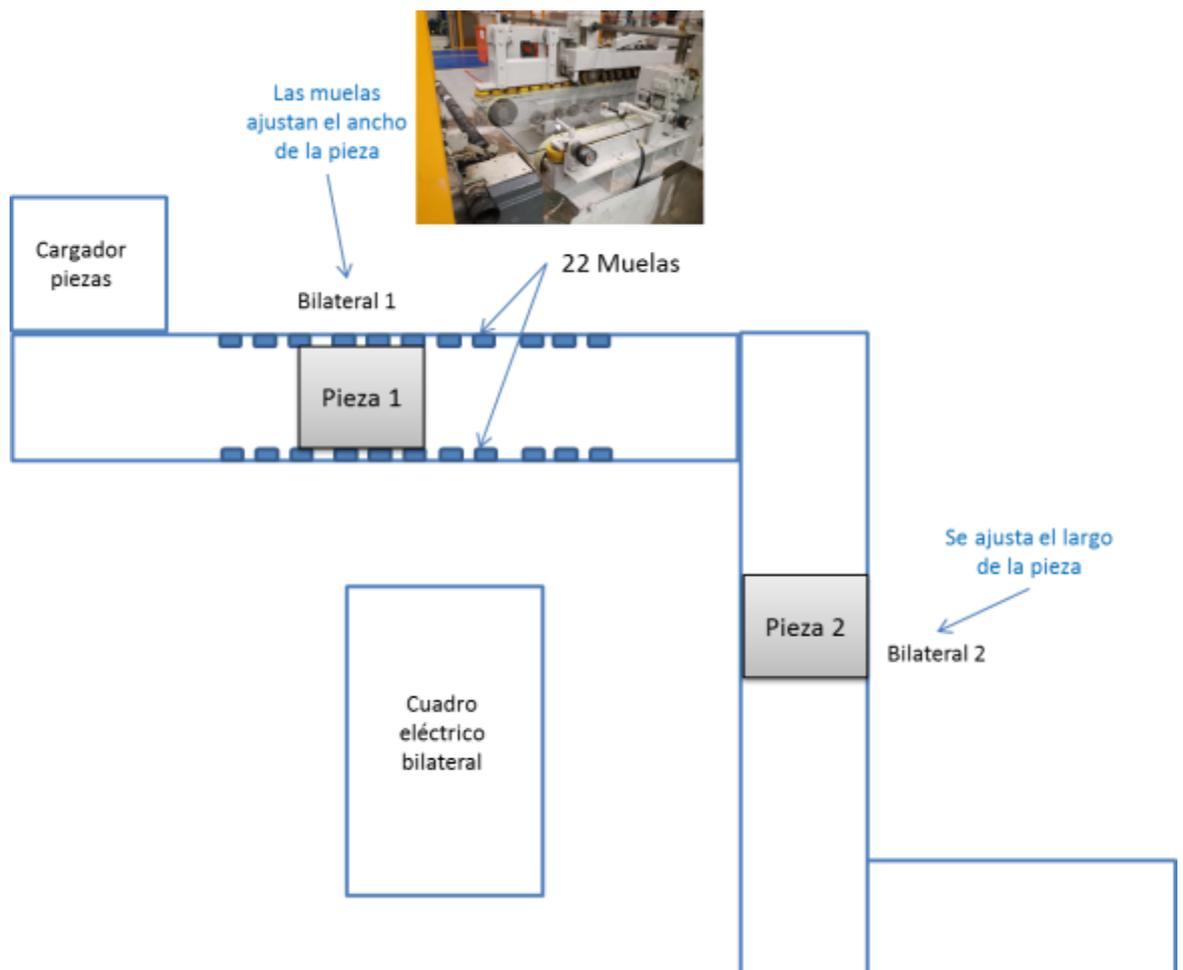


Imagen: Esquema general de la sección piloto.

Fuente: elaboración propia AIDIMME.

En cada bilateral se ubican 22 muelas de pulido (11 a cada lado del cristal). Cada grupo de muelas realizan una función: arranque de material, biselado superior, biselado inferior y pulido.

