

2020-2021  
ENTREGABLE

# Proyecto "VIRTUAL SENSE"

*DISEÑO DE SENSORES VIRTUALES PARA EL CONTROL DE PARÁMETROS DE MÁQUINA EN TIEMPO REAL*

Resumen de resultados

Número de proyecto: 22000059

Expediente: IMDEEA/2020/27

Duración: Del 01/04/2020 al 31/07/2021

Coordinado en AIDIMME por: SÁNCHEZ ASINS, JOSÉ LUIS

Línea de I+D: **INDUSTRIA 4.0**

## Contenido

<b>1</b>	<b>DESCRIPCIÓN Y OBJETIVOS DEL PROYECTO.....</b>	<b>4</b>
<b>2</b>	<b>CARACTERIZACIÓN DE SOLUCIONES .....</b>	<b>5</b>
2.1	Descripción de los procesos prioritarios en el sector del Mueble. ....	6
2.2	Descripción de los procesos prioritarios en el sector Metal .....	9
2.2.1	Procedimientos de conformación sin pérdida de material .....	9
2.2.2	Procesos de Conformación por deformación .....	10
2.2.3	Procesos de Deformación en frío .....	11
2.2.4	Procedimiento de conformación con pérdida de material. Conformación por separación y corte .....	11
2.2.5	Procedimiento de acabados.....	12
2.3	Identificación de carencia de datos.....	12
2.3.1	Calidad de mecanizados en el sector Mueble.....	12
2.3.2	Desgaste de consumibles en operación de lijado .....	13
2.3.3	Cantidad de material aplicado en los Procesos de Acabado y control de la viscosidad del material.....	14
2.3.4	Concentración de aceite en emulsiones aceites-agua en el sector Metal .....	15
2.3.5	Gramaje de fosfato y polímero en baños del sector Metal.....	16
2.4	Requisitos funcionales de los sensores virtuales .....	18
2.4.1	Requisitos para sensor virtual de valoración de calidad de mecanizados. ....	18
2.4.2	Requisitos para sensor virtual para ciclo de vida de lijas. ....	19
2.4.3	Requisitos para sensor virtual de gramaje aplicado de material de acabado y viscosidad real. ....	20
2.4.4	Requisitos para sensor virtual de medir concentración del aceite en taladrina.....	21
2.5	Requisitos para sensor virtual de medir gramaje depositado de fosfato y polímero. ....	21
<b>3</b>	<b>DISEÑO Y DESARROLLO DE SENSORES .....</b>	<b>22</b>
3.1	Selección de modelos de cálculo.....	22
3.1.1	Modelos seleccionados .....	23
3.1.2	División del conjunto de datos y validación cruzada .....	24
3.2	Identificación de variables en los sensores virtuales seleccionados.....	26
3.2.1	Sensor Virtual 1: Medida viscosidad de barniz. ....	26
3.2.2	Sensor Virtual 2: Medida del gramaje de barniz aplicado.....	26
3.2.3	Sensor Virtual 3: Medida de la concentración de taladrina. ....	27
3.3	Diseño y desarrollo de experimentos.....	28
3.3.1	Sensor Virtual 1: Medida de viscosidad de barniz. ....	28
3.3.2	Sensor Virtual 2: Medida de gramaje de barniz aplicado.....	33
3.3.3	Sensor Virtual 3: Medida de concentración de aceite en taladrina.....	42

“VIRTUAL SENSE” – Resumen de resultados.

<b>3.4</b>	<b>Desarrollo de los sensores virtuales.....</b>	<b>46</b>
3.4.1	Sensor Virtual 1.....	48
3.4.2	Sensor Virtual 2.....	52
3.4.3	Sensor Virtual 3.....	58
<b>3.5</b>	<b>CONCLUSIONES.....</b>	<b>61</b>
<b>4</b>	<b>PRUEBAS PILOTO Y VALIDACIÓN.....</b>	<b>62</b>
<b>4.1</b>	<b>Objetivo de los pilotos .....</b>	<b>62</b>
<b>4.2</b>	<b>Desarrollo de los Pilotos.....</b>	<b>64</b>
4.2.1	Sensor Virtual 1.....	64
4.2.2	Sensor Virtual 2.....	67
4.2.3	Sensor Virtual 3.....	71
<b>4.3</b>	<b>Resultado del Piloto .....</b>	<b>73</b>
4.3.1	Sensor Virtual 1.....	73
4.3.2	Sensor Virtual 2.....	74
4.3.3	Sensor Virtual 3.....	75
<b>4.4</b>	<b>Conclusiones.....</b>	<b>76</b>

## 1 DESCRIPCIÓN Y OBJETIVOS DEL PROYECTO.

Existe una gran cantidad de sensores físicos (conocidos como sensores hardware) capaces de medir una gran variedad de magnitudes físicas de relevancia para la monitorización de un proceso industrial: temperatura, humedad, consumo de corriente, aceleración, campo magnético, sonido, velocidades, presencia, luminosidad, distancia, etc.

Sin embargo, existen diferentes procesos industriales donde es inviable la instalación de un sensor físico, por diferentes motivos:

- El acceso a la zona física del proceso hace imposible acceder a un operario a la misma para la instalación del sensor.
- El ambiente en el que se desarrolla el proceso es agresivo para un sensor físico (normalmente cuando se trata de procesos químicos).
- No existe un sensor que pueda realizar directamente la medida.
- El proceso en cuestión requiere de una protección determinada, lo que encarece mucho el dispositivo (por ejemplo en procesos con atmósferas explosivas, donde todos los equipos eléctricos deben contar con certificación ATEX)

Además, la implantación de sensores físicos (hardware) requiere de la parada del proceso durante la instalación y pruebas de los mismos, lo que muchas veces supone un freno para su adopción, debido a las urgencias de fabricación.

En éste sentido, el proyecto perseguía el diseño y desarrollo de sensores virtuales (también conocidos como sensores software) para solventar ésta carencia, permitiendo capturar datos en aquellos procesos donde es inviable instalar sensores hardware (o no existen), alimentando al resto de habilitadores digitales, para una correcta adopción de la industria 4.0 en cualquier tipo de proceso.

En el caso del sector del mueble, los entornos y procesos donde el desarrollo de sensores virtuales tiene aplicación se pueden centrar en los procesos de acabado de piezas de mobiliario. Por ejemplo, para la calidad del acabado en piezas de barnizado es esencial el control de la viscosidad de los barnices justo antes de su aplicación. En la actualidad, no existe un sensor que permita medir la viscosidad en tiempo real de los diferentes tipos de barnices que se aplican a una pieza (capa de fondo, capa de imprimación, capa de acabado, etc.). Habitualmente se realizan pruebas manuales, con una muestra puntual (ensayo copa Ford) de modo similar al que se realiza en un laboratorio. Igualmente, la medición del gramaje aplicado a las piezas (cantidad de producto por metro cuadrado) requiere extraer manualmente piezas de la línea y realizar pesadas de comprobación, siendo también una variable fundamental que influye en el resultado.

En el sector metalmecánico se han identificado entornos apropiados para el desarrollo de sensores virtuales en procesos de mecanizado (medición de la degradación de

“VIRTUAL SENSE” – Resumen de resultados.

aceite de máquinas), conformado de piezas (tratamientos térmicos) y acabados (tratamientos químicos).

El **objetivo general** del proyecto era la potenciación de los habilitadores digitales de la industria 4.0 en el sector mueble y metalmecánico mediante el desarrollo de sensores virtuales específicos para procesos sectoriales, parametrizables en función de las características concretas del proceso y adaptativos a las variaciones del proceso. Estos sensores virtuales están orientados a la captura de datos e información de parámetros clave de procesos industriales, para los no se dispone de sensores hardware.

A partir de éste objetivo general se desplegaban los siguientes **objetivos específicos**:

- Identificación de relaciones causa-efecto entre las medidas clave de cada proceso y otros parámetros primarios del mismo que si pueden ser leídos mediante sensores hardware disponibles en la actualidad en el mercado.
- Diseño y desarrollo de sensores virtuales parametrizables y adaptativos para procesos complejos de medir en el sector del mueble y metalmecánico.
- Desarrollo de 2 pruebas piloto del sensor virtual en procesos tanto del sector del mueble como metalmecánico, que han permitido validar los resultados alcanzados.

## 2 CARACTERIZACIÓN DE SOLUCIONES

El objetivo de este paquete de trabajo es la caracterización de los procesos industriales sobre los que se aplicarán de forma generalizada los resultados del proyecto, así como la definición de los requisitos funcionales que deberán de cumplir los sensores virtuales que se van a diseñar y desarrollar con la ejecución del proyecto.

La dificultad de realizar medidas precisas se ha ido reduciendo con el tiempo con la comercialización de sensores cada vez más baratos y precisos que permiten de manera sencilla conocer en tiempo real las magnitudes clave para conocer el funcionamiento de los procesos productivos.

Sin embargo, existen ciertas medidas que sí son de vital importancia pero que resultan ciertamente complicadas de obtener, debido a diversos factores particulares de cada caso. El objetivo de este documento es intentar identificar estos procesos, las variables claves que se necesitaría conocer, y definir cómo se podría abordar la obtención de esas medidas a través de sensores virtuales, es decir, detallando los sensores que se instalarían que están directamente relacionados con esta magnitud para posteriormente estimar el valor real basándonos en estos.

“VIRTUAL SENSE” – Resumen de resultados.

## 2.1 DESCRIPCIÓN DE LOS PROCESOS PRIORITARIOS EN EL SECTOR DEL MUEBLE.

Los procesos principales en el sector del Mueble se indican en el siguiente gráfico.

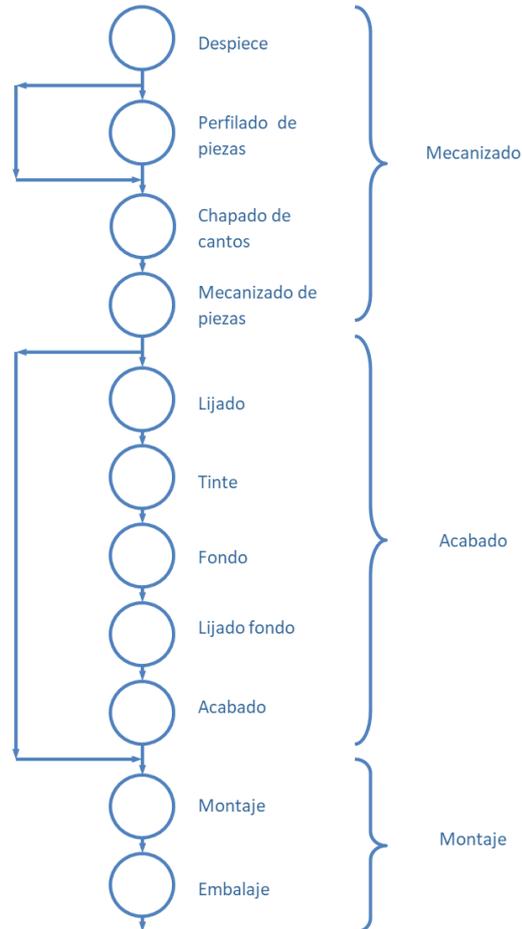


Diagrama de flujo global del proceso de fabricación de muebles. Fuente: elaboración propia AIDIMME.

De cada uno de estos procesos, además de la tecnología empleada, se ha identificado su flujo de valor, es decir las entradas y salidas relevantes del mismo, para identificar las mediciones implicadas en cada uno de ellos. Estos flujos de valor son los siguientes:

DESPIECE

Entradas al proceso	Salidas del proceso
<p><b>Tableros, caracterizados por:</b></p> <ul style="list-style-type: none"> <li>✓ Tipo de tablero (partículas, fibras, densidad, alistonados, atamborados, etc.)</li> <li>✓ Medidas (2440 x 1220, 2440 x 2050, 2440 x 3660, 2440 x 4880, etc.)</li> <li>✓ Grosos (16, 19, 22, 25, 30, 40, .....)</li> <li>✓ Recubrimiento. Existe una gran variedad diferentes de recubrimientos, ya sean naturales o sintéticos.</li> </ul>	<p>Piezas con las medidas requeridas.</p> <ul style="list-style-type: none"> <li>✓ Nº de piezas cortadas</li> <li>✓ Dimensiones de las piezas cortadas</li> </ul> <p>Retales de tablero</p> <ul style="list-style-type: none"> <li>✓ Dimensión de los retales generados</li> <li>✓ Cantidad de retales</li> </ul>

PERFILADO

Entradas al proceso	Salidas del proceso
<ul style="list-style-type: none"> <li>✓ Piezas cortadas con una medida en bruto. Medida superior a la medida de la pieza final.</li> <li>✓ Listado de piezas a perfilar, donde se indica: <ul style="list-style-type: none"> <li>○ Dimensiones de las piezas a obtener</li> <li>○ Ancho</li> <li>○ Largo</li> <li>○ Grosor</li> <li>○ Cantidad de piezas.</li> <li>○ Tipo de perfilado (perfil a obtener) esto depende de la forma de la herramienta que esté instalada en la máquina.</li> </ul> </li> </ul>	<ul style="list-style-type: none"> <li>✓ Piezas con dos cantos perfilados</li> <li>✓ Piezas con los cuatros cantos perfilados</li> </ul>

CHAPADO

Entradas al proceso	Salidas del proceso
<ul style="list-style-type: none"> <li>✓ El material de entrada al proceso son piezas escuadradas con la media justa, en el caso de contar con dispositivos de perfilado, la pieza puede entrar con una</li> </ul>	<ul style="list-style-type: none"> <li>✓ Piezas con algún canto chapado, pero que requieren de más pasadas. En este caso la pieza se debe considerar como “en curso”, pendiente de finalizar.</li> </ul>

“VIRTUAL SENSE” – Resumen de resultados.

- sobre medida.
- ✓ **Material de canto necesario para recubrir los lados establecidos.**
  - ✓ **Material adhesivo, en función del tipo de máquina con que se cuente se requerirá un tipo de adhesivo diferente.**

- ✓ Piezas con los cantos chapados, según diseño de producto. En este caso se considera que la operación de chapado se encuentra finalizada.

#### MECANIZADO/FRESADO

Entradas al proceso
<ul style="list-style-type: none"> <li>✓ <b>Piezas escuadradas con la media justa, con los cantos correspondientes chapados.</b></li> <li>✓ <b>Piezas de madera precortadas que requieren de ser cortadas a medida y /o mecanizadas.</b></li> </ul>

#### Salidas del proceso

- ✓ Piezas mecanizadas según diseño

#### LIJADO

Entradas al proceso
<ul style="list-style-type: none"> <li>✓ <b>Piezas mecanizadas.</b></li> <li>✓ <b>Piezas con aplicaciones previas de material sellante o fondo.</b></li> </ul>

#### Salidas del proceso

- ✓ Piezas lijadas.

#### APLICACIÓN DE FONDO/ACABADO

Entradas al proceso
<ul style="list-style-type: none"> <li>✓ <b>Piezas que han pasado por procesos posteriores de lijado.</b></li> </ul>

#### Salidas del proceso

- ✓ Piezas con producto de acabado depositado.

#### MONTAJE

Entradas al proceso
<ul style="list-style-type: none"> <li>✓ <b>Piezas acabadas.</b></li> <li>✓ <b>Herrajes, mechones y otros elementos de unión.</b></li> </ul>

#### Salidas del proceso

- ✓ Módulos y mueble acabado ya montado.

“VIRTUAL SENSE” – Resumen de resultados.

- ✓ **Adhesivo.**
- ✓ **Tiradores y embellecedores.**

EMBALAJE

Entradas al proceso	Salidas del proceso
<ul style="list-style-type: none"> <li>✓ <b>Mueble acabado</b></li> <li>✓ <b>Conjunto de piezas y herrajes que dan forma a un mueble.</b></li> </ul>	<ul style="list-style-type: none"> <li>✓ Paquetes de expedición.</li> </ul>

## 2.2 DESCRIPCIÓN DE LOS PROCESOS PRIORITARIOS EN EL SECTOR METAL

Las técnicas de fabricación más usuales, se clasifican en dos grupos:

1. Fabricación por moldeo, también llamado procedimiento de conformación sin pérdida de material, ya que a lo largo de los procesos no se desperdicia ni se pierde parte alguna del material con el que se trabaja.
2. Procedimiento de fabricación por separación y corte, también llamado procedimiento de conformación con pérdida de material, ya que a lo largo de los procesos se desperdicia o pierde alguna parte del material con el que se trabaja.

Para conocer los procesos estándar que intervienen en la fabricación metálica se va a realizar una revisión con una breve descripción de los distintos procesos que podemos encontrarnos.

### 2.2.1 PROCEDIMIENTOS DE CONFORMACIÓN SIN PÉRDIDA DE MATERIAL

#### Fusión y Moldeo

Consiste en el conformado de metales y aleaciones consistentes en la preparación de un molde con la forma de la pieza, en el cual se vierte el material fundido, dejándolo enfriar hasta su completa solidificación.

Los procesos de moldeo se diferencian según la naturaleza del molde y el método de vertido. De esta forma, según la naturaleza del molde se distinguen: de molde permanente (de hierro colado, acero o grafito) o de molde perdido (arena y arcilla); y según el método de vertido, puede ser por gravedad o por presión.

“VIRTUAL SENSE” – Resumen de resultados.

La elección de un método u otro depende de la complejidad de la pieza, grado de tolerancia respecto a las medidas establecidas, número de piezas a fabricar, coste del molde, acabado.

- Moldeo por gravedad: Este se realiza vertiendo el metal fundido sobre un molde, de manera que éste se desplace por su propio peso. Se utiliza principalmente para fabricar piezas de fundición de acero, bronce, latón y distintas aleaciones de aluminio. Existen distintas técnicas: en arena, en coquilla y a la cera perdida.
- 
- Moldeo por presión: Se lleva a cabo introduciendo el material fundido en el interior del molde forzando la entrada en el mismo. En este método se emplean moldes permanentes. Se distinguen varios procesos por la forma en la que se ejerce presión, pudiendo generarse por fuerza centrífuga o por inyección. En el moldeo por fuerza centrífuga, el molde gira alrededor de un eje que puede ser horizontal o vertical, con lo que la fuerza centrífuga obliga al metal fundido a rellenar todas las cavidades del mismo. Se emplea fundamentalmente para piezas de revolución, presentando además, la ventaja de que pueden obtenerse piezas de menor espesor que las que se obtienen por gravedad.

El moldeo por inyección, es el moldeo a presión propiamente dicho. El metal se inyecta en el molde por medio de una máquina. La inyección puede hacerse por medio de un émbolo o usando aire comprimido. Este método presenta la ventaja de que pueden fabricarse piezas de formas complicadas de una manera bastante económica y de gran precisión. Además, las piezas resultan limpias y sin defectos.

## 2.2.2 PROCESOS DE CONFORMACIÓN POR DEFORMACIÓN

La conformación por deformación se produce por la modificación permanente de la forma de un sólido aplicando, mediante herramientas y útiles apropiados, tensiones superiores al límite elástico del material, a temperaturas inferiores a la de fusión.

Podemos diferenciar entre procesos de deformación en caliente y procesos de deformación en frío.

### **Deformación en caliente:**

Forja: La forja es el procedimiento por el que se da forma a los metales mediante golpes, generalmente con el material a alta temperatura. Mediante este procedimiento se mejora considerablemente las propiedades mecánicas del material y puede realizarse de forma manual o automáticamente.

Laminación: Consiste en dar sucesivas pasadas al material entre unos rodillos, a partir de lingotes hasta obtener la chapa del espesor o el perfil de la forma requerida.

“VIRTUAL SENSE” – Resumen de resultados.

Extrusión: la extrusión, consiste en hacer fluir un material a través del orificio de una matriz, con una sustancial reducción de sección, mediante algún sistema que le transmita gran cantidad de energía en poco tiempo. Esta técnica nos permite conseguir buenos acabados superficiales y tolerancias, altas resistencias mecánicas y obtener perfiles de geometría compleja.

Estampación en caliente: Consiste en someter, por medio de una prensa o un martinete, a un esfuerzo de compresión a un metal, entre dos moldes de acero que se desplazan uno contra otro, denominados estampas.

### 2.2.3 PROCESOS DE DEFORMACIÓN EN FRÍO

Estampación en frío: este proceso se realiza con el material por debajo de la temperatura de recristalización. Esta estampación, a diferencia que la estampación en caliente, se aplica a la obtención de piezas de menor espesor, generalmente chapas o láminas de espesor uniforme.

Al ser un proceso de trabajo en frío, el tamaño y geometría de las piezas que se pueden fabricar están limitados.

Embutición: es un proceso de transformación que consiste en la obtención de piezas huecas partiendo de chapas de metal. Mediante este proceso se pueden obtener piezas de diversas formas.

Doblado y curvado: son operaciones de deformación plástica para dar forma a chapas de metal aplicando fuerzas de cierta intensidad para provocar la deformación de la chapa de forma permanente. Para ello se emplean prensas con matriz.

Estirado y Trefilado: es un proceso de deformación plástica que consiste en estirar una barra o varilla metálica. Para ello, se utiliza una matriz de un material metálico muy duro a través de la cual se hacen pasar los materiales. Se realiza principalmente para calibrar o endurecer con la deformación.

Por su parte el trefilado consiste en reducir la sección de barras o alambres, pasándolos mediante tracción a través de orificios calibrados denominados mandriles en operaciones sucesivas.

### 2.2.4 PROCEDIMIENTO DE CONFORMACIÓN CON PÉRDIDA DE MATERIAL. CONFORMACIÓN POR SEPARACIÓN Y CORTE

En esta categoría encontramos aquellos procesos de fabricación con pérdida de material por separación o corte, consistentes en eliminar el material sobrante de una pieza inicial hasta transformarla en una pieza terminada con unas formas y dimensiones concretas. En los diferentes procesos el material sobrante, puede encontrarse en forma de virutas o recortes.

“VIRTUAL SENSE” – Resumen de resultados.

Cizallado: Este proceso consiste en el corte mecánico de metales en forma de chapa o plancha sin producción de viruta mediante el empleo de dos cuchillas rectas.

Punzonado o Troquelado: Son operaciones de cizallado, pero en estas el corte a realizar tienen forma determinada, mediante el empleo de un punzón o matriz. En el punzonado la pieza perforada es la pieza a producir y el recorte es desperdicio, mientras que en el proceso de troquelado la pieza se obtiene mediante el recorte.

Torneado: Es uno de los procesos de mecanizado de uso más común. Es el proceso mediante el cual, se obtienen piezas con forma de cilíndricas, cónicas o esféricas y se pueden realizar roscas en piezas. En los tornos la herramienta de corte se mueve de forma lineal mientras la pieza de trabajo gira.

Fresado: Al igual que torneado, es otro de los procesos de mecanizado más común. Consiste en mecanizar piezas mediante máquinas fresadora. Las fresadoras disponen de herramientas denominadas fresas que se mueven rotando con altas velocidades, las cuales mecanizan las superficies de piezas que se desplazan bajo las fresas.

## 2.2.5 PROCEDIMIENTO DE ACABADOS

Otros procesos que podemos encontrar en el sector de producción y transformación metálica son procesos relacionados con los acabados y tratamientos superficiales. Estos son operaciones que se realizan en las superficies con el fin de eliminar imperfecciones, protegerlas de corrosión o modificar el aspecto.

