


eman ta zabal zazu



Universidad  
del País Vasco

Euskal Herriko  
Unibertsitatea

Grado en Ingeniería Informática  
Computación

Trabajo de Fin de Grado

---

**Procesado y análisis de datos procedentes de  
una máquina de extrusión de polímeros**

---

Autor

*Jon Vadillo Jueguen*

informatika  
fakultatea



facultad de  
informática

2018



---

## Resumen

---

Este Trabajo de Fin de Grado se circunscribe dentro de un proyecto real más amplio, desarrollado en el entorno de la *Industria 4.0*. El objetivo principal del TFG consiste en realizar, a modo de prueba de concepto, un análisis de datos procedentes de una máquina de extrusión de polímeros, con la finalidad de mostrar la viabilidad y el interés de la aplicación de recursos computacionales enfocados a la fabricación avanzada.

Para ello, en primer lugar, se han seleccionado, implementado y validado múltiples técnicas de preprocesado para el tratamiento inicial de los datos. En segundo lugar, se ha analizado, de manera experimental, el comportamiento de diversos modelos de minería de datos en diferentes escenarios, con la finalidad de evaluar el potencial del uso de estos recursos.

Por último, tras describir las aportaciones más relevantes, se proponen varias vías de mejora y líneas futuras abiertas que faciliten el desarrollo de objetivos más ambiciosos a largo plazo.



---

## **Agradecimientos**

---

Antes de comenzar, me gustaría agradecer la ayuda recibida por todas las personas que han formado parte de este proyecto.

En primer lugar, agradecer a los directores del proyecto, Borja Calvo y Arantza Illarramendi, por su compromiso con el proyecto y por todo lo que he aprendido a través de sus consejos. Considero sinceramente que este trabajo no podría haber estado mejor dirigido.

Por otro lado, quisiera mostrar mi más sincera gratitud a todos los miembros de la empresa Savvy Data Systems, en particular a su director Fernando Sáenz, por la confianza depositada en mí para colaborar en uno de sus proyectos, y agradecerles haberme ofrecido su ayuda cada vez que la he necesitado. Del mismo modo, agradecer a la empresa Urola, y en particular a Gurutz Galfarsoro, por resolvernos todas y cada una de las dudas técnicas que se nos iban generando a lo largo del proyecto.

Por último, pero no por ello menos importante, agradecer a los integrantes del grupo de investigación BDI, en particular a Kevin Villalobos y a Borja Díez, por sus consejos a lo largo de estos meses, y por todo el apoyo proporcionado, tanto a nivel profesional como personal.



---

# Índice general

---

<b>Resumen</b>	<b>I</b>
<b>Índice general</b>	<b>v</b>
<b>Índice de figuras</b>	<b>IX</b>
<b>Indice de tablas</b>	<b>XV</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Contenido . . . . .	2
<b>2. Antecedentes</b>	<b>3</b>
2.1. Empresas interesadas en el proyecto . . . . .	3
2.1.1. Savvy Data Systems . . . . .	4
2.1.2. Urola Solutions . . . . .	5
2.1.3. Fábrica de Jabón La Corona y Bowler Plastics (Pty) Ltd . . . . .	5
2.2. Colaboración interempresarial . . . . .	5
<b>3. Objetivos y Planificación</b>	<b>7</b>
3.1. Objetivos del proyecto . . . . .	7
3.2. Metodología . . . . .	8
3.3. Gestión del tiempo . . . . .	9
	v

<b>4. Comprensión de los datos</b>	<b>11</b>
4.1. Captura de los datos . . . . .	12
4.2. Descripción y visualización de las señales . . . . .	15
4.2.1. Señales de temperatura . . . . .	15
4.2.2. Velocidad de giro del husillo y consumo del motor . . . . .	19
4.2.3. Presión . . . . .	21
4.2.4. Indicador de alarma activa y máquina en marcha . . . . .	22
4.2.5. Producción . . . . .	24
4.3. Análisis de calidad de los datos . . . . .	25
4.3.1. Errores en los datos . . . . .	25
4.3.2. Calidad del conjunto de datos . . . . .	27
<b>5. Preprocesado de los datos</b>	<b>29</b>
5.1. Tratamiento de valores perdidos . . . . .	30
5.1.1. Interpolación lineal . . . . .	30
5.1.2. Interpolación por splines . . . . .	31
5.1.3. Media móvil . . . . .	34
5.1.4. Suavizado de Kalman . . . . .	35
5.1.5. Comparación de los resultados . . . . .	38
5.2. Eliminación de ruido . . . . .	41
5.2.1. Suavizado por promedio . . . . .	42
5.2.2. Suavizado mediante el filtrado frecuencial . . . . .	43
5.3. Discretización . . . . .	47
5.3.1. Espaciado uniforme (Equal Width) . . . . .	48
5.3.2. Frecuencia uniforme (Equal Frequency) . . . . .	49
5.3.3. Algoritmo <i>K-means</i> . . . . .	49



---

5.4.	Alineación de los datos . . . . .	50
5.5.	Tratamiento de valores atípicos . . . . .	55
5.5.1.	Test de Tukey . . . . .	55
5.5.2.	Corrección secuencial de valores contiguos . . . . .	57
5.6.	Mejoras y recursos adicionales . . . . .	57
<b>6.</b>	<b>Análisis de los datos</b>	<b>61</b>
6.1.	Modelos utilizados . . . . .	61
6.1.1.	Modelos probabilísticos . . . . .	62
6.2.	Redes Neuronales Artificiales . . . . .	67
6.3.	Diseño de los análisis . . . . .	70
6.3.1.	Objetivos y consideraciones previas . . . . .	70
6.3.2.	Selección y preparación del conjunto de datos . . . . .	71
6.3.3.	Tipos de análisis . . . . .	72
6.4.	Predicción y modelado de temperaturas . . . . .	73
6.4.1.	Análisis mediante Redes Bayesianas . . . . .	75
6.4.2.	Análisis mediante Redes Neuronales . . . . .	83
6.5.	Predicción de alarmas . . . . .	86
<b>7.</b>	<b>Conclusiones</b>	<b>93</b>
7.1.	Contribuciones técnicas . . . . .	93
7.2.	Contribuciones personales . . . . .	94
<b>8.</b>	<b>Propuestas de mejora y líneas futuras</b>	<b>97</b>
8.1.	Posibles líneas de investigación . . . . .	97
8.1.1.	Optimización de recursos . . . . .	97
8.1.2.	Herramientas de simulación y asistencia . . . . .	99

8.1.3. Control del proceso mediante redes neuronales . . . . .	100
8.2. Propuestas de mejora respecto a la captura de los datos . . . . .	102
8.2.1. Mejoras en cuanto al análisis de temperaturas y configuración . . .	102
8.2.2. Mejoras en cuanto al mantenimiento predictivo . . . . .	103
8.2.3. Mejoras en cuanto a la optimización de recursos y control auto- mático . . . . .	104
<b>Anexos</b>	
<b>A. Extrusión</b>	<b>109</b>
A.1. Elementos principales de una extrusora . . . . .	109
A.2. Modelos de desplazamiento del material . . . . .	111
<b>B. Problemas de optimización y metaheurísticos</b>	<b>117</b>
B.1. Conceptos básicos . . . . .	117
B.2. Problemas de optimización multiobjetivo . . . . .	118
<b>C. Implementación</b>	<b>121</b>
<b>Bibliografía</b>	<b>123</b>

---

## Índice de figuras

---

3.1. Ciclo vital del modelo de proceso definido en CRISP-DM, donde se muestran las distintas fases y sus relaciones principales. . . . .	9
3.2. Diagrama de Gantt donde se muestra la distribución del tiempo de dedicación estimado para las diferentes fases del proyecto. . . . .	10
4.1. Ubicación de los sensores en el cilindro de una extrusora con 4 zonas, donde se pueden visualizar también el resto de elementos principales de la máquina. . . . .	13
4.2. Detalle de la ubicación de los sensores en el cabezal de la extrusora. . . .	14
4.3. Mediciones de un sensor de temperatura en un intervalo aproximado de una semana. . . . .	17
4.4. Señales capturadas por 4 sensores de temperatura situados de manera contigua en el cilindro de la extrusora, en un intervalo aproximado de una semana. . . . .	18
4.5. Señales capturadas por 4 sensores del cabezal de una extrusora, en un intervalo aproximado de una semana. . . . .	19
4.6. Todas las señales de temperatura capturadas en la extrusora, resaltando la temperatura en la última zona del cilindro, la temperatura de fundido y la temperatura en la tercera zona del cabezal. . . . .	20
4.7. Señales correspondientes al consumo del motor, velocidad de giro del husillo y temperatura de fundido. . . . .	21
4.8. Presión y temperatura de fundido capturados en 3 extrusoras diferentes. El lector puede asumir que los valores y proporciones de los ejes son comunes en los 3 gráficos. . . . .	22

4.9. Indicador de alarma activa y máquina activa, donde se ha añadido también la temperatura de fundido a modo de referencia. . . . .	23
4.10. Indicador de producción, donde se han añadido también los indicadores de máquina activa y temperatura de fundido a modo de referencia . . . . .	24
4.11. Detalle de una señal de temperatura, donde podemos apreciar el efecto del ruido. . . . .	27
5.1. Intervalo de datos utilizado para la comparación de los resultados de las técnicas de imputación. . . . .	31
5.2. Resultados obtenidos utilizando la interpolación lineal como método de imputación. . . . .	32
5.3. Resultados obtenidos utilizando la interpolación mediante curvas spline cúbicas como método de imputación. . . . .	32
5.4. Resultados obtenidos utilizando la imputación basada en la interpolación mediante splines en una señal sin ruido. . . . .	33
5.5. Resultados obtenidos utilizando el método de imputación <i>Last Observation Carried Forward</i> . . . . .	33
5.6. Resultados obtenidos utilizando la Media Móvil Simple como método de imputación, con diferentes tamaños de ventana ( $k$ ). . . . .	35
5.7. Resultados obtenidos utilizando la Media Móvil Ponderada Lineal como método de imputación, con diferentes tamaños de ventana ( $k$ ). . . . .	36
5.8. Resultados obtenidos utilizando la Media Móvil Ponderada Exponencial como método de imputación, con diferentes tamaños de ventana ( $k$ ). . . . .	37
5.9. Resultados obtenidos utilizando el suavizado de kalman (usando un modelo estructural) como método de imputación. . . . .	38
5.10. Resultados obtenidos utilizando el suavizado de kalman (usando un modelo ARIMA) como método de imputación. . . . .	39
5.11. Comparación del error obtenido en los diferentes métodos de imputación .	39
5.12. Segundo intervalo (con inestabilidades) para analizar el comportamiento de los métodos de imputación. Las zonas con los valores eliminados se han resaltado en rojo, para facilitar su detección. . . . .	40

---

5.13. Resultados de los métodos de imputación basados en el suavizado de Kalman en un intervalo inestable. . . . .	41
5.14. Efecto del suavizado por promedio en una señal de temperatura, para diferentes tamaños de ventana ( $w$ ). . . . .	42
5.15. Representación de diferentes variaciones para realizar el filtrado por promedio: ventana regular (arriba), ventana de Hamming sin solapamiento (medio) y ventana de Hamming con solapamiento (abajo) . . . . .	43
5.16. Ilustración de la generación de una señal a partir de sinusoides armónicas de distinta frecuencia. Nótese que a medida que aumentamos la frecuencia, también disminuye su amplitud, lo que refleja la magnitud (o "importancia") de tal armónico en la señal objetivo. . . . .	44
5.17. Espectro de magnitud de una señal de temperatura. . . . .	45
5.18. Resultados obtenidos al filtrar el dominio frecuencial de la señal para eliminar el ruido. En las imágenes relativas al espectro de magnitud, se ha añadido en rojo la frecuencia de corte del filtro paso bajo ( $f_c$ ). . . . .	46
5.19. Distribución de valores de la señal de temperatura utilizada para la comparación de los métodos de discretización. . . . .	48
5.20. Discretización de una señal de temperatura en 10 intervalos, utilizando el método <i>equal width</i> . Se han añadido en rojo los límites de los intervalos asignados. . . . .	49
5.21. Discretización de una señal de temperatura en 10 intervalos, utilizando el método <i>equal frequency</i> . Se han añadido en rojo los límites de los intervalos asignados. . . . .	50
5.22. Discretización de una señal de temperatura en 10 intervalos, utilizando el método <i>K-means</i> . Se han añadido en rojo los límites de los intervalos asignados. . . . .	51
5.23. Representación de una extrusora de dos zonas. . . . .	54
5.24. Señal de temperatura utilizada para evaluar las técnicas de tratamiento de valores atípicos. . . . .	55
5.25. Resultados tras el tratamiento de valores atípicos en una señal de temperatura, mediante el método basado en el test de Tukey. . . . .	56

5.26. Resultados tras el tratamiento de valores atípicos en una señal de temperatura, mediante el método presentado en el Algoritmo 1. . . . .	58
6.1. Ejemplo de un grafo acíclico dirigido, con 4 vértices: A,B,C y D. . . . .	63
6.2. Ejemplo de la topología de una red neuronal básica. . . . .	67
6.3. Representación gráfica de la función de propagación y función de activación en una neurona, donde $w_i$ representa el peso de la conexión con la $i$ -ésima neurona de la capa anterior. . . . .	68
6.4. Comparación de tres funciones de activación clásicas en redes neuronales: sigmoide, tangente hiperbólica y <i>Rectified Linear Unit</i> (ReLU). . . . .	68
6.5. Representación gráfica de un problema linealmente separable y dos problemas linealmente inseparables. . . . .	70
6.6. Visualización de las señales de temperatura y la velocidad de giro del husillo (RPM) utilizadas para el análisis. . . . .	74
6.7. Evolución de las temperaturas del cilindro en las dos máquinas utilizadas en el análisis. El lector puede asumir que los ejes verticales de los dos gráficos muestran el mismo intervalo de valores y con la misma escala. . . . .	75
6.8. Correlación entre las variables de los tres conjuntos de datos que utilizaremos para el análisis de temperaturas. . . . .	76
6.9. Densidad de la probabilidad marginal de la temperatura de fundido sin evidencias (arriba), y densidad de la probabilidad condicionada tras la propagación de la evidencia (abajo). . . . .	79
6.10. Estructuras de las redes Bayesianas generadas, para diferentes límites en cuanto al número de padres por nodo. . . . .	80
6.11. Predicción de la temperatura de fundido mediante redes Bayesianas con un máximo de 1 padre por nodo. . . . .	81
6.12. Predicción de la temperatura de fundido mediante una red Bayesiana con un máximo de 2 padres por nodo. . . . .	81
6.13. Predicción de la temperatura de fundido mediante una red Bayesiana sin límites en cuanto a la cantidad de padres por nodo. . . . .	82

---

6.14. Resultados obtenidos al analizar el error de predicción de la temperatura de fundido mediante redes Bayesianas con diferentes restricciones en cuanto al número de padres por nodo. . . . .	82
6.15. Estructuras de las tres redes neuronales generadas para la predicción de temperatura. La anchura de las conexiones refleja la magnitud del peso, el color gris representa un peso negativo y el color negro un peso positivo. . . . .	84
6.16. Resultados obtenidos al predecir la temperatura de fundido mediante el modelo A (red neuronal artificial). . . . .	85
6.17. Resultados obtenidos al predecir la temperatura de fundido mediante el Modelo B (red neuronal artificial). . . . .	85
6.18. Resultados obtenidos al predecir la temperatura de fundido mediante el Modelo C (red neuronal artificial). . . . .	86
6.19. Representación gráfica de una matriz de confusión. . . . .	86
6.20. Resultados obtenidos al predecir el estado de activación de la alarma mediante un clasificador Bayesiano. . . . .	88
6.21. Resultados obtenidos al predecir el estado de activación de la alarma mediante una red neuronal artificial. . . . .	89
6.22. Resultados obtenidos al predecir con 5 minutos de adelanto el estado de activación de la alarma mediante una red Bayesiana. . . . .	90
6.23. Resultados obtenidos al predecir con 5 minutos de adelanto el estado de activación de la alarma mediante una red neuronal artificial. . . . .	91
8.1. Interfaz de la aplicación generada para analizar el comportamiento de la temperatura de fundido al modificar dos variables de temperatura. . . . .	100
8.2. Gráficos tridimensionales dinámicos generados por la aplicación mostrada en la Figura 8.1, donde se visualizan los valores de la temperaturas de fundido predecidos al modificar las temperaturas de las Zonas 2 y 4 del cilindro de una extrusora. . . . .	101
8.3. <i>Workflow</i> básico para una adecuada captura de los datos en cuanto a diversidad en las configuraciones. . . . .	103
A.1. Esquema general de una extrusora. La imagen original ha sido extraída de [Beltrán and Marcilla, 2012] (página 104). . . . .	110

A.2. Características principales de un husillo de extrusión. La imagen original ha sido extraída de [Beltrán and Marcilla, 2012] (página 108). . . . .	111
A.3. Elementos principales del cabezal de una extrusora. La imagen original ha sido extraída de [Beltrán and Marcilla, 2012] (página 113). . . . .	112
A.4. Representación de las 3 zonas principales en una extrusora y la evolución de la presión a lo largo del proceso, utilizando el husillo como referencia. La imagen original ha sido extraída de [Beltrán and Marcilla, 2012] (página 106). . . . .	112
A.5. Características principales del modelo de desplazamiento durante la zona de transición. La imagen original ha sido extraída de [Beltrán and Marcilla, 2012] (página 123). . . . .	114
A.6. Representación gráfica de la <i>longitud de fundido</i> en la zona de transición. La imagen original ha sido extraída de [Beltrán and Marcilla, 2012] (página 124). . . . .	114
A.7. Representación gráfica de los perfiles de velocidad de los flujos principales presentes en la zona de dosificación. La imagen original ha sido extraída de [Beltrán and Marcilla, 2012] (página 128). . . . .	115
B.1. Representación gráfica de un conjunto de soluciones para un problema de optimización de dos funciones objetivo. . . . .	119



---

## Indice de tablas

---

3.1. Dedicación de horas estimadas para cada una de las fases del proyecto. . .	10
4.1. Proporción de valores entre la velocidad de giro del husillo y el consumo del motor, donde se puede comprobar que cuando la velocidad de giro es nula, el consumo de motor también lo es. . . . .	21
4.2. Proporción de valores entre el indicador de máquina activa y la velocidad de giro del husillo . . . . .	23
4.3. Proporción de valores entre el estado de la máquina y el estado de la alarma.	23
5.1. Resultados obtenidos al aplicar el filtro en el dominio frecuencial como método de compresión para una señal de temperatura. . . . .	47
5.2. Ejemplo de una alineación <i>time-driven</i> de dos señales de temperatura. . .	51
5.3. Ejemplo de una alineación <i>product-driven</i> de dos señales de temperatura, donde el material necesita dos segundos para trasladarse de una zona a otra.	52



# CAPÍTULO 1

---

## Introducción

---

Los avances en los sistemas de información han propiciado el desarrollo de métodos innovadores para la explotación de datos de diferentes sectores. Hoy en día, gracias a los recursos tecnológicos que permiten manejar eficientemente grandes volúmenes de datos, estos métodos de explotación consiguen obtener información cada vez más valiosa partiendo de datos en bruto<sup>1</sup>, abriendo así nuevas vías y oportunidades para la extracción de conocimiento que, en muchos dominios, son cada vez más demandadas.

En los últimos años, un sector que ha conseguido beneficiarse de las ventajas que ofrecen estos tipos de procesamiento de datos es el sector industrial. De hecho, el impacto de los sistemas avanzados de información ha sido tan importante que se han establecido conceptos como "*Industria 4.0*"<sup>2</sup> o "*cuarta revolución industrial*" para referirse a la situación actual [Kagermann et al., 2013]. A raíz de eso, cada vez más empresas están apostando por un proceso de digitalización, con el objetivo de poder beneficiarse de las ventajas que proporcionan estas tecnologías.

En este Trabajo de Fin de Grado (TFG, en adelante), se va a desarrollar un análisis de los datos de una empresa que está en un proceso de digitalización, la cual produce botellas de plástico a través de procesos químicos. Para llevar a cabo el análisis, se van a utilizar diferentes recursos computacionales, centrándonos principalmente en el uso de técnicas de minería de datos.

---

<sup>1</sup>El término datos *en bruto* (en inglés, *raw data*) hace referencia a los datos directamente capturados, es decir, sin ningún tipo de procesado o transformación.

<sup>2</sup> El concepto *Industria 4.0* se basa en la digitalización de los sistemas de producción de las industrias, con el objetivo de aumentar la eficiencia en la producción, gestión y en otros sectores de negocio mediante el uso de sistemas avanzados de información.

## 1.1. Contenido

Esta memoria se estructura en 8 capítulos, organizados de la siguiente manera:

- En el Capítulo 2, se presentan los antecedentes del proyecto y las diferentes empresas que forman parte en él.
- En el Capítulo 3, se exponen los objetivos y la planificación del proyecto
- En el Capítulo 4, se desarrolla una fase de comprensión de los datos, analizando las características de los datos con los que se va a trabajar, y presentándolos de una manera gráfica.
- En el Capítulo 5, se expone el trabajo realizado en cuanto al diseño, implementación y validación de diferentes técnicas de preprocesado.
- En el Capítulo 6, se desarrolla el análisis de los datos mediante diferentes técnicas computacionales, analizando el potencial y la efectividad de dichas técnicas.
- En el Capítulo 7, se exponen las conclusiones finales del proyecto.
- Finalmente, en el Capítulo 8, se proponen posibles mejoras y líneas futuras del proyecto.

## CAPÍTULO 2

---

### Antecedentes

---

Este Trabajo de Fin de Grado se circunscribe en un proyecto real, en el cual participan diferentes empresas. Por esta razón, antes de desarrollar el proyecto, es fundamental analizar y comprender el punto de vista de cada empresa, así como los objetivos particulares de cada una y el estado de la colaboración entre ellas. Por tanto, en este capítulo vamos a exponer los antecedentes del proyecto, estudiando el contexto global del mismo desde una perspectiva de negocio.

#### 2.1. Empresas interesadas en el proyecto

En este proyecto, forman parte diferentes empresas:

- Las empresas encargada de producir botellas de plástico: Fábrica de Jabón La Corona y Bowler Plastics (Pty) Ltd.
- La empresa encargada de producir las máquinas industriales que son utilizadas para la creación de botellas de plástico: Urola Solutions.
- La empresa que proporciona los servicios informáticos para la explotación de los datos recogidos en las máquinas industriales: Savvy Data Systems.

Como es lógico, el campo de trabajo y los objetivos de cada empresa son totalmente diferentes, y, por este motivo, vamos a analizar de manera individual el papel que toma cada una de ellas en el proyecto.

### 2.1.1. Savvy Data Systems

El área de negocio de esta empresa se basa en el concepto *Industria 4.0*, y los servicios que ofrece están dirigidos a la explotación de datos industriales mediante sistemas avanzados de información. Para conseguir esto, es necesario un proceso de digitalización previo, el cual se aplica de manera incremental:

1. Diseñar y construir un sistema para la adecuada captura, codificación y transmisión de los datos capturados por diferentes sensores.
2. Almacenar y gestionar los datos de manera adecuada e interoperable, facilitando así el análisis o la aplicación de diferentes técnicas de explotación.

Una vez implementados estos pasos, la empresa realiza la explotación de los datos mediante dos enfoques principales:

- Business Intelligence: el objetivo de este enfoque es poder proporcionar recursos que permitan a los expertos en un dominio concreto analizar sus datos de una manera eficiente e inteligente. Por este motivo, las técnicas utilizadas suelen tener un enfoque exploratorio o analítico, y se busca que los resultados obtenidos puedan ser comprendidos y analizados por personas sin conocimientos informáticos.
- Machine Learning: el objetivo de este tipo de técnicas es realizar un proceso de aprendizaje automático mediante algoritmos computacionales, con el objetivo de que un sistema consiga un conocimiento profundo sobre los datos. Si bien tiene relación con el anterior enfoque (de hecho, ambos tienen diversos conceptos y métodos en común), los objetivos que se persiguen mediante el uso de técnicas de *machine learning* son diferentes, por ejemplo, predicción automática en tiempo real, herramientas de clasificación o regresión, etc. Además, en muchos casos, el conocimiento adquirido es difícilmente interpretable incluso por personas expertas en ciencias de la computación, lo que dificulta la transmisión del conocimiento a otros dominios.

Basándose en estos dos enfoques, el objetivo final es proporcionar herramientas o servicios que se adapten a las necesidades de cada cliente, por ejemplo, modelos de predicción de anomalías, la configuración automática de las máquinas en tiempo real, etc.

### 2.1.2. Urola Solutions

Urola Solutions es la empresa encargada de construir y comercializar la maquinaria industrial utilizada para el proceso de fabricación de botellas. Estas máquinas realizan un proceso denominado extrusión, por lo que son conocidas también como extrusoras. Como la extrusión es un concepto que puede resultar complejo, se explicará detalladamente en el Anexo A.

En dichas máquinas, se incorporan sensores para la captura de diferentes fenómenos, señales o estados del proceso: las temperaturas en las zonas principales, la velocidad del motor, el estado de elementos mecánicos, etc. Debido a ello, el interés principal de esta empresa respecto al proyecto es el de desarrollar un proceso de servitización que permita incorporar un valor añadido a la venta de las extrusoras mediante la integración de diferentes servicios de explotación de los datos generados (concretamente, los servicios proporcionados por la empresa Savvy Data Systems). Esto supondría aumentar la competitividad de la empresa en el mercado, ya que ofrece a los clientes la oportunidad de beneficiarse de las ventajas que proporcionan las soluciones basadas en la *Industria 4.0*.

### 2.1.3. Fábrica de Jabón La Corona y Bowler Plastics (Pty) Ltd

Estas empresas serán las encargadas de producir las botellas de plástico mediante la maquinaria proporcionada por Urola, por lo que serán las empresas que nos proporcionen los datos a analizar. El interés principal de estas empresas respecto a este proyecto se basa en poder aumentar la eficiencia de sus sistemas de producción, mediante la explotación de los datos obtenidos en sus máquinas.

## 2.2. Colaboración interempresarial

Una vez presentadas las empresas que forman parte en el proyecto, vamos a proceder a analizar el contexto y el estado de la colaboración entre ellas.

Para empezar, debemos tener en cuenta que, durante el desarrollo de este TFG, la colaboración de estas empresas se encuentra aun en sus primeras fases, lo que nos generará algunos inconvenientes, como expondremos más adelante. Por otro lado, desde un punto de vista global, la colaboración tiene diferentes objetivos. Primero, el objetivo principal de las empresas encargadas de la producción de botellas de plástico será poder optimizar

sus recursos y su tasa de producción, reduciendo a su vez el coste de los mismos. Para conseguir estos objetivos, se podrían plantear análisis basados en paradigmas generales y altamente utilizados en procesos de estas características, como podrían ser:

- Análisis enfocados al ahorro u optimización de recursos: por ejemplo, reducir la cantidad de materia prima o el consumo de energía necesario para la creación de botellas, la búsqueda de configuraciones óptimas para garantizar un aumento en la producción, etc.
- Análisis enfocados a la predicción de fallos o anomalías: por ejemplo, predecir posibles errores en el funcionamiento, predecir si el producto cumplirá o no los requisitos mínimos de calidad, etc.

Los análisis mencionados, sin embargo, requerirían una dedicación que excedería el alcance de este TFG, no tanto por el tipo de análisis, sino por las características del estado del proyecto, ya que, como se ha mencionado anteriormente, la colaboración interempresarial está todavía en sus primeras fases de desarrollo, y la calidad y características de los datos disponibles no son suficientes como para desarrollar un análisis de tal profundidad de manera adecuada. Por tanto, será Savvy Data Systems la encargada del desarrollo de dichos análisis y del cumplimiento de los objetivos a largo plazo.

En resumen, teniendo en cuenta las características globales del proyecto, mediante este TFG se pretenden establecer las bases para el desarrollo de los objetivos a largo plazo, además de analizar, a modo de prueba de concepto, la viabilidad de los métodos o técnicas que puedan ser útiles para tales objetivos.



### Objetivos y Planificación

---

#### 3.1. Objetivos del proyecto

Como ya hemos mencionado en el Capítulo 2, este TFG se circunscribe dentro de un proyecto real, de un alcance más amplio, el cual está todavía en sus primeras fases de desarrollo. Por tanto, el objetivo principal será poder conseguir, a modo de prueba de concepto, unas conclusiones útiles para desarrollar o replantear los objetivos a largo plazo. Como esta descripción puede resultar demasiado general, se han especificado los siguientes subobjetivos:

1. Plantear, implementar y comparar técnicas de preprocesamiento para diferentes análisis de datos.

El preprocesado de los datos es fundamental para poder realizar un análisis adecuado, pero, dependiendo del tipo de análisis, los datos deberán procesarse usando diferentes métodos. Por este motivo, vamos a plantear y analizar diferentes estrategias de preprocesado, tratando de contemplar el mayor número de situaciones posibles, sin limitarnos solamente a los objetivos particulares de este proyecto. De esta manera, el ingeniero de datos que deba seguir trabajando en el proyecto en líneas futuras podrá elegir las técnicas de preprocesado que mejor se adapten a sus necesidades.

2. Diseñar y desarrollar un análisis de datos mediante diferentes técnicas de minería de datos.

El objetivo de este análisis será plantear una base en cuanto a la explotación de los datos, con la intención de mostrar las ventajas y el potencial del uso de este tipo de técnicas, y proponer diferentes alternativas que puedan ayudar a definir o decidir nuevas líneas futuras del proyecto.


## 3.2. Metodología

El desarrollo de este TFG se ha basado en la metodología CRISP-DM (*Cross Industry Standard Process for Data Mining* [Shearer, 2000]), la cual está enfocada a proyectos de minería de datos como el que vamos a desarrollar. En esta metodología, se definen 6 fases principales (véase la Figura 3.1):

1. Comprensión del negocio (*business understanding*), la cual se basa en analizar y comprender los objetivos del proyecto desde una perspectiva de negocio, lo que es fundamental para definir una planificación preliminar del proyecto<sup>1</sup>.
2. Comprensión de los datos (*data understanding*), la cual se basa en analizar y familiarizarse los conjuntos de datos disponibles, de modo que podamos detectar los posibles errores, evaluar la calidad de los datos o descubrir características que puedan ser relevantes para el desarrollo de los análisis.
3. Preprocesado de los datos (*data preprocessing* o *data preparation*), la cual engloba el diseño, implementación y ejecución de todas las tareas encargadas de generar un conjunto de datos adecuado para su posterior análisis o explotación.
4. Análisis de datos (*data analysis* o *modeling*), donde el objetivo es seleccionar y desarrollar las técnicas de análisis o modelado deseadas y realizar la calibración de los parámetros correspondientes.
5. Validación (*validation*): en la cual se evalúan los resultados obtenidos en la fase del análisis, valorando el cumplimiento de los diferentes objetivos y determinando posibles mejoras o puntos débiles.