La empresa ha detectado que el deterioro de las muelas es un factor clave a la hora de generar defectos de calidad en las piezas, por lo que un control del desgaste de las mismas para anticipar su sustitución resulta clave en el piloto.

Así mismo, resulta importante vincular la actividad de la máquina (paso de piezas y sus paradas) con dicho uso de las muelas.

Por tanto, los principales objetivos a cubrir con el presente piloto son:

- Monitorizar el estado de las muelas que dan las dimensiones finales a los cristales.
- Monitorizar el estado de la máquina (en marcha o parada), los motivos y duración de las paradas), paso de piezas, etc.

El sistema de captura de datos del piloto en Profiltek se compone de un conjunto de sensores de medida directa (corriente, velocidad de línea, y paso de piezas), cuyas señales eléctricas se conectan a una serie de tarjetas de entrada de datos digital de un autómata programable. Dicho autómata conectado a un servidor vía router WIFI permite almacenar la información capturada en una base de datos alojada en un servidor.

Además de estos elementos, se ha utilizado una pantalla táctil para informar al operario del estado de la línea (mostrando los valores capturados por los sensores). Además, la pantalla permite al operario interactuar con el sistema, de modo que pueda registrar paradas de máquina e indicar el motivo de la misma.

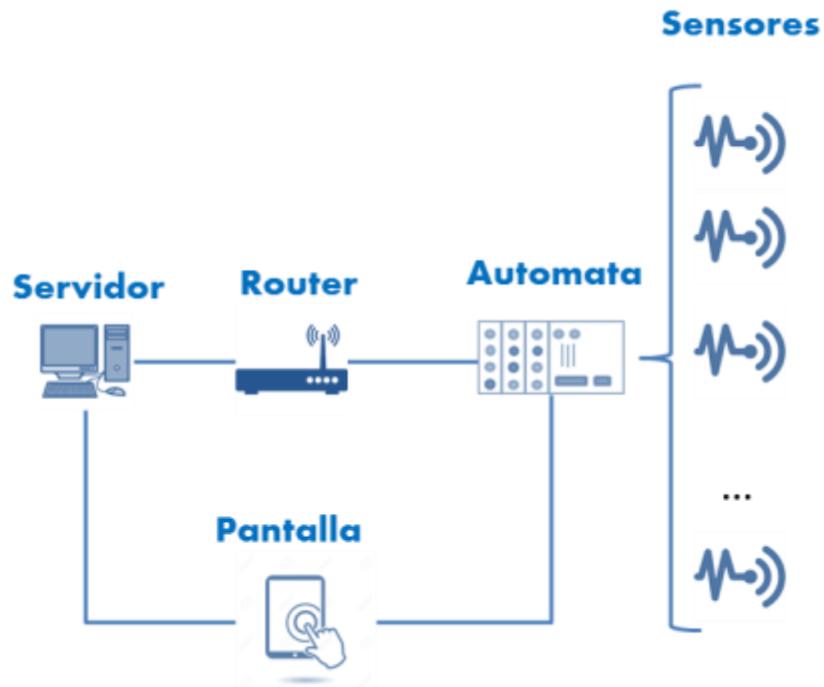


Imagen: Esquema del sistema de captura de datos.

Fuente: elaboración propia AIDIMME.

Por tanto, los elementos físicos (hardware) de la instalación de éste piloto demostrador son:

- Sensores.
- Automata programable con fuente de alimentación y tarjetas de entrada de datos.
- Router WIFI.
- Servidor, junto con teclado, ratón, y monitor.

A continuación se muestran las imágenes de la instalación de los sensores instalados por AIDIMME.



Imagen: Sensor inductivo para el cálculo del paso de piezas

Fuente: Fotografía tomada por AIDIMME en la línea de Profiltek.



Imagen: Sensor inductivo para el cálculo de la velocidad de la línea.

Fuente: Fotografía tomada por AIDIMME en la línea de Profiltek.



Imagen: Sensores de corriente para medir consumo motores muelas.

Fuente: Fotografía tomada por AIDIMME en la línea de Profiltek.



Imagen: Transformador para medir consumo general de la máquina

Fuente: Fotografía tomada por AIDIMME en la línea de Profiltek.