Para la eliminación de imperfecciones nos podemos encontrar con diferentes operaciones que pueden realizarse a los metales, como: Esmerilado, Desbarbado, Chorro de arena, Lijado, Limado, Abrillantado, Pulido, Bruñido, etc.

Dentro de las operaciones de protección contra la corrosión, encontramos operaciones como: Pasivado, Recubrimientos metálicos (Zincados, Niquelados, Cromados...) y no metálicos (Pinturas, Barnices, lacas, plásticos...)

## 2.3 IDENTIFICACIÓN DE CARENCIA DE DATOS

### 2.3.1 CALIDAD DE MECANIZADOS EN EL SECTOR MUEBLE.

En el sector del mobiliario el control calidad se puede establecer en 2 aspectos. Uno es el que correspondiente a la calidad de acabado de producto y el otro al montaje.

“VIRTUAL SENSE” – Resumen de resultados.

Si bien ambas características hacen referencia al mueble montado, ambas tienen su origen en la calidad individual de sus piezas.

La calidad de acabado a nivel piezas, es un parámetro que puede corregirse de forma individual mediante el control de calidad de las piezas, tras realizar las operaciones de acabado, por lo que la incidencia a nivel mueble montado siempre será menor y en muchas ocasiones son incidencias derivadas del almacenaje de las piezas o de la manipulación de estas en el proceso de montaje final.

Los errores de montaje de un mueble (descuadras, desajustes...), tienen relación directa con la mecanización de piezas. A diferencia que la calidad de pieza acabada, esta tiene mayor complejidad para poder ser comprobado a nivel de pieza y la rectificación suele pasar por la fabricación de nuevas piezas con el consiguiente coste y tiempo asociado a la producción que ello supondrá para la empresa.

Hay que tener en cuenta que hay una parte del sector del mobiliario en la que el montaje final no se realiza en fábrica, sino que el mueble se comercializa en formato kit, y el montaje lo realiza el cliente final. En estos casos y teniendo en cuenta el gran volumen de piezas en este tipo de fabricación, se hace imprescindible la correcta mecanización de las piezas.

Por todo ello, disponer un control de calidad en tiempo real de las piezas mecanizadas resulta de gran interés para todo el sector, especialmente para aquellos en los que se trabaja con grandes volúmenes de piezas.

Si bien existen medios de comprobación de la calidad, como los basados en visión artificial, etc. Estos implican la mecanización previa de las piezas para poder comprobarlas y dar conformidad a las mismas o bien desecharlas.

El planteamiento de un sensor que permita tener una valoración de calidad previos a la mecanización, implicaría una reducción significativa con respecto a tiempos y costes de producción, evitando los desperdicios por no conformidad, de piezas.

### **2.3.2 DESGASTE DE CONSUMIBLES EN OPERACIÓN DE LIJADO**

El proceso de lijado existe en gran parte de la industria, ya que es un proceso recurrente para eliminar las irregularidades de las superficies, así como para prepararlas para etapas posteriores de manufactura como el barnizado o la pintura. Así mismo para conseguir un nivel de calidad adecuado en el proceso de barnizado/pintado es necesario realizar un lijado entre las diferentes capas de barniz/pintura aplicadas.

Tanto en procesos manuales como automáticos, las lijas deben cambiarse con cierta frecuencia, ya que su propio uso las desgasta y hace que queden inservibles.

En los procesos de lijado manual, la detección del momento en el que la lija no está proporcionando los resultados esperados es muy rápida debido a que existe un operario que realiza y supervisa directamente el proceso.

“VIRTUAL SENSE” – Resumen de resultados.

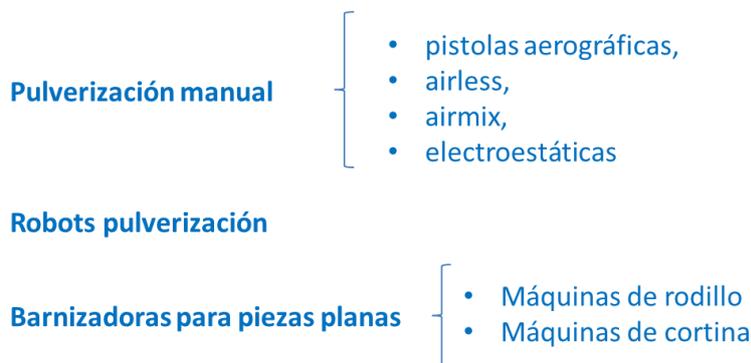
En el lijado automático, por el contrario, el operario no puede realizar una inspección visual del estado de la banda de lija, debido estas van instaladas en el interior de la máquina, por lo que controlar el momento en el que es necesario cambiar la lija resulta muy complicado y solo es posible al comprobar piezas ya procesadas. Dado que este tipo de instalaciones tienen un ritmo de producción elevado, no resulta sencillo realizar el control de calidad en línea de las piezas.

El objetivo en este caso es crear un sensor virtual, que mediante sensores reales fáciles de instalar, permita extrapolar el estado de la lija utilizando otras magnitudes tomadas directamente por sensores.

Disponer de datos sobre el desgaste en tiempo real de una lija, permitirá detectar con antelación el fin de la vida útil de la misma y poder sustituirla, antes de que aparezcan piezas no conformes en la producción, reduciendo así los tiempos de fabricación totales y los costes derivados del reprocesado de piezas.

### 2.3.3 CANTIDAD DE MATERIAL APLICADO EN LOS PROCESOS DE ACABADO Y CONTROL DE LA VISCOSIDAD DEL MATERIAL.

En las operaciones de acabado pueden aplicarse tanto materiales de fondo, lacados de color o barnices. Estos procesos de acabado pueden realizarse con diversos sistemas. Entre los sistemas de aplicación de productos para el acabado de piezas para la fabricación de mobiliario podemos encontrarlos los que se muestran en el siguiente esquema:



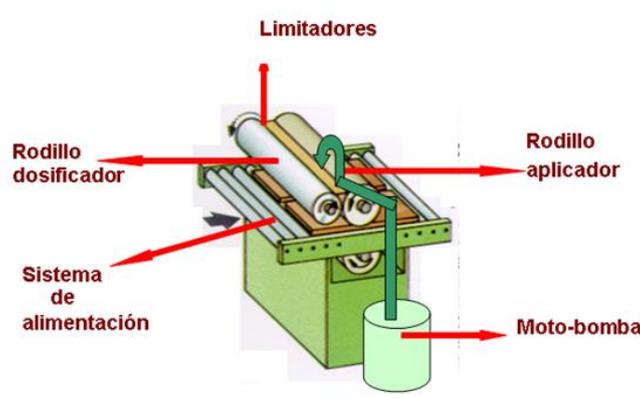
*Sistemas de aplicación de productos de acabado. Fuente: elaboración propia AIDIMME.*

La elección de los sistemas de aplicación dependerá de la forma y tamaño de las piezas a terminar y del tipo de productos a utilizar. Pero en todos ellos el gramaje aplicado es una variable que debe ser controlada. Éste gramaje aplicado depende de múltiples variables que tienen gran influencia en el resultado del gramaje total aplicado.

En los sistemas de aplicación manuales, los parámetros que influyen en el cálculo del gramaje total aplicado, son variables que dependen de la acción humana del trabajador y pueden ser corregidas inmediatamente por el mismo, en base a su experiencia y entrenamiento. Por tanto, no se plantea la definición de sensores virtuales para éste tipo de aplicaciones.

“VIRTUAL SENSE” – Resumen de resultados.

Se considera que en sistemas automatizados como la aplicación de barniz por sistemas de rodillos o cortina, con menor dependencia de acciones manuales por parte del trabajador, cobra más importancia la automatización del cálculo del gramaje aplicado.



*Sistema de aplicación por máquina de rodillos. Fuente: AIDIMME.*

El objetivo sería definir un sensor virtual que calcule el gramaje aplicado en función de las múltiples variables de entrada cuantificables mediante sensores simples.

De la necesidad de cuantificar esas variables de entrada se desprende la necesidad de generar otro nivel de sensor virtual para poder cuantificar una de las variables de entrada de mayor incidencia en el gramaje de material de acabado aplicado.

Esta variable es la viscosidad de los productos de acabado. Este es un parámetro común a todos los productos de acabado y tiene gran incidencia en el resultado final de la aplicación del mismo.

La viscosidad del producto se debe ajustar a los valores indicados por el fabricante y adaptarla al equipo de aplicación a emplear. Se debe mantener constante durante el proceso de aplicación, pero puede verse afectada por factores como la temperatura ambiente, lo que hace necesario corregir la mezcla para mantener el valor de viscosidad.

Disponer de datos de la viscosidad de una mezcla permitirá mantener las condiciones óptimas de la misma que conjuntamente al cálculo del gramaje del material de acabado aplicado, permitirá evitar problemas en la aplicación y en los acabados de las piezas, antes de que estos se produzcan obligando a repetir los procesos.

### 2.3.4 CONCENTRACIÓN DE ACEITE EN EMULSIONES ACEITES-AGUA EN EL SECTOR METAL

En los procesos de transformación metálica, y más concretamente en los procesos de mecanizado el aceite de lubricación, es un elemento clave para garantizar la correcta ejecución del proceso. Su función es la de lubricar y refrigerar la pieza que se está procesando y la herramienta de corte durante el mecanizado.

“VIRTUAL SENSE” – Resumen de resultados.

El aceite de lubricación (también conocido como taladrina), se genera a partir de una emulsión de aceite de lubricación y agua osmotizada, cuya concentración debe mantenerse constante para garantizar la función de lubricación. Esta concentración debe mantenerse en el rango de 5-7% de aceite.

Con el paso del tiempo, la concentración del aceite aumenta principalmente por evaporación del agua, y el circuito pierde volumen por pérdidas que quedan en la viruta y piezas finales. Si la concentración de la taladrina no es la correcta se producen problemas de dos tipos:

- Desgaste excesivo de la herramienta de corte.
- Futuros problemas de corrosión en la pieza.

Para medir el nivel de concentración del aceite en agua se utilizan instrumentos de medida analógicos como el refractómetro. Para llevar a cabo la medición se toma una muestra del aceite de lubricación del depósito de la máquina, se deposita una gota en el equipo de medición y mediante una escala visible en el equipo se calcula la concentración.



Ejemplo de refractómetro empleado en el sector. Fuente: [www.amazon.es](http://www.amazon.es)

Éste tipo de mediciones se llevan a cabo de forma manual y puntual (como mucho una vez por turno de fabricación), y no existe una forma de automatizar la medición ni obtener datos en tiempo real que permita anticipar problemas durante un turno de trabajo.

### 2.3.5 GRAMAJE DE FOSFATO Y POLÍMERO EN BAÑOS DEL SECTOR METAL.

Dentro de los procesos de acabado en fabricación de productos metálicos, los baños químicos son habituales para dotar de protección al metal frente a la corrosión, así como para mejorar sus características superficiales.

“VIRTUAL SENSE” – Resumen de resultados.

Dentro de éste proceso de baños, controlar el gramaje depositado de productos como el fosfato y el polímero resulta clave para determinar si el proceso ha sido adecuado o no. En función del tipo de proceso, el grosos objetivo de las capas pueden variar, pero de forma general, el objetivo es obtener una capa de polímero 1’5-3 gr/cm<sup>2</sup>, y una capa de fosfato de 6-12 gr/cm<sup>2</sup>.

El proceso se inicia con un lavado de la bobina de alambón. A continuación pasa por diferentes tanques de decapado, cada uno con diferentes concentraciones de ácido clorhídrico (HCl). Tras otra etapa de lavado, pasa por un tanque de afinado. A continuación, se pasa por tanques de fosfatado, lavado, neutralizado y polímero, para terminar con un secado.



Ejemplo de bobina de alambón al final de un proceso de baños. Fuente: Kamax

Estas actividades pueden estar monitorizadas mediante sistemas tipo SCADA donde se controlen y registren diferentes parámetros de producción como: temperatura de cada etapa de baños, velocidades y otros parámetros de máquina. Sin embargo, el gramaje final depositado (objetivo final del proceso) se mide de forma manual y puntual mediante equipamiento de laboratorio a partir de muestras tomadas en el proceso.

Si el objetivo de gramaje depositado no se cumple hay que reprocesar toda la bobina, ya que el material no es apto para pasar a sección de mecanizado.

Por tanto, el objetivo es diseñar un sensor virtual que permita disponer en tiempo real del valor de gramaje depositado en el metal, tanto de capa de fosfato, como de capa de polímero.

## 2.4 REQUISITOS FUNCIONALES DE LOS SENSORES VIRTUALES

### 2.4.1 REQUISITOS PARA SENSOR VIRTUAL DE VALORACIÓN DE CALIDAD DE MECANIZADOS.

A pesar de existir diferentes máquinas para la realización de mecanizados, los centros de mecanizado CNC, son los más extendidos en la industria y los que permiten fabricación de mayor tamaño de lote, por ello son los elegidos para la descripción de requisitos.

Hay que diferenciar entre los centros de mecanizado tradicionales y los centros de mecanizado nesting, ya que estos últimos realizan no solo la mecanización, sino también el corte de piezas. Estas realizan el corte mediante fresado, por lo que los errores de mecanizado en este tipo de centros son menores.

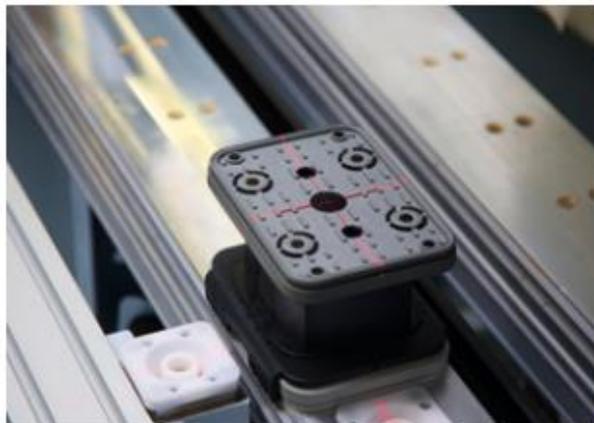
Para la correcta realización de mecanizados en el control numérico existen diversos factores que influyen en el posicionamiento de los mismos. Los parámetros más importantes de una pieza que se pueden medir:

- Dimensiones de la pieza (largo, ancho)
- Escuadrado de pieza

Estos valores son básicos para un perfecto mecanizado de pieza. Ya que si cualquiera de estos falla la mecanización no será correcta. Para la medición de ambos parámetros de forma automática pueden emplearse sensores ópticos de perfiles y/o palpadores.

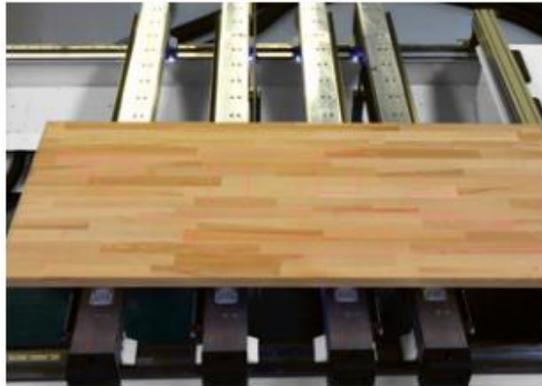
Aparte de los parámetros de la pieza a mecanizar, como variables externas que pueden condicionar la posición de los mecanizados se encuentran las siguientes:

- Posicionamiento de Pieza en cuna CNC
- Sujeción de la pieza



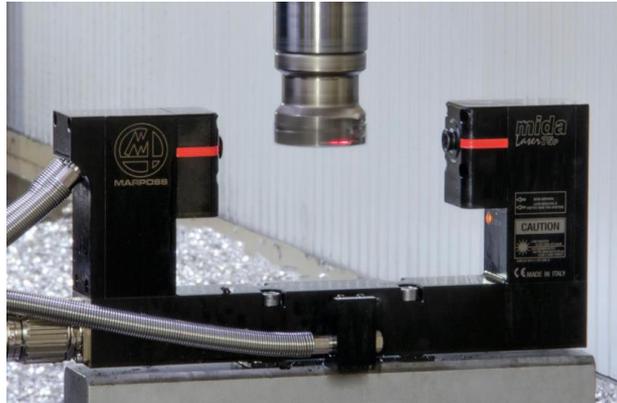
Aspiración con asistente de posicionamiento laser. Fuente: Schmalz

“VIRTUAL SENSE” – Resumen de resultados.



Posicionamiento medios sujeción mediante proyección laser. Fuente: Lap-laser.

- Error de posicionamiento del CNC (0,0 maquina)
- Estado de la herramienta de mecanizado.



Comprobación de herramienta mediante laser. Fuente: Marposs.

## 2.4.2 REQUISITOS PARA SENSOR VIRTUAL PARA CICLO DE VIDA DE LIJAS.

Para medir en tiempo real el estado exacto de la lija, de forma que indique exactamente cuándo realizar el cambio, justo antes de producir piezas defectuosas, es necesario crear un sensor virtual, ya que no existe ningún sensor que permita dicha monitorización.

El objetivo en este caso es crear un sensor virtual, que mediante sensores reales fáciles de instalar, permita extrapolar el estado de la lija utilizando otras magnitudes tomadas directamente por sensores. En particular se identifica necesaria la medición de las siguientes variables:

- Temperatura de la lija.
- Vibración.
- Velocidad de lijado.
- Intensidad eléctrica.

“VIRTUAL SENSE” – Resumen de resultados.

- Presión.
- Velocidad de la línea.
- Datos manuales.

### 2.4.3 REQUISITOS PARA SENSOR VIRTUAL DE GRAMAJE APLICADO DE MATERIAL DE ACABADO Y VISCOSIDAD REAL.

Para obtener el gramaje de material de acabado aplicado a piezas planas mediante máquinas de rodillo hay que tener en cuenta el funcionamiento y elementos que constituyen dichas maquinas, ya que con cada uno de ellos se controlan variables que tienen incidencia directa en el acabado final de las piezas.



Sistema de aplicación de rodillos. Fuente: Laboratorio AIDIMME.

Los parámetros según los que se obtendrán diferentes gramajes aplicados a piezas y que son necesarios controlar y registrar para poder estimar dicho gramaje, son los que se enumeran a continuación:

- Velocidad de avance del rodillo aplicador
- Dureza del material del rodillo aplicador
- Grado de acabado en los rodillos de caucho
- Sentido de giro del rodillo dosificador
- El espesor de paso de pieza

El gramaje aplicado depende de las variables identificadas anteriormente. De estas las variables de mayor relevancia son la velocidad del rodillo aplicador (y su sincronía con la velocidad del tapiz) y el espesor de la pieza. Estas pueden ser sensorizadas mediante sensores simples instalados para tal efecto en las maquinas.

Por otro lado existen algunas variables son de difícil digitalización, pero suelen ser constantes largos periodos de tiempo, pues son decisiones de largo plazo al diseñar el proceso de fabricación como son la dureza del rodillo aplicador y el grado de acabado del rodillo.

“VIRTUAL SENSE” – Resumen de resultados.

Además de los parámetros anteriores la viscosidad del barniz es otra variable de influencia sobre el gramaje del material aplicado. En ese caso existen sensores para obtener el valores de la viscosidad pero al tratarse de sensores de alto coste son inviables para sistemas de producción como los que no encontramos. Por ello se ha planteado la creación de un nivel anterior de sensor virtual que permita la estimación de esta.

Para ello será necesario emplear los datos de viscosidad teórica así como una serie de datos reales de la viscosidad a diferentes temperaturas para los distintos materiales a fin de obtener la viscosidad en tiempo real de cualquier producto.

#### **2.4.4 REQUISITOS PARA SENSOR VIRTUAL DE MEDIR CONCENTRACIÓN DEL ACEITE EN TALADRINA.**

Para poder obtener una medida en tiempo real de la concentración de aceite en la emulsión lubricante de aceite- agua es necesario controlar distintas variables que tienen incidencia directa sobre la concentración de aceite.

Las principales variables a analizar son:

- Tipo de máquina.
- Material
- Fecha de relleno
- Concentración adicionada
- Concentración previa
- Volumen de emulsión
- Tiempo de trabajo.
- Temperatura de la mezcla
- Temperatura ambiente
- Humedad relativa

Algunas de las variables identificadas son de difícil digitalización y requerirán de un registro realizado in situ, para su posterior integración en los algoritmos de cálculo de la variable deseada.

#### **2.5 REQUISITOS PARA SENSOR VIRTUAL DE MEDIR GRAMAJE DEPOSITADO DE FOSFATO Y POLÍMERO.**

Para poder obtener una medida en tiempo real del gramaje depositado de fosfato y de polímero es necesario controlar distintas variables que tienen incidencia directa ambos.

Las principales variables a analizar para el gramaje de fosfato son:

- Puntos de fosfato.
- Temperatura.
- Contenido en Fe.

“VIRTUAL SENSE” – Resumen de resultados.

Se ha identificado que para el cálculo de gramajes de polímero, los parámetros de mayor relevancia son:

- Residuo seco.
- pH.
- Temperatura.

### 3 DISEÑO Y DESARROLLO DE SENSORES

El objetivo de este paquete de trabajo es el diseño y desarrollo de sensores virtuales, adaptados a las necesidades de los procesos industriales analizados en el PT4, que permitan medir los datos relevantes para la correcta gestión del proceso en cuestión.

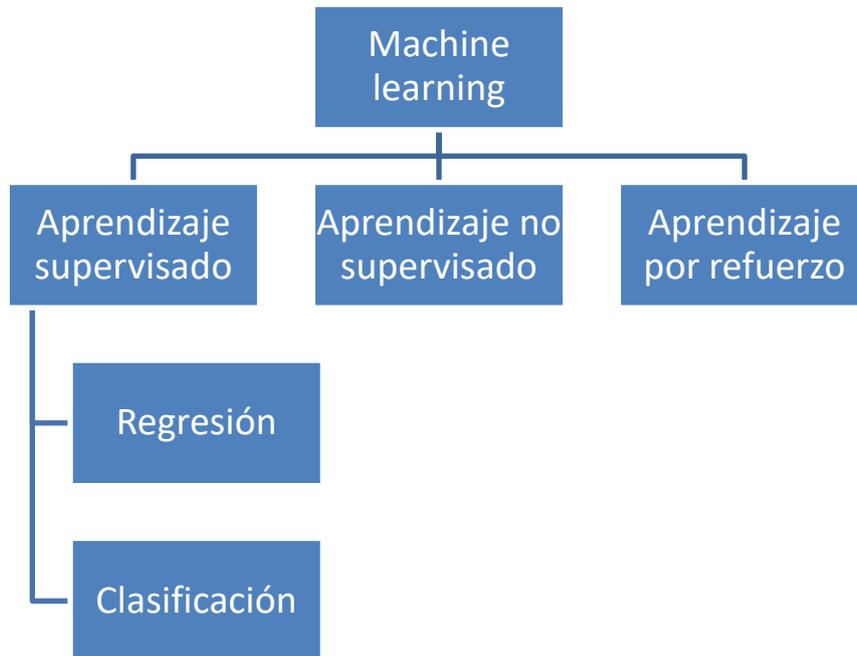
#### 3.1 SELECCIÓN DE MODELOS DE CÁLCULO

En primer lugar se han explorado los distintos modelos de cálculo existentes para solucionar el problema planteado como objetivo de este proyecto. Al tratarse de sensores virtuales, teóricamente podríamos encontrar 2 posibilidades distintas:

- Sensores discretos: muestran únicamente un valor dentro de un conjunto de posibilidades definidas. Un ejemplo de este tipo de sensor virtual sería uno que informara de la posición de determinada pieza en una máquina dado que esta solo puede estar en un número determinado de posiciones.
- Sensores continuos: aquellos que muestran un valor numérico continuo. Son el ejemplar más común, puede ser por ejemplo un sensor de temperatura, presión o humedad, que arrojan la medición continua de una magnitud.