---

<sup>1</sup>En este documento, esta fase ha sido presentada en el Capítulo 2, a modo de antecedentes.



**Figura 3.1:** Ciclo vital del modelo de proceso definido en CRISP-DM, donde se muestran las distintas fases y sus relaciones principales.

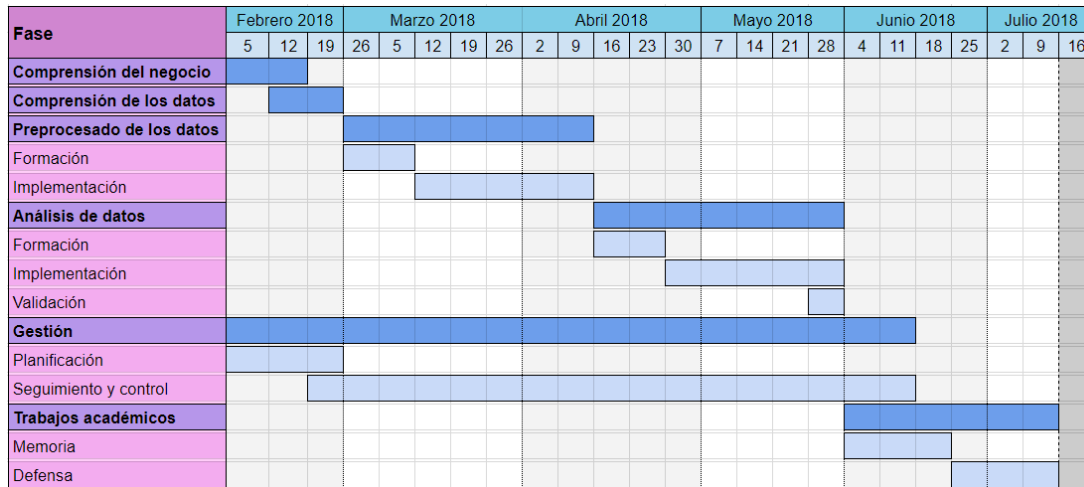
6. Despliegue (*deployment*), la cual se basa en transmitir y presentar de manera adecuada el conocimiento extraído a partir de las diferentes fases del proyecto, así como la generación de herramientas o recursos funcionales, como por ejemplo, el despliegue de los modelos de minería de datos en servicios web, la generación de sistemas expertos, etc.

### 3.3. Gestión del tiempo

La metodología CRISP-DM define el siguiente marco orientativo en cuanto a la distribución del tiempo para el desarrollo de cada fase:

- 50%-70 % del tiempo para la fase de preprocesado de los datos.
- 20%-30 % del tiempo para la fase de comprensión de los datos.
- 10%-20 % del tiempo para las fases de comprensión del negocio, análisis de datos y validación.
- 5 %-10 % del tiempo para la fase de despliegue.

Sin embargo, teniendo en cuenta las características del proyecto, ha sido necesario adaptar la distribución del tiempo en algunas de las fases. Para empezar, excluirémos la fase de



**Figura 3.2:** Diagrama de Gantt donde se muestra la distribución del tiempo de dedicación estimado para las diferentes fases del proyecto.

Fase	Dedicación estimada (horas)
Comprensión del negocio	20
Comprensión de los datos	30
Preprocesado de los datos	120
Formación	20
Implementación	100
Análisis de datos	110
Formación	20
Implementación y desarrollo	80
Validación	10
Trabajos académicos	50
Memoria	30
Defensa	20
<b>Total</b>	<b>330</b>

**Tabla 3.1:** Dedicación de horas estimadas para cada una de las fases del proyecto.

despliegue del alcance del proyecto, siendo Savvy Data Systems la empresa responsable de dichas tareas. Por otro lado, aumentaremos la dedicación destinada al preprocesado y al análisis de datos, ya que en ambas incluiremos una fase de formación en la que se estudiarán los aspectos teóricos de las técnicas o modelos necesarios para el desarrollo las tareas correspondientes. Finalmente, y al tratarse de un proyecto académico, será necesario recoger el trabajo realizado en una memoria, así como preparar una presentación para la defensa del proyecto, por lo que reservaremos un intervalo para el desarrollo de estas tareas.

Teniendo en cuenta estas adaptaciones, la distribución del tiempo estimado para cada fase se muestra en la Figura 3.2, y en la Tabla 3.1 se recoge la dedicación en horas estimada para cada tarea.

### Comprensión de los datos

---

Antes de comenzar a trabajar de manera directa con los datos, es importante entender qué tipo de datos se van a utilizar, especialmente en proyectos que requieren manejar información sobre dominios técnicos o desconocidos para el analista. Por este motivo, en este capítulo vamos a realizar un pre-análisis de los datos con los siguientes objetivos:

- Entender el formato, la estructura y la organización de los ficheros de datos que tendremos que manejar, así como entender cómo se ha realizado su captura, o conocer el origen de los mismos (por ejemplo, la ubicación de cada sensor en la extrusora).
- Conocer y entender las características de las diferentes señales, analizando también las relaciones entre ellas.
- Identificar los posibles errores que puedan contener los datos, de manera que nos permita posteriormente plantear soluciones para corregirlos o controlarlos.

Además de los objetivos expuestos, en este capítulo presentaremos los datos de manera visual, para que el lector pueda comprender mejor las características principales de los mismos. Sin embargo, para garantizar la confidencialidad de los datos, se van a ocultar o modificar intencionadamente algunos detalles de los mismos (por ejemplo, la información de los ejes), manteniendo siempre las características generales (por ejemplo, la forma de las señales o las relaciones entre ellas).

## 4.1. Captura de los datos

El primer paso para entender los datos es analizar el tipo de sensores que tienen las diferentes máquinas a las cuales tendremos acceso. En su totalidad, cada una de estas máquinas puede tener más de 30 indicadores<sup>1</sup>, debido a que la información que se captura está dirigida a diferentes sectores de negocio, por ejemplo, producción, logística o seguridad. Con el fin de no excedernos en el análisis de cada sensor, solo se tendrán en cuenta aquellos que nos sirvan de utilidad para nuestro proyecto.

Al analizar las diferencias entre las extrusoras disponibles, hemos observado que el número de sensores varía dependiendo del modelo, pero, en general, comparten la siguiente estructura:

1. Cuatro, cinco o seis sensores de temperatura en el cilindro de la extrusora, uniformemente distribuidos a lo largo de la máquina, hasta llegar al cabezal. De acuerdo con la terminología utilizada por los profesionales a cargo de las máquinas, es frecuente referirse al cilindro directamente como *extrusora*, por lo que, a lo largo del documento, utilizaremos de manera equivalente los términos *temperaturas de cilindro* y *temperaturas de extrusora*. Un ejemplo de la ubicación de estos sensores puede verse en la Figura 4.1, donde se muestra una extrusora de 4 zonas.

Hay que tener en cuenta que estos sensores no están en contacto con el plástico, ya que de ser así, el sensor podría funcionar de manera incorrecta, o incluso averiarse. Por tanto, el valor capturado hará referencia a la temperatura de la superficie del cilindro, donde estará ubicado también el sistema de calefacción.


2. Dos sensores para medir la temperatura de fundido y la presión de fundido (uno para cada señal), ambos situados en una zona intermedia entre el final del cilindro y el comienzo del cabezal (véase la Figura 4.1). Hay que tener en cuenta que el material se fundirá antes de llegar a este punto, aunque estos indicadores se hayan nombrado haciendo referencia a tal estado del material.
3. Cuatro, cinco o seis sensores de temperatura en el cabezal. En este caso, los sensores tampoco estarán en contacto con el material, sino que se encontrarán alrededor del cabezal (la posición de cada sensor podría variar dependiendo del modelo de

---

<sup>1</sup> En nuestro contexto, el término indicador hace referencia a un fenómeno o fuente de información que se desea monitorizar y analizar por tratarse de una fuente de información relevante (por ejemplo, la velocidad de giro del husillo, el número de botellas producidas por hora, etc.)

extrusora). Un ejemplo de la ubicación de estos sensores puede verse en la Figura 4.2, donde se muestra un cabezal de 4 zonas.

4. Sensores para medir la velocidad de giro del husillo y el consumo eléctrico del motor.
5. Indicador para conocer la receta activa<sup>2</sup>.
6. Indicador del estado de activación de la extrusora (indica si la máquina está en marcha o parada).
7. Indicador de activación de la alarma de la máquina.



**Figura 4.1:** Ubicación de los sensores en el cilindro de una extrusora con 4 zonas, donde se pueden visualizar también el resto de elementos principales de la máquina.


Cabe mencionar que la captura de los datos se realiza con una frecuencia de muestreo de 1Hz, es decir, capturando un dato por segundo. Además, los datos se almacenan de manera síncrona, por lo que podemos considerar que todos los sensores muestrean la señal a la vez.

En cuanto al formato de los datos, la información de cada indicador la recibiremos de manera independiente en un archivo de formato CSV (*Comma Separated Values*), los cuales tendrán la siguiente información: el *timestamp*<sup>3</sup> y el valor del indicador. El *timestamp* estará representado mediante el formato *yyyy-mm-ddTHH:MM:SSZ*, donde:

- *yyyy* representa el año, mediante 4 dígitos.

<sup>2</sup>En procesos químicos, la receta hace referencia a la composición química del material usado como materia prima.

<sup>3</sup> El *timestamp* o marca temporal es una cadena de caracteres, que, con un formato determinado, representa el instante en el que ha ocurrido un suceso, en nuestro caso, la captura de los datos.



**Figura 4.2:** Detalle de la ubicación de los sensores en el cabezal de la extrusora.

- mm representa el mes, mediante 2 dígitos.
- dd representa el día, mediante 2 dígitos.
- T sirve únicamente para separar el día de la hora (por tanto, no proporciona ninguna información sobre la fecha).
- HH representa la hora, mediante 2 dígitos.
- MM representa los minutos, mediante 2 dígitos.
- SS representa los segundos (con fracciones), mediante 2 dígitos para la parte entera, y 3 para la fracción (por ejemplo, 01.333).
- Z representa la zona horaria o *timezone* (en nuestro caso, no es relevante).

A modo de ejemplo, el *timestamp* 2017-09-18T23:00:01.000Z representará el día 18 de septiembre del año 2017, a las 23:00:01 horas de la madrugada (por simplificar, en este ejemplo se ha dejado a un lado la interpretación de la fracción de segundo).

Como los indicadores se capturan de manera síncrona, podemos asumir que todos los ficheros comparten los mismos *timestamp*, lo que nos permitirá relacionar o unir los datos de manera directa.

Para finalizar, hay que tener en cuenta que, con el objetivo de una mejor gestión de la información, cada indicador tiene asociado un código (por ejemplo, el código ABCD123 para el indicador de la velocidad del motor), y, en nuestro caso, las diferentes máquinas tienen asociadas un conjunto similar de indicadores. Esto quiere decir que, los indicadores que



conceptualmente son compatibles entre las máquinas (por ejemplo, el primer sensor de temperatura del cilindro), tendrán el mismo código en todas las máquinas. Sin embargo, no todas las máquinas tienen el mismo diseño, ni los mismos sensores, por lo que puede ocurrir que, aunque una máquina tenga asociado un indicador, no exista un sensor que capture dicha información (en tal caso, el fichero correspondiente no contendrá ningún valor).

## 4.2. Descripción y visualización de las señales

En esta sección vamos a presentar las señales de una manera gráfica, para analizar mejor las características principales de las mismas. Además, el hecho de visualizar y conocer las señales nos puede ayudar a plantear de antemano las técnicas más adecuadas con las que trabajar en etapas posteriores (por ejemplo, qué técnicas de preprocesado podrían adaptarse mejor a las características de los datos).

Hay que tener en cuenta que no todas las máquinas tienen el mismo comportamiento, aunque en general compartan muchas características similares. Para no excedernos en el análisis, se van a mostrar los datos extraídos de una sola extrusora, por lo que el análisis se va a centrar en comentar las características generales, y no las particulares de cada ejemplo.

### 4.2.1. Señales de temperatura

Las temperaturas están codificadas mediante valores reales, y la unidad es el grado Celsius (°C). Para empezar, vamos a mostrar en la Figura 4.3 las mediciones capturadas durante una semana para un único sensor, con el fin de mencionar ciertas características que compartirán todas las señales de temperatura. En dicha figura se han resaltado tres zonas:

- La zona 1 muestra el funcionamiento estable de la extrusora. Como se puede apreciar, la señal oscila de manera periódica, manteniendo la misma amplitud y frecuencia durante todo el intervalo. La razón por la que la señal oscila de esta manera se debe al sistema de retroalimentación utilizado para controlar la temperatura:


En un principio, un operador establece la temperatura deseada para esa zona, lo que activará el sistema de calefacción. En caso de que la medición sobrepase la

temperatura deseada (o un umbral especificado), el sistema de calefacción se detendrá, activando el sistema de ventilación (si lo hubiera) para enfriar la zona. Al descender la temperatura, se activará de nuevo el sistema de calefacción, calentando nuevamente la zona. Como consecuencia de este sistema de control, la temperatura aumentará y disminuirá periódicamente, obteniendo la forma mostrada en la Figura 4.3 (en el intervalo resaltado como *funcionamiento estable*).

- La zona 2 muestra un funcionamiento inestable de la máquina. En este caso, podría decirse que la señal aún conserva una forma periódica, pero muy irregular, donde tanto la amplitud como la frecuencia cambian a lo largo del intervalo. De acuerdo con los datos que hemos analizado, el motivo por el que la máquina muestra un comportamiento irregular parece estar relacionado con la parada de la máquina, como se mostrará en la Figura 4.7, ya que dichas paradas coinciden con los intervalos irregulares. Esto podría deberse a múltiples razones, como por ejemplo, un cambio en la receta, una reconfiguración de la extrusora o una parada preventiva de la máquina.
- La zona 3 muestra los registros capturados durante la parada total de una máquina. Nótese que los valores obtenidos durante este intervalo serán los valores detectados a temperatura ambiente, para la cual añadiremos una referencia en el eje horizontal. En algunos casos, la máquina detiene su funcionamiento sin enfriar del todo las zonas, manteniéndolas a una temperatura elevada pero inferior a sus valores operativos. Esto sucede, por ejemplo, cuando existe la necesidad de detener la máquina teniendo aún producto en su interior, ya que un arranque *en frío* podría averiar los elementos de la máquina. En esos casos, la razón por la que las temperaturas se mantienen inferiores a sus valores operativos es debido a que, si tuvieran temperaturas muy elevadas, el plástico podría quemarse.

Una vez expuestas las características generales de una señal de temperatura, vamos a analizar las relaciones entre las diferentes señales de este tipo. Para empezar, en la Figura 4.4 mostraremos las temperaturas capturadas por 4 sensores en el cilindro, los cuales se encuentran uniformemente distanciados a lo largo del mismo. Hay que tener en cuenta que, en el gráfico, las señales se han espaciado intencionadamente para procurar una mejor visibilidad, por lo que, en los datos reales, las temperaturas tendrán valores más próximos.

En cuanto a las temperaturas del cilindro, hemos observado que, en general, la temperatura aumenta al avanzar de sensor (es decir, la temperatura del cilindro aumentará a medida



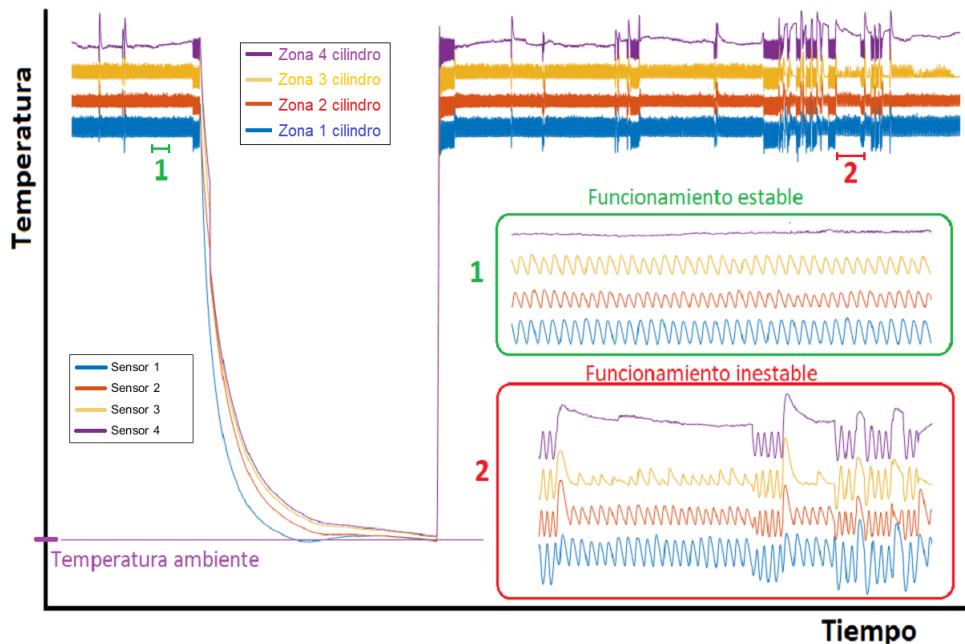
**Figura 4.3:** Mediciones de un sensor de temperatura en un intervalo aproximado de una semana.

que avancemos en él). Esto podría variar en cuanto al modelo de extrusora, ya que en algunas máquinas las temperaturas toman valores muy parecidos a lo largo del cilindro. Aparte de eso, también podemos observar que las señales se vuelven más estables de un sensor a otro, llegando a prácticamente no oscilar en la cuarta zona. Otra característica significativa es que, en las zonas inestables, todas las señales parecen estar afectadas de un modo muy similar, lo que se puede apreciar en la segunda zona resaltada de la Figura 4.4.

Una vez analizadas las señales capturadas en el cilindro, procederemos a mostrar las señales de los 4 sensores disponibles en el cabezal de la extrusora, en la Figura 4.5. En este caso, la posición de los sensores puede visualizarse en la Figura 4.2, ya que la distribución tiene características más complejas<sup>4</sup>. Analizando la relación entre las señales, podemos ver que no siguen el mismo patrón que las temperaturas capturadas en el cilindro, ya que un avance en el cabezal no supone necesariamente un aumento en la temperatura, ni una mayor estabilidad. Además, podemos observar en la segunda zona resaltada que las inestabilidades no afectan de la misma manera a todas las señales (ni ocurren a la vez), lo que sí sucedía en el cilindro. Por último, cabe destacar que solo una señal (la capturada por el tercer sensor) mantiene una forma similar a la última señal del cilindro.

Dejando a un lado las particularidades de este ejemplo, lo que se quiere transmitir es que las señales capturadas en el cabezal no muestran necesariamente el mismo patrón de

<sup>4</sup>Recordemos que, dependiendo del modelo de extrusora, tanto el cabezal como la disposición de los sensores podría ser diferente.



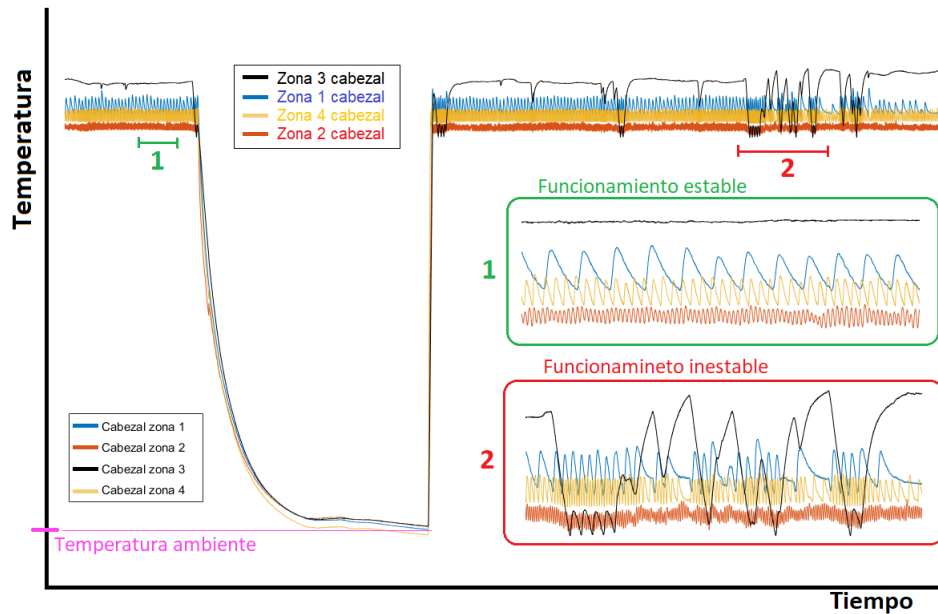
**Figura 4.4:** Señales capturadas por 4 sensores de temperatura situados de manera contigua en el cilindro de la extrusora, en un intervalo aproximado de una semana.

evolución que las señales capturadas en el cilindro, ni una continuación directa respecto a las señales anteriores, debido a que las características de esta zona son diferentes a las del cilindro.

Para finalizar con el análisis de las señales de temperatura, vamos a mostrar en la Figura 4.6 la señal correspondiente a la temperatura de fundido, cuyo sensor se ubica entre el cilindro y el cabezal. En este gráfico vamos a mostrar además todas las señales de temperatura, con la finalidad de que el lector observe las diferencias de temperatura que puede haber entre las diferentes zonas de la máquina. Para garantizar la visibilidad, al igual que en los casos anteriores, se han desplazado ligeramente las señales, excepto tres (una por cada zona), las cuales se mostrarán mantenidos sus valores reales:

1. La temperatura de fundido
2. La temperatura en la última zona del cilindro
3. La temperatura en el tercer sensor del cabezal. Se ha seleccionado el tercer sensor por ser, como hemos mencionado anteriormente, la única señal del cabezal con una forma similar a las registradas en zonas anteriores.

Para resaltar estas tres señales por encima del resto, el color de las demás señales será difuminado.

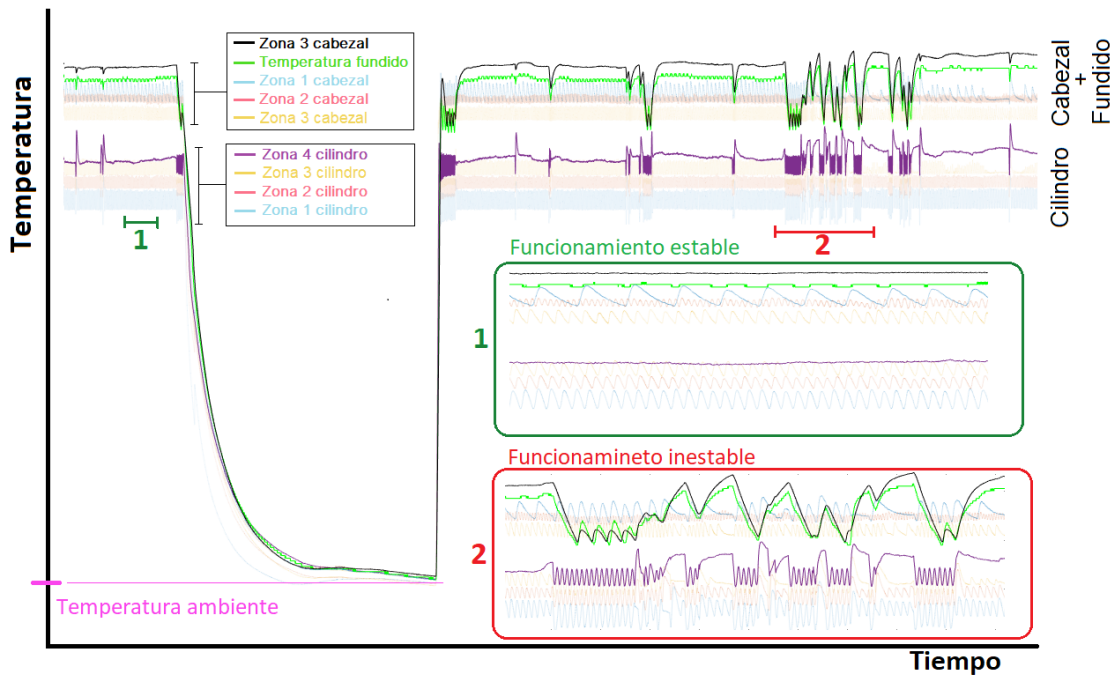


**Figura 4.5:** Señales capturadas por 4 sensores del cabezal de una extrusora, en un intervalo aproximado de una semana.

Analizando la Figura 4.6, podemos ver que las temperaturas del cabezal y fundido son bastante más elevadas que en el cilindro. Por otro lado, podemos observar que la señal de fundido y la obtenida en la tercera zona del cabezal son muy parecidas, tanto en forma como en valor. Esto podría reflejar que dichas zonas tienen una influencia similar en cuanto a la calefacción del producto, o que simplemente tienen unas características parecidas en cuanto a la captura de información. En cualquier caso, esto no se cumple en todas las extrusoras, por lo que no debería considerarse una característica general. Por último, en esta gráfica podemos ver que, aunque las inestabilidades en las señales ocurren prácticamente en los mismos intervalos, las señales del cilindro y las del cabezal (y fundido) no se ven afectadas necesariamente de la misma manera.

#### 4.2.2. Velocidad de giro del husillo y consumo del motor

La velocidad de giro del husillo está codificada mediante valores reales, siendo la unidad las revoluciones por minuto (RPM). El consumo del motor también está codificado como valores reales, siendo la unidad el amperio (A). Estos dos indicadores están estrechamente relacionados, ya que el motor será el actuador que provoque el giro del husillo, y por tanto, una mayor velocidad de giro supondrá un mayor consumo. Aun así, el consumo del motor no está condicionado solo por la velocidad de giro del husillo, ya que dependiendo



**Figura 4.6:** Todas las señales de temperatura capturadas en la extrusora, resaltando la temperatura en la última zona del cilindro, la temperatura de fundido y la temperatura en la tercera zona del cabezal.


del material a desplazar la potencia necesaria será diferente (por ejemplo, en base a la densidad del material).

Estas dos señales se pueden visualizar en la Figura 4.7, donde se ha añadido también la temperatura de fundido a modo de referencia. Para mejorar la visibilidad, las señales serán normalizadas y desplazadas de manera que no se solapen. Como podemos comprobar, las paradas del motor coinciden con los intervalos en los que las temperaturas se desestabilizan. Además, en la imagen se ha resaltado y ampliado el intervalo donde la máquina comienza a funcionar de nuevo tras estar totalmente parada. En este intervalo (al que nos referiremos como *intervalo de estabilización*) se puede apreciar que, hasta que la máquina no alcanza una temperatura elevada y un comportamiento estable, el motor no se activa, ya que la extrusora no estaría aún en un estado operativo.

Por último, vemos que, como es lógico, en los intervalos en los que la velocidad del husillo es 0, el consumo de motor también se reducirá a 0. Esto lo podremos comprobar en la Tabla 4.1, donde hemos calculado la proporción de valores para las que se cumple dicha condición, siendo el resultado del 100%.

Proporción de valores	Consumo motor = 0	Consumo motor > 0
RPM husillo = 0	100%	0%
RPM husillo > 0	0%	100%

**Tabla 4.1:** Proporción de valores entre la velocidad de giro del husillo y el consumo del motor, donde se puede comprobar que cuando la velocidad de giro es nula, el consumo de motor también lo es.

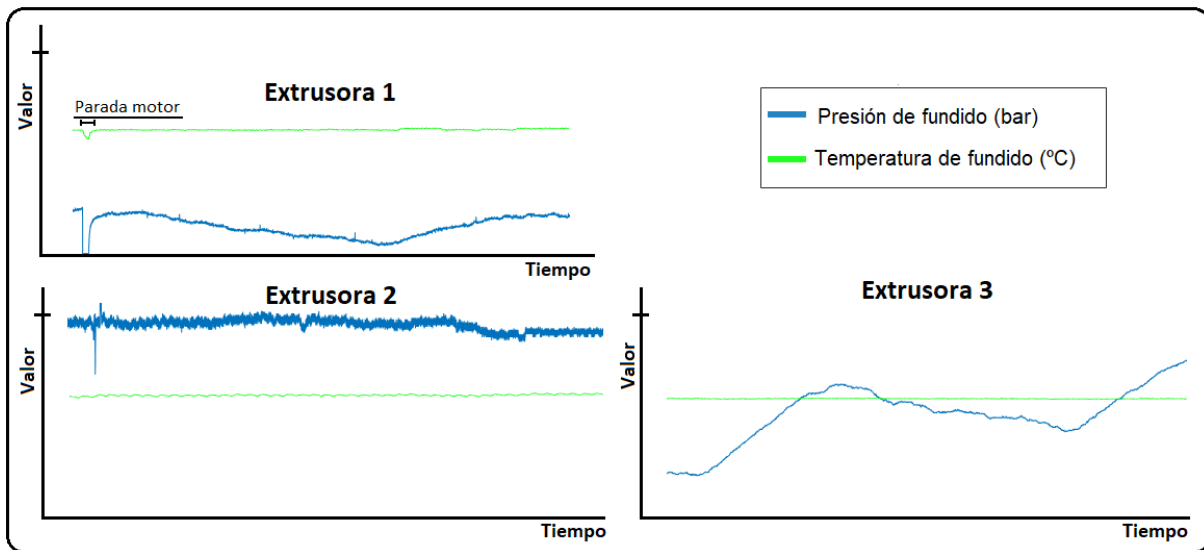


**Figura 4.7:** Señales correspondientes al consumo del motor, velocidad de giro del husillo y temperatura de fundido.

### 4.2.3. Presión

La presión está codificada mediante valores reales, siendo la unidad el bar. Dependiendo de la extrusora, hemos observado que la presión se comporta de manera diferente, siendo a su vez la única señal analizada hasta ahora que no se mantiene en un rango de valores determinado a lo largo del proceso. Para entender mejor estas características, hemos añadido en la Figura 4.8 las presiones de fundido obtenidas en tres extrusoras diferentes. En cada caso, se ha añadido también la temperatura de fundido registrada en la máquina correspondiente, a modo de referencia.

Una característica común que hemos observado en todas las extrusoras es que, durante los intervalos en los cuales el motor se detiene, la presión desciende de manera mucho más



**Figura 4.8:** Presión y temperatura de fundido capturados en 3 extrusoras diferentes. El lector puede asumir que los valores y proporciones de los ejes son comunes en los 3 gráficos.

brusca que las señales de temperatura, llegando a descender a cero en la mayoría de los casos. Un ejemplo de esto se puede observar en el primer gráfico de la Figura 4.8 (esquina superior izquierda), donde se ha resaltado un intervalo en el que el motor se detiene.