El armario con el autómata (y sus conexiones con todos los sensores) y la pantalla de visualización, así como el router y el servidor se ubicaron junto al cuadro eléctrico de la máquina, ya que era la ubicación que la empresa consideró más adecuada.



Imagen: Instalación del cuadro en Profiltek

Fuente: Fotografía tomada por AIDIMME en la línea de Profiltek.



Imagen: Imagen de la pantalla Kimco

Fuente: Fotografía tomada por AIDIMME en la línea de Perfiltek.

Al igual que en el otro piloto, una vez realizada la instalación se toman datos para comprobar el funcionamiento del sistema.

En la imagen puede verse una tabla de la base de datos donde se registran valores de intensidad de corriente de las tres fases de alimentación de la máquina.

ID	FASE1	FASE2	FASE3	ELECTROVAL	ELECTROVAL	ELECTROVAL	ELECTROVAL	ELECTROVAL	ELECTROVAL	DATE_TIME
1818334	90	88	91	1	1	1	1	1	1	1 2019-06-21 13:25:42.247
1818333	90	86	91	1	1	1	1	1	1	1 2019-06-21 13:25:41.177
1818332	92	87	89	1	1	1	1	1	1	1 2019-06-21 13:25:40.123
1818331	91	87	92	1	1	1	1	1	1	1 2019-06-21 13:25:39.057
1818330	90	88	90	1	1	1	1	1	1	1 2019-06-21 13:25:38.007
1818329	92	87	89	1	1	1	1	1	1	1 2019-06-21 13:25:36.943
1818328	92	88	89	1	1	1	1	1	1	1 2019-06-21 13:25:35.873
1818327	95	90	93	1	1	1	1	1	1	1 2019-06-21 13:25:34.820
1818326	97	92	93	1	1	1	1	1	1	1 2019-06-21 13:25:33.753
1818325	94	92	95	1	1	1	1	1	1	1 2019-06-21 13:25:32.697
1818324	97	91	93	1	1	1	1	1	1	1 2019-06-21 13:25:31.633
1818323	97	91	93	1	1	1	1	1	1	1 2019-06-21 13:25:30.573
1818322	97	91	96	1	1	1	1	1	1	1 2019-06-21 13:25:29.523

Imagen: Fragmento de la base de datos

Fuente: PROFILTEK.

MODELO PREDICTIVO

El modelo predictivo que se plantee debe ser capaz de proporcionar los datos que se desea conocer en cada máquina pero sin que dichos datos se midan directamente, sino a partir de la información proporcionada por los dispositivos autónomos y no invasivos.

El primer paso debe ser conocer el problema que se debe resolver, así como las herramientas de las que disponemos para hacerlo. El reto se encuentra en idear una función que dada una muestra de las medidas indirectas, nos devuelva un estado definido por las medidas tomadas de forma directa, de esta forma, poder tener resultados directos de forma no invasiva. Tal como se muestra a continuación:

$$\begin{aligned}
 (x_1, x_2, \dots, x_n) &\xrightarrow{f_1} y_1 \\
 (x_1, x_2, \dots, x_n) &\xrightarrow{f_2} y_2 \\
 &\vdots \\
 (x_1, x_2, \dots, x_n) &\xrightarrow{f_m} y_m
 \end{aligned}$$

El problema aquí es que las funciones f_1, f_2, \dots, f_m son desconocidas y se necesitarán herramientas que permitan averiguarlas o aproximarlas si es que esta aproximación es posible. Para ello, se va a utilizar la potencia de las redes neuronales artificiales, un

algoritmo de aprendizaje cuyo concepto se basa livianamente en el funcionamiento de las redes de neuronas formadas en el cerebro.

Para conocer el estado del proceso se dispone de unos datos de entrada y unos datos de salida.