Es importante realizar esta distinción antes seleccionar un modelo de cálculo y conocer el campo del aprendizaje automático tal como se presenta en la siguiente imagen:

“VIRTUAL SENSE” – Resumen de resultados.



En ambos tipos de sensores, el aprendizaje será supervisado pues se va a trabajar con datos etiquetados de forma que el objetivo es entrenar un modelo que sea capaz de obtener las etiquetas de nuevos datos que no le hayan sido mostrados nunca. Sin embargo, la aproximación será diferente dependiendo del tipo de sensor que vayamos a utilizar. Para los sensores discretos, utilizaremos algoritmos de clasificación ya que intentamos predecir una clase dentro de un conjunto limitado. Por otra parte para los sensores continuos, al intentar obtener un modelo que prediga una cantidad, utilizaremos modelos de regresión.

En este proyecto únicamente se van desarrollar sensores virtuales continuos, es por eso que se deberán utilizar modelos de aprendizaje por refuerzo de regresión.

Se han evaluado diversas técnicas matemáticas:

- Regresión por descenso de gradiente.
- Regresión mediante árboles y bosques
- Regresión mediante redes neuronales
- Máquinas de vectores soporte

### 3.1.1 MODELOS SELECCIONADOS

Todos los modelos evaluados aplican de manera correcta para el problema a solucionar.

Cabe apuntar que el objetivo de este apartado es identificar metodologías que nos permitan deducir razonadamente cuál de los algoritmos de nuestra caja de herramientas da mejor resultado en los problemas específicos que estamos solucionando. Es decir, necesitamos un método fiable de comparación que nos permita realizar un baremo de qué algoritmos han

“VIRTUAL SENSE” – Resumen de resultados.

funcionado mejor con el conjunto de datos. Se ha optado por el método descrito a continuación.

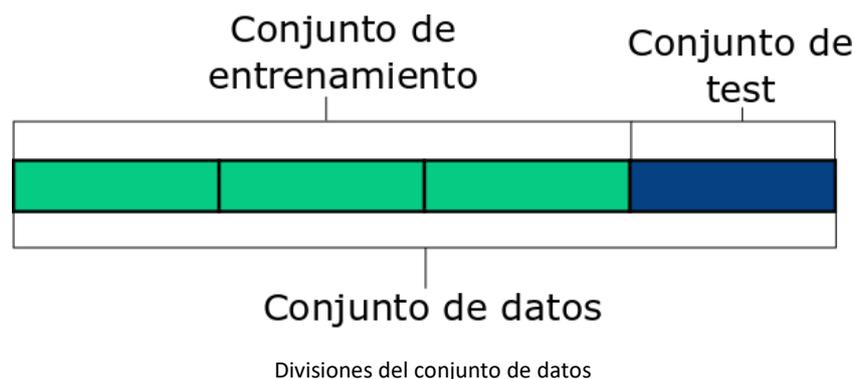
### 3.1.2 DIVISIÓN DEL CONJUNTO DE DATOS Y VALIDACIÓN CRUZADA

Seguidamente se explica por qué es útil dividir el conjunto de datos en subconjuntos y cómo esto se aplica para generar un método de medición del desempeño de los modelos utilizando la validación cruzada o *Cross validation*.

Con el objetivo de encontrar la configuración que mejor se adapte a los datos de entrenamiento, todos los modelos deben pasar por un proceso conocido como entrenamiento. Al final del proceso de entrenamiento, se obtendrá el modelo con los parámetros que ofrezcan un resultado lo más parecido posible a los datos con los que se ha entrenado.

Cabe ahora la cuestión de con qué datos se deben entrenar los modelos. La solución más directa es la de entrenar con todos los datos disponibles, sin embargo, esto provoca un problema, ya que una vez entrenado el modelo, debemos testear su funcionamiento, si utilizamos todos los datos disponibles, no tenemos más opción que comprobar el desempeño del modelo generado sobre estos mismos datos, lo que nos quita la posibilidad de conocer el funcionamiento con datos nuevos que el modelo no había visto nunca.

Es por esto que los modelos no se entrenan nunca con la totalidad de los datos, sino que se hacen varias divisiones de estos. Existen distintas formas de realizar estas divisiones. En este caso vamos a presentar una de las más simples a la vez más útiles: dividiremos nuestro conjunto de datos en dos subconjuntos: uno de entrenamiento y otro de test. Un conjunto de proporciones que se suele utilizar en estos casos es 70% entrenamiento y 30% test o 75%-25% respectivamente. Este último modelo es el que se muestra en la imagen siguiente:



Sin embargo, una debilidad de utilizar el primer 75% para entrenar es que la elección de esta partición es arbitraria por lo que no tiene por qué ser la mejor para entrenar y el conjunto de test resultante no tiene por qué comportarse de manera correcta. Este problema se soluciona utilizando la validación cruzada o *Cross Validation*.

“VIRTUAL SENSE” – Resumen de resultados.

El sistema de validación cruzada realiza el comportamiento expresado en el siguiente pseudocódigo:

```
particiones = dividir_en_partes_iguales(dataset, n)
resultados = []
for partición in particiones:
    entrenamiento = particiones - partición
    test = particion
    modelo = ml.entrenar(entrenamiento)
    resultado_particion = modelo.testear(test)
    resultados.añadir(resultado_particion)
return resultados
```

Es decir, extrae una de las particiones y la guarda como test, el resto se utilizan para entrenar el modelo. Una vez concluidos el entrenamiento y el test, los resultados se añaden al conjunto de resultados y se repite el proceso eligiendo como test la siguiente partición y dejando el resto como entrenamiento. El proceso se repite hasta tener todas las posibilidades como test.

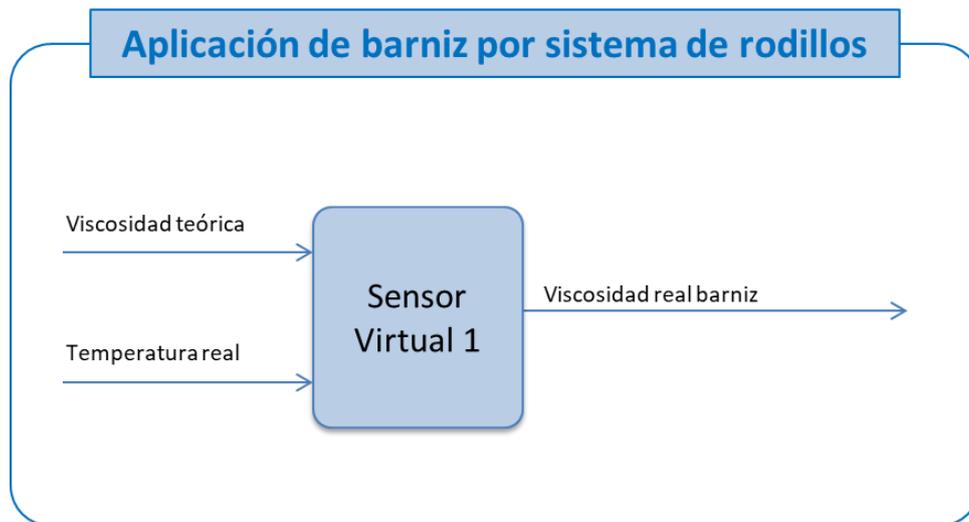
El número  $n$  que se envía a la función `dividir_en_partes_iguales` representa la cantidad de particiones que se van a crear. Este tipo de validación se llama *n-fold cross validation*, una de las validaciones más populares es *10-fold cross validation*, es decir, realizar 10 particiones, y es la que utilizaremos en este estudio. Cabe destacar que la elección del número de particiones es arbitrario y la decisión recae sobre el analista de datos, llegando al punto de existir la posibilidad de hacer tantas particiones como datos individuales haya, entrenando con el conjunto de datos casi completo y testeando solo con un dato, este tipo de validación cruzada se conoce como *leave one out cross validation*.

En este estudio se utilizará la validación cruzada para conocer cuál es el mejor de los modelos utilizados. Esto se traduce en que el sistema de elección de modelo se basará en un proceso iterativo en el que se prueba un modelo de aprendizaje supervisado para regresión y después se obtienen los resultados de la validación cruzada sobre el conjunto de datos. Una vez obtenidos los resultados de varios modelos se considerará mejor aquel que haya obtenido mejores resultado acumulados para la *cross validation*.

## 3.2 IDENTIFICACIÓN DE VARIABLES EN LOS SENSORES VIRTUALES SELECCIONADOS

### 3.2.1 SENSOR VIRTUAL 1: MEDIDA VISCOSIDAD DE BARNIZ.

La viscosidad es un parámetro muy importante que depende de la composición química del barniz y la temperatura del mismo en el momento de la aplicación. Se propone la definición de un primer sensor virtual para obtener un valor real de la viscosidad, en base a la viscosidad teórica definido por el fabricante del barniz en su ficha técnica (bajo condiciones estándar de laboratorio -23°C – 50%Hr) y la temperatura real en el momento de la aplicación.



*Posibles sensores virtuales en aplicación por sistema de rodillos.*

*Fuente: AIDIMME.*

Las variables identificadas como potencialmente relevantes para el cálculo de la viscosidad, pueden ser de dos tipos:

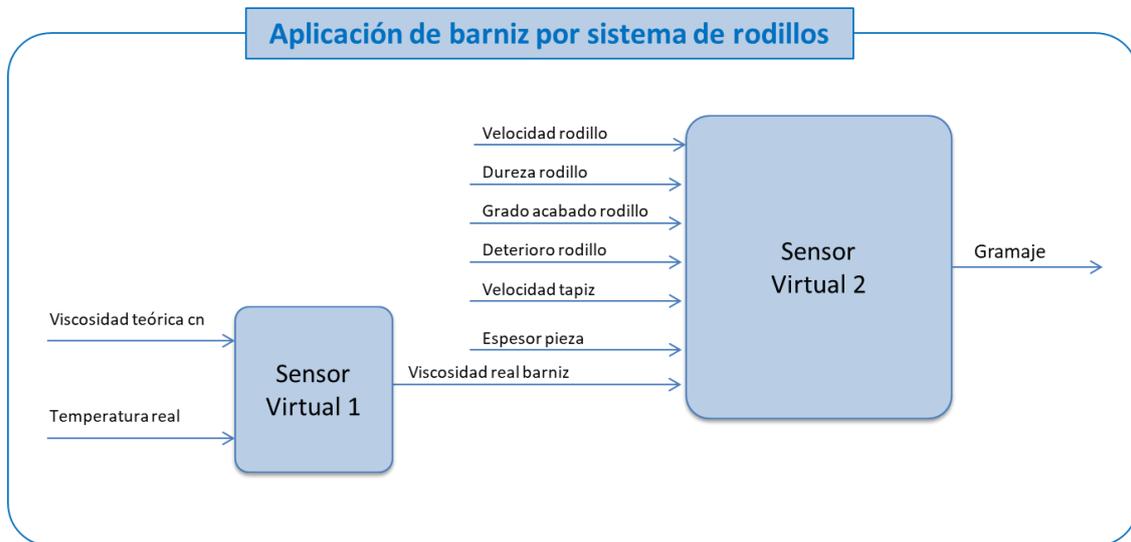
- Parámetros de registro manual. Se trata de datos que un operario tendrá que registrar de forma manual, y que cambian cada cierto tiempo: con el tipo de barniz a aplicar.
- Parámetros adquiridos mediante sensores. Se trata de datos para los que se estima posible adquirir e instalar un sensor que pueda dar una medida en tiempo real: temperatura del barniz.

### 3.2.2 SENSOR VIRTUAL 2: MEDIDA DEL GRAMAJE DE BARNIZ APLICADO.

Se plantea la posibilidad de definir un segundo sensor virtual que calcule el gramaje aplicado en función de las siguientes variables de entrada: velocidad, dureza, grado de acabado y deterioro del rodillo aplicador; velocidad del tapiz (en sincronía con la del rodillo aplicador); espesor de la pieza; y viscosidad del barniz aplicado.

“VIRTUAL SENSE” – Resumen de resultados.

La viscosidad del barniz se obtendrá a partir del output generado por el primer sensor virtual definido.



Posibles sensores virtuales en aplicación por sistema de rodillos.

Fuente: AIDIMME.

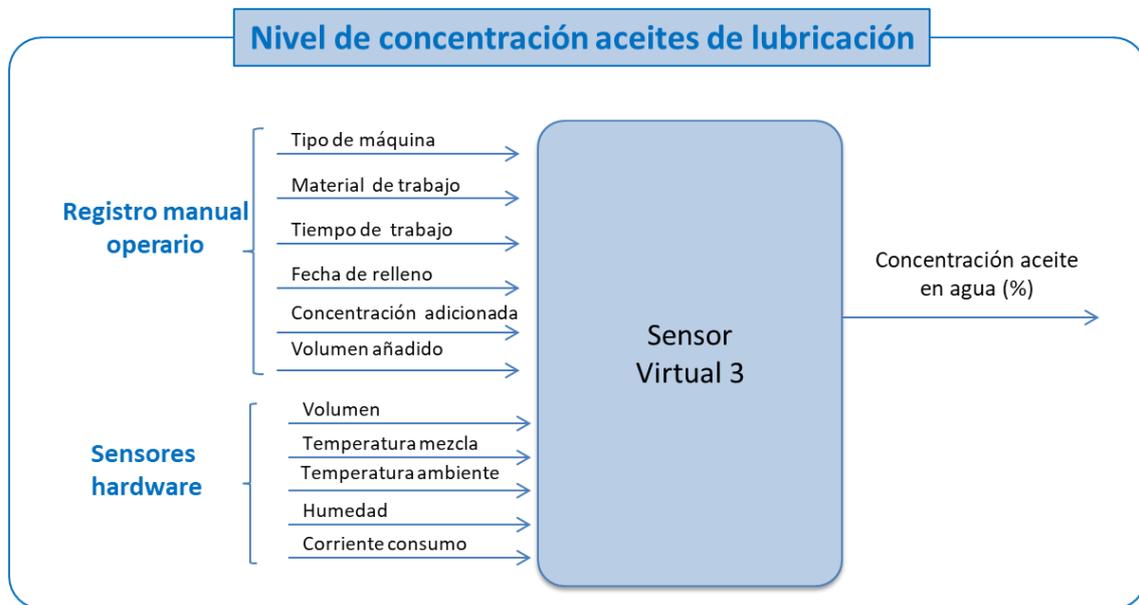
Las variables identificadas como potencialmente relevantes para el cálculo de la viscosidad, pueden ser de dos tipos:

- Parámetros de registro manual. Se trata de datos que un operario tendrá que registrar de forma manual, y que cambian cada cierto tiempo: dureza del rodillo, grado de acabado del rodillo.
- Parámetros adquiridos mediante sensores. Se trata de datos para los que se estima posible adquirir e instalar un sensor que pueda dar una medida en tiempo real: velocidad del rodillo, velocidad del tapiz, espesor de la pieza.

### 3.2.3 SENSOR VIRTUAL 3: MEDIDA DE LA CONCENTRACIÓN DE TALADRINA.

Según las variables identificadas, se propone diseñar y desarrollar un sensor virtual como el mostrado en la siguiente imagen, que permita realizar una estimación en tiempo real de la concentración del aceite en agua en función de las variables identificadas previamente.

“VIRTUAL SENSE” – Resumen de resultados.



*Possible sensor virtual en torno de decoletaje.*

*Fuente: AIDIMME.*

Las variables identificadas como potencialmente relevantes para el cálculo de la concentración, en el piloto a llevar a cabo en la empresa FACTOR se han clasificado en dos categorías:

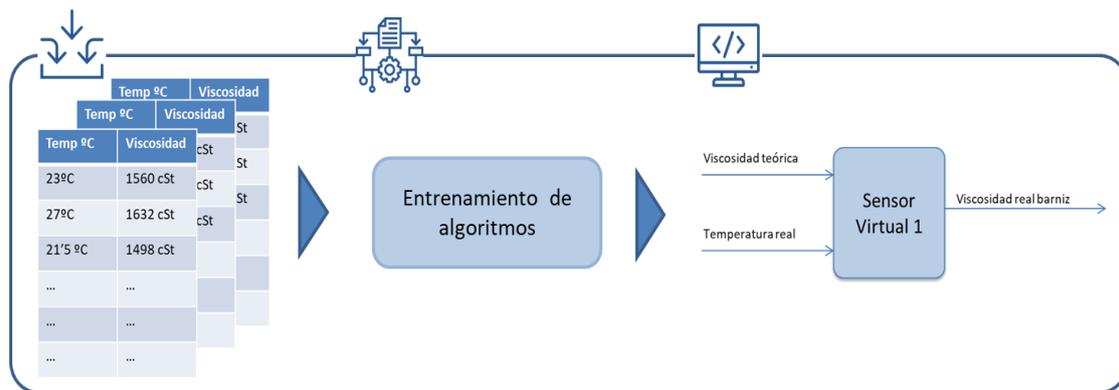
- Parámetros de registro manual. Se trata de datos que un operario tendrá que registrar de forma manual, y que cambian cada cierto tiempo: con el lote de fabricación, con una actividad de mantenimiento, etc.
- Parámetros adquiridos mediante sensores. Se trata de datos para los que se estima posible adquirir e instalar un sensor que pueda dar una medida en tiempo real: volumen de mezcla, temperatura mezcla, temperatura ambiente, humedad relativa.

### 3.3 DISEÑO Y DESARROLLO DE EXPERIMENTOS

#### 3.3.1 SENSOR VIRTUAL 1: MEDIDA DE VISCOSIDAD DE BARNIZ.

Para el desarrollo del sensor virtual 1 debe de generarse un dataset con medidas de viscosidad de diferentes tipos de barnices a diferentes temperaturas. Con ésta información se puede comenzar a entrenar diferentes algoritmos que den lugar a un modelo matemático final capaz de calcular la viscosidad real de un barniz en función de la temperatura a la que se encuentre.

“VIRTUAL SENSE” – Resumen de resultados.



Esquema general de obtención del sensor virtual 1.

Fuente: AIDIMME.

Para generar el dataset de datos de viscosidad de barnices en función de su temperatura se ha recurrido a dos fuentes de información.

Por un lado a la búsqueda bibliográfica de datos. Se ha identificado información de diferentes medidas de viscosidad en función de la temperatura generada por el fabricante de equipos de aplicación de pintura Kremlin (Kremlin, 1999). La información recopilada hace referencia a barnices utilizado para aplicación mediante pulverizado con pistola aerográfica, que suelen tener menor viscosidad de los barnices empelados para su aplicación mediante máquina de rodillos o un sistema de cortina

Por otro lado se han realizado ensayos de viscosidad cinemática propios, dado que no se ha identificado información disponible para barnices de aplicación mediante sistema de rodillos.

El ensayo consiste en registrar la temperatura del barniz, llenar una copa de vaciado normalizada (ASTM Ford, ASTM D4212, ISO 2431) y registrar el tiempo que tarda en vaciarse. En función de la copa normalizada escogida, la ecuación para transformar el tiempo de vaciado en centiStokes (unidad de medida de la viscosidad cinemática) difiere.

En las pruebas realizadas se planifica utilizar las copas ISO 2431 de diámetros  $\varnothing 6$  y  $\varnothing 8$ . De forma general se utiliza la copa de diámetro 8, por la elevada viscosidad de los barnices empleados, salvo cuando las mediciones obtenidas sean inferiores de los 30 segundos, donde se cambia a copa de diámetro 6.

Las ecuaciones para transformar el tiempo de vaciado a centiStokes son:

Tipo de copa	Ecuación viscosidad
ISO 2431 Nr 6	$v=6,900t-570/t$
ISO 2431 Nr 8	$v=21,78-306/t$

“VIRTUAL SENSE” – Resumen de resultados.

Cada barniz debe de acondicionarse previamente para lograr un rango de mediciones entre 5 – 40°C. Para ello, se recurre a un equipo de refrigeración (para bajar de temperatura ambiente) y una cámara climática (para aumentar la temperatura por encima de temperatura ambiente).

Tras acondicionar los productos mediante la nevera o la cámara climática, a las condiciones de temperatura deseada, estos se mezclarán meticulosamente para evitar las posibles deposiciones que se hayan podido realizar en el fondo y se extraerá una muestra del producto.

Inicialmente se realizará la toma de temperatura de la muestra, mediante una sonda de temperatura que se introducirá en dicha muestra.

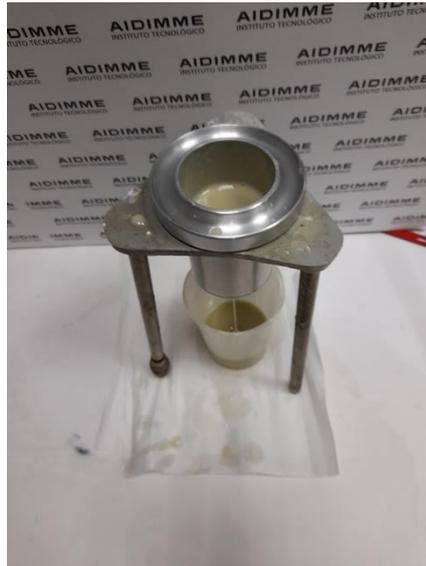


*Toma de temperatura de la muestra.*

*Fuente: AIDIMME.*

A continuación con dicha muestra se procederá a llenar la copa ISO 2431 enrasando el producto con el borde de la copa. Esto se realizará con la boquilla de la copa tapada para que no se salga el producto antes de iniciar el cálculo de la viscosidad.

“VIRTUAL SENSE” – Resumen de resultados.



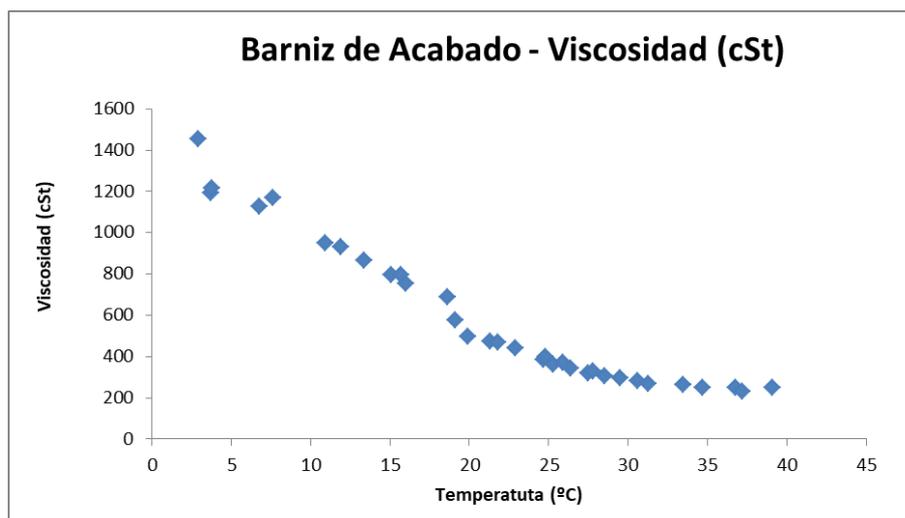
Toma datos de Viscosidad.