#### 4.2.4. Indicador de alarma activa y máquina en marcha

Estos dos indicadores estarán codificados mediante valores booleanos, donde en ambos casos el valor *"true"* indicará un estado activo, y el valor *"false"* un estado inactivo. El indicador de máquina en marcha también podría deducirse bien por el indicador de consumo de motor, o bien por el de velocidad de giro del husillo, ya que la detención de la máquina supondrá la detención del motor, reduciendo su consumo y velocidad a 0. Para comprobar que esto es cierto, hemos calculado en la Tabla 4.2 la proporción de valores que cumplen esta condición<sup>5</sup>. En este caso, podemos ver que la compatibilidad no es del 100%, ya que existen valores no nulos de la velocidad cuando la máquina está inactiva (así como velocidades nulas cuando la máquina está activa). En cualquier caso, podríamos considerar que la proporción es lo suficientemente grande como para asumir dicha compatibilidad.

Analizando la relación entre el estado de la máquina y el estado de la alarma, podemos

<sup>5</sup> Para realizar los cálculos se han tenido en cuenta solamente la velocidad de giro del husillo, ya que, como hemos visto en la Tabla 4.1, la compatibilidad entre este indicador y el consumo del motor es del 100%, por lo que los resultados serían los mismos.



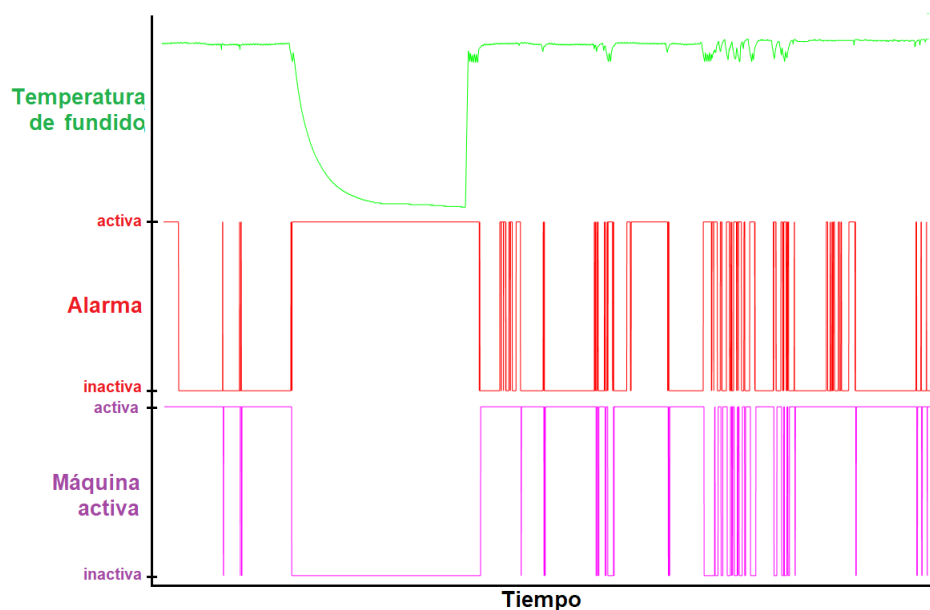
Proporción de valores	Máquina activa	Máquina inactiva
RPM husillo = 0	0.02%	98.70%
RPM husillo > 0	99.98%	1.30%

**Tabla 4.2:** Proporción de valores entre el indicador de máquina activa y la velocidad de giro del husillo

ver en la Figura 4.9 que también existe una relación entre estas variables, ya que en la mayoría de intervalos donde la máquina no está activa, la alarma sí lo está. Sin embargo, la activación de la alarma también ocurre en casos donde la máquina está activa (véase la Tabla 4.3). Esto se debe a que la alarma puede ser activada por diversas causas, las cuales pueden suceder durante el proceso (una descenso en el nivel de aceite, la apertura de una puerta en la máquina, etc.). El hecho de que en los datos no se refleje la causa de activación de la alarma supone un problema en cuanto a la posibilidad de modelar o intentar predecir esas situaciones, además de dificultar el análisis o la interpretación adecuada de los resultados.

Proporción de valores	Máquina activa	Máquina inactiva
Alarma activa	15.53%	98.99%
Alarma inactiva	84.47%	1.01%

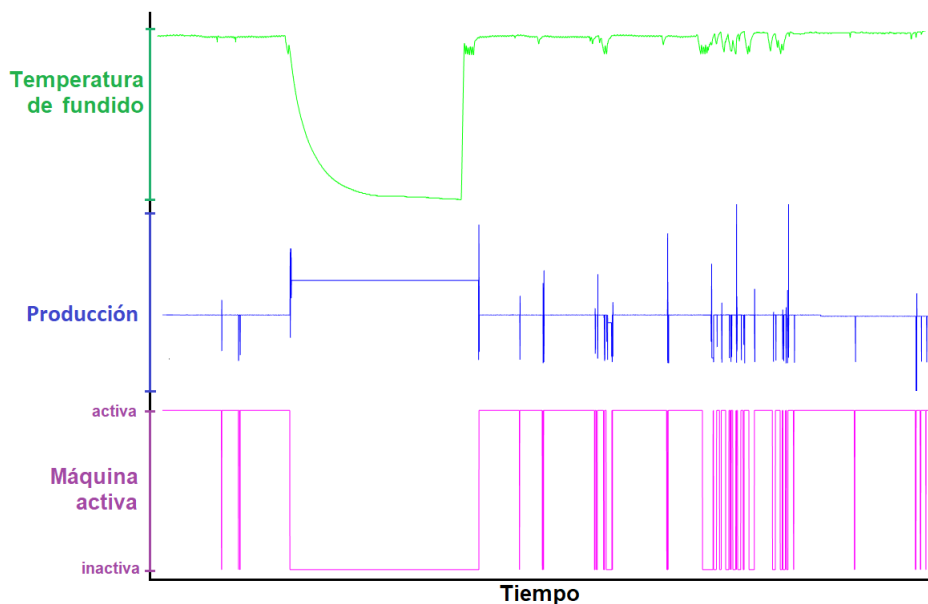
**Tabla 4.3:** Proporción de valores entre el estado de la máquina y el estado de la alarma.



**Figura 4.9:** Indicador de alarma activa y máquina activa, donde se ha añadido también la temperatura de fundido a modo de referencia.

#### 4.2.5. Producción

La producción está codificada mediante valores enteros positivos, siendo la unidad el número de botellas por hora generadas. Analizando las señales de este indicador en diferentes extrusoras, hemos observado que, cuando la máquina no está en marcha, el valor de la producción toma valores erróneos, mostrando, por ejemplo, un aumento significativo de la producción al detenerse la máquina. Un ejemplo de este comportamiento puede verse en la Figura 4.10, donde se muestra gráficamente el indicador de producción, junto a la temperatura de fundido y el indicador de alarma activa, a modo de referencia (todos los valores están normalizados). Este error ha sido confirmado por los responsables de la empresa, y es debido a un problema en el cálculo del indicador. Por tanto, en tales intervalos descartaremos la información sobre la producción, lo que no supone un problema si asumimos que, cuando la máquina no está en marcha, la producción es nula.



**Figura 4.10:** Indicador de producción, donde se han añadido también los indicadores de máquina activa y temperatura de fundido a modo de referencia

## 4.3. Análisis de calidad de los datos

Antes de comenzar a trabajar con los datos, debemos analizar y evaluar la calidad de los mismos, por las siguientes razones:

1. Para evaluar si el conjunto de datos es adecuado para poder trabajar con él. Esto será especialmente importante en este proyecto, ya que, al ser un proyecto en su fase inicial, puede ocurrir que algunos datos estén recogidos de manera inadecuada o que no existan registros acerca de un suceso importante.
2. Para detectar si los datos contienen errores o características a corregir, como por ejemplo, valores atípicos, ruido, etc. De esta manera, podremos plantear el tratamiento que tendremos que aplicar a los datos durante el preprocesado, o evaluar que tipo de técnicas podrían ser las más efectivas para ello.

### 4.3.1. Errores en los datos

Tras analizar los datos, hemos encontrado una serie de errores o características que podrían suponer un problema a la hora de analizarlos, y que, por tanto, deberán ser controlados o corregidos en la parte del preprocesado.

- Valores repetidos

Hemos observado que las señales contienen valores repetidos, es decir, registros con el mismo *timestamp* y valor. Como todas las señales se muestrean de manera síncrona, estas repeticiones ocurrirán en todas las señales. Este error es el menos significativo, ya que identificar y eliminar dichas repeticiones es trivial.

- Valores perdidos (*missing values*)

También hemos observado que las señales contienen valores perdidos, es decir, intervalos de tiempo en los que no se ha almacenado información. En nuestro caso, los valores perdidos se podrían clasificar en dos tipos: registros con *timestamp* pero sin valor, o registros sin *timestamp* ni valor. En el segundo caso, la ausencia de registros produce una discontinuidad en los *timestamps*, y, por lo general, la ausencia se prolonga para un intervalo de muestras consecutivas, pudiendo llegar a perder varios minutos u horas de información. A modo de ejemplo, si

tuviéramos una ausencia desde el instante 2017-10-20T07:00:01.000Z al instante 2017-10-20T07:01:01.000Z (ambos inclusive), en el fichero correspondiente pasaríamos directamente del instante 2017-10-20T07:00:00.000Z al instante 2017-10-20T07:01:02.000Z.

Al margen de estos errores, donde la ausencia de valores es temporal, también hemos encontrado casos en los que no existe ningún dato disponible para un indicador en concreto. Esto puede deberse a que el sensor encargado de capturar esa información haya dejado de funcionar, o a que directamente una máquina no contenga dicho sensor, ya que, como se ha mencionado en la Sección 4.1, una máquina puede tener asociado un indicador aunque no disponga de un sensor para su captura.

- Valores atípicos (*outliers*)

En general, los valores atípicos son datos que reflejan un valor inusual o erróneo, por ejemplo, una medición de 100°C en la temperatura ambiente de una ciudad. En los datos que hemos analizado, hemos observado que existen valores que claramente reflejan un error en la captura de los datos, por ejemplo, registros puntuales que indican temperaturas superiores a 500°C, o un descensos repentinos a 0°C entre dos muestras consecutivas.

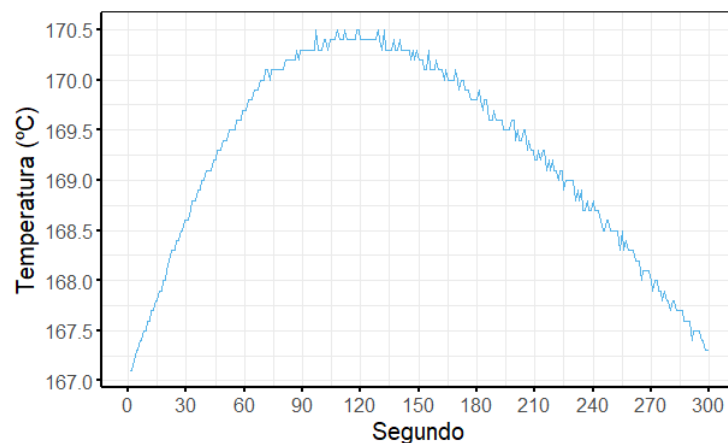
Aunque estos casos extremos sean fáciles de detectar y clasificar como *outliers*, definir de manera general qué son valores atípicos no es trivial, ya que, por ejemplo, comportamientos que para un modelo de extrusora serían anómalos, para otro modelo podrían no serlo. Además, si elimináramos de manera general los registros en los que las señales se alejan del comportamiento normal, podríamos perder intervalos que proporcionen información sobre fallos o anomalías, siendo esto precisamente lo que convendría estudiar si quisiéramos realizar un análisis enfocado al mantenimiento de la extrusora o a la detección de errores. Por estas razones, el tratamiento de los valores atípicos podría variar dependiendo de factores como la fuente de los datos o el tipo de análisis deseado, lo que podría dificultar la implementación de un método genérico para corregir estos errores de manera adecuada.

- Ruido

En general, denominamos ruido a las perturbaciones o corrupciones que sufren los datos durante su captura, transmisión, u otro procesamiento [Tuzlukov, 2010]. El ruido es un factor que afecta en mayor o menor medida a cualquier señal, especialmente a las capturadas por sensores, y pueden deberse a múltiples causas, muchas de ellas inevitables, como por ejemplo el error de precisión del sensor.

En nuestros datos, hemos observado que las señales muestran cierto nivel de ruido, aunque de magnitud relativamente pequeña, suponiendo por lo general una perturbación menor a un grado Celsius ( $^{\circ}\text{C}$ ) en el caso de las temperaturas. Sin embargo, la eliminación de ruido puede suponer una mejora en la calidad de los datos, ya que podría mejorar la efectividad de los modelos de minería de datos [Zhu and Wu, 2004].

Para visualizar el efecto del ruido en nuestros datos, vamos a mostrar en la Figura 4.11 la señal capturada por un sensor de temperatura en un intervalo de 5 minutos. Es interesante que el efecto del ruido sea notablemente mayor en el segundo intervalo de la señal (es decir, al descender), lo que quizás podría mostrar que el sensor no es tan eficaz al medir la temperatura mientras el sistema de enfriamiento está en marcha.



**Figura 4.11:** Detalle de una señal de temperatura, donde podemos apreciar el efecto del ruido.

#### 4.3.2. Calidad del conjunto de datos

En los anteriores apartados hemos analizado la calidad de los datos en cuanto a errores o características a controlar se refiere. Por tanto, en este apartado vamos a comentar otro tipo de características que también influyen en la calidad del conjunto de datos, especialmente a la hora de aplicar modelos de minería de datos.

Para empezar, uno de los factores a tener en cuenta es la cantidad de datos que tendremos disponibles, ya que un conjunto muy reducido podría no ser suficiente para determinados tipos de análisis. En nuestro caso, la cantidad de datos no ha supuesto un problema, ya que hemos tenido acceso a los registros de diferentes máquinas, las cuales han estado en

funcionamiento durante varias semanas. Aun así, algunas de estas máquinas no capturaban indicadores relevantes, por lo que los datos de dichas máquinas no han podido ser utilizados.

Sin embargo, el mayor inconveniente que hemos encontrado es que la configuración y el comportamiento de las máquinas es prácticamente el mismo a lo largo de todo el proceso, por lo que el conjunto de datos de cada máquina refleja un comportamiento muy similar durante los intervalos disponibles. El hecho de que dispongamos datos con tan poca heterogeneidad podría suponer que los modelos de aprendizaje automático que utilicemos no tengan una capacidad de generalización o abstracción suficiente, y que, por tanto, la capacidad de modelar situaciones diferentes a las aprendidas sean poco fiables.

Por último, creemos que los indicadores que se recogen actualmente podrían no ser suficientes para realizar algunos de los análisis que se plantean a largo plazo, o al menos para modelar adecuadamente ciertos procesos, por lo que, a lo largo del documento, se especificarán las posibles mejoras que recomendaríamos para una captura de datos adecuada y dirigida a dichos análisis.

### Preprocesado de los datos

---

El preprocesado de los datos engloba todas las operaciones o técnicas que se deberán aplicar para construir un conjunto de datos adecuado para su posterior uso o análisis. En otras palabras, mediante el preprocesado pasaremos de tener un conjunto de datos en bruto a tener un conjunto de datos adaptado y particularizado a los diferentes análisis o técnicas que se deseen utilizar posteriormente.

El preprocesado de los datos es vital para garantizar la aplicabilidad de las técnicas a utilizar, es decir, garantizar que los datos cumplen los requisitos que pudieran imponer dichas técnicas, por ejemplo, la discretización de valores continuos, la normalización en un rango de valores determinado, etc. Por otro lado, el preprocesado es fundamental para aumentar la eficacia de dichas técnicas, ya que un conjunto de datos en bruto podría contener información inadecuada, lo que podría llevar a resultados erróneos o dificultar el proceso de aprendizaje de los modelos de minería de datos.

Debido a que los objetivos del preprocesado varían dependiendo del tipo de análisis que se vaya realizar posteriormente, hemos decidido plantear esta sección de la manera más general posible, es decir, tratando de contemplar el mayor número de objetivos y situaciones, sin limitarnos solamente a los objetivos particulares de este proyecto. De esta manera, el ingeniero de datos que deba seguir trabajando en este proyecto en líneas futuras podrá elegir las técnicas que mejor se adapten a sus necesidades.

Por tanto, en este capítulo vamos a analizar y comparar diferentes técnicas de preprocesado, para poder así evaluar cuáles se adaptan mejor a las características de nuestros datos, o a los requisitos que demanden los análisis que se vayan a emplear posteriormente.

## 5.1. Tratamiento de valores perdidos

El tratamiento de valores perdidos es fundamental en la preparación del conjunto de datos, ya que la ausencia de datos podría suponer, entre otros, problemas a la hora de procesarlos, o un descenso en la efectividad de los modelos de *data mining*. Este tratamiento es fundamental cuando la continuidad de los datos es un factor importante, por ejemplo, en el caso de tratar las señales como series temporales, ya que la ausencia de datos durante largos intervalos de tiempo puede producir discontinuidades indeseadas, reduciendo así la calidad de los datos o de los análisis realizados.

Como ya comentamos en la Sección 4.3.1, en nuestros datos hemos observado la presencia de señales con intervalos de datos perdidos, por lo que debemos de analizar qué métodos son los más efectivos a la hora de asignar valores a los registros imputados. La efectividad de dichos métodos será importante, ya que, como es lógico, una imputación incorrecta puede perjudicar en gran medida la calidad de los datos, debido a que estaríamos añadiendo valores que no se asemejan a los datos reales.


En este documento se han analizado diferentes métodos. Como cada uno de ellos puede tener diferentes variantes o implementaciones, se han seleccionado las más representativas, o las que mejores resultados obtienen entre ellas. Para evaluar la efectividad de dichos métodos, vamos a eliminar intervalos en señales para las cuales conocemos su valor real, de manera que podamos calcular el error obtenido en la imputación. Para comenzar, hemos eliminado dos intervalos en una zona estable de una señal de temperatura, como se muestra en la Figura 5.1. El primer intervalo será de 4 minutos de duración (es decir, 240 muestras consecutivas), y se eliminará en una zona con una curvatura (en el pico de la oscilación). El segundo intervalo será más simple, de solo 1 minuto de duración (60 muestras consecutivas) y un intervalo prácticamente lineal.

A continuación, introduciremos los métodos de imputación que se han contemplado en este documento, mostrando en cada caso los resultados obtenidos al imputar los valores para la señal presentada en la Figura 5.1.

### 5.1.1. Interpolación lineal

Este método realizará una interpolación lineal del intervalo perdido partiendo de la primera y última observación disponible. En otras palabras, teniendo una señal  $s = (s_1, \dots, s_N)$





**Figura 5.1:** Intervalo de datos utilizado para la comparación de los resultados de las técnicas de imputación.

de tamaño  $N$  para la cual no existen valores en el intervalo  $[i, j]$ , el método interpolará una línea que conecte los puntos  $s_{i-1}$  y  $s_{j+1}$ :

$$p(u) = \frac{s_{i-1}(j-u) + s_{j+1}(u-i)}{j-i}, u \in [i, j],$$

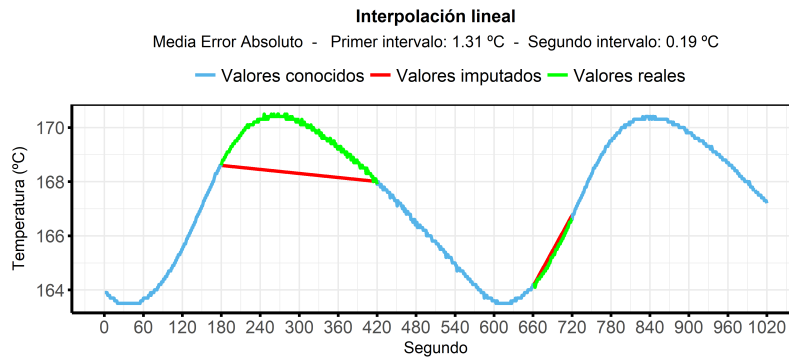
que será la utilizada para imputar los valores en el intervalo  $[i, j]$ .

Como podemos anticipar, este método no será capaz de interpolar adecuadamente intervalos con curvas pronunciadas, pero podría ser útil en intervalos rectos o con poca curvatura, ya que, además, no requiere apenas coste computacional, lo que puede suponer una ventaja importante a la hora de manejar grandes volúmenes de datos.

En la Figura 5.2 podemos ver los resultados obtenidos con este método. Como era de esperar, el método no se ajusta bien al primer intervalo (formado por una curva), pero sí al segundo, ya que prácticamente es un segmento lineal.

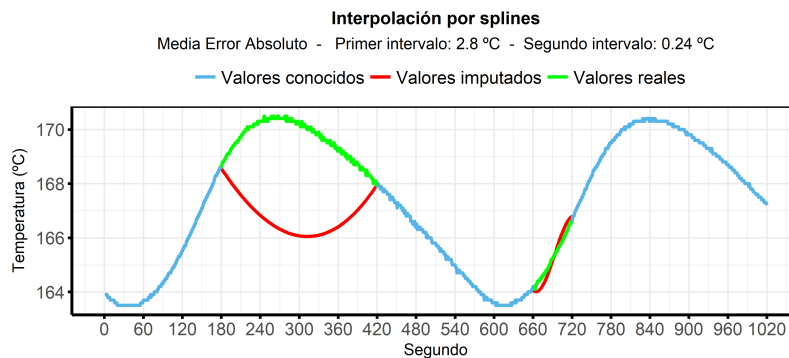
### 5.1.2. Interpolación por splines

Las curvas splines son curvas formadas por segmentos polinomiales, las cuales poseen características que las hacen especialmente útiles en problemas de interpolación, por ejemplo, la capacidad de modelar adecuadamente formas complejas mediante polinomios de grado bajo (en la práctica, lo más común es utilizar polinomios de grado 2 o 3, debido a su




**Figura 5.2:** Resultados obtenidos utilizando la interpolación lineal como método de imputación.

fácil manejo y reducido coste computacional). En la Figura 5.3 se muestran los resultados obtenidos mediante este método, utilizando curvas splines cúbicas.



**Figura 5.3:** Resultados obtenidos utilizando la interpolación mediante curvas spline cúbicas como método de imputación.


Como podemos observar en la Figura 5.3, el método no es capaz de modelar los segmentos de valores perdidos de manera adecuada, especialmente en el primer intervalo. Estos resultados podrían deberse al ruido, ya que las perturbaciones podrían suponer que los segmentos interpolados para las curvas spline sean incorrectos. Para comprobar si esto es cierto, hemos eliminado el ruido de la señal mediante el filtro propuesto en la Sección 5.2.2, y hemos aplicado de nuevo el método de imputación, obteniendo los resultados mostrados en la Figura 5.4. En este caso, los resultados muestran que, sobre una señal sin ruido, el método de imputación es capaz de modelar adecuadamente la curva, consiguiendo una imputación muy cercana a los valores reales. Sin embargo, esto refleja que el método podría ser extremadamente sensible al ruido, y, por tanto, no parece fiable para ser utilizado en datos reales.



**Figura 5.4:** Resultados obtenidos utilizando la imputación basada en la interpolación mediante splines en una señal sin ruido.

### Last Observation Carried Forward

Este método se basa simplemente en imputar el último valor disponible antes de llegar al intervalo con datos perdidos (en otras palabras, *llevar o arrastrar* hacia delante la última observación disponible). Este método es claramente una mala opción para modelar segmentos no horizontales, por lo que no es un método eficaz para la imputación de largos intervalos en señales curvas como las temperaturas. Esto se puede comprobar en la Figura 5.5, donde vemos que la imputación es demasiado básica. Sin embargo, este método podría servir en señales que muestran una alta estabilidad (como por ejemplo la velocidad de motor), en señales categóricas (como la señal binaria de máquina en marcha), o para imputar intervalos cortos (véase la Sección 5.5.1, donde se ha aplicado esta técnica para el tratamiento de valores atípicos).



**Figura 5.5:** Resultados obtenidos utilizando el método de imputación *Last Observation Carried Forward*.

### 5.1.3. Media móvil

La media móvil calcula el promedio de los valores de la señal en base a una ventana móvil, es decir, que se desplaza a lo largo de la señal. En nuestro caso, utilizaremos la versión conocida como *media móvil central*, la cual definiremos de la siguiente manera: siendo  $s = (s_1, \dots, s_N)$  una señal de tamaño  $N$ , la media móvil central de la posición  $i$  será el promedio de los valores  $(s_{i-k}, \dots, s_{i-1}, s_{i+1}, \dots, s_{i+k})$ , donde  $k$  es el tamaño de la ventana a utilizar.

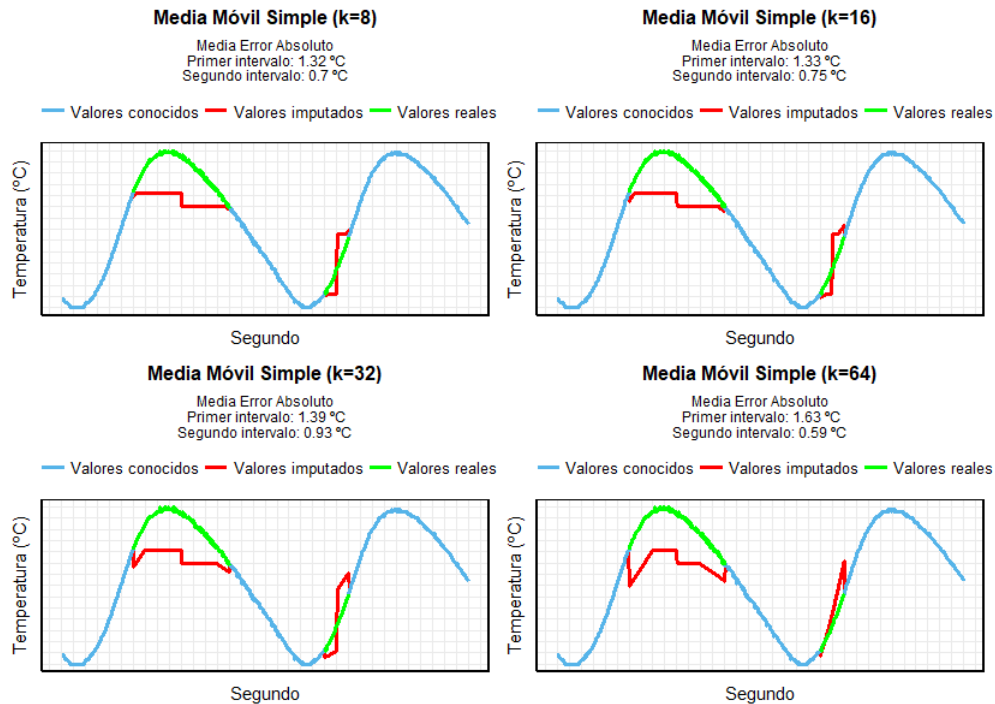
Para calcular el promedio, es común ponderar los valores de manera que los valores lejanos tengan una influencia menor a los valores cercanos. Dependiendo de cómo se realice esta ponderación, existen tres variantes principales:

- **Media Móvil Simple (MMS)**, en la cual todos los valores tendrán el mismo peso (es decir, no hay ponderación).
- **Media Móvil Ponderada Lineal (MMPL)**, en la cual los pesos decrecen de manera lineal según se alejen del punto central, asignando un peso de  $1/(1+p)$  a los valores en las posiciones  $i \pm p$  (es decir, los valores en las posiciones  $i \pm 1$  serán ponderados con un peso de  $1/2$ , los valores en las posiciones  $i \pm 2$  con un peso de  $1/3$ , etc).
- **Media Móvil Ponderada Exponencial (MMPE)**, en la cual los pesos decrecen de manera exponencial según se alejen del punto central, asignando un peso de  $1/(2^p)$  a los valores en las posiciones  $i \pm p$  (es decir, los valores en las posiciones  $i \pm 1$  serán ponderados con un peso de  $1/2^1$ , los valores en las posiciones  $i \pm 2$  con un peso de  $1/2^2$ , etc).

Para comparar el efecto de cada método, realizaremos la imputación con 4 tamaños de ventana:  $k = \{8, 16, 32, 64\}$ . Los resultados pueden verse en las figuras 5.6 (MMS), 5.7 (MMPL) y 5.8 (MMPE)<sup>1</sup>. Analizando los resultados, podemos observar que ningún método consigue un buen ajuste en los intervalos perdidos. Comparando los métodos MMS y MMPL, vemos que el segundo consigue una continuidad más suave en los intervalos (especialmente para tamaños de ventana grandes), lo que es debido a la ponderación de valores. Sin embargo, en ambos casos el aumento en el tamaño de la ventana no ha resultado efectivo, ya que la forma obtenida se vuelve discontinua e irregular, aumentando

<sup>1</sup>En las figuras 5.6, 5.7 y 5.8 se ha omitido intencionadamente la información de los ejes, por motivos de espacio y visualización.

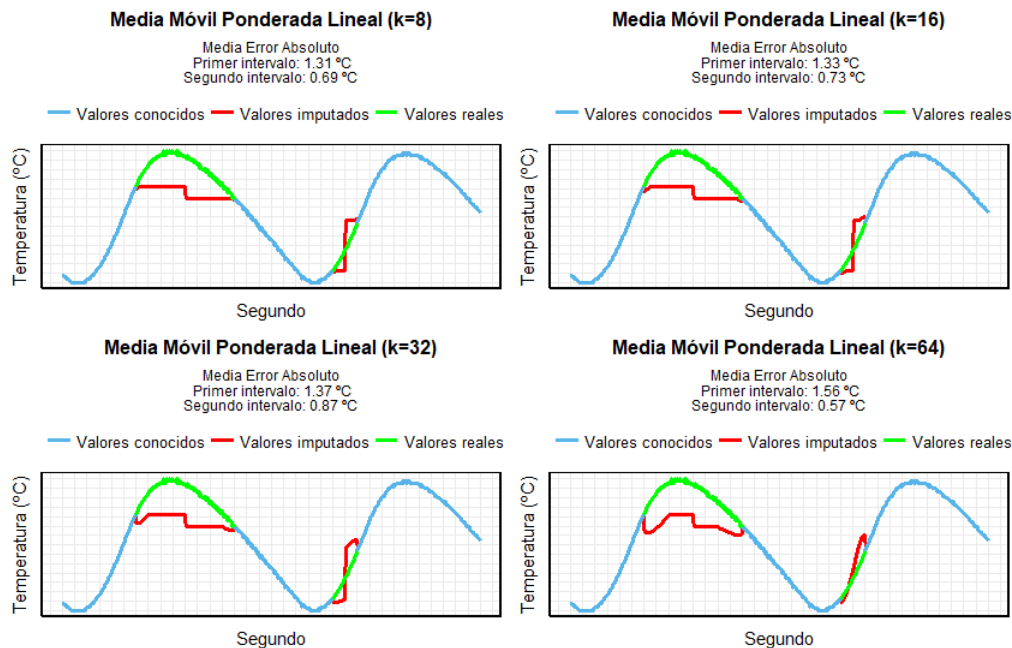
el error. Por otro lado, el método MMPE consigue prácticamente el mismo resultado para cualquier tamaño de ventana, lo que podría indicar que el efecto de la ponderación exponencial es demasiado elevado.