Datos de Entrada (Indirectos):

- **Sonido.** Los datos de sonido recogidos por un micrófono son tratados debido a su alta frecuencia de toma, en este caso se utilizan FPGAS para transformar los datos a espectro de frecuencia. Siendo así, estos datos están conformados por el valor de pico y el valor de frecuencia de pico de cada uno de los 10 primeros armónicos principales. Esto se traduce en 20 valores de tipo double.
- **Vibración.** Los datos de vibración se recogen mediante un acelerómetro de 3 ejes, por ello sufre el mismo problema que el sonido: una frecuencia de toma de datos muy elevada. En este caso, la solución ha sido la misma y por tanto, igualmente se recogen 20 datos por eje representando valor y frecuencia de los picos de los 10 armónicos. Por todo esto, tendremos 20 datos de tipo double por eje, es decir, 60 datos en total.
- **Variación del campo magnético.** Se registran las variaciones mediante un magnetómetro de 3 ejes que ofrece 3 datos de tipo integer.
- **Temperatura ambiental.** Un sensor mide los grados de la estancia ofreciendo un dato de tipo integer.
- **Iluminación.** Un luxómetro mide los lúxes que recibe reportando un dato de tipo integer.
- **Humedad ambiental.** El sensor de humedad reporta un dato de tipo integer.

Datos de Salida (Medidas directas):

- **Pieza fabricada** (Se ha fabricado una pieza en el proceso). Para obtener esta información nos basaremos en el contador de piezas instalado mediante un inductivo, este valor viene representado mediante 1 dato de tipo integer.
- **Estado de la máquina.** Representa si la máquina está en funcionamiento o parada, los datos se toman diferenciando si se trata de una microparada (menos de 5 minutos) o una parada completa mediante dos variables tipo bit que se muestran a uno o cero. Sin embargo, para el estudio de correlación, vamos a tomar ambas con el mismo estado, dejando un valor tipo bit que se mostrará a 1 si la parada está activada o 0 si no lo está.
- **Calidad del producto fabricado.** La calidad del producto viene dada por pares de enteros indicando el tipo de defecto encontrado y el número de piezas no conformes con ese problema.

Una vez explicadas las entradas y salidas de la red neuronal, se procede a definirla. En particular, como se intenta aproximar 3 salidas diferentes, vamos a necesitar 3

aproximadores diferentes para las funciones f_1 , f_2 , f_3 por lo que utilizaremos 3 redes neuronales.

Piezas fabricadas

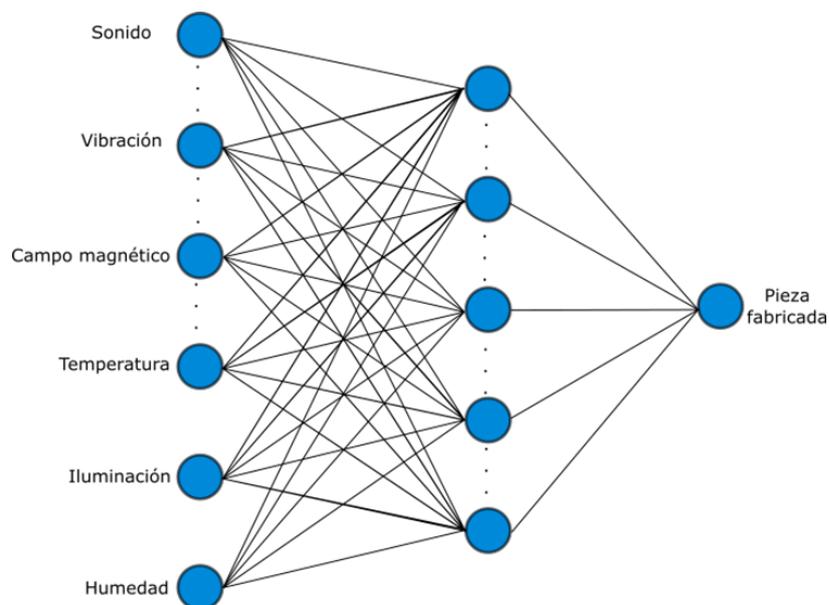
En el primer caso vamos a tener una red neuronal de clasificación. Se trata de una clasificación binaria pues tendremos el valor 1 para pieza fabricada y 0 en caso contrario, de esta forma, vamos a especificar la arquitectura de la red.