Fuente: AIDIMME.

El producto saldrá a través de la boquilla de la copa de forma que se formara un hilo de material. Este hilo debido a la viscosidad llegará a cortarse en un momento determinado.

El tiempo que transcurre desde el inicio hasta el corte del hilo de material, es el que tiempo a tomar para conocer la viscosidad del producto.

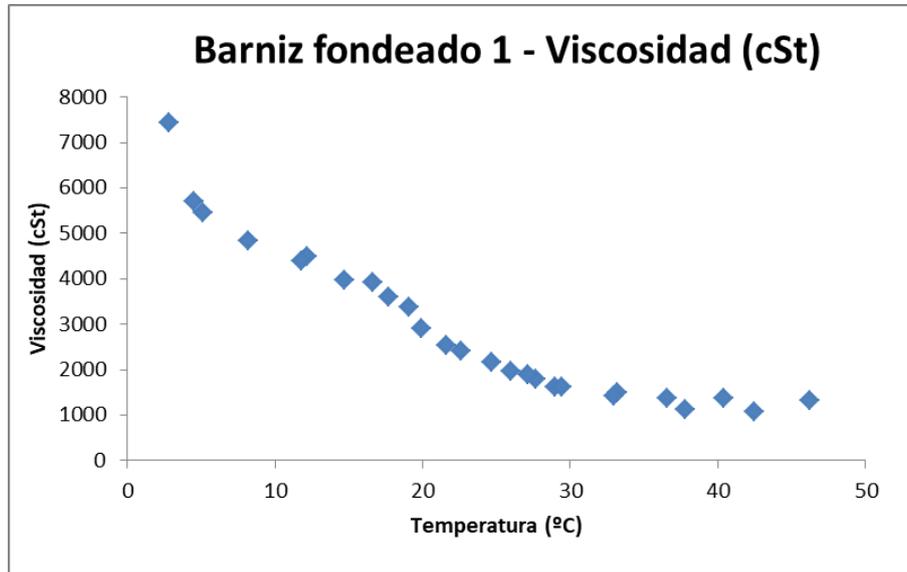
Para el caso de los tres barnices para los que se han llevado a cabo ensayos de viscosidad, se obtienen unas gráficas de tipo similar donde se aprecia una relación de tipo logarítmico.



Grafica de Viscosidad Cinemática para barniz de acabado

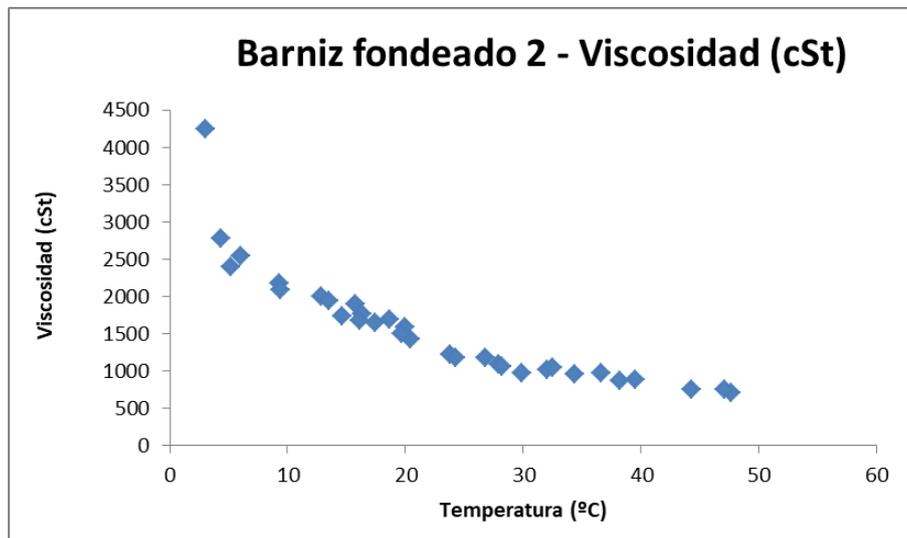
“VIRTUAL SENSE” – Resumen de resultados.

Fuente: AIDIMME.



Gráfica de Viscosidad Cinemática para barniz de fundeado 1

Fuente: AIDIMME.



Gráfica de Viscosidad Cinemática para barniz de fundeado 2

Fuente: AIDIMME.

“VIRTUAL SENSE” – Resumen de resultados.

### 3.3.2 SENSOR VIRTUAL 2: MEDIDA DE GRAMAJE DE BARNIZ APLICADO.

Para el desarrollo del sensor virtual 2 se emplea una máquina barnizadora de rodillos disponible de la marca Sorbini, instalada en planta piloto de AIDIMME



*Barnizadora de rodillos empelada.*

*Fuente: AIDIMME.*

Para éste sensor virtual 2 los parámetros a controlar son:

- Velocidades de rodillos aplicador y dosificador
- Distancia entre los rodillos
- Dureza del rodillo
- Grado de acabado del rodillo
- Deterioro del rodillo
- Velocidad del tapiz
- Espesor pieza
- Viscosidad barniz

En una misma máquina la dureza del rodillo aplicador es constante, así como el grado de acabado del mismo. El deterioro del rodillo es variable con el tiempo, pero su evolución es muy lenta en el tiempo.

Por tanto, las variables a considerar dentro del experimento para el desarrollo del sensor virtual son la velocidad del tapiz, la velocidad del rodillo aplicador, la velocidad del rodillo dosificador, la distancia entre rodillos, y la viscosidad del barniz (output del sensor virtual 1).

Varios de estos parámetros son ajustables mediante el control de la máquina.

“VIRTUAL SENSE” – Resumen de resultados.

También existen en la máquina otros elementos que permiten realizar ajustes de la misma de forma manual.



*Sistema de ajuste manual de la máquina barnizadora.*

*Fuente: AIDIMME.*

A continuación, se expone la forma de ajustar los parámetros de máquina requeridos para el desarrollo del sensor virtual.

#### Ajuste de la distancia entre Rodillo Dosificador y Aplicador

El Ajuste de la distancia entre rodillos se realiza de forma manual, mediante el accionamiento de la rueda de la imagen anterior.

Este ajuste no tiene límite ya que de la elasticidad del rodillo aplicador permite realizar el apriete sin llegar a un tope. No obstante no se debe realizar un apriete excesivo ya que podría dañarse el rodillo aplicador.

No existe ningún sistema que informe de la distancia entre ambos rodillos. Y la rueda de ajuste a pesar de venir con un indicador no es precisa por desajustes y holguras.

#### Ajuste de la velocidad de los Rodillos

La velocidad del rodillo Aplicador tiene que estar en sincronía con la velocidad lineal del tapiz.

Para ajustar la velocidad del rodillo se utiliza la consola de control de la máquina. Activando inicialmente el motor de la misma y entran en el menú correspondiente y configurando la velocidad del mismo.

Para ajustar la velocidad del rodillo dosificador, de igual forma se configura mediante la consola de control. Si bien, como norma general al arranque de la máquina este rodillo inicialmente se mueve a la misma velocidad del rodillo, una vez pasados unos minutos y preparada la máquina suele detenerse. Solo en caso, de necesitar mayor o menor cantidad de material en el rodillo aplicador, se accionará con movimiento a favor o en contra respectivamente.

“VIRTUAL SENSE” – Resumen de resultados.



Controles de velocidad y sentido de giro de los rodillos.

Fuente: AIDIMME.

En la imagen anterior se pueden visualizar los botones para el control de la velocidad de los rodillos (numerados del 1 al 6).

#### Velocidad del Tapiz

La velocidad del tapiz al igual que la velocidad de los rodillos se ajusta con el panel de mando, con los botones numerados del 7 al 9 (marcados en rojo en la siguiente imagen).

Esta como se ha comentado anteriormente tiene que ser la misma que la velocidad del rodillo aplicador. En caso contrario se obtendrían piezas con acabados defectuosos.

#### Altura del Rodillo Aplicador (espesor de pieza).

Este parámetro se regula también con el panel de control de la máquina. Introduciendo la altura de la pieza la maquina se ajusta automáticamente. Hay que tener en cuenta que la maquina tiene un +/- definido por el error de máquina y viene de fábrica.

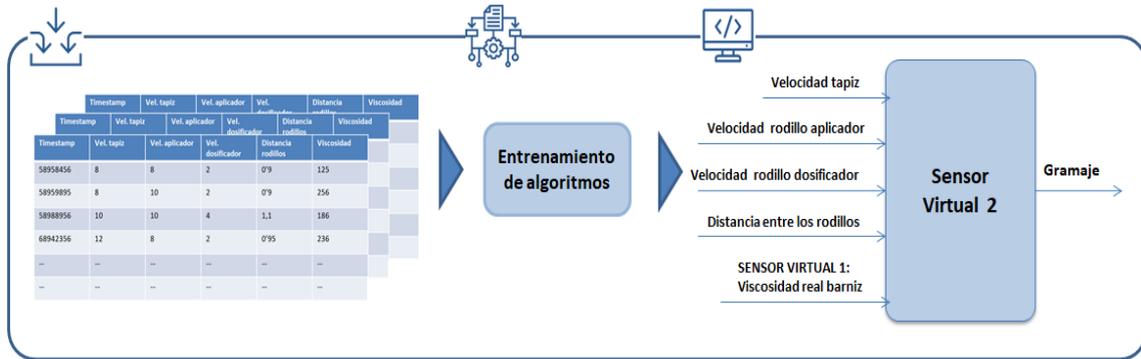
#### Altura de las Cuchillas Limpiadoras

Las cuchillas que limpian los rodillos antes de una nueva pasada también son ajustables en altura. Este ajuste se realiza de forma manual con las manivelas que se encuentran en la parte superior de la máquina.

Dado que se va aplicar una técnica de machine learning por aprendizaje supervisado, para desarrollar el sensor deben de generarse dos tipos de datasets:

“VIRTUAL SENSE” – Resumen de resultados.

- Dataset 1: Se trata de los parámetros variables en la máquina: velocidad del tapiz, velocidad del rodillo aplicador, velocidad rodillo dosificador, distancia entre rodillos y viscosidad del barniz.
- Dataset 2: Se trata del output del sensor, consistente en el peso real del barniz aplicado en las condiciones del dataset 1.



Esquema general de obtención del sensor virtual 2.

Fuente: AIDIMME.

Para la captura de los datos necesarios para ambos datasets se requiere tanto la instalación de un sistema de captura de datos en la máquina, como del registro manual del peso de las piezas que se barnicen.

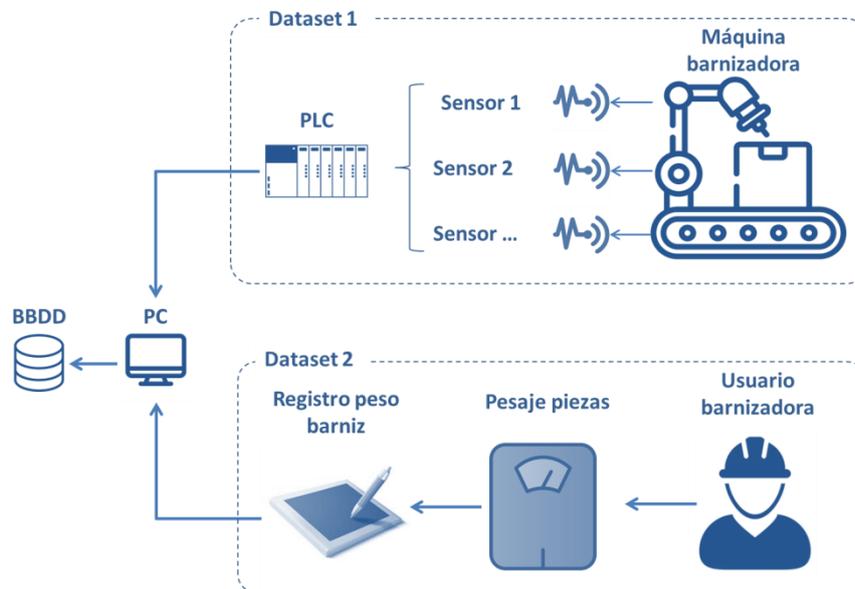


Figura 1: Esquema conceptual necesidades de captura de datos.

Fuente: AIDIMME.

“VIRTUAL SENSE” – Resumen de resultados.

Para capturar datos de velocidades de tapete y rodillos, apriete entre rodillos se requiere la instalación de sensores, que mediante un PLC puedan registrar los parámetros de forma continua y automática a lo largo del tiempo. El PLC comunicará con un PC para realizar un volcado y guardado de los mismos en una base de datos definida para el proyecto.

Por otro lado, el registro de gramaje del barniz aplicado requiere del pesaje de las piezas antes y después de ser barnizadas, siendo el gramaje aplicado la diferencia entre ambas magnitudes. La adopción de un sistema de pesaje automático a la entrada y salida de la máquina excedía el alcance del proyecto, por lo que se ha optado por llevar la operación de forma manual por los técnicos participantes en el proyecto. Sin embargo, el registro del peso se plantea realizarse mediante una aplicación web, y que los datos se vuelquen de forma automática en una base de datos.

### Desarrollos realizados.

Para la captura de los parámetros de configuración de máquina se han seleccionado los siguientes tipos de sensores:

Parámetro de máquina	Tipo de sensor	Cantidad
Velocidad del tapete	Inductivo	2
Velocidad rodillo aplicador	Inductivo	2
Velocidad rodillo dosificador	Inductivo	2
Apriete entre rodillos	Desplazamiento lineal	1
Temperatura barniz (viscosidad)	Sonda de temperatura PT 100	1

*Tabla de parámetros y sensores.*

*Fuente: AIDIMME.*

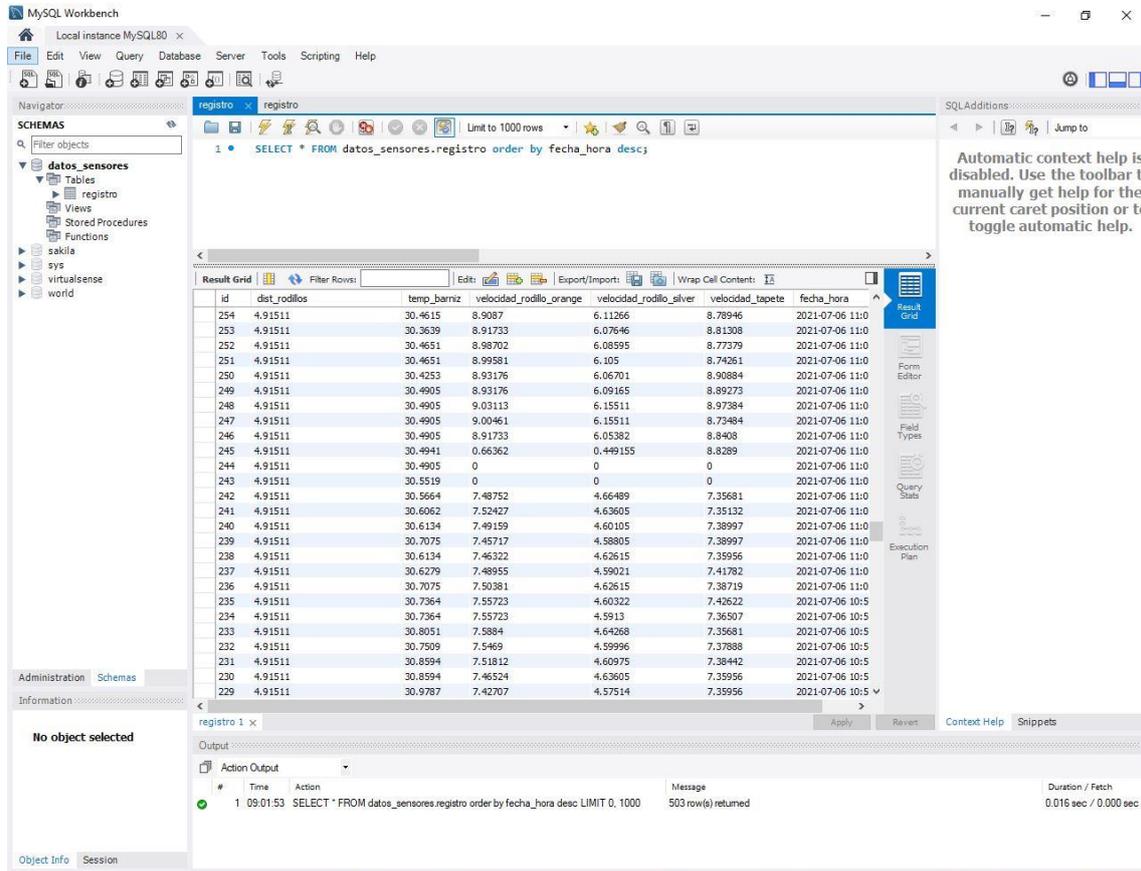
Se ha instalado un cuadro eléctrico con las tarjetas de adquisición de datos, un PLC, borneras y fuente de alimentación, así como también un PC para completar la captura y almacenaje de los datos.

Para el registro del pesaje de las piezas que se barnicen se desarrolla una aplicación informática que permite crear las variables a registrar, indicando el tipo de dato (numérico, texto, listado de opciones, etc.).

Para la correcta captación de datos de los sensores, con la que poder generar del data set que permita el desarrollo del sensor virtual, se han realizado verificaciones de los datos obtenidos por los sensores instalados en la máquina, cuando esta se encuentra en funcionamiento a fin de comprobar el correcto escalado de los mismos.

## “VIRTUAL SENSE” – Resumen de resultados.

Para ello se han captado datos de funcionamiento con las diferentes configuraciones de velocidades del tapete, del rodillo aplicador y del rodillo dosificador. De esa manera, conocidas dichas configuraciones, con los datos obtenidos se han aplicados las correcciones de escalado para el perfecto ajuste entre los valores máquina-sensor.



Captura de pantalla de la base de datos para los sensores.

Fuente: AIDIMME.

Una vez sensorizada máquina y corregido el escalado de los datos de los mismo, el experimento consiste en realizar el proceso de barnizado de probetas de madera de dimensión 20x50 cm ya que representa una décima parte de un metro cuadrado, lo que luego facilitará el estudio del gramaje aplicado.

El procesado de piezas se ha realizado con distintas combinaciones de parámetros, siendo los valores empleados los siguientes:

“VIRTUAL SENSE” – Resumen de resultados.

Velocidad tapiz	Velocidad Aplicador	Velocidad Dosificador	Sentido giro dosificador
6	6	0	A favor
8	8	2	A la contra
10	10	4	-
12	12	-	-

Tabla de rango de valores testados para cada variable.

Fuente: AIDIMME.

Hay que tener en cuenta que las velocidades del Tapiz y del Aplicador deben ser siempre la misma, para obtener los mejores resultados en el proceso.

Barnizadas las piezas, se han depositado en un carro para posteriormente secarlas en el túnel de secado UV, y posteriormente se han pesado nuevamente para obtener el peso final de la pieza con el acabado aplicado.



Figura 2: Detalle piezas procesadas en carro secado.

Fuente: AIDIMME.

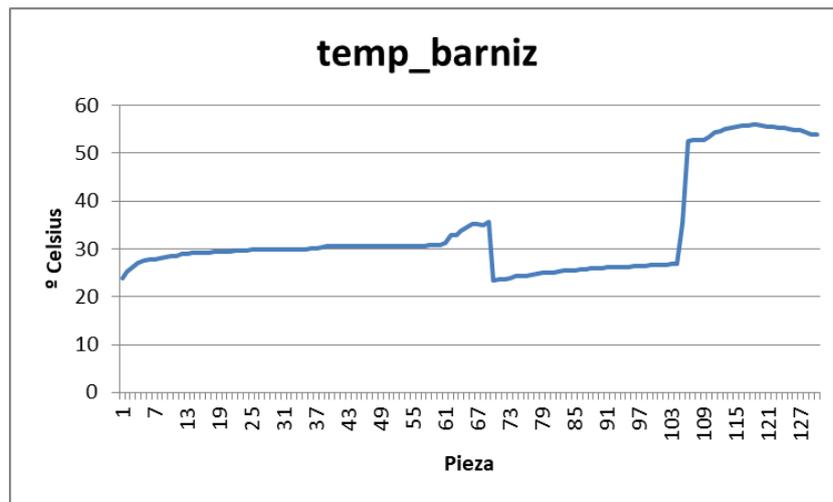
Con los datos de gramaje inicial / final y el resto de datos de los diferentes sensores se genera el algoritmo para el sensor virtual 2 que permite obtener el dato de gramaje de material aplicado.

“VIRTUAL SENSE” – Resumen de resultados.

**Resultado.**

Como resultado se han obtenido los dos dataset que son empleados para el aprendizaje y generación del modelo de cálculo del sensor virtual 2. Por un lado, un data set con toda la información de los sensores, y por otro el gramaje pesado de las piezas barnizadas.

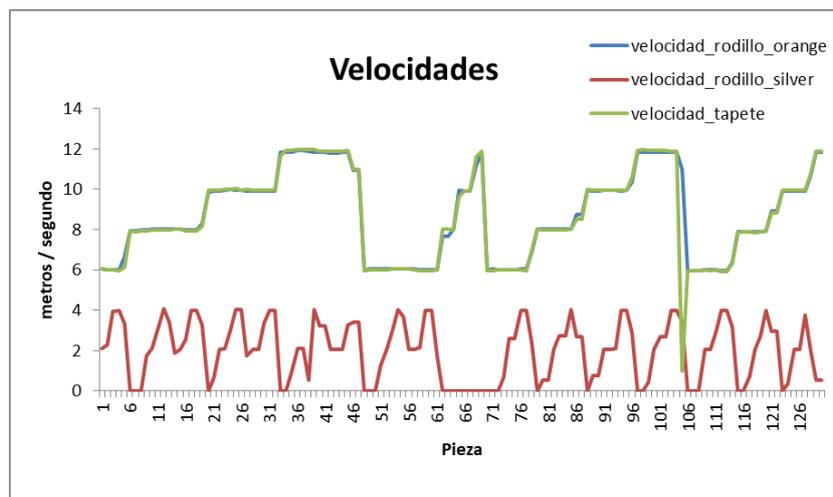
Los datos de temperatura del barniz han oscilado entre 23°C y 55°C, del modo que se refleja en la siguiente gráfica.



Temperatura de barniz medidas.

Fuente: AIDIMME.

Las velocidades de tapete y rodillo aplicador han oscilado entre 6 metros / segundo y 12 metros segundo. La velocidad del rodillo dosificador ha oscilado entre 0 metros / segundo (parado) y 4 metros segundo.

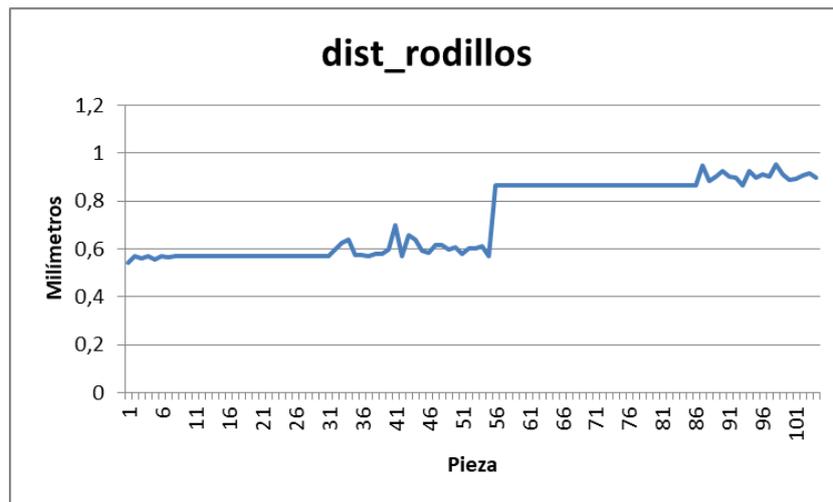


Velocidades tapete y rodillos. Fuente: AIDIMME.