**Figura 5.6:** Resultados obtenidos utilizando la Media Móvil Simple como método de imputación, con diferentes tamaños de ventana ( $k$ ).

#### 5.1.4. Suavizado de Kalman

Un filtro de Kalman, explicado de manera simplificada, es un algoritmo de procesamiento especialmente utilizado para modelar sistemas dinámicos y procesos estocásticos. Estos modelos gozan de una serie de propiedades que les permite representar con gran exactitud este tipo de sistemas, por ejemplo, la capacidad de modelar factores que provocan perturbaciones en el estado del proceso, como el ruido de las señales o la imprecisión de los sensores. Para ello, el estado del proceso en el instante  $t$  es calculado partiendo de estados pasados (lo que la convierte en una función recursiva), observaciones presentes (es decir, datos que hagan referencia a fenómenos ocurridos en el instante actual  $t$ , como puede ser la medición de un sensor) y factores modelados probabilísticamente (por ejemplo, factores relacionados con el ruido). Todos estos valores se ponderan mediante unos parámetros, que habrá que optimizar de manera que el error sea minimizado. Descripciones



**Figura 5.7:** Resultados obtenidos utilizando la Media Móvil Ponderada Lineal como método de imputación, con diferentes tamaños de ventana ( $k$ ).

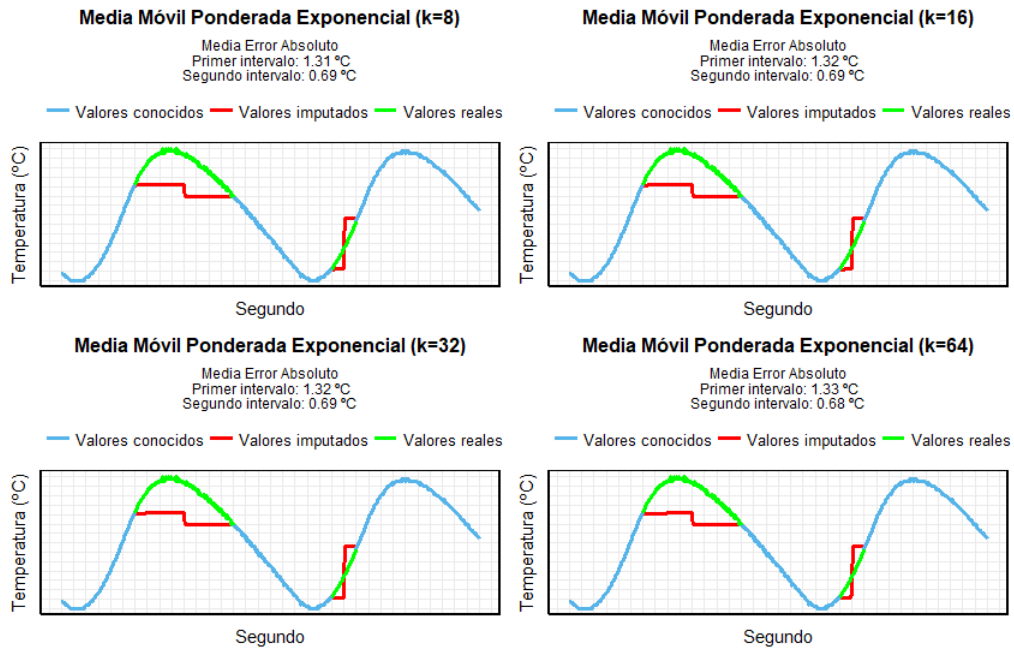
más detalladas sobre los filtros de Kalman y sus bases matemáticas pueden encontrarse en [Welch and Bishop, 2001] y [Maybeck, 2012].

Una variante estrechamente relacionada al filtro de Kalman es el suavizado de Kalman, donde la diferencia se basa principalmente en la propiedad de causalidad de los datos<sup>2</sup>, propiedad que se cumple en filtro, pero no en el suavizado. Por tanto, el suavizado de Kalman utilizará valores pasados, presentes y futuros para calcular el estado del sistema en un instante determinado. Intuitivamente, el suavizado también podría interpretarse como una acción de intentar "corregir" estimaciones pasadas con el fin de mejorar la representación del sistema. Por otro lado, el filtrado podría interpretarse como una acción de predecir valores futuros partiendo de valores pasados y presentes.

Los métodos de imputación utilizados aplicarán el suavizado de Kalman sobre un modelo conocido como espacio de estados, lo que, explicado de manera simplificada, será el modelo utilizado para la representación del sistema dinámico. Para realizar las pruebas hemos utilizado dos tipos de modelo:

- Modelo estructural básico, el cual representa el espacio de estados mediante la des-

<sup>2</sup> Un sistema cumple la propiedad de causalidad si solamente utiliza valores de instantes presentes y/o pasados para calcular el estado actual, es decir, si no utiliza valores futuros.



**Figura 5.8:** Resultados obtenidos utilizando la Media Móvil Ponderada Exponencial como método de imputación, con diferentes tamaños de ventana ( $k$ ).

composición de la serie temporal en componentes que describen la evolución de dicha serie (media, tendencia, etc.).

- Modelo Autorregresivo Integrado de Promedio Móvil, más conocido como ARIMA (acrónimo de la terminología inglesa *AutoRegressive Integrated Moving Average*). En este caso, la serie temporal es modelada mediante tres componentes principales:
  - El componente autorregresivo  $AR(p)$ , el cual utiliza valores pasados para realizar la regresión de los valores de la serie temporal a modelar (el parámetro  $p$  denotará el número de términos pasados a utilizar).
  - El componente integrador  $I(d)$ , el cual denotará el grado de diferenciabilidad  $d$  del modelo. En nuestro contexto, diferenciar hace referencia a la operación de restar valores contiguos  $d$  veces, es decir, calcular  $\sum_{i=t-d+1}^t (y_i - y_{i-1})$ , siendo  $y_t$  el valor de la serie en el instante  $t$ . Esta transformación elimina el efecto de componentes como la tendencia y la estacionalidad, lo que convierte la serie temporal en estacionaria<sup>3</sup>


<sup>3</sup> En teoría de sistemas, se dice que un proceso es estacionario si las variables que definen su comportamiento no varían respecto al tiempo. Una noción similar se aplica también en campos como la estadística, donde se dice que un proceso estocástico es estacionario si los parámetros de su distribución de probabilidad (como podrían ser la media, la varianza, etc.) no varían respecto al tiempo.

- El componente media móvil  $MM(q)$ , el cual modela el error del sistema mediante la combinación de términos de error anteriores (el parámetro  $q$  especifica el número de términos de error a utilizar).

Combinando estos tres componentes, obtenemos el modelo  $ARIMA(p, d, q)$ .

Aunque ambos modelos tienen características comunes, se distinguen principalmente en que, mientras que en el modelo estructural la tendencia y estacionalidad se modelan de manera explícita, en el modelo ARIMA estos componentes se eliminan mediante la diferenciación sucesiva (la que define el componente integrador  $I(d)$ ) [Durbin and Koopman, 2012].

Una vez introducidas las nociones básicas para entender en qué se basa este método de imputación, presentaremos en las Figuras 5.9 y 5.10 los resultados obtenidos con los dos modelos de espacio de estados mencionados (estructural y ARIMA). Como podemos observar, en los dos casos los valores imputados se ajustan con una gran exactitud a los valores reales, por lo que parecen métodos adecuados para realizar la imputación, al menos en intervalos estables. Sin embargo, hay que tener en cuenta que estos métodos requieren un proceso de ajuste para la optimización de parámetros, lo que podría suponer un tiempo de cómputo elevado en grandes volúmenes de datos.




**Figura 5.9:** Resultados obtenidos utilizando el suavizado de kalman (usando un modelo estructural) como método de imputación.

### 5.1.5. Comparación de los resultados

A modo de resumen, y para poder comparar el efecto de cada método de imputación, se han recogido en la Figura 5.11 los errores obtenidos en cada caso. Como podemos ver, los métodos basados en el suavizado de Kalman parecen ser los más adecuados, ya que






**Figura 5.10:** Resultados obtenidos utilizando el suavizado de kalman (usando un modelo ARIMA) como método de imputación.

consiguen un error significativamente menor al resto, y formas con una continuidad muy similar a la de los datos originales.

Respecto a los demás métodos de imputación, hay que tener en cuenta que, a pesar de que en estas pruebas no hayan conseguido resultados adecuados, podrían ser efectivos en otro tipo de señales o para otro tipo de objetivos. Un ejemplo de esto lo podemos ver en la Sección 5.5.1, donde se ha aplicado satisfactoriamente la técnica *Last Observation Carried Forward* para el tratamiento de valores atípicos.

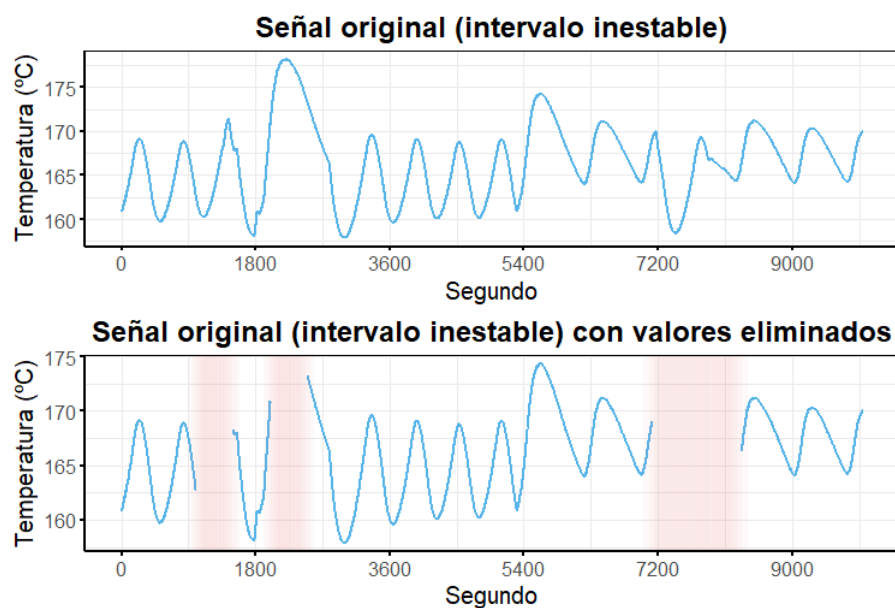


**Figura 5.11:** Comparación del error obtenido en los diferentes métodos de imputación

Prueba adicional: imputación en intervalos inestables

Para evaluar el grado de error de los métodos de imputación en situaciones más complejas (por ejemplo, en intervalos más inestables), vamos a realizar las mismas pruebas en un nuevo intervalo, el cual se muestra en la Figura 5.12. En esta señal, los dos primeros intervalos eliminados serán de 8 minutos (480 segundos), y el tercero de 20 minutos

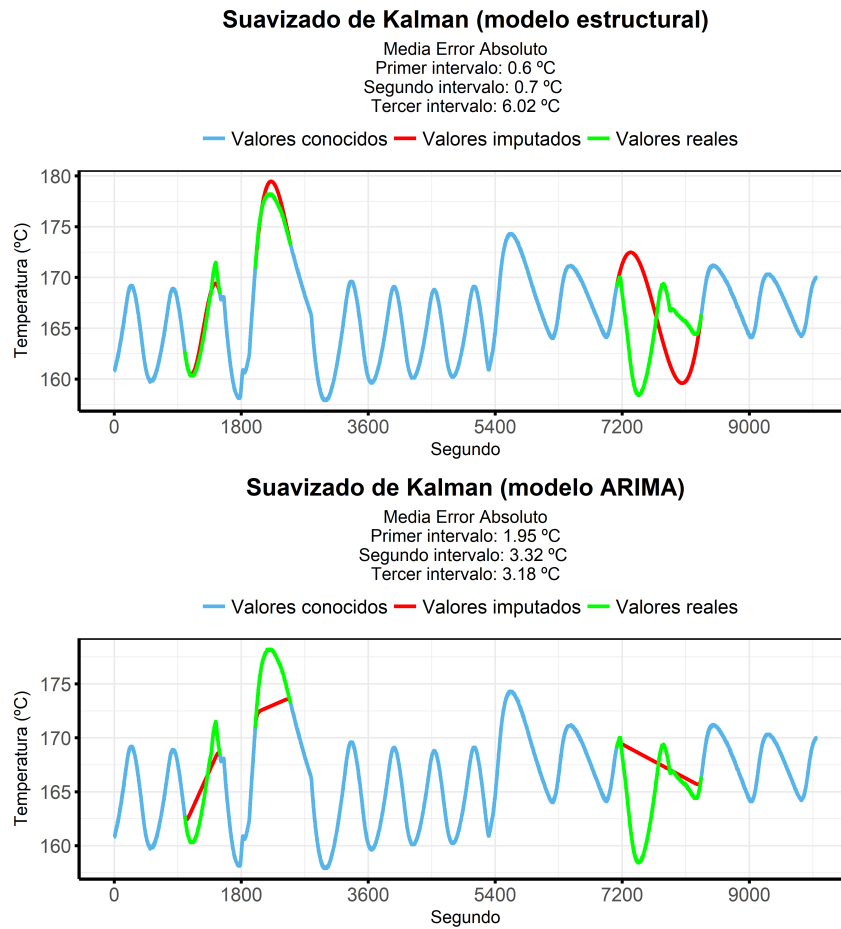
(1200 segundos). En esta prueba, solo se tendrán en cuenta los métodos basados en el suavizado de Kalman, debido a que han sido los únicos con unos resultados adecuados en la prueba anterior.



**Figura 5.12:** Segundo intervalo (con inestabilidades) para analizar el comportamiento de los métodos de imputación. Las zonas con los valores eliminados se han resaltado en rojo, para facilitar su detección.

En este caso, el método basado en el modelo ARIMA no consigue un buen ajuste en los intervalos perdidos, lo que muestra una falta de convergencia en el proceso de ajuste de parámetros, posiblemente debido a la irregularidad de la señal. El método basado en el modelo estructural, sin embargo, consigue interpolar los tres intervalos de manera adecuada, siendo el tercero de ellos el menos exacto, aunque el resultado sea aceptable al menos en cuanto a la forma, ya que logra una continuidad similar al resto de oscilaciones de la serie.

A la vista de los resultados obtenidos, podemos concluir que el método basado en el suavizado de Kalman (sobre un modelo estructural) es el más efectivo a la hora de realizar la imputación de valores perdidos, ya que, en las pruebas realizadas, ha resultado ser el único método capaz ajustarse de manera adecuada a la mayoría de intervalos con datos omitidos.



**Figura 5.13:** Resultados de los métodos de imputación basados en el suavizado de Kalman en un intervalo inestable.

## 5.2. Eliminación de ruido

La eliminación del ruido en las señales puede mejorar significativamente la calidad de los datos, ya que, como se ha comentado anteriormente, diversos análisis o modelos de minería de datos pueden ser sensibles a tales perturbaciones. Un ejemplo de esto lo hemos visto en la Sección 5.1.2, donde se comprobó que el método de imputación basado en la interpolación mediante splines mejoraba significativamente los resultados al utilizar una señal sin ruido.

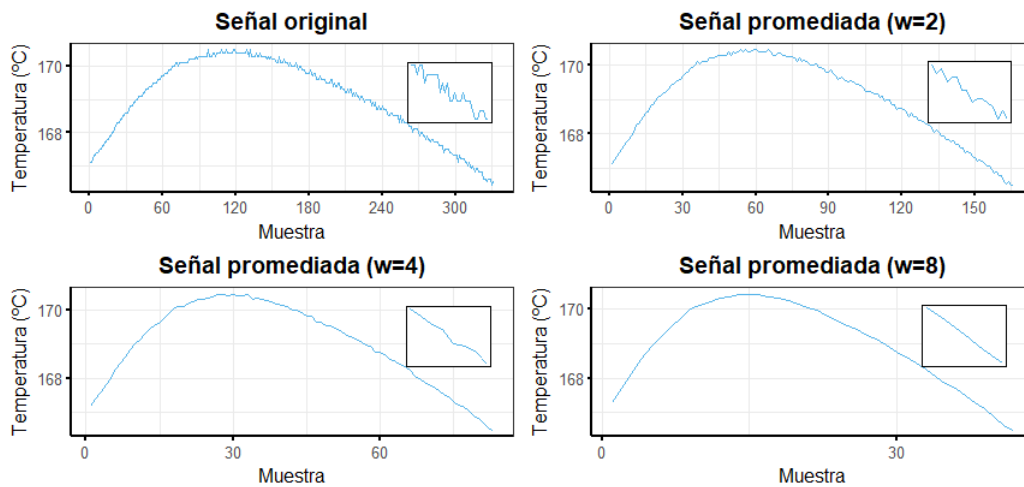
Por tanto, en esta sección vamos a analizar dos maneras principales de eliminar el ruido en los datos: promediando las señales y mediante el filtrado del dominio frecuencial.

### 5.2.1. Suavizado por promedio

Este método se basa simplemente en calcular el promedio de la señal para intervalos consecutivos, usando para ello una ventana de tamaño  $w$ . De manera formal, definiremos la transformación de la siguiente manera: siendo  $s = (s_1, \dots, s_N)$  una señal de tamaño  $N$ , el objetivo será calcular un vector  $s' = (s'_1, \dots, s'_M)$  de tamaño  $M = \frac{N}{w}$  donde:

$$s'_i = \frac{1}{w} \sum_{j=1}^w s_{j+(i-1)w}$$

A modo de ejemplo, en la Figura 5.14 se muestran los resultados obtenidos al suavizar una señal de temperatura con esta técnica, utilizando para ello ventanas rectangulares de 2, 4, y 8 muestras. Como podemos observar, la transformación logra reducir el nivel de ruido de manera significativa, siendo mayor el efecto del filtrado a medida que aumentamos el tamaño de la ventana.




**Figura 5.14:** Efecto del suavizado por promedio en una señal de temperatura, para diferentes tamaños de ventana ( $w$ ).

El principal inconveniente de esta técnica es que supone una pérdida de información, además de una reducción en el número de muestras de la señal, lo que puede ser un inconveniente dependiendo del tipo de análisis que se quiera realizar. Por tanto, las características de la ventana (tamaño, tipo, solapamiento...) deberán de ser adaptadas de manera adecuada dependiendo de los objetivos o análisis posteriores.

Por último, esta técnica puede extenderse modificando el tipo de ventana utilizada (la cual ponderará los valores de la señal dependiendo de su posición en el intervalo), o añadiendo

un solapamiento (es decir, el número de muestras que se solapan entre dos intervalos contiguos). Para presentar estas características de manera gráfica, se han añadido en la Figura 5.15 dos tipos comunes de ventana (rectangular y Hamming), y una representación del efecto del solapamiento.



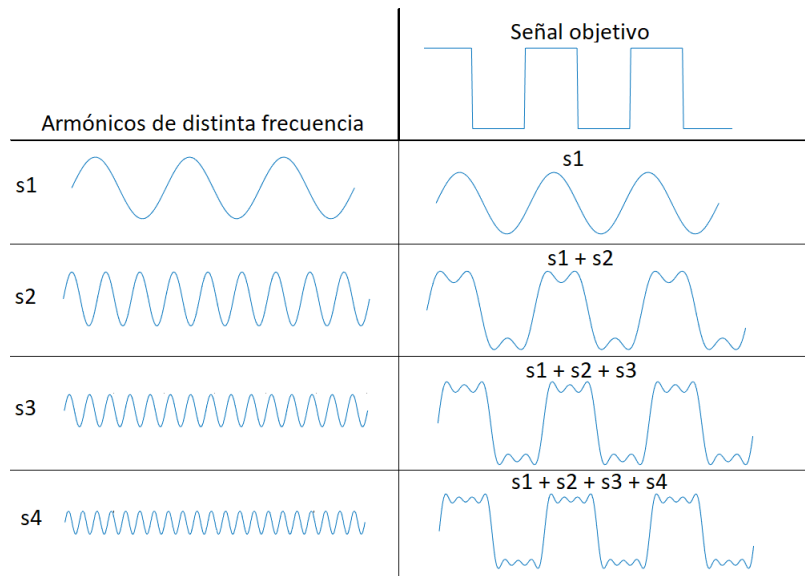
**Figura 5.15:** Representación de diferentes variaciones para realizar el filtrado por promedio: ventana regular (arriba), ventana de Hamming sin solapamiento (medio) y ventana de Hamming con solapamiento (abajo)

### 5.2.2. Suavizado mediante el filtrado frecuencial

Todos los análisis que se han realizado hasta ahora se han basado en el dominio temporal, el cual describe la evolución de la señal en función del tiempo. Sin embargo, en procesamiento de señales, es común utilizar el dominio frecuencial, el cual describe las características de los componentes frecuenciales que forman la señal. Como el análisis del dominio frecuencial puede resultar complejo, se van a introducir las nociones básicas, de modo que el lector pueda comprender los fundamentos de este método de suavizado sin la necesidad de estar familiarizado de antemano con el análisis frecuencial de las señales.

En pocas palabras, el análisis del dominio frecuencial se fundamenta en la posibilidad de representar una señal por medio de combinaciones de sinusoides armónicas<sup>4</sup> de distinta

<sup>4</sup>Diremos que un conjunto de señales sinusoidales están armónicamente relacionadas si todas tienen el mismo periodo.



**Figura 5.16:** Ilustración de la generación de una señal a partir de sinusoides armónicas de distinta frecuencia. Nótese que a medida que aumentamos la frecuencia, también disminuye su amplitud, lo que refleja la magnitud (o "importancia") de tal armónico en la señal objetivo.

frecuencia. Para ilustrar un ejemplo, hemos creado la Figura 5.16. Por tanto, mediante esta representación, podemos describir cuál es la magnitud de cada frecuencia, lo que intuitivamente se puede entender como la influencia de la senoide correspondiente a dicha frecuencia en la señal original<sup>5</sup>.

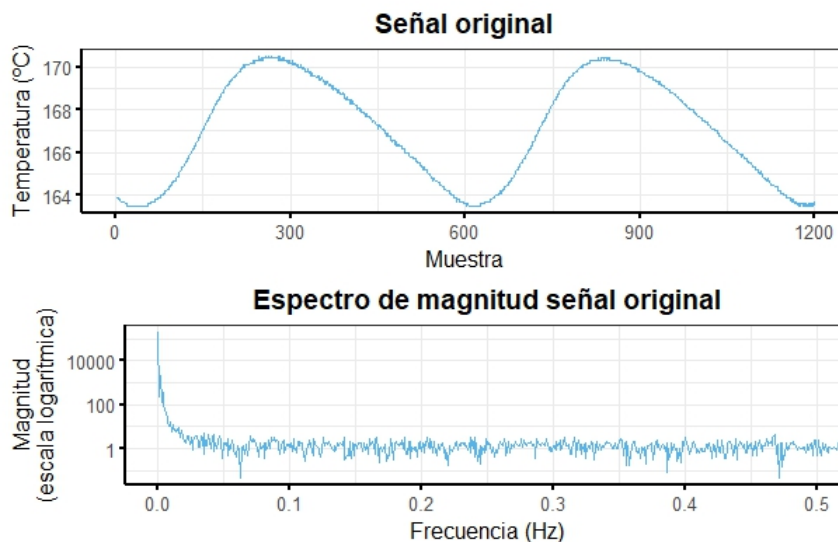
Por ejemplo, si generáramos una señal sinusoidal de frecuencia  $\omega$  y analizáramos su dominio frecuencial, veríamos que, excepto  $\omega$ , el resto de frecuencias tendría una magnitud nula, ya que  $\omega$  es la única frecuencia presente en la señal. De una manera similar, si analizáramos el dominio frecuencial de una señal de audio en la que se escucha una nota musical, veríamos que existe una frecuencia con una magnitud predominante: la relativa a la nota escuchada (ya que una nota musical no es más que un sonido con una frecuencia de vibración determinada). De esta manera, podríamos averiguar cuál es la nota presente en el audio, algo que sería imposible desde el dominio temporal, donde solamente veríamos la evolución del volumen a lo largo del tiempo (mediante la amplitud de la señal).

Siguiendo con el ejemplo de la nota musical, pondremos un ejemplo de filtrado en el dominio frecuencial: imaginemos que tenemos un audio en el que un pitido intenso y constante (por ejemplo, una nota musical generada artificialmente) eclipsa el sonido de una conversación. Si mediante el dominio frecuencial detectamos cuál es la frecuencia del

<sup>5</sup> Además de la magnitud, la fase es otra característica fundamental en la que se basa el análisis frecuencial, pero será omitida en esta sección debido a que no será relevante para la comprensión del método de filtrado.

pitido, y eliminamos (filtramos) ese componente, lograremos eliminar el pitido y escuchar la conversación, originalmente inaudible.

Llevando esta idea a nuestros datos, el ruido de las señales puede ser eliminado filtrando las frecuencias que lo generen. Para ello, es necesario primero analizar cómo es el espectro de magnitud de nuestras señales. En la Figura 5.17 mostramos el espectro de magnitud de una señal de temperatura. El espectro refleja claramente que la señal está compuesta principalmente por frecuencias muy bajas, lo que tiene sentido por dos razones: la primera es que la evolución de la temperatura toma una forma mayormente sinusoidal, como ya hemos mencionado anteriormente, y la segunda es que dicha evolución se produce de manera lenta, realizando una oscilación completa aproximadamente cada 600 muestras, lo que refleja una frecuencia fundamental de aproximadamente  $\frac{1}{600}\text{Hz}$ <sup>6</sup>.

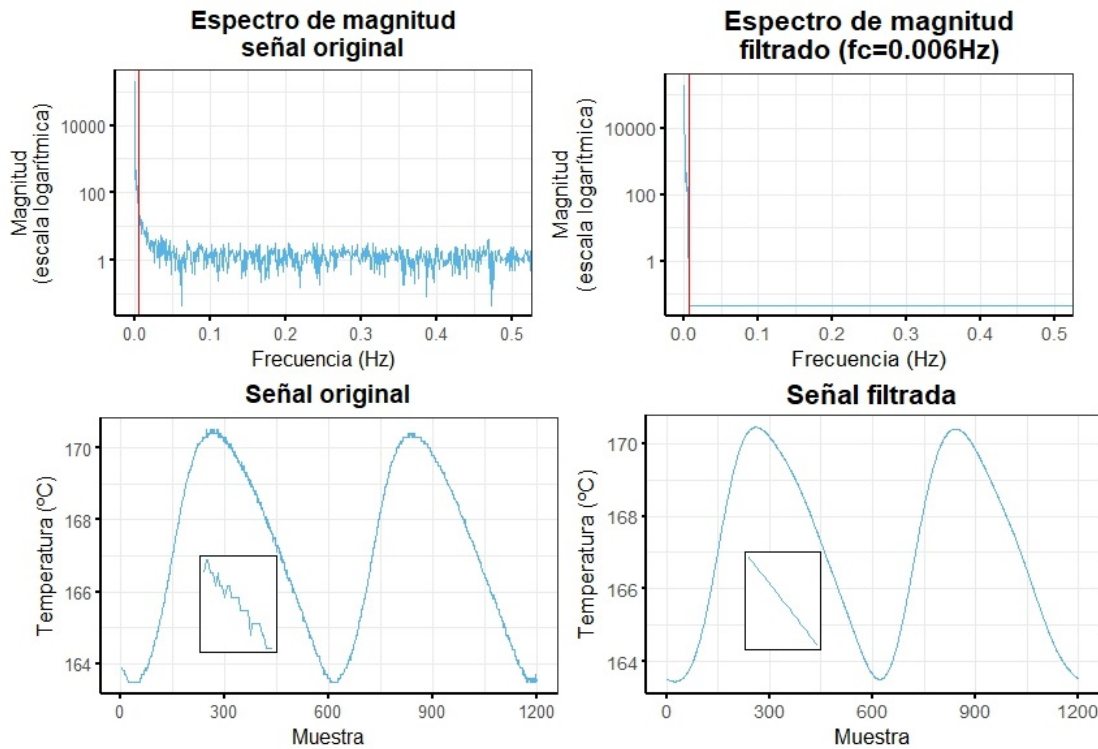


**Figura 5.17:** Espectro de magnitud de una señal de temperatura.

En definitiva, este análisis muestra que, desde un punto de vista frecuencial, la mayor parte de la información está contenida en un rango muy reducido de frecuencias (bajas). Por tanto, el resto de frecuencias (altas) no proporcionan información relevante, y, de hecho, podrían ser las causantes del ruido. Para comprobar si esto es cierto, vamos a eliminar las frecuencias altas mediante lo que se denomina un filtro paso bajo. Este filtro eliminará la información frecuencial a partir de una frecuencia en concreto, comúnmente denominada frecuencia de corte. Los resultados obtenidos con este filtro se muestran en la Figura 5.18. Como podemos observar, el ruido ha sido eliminado de manera completa, lo que confirma

<sup>6</sup>La razón física por la que las señales de temperatura oscilan a tan baja frecuencia se debe a la inercia térmica de los sistemas como las extrusoras, ya que no es físicamente posible hacer oscilar la temperatura varios grados en pocos segundos

que las frecuencias altas son las responsables del ruido en la señal. Cabe destacar que, al contrario que en el suavizado por promedio, este método no supone una reducción en el tamaño de la serie.



**Figura 5.18:** Resultados obtenidos al filtrar el dominio frecuencial de la señal para eliminar el ruido. En las imágenes relativas al espectro de magnitud, se ha añadido en rojo la frecuencia de corte del filtro paso bajo ( $f_c$ ).

#### Apartado adicional: compresión mediante el dominio frecuencial

Antes de finalizar, queremos matizar el hecho de que con solamente un rango de frecuencias muy reducido somos capaces de representar la señal de una manera precisa y sin ruido. Esto puede tener múltiples aplicaciones además del filtrado del ruido, como por ejemplo, en la compresión de los datos, ya que en vez de almacenar la señal completa, podemos almacenar únicamente la información frecuencial filtrada, ahorrando espacio de almacenamiento. Además, como la pérdida de información será muy baja, el error de reconstrucción será mínimo.