En la capa de entrada tendremos tantos datos como datos de entrada, en este caso serán 20 de sonido, 60 de vibraciones, 3 de variación de campo magnético, 1 de humedad, 1 de temperatura y 1 de iluminación. Esto conforma una capa de entrada de 86 neuronas.

La capa de salida también viene definida por la predicción que vamos a realizar. Siendo una clasificación binaria, tendremos una única neurona de salida con 2 posibles valores de resultado.

Una capa oculta suele ser suficiente para la mayoría de problemas. En algunas situaciones, aumentar el número de capas ocultas puede aumentar la precisión aunque también aumenta el tiempo de entrenamiento.

Es práctica habitual elegir un número de neuronas en las capas ocultas que se encuentre entre el número de neuronas en la de entrada y en la de salida. Visto esto, vamos a utilizar una capa oculta y la media entre el número de neuronas de entrada y de salida para calcular el número de neuronas en la capa oculta, siendo esto $(86+1)/2$. De esta forma, la red neuronal quedaría como se muestra en la figura siguiente.



Red neuronal utilizada para determinar la cantidad de piezas fabricadas por una máquina a partir de mediciones indirectas

Comprobaremos los resultados también con 2 capas ocultas para comprobar si los resultados mejoran, manteniendo el mismo número de neuronas para ambas capas.

Estado de la máquina

En este caso nos encontramos otra vez ante una clasificación binaria ya que debemos discernir entre máquina funcionando o máquina parada, por lo que la arquitectura de la red será idéntica a la explicada en la sección anterior

Calidad del producto fabricado

Necesitaremos una red neuronal de regresión, que intente averiguar la cantidad de piezas no conformes que se han producido ya que una aproximación de clasificación es posible pero resultaría muy poco útil. Vamos a predecir el porcentaje de defectos que se ha producido durante la orden de fabricación.

Al tratarse de una red neuronal de regresión sobre una sola cantidad, igualmente tendremos una red neuronal con una arquitectura igual a la de los casos anteriores con la diferencia de que la función de activación de la capa de salida será lineal.

Resultados de la prueba: estado de la máquina

Como se ha indicado anteriormente, se han colocado sobre una máquina los dispositivos desarrollados, para validar tanto su funcionamiento como la posibilidad de medir el estado del proceso únicamente con ellos.



Imagen de los dispositivos adheridos mediante imanes a una prensa

Se obtienen datos tanto de los sensores directos (inductivo y corriente) como de los indirectos que incorpora el dispositivo.

Una vez tratados los datos, se debe montar el dataset. En este caso será suficiente asignar como target a cada fila de datos el resultado de la toma directa que identifica si este se encuentra en una parada o no. En este caso las etiquetas elegidas han sido FUNCIONANDO y PARADO.

Se utilizó el software de prototipado Weka para probar el modelo y estos son los resultados obtenidos utilizando la red neuronal definida anteriormente:

```

Time taken to build model: 1575.82 seconds

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances   30866      96.069 %
Incorrectly Classified Instances  1263       3.931 %

Kappa statistic                 0.9213

Mean absolute error             0.0417

Root mean squared error         0.1856

Relative absolute error         8.3413 %

Root relative squared error     37.1383 %

Total Number of Instances      32129

=== Detailed Accuracy By Class ===

      TP Rate  FP Rate  Precision  Recall  F-Measure  MCC   ROC Area  PRC Area  Class
      0,953   0,032   0,970     0,953   0,962     0,921  0,993   0,994   FUNCIONANDO
      0,968   0,047   0,951     0,968   0,960     0,921  0,993   0,992   PARADO
Weighted Avg.  0,961   0,039   0,961     0,961   0,961     0,921  0,993   0,993

=== Confusion Matrix ===

  a  b  <-- classified as
15818  772 |  a = FUNCIONANDO
    
```

Se puede comprobar que los resultados son muy buenos, obteniendo un 96% de aciertos, con esto se considera validado el sistema por lo que se procede a diseñarlo en Python utilizando la biblioteca KERAS que funcionará más rápido y se puede instalar como un sistema solvente en cualquier máquina. Por ello el diseño de la red neuronal

utilizando KERAS y la función de activación sigmoide, tal como se ha probado en el software de prototipado queda de la siguiente manera:

```

model.add(tf.keras.layers.Dense(86, activation=tf.math.sigmoid))
model.add(tf.keras.layers.Dense(43, activation=tf.math.sigmoid))
model.add(tf.keras.layers.Dense(1, activation=tf.math.sigmoid))
    
```