“VIRTUAL SENSE” – Resumen de resultados.

La distancia entre rodillos ha oscilado en todas la pruebas entre 0’55 mm y 0’9 mm. Sin embargo, se ha mantenido bastante constante alrededor de 0’55mm para el primer barniz empleado en las pruebas, y sobre 0’85 mm para el segundo barniz.

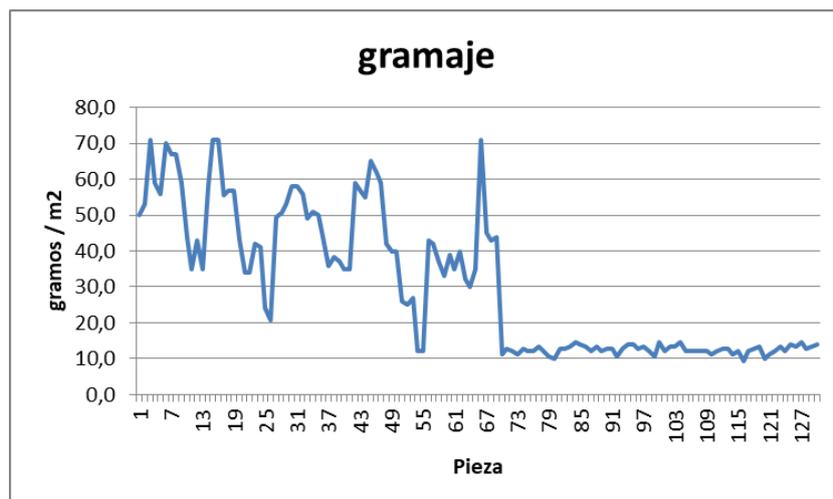
Se aprecia pequeñas variaciones en la medida, al final de las pruebas, justo cuando las velocidades de trabajo son más altas.



Distancia entre rodillos

Fuente: AIDIMME.

El gramaje aplicado se ha situado en torno a los 10 gramos/metro<sup>2</sup> y 70 gramos /metro<sup>2</sup> para el primer barniz, y entre los 9 gramos / metro<sup>2</sup> y 15 gramos / metro<sup>2</sup> para el segundo barniz.



Gramaje resultante.

Fuente: AIDIMME.

“VIRTUAL SENSE” – Resumen de resultados.

### 3.3.3 SENSOR VIRTUAL 3: MEDIDA DE CONCENTRACIÓN DE ACEITE EN TALADRINA.

Para el desarrollo del sensor virtual 3 se utiliza un torno de decoletaje marca Nakamura. El torno pertenece a una de las empresas colaboradoras en el proyecto (Factor Decoletaje, S.L.).



*Torno de decoletaje seleccionado para el experimento*

*Fuente: Factor.*

Para éste sensor virtual número 3 los parámetros a registrar son:

- Tipo de máquina. La antigüedad de la máquina influye en las pérdidas de material o impurezas que puedan llegar al circuito de taladrina.
- Material. En función de la dureza del material, los esfuerzos de corte y el calentamiento es diferente y la evaporación del agua puede cambiar.
- Fecha de relleno. Se trata de fecha en la que se llevó acabo la última adición de taladrina a la máquina. Cuando se adiciona nueva taladrina, las concentraciones en la máquina se presuponen optimas.
- Concentración adicionada. La concentración de la emulsión que se añade al depósito de la máquina influye en la nueva concentración de la mezcla total.
- Concentración previa. La concentración de la emulsión que quedaba en el depósito de la máquina (antes de añadir nueva taladrina) influye en la nueva concentración de la mezcla total.
- Volumen de emulsión. El volumen de la mezcla puede dar una relación de la cantidad de agua que ha evaporado y se ha perdido en la salida de las piezas procesadas, ya que estas no salen completamente secas.
- Tiempo de trabajo. Cuanto mayor tiempo ha estado la máquina trabajando desde la última reposición de taladrina en el circuito, mayor evaporación de agua se ha producido, y mayor será la concentración de aceite. No es lo mismo que pase tiempo con la máquina parada, que a pleno funcionamiento.

“VIRTUAL SENSE” – Resumen de resultados.

- Temperatura de la mezcla. A mayor temperatura de la mezcla mayor evaporación de agua se produce.
- Temperatura ambiente. Relacionada con la temperatura de la mezcla. Cuando el ambiente presenta mayor temperatura la evaporación de agua se produce más rápido.
- Humedad relativa. Se estima que puede tener influencia en la rapidez de la evaporación del agua.
- Consumo de corriente. Se trata de una magnitud que puede estar relacionada con el tiempo de trabajo de la máquina, en el caso que no se registrara de forma manual, o el registro no fuera fiable.

Como el experimento se va a llevar a cabo en una sola máquina, la variable tipo de máquina va a ser constante y no se va a utilizar.

Hay una serie de mediciones con sensores (volumen del depósito y temperatura de la emulsión) que deben realizar en el depósito de taladrina de la máquina.

Dado que se va aplicar una técnica de machine learning por aprendizaje supervisado, para desarrollar el sensor deben de generarse dos tipos de datasets:

- Dataset 1: Se trata de los parámetros variables en la máquina o en las condiciones ambientales de planta, que pueden ser capturados directamente de forma automática y continua por sensores: temperatura y humedad ambiente, temperatura de la mezcla, corriente consumida, volumen del depósito.
- Dataset 2: Se trata de parámetros que no pueden ser medidos mediante sensores, y que han de ser registrados de forma manual. Entre ellos, el output del sensor virtual, consistente en la concentración de aceite en la emulsión que da lugar a la taladrina.

Para la captura de los datos necesarios para ambos datasets se requiere tanto la instalación de un sistema de captura de datos en la máquina, como del registro manual de diferentes variables del proceso de decoletaje, que el operario puede consultar en las órdenes de producción u hojas de ruta de fabricación.

Para capturar datos temperatura y humedad ambiente, temperatura de la emulsión de taladrina, volumen del depósito y corriente se requiere la instalación de sensores, que mediante un PLC puedan registrar los parámetros de forma continua y automática a lo largo del tiempo. El PLC comunicará con un PC para realizar un volcado y guardado de los mismos en una base de datos definida para el proyecto.

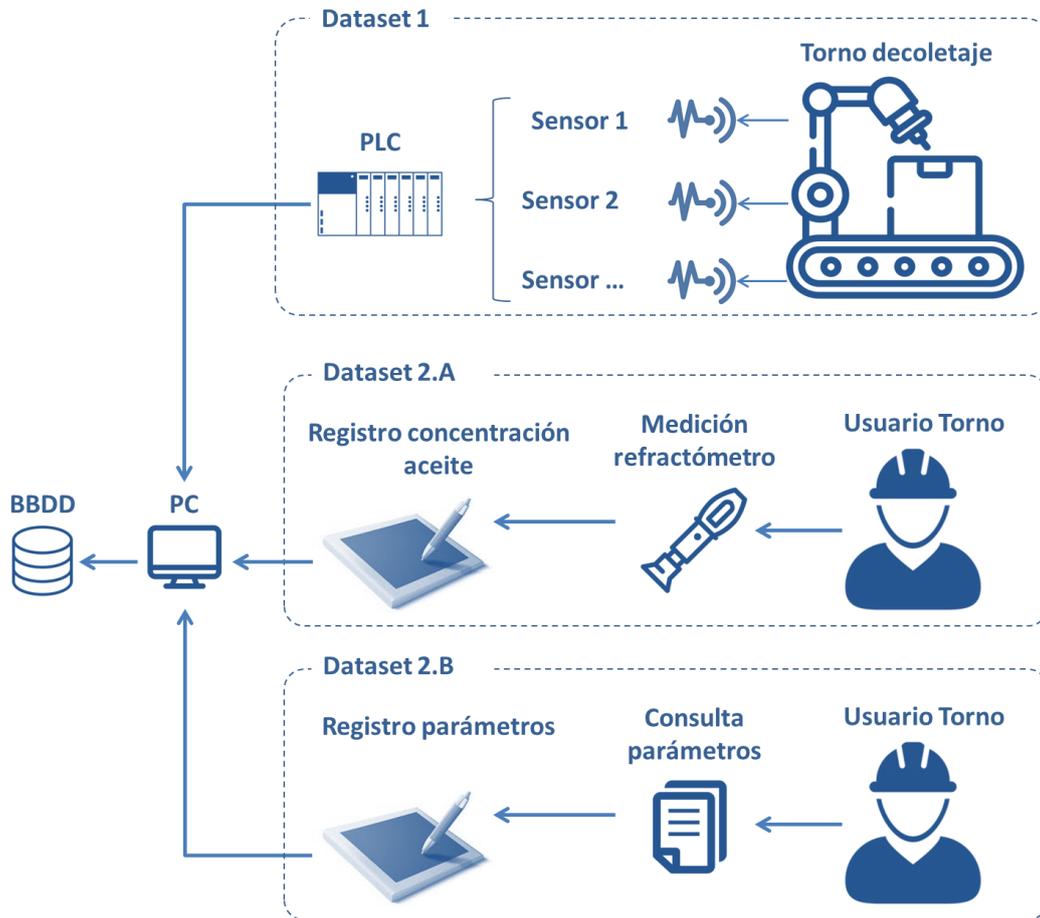
Por otro lado, el registro del material de trabajo, tiempos de trabajo, fecha de relleno de taladrina en el depósito, concentración de taladrina adicionada, volumen añadido, y concentración de taladrina real (medida con un refractómetro) se deben de llevar a cabo de forma manual ya que no es posible su captura automática. El registro de las mismas se va a llevar a cabo mediante una aplicación web, volcándose los mismos de forma automática en una base de datos.

Éste dataset de registro manual, lo podemos descomponer en dos partes:

- Dataset 2.A: constando de todos los datos que van a servir como entradas al modelo predictivo de la concentración de taladrina.

“VIRTUAL SENSE” – Resumen de resultados.

- Dataset 2.B: constando de las medidas reales de concentración de aceite en la taladrina realizadas mediante un refractómetro.



Esquema conceptual necesidades de captura de datos.

Fuente: AIDIMME.

“VIRTUAL SENSE” – Resumen de resultados.

Al igual que para el caso del sensor virtual 2, se ha requerido de una aplicación de registro de datos manual para recoger diferentes variables que no pueden ser capturadas de forma automática mediante sensores.

Para adaptar la aplicación de registro de datos a las necesidades del proyecto en el caso del sensor virtual 3, se han generado las siguientes variables para su registro manual:

Variable	Tipo	Unidad medida
Tipo de maquina	Multirespuesta	-
Material de trabajo	Multirespuesta	-
Fecha de relleno	Numérico	-
Concentración adicionada	Numérico	%
Volumen adicionado	Numérico	litros
Concentración refractómetro	Numérico	%

*Tabla de variables de registro manual generadas.*

*Fuente: AIDIMME.*

- Tipo de máquina. La máquina sobre la que se va a desarrollar el sensor va a ser solo una, denominada como Nakamura 2.
- Material de trabajo. El material con el que se trabaja en la máquina puede ser aluminio, y diferentes tipos de acero.
- Fecha de relleno. Esta variable recoge cada vez que se realiza un relleno adición de taladrina en el depósito.
- Concentración adicionada. Cada vez que se realice un rellenado del depósito de taladrina se indicará la concentración de la emulsión adicionada.
- Volumen adicionado. Cada vez que se adiciona taladrina al depósito se registra la cantidad adicionada.
- Concentración refractómetro. Concentración real de la taladrina del depósito medida con un refractómetro.

Dado que el desarrollo del sensor virtual se ha realizado sobre un entorno industrial real, las necesidades de producción reales impiden la manipulación del valor de las variables de entrada al modelo (material de trabajo, concentraciones, temperaturas, etc.).

Por tanto, la captura de datos de los sensores se ha llevado a cabo de forma automática sobre las condiciones de trabajo reales en fábrica. Los datos recopilados de forma manual, han sido introducidos por el personal de Factor SL según las condiciones de trabajo de la máquina.

“VIRTUAL SENSE” – Resumen de resultados.

Como resultado se han obtenido los dos dataset que son empleados para el aprendizaje y generación del modelo de cálculo del sensor virtual 3. Por un lado, un data set con toda la información de los sensores, y por otro las registradas de manera manual como la cantidad de taladrina adicionada, el tiempo entre relleno del depósito o la concentración de aceite real medida con un refractómetro.

Toda esta información se unifica en un solo dataset buscando las marcas temporales de ambos dataset. En la siguiente figura se muestra un ejemplo del dataset final generado para el entrenamiento de diferentes modelos predictivos.

	A	B	C	D	E	F	G	H
1	Corriente	cantidad	humAmbien	nivelVaciad	tempAmbier	tempMezcla	tiempoRelle	concentraci
2	12,8043278	0	45,6892697	1,61810949	20,5162121	44,2623783	2	5,11640484
3	11,4757725	0	51,6003695	1,78167313	23,4705816	46,6711519	2	5,61702188
4	13,2527927	0	69,3623478	2,12045592	26,1584283	31,5213082	2	6,26741335
5	11,5994906	8	69,2827644	1,26232613	20,9420841	39,2901816	0	5,92834686
6	11,6431154	8	64,3094515	1,53116166	16,8863892	47,2268782	0	5,79642335
7	12,6885622	8	58,9874408	2,54369392	26,4920974	40,954106	0	6,43634751
8	13,7130693	0	56,2863046	4,64589035	23,7723632	40,9166752	1	6,19291005
9	12,6652555	0	55,7647127	5,37959224	21,1245104	43,9462706	2	6,00247233
10	10,9560398	0	68,5785922	6,50345134	16,9951445	35,3651365	2	5,96247508
11	12,7454723	0	55,7528145	7,82691718	20,0474506	37,8632623	3	6,60531032
12	12,877271	0	51,2138725	7,94919382	23,2167233	39,8405098	3	6,88307873
13	13,3030973	0	68,1107005	8,09696753	14,9413035	41,7900056	3	5,99812579
14	12,5999758	7	49,1346059	1,02995775	19,9575928	39,3270316	0	5,4916931
15	13,8533055	7	57,133119	3,12279875	14,9337425	39,0530284	0	5,52556247
16	15,25678	0	46,3497189	4,35003316	24,4372804	42,8525648	1	5,89695347
17	13,60	0	59,890383	5	18136	47,5132845	1	5,21473466
JR		0	67,8378357		978	47,5219003		6,12942986
			60			38,540282		5,108

Extracto del dataset final generado.

Fuente: AIDIMME.

### 3.4 DESARROLLO DE LOS SENSORES VIRTUALES

Para el desarrollo de los sensores virtuales se lleva a cabo el entrenamiento de los diferentes modelos expuestos anteriormente. Una vez se ejecutan los algoritmos sobre los datos, se obtiene un modelo que permite predecir la magnitud deseada. Sin embargo, es necesario encontrar métodos y métricas para comprobar que efectivamente el modelo está funcionando de la manera más certera posible. De aquí en adelante se utilizará la siguiente notación:

$y$  → Valor del dato original

$\hat{y}$  → Valor del dato predicho por el modelo

$N$  → Cantidad total de datos.

“VIRTUAL SENSE” – Resumen de resultados.

Se muestran a continuación algunos de los métodos más útiles para comprobar el desempeño de un modelo de aprendizaje automático.

### Error medio absoluto

Este método consiste en comprobar la desviación media que ha tenido la predicción del valor original, para ello, se suma la desviación de cada uno de los resultados y se divide por el total de datos. Normalmente se conoce a esta medida como MAE, siglas en inglés de *Mean Absolute Error*.

De esta forma se define de la siguiente manera:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}|$$

Al tratarse de un cálculo lineal, una predicción con un conjunto grande de pequeños errores podría generar el mismo resultado que un conjunto sin errores a excepción de un dato muy desviado.

### Raíz del error medio cuadrático

Más conocido como *Root Mean Square Error (RMSE)*, toma una aproximación cuadrática al cálculo del error. Se define de la siguiente manera:

$$RMSE = \sqrt{\frac{\sum (y - \hat{y})^2}{N}}$$

En este caso, la aproximación es cuadrática, por ello, los errores grandes son muy penalizados aumentando el valor total del cálculo del error enormemente, mientras que los errores pequeños resultan casi ignorados.

### R cuadrado (R Square).

La función R cuadrado surge para tener una base sólida de comparación entre varios modelos. El objetivo de esta medida no es obtener un valor de desviación que trabaje en las mismas unidades que los datos originales sino en tener una medida relativa de cuánto se está desviando un modelo. La medida R cuadrado se define de la siguiente manera:

$$R^2 = \frac{\sum (y - \bar{y})^2 - \sum (y - \hat{y})^2}{\sum (y - \hat{y})^2}$$

Aquí aparece el valor medio de  $y$  expresado como  $\bar{y}$ , es decir:

“VIRTUAL SENSE” – Resumen de resultados.

$$\bar{y} = \frac{1}{N} \sum_{i=1}^N y_i$$

El término  $R^2$  representa entonces la desviación de la recta de regresión generada respecto a la recta generada por el término medio de los valores de  $y$ . Esta medida es muy sólida para realizar comparaciones. Entre distintos modelos

En el proyecto se han utilizado estas tres medidas para comparar y estudiar los resultados de los modelos.

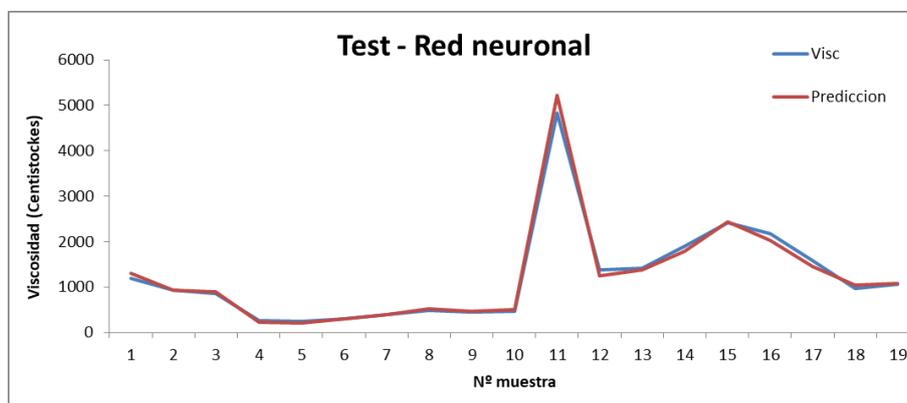
### 3.4.1 SENSOR VIRTUAL 1.

#### Modelo con Red Neuronal

Tras realizar el entrenamiento de un modelo mediante redes neuronales se obtiene un modelo que se ajusta bastante a los datos de entrenamiento con un Error medio absoluto de 98'89 centistokes, un Error medio cuadrático 32.031'75 y una  $R^2$  de 0'98.

Tras realizar el test del modelo previamente entrenado mediante redes neuronales se obtiene un Error medio absoluto de 72'03 centistokes, un Error medio cuadrático 12.955'43 y una  $R^2$  de 0'99.

En la siguiente gráfica se puede visualizar la comparativa entre la viscosidad real obtenida, y la predicción que lleva a cabo el modelo.

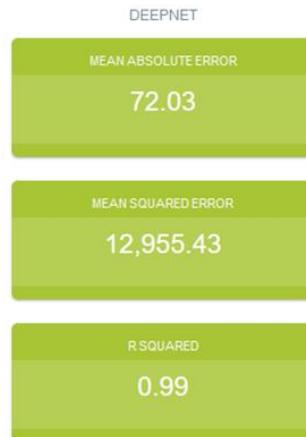


*Viscosidad real vs. Predicción del modelo (test red neuronal)*

Fuente: AIDIMME.

A continuación, se muestra la comparativa de los tres indicadores de precisión del modelo.

“VIRTUAL SENSE” – Resumen de resultados.



Indicadores precisión del modelo predictivo (test red neuronal)

Fuente: AIDIMME.

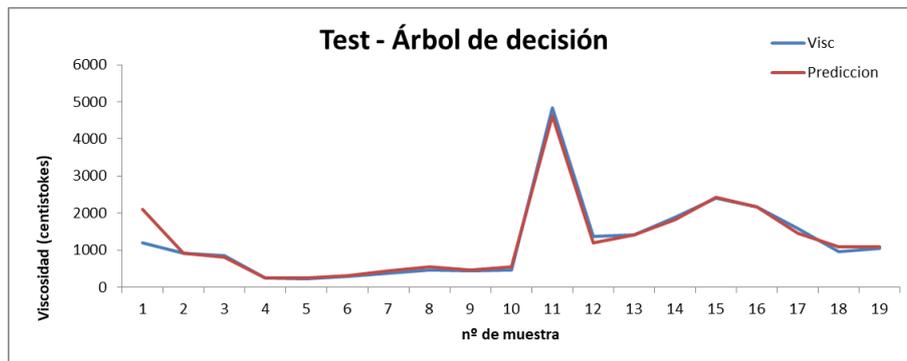
La  $R^2$  de 0'99 en la fase de test, muestran que el modelo generado es muy robusto y preciso para predecir la viscosidad.

Modelo con Árbol de decisión

Tras realizar el entrenamiento de un modelo mediante árbol de decisión se obtiene un modelo que se ajusta bastante a los datos de entrenamiento con un Error medio absoluto de 111'02 centistokes, un Error medio cuadrático 103.635'50 y una  $R^2$  de 0'95.

Tras realizar el test del modelo previamente entrenado mediante árbol de decisión se obtiene un Error medio absoluto de 105'42 centistokes, un Error medio cuadrático 51.032'68 y una  $R^2$  de 0'96.

En la siguiente gráfica se puede visualizar la comparativa entre la viscosidad real obtenida, y la predicción que lleva a cabo el modelo.

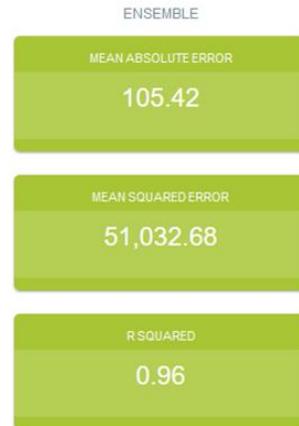


Viscosidad real vs. Predicción del modelo (test red neuronal)

Fuente: AIDIMME.

“VIRTUAL SENSE” – Resumen de resultados.

A continuación, se muestra la comparativa de los tres indicadores de precisión del modelo.



*Indicadores precisión del modelo predictivo (test red neuronal)*

*Fuente: AIDIMME.*

La  $R^2$  de 0'96 en la fase de test, muestran que el modelo generado es muy robusto y preciso para predecir la viscosidad, aunque ligeramente peor que el modelo generado mediante redes neuronales.