Para comprobar el ahorro en espacio que podría suponer, vamos a comparar el espacio de almacenamiento original de una señal de temperatura con el espacio de almacenamiento del dominio frecuencial filtrado (a lo que nos referiremos como señal comprimida). Para



Media error absoluto reconstrucción (umbral)	Número muestras señal comprimida	Espacio en disco señal comprimida	Ahorro espacio en disco
0,05	6.391	94KB	99,47%
0,1	4.501	66KB	99,63%
0,5	2.187	32KB	99,82%
Señal original	604.486	18.043KB	

**Tabla 5.1:** Resultados obtenidos al aplicar el filtro en el dominio frecuencial como método de compresión para una señal de temperatura.

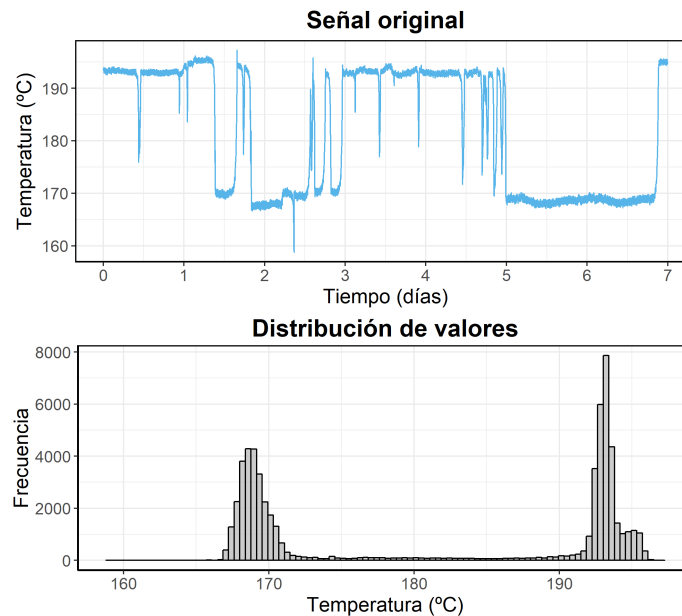
controlar el error de reconstrucción de la señal vamos a fijar un umbral, es decir, debemos encontrar una frecuencia de corte con la que, filtrando el espectro de magnitud, la media de error (absoluto) de la señal reconstruida sea igual o menor al umbral especificado.

Los resultados obtenidos se muestran en la Tabla 5.1. Como podemos observar, la reducción supone un ahorro muy significativo de espacio en disco, lo que indica que es un método efectivo para la compresión de las señales, al menos en las de temperatura. El análisis de la efectividad de otros métodos de reducción y su aplicabilidad en los diferentes tipos de señales queda fuera del alcance de este proyecto.

### 5.3. Discretización

La discretización de valores continuos suele ser necesaria al trabajar con datos continuos, ya que muchos de los modelos de minería de datos están diseñados e implementados para trabajar con datos discretos. Sin embargo, dependiendo de las técnicas de discretización que utilizemos, conseguiremos diferentes resultados, los cuales pueden ser importantes a la hora de trabajar sobre los datos.

Para analizar el efecto de las diferentes técnicas de discretización, vamos a utilizar la señal de temperatura mostrada en la Figura 5.19. En la misma Figura se muestra también la distribución de los valores de la señal, donde podemos observar que existen dos zonas principales con una gran densidad de datos. Para poder comparar adecuadamente los resultados de las diferentes técnicas, la señal será discretizada en 10 intervalos. En cada caso, mostraremos a modo de resultado los intervalos asignados por cada método utilizada, así como la proporción de observaciones por intervalo obtenidas.

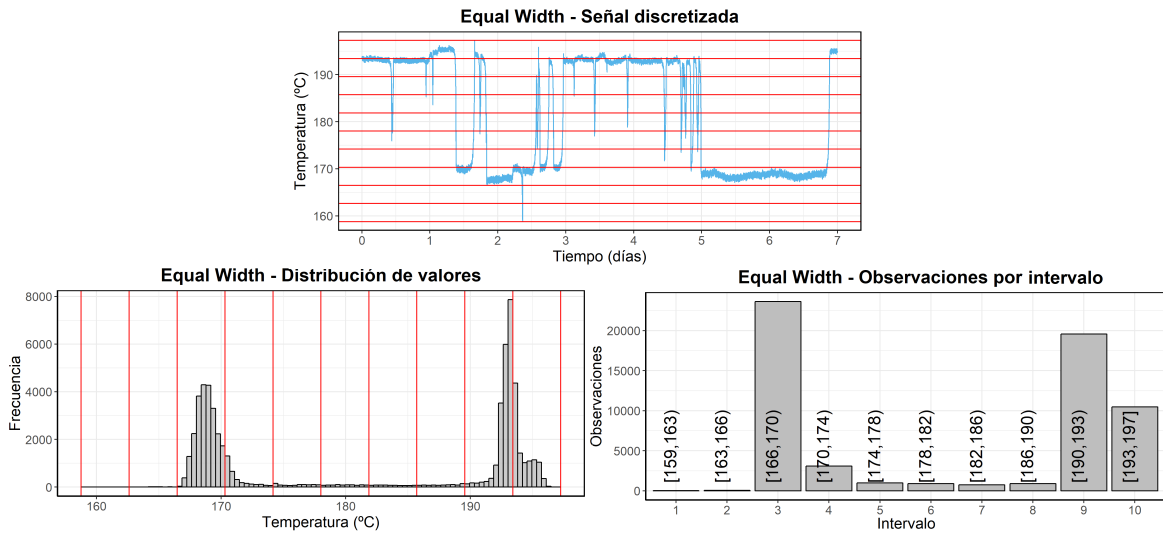


**Figura 5.19:** Distribución de valores de la señal de temperatura utilizada para la comparación de los métodos de discretización.

### 5.3.1. Espaciado uniforme (Equal Width)

Este método discretizará la señal dividiendo el rango de valores en intervalos uniformes, es decir, del mismo tamaño o anchura [Yang and Webb, 2001]. Este criterio es el más efectivo cuando la distribución de valores es uniforme, ya que cada intervalo tendría asignado un número similar de observaciones. Sin embargo, cuando la distribución de valores no cumple esta condición (como es nuestro caso), existe el riesgo de que este criterio agrupe en el mismo intervalo una zona de alta densidad, perdiendo resolución en esa zona, y obteniendo una discretización desbalanceada.

Los resultados obtenidos con este método se muestran en la Figura 5.20. Tal y como hemos explicado, los resultados muestran que los intervalos no están proporcionadas en cuanto al número de observaciones. Esto podría suponer un inconveniente a la hora de aplicar modelos de minería de datos, ya que un conjunto de datos desbalanceado reduce significativamente la capacidad de aprendizaje. En cualquier caso, valorar si esto es un inconveniente o no depende de las características del análisis posterior.



**Figura 5.20:** Discretización de una señal de temperatura en 10 intervalos, utilizando el método *equal width*. Se han añadido en rojo los límites de los intervalos asignados.


### 5.3.2. Frecuencia uniforme (Equal Frequency)

En este caso, el rango de valores se dividirá de tal manera que todos los intervalos tengan el mismo número de observaciones [Yang and Webb, 2001]. Por tanto, este método sí conseguirá un reparto proporcionado de los valores de la variable discretizada en señales con una distribución de valores no uniforme, ofreciendo una mayor resolución en las zonas de alta densidad. A costa de eso, los intervalos no serán uniformes, y estarán condicionados por el conjunto usado para la discretización. Esto quiere decir que los intervalos seleccionados para un conjunto determinado de datos podría no ser adecuado para otro conjunto, lo que dificultaría la compatibilidad.

Los resultados obtenidos con esta técnica se muestran en la Figura 5.21, donde se puede ver que la mayoría de intervalos se encuentran en las zonas de alta densidad de observaciones, consiguiendo así un reparto proporcionado de los posibles valores.

### 5.3.3. Algoritmo *K-means*

Este método generará el reparto de clases utilizando el algoritmo de agrupamiento *K-means*. En pocas palabras, el reparto se realiza de tal manera que cada observación pertenece al grupo que, mediante un criterio de cercanía, tiene un valor medio más cercano



**Figura 5.21:** Discretización de una señal de temperatura en 10 intervalos, utilizando el método *equal frequency*. Se han añadido en rojo los límites de los intervalos asignados.

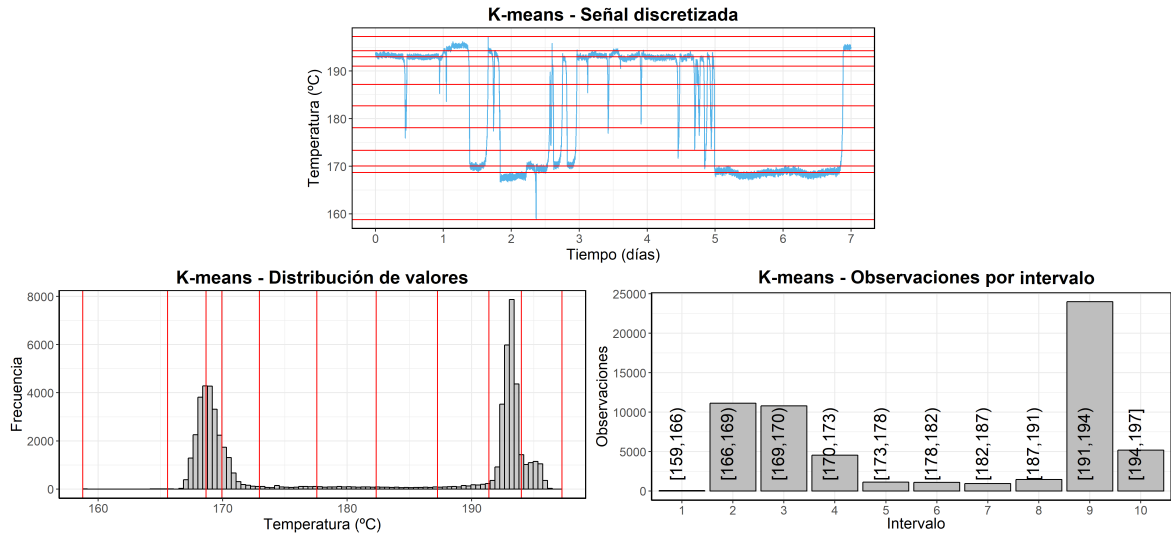
[Gupta et al., 2001]. Una característica a tener en cuenta es que el algoritmo no es determinista, ya que el algoritmo asigna inicialmente los grupos de manera aleatoria. Por tanto, dos ejecuciones distintas sobre el mismo conjunto de datos no garantiza conseguir el mismo reparto.

Los resultados obtenidos con este método se muestran en la Figura 5.22. En este caso, vemos que los intervalos tampoco son uniformes, y, aunque consiga un reparto ligeramente más uniforme que el método *equal width*, no logra una resolución tan alta en las zonas de alta densidad como la obtenida con el método *equal frequency*.

## 5.4. Alineación de los datos

En un proceso donde se recogen series temporales de diferentes sensores, la organización de los datos se puede realizar desde diferentes puntos de vista, los cuales se van a definir de la siguiente manera:

- *Time-driven*, donde los datos se organizan en función del tiempo.
- *Product-driven*, donde los datos se organizan en base a cada unidad de producto.



**Figura 5.22:** Discretización de una señal de temperatura en 10 intervalos, utilizando el método *K-means*. Se han añadido en rojo los límites de los intervalos asignados.

Time-driven		
Timestamp	Temp. zona 1 (°C)	Temp. zona 2 (°C)
0:00:00	180	190
0:00:01	181	191
0:00:02	182	192
0:00:03	183	193
0:00:04	184	194
0:00:05	185	195

**Tabla 5.2:** Ejemplo de una alineación *time-driven* de dos señales de temperatura.

Para entender mejor las diferencias entre estas dos manera de organizar los datos, consideremos el siguiente ejemplo: supongamos que una sección de fluido tarda dos segundos en trasladarse de la Zona 1 a la Zona 2 de una extrusora. Si alineamos las señales con el *timestamp* como referencia, diremos que estamos realizando una organización *time-driven*, consiguiendo un conjunto de datos como el mostrado en la Tabla 5.2. Sin embargo, como el fluido necesita dos segundos en desplazarse de una zona a otra, sabemos que, el material presente en la Zona 1 en el instante  $t$ , estará en la Zona 2 a en el instante  $t + 2$ . Por tanto, podemos organizar el conjunto de datos con el producto como referencia (*product-driven*), retrasando dos muestras la señal de la Zona 2 (o adelantando la Zona 1), como se muestra en la Tabla 5.3.

La ventaja de organizar el conjunto de datos con el producto como referencia es la posibilidad de obtener información acerca del mismo a lo largo del proceso, lo que permite estimar, entre otras cosas, a qué temperatura estaban las zonas de la máquina en los instantes en el que el producto las atravesó, dando pie a descubrir patrones que detecten, por

Product-driven		
Timestamp (referencia zona 2)	Temp. zona 1 (°C)	Temp. zona 2 (°C)
0:00:00		190
0:00:01		191
0:00:02	180	192
0:00:03	181	193
0:00:04	182	194
0:00:05	183	195
0:00:06	184	
0:00:07	185	

**Tabla 5.3:** Ejemplo de una alineación *product-driven* de dos señales de temperatura, donde el material necesita dos segundos para trasladarse de una zona a otra.

ejemplo, cuándo una botella será de mala calidad.

Sin embargo, calcular la posición que ha tenido el plástico de una botella determinada a lo largo del proceso es una tarea extremadamente compleja, como se explica en el Anexo A. Aunque en el mercado existan simuladores especializados en procesos de extrusión de polímeros, su manejo es complejo y requiere un trabajo previo que excedería el alcance de este TFG (por ejemplo, el modelado virtual de la máquina). Por este motivo, para realizar estos cálculos vamos a utilizar una aproximación básica, teniendo en cuenta simplemente las características básicas de la extrusora, como la geometría de los elementos principales y la velocidad de motor.

Como la organización *time-driven* es trivial, en este apartado vamos a exponer cómo hemos alineado las series temporales para conseguir una organización *product-driven*. Realmente, lo que expondremos será cómo hemos calculado el desfase temporal entre las zonas, es decir, el tiempo que necesita el producto para desplazarse de una zona a otra, ya que, conociendo eso, la alineación se basa simplemente en retrasar o adelantar cada señal el número de segundos necesario. Para empezar, expondremos la información que hemos utilizado para esta tarea:

- Distancias entre los sensores, las que definiremos como  $d = (d_1, \dots, d_N)$ , siendo  $N + 1$  el número de sensores, y  $d_i$  la distancia entre el sensor de la Zona  $i$  y el sensor de la Zona  $i + 1$ . También debemos de conocer la posición de cada sensor en la máquina, para poder relacionarlo con los demás elementos.
- Velocidad de giro del husillo,  $v_{RPM}$  (recordemos que la unidad es el número de revoluciones por minuto).
- Paso del husillo, es decir, la distancia lineal de una vuelta del tornillo. Teniendo

en cuenta que el paso del husillo puede variar a lo largo del mismo, es necesario conocer el paso en cada zona, así como los puntos en los que se produce un cambio, ya que afectará de manera directa a la velocidad de desplazamiento. Por tanto, los pasos de las diferentes zonas los definiremos como  $p = (p_1, \dots, p_M)$ , siendo  $M$  el número de zonas del husillo.

- Longitud del cilindro, longitud del cabezal y longitud del husillo.

A continuación, explicaremos cómo hemos realizado el cálculo del tiempo que necesita el material para trasladarse de una zona a otra. Como las características del avance no son las mismas en el cilindro y en el cabezal, explicaremos de manera individual el avance en cada zona:


- Avance en el cilindro

Para calcular la velocidad de desplazamiento del material en el cilindro, debemos de conocer, a partir de las características del husillo y de la velocidad de giro, qué velocidad de avance tiene el producto en las diferentes zonas. A modo de ejemplo, consideremos la Figura 5.23, la que muestra una extrusora de solamente dos zonas. Si el paso del husillo en la zona  $i$  es de  $p_i$  milímetros (mm), sabemos que, en una vuelta completa, el producto avanzará  $p_i$  milímetros. Si la velocidad de giro es de  $v_{RPM}$  vueltas por minuto, la velocidad de desplazamiento en la zona  $i$  ( $v_i$ , en milímetros por segundo) será:

$$v_i = \frac{v_{RPM} \cdot p_i}{60}$$

Si calculamos la velocidad para cada zona, sabiendo las distancias  $d = (d_1, \dots, d_N)$  entre los sensores, el tiempo necesario que necesita el fluido para llegar de una zona a otra será de  $\frac{d_i}{v_i}$  segundos. Hay que tener en cuenta que entre dos sensores pueden existir puntos de cambio de velocidad, por lo que los cálculos deberán realizarse teniendo en cuenta dichos cambios. Por otro lado, tal y como se muestra en la Figura 5.23, se va a considerar que la distancia entre dos zonas consecutivas es la distancia entre los sensores de ambas zonas, por lo que, interpretamos que el producto alcanza la zona  $i$  cuando alcanza el punto en el que se sitúa el sensor, ya que este será el punto medio de la zona.

Como último apunte, tenemos que tener en cuenta que la longitud del husillo suele ser menor a la del cilindro, como se muestra en la Figura 5.23. Sin embargo, podemos asumir que la velocidad de avance del producto en ese intervalo es la misma que en la última zona del husillo.



**Figura 5.23:** Representación de una extrusora de dos zonas.

- Avance en el cabezal

Aunque el flujo de material en el cabezal se mantiene constante, el avance en esta zona ha sido más complicado de modelar, ya que el fluido atraviesa secciones de diferentes características hasta llegar a la salida. Además, algunas de estas secciones no son estáticas, ya que se ajustan dependiendo del producto que se quiera realizar, como por ejemplo la anchura de la boquilla y secciones previas, lo que se utiliza para controlar el espesor del material expulsado, entre otras cosas.

La estimación más básica podría realizarse simplemente asumiendo la misma velocidad de la última zona del cilindro (es decir, la zona anterior al cabezal), aunque esto podría ser demasiado impreciso, ya que el flujo no es necesariamente el mismo en esas dos zonas. Por otro lado, asumiendo que el flujo es constante, también podríamos estimar el caudal si conociéramos la frecuencia con la que se expulsa el material, así como la cantidad expulsada por unidad de producto. Sin embargo, no tenemos datos que proporcionen dicha información.

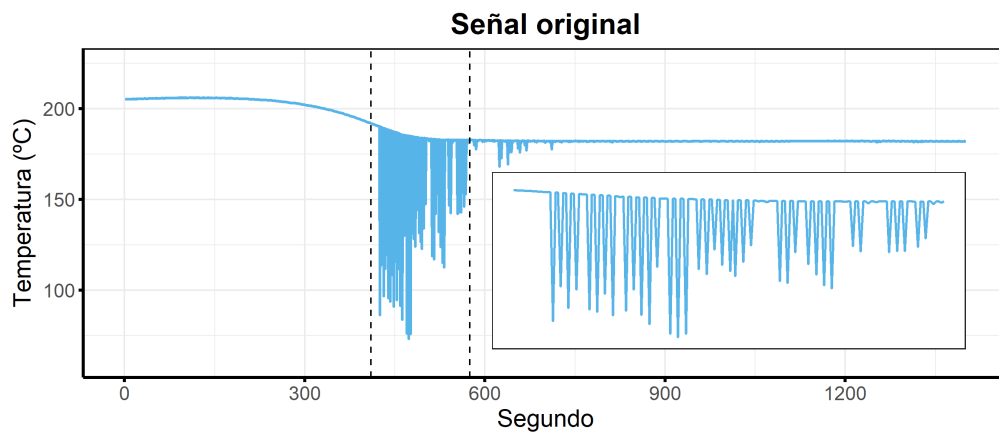
En definitiva, creemos que una organización *product-driven* requiere un proceso de cálculo extremadamente complejo como para ser aplicado de manera eficiente y precisa. Si bien en [Beltrán and Marcilla, 2012] se proponen aproximaciones eficientes para modelar estos procesos, estas se limitan a la zona de dosificado del material, por ser la zona más simple de modelar, ya que se asume que el material está totalmente fundido y homogeneizado. Además, dichas aproximaciones requieren datos que, por el momento, no tenemos disponibles, como la viscosidad del material a lo largo del proceso o la información sobre la presión en las diferentes zonas.



Por todos estos motivos, creemos que la alineación de los datos presentada en esta sección podría ser mejorada en líneas futuras añadiendo más información sobre el proceso de extrusión y con un mejor modelado de la dinámica del fluido.

## 5.5. Tratamiento de valores atípicos

Como expusimos en las Sección 4.3.1, hemos observado que las señales contienen datos que claramente muestran valores atípicos, como por ejemplo, descensos repentinos de temperatura, como se muestra en la Figura 5.24.



**Figura 5.24:** Señal de temperatura utilizada para evaluar las técnicas de tratamiento de valores atípicos.

Aunque el concepto de *valor atípico* varía dependiendo de las características de los datos, se han propuesto métodos generales para la detección de los mismos [Niu et al., 2011]. En esta sección, presentaremos dos maneras de realizar la detección y corrección de este tipo de errores, los cuales consiguen resultados adecuados en nuestros datos.


### 5.5.1. Test de Tukey

Este método clasificará como *outlier* cualquier valor que se encuentre fuera de un intervalo de valores definido en base al rango intercuartil de los datos ( $RQ$ ), el cual se define como  $RQ = Q_3 - Q_1$ , siendo  $Q_3$  y  $Q_1$  el tercer y primer cuartil de la distribución de valores, respectivamente. De manera formal, el rango de *valores típicos* o *normales* lo definiremos como  $[Q_1 - k(Q_3 - Q_1), Q_3 + k(Q_3 - Q_1)]$ , con  $k \in \mathbb{R}^+$ , aunque generalmente

se utilice  $k = 1,5$ . Por tanto, cualquier valor fuera de este rango se considerará un valor atípico.

Como las señales pueden cambiar su zona de oscilación a lo largo del tiempo, calcular el rango intercuartil utilizando largos periodos de tiempo puede llevar a falsos positivos. Una solución a este problema podría ser el uso de una ventana móvil, cuyo tamaño puede ajustarse dependiendo de las características de los datos (en nuestro caso, hemos utilizado una ventana de 50 muestras).

Una vez detectados los valores atípicos, podríamos corregirlos como si se trataran de valores perdidos, por lo que podemos utilizar alguno de los métodos presentados en la Sección 5.1. A modo de prueba, hemos utilizado el método *Last Observation Carried Forward* para corregir los *outliers* de la señal presentada en la Figura 5.24, ya que, al ser principalmente errores puntuales, es un método que consigue una imputación correcta y eficiente, debido a su bajo coste computacional. Los resultados obtenidos pueden verse en la Figura 5.25. Como podemos observar, se ha logrado corregir de manera adecuada la mayoría de valores atípicos presentes en la señal, a excepción de algunos *outliers* de baja magnitud, lo que podría corregirse ajustando el valor del parámetro  $k$  o el tamaño de la ventana.



**Figura 5.25:** Resultados tras el tratamiento de valores atípicos en una señal de temperatura, mediante el método basado en el test de Tukey.

### 5.5.2. Corrección secuencial de valores contiguos

Este método (al que nos referiremos también como *método iterativo*) se basa en recorrer la señal corrigiendo los valores que tengan una diferencia significativa respecto al valor de la observación anterior. La diferencia máxima permitida será especificada mediante un umbral  $\varepsilon$ , de modo que, dependiendo de la señal, podría ser un parámetro a ajustar. En el Algoritmo 1 se muestra el procedimiento básico para el tratamiento de valores atípicos mediante este método, y en la Figura 5.26 se muestran los resultados obtenidos.

---

**Datos:** Serie temporal  $s = (s_1, \dots, s_N)$ .  
 Umbral utilizado para la definición de valores atípicos,  $\varepsilon$ .  
**Resultado:** serie temporal  $s' = (s'_1, \dots, s'_N)$  sin valores atípicos.

```

i := 1
mientras i < N hacer
  | si  $|s_i - s_{i+1}| > \varepsilon$  entonces
  |    $s_{i+1} := s_i$ 
  | fin
  | i := i + 1
fin
devolver s;
```

---

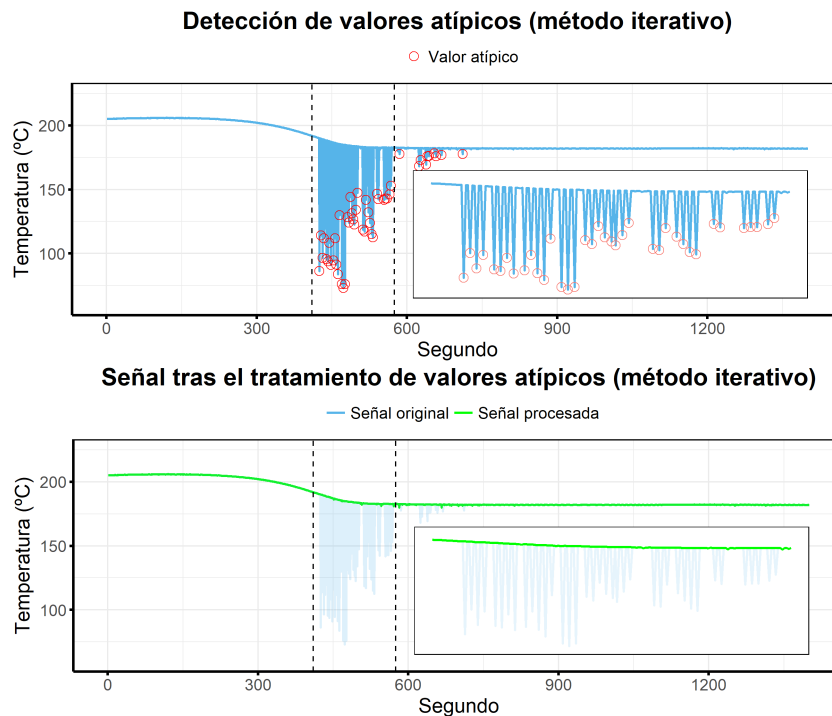
**Algoritmo 1:** Método iterativo propuesto para el tratamiento de valores atípicos.

Nótese que el algoritmo tiene en cuenta sus propias correcciones a la hora de detectar nuevos *outliers*, por lo que requiere un procesamiento secuencial. En caso de que fuera necesario, este método puede extenderse añadiendo criterios más complejos en cuanto a la detección de *outliers* (por ejemplo, mediante un umbral dinámico), o utilizando otros criterios para la corrección (por ejemplo, que el valor imputado sea el promedio de un número  $k$  de valores previos).

Por último, cabe destacar que este método asume que el primer valor de la señal será correcto, ya que, en caso de que la primera observación fuera un valor atípico, dicho valor se propagaría, corrigiendo erróneamente los valores correctos de la señal.

## 5.6. Mejoras y recursos adicionales

En esta sección queremos proponer el uso de otras tecnologías y recursos para realizar las operaciones de preprocesado presentadas a lo largo de este capítulo. Si bien la implemen-



**Figura 5.26:** Resultados tras el tratamiento de valores atípicos en una señal de temperatura, mediante el método presentado en el Algoritmo 1.

tación de estas técnicas queda fuera del alcance este TFG (principalmente debido a que se fundamentan en un campo de estudio ajeno a la modalidad de computación), creemos que podría ser una alternativa muy interesante para investigar en líneas futuras.

Fundamentalmente, estas tecnologías se basan en el uso de tecnologías web semánticas (TWS, en adelante) para la representación y extracción de conocimiento en diferentes dominios. Las TWS tienen como objetivo principal establecer una representación del conocimiento en un formato que facilite la comprensión tanto para los sistemas automatizados como para los humanos, principalmente mediante el uso de metadatos semánticos y ontológicos. Esta representación del conocimiento permite a su vez lograr una mayor interoperabilidad, y la posibilidad de analizar automáticamente información almacenada en diferentes fuentes de datos, con el fin de obtener nuevas fuentes de conocimiento (lo que popularmente se conoce como *Knowledge Discovery in Databases*).

En relación con nuestro proyecto, diversas líneas de investigación recientes muestran que las TWS tienen aplicaciones directas en cuanto al preprocesado de los datos, ya que, al partir de una representación ontológica del conocimiento, podemos generar recursos que permitan conseguir, por ejemplo, una definición automática de valores atípicos [Eснаоla-Gonzalez et al., 2016]. La principal ventaja que ofrecen este tipo de recursos es el nivel

de abstracción que proporciona al ingeniero de datos, ya que le permite trabajar partiendo de un conocimiento generado por expertos en un dominio concreto, aumentando así no solo la productividad, sino la fiabilidad de los sistemas implementados. Estas ventajas cobran aun más valor en empresas como Savvy Data Systems, donde, al trabajar en múltiples proyectos, la posibilidad de gestionar eficientemente las fases de comprensión y preprocesado de los datos puede suponer un aumento decisivo en la productividad.

Hoy en día, además, estas tecnologías han aumentado significativamente su potencial y su aplicabilidad gracias a los grandes repositorios públicos, popularmente conceptualizados como *datos abiertos* (en inglés, *open data*), ya que estos recursos permiten escoger entre diversas fuentes de datos aquellas que más se ajusten a las características o a la naturaleza del dominio de aplicación considerado.

Por estos motivos, creemos que el uso y la combinación de las tecnologías presentadas en esta sección pueden ser de gran utilidad para mejorar, en líneas futuras, las técnicas de preprocesado presentadas en este capítulo.



## CAPÍTULO 6

---

### Análisis de los datos

---

En este capítulo vamos a exponer y desarrollar el trabajo realizado en cuanto al análisis de los datos, haciendo un especial énfasis en el potencial y las aplicaciones de los modelos de minería de datos utilizados.

#### 6.1. Modelos utilizados

Para comenzar, presentaremos los modelos utilizados para realizar el análisis de los datos, los cuales han sido seleccionados teniendo en cuenta los siguientes factores:

- El potencial para modelar adecuadamente los datos con los que se van a trabajar.
- La capacidad de adaptarse o extenderse, de manera que faciliten su aplicación al mayor número de situaciones u objetivos posibles.

Teniendo en cuenta estos factores, hemos decidido usar principalmente dos tipos de modelos: modelos probabilísticos y modelos basados en redes neuronales. Por tanto, a continuación analizaremos de manera individual las características principales de cada uno de ellos, así como su potencial y sus posibles aplicaciones.

### 6.1.1. Modelos probabilísticos

Dado un conjunto de variables aleatorias, el objetivo de los modelos probabilísticos es modelar la función de probabilidad conjunta de esas variables, describiendo así las relaciones entre ellas [Castillo et al., 1998]. Estos modelos son utilizados principalmente para representar procesos estocásticos, no deterministas o con un cierto grado de incertidumbre, y son la base de modelos más complejos como los sistemas expertos basados en probabilidad.