Resultados de la prueba: piezas fabricadas

Para este apartado, se han realizado pruebas con las redes neuronales descritas anteriormente, sin embargo, la alta frecuencia de los datos complica la posibilidad de predecir a un nivel de detalle tan grande, por ello, se han buscado otras vías alternativas de ejecución, la que mejor resultado ha dado ha sido reutilizar la red neuronal utilizada en el apartado anterior para calcular el tiempo de funcionamiento y con ello escalar el número de piezas fabricadas mediante la frecuencia media de fabricación encontrada en los datos, ya que esta máquina en particular no suele sufrir ralentizaciones, tal como se puede ver en el gráfico de fabricación:



Tasa de producción de la máquina estampadora (piezas fabricadas vs marcas de tiempo).

Fuente: elaboración propia

El código cuenta la cantidad de registros en los que se predice funcionamiento en lugar de para y multiplica por el tiempo medio de captura de datos, para después dividir por el tiempo medio de fabricación, obteniendo las piezas fabricadas en el periodo de tiempo designado.

```
def predecir_piezas(inicio,fin):  
    datos = obtener_datos_tiempo(inicio, fin)  
    tiempo_trabajado = 0  
    for registro in datos:  
        if nn_predict(registro)=='FUNCIONANDO':  
            tiempo_trabajado += 5  
    piezas_fabricadas = tiempo_trabajado/3  
    return piezas_fabricadas
```

Este método resulta una muy buena aproximación ofreciendo resultados de gran calidad, con una desviación media inferior al 5%, consiguiendo una estimación certera de la fabricación.

Resultados de la prueba: calidad de piezas

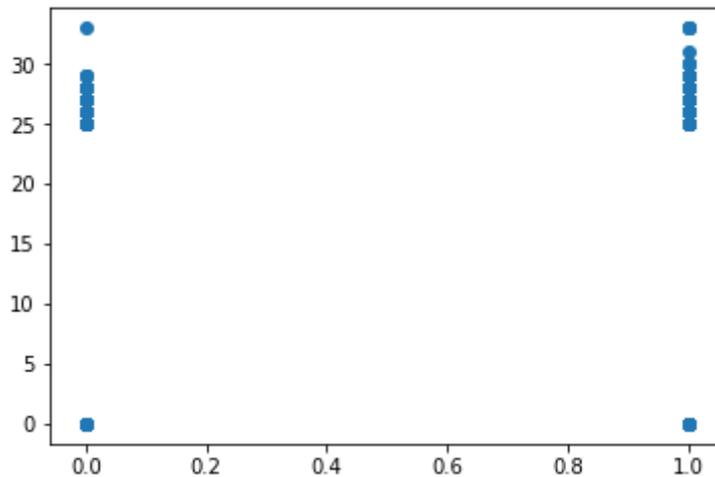
Este apartado ha sido omitido temporalmente pues los datos recogidos de calidad de fabricación no reportan suficientes datos de defectos como para realizar un entrenamiento de las redes neuronales.