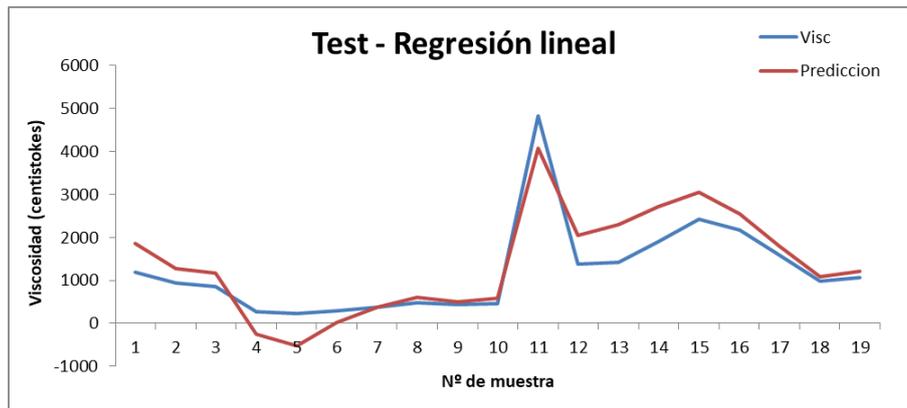
#### Modelo con Regresión Lineal

Tras realizar el entrenamiento de un modelo mediante regresión lineal se obtiene un modelo que se ajusta de forma moderada a los datos de entrenamiento con un Error medio absoluto de 469'82 centistokes, un Error medio cuadrático 401.338'24 y una  $R^2$  de 0'8.

Tras realizar el test del modelo previamente entrenado mediante regresión lineal se obtiene un Error medio absoluto de 412'40 centistokes, un Error medio cuadrático 250.171'77 y una  $R^2$  de 0'81.

En la siguiente gráfica se puede visualizar la comparativa entre la viscosidad real obtenida, y la predicción que lleva a cabo el modelo.

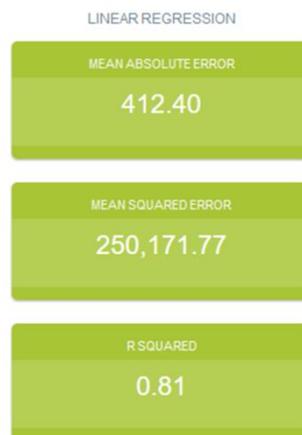
“VIRTUAL SENSE” – Resumen de resultados.



Viscosidad real vs. Predicción del modelo (test red neuronal)

Fuente: AIDIMME.

A continuación, se muestra la comparativa de los tres indicadores de precisión del modelo.



Indicadores precisión del modelo predictivo (test red neuronal)

Fuente: AIDIMME.

La  $R^2$  de 0'81 en la fase de test, muestran que el modelo generado es medianamente robusto para predecir la viscosidad. Sin embargo, llega a predecir valores de viscosidad negativos, lo que no es físicamente posible. Es claramente peor que el modelo generado mediante redes neuronales y el generado mediante árbol de decisión.

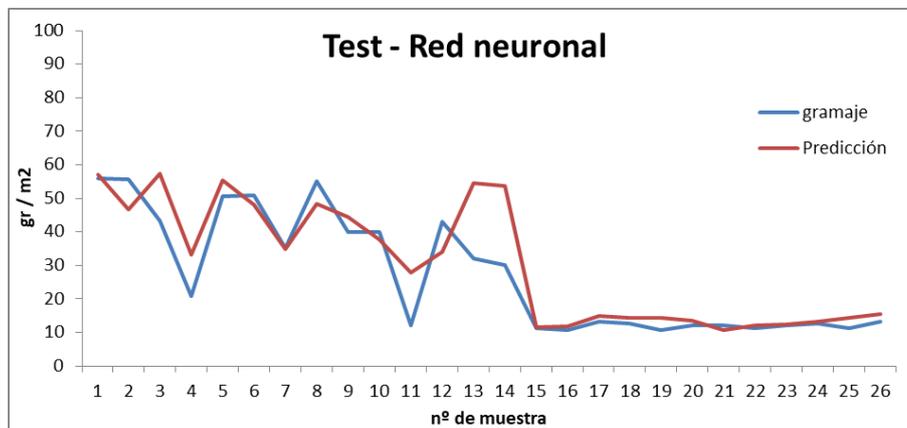
### 3.4.2 SENSOR VIRTUAL 2.

#### Modelo con Red Neuronal

Tras realizar el entrenamiento de un modelo mediante redes neuronales se obtiene un modelo que se ajusta bastante a los datos de entrenamiento con un Error medio absoluto de 3’52 gramos/m<sup>2</sup>, un Error medio cuadrático 35’02 y una R<sup>2</sup> de 0’91.

Tras realizar el test del modelo previamente entrenado mediante redes neuronales se obtiene un Error medio absoluto de 5’65 gramos/m<sup>2</sup>, un Error medio cuadrático 75’58 y una R<sup>2</sup> de 0’75.

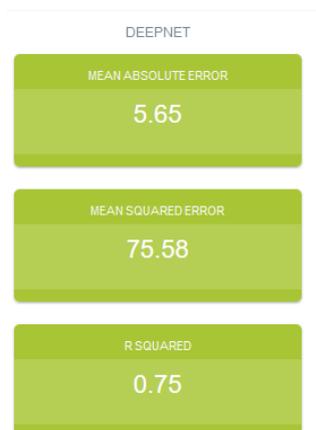
En la siguiente gráfica se puede visualizar la comparativa entre el gramaje real obtenido, y la predicción que lleva a cabo el modelo.



Gramaje real vs. Predicción del modelo (test red neuronal)

Fuente: AIDIMME.

A continuación, se muestra la comparativa de los tres indicadores de precisión del modelo.



Indicadores precisión del modelo predictivo (test red neuronal) Fuente: AIDIMME.

“VIRTUAL SENSE” – Resumen de resultados.

Un error de hasta 10 gramos / m<sup>2</sup> se considera por los expertos en barnizado de piezas planas aceptable. En éste sentido el Error medio absoluto se sitúa por debajo de éste límite.

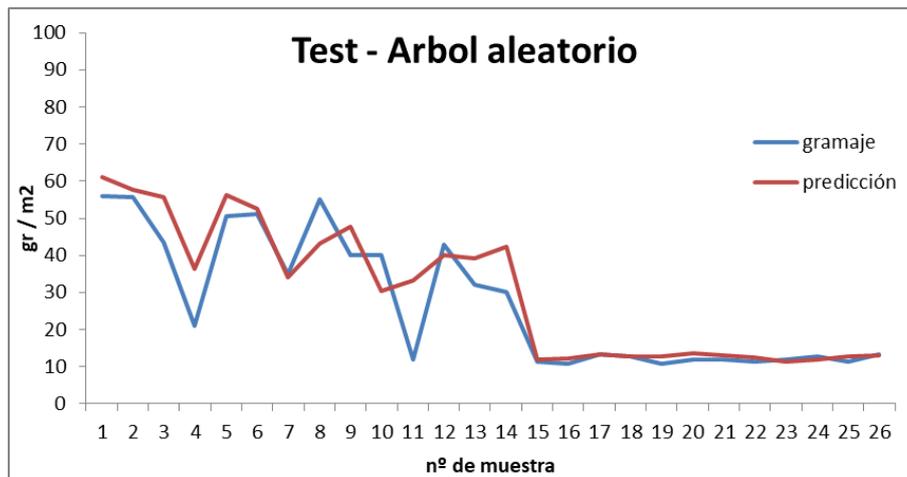
Sin embargo, una R<sup>2</sup> por debajo de 0’8 nos indica que el modelo no es lo suficiente preciso.

Modelo con Árbol de decisión Aleatorio

Tras realizar el entrenamiento de un modelo mediante un árbol de decisión aleatorio se obtiene un modelo que se ajusta bastante a los datos de entrenamiento con un Error medio absoluto de 1’84 gramos/m<sup>2</sup>, un Error medio cuadrático 10’22 y una R<sup>2</sup> de 0’97. Los indicadores para el dataset de entrenamiento son mejores que para el modelo de red neuronal.

Tras realizar el test del modelo previamente entrenado mediante redes neuronales se obtiene un Error medio absoluto de 4’9 gramos/m<sup>2</sup>, un Error medio cuadrático 54’99 y una R<sup>2</sup> de 0’82.

En la siguiente gráfica se puede visualizar la comparativa entre el gramaje real obtenido, y la predicción que lleva a cabo el modelo.

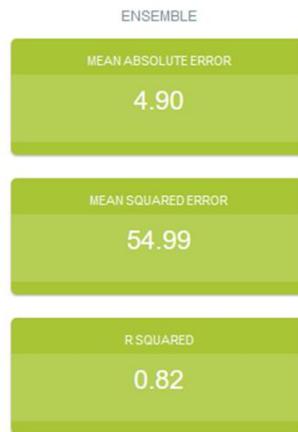


Gramaje real vs. Predicción del modelo (test árbol de decisión aleatorio)

Fuente: AIDIMME.

A continuación, se muestra la comparativa de los tres indicadores de precisión del modelo.

“VIRTUAL SENSE” – Resumen de resultados.



*Indicadores precisión del modelo predictivo (test árbol de decisión aleatorio)*

*Fuente: AIDIMME.*

Un error de hasta 10 gramos / m<sup>2</sup> se considera por los expertos en barnizado de piezas planas aceptable. En éste sentido el Error medio absoluto se sitúa por debajo de éste límite.

La R<sup>2</sup> es superior a 0’8, mejorando la precisión del test del modelo anterior.

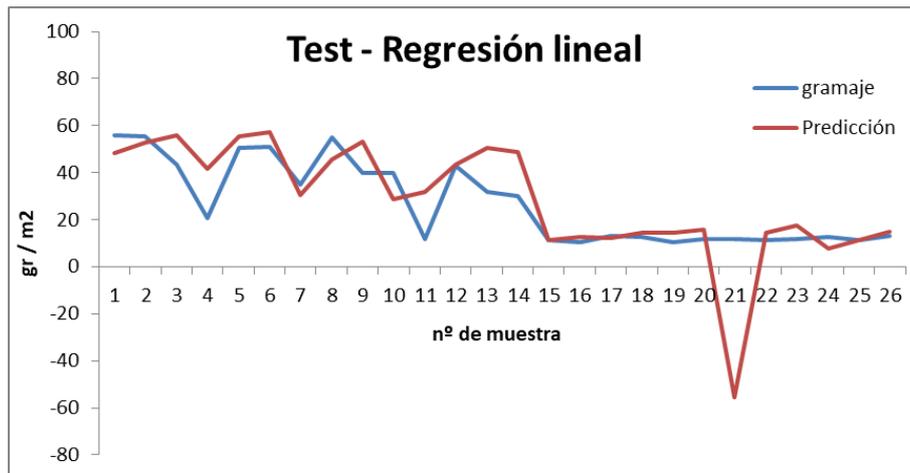
### Modelo con Regresión lineal

Tras realizar el entrenamiento de un modelo mediante regresión lineal se obtiene un modelo que se ajusta bastante a los datos de entrenamiento con un Error medio absoluto de 5’65 gramos/m<sup>2</sup>, un Error medio cuadrático 64’40 y una R<sup>2</sup> de 0’84. De los tres modelos generados, este es que peor resultado arroja en la fase de entrenamiento.

Tras realizar el test del modelo previamente entrenado mediante regresión lineal se obtiene un Error medio absoluto de 9’43 gramos/m<sup>2</sup>, un Error medio cuadrático 262’88 y una R<sup>2</sup> de 0’13.

En la siguiente gráfica se puede visualizar la comparativa entre el gramaje real obtenido, y la predicción que lleva a cabo el modelo.

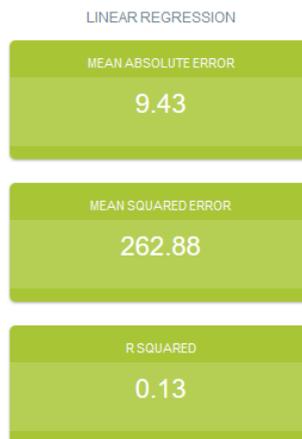
“VIRTUAL SENSE” – Resumen de resultados.



Gramaje real vs. Predicción del modelo (test regresión lineal)

Fuente: AIDIMME.

A continuación, se muestra la comparativa de los tres indicadores de precisión del modelo.



Indicadores precisión del modelo predictivo (test regresión lineal)

Fuente: AIDIMME.

Se trata del modelo con peores indicadores de precisión. El error medio cuadrático se sitúa por debajo de 10 gramos /m<sup>2</sup>, pero el valor de la R<sup>2</sup> de 0'13, desaconseja claramente la adopción de éste modelo.

Modelo con Árbol de decisión aleatorio sin sensor apriete rodillos.

Si se comparan los tres modelos, el Árbol Aleatorio (RandomForest) es el que mejores indicadores de precisión alcanza, tanto en la fase de test como de entrenamiento.

“VIRTUAL SENSE” – Resumen de resultados.

En la siguiente tabla, además de la comparativa de precisión de la parte inferior, se muestra la importancia que cada modelo otorga a cada variable de entrada. Tanto la red neuronal como el árbol aleatorio otorgan la máxima importancia a la distancia entre rodillos.

Sin embargo, en el resultado del sensor virtual 2 se ha visto como la distancia entre rodillos se han mantenido prácticamente constante para un mismo tipo de barniz. Por tanto, el peso de la variable distancia entre rodillos está “falseando” el de la variable tipo de Barniz.

	NeuralNet	RandomForest	Linear
<b>Importancia de los campos</b>			
dist_rodillos	0,81999	0,68096	NA
direccion_dosificador	0,05888	0,06362	NA
temp_barniz	0,05058	0,075	NA
velocidad_tapete	0,0374	0,01729	NA
velocidad_rodillo_silver	0,02222	0,03535	NA
velocidad_rodillo_orange	0,00941	0,041	NA
Barniz	0,00152	0,08678	NA
<b>Sobre entrenamiento</b>			
MAE	3,52	1,84	5,68
MSE	35,02	10,22	64,4
R2	0,91	0,97	0,84
<b>Sobre test</b>			
MAE	5,65	4,9	9,43
MSE	75,58	54,99	262,88
R2	0,75	0,82	0,13

Comparativa modelos predictivos generados.

Fuente: AIDIMME.

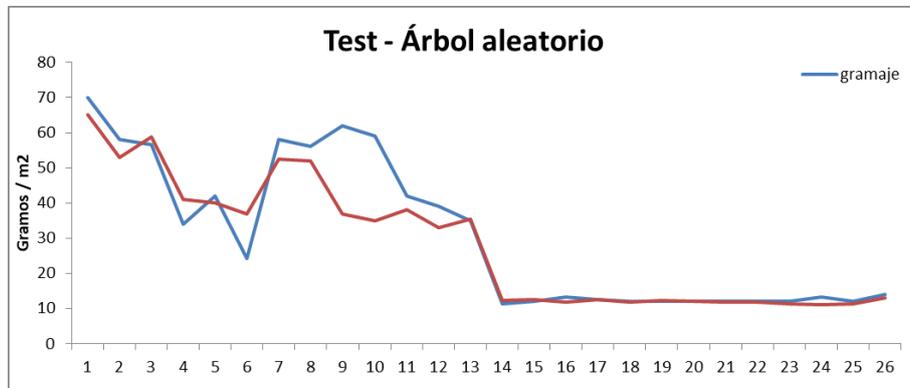
Por ello, se ha repetido el aprendizaje del modelo de árbol aleatorio sin tener en cuenta la distancia entre rodillos.

Tras realizar el entrenamiento de un modelo mediante un árbol de decisión aleatorio se obtiene un modelo que se ajusta bastante a los datos de entrenamiento con un Error medio absoluto de 2'18 gramos/m<sup>2</sup>, un Error medio cuadrático 14'85 y una R<sup>2</sup> de 0'96. Los indicadores para el dataset de entrenamiento ligeramente peores que cuando se entrenó en algoritmo considerando la variable distancia entre rodillos.

Tras realizar el test del modelo previamente entrenado mediante árbol de decisión aleatorio se obtiene un Error medio absoluto de 4'28 gramos/m<sup>2</sup>, un Error medio cuadrático 60'67 y una R<sup>2</sup> de 0'86. Todos estos indicadores mejoran el resultado del test sobre el modelo que si contemplaba a la variable distancia entre rodillos.

“VIRTUAL SENSE” – Resumen de resultados.

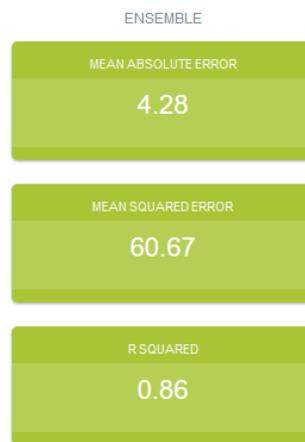
En la siguiente gráfica se puede visualizar la comparativa entre el gramaje real obtenido, y la predicción que lleva a cabo el modelo.



Gramaje real vs. Predicción del modelo (test árbol de decisión aleatorio ii)

Fuente: AIDIMME.

A continuación, se muestra la comparativa de los tres indicadores de precisión del modelo.



Indicadores precisión del modelo predictivo (test árbol de decisión ii)

Fuente: AIDIMME.

“VIRTUAL SENSE” – Resumen de resultados.

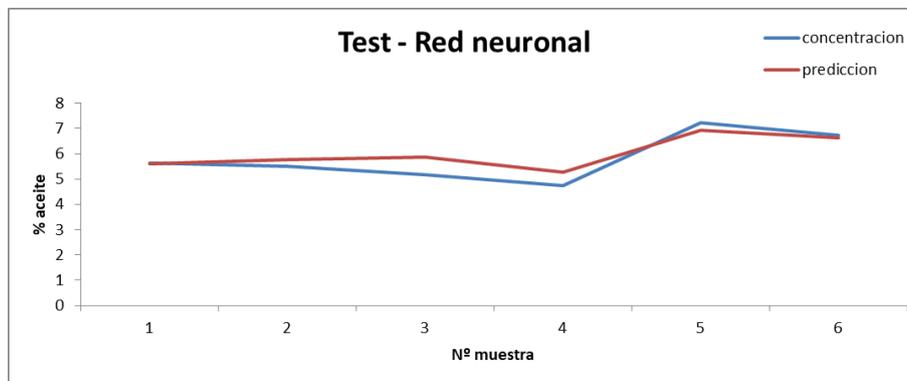
### 3.4.3 SENSOR VIRTUAL 3.

#### Modelo con Red Neuronal

Tras realizar el entrenamiento de un modelo mediante redes neuronales se obtiene un modelo que se ajusta bastante a los datos de entrenamiento con un Error medio absoluto de 0’05 unidades porcentuales de % de aceite, un Error medio cuadrático 0’01 y una  $R^2$  de 0’95.

Tras realizar el test del modelo previamente entrenado mediante redes neuronales se obtiene un Error medio absoluto de 0’31 unidades porcentuales de % de aceite, un Error medio cuadrático 0’15 y una  $R^2$  de 0’82.

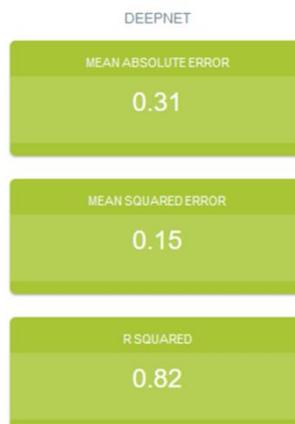
En la siguiente gráfica se puede visualizar la comparativa entre el % de aceite real obtenido, y la predicción que lleva a cabo el modelo.



% aceite en taladrina real vs. Predicción del modelo (test red neuronal)

Fuente: AIDIMME.

A continuación, se muestra la comparativa de los tres indicadores de precisión del modelo.



Indicadores precisión del modelo predictivo (test red neuronal. Fuente: AIDIMME).

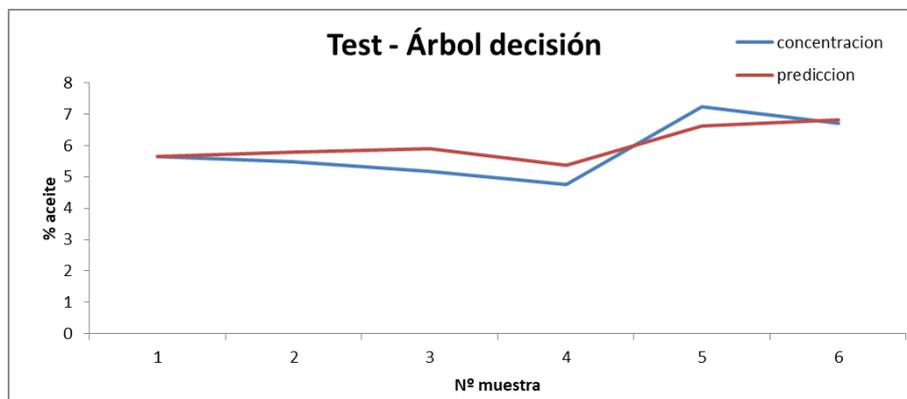
“VIRTUAL SENSE” – Resumen de resultados.

### Modelo con Árbol de decisión Aleatorio

Tras realizar el entrenamiento de un modelo mediante un árbol de decisión aleatorio se obtiene un modelo que se ajusta bastante a los datos de entrenamiento con un Error medio absoluto de 0'16 unidades porcentuales de % de aceite, un Error medio cuadrático 0'05 y una  $R^2$  de 0'85. Los indicadores para el dataset de entrenamiento son peores que para el modelo de red neuronal.

Tras realizar el test del modelo previamente entrenado mediante redes neuronales se obtiene un Error medio absoluto de 0'39 unidades porcentuales de % de aceite, un Error medio cuadrático 0'22 y una  $R^2$  de 0'73.

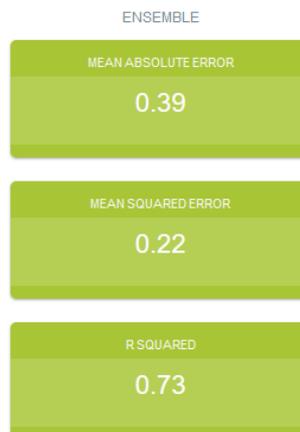
En la siguiente gráfica se puede visualizar la comparativa entre el % de aceite real obtenido, y la predicción que lleva a cabo el modelo.



% aceite en taladrina real vs. Predicción del modelo (test árbol de decisión aleatorio)

Fuente: AIDIMME.

A continuación, se muestra la comparativa de los tres indicadores de precisión del modelo.



Indicadores precisión del modelo predictivo (test árbol de decisión aleatorio.)Fuente: AIDIMME.

“VIRTUAL SENSE” – Resumen de resultados.

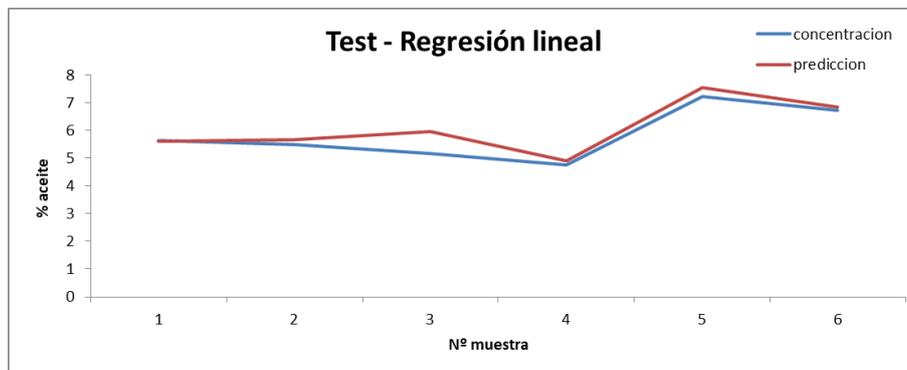
Este modelo no tiene precisión suficiente para realizar una buena predicción.