En un principio, los principales inconvenientes de los modelos probabilísticos se debían a su ineficiencia, ya que requerían el ajuste de un gran número de parámetros, y existía una carencia en cuanto a métodos eficientes que consiguieran una estimación precisa de los mismos. Para hacer frente a estos problemas, se propusieron nuevos modelos y simplificaciones que reducían significativamente el número de parámetros a estimar, dando lugar a modelos de gran potencial y aplicables en problemas prácticos, como las redes Bayesianas o las redes de Markov.

Para el análisis de nuestros datos, hemos decidido centrarnos en el uso de las redes Bayesianas, por lo que, en el siguiente apartado, presentaremos las nociones básicas para comprender los fundamentos de este tipo de modelos. Además analizaremos por qué son interesantes para modelar los datos de este proyecto y comentaremos las diferentes aplicaciones que pueden ofrecer.

#### Introducción a las Redes Bayesianas


Las redes Bayesianas son modelos gráficos probabilísticos, formados por dos componentes estrechamente relacionados:

- Un grafo acíclico dirigido (DAG, por sus siglas en inglés *Directed Acyclic Graph*), también conocido como *componente cualitativo* de la red, donde cada nodo representa una variable aleatoria, y cada arista representa una relación de dependencia entre las variables que conecta<sup>1</sup>. Por tanto, el grafo será la estructura que defina el modelo de dependencias condicionales de las variables, además de la forma de la factorización de las funciones de probabilidad de las mismas, como detallaremos en el siguiente apartado.

---

<sup>1</sup>En un grafo dirigido, al nodo de salida se le conoce como padre, y al nodo de entrada como hijo.





**Figura 6.1:** Ejemplo de un grafo acíclico dirigido, con 4 vértices: A,B,C y D.

- Una función de probabilidad conjunta que describa la distribución de probabilidad del conjunto de variables. Esta función se descompone (o factoriza) en un conjunto de funciones de probabilidad condicionadas, una para cada variable, y definidas a partir del grafo que forma la red, de la siguiente manera: siendo  $X_i$  una variable aleatoria, e  $\mathbf{Y}$  el conjunto de vértices que son padres del nodo correspondiente a  $X_i$ , la función de probabilidad condicionada asociada a la variable  $X_i$  será  $p(X_i|\mathbf{Y})$ .

A modo de ejemplo, consideremos el grafo presentado en la Figura 6.1. Si este grafo representará una red Bayesiana, las función de probabilidad asociadas serían:

- Vértice A: la probabilidad marginal  $p(A)$ , ya que no tiene padres.
- Vértice B: la probabilidad marginal  $p(B)$ , ya que tampoco tiene padres.
- Vértice C: la probabilidad condicionada  $p(C|A, B)$ , ya que A y B son los padres de C.
- Vértice D: la probabilidad condicionada  $p(D|C)$ , ya que C es el único padre de D.
- Probabilidad conjunta:  $p(A, B, C, D) = p(A)p(B)p(C|A, B)p(D|C)$ .

Hay que tener en cuenta que estas funciones de probabilidad estarán definidas por un conjunto de parámetros, también conocido como *componente cuantitativo* de la red, que habrá que ajustar para que dichas funciones representen adecuadamente la distribución de probabilidad de los datos.

Gracias a que las relaciones de dependencia están representadas gráficamente, las redes Bayesianas son herramientas muy útiles e intuitivas, ya que permiten analizar el conocimiento modelado de una manera visual. Esto facilita también el traslado de conocimiento a otros dominios, e incluso la cooperación, ya que el grafo de la red puede ser diseñado o corregido por los expertos en el dominio.

## Tipos de Redes Bayesianas

Las redes Bayesianas pueden clasificarse en diferentes tipos, dependiendo del tipo de variables que la formen:

- **Redes Bayesianas Multinomiales**, donde todas las variables son discretas.
- **Redes Bayesianas Continuas**, donde todas las variables son continuas. En la práctica, se suele asumir que estas variables siguen una distribución Gaussiana, por lo que las funciones de probabilidad asociadas se modelan mediante distribuciones normales. Por este motivo, suele emplearse el término *redes Bayesianas Gaussianas* para referirse a este tipo de redes. Si bien es posible definir redes Bayesianas donde las variables siguen otros tipos de distribuciones (lo que se conoce en la literatura como *redes Bayesianas flexibles* [Pérez et al., 2009]), estas son menos frecuentes, y el número de librerías de programación que proporcionan implementaciones de redes de este tipo es escaso en comparación con las redes Gaussianas.
- **Redes Bayesianas Mixtas**, donde las variables que la forman pueden ser tanto discretas como continuas. En este caso, también es frecuente asumir que las variables continuas siguen una distribución Gaussiana.

## Aprendizaje de las redes Bayesianas

El proceso de aprendizaje o construcción de una red Bayesiana puede dividirse en dos partes: el aprendizaje estructural, donde se define la estructura del grafo acíclico dirigido, y el aprendizaje paramétrico, donde se ajustan los parámetros de las funciones de probabilidad.

- Aprendizaje estructural

El objetivo de esta fase es definir la estructura del grafo acíclico dirigido que representará la red. Como ya hemos mencionado anteriormente, esto implicará definir el modelo de dependencia de las variables.

Hay que tener en cuenta que el proceso de aprendizaje estructural de una red es un problema de optimización NP-duro, por lo que, en la práctica, se utilizan principalmente algoritmos de aproximación. Los métodos de aprendizaje estructural se pueden dividir en las siguientes categorías:

- Métodos basados en restricciones, los que se basan principalmente en analizar las relaciones de dependencia de las variables mediante tests de independencia.
- Métodos basados en búsquedas, también denominados *score + search*, donde se realiza una búsqueda (principalmente mediante heurísticos, para garantizar la eficiencia) de la estructura óptima de la red. Esta búsqueda es guiada en base a una métrica (*score*), las cuales evalúan el ajuste de la red en base a los datos de entrenamiento.

#### ■ Aprendizaje paramétrico

Una vez tengamos definida la estructura de la red, el siguiente paso será ajustar los parámetros de las funciones de probabilidad que representa el grafo, es decir, ajustar los parámetros de la distribución asociada a cada variable.

Para realizar el ajuste, uno de los métodos más frecuentes es utilizar estimadores maximoverosímiles, los cuales se basan en estimar los parámetros que maximicen la probabilidad de los resultados experimentales. En otras palabras, dado un conjunto muestral de datos, estimar el valor de los parámetros que maximice la probabilidad de obtener dichas muestras.

Otros métodos frecuentes para la estimación de parámetros se basan en la estimación Bayesiana, donde los parámetros son considerados variables aleatorias con una distribución inicial o *a priori* que se corrigen mediante las observaciones del conjunto de datos (consiguiendo una distribución *a posteriori*).

### Aplicaciones y potencial de las Redes Bayesianas

Las principales aplicaciones de las redes Bayesianas, además de modelar las relaciones de dependencia condicional de las variables y su probabilidad conjunta, son las siguientes:

- Inferencia: es el proceso más importante en una red Bayesiana, ya que es la base del razonamiento probabilístico. La inferencia se basa en estimar el valor (o la distribución de probabilidad) de un conjunto de variables a partir de los valores conocidos de otro conjunto de variables (evidencia). Las evidencias las podríamos clasificar en dos tipos:
  - Evidencias fuertes (en inglés *hard evidences*), donde se instancia el valor concreto de una o más variables ( $E = \{X_{i_1} = e_1, \dots, X_{i_k} = e_k\}$ ).

- Evidencias débiles (*soft evidences*), donde se reasignan nuevas distribuciones de probabilidad a una o más variables, lo que se podría entender también como una reasignación de parámetros (por ejemplo, con la intención de contrastar una hipótesis nula en un test estadístico).

A este tipo de consultas basadas en la inferencia se les conoce también como *queries*, destacando las denominadas como *Conditional Probability Queries* (CPQ) o *Most Probable Explanation* (MPE, también denominado *Maximum a posteriori* o MAP):

- Las consultas de tipo CPQ se basan en calcular la probabilidad marginal *a posteriori* de un subconjunto de variables dada una evidencia fuerte. En nuestro caso, un ejemplo podría ser el consultar, estableciendo como evidencia la configuración de la máquina, la probabilidad de que una alarma se active o la probabilidad de que con la configuración establecida una zona tome temperaturas en un rango determinado.
- Las consultas de tipo MPE se basan en calcular la configuración de un conjunto de variables que maximiza la probabilidad de una evidencia. En nuestro caso, un ejemplo práctico podría ser el de la imputación de valores perdidos para un conjunto de variables, utilizando como evidencia las observaciones disponibles.

La ventaja de las redes Bayesianas frente a otros modelos es la flexibilidad que ofrece en este tipo de consultas, ya que permiten estimar el valor de cualquier conjunto de nodos utilizando como evidencia otro conjunto cualquiera de nodos.

- Muestreo de la red: otra aplicación frecuente de las redes probabilísticas es la de generar observaciones a partir de las distribuciones de probabilidad aprendidas por la red, lo que se conoce como muestreo. Esto puede ser utilizado para diversos objetivos, siendo uno de los más populares el descubrimiento de nuevas configuraciones o soluciones a un problema.


En resumen, teniendo en cuenta las características de las redes Bayesianas, sus posibles aplicaciones y su flexibilidad para adaptarse a distintos tipos de datos, creemos que es un modelo adecuado para ser analizado en este proyecto, con potencial para ser aplicado en diferentes análisis, o como base para proponer diferentes objetivos.

## 6.2. Redes Neuronales Artificiales

Las redes neuronales artificiales [Fausett, 1993] son modelos computacionales que, debido a su potencial y a sus múltiples extensiones, se han convertido en uno de los modelos de aprendizaje automático más populares de los últimos años. Las redes neuronales artificiales surgen de un intento por imitar el mecanismo de aprendizaje del cerebro, tratando de modelar matemáticamente tanto su estructura como su funcionamiento.

### Características básicas de las redes neuronales


Estos modelos están formados por un conjunto de unidades denominadas neuronas, las cuales se conectan y comunican a partir de un conjunto de conexiones. Estas conexiones tendrán asignadas un peso, indicando así la influencia de las mismas. Dependiendo de la topología de la red (es decir, de la distribución de las neuronas y las conexiones), o de la forma en que procesan la información, existen diferentes tipos de redes neuronales. Para introducir las nociones básicas de estos modelos, vamos a partir de un diseño conocido como perceptrón simple [Rosenblatt, 1957]. En este diseño, las neuronas están distribuidas en dos capas, donde cada neurona de la primera está conectada (mediante aristas dirigidas) a cada una de las neuronas de la segunda, sin conexiones entre las neuronas de la misma capa, tal y como se muestra en la Figura 6.2.



**Figura 6.2:** Ejemplo de la topología de una red neuronal básica.


Las neuronas de la primera capa forman lo que se denomina *capa de entrada*, ya que es la que contendrá los datos de entrada (*input*). Las neuronas de la segunda capa formarán por tanto la *capa de salida*, es decir, la que proporcionará el valor del resultado (*output*). Por simplicidad, vamos a asumir que las variables que estamos manejando (tanto de entrada como de salida), son binarias, donde los posibles valores son  $\{0, 1\}$ .

La transmisión de información de las neuronas se realiza mediante una función conocida como *función de propagación*, la que comúnmente se basa en sumar los valores de las neuronas anteriores (es decir, de la capa anterior) multiplicados por los pesos de la conexión. Una vez calculado este valor ( $s$ ), el *estado* de las neuronas (lo que será también el valor de salida de las mismas) se calcula mediante una función conocida como *función de activación*, la que toma como entrada tanto el valor  $s$  como el estado actual de la neurona (por lo que podríamos decir que esta operación supone una actualización del estado). En la Figura 6.3 se muestra una representación gráfica de estos pasos.



**Figura 6.3:** Representación gráfica de la función de propagación y función de activación en una neurona, donde  $w_i$  representa el peso de la conexión con la  $i$ -ésima neurona de la capa anterior.

Al tratar con variables binarias, es común utilizar funciones de activación como la sigmoide o la tangente hiperbólica, ya que acotan el valor de la señal en un rango determinado ( $[0, 1]$  y  $[-1, 1]$ , respectivamente). Sin embargo, existen otras funciones no acotadas y ampliamente utilizadas, como por ejemplo la función *Rectified Linear Unit* (ReLU). Estas funciones se muestran de manera gráfica en la Figura 6.4.



**Figura 6.4:** Comparación de tres funciones de activación clásicas en redes neuronales: sigmoide, tangente hiperbólica y *Rectified Linear Unit* (ReLU).

Mediante este sistema de propagación, la información avanzará hasta la capa de salida, siendo el resultado de salida *output* el valor del estado de las neuronas de dicha capa. En caso de que estas neuronas representen variables binarias, el valor del estado puede

redondearse para conseguir salidas discretas (por ejemplo,  $\{0, 1\}$  si utilizamos la función sigmoide).

### Proceso de aprendizaje


En cuanto al proceso de aprendizaje, el objetivo será ajustar los pesos de las conexiones (parámetros), de manera que el error de la red sea minimizado. Nótese que una red neuronal puede interpretarse como una función  $f(\mathbf{X}) = \mathbf{Y}$ , donde  $\mathbf{X}$  representa el conjunto de variables de entrada e  $\mathbf{Y}$  el conjunto de variables de salida, por lo que el error puede interpretarse como la diferencia (mediante algún criterio) entre el resultado de la red y el valor real. Aunque existen diferentes métodos de aprendizaje, hoy en día las técnicas más utilizadas se basan en el algoritmo conocido como *backpropagation*, el cual se basa en propagar el error desde la capa de salida hasta la capa de entrada (*hacia atrás*), corrigiendo el peso de cada conexión en base a su contribución relativa al error total [Rojas, 1996].

### Evolución y extensiones

El principal problema de este diseño es que solamente puede ser aplicado en problemas linealmente separables (véase la Figura 6.5), por lo que no sirve para modelar problemas más complejos. Para superar esta limitación, se han propuesto nuevos diseños, como el perceptrón multicapa, una extensión del perceptrón simple en la cual se añaden capas internas (o capas *ocultas*) entre la entrada y la salida de la red. El uso de capas ocultas permite modelar problemas no lineales, permitiendo, de hecho, la posibilidad de modelar cualquier función, lo que se conoce como *teorema de aproximación universal* [Cybenko, 1989] [Hornik, 1991].

Hay que tener en cuenta que el hecho de añadir capas ocultas aumenta significativamente el número de parámetros a ajustar, por lo que estos diseños fueron descartados en un comienzo debido a la inexistencia de métodos eficientes de aprendizaje. Sin embargo, la aparición de métodos de entrenamiento como el *backpropagation* permitieron redefinir los procesos de aprendizaje de una manera eficiente y adecuada a modelos con múltiples capas, lo que dio pie a una mayor investigación y a la aparición de modelos más complejos [Rojas, 1996].

Tras estos avances, las redes neuronales forman hoy en día parte del estado del arte de prácticamente cualquier problema que pueda modelarse mediante técnicas de aprendizaje



**Figura 6.5:** Representación gráfica de un problema linealmente separable y dos problemas linealmente inseparables.

automático, ya que existen múltiples extensiones que permiten el manejo de imágenes, el manejo de series temporales, etc. Además, gracias a los avances computacionales, es posible entrenar eficientemente modelos con una gran cantidad de parámetros, lo que permite utilizar redes con topologías muy complejas y de múltiples capas y componentes, lo que hoy en día es catalogado como *deep learning*.

### 6.3. Diseño de los análisis

En esta sección definiremos las características de la experimentación que desarrollaremos posteriormente, describiendo los objetivos, los datos utilizados y los diferentes tipos de análisis.

#### 6.3.1. Objetivos y consideraciones previas

El objetivo de los análisis que realizaremos en las siguientes secciones será analizar el comportamiento de los modelos propuestos, para, por un lado, comprobar si son capaces de modelar adecuadamente los datos, y, por otro lado, para exponer las diferentes aplicaciones que puedan ser útiles para líneas futuras.

Antes de comenzar, hay que tener en cuenta que, tal y como hemos comentado en la Sección 4.3, los datos que tenemos para cada máquina contienen muy poca diversidad, por lo que asumimos de antemano que no seremos capaces de generar modelos funcionales o fiables en situaciones que se alejen de dichos datos. Por tanto, esta sección se ha desarrollado haciendo un mayor énfasis en mostrar el funcionamiento de los modelos en situaciones prácticas, con la finalidad de mostrar su potencial y su aplicabilidad en líneas futuras, y no tanto en una búsqueda exhaustiva de modelos óptimos o de la minimización



del error. Por estas razones, asumimos que tanto la calidad de los datos como la calidad de los modelos empleados en esta sección tendrán margen de mejora cuando tengan que ser aplicados de manera funcional.

### 6.3.2. Selección y preparación del conjunto de datos

Para realizar estos análisis hemos decidido centrarnos en los datos de dos máquinas del mismo modelo de extrusora, ya que, de acuerdo con los expertos, contiene un diseño que está dando resultados satisfactorios en cuanto a producción y eficiencia. Además, estas máquinas contienen valores en todos los indicadores necesarios, lo que no se cumple en todas las máquinas. Para diferenciar estas dos extrusoras, nos referiremos a ellas como *Máquina 1* y *Máquina 2*.

Si bien el diseño de estas dos extrusoras es el mismo, la configuración operativa de sus temperaturas (y el resto de variables de control) no es necesariamente la misma, ya que pueden ser manejadas por operarios diferentes, utilizar diferentes recetas o producir diferentes productos. Sin embargo, y como veremos más adelante, ambas comparten características similares. Por otro lado, el hecho de utilizar dos máquinas del mismo modelo puede ser interesante para analizar la compatibilidad entre las máquinas, y evaluar si un modelo entrenado con los datos de una tiene un comportamiento adecuado con la otra.

Por tanto, utilizaremos tres conjuntos de datos principales:

1. Conjunto de entrenamiento: este conjunto contendrá datos de la Máquina 1, en un intervalo aproximado de una semana.
2. Conjunto de validación 1: este conjunto contendrá datos de la Máquina 1, en un intervalo aproximado de una semana, pero en diferentes fechas que el conjunto de entrenamiento.
3. Conjunto de validación 2: este conjunto contendrá datos de la Máquina 2, en un intervalo aproximado de una semana.

En cuanto al preprocesado de los datos, los valores perdidos han sido imputados mediante el suavizado de Kalman (utilizando un modelo estructural, véase la Sección 5.1.4), los outliers han sido eliminados mediante el método basado en el test de Tukey (Sección 5.5.1) y el ruido ha sido filtrado mediante el promediado de señales, con una ventana de 8 muestras. En cuanto a la eliminación de ruido, hemos seleccionado el promediado

para reducir intencionadamente el número de muestras de las señales, ya que, al oscilar de manera lenta, muchos de los valores contiguos son prácticamente el mismo valor. Sin embargo, en los casos donde la pérdida de muestras puede suponer un inconveniente (por ejemplo, al analizar las alarmas, ya que promediar dicha señal podría suponer perder información acerca del instante concreto en el que se activa), hemos empleado el método basado en el filtrado frecuencial.

### 6.3.3. Tipos de análisis

Teniendo en cuenta los objetivos de la colaboración interempresarial previstos a largo plazo (véase la Sección 2.2) y las características y calidad de los datos disponibles (véase la Sección 4.2), hemos decidido plantear dos tipos de análisis, que describiremos a continuación:

#### 1. Análisis enfocados a la predicción y modelado de las señales de temperatura

Este análisis tiene como objetivo mostrar diferentes técnicas y estrategias para la predicción de la temperatura en diferentes zonas, así como diferentes recursos para analizar y modelar las relaciones entre ellas. Este análisis se propone como base para el desarrollo de objetivos más complejos, como pueden ser:

- El modelado avanzado de las relaciones entre las variables, lo que puede dar lugar a una mejor comprensión del funcionamiento de las máquinas, facilitando así vías para la búsqueda de nuevas configuraciones de las extrusoras o de la optimización de recursos.
- La creación de herramientas enfocadas a la simulación de procesos o al control inteligente de las máquinas.

Por último, vamos a utilizar tanto redes Bayesianas como redes neuronales, desarrollando (dependiendo de las características particulares de cada modelo) diferentes métodos o alternativas para llevar a cabo estos procedimientos.

#### 2. Análisis enfocado a la predicción de alarmas

En este caso, el objetivo será evaluar la aplicabilidad de los modelos en tareas relacionadas con el mantenimiento predictivo de las extrusoras, así como la detección de riesgos o anomalías. Para ello, plantearemos un análisis de predicción de

alarmas, ya que es el único indicador disponible directamente relacionado con el mantenimiento de las máquinas.

En este caso, también utilizaremos tanto redes Bayesianas como redes neuronales, para poder evaluar y comparar la aplicación de diferentes estrategias para la predicción de alarmas.

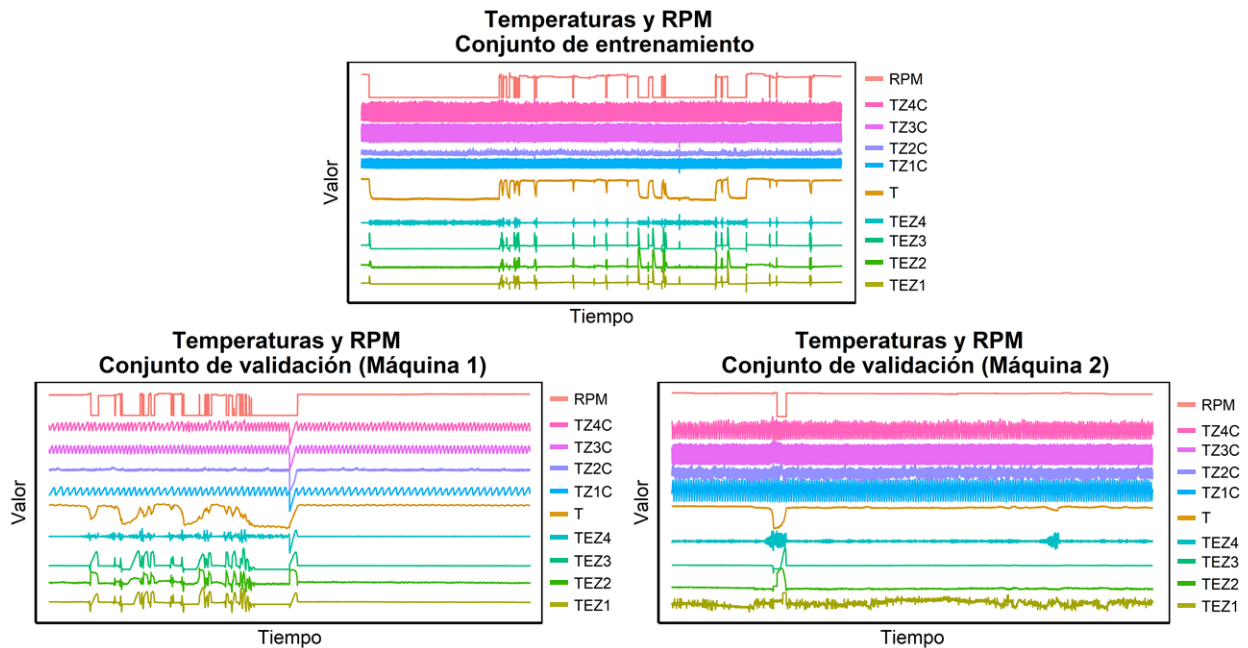
Hay que tener en cuenta que, como ya comentamos en la Sección 4.2.4, el indicador de alarma únicamente refleja si la alarma está activa, pero no la causa de activación. Esto limita en gran medida tanto la calidad del análisis como la validación de sus resultados, ya que la alarma puede ser activada por múltiples razones, de las cuales no todas tienen relación con el funcionamiento de la máquina. De hecho, de acuerdo con la información proporcionada por los expertos, existen más de 150 sucesos diferentes que pueden generar la activación de la alarma, de los cuales un conjunto determinado está formado por sucesos que suponen la detención de la máquina, mientras que otros simplemente generan una señal de advertencia.

Por estos motivos, trataremos de proponer diferentes alternativas para el adecuado diseño de este tipo de análisis, así como posibles mejoras en cuanto a la captura u organización de los datos.

## 6.4. Predicción y modelado de temperaturas

En esta sección llevaremos a cabo los análisis relacionado con las señales de temperatura. Para ello, vamos a utilizar las siguientes variables, las cuales están directamente relacionadas con la configuración de la extrusora:

- Las temperaturas capturadas en las diferentes zonas del cilindro, a las que también haremos referencia como *zonas de extrusora*. En las máquinas utilizadas para el análisis contaremos con 4 zonas uniformemente distribuidas a lo largo del cilindro. Para hacer referencia a estos indicadores, utilizaremos la abreviación TEZ<sub>*i*</sub> (Temperatura Extrusora Zona *i*), por ejemplo, TEZ<sub>1</sub> para referirnos al primer indicador.
- Las temperaturas capturadas en las diferentes zonas del cabezal. En las máquinas utilizadas para el análisis contaremos con 4 zonas, con una distribución similar a la mostrada en la Figura 4.2. Para hacer referencia a estos indicadores, utilizaremos la abreviación TZ<sub>*i*</sub>C (Temperatura Zona *i* Cabezal), por ejemplo, TZ<sub>1</sub>C para referirnos al primer indicador.




**Figura 6.6:** Visualización de las señales de temperatura y la velocidad de giro del husillo (RPM) utilizadas para el análisis.

- La temperatura de fundido, para la que utilizaremos la abreviación T.
- La velocidad de giro del motor, para la que utilizaremos la abreviación RPM.

Como ya mencionamos en la Sección 6.3.2, aunque el diseño de las dos máquinas que utilizaremos sea el mismo, la configuración operativa de sus temperaturas (y el resto de variables de control) no es necesariamente la misma. Para comprobar esto, y hacer una primera evaluación de las relaciones entre las variables, mostramos en la Figura 6.6 las señales de temperatura junto con la velocidad de giro del husillo. Por motivos de confidencialidad y visualización, las señales han sido normalizadas y desplazadas, siendo el objetivo principal observar la forma de las señales. Sin embargo, hemos observado que la configuración de las dos máquinas es diferente, principalmente en cuanto a las temperaturas del cilindro, ya que la evolución de la temperatura entre cada zona es diferente, tal y como se muestra en la Figura 6.7. Aunque en los gráficos de dicha figura se haya eliminado intencionadamente la información de los ejes (por motivos de confidencialidad), el lector puede asumir que los dos ejes horizontales muestran el mismo intervalo de valores y con la misma escala.

Para realizar un primer análisis de las relaciones entre variables, mostramos en la Figura 6.8 dos tipos de correlación para cada par de variables del mismo conjunto de datos:



**Figura 6.7:** Evolución de las temperaturas del cilindro en las dos máquinas utilizadas en el análisis. El lector puede asumir que los ejes verticales de los dos gráficos muestran el mismo intervalo de valores y con la misma escala.

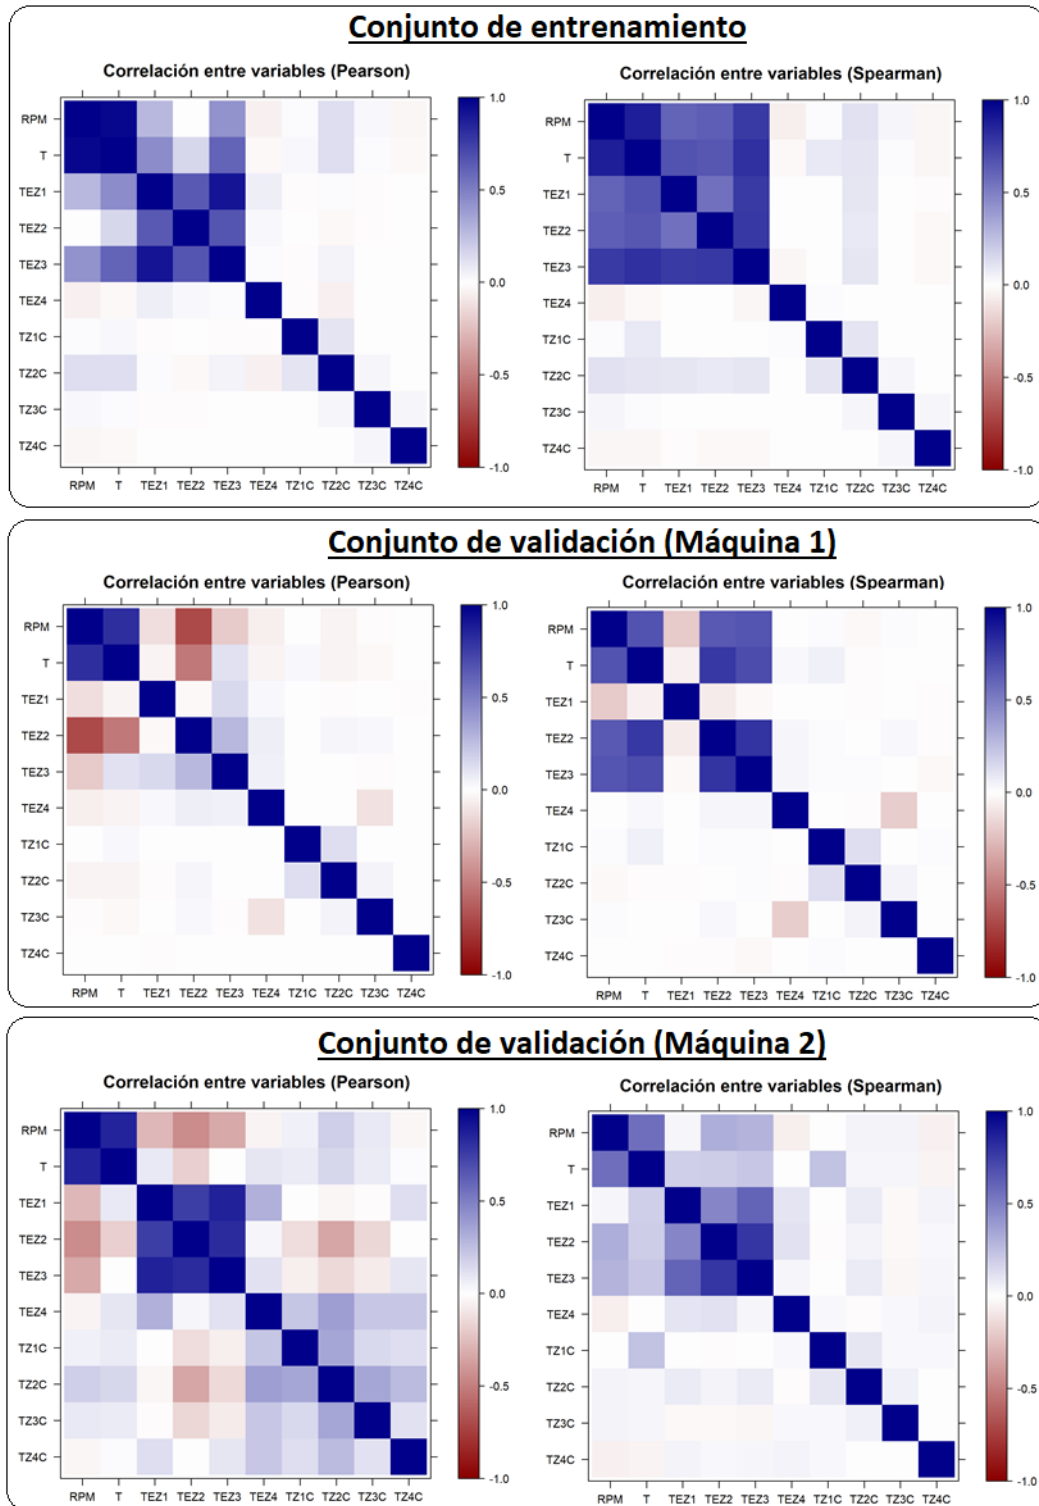
el coeficiente de correlación de Pearson y el coeficiente de correlación de Spearman. Mientras que el primero indica la relación lineal entre dos variables, el segundo describe la relación de monotonía entre dos variables, sea una relación lineal o no [Yule, 1919].