Presencia del operario

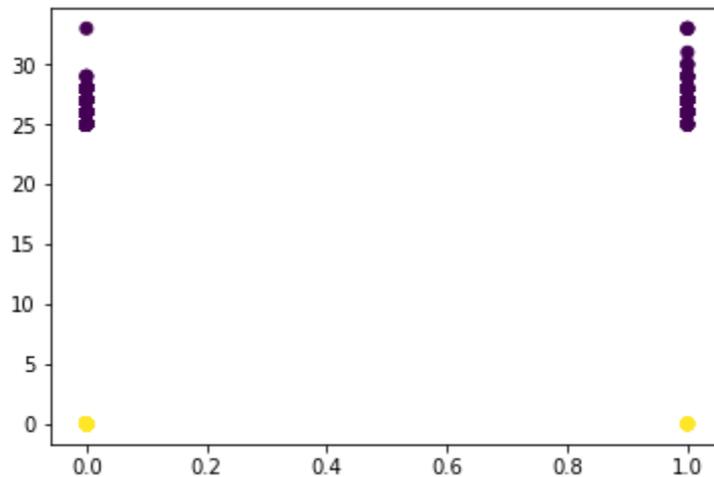
En este caso no se disponía de datos que identifiquen si el operario está o no en el área de trabajo, es decir, los datos están sin etiquetar. En este escenario únicamente se puede utilizar el entrenamiento no supervisado. Particularmente, se utilizará el algoritmo de K-medias (*K-means*) para generar grupos (clusters) de elementos. Una característica clara del algoritmo de K-medias es que deja el número de centróides a elección, en este caso la elección debe ser clara, ya que se está intentando discernir entre dos situaciones distintas claramente diferenciadas: El operario está presente o no lo está, por tanto se utiliza K=2.

Lo primero que se realiza antes de ejecutar el algoritmo es algún tratamiento previo, en particular, se van a eliminar *outliers* ya que en los datos de calor hay dos medidas que llegan prácticamente a 5000°C lo cual no tiene sentido y únicamente entorpecerá el resultado.

Seguidamente se utiliza Python y la librería sklearn para utilizar K-medias, Se puede visualizar el conjunto inicial de los datos recogidos por el autómata como:



Al aplicar el algoritmo se obtiene el siguiente agrupamiento:



Este resultado se repite en caso de que los datos se normalicen o se distancien, debido a que el resultado de tener movimiento pero no calor es un evento muy poco común que se produce en tan pocas ocasiones que es despreciable.

Se puede afirmar de forma certera que el cluster superior (marrón) indica la presencia de persona mientras que el inferior (amarillo) indica lo contrario.

Por último, se necesita algún método para asignar a los nuevos casos que aparezcan, en este caso las tres opciones más sencillas serían:

1. Reutilizar los centróides de K-medias y asignar el nuevo dato al centróide más cercano.
2. Utilizar el algoritmo de k-vecinos más cercanos (K-NN).
3. Utilizar una simple función de salto dada la simplicidad de la agrupación.

Cualquiera de estas opciones habría dado buen resultado de forma sencilla, aunque se ha optado por utilizar los K-vecinos más cercanos con $K=3$. Este algoritmo se puede encontrar también en la biblioteca sklearn, el siguiente código realiza la clasificación:

```
from sklearn.neighbors import KNeighborsClassifier
kvecinos = KNeighborsClassifier(n_neighbors=3)
kvecinos.fit(datos, dato_nuevo)
```

CONCLUSIONES

Se ha demostrado que es posible medir el estado de un proceso sin intervenir en la máquina ni en otras partes del proceso. Mediante un conjunto de dispositivos totalmente externos al proceso, hemos determinado la tasa de producción y las paradas de máquina con un error menor al 5%. Por tanto, los dispositivos desarrollados, con validaciones adicionales que no han podido ser finalizadas y con mejoras en el diseño y en la sensórica para reducir su tamaño y afinar las mediciones, pueden ser utilizados en entornos industriales para volcar datos relevantes de proceso en un sistema cloud accesible por cualquier usuario.

La facilidad de instalación, el coste y la rapidez con que estos dispositivos pueden estar operativos supone una ventaja relevante para medir y controlar los procesos analizados.

5. Referencias

- Glorot, X. &. (2010). Understanding the difficulty of training deep feedforward neural networks. . *Proceedings of the thirteenth international conference on artificial intelligence and statistics* , 249-256.
- Karsoliya, S. (2012). Approximating Number of Hidden layer neurons in Multiple Hidden Layer BPNN Architecture.
- Kurt Hornik, M. S. (1989). Multilayer Feedforward Networks are Universal Approximators. *Pergamon press*.
- L., R. I. (2000). A statistical procedure for determining the optimal number of hidden neurons of a neuralmodel.
- Stathakis, D. (2009). How many hidden layers and nodes? *International Journal of Remote Sensing*, 2133-2147.
- Yinyin Liu, J. A. (2007). Optimizing Number Of Hidden Neurons in Neural Networks.