### Modelo con Regresión lineal

Tras realizar el entrenamiento de un modelo mediante regresión lineal se obtiene un modelo que se ajusta bastante a los datos de entrenamiento con un Error medio absoluto de 0’09 unidades de % de aceite, un Error medio cuadrático 0’01 y una  $R^2$  de 0’96. De los tres modelos generados, este es que mejor resultado arroja en la fase de entrenamiento.

Tras realizar el test del modelo previamente entrenado mediante regresión lineal se obtiene un Error medio absoluto de 0’26 unidades de % de aceite, un Error medio cuadrático 0’13 y una  $R^2$  de 0’85.

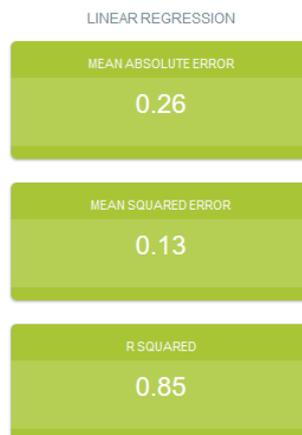
En la siguiente gráfica se puede visualizar la comparativa entre el % de aceite real obtenido, y la predicción que lleva a cabo el modelo.



% aceite en taladrina real vs. Predicción del modelo (test regresión lineal)

Fuente: AIDIMME.

A continuación, se muestra la comparativa de los tres indicadores de precisión del modelo.



Indicadores precisión del modelo predictivo (test regresión lineal. Fuente: AIDIMME.

“VIRTUAL SENSE” – Resumen de resultados.

En la fase de test, la precisión del modelo ha bajado.

### 3.5 CONCLUSIONES

Tras el desarrollo y testeo de modelos predictivos que dan lugar a los tres sensores virtuales definidos se puede concluir que:

Para el sensor virtual 1. Medida de la viscosidad de un barniz.

- No hace falta ajustar y desarrollar modelos de forma específica para cada tipo de barniz para conseguir una precisión elevada. Se puede tomar la variable “tipo de barniz” como una variable de entrada de un modelo más genérico, con una precisión muy elevada.
- La generación de datos para el entrenamiento del modelo puede realizarse fuera de un entorno productivo, lo que agiliza la generación del dataset.
- Al depender exclusivamente de la temperatura del barniz, con un dataset relativamente pequeño (50-100 medidas repartidas entre todo el rango de temperaturas del barniz), puede entrenarse un modelo con bastante precisión.
- La precisión del modelo generado es apta para el objetivo deseado.

Para el sensor virtual 2. Medida del gramaje de barniz aplicado.

- En entrenamiento de un modelo requiere de un dataset amplio, con una gran cantidad de registros para lograr que sea representativo.
- La generación de datos para el entrenamiento del modelo no puede realizarse fuera de un entorno productivo, requiere la utilización de la máquina barnizadora.
- Para reducir el tiempo de generación del dataset, deben de modificarse las condiciones de trabajo de la máquina (velocidades y tipos de barniz) para abarcar más rangos de medida en menor tiempo.
- La precisión del modelo generado es apta para el objetivo deseado.

Para el sensor virtual 3. Medida de la concentración de aceite en la taladrina.

- En entrenamiento de un modelo requiere de un dataset amplio, con una gran cantidad de registros para lograr que sea representativo. Con el dataset generado para el desarrollo del sensor, no se consigue ningún modelo con una precisión  $R^2 > 0'9$  en la fase de test.
- La generación de datos para el entrenamiento del modelo no puede realizarse fuera de un entorno productivo, requiere la utilización de un torno de decoletaje.
- La mayoría de variables de las que depende el modelo no pueden ser modificadas (temperatura y humedad ambiente, consumo energético, temperatura aceite, etc.). Para generar un dataset con mayor calidad de información, la única solución es alargar

“VIRTUAL SENSE” – Resumen de resultados.

- en el tiempo la fase de captura de datos, o introducir nuevas variables como el material de trabajo en la máquina, que si puede ser controlado.
- La precisión del modelo generado es debe ser mejorada para el objetivo deseado.

## 4 PRUEBAS PILOTO Y VALIDACIÓN

El objetivo de este paquete de trabajo es desarrollar dos pruebas piloto en dos empresas colaboradoras, con objeto de validar el funcionamiento de los sensores virtuales desarrollados, adaptados a las necesidades de los procesos industriales analizados en el PT3 y evaluar la aplicación de la tecnología.

### 4.1 OBJETIVO DE LOS PILOTOS

Los dos sensores virtuales diseñados para el sector madera/mueble han sido desarrollados sobre una máquina barnizadora de rodillos para piezas planas ubicada en AIDIMME. Se trata de un equipo utilizado para demostraciones y formación en procesos de barnizado que ha podido ser empleado sin restricciones para los tests de desarrollo de los sensores virtuales.

Los principales resultados obtenidos durante la fase de desarrollo han sido:

- Un sensor virtual que mide con precisión la viscosidad de 3 barnices diferentes en base a la temperatura del mismo.
- Un sensor virtual que mide el gramaje aplicado en función del tipo de barniz, y las condiciones de trabajo (temperatura barniz, velocidades de avance y rodillos, apriete de rodillos)

Durante estos test se ha podido controlar el tipo de barniz empleado, las velocidades del tapiz, el rodillo aplicador, el rodillo dosificador, y la distancia entre rodillos. Incluso se ha podido controlar (en cierta medida) la temperatura del barniz aplicado mediante su enfriado previo en cámara climática, y posterior subida de temperatura mediante la resistencia eléctrica que lleva incorporada la máquina en su depósito.

Durante el piloto se replica el procedimiento de generación de los dos sensores virtuales en una instalación industrial real, donde no va a ser posible modificar los parámetros de trabajo de la máquina (será los requeridos por necesidades de producción), ni el tipo de barniz, ni la temperatura del mismo.

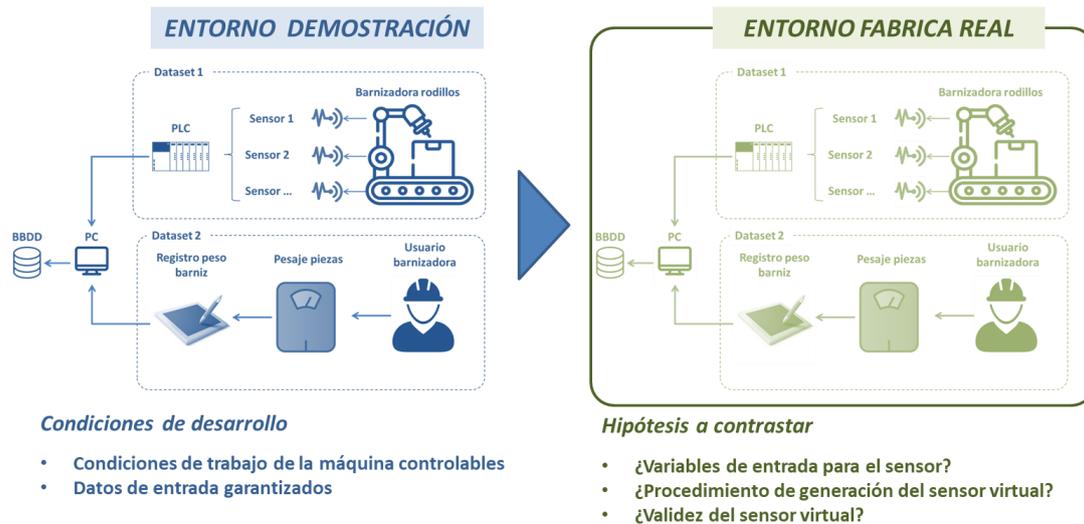
Por tanto, el objetivo de la prueba piloto en un entorno industrial se puede resumir en la corroboración de las siguientes premisas o hipótesis:

- HP1-1.- Las variables de entrada para la generación de los sensores virtuales en un entorno industrial real, son las mismas que para el entorno de demostración.

“VIRTUAL SENSE” – Resumen de resultados.

- HP1-2.- El procedimiento de generación de los sensores virtuales se mantiene constante y no necesita ser modificado, para el desarrollo del sensor en un entorno industrial real.
- HP1-3.- Los sensores virtuales obtenidos para un entorno industrial real tienen una precisión adecuada para considerarlos como válidos.

A continuación, se muestra un esquema con las diferencias básicas de ambos entornos de desarrollo, y el resumen de las hipótesis a contrastar.



Esquema de objetivos del piloto madera/mueble.

Fuente: AIDIMME.

El sensor virtual diseñado para el sector metalmecánico ha sido desarrollado sobre un torno de decoletaje ubicada en la empresa Factor SL. Se trata de un equipo empleado al 100% en tareas de producción, con una carga de trabajo muy alta. Por tanto, el entorno de trabajo para el desarrollo de este sensor es el de fábrica real.

Los principales resultados obtenidos durante la fase de desarrollo han sido:

- Un sensor virtual que mide la concentración de aceite en la taladrina, empleada como lubricante durante el proceso de arranque de viruta.

Durante el test efectuado para la toma de datos, que han permitido desarrollar el sensor, no se han podido modificar las condiciones externa (temperatura y humedad ambiente), ni las condiciones de trabajo (consumo corriente, temperatura taladrina, tipo de material mecanizado, etc.), derivadas de las propias necesidades de producción.

El desarrollo del sensor, ha contado con el hándicap de necesitar una elevada carga de datos manuales (tipo de material trabajado, fecha de relleno, cantidad adicionada, etc.), que se genera de manera puntual (1 vez por turno), por lo que el volumen de datos generado ha sido escaso.

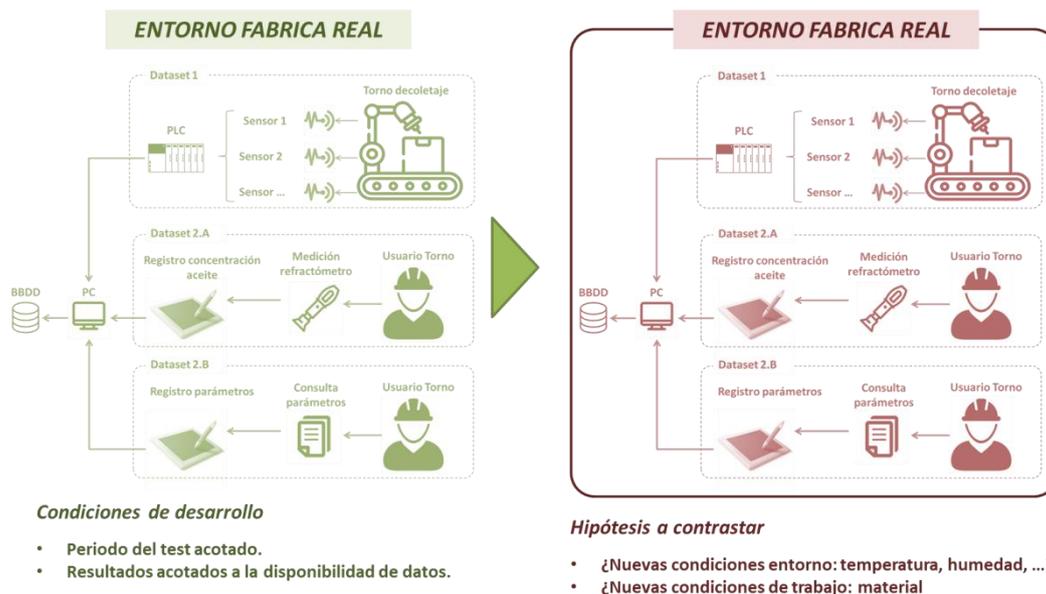
“VIRTUAL SENSE” – Resumen de resultados.

Durante el piloto planteado, el procedimiento de desarrollo del sensor se mantiene constante. En éste caso, el interés del piloto se centra en lograr testar la validez del sensor en condiciones externas diferentes a las del desarrollo del PT5, y con nuevos materiales de trabajo.

Por tanto, el objetivo de la prueba piloto en un entorno industrial se puede resumir en la corroboración de las siguientes premisas o hipótesis:

- HP2-1.- El sensor virtual es válido para condiciones externas (temperatura y humedad) diferentes a las utilizadas en los test de desarrollo.
- HP2-2.- El sensor virtual es válido para materiales de trabajo diferentes a los empleados durante los test de desarrollo.

A continuación, se muestra un esquema con las diferencias básicas de ambos entorno de desarrollo, y el resumen de las hipótesis a contrastar.



Esquema de objetivos del piloto metalmecánico.

Fuente: AIDIMME.

## 4.2 DESARROLLO DE LOS PILOTOS

### 4.2.1 SENSOR VIRTUAL 1

Se han realizado el ensayo de viscosidad de 2 tipos de pinturas empleados por Royo en el proceso de acabado, para generar un dataset que permita entrenar el modelo matemático que dará lugar al sensor virtual 1. Se trata de un barniz de coloración gris (GR16) y otro barniz de coloración blanca (BC0 BL1)

“VIRTUAL SENSE” – Resumen de resultados.

El ensayo consiste en registrar la temperatura del material, llenar una copa de vaciado normalizada (ASTM Ford nº 4, que es la que utiliza la empresa en sus test de calidad) y registrar el tiempo que tarda en vaciarse. En función de la copa normalizada escogida, la ecuación para transformar el tiempo de vaciado en centiStokes (unidad de medida de la viscosidad cinemática) difiere.

Los ensayos de viscosidad realizados con las muestras de Royo, han seguido el mismo procedimiento que el llevado a cabo con los tres barnices empleados en el Paquete de Trabajo PT5.

Como se indica en el procedimiento, cada material de acabado debe de acondicionarse previamente para lograr un rango de mediciones que abarque temperaturas desde temperaturas bajas (5°C) a temperaturas altas (40°C). Para ello, se recurre a un equipo de refrigeración (para bajar de temperatura ambiente) y una cámara climática (para aumentar la temperatura por encima de temperatura ambiente).

Tras acondicionar los productos mediante la nevera o la cámara climática, a las condiciones de temperatura deseada, estos se remueven meticulosamente para evitar las posibles deposiciones que se hayan podido realizar en el fondo y se extrae una muestra del producto.

Inicialmente se realiza la toma de temperatura de la muestra, mediante una sonda de temperatura que se introduce en dicha muestra.

A continuación con dicha muestra se procede a llenar la copa Ford número 4 enrasando el producto con el borde de la copa. Esto se realiza con la boquilla de la copa tapada para que no se salga el producto antes de iniciar el cálculo de la viscosidad.

El producto sale a través de la boquilla de la copa de forma que se forma un hilo de material. Este hilo debido a la viscosidad llegará a cortarse en un momento determinado.

El tiempo que transcurre desde el inicio hasta el corte del hilo de material, es el que tiempo a tomar para conocer la viscosidad del producto.

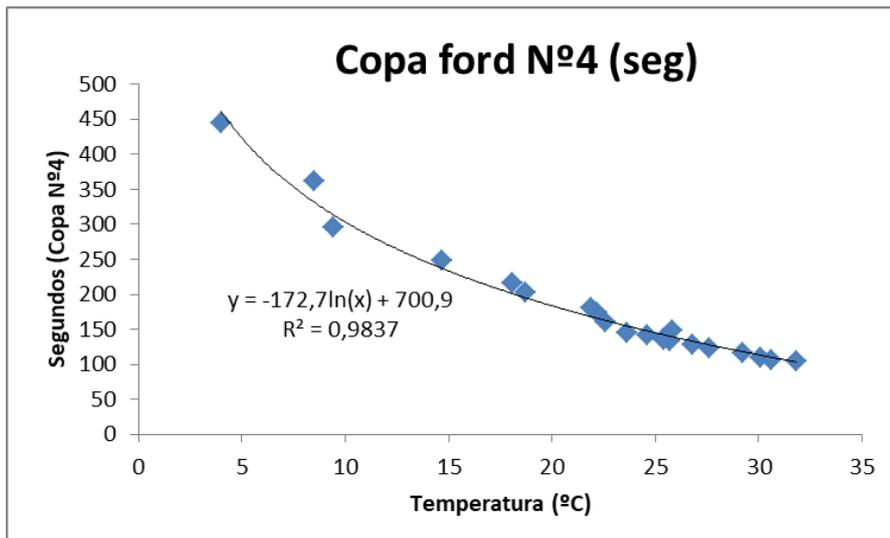
Cuando se ha recorrido todo el rango de temperaturas deseado se finaliza el ensayo con ese material, se procede a la limpieza con disolvente de la copa Ford, y se registran las mediciones en una hoja Excel para su posterior tratamiento.

Para el caso de las muestras de pinturas de Royo con los ensayos de viscosidad, que se han llevado a cabo se obtienen los resultados que se pueden ver representados en las siguientes gráficas.

#### Datos de la muestra de pintura GR16 de Royo.

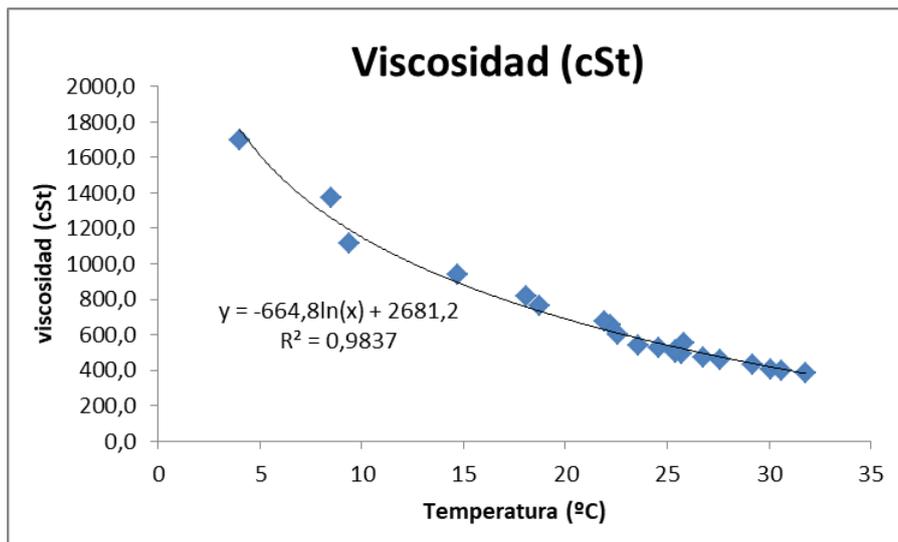
La primera gráfica muestra la viscosidad medida en segundos de copa Ford nº4, respecto de la temperatura del barniz. La segunda gráfica, presenta el eje y transformado a centiStokes según la tabla de conversiones de la norma ASTM.

“VIRTUAL SENSE” – Resumen de resultados.



Datos con Copa Ford 4 de pintura GR16.

Fuente: Aidimme.



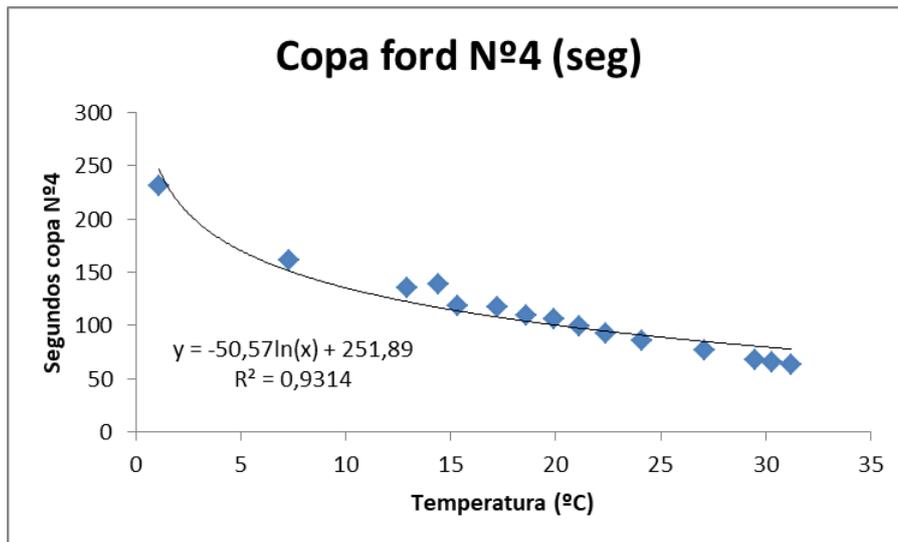
Gráfica de viscosidad en centistoks de la pintura GR16.

Fuente: Aidimme.

Datos de la muestra de pintura BL1 de Royo

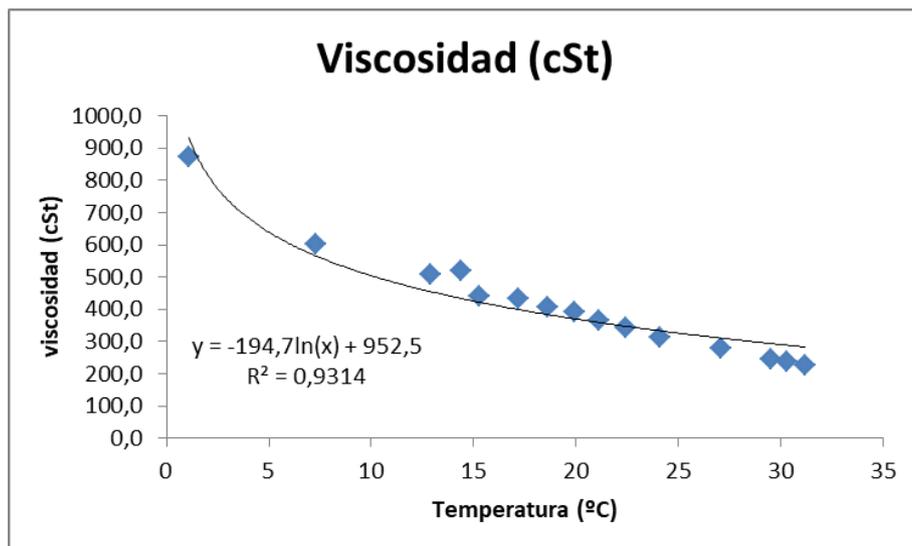
La primera gráfica muestra la viscosidad medida en segundos de copa Ford n°4, respecto de la temperatura del barniz. La segunda gráfica, presenta el eje y transformado a centiStokes según la tabla de conversiones de la norma ASTM.

“VIRTUAL SENSE” – Resumen de resultados.



Datos con Copa Ford 4 de la pintura BL1.

Fuente: Aidimme.



Gráfica de viscosidad en centistoks de la pinturaBL1.

Fuente: Aidimme.

Se puede observar como existe una fuerte correlación entre la temperatura del barniz y la viscosidad en ambos casos.

#### 4.2.2 SENSOR VIRTUAL 2

El montaje en la empresa del piloto, implica la instalación en la cabina de los siguientes elementos:

“VIRTUAL SENSE” – Resumen de resultados.

- Dos sondas de temperatura con certificación Atex clase 3, a colocar en los depósitos de pintura.