Analizando estos gráficos, observamos que, en general, las temperaturas del cabezal no muestran signos de correlación con ninguna de las variables, ni siquiera entre ellas, lo que tiene sentido teniendo en cuenta la forma de dichas temperaturas en comparación con el resto (véase la Figura 6.6). Lo mismo ocurre para el indicador TEZ4, aunque en menor medida, ya que no oscila en un rango de valores tan ancho como las temperaturas del cabezal. Por otro lado, sí podemos detectar una alta correlación entre las temperaturas del cilindro, la temperatura de fundido y la velocidad del motor, aunque en cada conjunto de datos las correlaciones sean diferentes. Hay que tener en cuenta que las señales no muestran la misma distribución de zonas irregulares o paradas del motor, por lo que las diferencias podrían deberse a las características particulares de las temperaturas en los intervalos seleccionados, mostrando correlaciones diferentes debido a esas particularidades.

Una vez presentadas las señales, vamos a proceder a utilizar tanto redes Bayesianas como redes neuronales para continuar con el análisis.

#### 6.4.1. Análisis mediante Redes Bayesianas

La principal ventaja de las redes Bayesianas es que permiten calcular la distribución de probabilidad de un conjunto cualquiera de variables dado como evidencia otro conjunto cualquiera, por lo que ofrecen la posibilidad de realizar estos cálculos de manera flexible. Además, el hecho de poder calcular la distribución de probabilidad para los diferentes



**Figura 6.8:** Correlación entre las variables de los tres conjuntos de datos que utilizaremos para el análisis de temperaturas.

valores (en vez de calcular solamente el valor exacto) puede ser de gran utilidad para los expertos, ya que permite analizar diferentes configuraciones.

Si bien las redes Bayesianas son utilizadas principalmente en valores discretos, consideramos que los datos seleccionados no favorecen la discretización, debido a dos motivos principales:

- La distribución irregular de los valores de algunas señales de temperatura, donde la mayor parte de valores se concentra en 1 o 2 intervalos.
- La poca varianza en los valores de algunas señales de temperatura, al oscilar en un rango de valores muy reducido.

Por estos motivos, al evaluar la aplicabilidad de los diferentes métodos de discretización, hemos encontrado los siguientes inconvenientes:

- Al utilizar el método *equal width*, la discretización es excesivamente desproporcionada, ya que la mayor parte de valores se agrupan en el mismo intervalo. Si bien una manera de conseguir un mejor reparto de valores podría ser aumentar el número de intervalos, necesitaríamos una cantidad demasiado elevada, lo que lleva a que el problema sea intratable de manera eficiente (nótese que el aumento de los posibles valores incrementa de manera exponencial el número de parámetros de la red Bayesiana). Además, el hecho de necesitar un gran número de intervalos nos lleva a la conclusión de que sería más conveniente utilizar directamente valores continuos, por lo que hemos descartado este método de discretización. Lo mismo ocurre al utilizar el método basado en el algoritmo *K-means*, aunque consiga un reparto ligeramente más proporcionado que el método *equal width*.
- Al utilizar el método *equal frequency*, la discretización consigue un reparto de valores proporcionado, pero, debido a la poca varianza en los datos de algunas temperaturas, se definen múltiples intervalos en un rango muy reducido de valores, lo que conlleva a una resolución excesiva y a una gran inestabilidad en el proceso de aprendizaje. Además, hay que tener en cuenta que este método no resulta adecuado en datos con grandes proporciones de valores repetidos, ya que podría no ser posible encontrar el número de intervalos necesario como para realizar un reparto proporcionado. Esta limitación se comprende mejor si consideramos un caso extremo, por ejemplo, si quisiéramos discretizar en dos o más intervalos una línea

horizontal (donde todos los valores son iguales). Si bien nuestros casos no son tan extremos, ciertas señales de temperatura solamente podrían ser discretizadas mediante menos de 5 intervalos, lo que conlleva a que el reparto sea muy dependiente del conjunto de datos utilizado, perdiendo capacidad de generalización.

Por estos motivos, hemos decidido no desarrollar el análisis basado en valores discretos, y utilizar directamente valores continuos.

Para evaluar la capacidad de las redes de predecir adecuadamente los valores de temperatura, estableceremos como evidencia una configuración de temperaturas del cilindro junto con la velocidad del motor, y estimaremos mediante la red el valor de la temperatura de fundido (recordemos que esta temperatura se toma al finalizar el cilindro). Como ya conocemos el valor real de la temperatura de fundido correspondiente a la evidencia, podremos calcular el error obtenido.

A modo de introducción, y simplemente para mostrar el efecto de las evidencias de manera visual, realizaremos un muestreo de una red Bayesiana ya entrenada<sup>2</sup> para generar muestras sobre la temperatura de fundido antes y después de propagar una evidencia. Si no establecemos ninguna evidencia, las muestras se generarán en base a la densidad de probabilidad marginal de dicha variable, pero al establecer la evidencia, la probabilidad se verá modificada, por lo que la densidad de los valores muestreados seguirá la probabilidad condicionada *a posteriori*.


Los resultados obtenidos con este experimento se muestran en la Figura 6.9. Como podemos observar, sin evidencias, la densidad muestra una distribución Gaussiana acorde con la distribución de valores de la señal de fundido. Sin embargo, al propagar la evidencia, la distribución se desplaza a un rango concreto, lo que muestra los valores más probables para la temperatura de fundido tras conocer el valor de las zonas previas (y la velocidad del motor). Para comprobar que la distribución de valores del segundo gráfico toma valores cercanos a la temperatura real, hemos añadido dicho valor en el segundo gráfico, el que, como podemos ver, se encuentra aproximadamente en el centro de la zona.

En base a estos resultados, hemos visto que podemos predecir el intervalo de valores más probables para la temperatura de fundido. Sin embargo, en algunas aplicaciones es necesario predecir un valor exacto de la temperatura, por lo que un intervalo de valores podría no ser suficientemente preciso. Por tanto, en la Figura 6.9 hemos añadido también

---

<sup>2</sup> Esta simulación ha sido realizada utilizando el modelo C mostrado en la Figura 6.10, aunque, al tratarse de una simulación meramente ilustrativa, consideramos que los detalles del modelo no son relevantes.





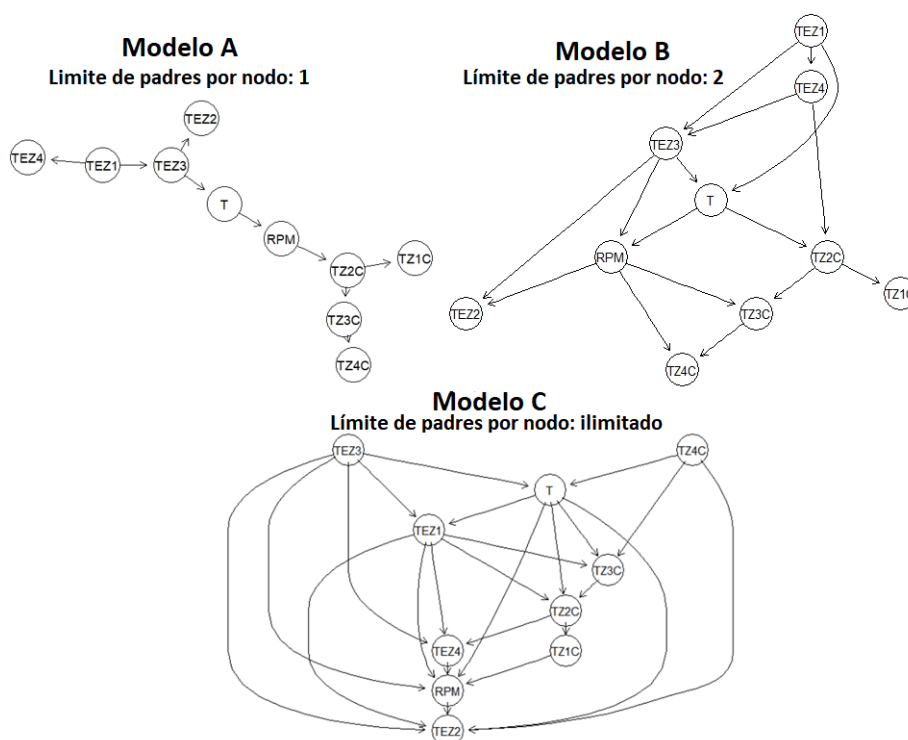
**Figura 6.9:** Densidad de la probabilidad marginal de la temperatura de fundido sin evidencias (arriba), y densidad de la probabilidad condicionada tras la propagación de la evidencia (abajo).

el valor obtenido al calcular la media<sup>3</sup> de los valores generados, el cual consigue un valor muy cercano al original. Otra aplicación interesante podría ser realizar la predicción de manera inversa, es decir, establecer como evidencia la temperatura de fundido deseada (o una combinación de diferentes variables) y muestrear valores correspondientes a los indicadores de configuración, de manera que podamos evaluar las configuraciones con las que, con mayor probabilidad, conseguiremos el resultado deseado.

Basándonos en esta estrategia, vamos a calcular el error obtenido por diferentes redes Bayesianas al predecir los valores de la temperatura de fundido para largos intervalos. Para realizar el aprendizaje estructural hemos utilizado un método *score+search*, utilizando el criterio *Bayesian Information Criterion* como *score* [Russell and Norvig, 1995], y para el aprendizaje paramétrico hemos utilizado un estimador máximo verosímil. Con el objetivo de limitar la complejidad de los modelos, hemos fijado las siguientes restricciones:

- Limitar el número de padres de cada nodo a 1.
- Limitar el número de padres de cada nodo a 2.
- No limitar el número de padres de cada nodo.

<sup>3</sup>Nótese que para calcular un único valor a partir del muestreo también podría haberse utilizado la mediana, la moda o algún otro estadístico.

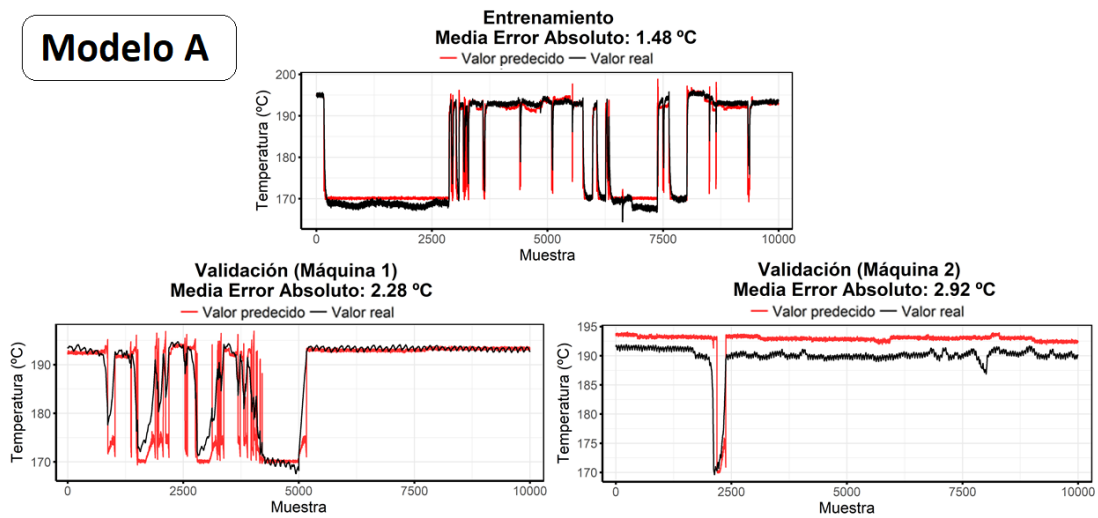


**Figura 6.10:** Estructuras de las redes Bayesianas generadas, para diferentes límites en cuanto al número de padres por nodo.

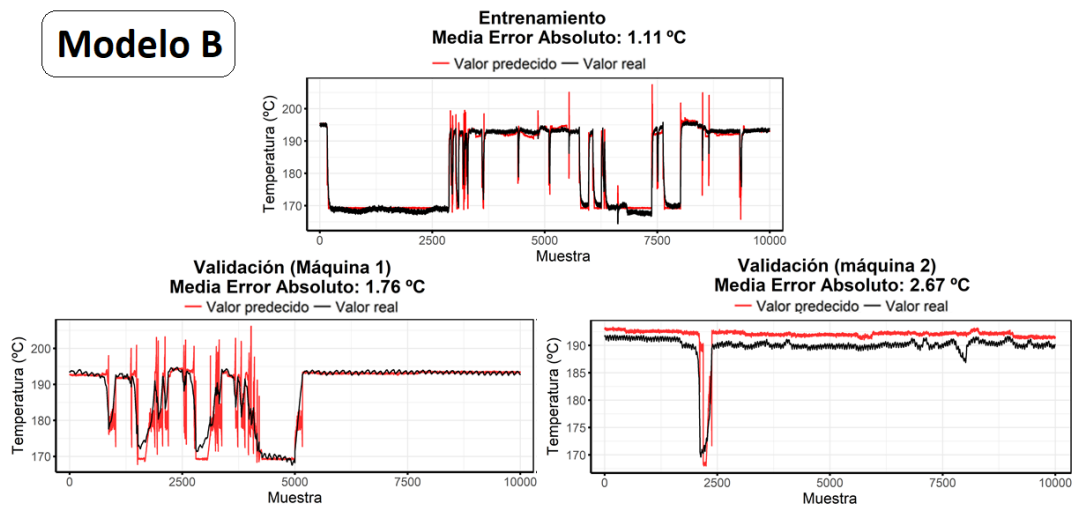
Las estructuras obtenidas en cada caso se muestran en la Figura 6.10. Como podemos observar, las dependencias principales ocurren entre los indicadores de las mismas zonas. Al aumentar el límite de padres por nodo, vemos que dichas dependencias siguen manteniéndose, aunque comienzan a generarse más conexiones entre los diferentes grupos.

Hay que tener en cuenta que, aunque hayan sido incluidas en la estructura, algunas conexiones pueden ser débiles, por lo que, de ser así, no aportarían información relevante en cuanto a las dependencias probabilísticas. Los resultados obtenidos en cuanto a la correlación entre las variables (véase la Figura 6.8) refuerzan esta hipótesis, ya que se puede comprobar que existen pocas relaciones, pero de una alta correlación. En cualquier caso, esto será analizado en base a los resultados obtenidos por cada red, ya que podremos comprobar si el hecho de utilizar un mayor número de conexiones supone una mejora significativa.

Una vez generadas las estructuras de cada red, hemos predecido los valores de la temperatura de fundido en los tres conjuntos de datos utilizados (el conjunto de entrenamiento y los dos conjuntos de validación), y hemos calculado el error obtenido con cada modelo. Los resultados obtenidos se muestran en la Figuras 6.11, 6.12 y 6.13, y se resumen en la



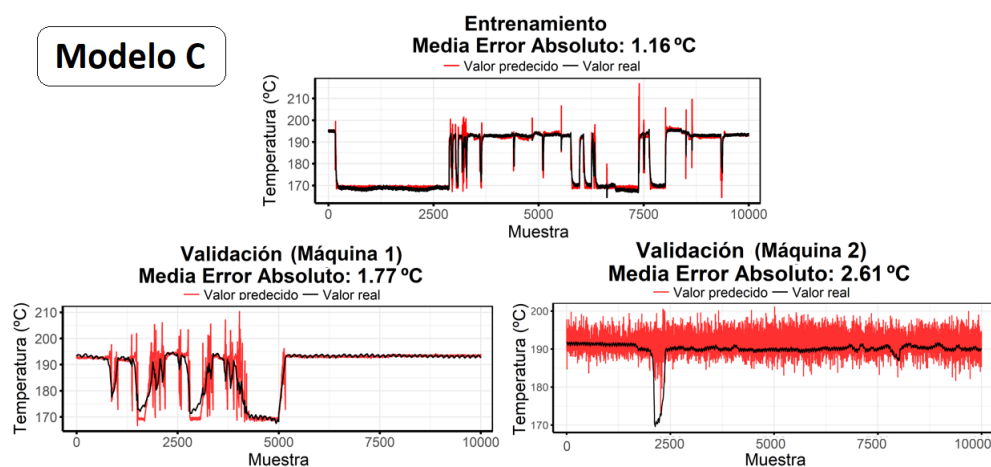
**Figura 6.11:** Predicción de la temperatura de fundido mediante redes Bayesianas con un máximo de 1 padre por nodo.



**Figura 6.12:** Predicción de la temperatura de fundido mediante una red Bayesiana con un máximo de 2 padres por nodo.

tabla 6.14. Por motivos de visualización y coste computacional, en todos los casos hemos utilizado 10000 observaciones de cada conjunto de datos para calcular el error obtenido, seleccionados mediante un muestreo uniforme de cada señal.

Como podemos observar, las tres redes consiguen unos resultados muy similares en el conjunto de entrenamiento y el primer conjunto de validación (Máquina 1), aunque el Modelo A consiga unos resultados ligeramente peores, lo que podría reflejar un subajuste debido a la limitación en cuanto al número de padres. En dichos conjuntos de datos, el funcionamiento de los modelos es adecuado en las zonas estables, pero muy irregular en



**Figura 6.13:** Predicción de la temperatura de fundido mediante una red Bayesiana sin límites en cuanto a la cantidad de padres por nodo.

Media Error Absoluto (°C)	Modelo A	Modelo B	Modelo C
Entrenamiento	1,48	1,11	1,16
Validación (Máquina 1)	2,28	1,76	1,77
Validación (Máquina 2)	2,92	2,67	2,61

**Figura 6.14:** Resultados obtenidos al analizar el error de predicción de la temperatura de fundido mediante redes Bayesianas con diferentes restricciones en cuanto al número de padres por nodo.

las zonas inestables, donde el error crece de manera significativa. Esto indica que la red no es capaz de modelar adecuadamente dichas zonas, lo que podría mejorarse con datos más heterogéneos.

En cuanto al segundo conjunto de validación (Máquina 2), los tres modelos consiguen resultados erróneos, aunque por diferentes razones. Mientras que los modelos A y B mantienen un error constante durante todo el intervalo, el modelo C muestra un comportamiento muy irregular, sin ninguna relación con la forma de la serie original. Esto podría ser señal de que en el Modelo C ha ocurrido un sobreajuste debido al elevado número de parámetros de la red, lo que significa que el modelo ha ajustado de manera excesiva sus parámetros para modelar los datos de entrenamiento (en los que consigue resultados adecuados), perdiendo así capacidad de generalización.

Teniendo en cuenta estos resultados, podemos determinar que las relaciones de dependencia más significativas son las capturadas en los modelos A y B, ya que el aumento en el número de parámetros no mejora de manera significativa el error obtenido. Por otro lado, los modelos entrenados parecen ser efectivos a la hora de predecir las temperaturas de una extrusora, aunque no muestren una adecuada capacidad de generalización al

validarlos con los datos de la Máquina 2. En cualquier caso, recordemos que estos resultados podrían ser muy diferentes si utilizáramos conjuntos de datos con mayor diversidad de configuraciones, por lo que no deben ser considerados como definitivos, sino como orientativos.

#### 6.4.2. Análisis mediante Redes Neuronales

Para realizar la predicción de temperaturas mediante redes neuronales hemos utilizado los datos continuos, previamente normalizados en el rango  $[0, 1]$  debido a los requisitos impuestos por la implementación utilizada (véase el Anexo C). Para normalizar los valores, utilizaremos la siguiente fórmula:

$$\bar{X} = \frac{X - X_{min}}{X_{max} - X_{min}}, \quad (6.1)$$

donde  $X$  representa el vector a normalizar y  $\bar{X}$  el vector normalizado en el rango  $[0, 1]$ . Es importante matizar que los valores  $X_{min}$  y  $X_{max}$  deben ser establecidos en la fase de aprendizaje (por ejemplo, en base al conjunto de entrenamiento o mediante límites definidos manualmente), por lo que serán los utilizados también para normalizar los datos de validación. En todo caso, los valores fuera del intervalo  $[X_{min}, X_{max}]$  se llevarán a 0 o 1.


En cuanto al proceso de predicción, emplearemos como variables predictoras las temperaturas del cilindro junto con la velocidad del motor, siendo la temperatura de fundido la variable a predecir. Para evaluar los resultados de diferentes topologías, vamos a utilizar tres modelos:

- Modelo A, el cual estará formado únicamente por la capa de entrada y de salida.
- Modelo B, el cual tendrá una capa interna de 3 neuronas.
- Modelo C, el cual tendrá dos capas internas, de 3 y 2 neuronas respectivamente.

En todos los casos, utilizaremos un algoritmo de aprendizaje conocido como *resilient backpropagation* [Riedmiller and Braun, 1993] y la función de activación sigmoide. Además, utilizaremos un nodo a modo de *bias*<sup>4</sup> en las capas ocultas y en la capa de salida.

---

<sup>4</sup> El término *bias* hace referencia a un nodo auxiliar frecuentemente utilizado en redes neuronales que sirve para simplificar el sistema de entrenamiento al expresar el umbral de activación de cada neurona como un peso sináptico [Rojas, 1996].



**Figura 6.15:** Estructuras de las tres redes neuronales generadas para la predicción de temperatura. La anchura de las conexiones refleja la magnitud del peso, el color gris representa un peso negativo y el color negro un peso positivo.

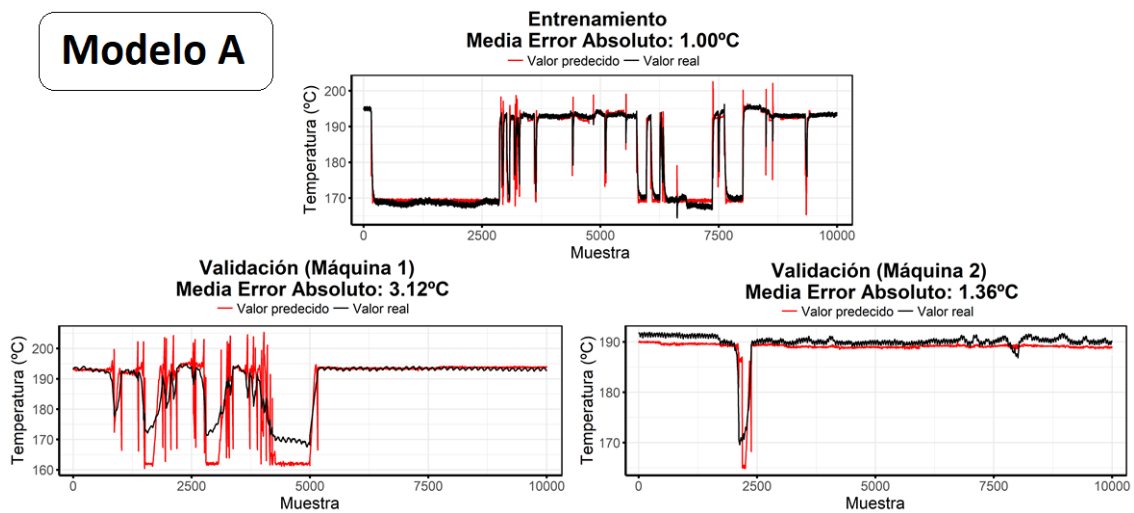
Las redes obtenidas tras el proceso de aprendizaje se muestran en la Figura 6.15. En las topologías más simples (Modelos A y B) podemos detectar, en base a la magnitud de las conexiones, que las variables de entrada de mayor influencia son la temperatura de la Zona 3 y la velocidad de giro del husillo. Sin embargo, a medida que incrementamos el número de capas ocultas, la relación entre las variables se vuelve más compleja, por lo que perdemos la capacidad de analizarla de manera intuitiva.

En cuanto a la predicción de la temperatura de fundido, los resultados obtenidos se muestran en las Figuras 6.16, 6.17 y 6.18. Comparando los resultados, podemos observar que todos los modelos consiguen predecir de manera adecuada el conjunto de entrenamiento, pero el comportamiento varía de manera notable en los conjuntos de validación. Analizando los resultados obtenidos en el primer conjunto de validación (Máquina 1), vemos que los modelos B y C consiguen una predicción precisa de las zonas estables, aunque muestran un comportamiento irregular en las zonas inestables. El Modelo A, por el contrario, no consigue modelar adecuadamente los descensos en las temperaturas, lo que muestra una falta de generalización.

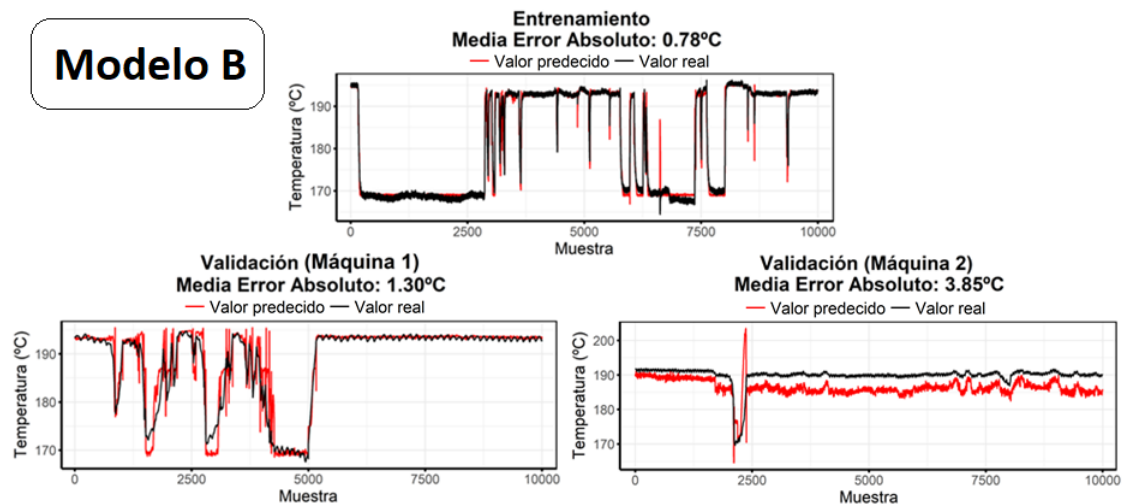
Por otro lado, analizando los resultados obtenidos en el segundo conjunto de validación (Máquina 2), podemos observar que el Modelo A refleja un comportamiento trivial, donde prácticamente predice el mismo valor a lo largo de la señal, por lo que no podemos considerar que los resultados sean adecuados a pesar de obtener un error bajo. En comparación, los Modelos B y C reflejan un comportamiento más adecuado, ya que consiguen adaptarse de manera adecuada a la forma de la señal, especialmente el Modelo C, el cual consigue aproximarse con una mayor precisión a los valores reales.

En resumen, las redes neuronales artificiales parecen ser modelos adecuados para la predicción de temperaturas, ya que consiguen resultados precisos con topologías relativa-


mente simples. Por otro lado, podemos determinar que los resultados mejoran al introducir capas ocultas en la topología de la red, ya que dichos modelos muestran una mayor capacidad de generalización en los dos conjuntos de validación utilizados.



**Figura 6.16:** Resultados obtenidos al predecir la temperatura de fundido mediante el modelo A (red neuronal artificial).



**Figura 6.17:** Resultados obtenidos al predecir la temperatura de fundido mediante el Modelo B (red neuronal artificial).



**Figura 6.18:** Resultados obtenidos al predecir la temperatura de fundido mediante el Modelo C (red neuronal artificial).

## 6.5. Predicción de alarmas

En esta sección trataremos de predecir la activación de la alarma partiendo del estado de la extrusora, utilizando tanto redes Bayesianas como redes neuronales.

Antes de comenzar, cabe mencionar que, para realizar el análisis de los resultados vamos a utilizar la herramienta conocida como *matriz de confusión* [Fawcett, 2006], donde las filas representan el número real de instancias por clase (en nuestro caso, el estado de la alarma), y las columnas el número de instancias clasificadas en cada clase (véase la Figura 6.19). Esta herramienta permite analizar de manera visual el comportamiento del modelo, además de ofrecer la posibilidad de detectar si existe alguna confusión principal entre dos clases (por ejemplo, que la proporción de falsos positivos sea elevada).