*Sondas de temperatura Atex 3.*

*Fuente: AIDIMME.*

- Dos sensores lineales para medir el apriete (distancia) entre el rodillo aplicador y el rodillo dosificador.

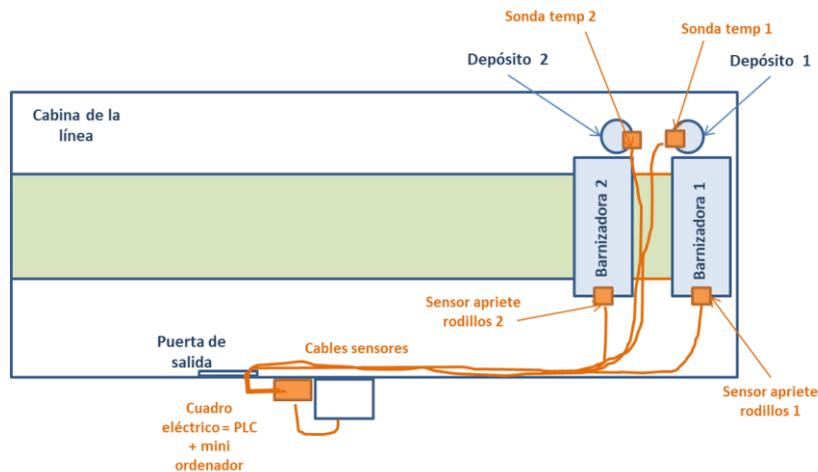


*Detalle sensores lineales.*

*Fuente: AIDIMME.*

- Cable apantallado de conexión de los sensores. Se requiere cable apantallado de 2 hilos desde los cuatro sensores hasta la zona donde se ubica el cuadro eléctrico, fuera de la cabina de barnizado, tal y como se muestra en el siguiente esquema.

“VIRTUAL SENSE” – Resumen de resultados.



Esquema de la instalación en Royo Spain S.L.

Fuente: AIDIMME.

Fuera de la cabina, al lado de la puerta de salida y de un pilar con toma de corriente eléctrica se ubica:

- El cuadro eléctrico que contiene un PLC, fuente de alimentación, tarjeta de adquisición de datos, y un mini ordenador.
- 



Detalle Interior cuadro toma datos.

Fuente: AIDIMME.

Dado que se va aplicar una técnica de machine learning por aprendizaje supervisado, para desarrollar el sensor deben de generarse dos tipos de datasets:

- Dataset 1: Se trata de los parámetros variables en la máquina: dado que la velocidad del tapiz, velocidad del rodillo aplicador y velocidad rodillo dosificador se mantienen

“VIRTUAL SENSE” – Resumen de resultados.

constantes, se genera un dataset de las mediciones de los sensores de distancia entre rodillos y viscosidad del barniz (mediante la captura de la temperatura del mismo).

- Dataset 2: Se trata del output del sensor, consistente en el peso real del barniz aplicado en las condiciones del dataset 1.

Para la captura de los datos necesarios para ambos datasets se requiere tanto la instalación de un sistema de captura de datos en la máquina, como del registro manual del peso de las piezas que se barnicen.

Los datos de los sensores se capturan de forma continua y automática a lo largo del tiempo mediante el PLC ubicado en el cuadro eléctrico del piloto. El PLC comunicará con un PC para realizar un volcado y guardado de los mismos en una base de datos definida para el proyecto.

Por otro lado, el registro de gramaje del acabado aplicado requiere del pesaje de las piezas antes y después de ser pintadas, siendo el gramaje aplicado la diferencia entre ambas magnitudes.

El registro del peso se realiza mediante el paso por la línea de barnizado de una pieza probeta de dimensiones 100 x 100 mm, registrando en una plantilla en papel el peso antes y después de barnizar, así como el tipo de barniz. Los propios operarios de la línea de barnizado realizan estas mediciones de forma puntual varias veces por turno durante la duración de la validación. Esta información se pasa posteriormente a un archivo de hoja de cálculo .xls.

Se ha generado un dataset que contiene los datos de los dos tipos de barniz trabajados en el piloto, justo con los valores de los sensores de apriete entre rodillos (indicados en el dataset como “dist1” y “dist2”), los valores de las dos sondas de temperatura del barniz (indicadas como “temp1” y “temp2” en el dataset) y el gramaje real registrado por los operarios.

En la siguiente imagen se muestra un extracto del dataset generado.

	A	B	C	D	E	F
1	Barniz	dist1	dist2	temp1	temp2	gramaje
2	0	4,384033	2,696346	28,7591	28,7498	20,49814
3	0	4,387703	2,705758	25,7897	25,77208	13,574241
4	0	4,283115	2,722221	25,4795	25,50726	13,487746
5	0	4,284849	2,700409	30,8172	30,90924	16,696275
6	0	4,262289	2,778659	32,8302	32,83846	16,7583514
7	0	4,346087	2,722052	27,7243	27,70738	19,0848962
8	0	4,363028	2,735356	34,3671	34,46088	16,7299968
9	0	4,390879	2,731032	32,0376	32,10483	16,7598464
10	0	4,264426	2,657684	26,5655	26,5442	13,7522756
11	0	4,256871	2,630355	28,7233	28,73762	20,4988424
12	0	4,298683	2,614126	26,9431	26,84418	16,7458189
13	0	4,393947	2,721756	32,6034	32,65182	16,7734401
14	0	4,32972	2,662192	29,4678	29,49286	20,4776191
15	0	4,367769	2,628841	27,6084	27,53542	18,0414642
16	0	4,217884	2,624197	33,6231	33,52622	16,7344922
17	0	4,254842	2,78357	26,644	26,55161	13,7677001
18	0	4,389691	2,626256	32,913	32,92093	16,752843
19	0	4,349989	2,633207	27,0525	27,12453	16,7632302
20	0	4,363637	2,74969	32,5697	32,58261	16,7756823
21	0	4,330677	2,701765	33,6639	33,76261	16,7344908
22	0	4,309746	2,641658	28,0095	28,00058	20,4989551
23	0	4,263878	2,795577	32,7493	32,73595	16,7637338
24	0	4,254917	2,776712	34,8399	34,77885	16,7139985
25	0	4,355341	2,776064	28,9412	28,98936	20,4945727
26	0	4,245303	2,679544	25,1522	25,25169	13,405969
27	0	4,399086	2,65152	29,7201	29,68846	20,4609027
28	0	4,326376	2,767024	31,2387	31,2517	16,689703
29	0	4,359826	2,718809	30,6755	30,64481	16,6771119
30	0	4,342538	2,765692	31,8585	31,92899	16,7469315
31	0	4,321444	2,744444	34,8712	34,94947	16,713315
	0			32,5594		16,763676

Extracto del dataset generado Fuente: AIDIMME.

“VIRTUAL SENSE” – Resumen de resultados.

En el dataset generado la distancia entre rodillos tanto en la primera, como en la segunda etapa de barnizado se mantiene casi constante (entre 0’42 y 0’44 mm la primera etapa y 0’26 y 0’28 la segunda etapa). La temperatura de ambos barnices ha sido muy similar, situándose en un rango entre 25°C y 35 °C.

Columna1	dist1	dist2	temp1	temp2
Promedio	4,300	2,700	29,964	29,963
Min	4,200	2,601	25,007	24,919
Max	4,400	2,800	34,985	35,025

Rango de los datos empleados.

Fuente: AIDIMME.

### 4.2.3 SENSOR VIRTUAL 3

El montaje en la empresa del piloto es el mismo que el realizado durante el paquete de trabajo PT5, que implicó la instalación en el torno de decoletaje de los siguientes elementos:

- Una sonda de temperatura de líquido.
- Un sensor de medición del nivel del depósito.
- Un sensor de medición del consumo de corriente de la máquina.
- Un sensor de medición de la temperatura y humedad ambiente (de la zona de la planta donde se ubica la máquina).

Dado que se va aplicar una técnica de machine learning por aprendizaje supervisado, para desarrollar el sensor deben de generarse tres tipos de datasets:

- Dataset 1: Se trata de los parámetros que se pueden capturar mediante los sensores instalados: temperatura de la emulsión de taladrina, nivel del depósito, corriente consumida por la máquina, temperatura ambiente y humedad ambiente.
- Dataset 2.A: constando de las medidas reales de concentración de aceite en la taladrina realizadas mediante un refractómetro.
- Dataset 2.B: consta de todos aquellos parámetros considerados relevantes para generar el modelo, pero cuya captura no se puede realizar de forma automática y se capturan registrándose de forma manual.

La captura de datos temperatura y humedad ambiente, temperatura de la emulsión de taladrina, volumen del depósito y corriente se lleva a cabo mediante los sensores, que conectados a un PLC pueden registrar los parámetros de forma continua y automática a lo largo del tiempo. El PLC comunica con un PC para realizar un volcado y guardado de los mismos en una base de datos definida para el proyecto.

Por otro lado, el registro del material de trabajo, tiempos de trabajo, fecha de relleno de taladrina en el depósito, concentración de taladrina adicionada, volumen añadido, y concentración de taladrina real (medida con un refractómetro) se deben de llevar a cabo de

“VIRTUAL SENSE” – Resumen de resultados.

forma manual ya que no es posible su captura automática. El registro de las mismas se va a llevar a cabo mediante una aplicación informática, volcándose los mismos de forma automática en una base de datos.

Como resultado se han obtenido los dos dataset que son empleados para el aprendizaje y generación del modelo de cálculo del sensor virtual 3. Por un lado, un data set con toda la información de los sensores, y por otro las registradas de manera manual como la cantidad de taladrina adicionada, el tiempo entre relleno del depósito o la concentración de aceite real medida con un refractómetro.

Toda esta información se unifica en un solo dataset buscando las marcas temporales de ambos dataset. En la siguiente figura se muestra un ejemplo del dataset final generado para el entrenamiento de diferentes modelos predictivos.

	A	B	C	D	E	F	G	H
1	Corriente	cantidad	humAmbien	nivelVaciad	tempAmbier	tempMezcla	tiempoRelle	concentracion
2	10,9626442	0	64,3950469	2,44658968	17,2460824	40,717486	2	5,30442969
3	13,0573316	0	69,8342078	2,76761182	18,2556405	40,8663449	2	5,66325519
4	13,461718	0	62,2108984	4,1343876	33,8110559	37,1477235	2	7,07360849
5	12,9455659	0	70,8869161	4,53033255	15,5967984	49,2062255	3	5,60351421
6	13,4190529	0	72,0707479	5,32256936	20,3670023	37,0829106	3	6,43646983
7	13,3462704	0	56,5082541	9,55497927	27,8351683	39,3328161	4	7,58664767
8	12,1734892	0	77,4050645	10,3775974	20,8882731	36,9168138	4	7,21820339
9	13,2774739	0	64,2923216	10,5510756	25,0245071	53,6572695	4	7,33749699
10	13,006535	0	61,1398434	10,9804395	18,6342709	40,4021601	5	7,22979871
11	12,9883046	0	63,2062019	11,994485	23,7513894	38,5863955	6	7,98067128
12	12,1967039	0	62,0024891	12,2587136	21,1043369	52,9680928	6	7,48698707
13	13,0785021	10	65,3418632	1,36094273	28,7519187	35,6349054	0	6,39012527
14	11,3520794	0	47,7024392	2,66989982	26,2727967	32,0008821	0	5,87150282
15	13,0249335	0	64,8640599	5,31327362	27,8792546	47,0246879	1	6,69272065
16	13,0981584	0	81,513726	6,16254193	12,226087	45,520981	1	5,51849929
17	11,9282158	0	65,6788805	7,08430897	17,2801433	38,2227414	2	6,02488107
18	13,3448816	0	53,7345084	8,35631694	23,783465	39,6264889	2	6,92614864
19	12,4854557	0	63,0431774	8,64645207	24,6048044	31,4594733	3	7,26396365
20	13,178556	0	57,6819641	10,009657	21,3185656	39,0058329	3	7,11563277
21	12,2815532	0	67,7458086	11,5011803	18,0044592	33,48548	3	7,02184401
22	12,201641	0	80,6943646	11,8123648	21,6243554	30,0050724	4	7,44823858
23	11,1639904	0	65,7472123	13,1186406	17,1012416	44,7487499	4	7,17501313
24	12,5013333	0	73,1203989	14,2319135	26,3163969	42,7735331	5	8,1049473
25	11,1756939	0	40,8857685	14,9260391	20,6208826	42,0541335	5	7,1895182
26	11,7002982	0	78,4411316	15,216601	19,6969241	46,0506037	6	7,88905996
27	12,6000	0	51,3830198	15,65	0,1716502	39,177288	6	8,3040210

Extracto del dataset generado en el piloto para el entrenamiento de modelos predictivos.

Fuente: AIDIMME.

“VIRTUAL SENSE” – Resumen de resultados.

### 4.3 RESULTADO DEL PILOTO

Únicamente se mostrará el método que ha conseguido mayor precisión en el grado de ajuste de la previsión con los datos reales generados y recogidos.

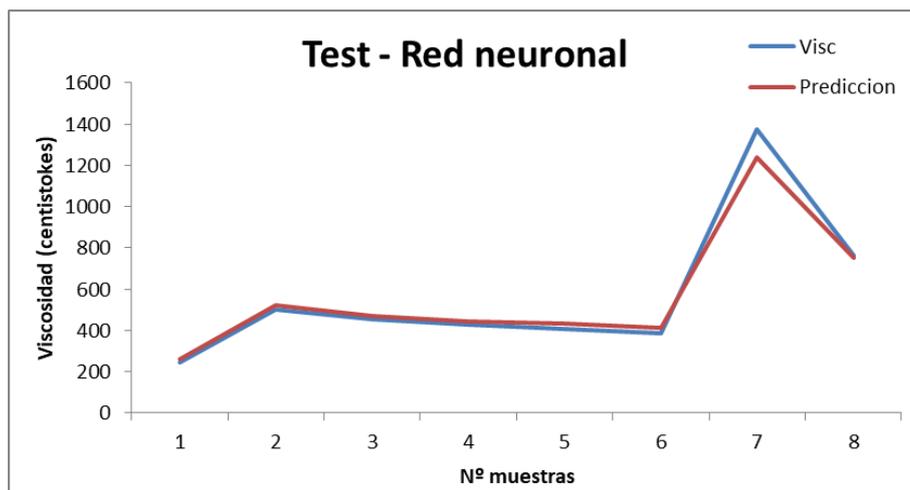
#### 4.3.1 SENSOR VIRTUAL 1

##### Modelo con Red Neuronal

Tras realizar el entrenamiento de un modelo mediante redes neuronales se obtiene un modelo que se ajusta bastante a los datos de entrenamiento con un Error medio absoluto de 29’03 centiStokes, un Error medio cuadrático 2.445’21 y una  $R^2$  de 0’97.

Tras realizar el test del modelo previamente entrenado mediante redes neuronales se obtiene un Error medio absoluto de 31’40 centiStokes, un Error medio cuadrático 2.482’33 y una  $R^2$  de 0’98.

En la siguiente gráfica se puede visualizar la comparativa entre la viscosidad real obtenida, y la predicción que lleva a cabo el modelo.

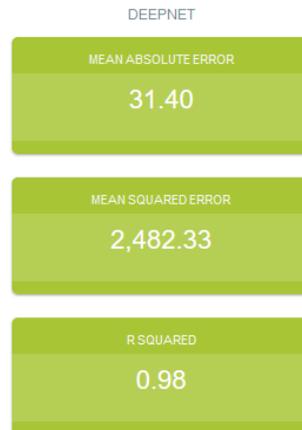


Viscosidad real vs. Predicción del modelo (test red neuronal)

Fuente: AIDIMME.

A continuación, se muestra la comparativa de los tres indicadores de precisión del modelo.

“VIRTUAL SENSE” – Resumen de resultados.



Indicadores precisión del modelo predictivo (test red neuronal)

Fuente: AIDIMME.

La  $R^2$  de 0'98 en la fase de test, muestran que el modelo generado es muy robusto y preciso para predecir la viscosidad.

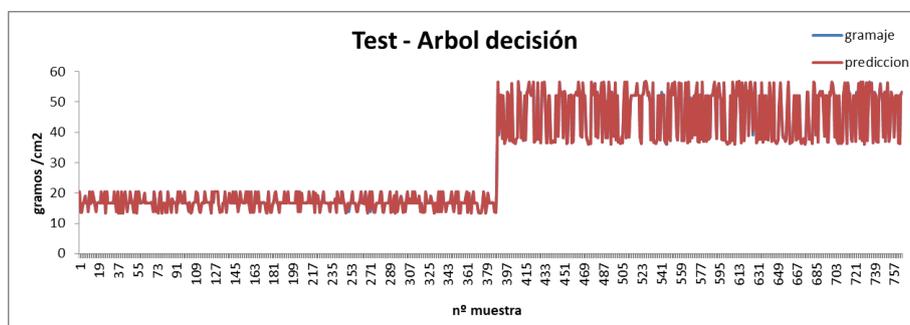
### 4.3.2 SENSOR VIRTUAL 2

#### Modelo con Árbol de decisión Aleatorio

Tras realizar el entrenamiento de un modelo mediante un árbol de decisión aleatorio se obtiene un modelo que se ajusta bastante a los datos de entrenamiento con un Error medio absoluto de 0'07 gramos/m<sup>2</sup>, un Error medio cuadrático 0'15 y una  $R^2$  de 1. Los indicadores para el dataset de entrenamiento son mejores que para el modelo de red neuronal.

Tras realizar el test del modelo previamente entrenado mediante redes neuronales se obtiene un Error medio absoluto de 0'03 gramos/m<sup>2</sup>, un Error medio cuadrático 0'03 y una  $R^2$  de 1.

En la siguiente gráfica se puede visualizar la comparativa entre el gramaje real obtenido, y la predicción que lleva a cabo el modelo.

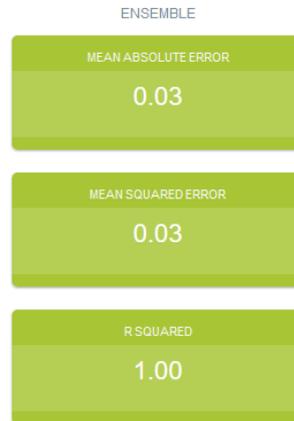


Gramaje real vs. Predicción del modelo (test árbol de decisión aleatorio)

Fuente: AIDIMME.

“VIRTUAL SENSE” – Resumen de resultados.

A continuación, se muestra la comparativa de los tres indicadores de precisión del modelo.



*Indicadores precisión del modelo predictivo (test árbol de decisión aleatorio)*

*Fuente: AIDIMME.*

Un error de hasta 10 gramos / m<sup>2</sup> se considera por los expertos en barnizado de piezas planas aceptable. En éste sentido el Error medio absoluto se sitúa por debajo de éste límite.

El modelo se puede considerar como de alta precisión.

### 4.3.3 SENSOR VIRTUAL 3

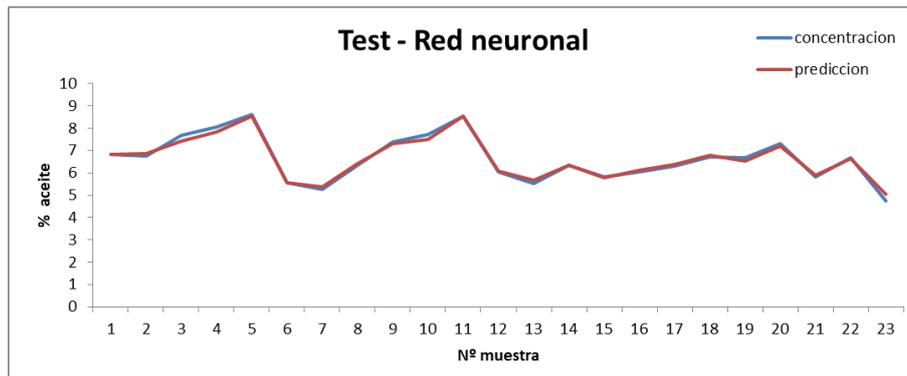
#### Modelo con Red Neuronal

Tras realizar el entrenamiento de un modelo mediante redes neuronales se obtiene un modelo que se ajusta bastante a los datos de entrenamiento con un Error medio absoluto de 0'05 unidades porcentuales de % de aceite, un Error medio cuadrático 0'01 y una R<sup>2</sup> de 0'99.

Tras realizar el test del modelo previamente entrenado mediante redes neuronales se obtiene un Error medio absoluto de 0'1 unidades porcentuales de % de aceite, un Error medio cuadrático 0'02 y una R<sup>2</sup> de 0'98.

En la siguiente gráfica se puede visualizar la comparativa entre el % de aceite real obtenido, y la predicción que lleva a cabo el modelo.

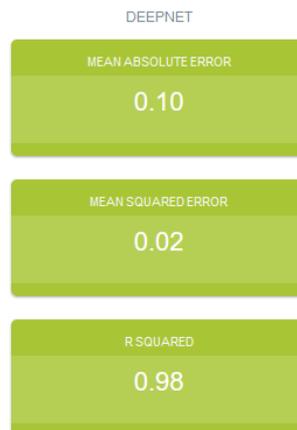
“VIRTUAL SENSE” – Resumen de resultados.



% aceite real vs. Predicción del modelo (test red neuronal)

Fuente: AIDIMME.

A continuación, se muestra la comparativa de los tres indicadores de precisión del modelo.



Indicadores precisión del modelo predictivo (test red neuronal)

Fuente: AIDIMME.

La precisión del modelo tras la fase de test se mantiene similar a la fase de entrenamiento.

## 4.4 CONCLUSIONES

A continuación se listan las principales conclusiones extraídas de las pruebas piloto realizadas:

- Se ha desarrollado un método de generación de sensores virtuales que ha sido validado en un entorno industrial, mediante el desarrollo y validación de tres tipos de sensores virtuales:
  - 1 sensor virtual para el cálculo de la viscosidad del barniz, en un proceso de barnizado de piezas planas de tablero de madera.
  - 1 sensor virtual para el cálculo del gramaje aplicado a una pieza plana, en un proceso de barnizado de piezas planas de tablero de madera.

“VIRTUAL SENSE” – Resumen de resultados.

- 1 sensor virtual para el cálculo de la concentración de aceite en la taladrina, en un proceso de torneado de piezas metálicas.
  
- Se ha generado un sensor virtual 1 basado en un modelo de redes neuronales para predecir con gran precisión la viscosidad de un barniz en base a la temperatura del mismo.
  
- Para el sensor virtual 1, como solo hay una variable de entrada, con un experimento donde se recojan 20-30 de entrada se puede entrenar un modelo inicial con gran precisión.
  
- Se ha generado un sensor virtual 2 basado en árboles de decisión que predice con buena precisión el gramaje aplicado. En el caso de una línea de producción real, las variables de entrada al modelo se han reducido, ya que la línea opera con velocidades de trabajo fijas (para lograr un gramaje objetivo).
  
- Se ha generado un sensor virtual 3 basado en redes neuronales que predice con buena precisión la concentración de aceite en la taladrina. En el caso de este tercer sensor virtual los tres modelos presentan una precisión similar a la hora de predecir el valor buscado.
  
- Para que la precisión de los sensores virtuales 2 y 3 sea adecuada, se requiere de experimentos específicos y mediciones reales de las variables a predecir (gramaje y concentración de aceite) con una frecuencia elevada. Si no se realiza así, el tiempo requerido para generar un dataset con datos suficientes es muy elevado.