**Matriz de confusión**

		Valor predecido	
		Positivo	Negativo
Valor real	Positivo	True Positive (TP)	False Negative (FN)
	Negativo	False Positive (FP)	True Negative (TN)

**Figura 6.19:** Representación gráfica de una matriz de confusión.

Además, para evaluar el comportamiento del modelo hemos decidido utilizar las siguientes métricas [Powers, 2011]:



- *Precision*, la que se define como el ratio de observaciones positivas correctamente clasificadas respecto al número total de observaciones clasificadas como positivas:

$$\frac{TP}{TP + FP}$$

- *Recall*, la que se define como el ratio de observaciones correctamente clasificadas como positivas respecto al número total de observaciones positivas:

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

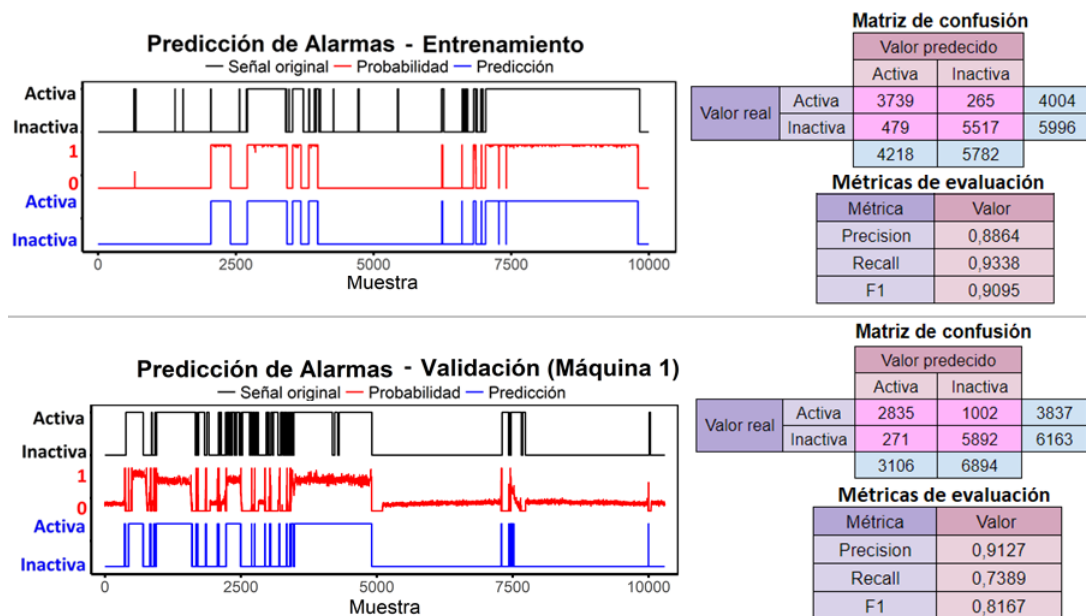
- *F1 score*, la que se define como la media armónica de las métricas *Precision* y *Recall*:

$$\frac{2(Precision \cdot Recall)}{(Precision + Recall)}$$

Estas métricas son adecuadas cuando los datos no están balanceados, como es nuestro caso, ya que todos los conjuntos contienen una proporción mayor de observaciones de alarma activa. De hecho, esto se vuelve extremo en el caso del conjunto de validación correspondiente a la Máquina 2, donde únicamente el 1,6 % de las observaciones muestran un estado activo de la alarma, por lo que no presentaremos los datos obtenidos para ese conjunto, ya que no sería significativo.

Una vez presentadas las métricas que utilizaremos para la validación de los resultados, comenzaremos con el análisis. Como ya hemos comentado en la Sección 6.3.3, el hecho de que los datos que utilizaremos únicamente muestren el estado de activación y no la causa reduce la posibilidad de profundizar en el análisis, así como de validar los resultados. Además, como ya comprobamos en la Sección 4.2.4, las activaciones de la alarma coinciden con las detenciones de las máquinas, por lo que incluir información relacionada con el estado de activación de la extrusora (por ejemplo, la velocidad del motor) conllevaría a crear un modelo trivial, ya que solamente tendría en cuenta dichas variables. Sin embargo, también sabemos que las paradas del motor suponen un descenso en las temperaturas (además de generar irregularidades), por lo que utilizar dichos indicadores como variables predictoras también podrían generar modelos triviales, los cuales determinarían la activación de la alarma simplemente en base a los descensos en las temperaturas.

Por estos motivos, predecir la activación de las alarmas de este modo resulta trivial, por lo que no realizaremos un análisis exhaustivo. Aún así, para comprobar que obtenemos

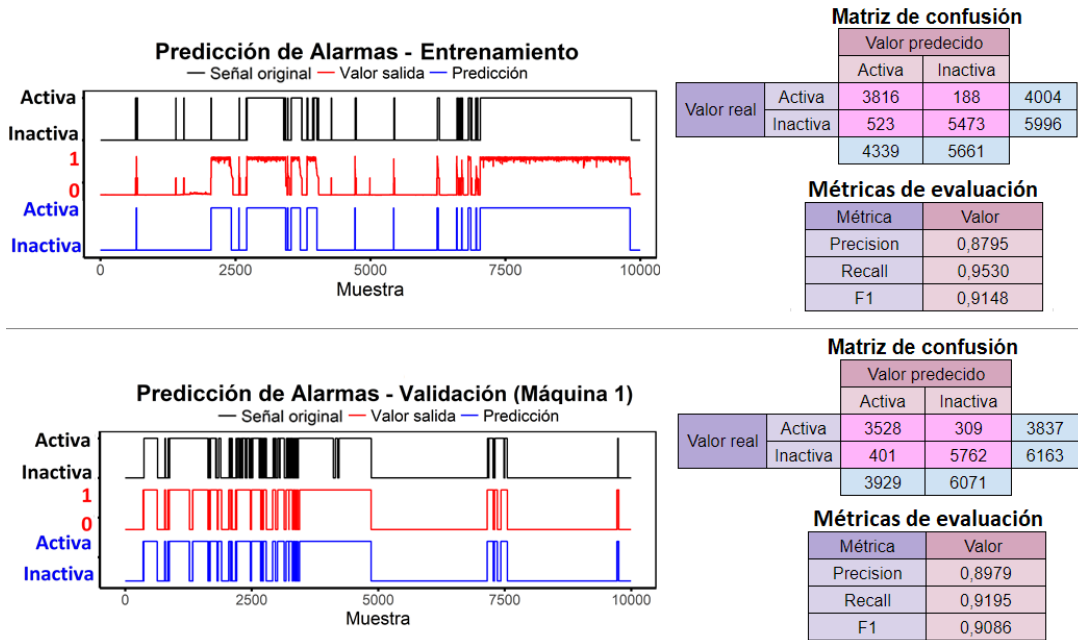


**Figura 6.20:** Resultados obtenidos al predecir el estado de activación de la alarma mediante un clasificador Bayesiano.

resultados adecuados, hemos entrenado una red Bayesiana y una red neuronal utilizando como variables predictoras únicamente las temperaturas del cilindro y fundido. En cuanto a la red Bayesiana, hemos decidido utilizar el clasificador Bayesiano conocido como *Naive Bayes* [Minsky, 1961], modelo muy popular en problemas de clasificación, donde la clase es el único padre de todas las demás variables (predictoras), y donde la clase, a su vez, no tiene padres. En cuanto a las redes neuronales, utilizaremos un perceptrón multicapa de una sola capa oculta, formada por 3 neuronas.

Los resultados obtenidos mediante estos modelos se muestran en las figuras 6.20 y 6.21. En el caso de la red Bayesiana, gracias a que permite calcular la probabilidad de la predicción, hemos añadido tanto la predicción como la probabilidad correspondiente. En el caso de la red neuronal, hemos añadido tanto el valor de salida de la neurona (valor continuo en el rango  $[0, 1]$ , ya que utilizamos la función de activación sigmoide) como la predicción, que será el valor de salida redondeado, con el fin de discretizarlo (el valor 0 corresponde a un estado inactivo, y el valor 1 a un estado activo). En este caso, el valor de salida no refleja una probabilidad, pero puede interpretarse como una medida de *convicción*. En los dos modelos, prediciremos que la alarma está activa cuando el valor de salida sea superior o igual a 0,5.

Analizando los resultados, podemos ver que ambos muestran un comportamiento similar, aunque la red Bayesiana refleja una mayor proporción de falsos negativos en el conjunto

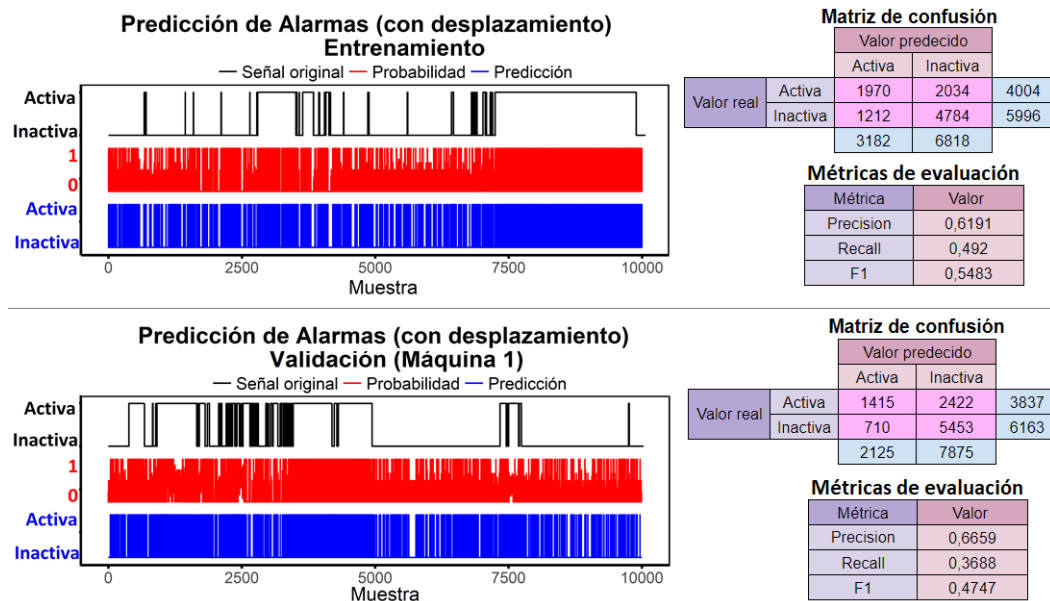


**Figura 6.21:** Resultados obtenidos al predecir el estado de activación de la alarma mediante una red neuronal artificial.

de validación, lo que se ve reflejado en el *Recall*. En cualquier caso, ambos modelos consiguen valores elevados en todas las métricas de evaluación utilizadas, lo que demuestra la trivialidad de los resultados, ya que solamente hemos necesitado las temperaturas de la extrusora.

Para evaluar el comportamiento de los modelos en una situación mas compleja, hemos decidido crear modelos que intenten predecir la activación de la alarma antes de que ocurran, por ejemplo, 5 minutos antes. Para realizar esto, hemos retrasado la señal de alarma 5 minutos respecto al resto de señales, de manera que, al realizar el proceso de aprendizaje, el modelo se ajuste en base al riesgo de que con la configuración actual la alarma pueda ser activada en un instante cercano.

Para realizar un proceso de aprendizaje adecuado, además de retrasar la señal correspondiente a la alarma, vamos a generar un nuevo conjunto de datos, de la siguiente manera: como vamos a intentar modelar los instantes de activación, seleccionaremos únicamente las observaciones en las que la alarma cambia de estado (de inactiva a activa). Sin embargo, en el intervalo de entrenamiento (de una duración aproximada de una semana, lo que equivale a aproximadamente 600000 muestras), hemos detectado aproximadamente 100 observaciones de este tipo, por lo que vamos a seleccionar dichos instantes junto con un número  $v$  de muestras anteriores y un número  $w$  de muestras posteriores. Es decir,

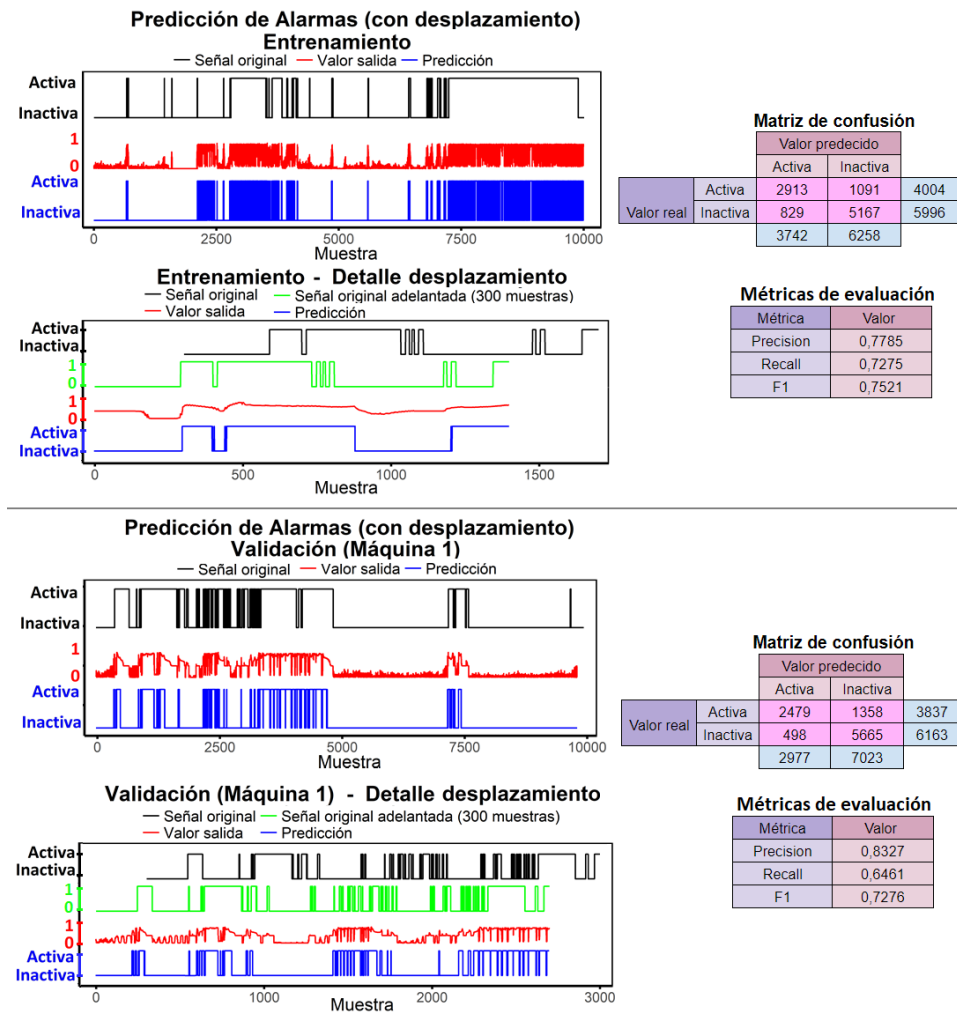


**Figura 6.22:** Resultados obtenidos al predecir con 5 minutos de adelanto el estado de activación de la alarma mediante una red Bayesiana.

si en el instante  $t$  la alarma pasa de estar inactiva a activa, seleccionaremos el intervalo  $[t - v, t + w]$  (en nuestro caso,  $v = w = 100$ ). De esta manera, conseguiremos un conjunto de datos con una cantidad adecuada de observaciones, además de garantizar, de manera sencilla, una adecuada proporción en cuanto a los estados de la alarma, solucionando así el problema del desbalanceo.

Los resultados obtenidos mediante este experimento se muestran en las figuras 6.22 y 6.23. Como podemos observar, la red Bayesiana no responde adecuadamente a los datos desplazados, consiguiendo unos resultados claramente insatisfactorios. La red neuronal, por el contrario, sí consigue unos resultados adecuados, mostrando capacidad de predecir la alarma con el tiempo establecido (5 minutos, equivalente a 300 muestras). Para comprobar esto de manera visual, en la figura 6.23 hemos añadido dos gráficos adicionales mostrando en mayor detalle el efecto del desplazamiento. Sin embargo, comparando los resultados con los obtenidos en los datos sin desplazar (véase la figura 6.21), vemos que el *recall* obtenido es significativamente más bajo, lo que se debe a un incremento notable en falsos negativos. Esto podría indicar que no todas las activaciones son adecuadamente modeladas, por lo que debería ser una característica a mejorar para aumentar la fiabilidad del modelo.

En resumen, y de acuerdo con los resultados obtenidos, podemos determinar que los modelos utilizados (en especial las redes neuronales) muestran un adecuado comportamiento



**Figura 6.23:** Resultados obtenidos al predecir con 5 minutos de adelanto el estado de activación de la alarma mediante una red neuronal artificial.

a la hora de predecir las alarmas. En cuanto a la validación de los resultados, creemos que para realizar un adecuado análisis es necesario incluir información más detallada acerca de la activación de las alarmas, como por ejemplo la causa o el intervalo de activación de cada suceso. Además, es evidente que es necesario incluir información de más indicadores, como por ejemplo los relacionados con los elementos mecánicos de las máquinas, ya que pueden tener una implicación directa con la activación de la alarma. Por último, teniendo en cuenta que tanto el diseño de las extrusoras como su funcionamiento contienen características complejas de analizar sin un conocimiento técnico, creemos que es especialmente necesaria la colaboración con los expertos en el dominio, para definir y diseñar adecuadamente este tipo de análisis.



### Conclusiones

---

En este capítulo se exponen, a modo de conclusiones, las contribuciones más relevantes extraídas en base al trabajo realizado a lo largo del proyecto y a los resultados obtenidos en las diferentes fases.

#### 7.1. Contribuciones técnicas

Las contribuciones principales del trabajo realizado se dividen en dos líneas principales: propuesta y validación de técnicas de preprocesado, y estudio de la viabilidad de diversas técnicas de minería de datos.

- Técnicas de preprocesado

Tal y como se describió en los objetivos, hemos planteado, implementado y validado múltiples técnicas de preprocesado para el tratamiento de los principales errores de los datos. De acuerdo con los resultados obtenidos, podemos determinar que todos los errores son corregidos de manera adecuada, por lo que estos tratamientos suponen un paso adelante hacia la mejora en la calidad de los datos.

Además, el hecho de proponer diferentes técnicas para cada uno de los tratamientos permite que el preprocesado pueda ser adaptado a múltiples tipos de análisis posteriores, lo que proporciona una gran flexibilidad, y lo que sin duda facilitará el trabajo del ingeniero o analista de datos que deba seguir trabajando en el proyecto.

### ■ Análisis de la viabilidad de las técnicas de minería de datos

El principal objetivo de esta fase era analizar la viabilidad y el potencial de las técnicas de *data mining* para la explotación de los datos. En esta línea, se han planteado dos tipos de modelos: redes Bayesianas y redes neuronales. Estos modelos han sido puestos a prueba en diferentes análisis, como la predicción de temperaturas o la predicción de alarmas, y, de acuerdo con los resultados, muestran un comportamiento adecuado en la mayoría de los casos, por lo que consideramos que son modelos aptos para llevar a cabo estos tipo de análisis.

Además, gracias a los análisis realizados hemos sido capaces de detectar y plantear qué características son las que deberían mejorarse respecto a la captura de los datos. Consideramos que esto es vital tanto para poder continuar trabajando en el proyecto como para garantizar la viabilidad y fiabilidad de los recursos computacionales propuestos, por lo que creemos que supone una contribución de gran utilidad de cara al futuro del proyecto.

En resumen, consideramos que el trabajo realizado en esta fase sirve como base para la explotación avanzada de los datos de las extrusoras, y que facilitará el desarrollo de los objetivos a largo plazo. De hecho, tras estos análisis, consideramos que las técnicas y modelos propuestos pueden ser utilizados en un gran número de aplicaciones, de una mayor complejidad, tal y como expondremos en la Sección 8, dedicada al trabajo futuro.

## 7.2. Contribuciones personales

A nivel personal, considero que trabajar en este proyecto me ha ayudado a mejorar en múltiples aspectos.

Para comenzar, el hecho de poder colaborar en un proyecto de empresa real ha sido una gran oportunidad no solo para poner a prueba los conocimientos adquiridos a lo largo de la carrera, sino para poner en práctica otras competencias profesionales, como por ejemplo, la colaboración con profesionales de otros dominios. Esto me ha permitido también ser consciente de la dificultad añadida que supone trabajar en un contexto real, donde características como la interoperabilidad de los datos o el traslado del conocimiento toman una importancia mucho mayor que en el mundo académico.

Por otro lado, enfrentarme a un proyecto aún en sus primeras fases de desarrollo me ha supuesto mejorar en aptitudes como la toma de decisiones, y me ha permitido comprobar y



valorar el gran trabajo inicial que conllevan los proyectos relacionados con la explotación de datos en el mundo industrial.

Finalmente, trabajar con dos directores de distintas especialidades y áreas de investigación ha sido muy enriquecedor, ya que me ha permitido desarrollar el proyecto desde un enfoque multidisciplinar, descubriendo así nuevos conceptos y tecnologías aplicables a múltiples campos de la informática.

Por todas estas razones, considero que este proyecto me ha ayudado a mejorar como profesional, y estoy seguro de que el conocimiento y la experiencia adquirida me será de gran utilidad para el desarrollo de proyectos futuros, y para afrontar nuevos retos con una mayor preparación y profesionalidad.



### Propuestas de mejora y líneas futuras

---

Basándonos en el trabajo y los análisis desarrollados a lo largo del documento, en este capítulo vamos a recopilar diferentes propuestas que consideramos de interés para mejorar la calidad de los datos, ampliar las posibilidades de análisis o desarrollar objetivos de mayor complejidad.

#### 8.1. Posibles líneas de investigación

En esta sección propondremos diversas líneas de investigación que consideramos de interés para el desarrollo de objetivos a largo plazo. Como ya mencionamos en la Sección [2.2](#), dichos objetivos se enfocan en dos líneas principales: la optimización de recursos y el mantenimiento predictivo de las extrusoras. Por tanto, las alternativas que proponemos están dirigidas a estos objetivos.

##### 8.1.1. Optimización de recursos

En nuestro contexto, entendemos como optimización la búsqueda de configuraciones de las máquinas que consigan minimizar o maximizar un objetivo concreto, por ejemplo, minimizar el coste de los recursos utilizados (como el coste energético o la cantidad de materia primera), maximizar la producción, o ambas a la vez.

Para conseguir tales objetivos, se podría considerar el uso de metaheurísticos, ya que estos métodos de optimización permiten explorar de manera eficiente grandes espacios

de soluciones, permitiendo así encontrar soluciones de calidad en un tiempo limitado. En la Sección 8.2.3 se proponen posibles mejoras en cuanto a la captura de los datos con el objetivo de facilitar el desarrollo de este tipo de análisis.

Para motivar el uso de metaheurísticos, supongamos que queremos determinar a qué temperaturas tenemos que mantener las zonas del cilindro para conseguir una temperatura de fundido concreta, tratando de minimizar el coste energético que supone calentar el cilindro a la vez que maximizamos la producción de botellas por hora<sup>1</sup>. Asumamos por simplicidad que el resto de variables se mantienen constantes a un valor determinado. Una aplicación práctica de esta búsqueda podría ser la de reconfigurar la máquina en tiempo real tras un intervalo inestable (lo que requiere un tiempo de ejecución limitado), o simplemente el descubrimiento de nuevas configuraciones (lo que no exige un tiempo de cómputo tan limitado).

Si quisiéramos realizar esta búsqueda manualmente, un experto tendría que evaluar, mediante alguna herramienta de simulación, un elevado número de combinaciones, por lo que es evidente que no favorece la búsqueda de configuraciones óptimas. Además, el manejo de múltiples variables es complejo de analizar de forma intuitiva, ya que cada variable (o cada combinación) no afecta de la misma manera a los indicadores de interés.

Por otro lado, evaluar todas las posibles configuraciones es inviable, ya que el número de combinaciones crece de manera exponencial en función del número de variables a considerar (en nuestro caso, de hecho, la cantidad de combinaciones posibles es infinita, ya que las variables son continuas).

Por estas razones, es necesario el uso de métodos eficientes que permitan encontrar soluciones de calidad en un tiempo razonable, aunque no garanticen la optimalidad del resultado final. Para conseguir esto, uno de los métodos más utilizados actualmente son las búsquedas basadas en metaheurísticos, por lo que consideramos que pueden ser de gran utilidad para ser aplicados en nuestro proyecto.

Para mantener esta sección lo más breve posible, las nociones básicas de los problemas de optimización y los metaheurísticos se recogen en el Anexo B, donde también proporcionamos varias referencias de interés para profundizar en este ámbito. Finalmente, algunos ejemplos de la aplicación de estos métodos en escenarios químicos o industriales puede verse en [Valadi and Siarry, 2014] y [Jalalinejad et al., 2007].

---

<sup>1</sup>En este ejemplo, asumimos que disponemos de un modelo capaz de predecir de manera fiable la temperatura de fundido (como por ejemplo, una red neuronal ya entrenada), así como herramientas para calcular el coste energético de la configuración o la tasa de producción.

### 8.1.2. Herramientas de simulación y asistencia

Como ya hemos visto en las secciones relacionadas con el análisis de los datos, los modelos utilizados pueden ser de gran utilidad en la predicción de indicadores como las temperaturas o las alarmas. En base a esas operaciones, podemos generar herramientas que sirvan de ayuda o soporte para los profesionales encargados del manejo o la configuración de las máquinas, por lo que en esta sección plantearemos diferentes alternativas.

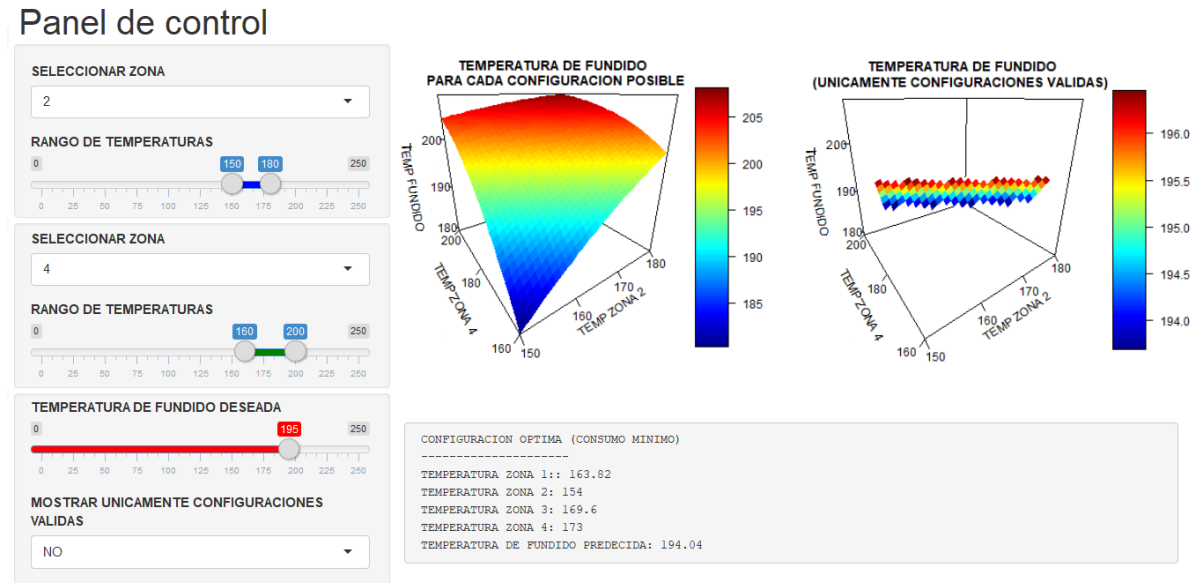
Una posible aplicación directa de estos modelos puede ser la generación de herramientas de simulación, en las cuales podamos definir una configuración (o estado) de una máquina de modo que la herramienta sea capaz de predecir el funcionamiento de la extrusora o el valor de los diferentes indicadores. Del mismo modo, estas operaciones pueden realizarse en base a los datos capturados en tiempo real, lo que permitiría predecir el riesgo de activación de una alarma o posibles alteraciones en la temperatura de alguna zona, lo que puede ser de gran utilidad para dar una respuesta proactiva a los posibles fallos de producción y lograr un mayor control del proceso.

Por otro lado, estas herramientas también ofrecen la oportunidad de que los expertos en el dominio analicen el comportamiento de sus máquinas de una manera más inteligente, por ejemplo, analizando el efecto que tienen las diferentes temperaturas del husillo en la temperatura de fundido. A modo de demostración, hemos generado una aplicación en la que, partiendo de una configuración determinada de la extrusora<sup>2</sup>, podemos alterar el valor de dos zonas del cilindro y observar el efecto de estas modificaciones en la temperatura de fundido, la cual será predecida mediante una red neuronal ya entrenada. La interfaz de la aplicación puede visualizarse en la Figura 8.1.

En dicha aplicación, el usuario tendrá la opción de seleccionar dos zonas de la extrusora, y establecer un rango de temperaturas para cada una de ellas. De esta manera, calcularemos el valor de la temperatura de fundido que obtendríamos para cada una de las combinaciones. Además, el usuario también podrá establecer el valor de la temperatura de fundido que desea obtener, para que la aplicación muestre automáticamente las combinaciones válidas para conseguir dicha temperatura (con un error de 1°C). Por último, la herramienta calculará, en base a algún criterio, cual es la combinación óptima para conseguir dicha temperatura de fundido (en este ejemplo, recomendaremos simplemente la configuración que consiga el promedio de temperaturas más bajo en la zona del cilindro, asumiendo que es la configuración que supone un menor consumo).

---

<sup>2</sup>Por simplicidad, en este ejemplo utilizaremos únicamente las temperaturas del cilindro y la temperatura de fundido.




**Figura 8.1:** Interfaz de la aplicación generada para analizar el comportamiento de la temperatura de fundido al modificar dos variables de temperatura.

Cabe destacar que, para garantizar un análisis adecuado, se generarán también gráficos tridimensionales dinámicos, donde el usuario puede modificar la perspectiva de visualización. Un ejemplo de estos gráficos se muestra en la Figura 8.2. En este ejemplo, puede comprobarse que la Zona 4 tiene una mayor influencia en la temperatura de fundido que la Zona 2, lo que tiene sentido teniendo en cuenta que es una zona más próxima al sensor que captura la temperatura de fundido. Si bien este ejemplo puede resultar trivial, la combinación de distintos tipos de variables puede no ser intuitiva de analizar, por ejemplo, la relación entre la velocidad de giro del husillo y la presión de fundido. De un modo similar, estos recursos gráficos pueden servir para comparar el funcionamiento de dos modelos de extrusora diferentes, o si las relaciones entre las variables es diferente en base al tipo de receta utilizada para el proceso.

### 8.1.3. Control del proceso mediante redes neuronales

En las últimas décadas, los sistemas conocidos como *Model Predictive Control* (MPC) han demostrado ser efectivos en tareas relacionadas con el control automático de máquinas industriales, especialmente en procesos donde los modelos matemáticos no consiguen representar completamente el comportamiento experimental observado [Piché et al., 1999] [Otero, 1998].

En estos sistemas, uno de los modelos más utilizados son las redes neuronales artificia-



**Figura 8.2:** Gráficos tridimensionales dinámicos generados por la aplicación mostrada en la Figura 8.1, donde se visualizan los valores de las temperaturas de fundido predecidos al modificar las temperaturas de las Zonas 2 y 4 del cilindro de una extrusora.

les, dando lugar a los controladores conocidos como NNMPC (*Neural Network Model Predictive Control*) [Qin and Badgwell, 1997]. Un ejemplo de la aplicación de estos sistemas de control en contextos similares al nuestro puede verse en [Otero, 1998], donde son utilizados para el control automático de un sistema termodinámico.

De cara a nuestro proyecto, y teniendo en cuenta los adecuados resultados conseguidos por las redes neuronales en el análisis experimental desarrollado, consideramos que podría ser interesante investigar la aplicación de estos modelos para el control automático de la extrusora. Además, en estos sistemas de control podrían combinarse diferentes componentes para conseguir un mayor potencial, como por ejemplo, modelos encargados de predicción de alarmas con los modelos encargados del control de las temperaturas, consiguiendo así la capacidad de dar una respuesta proactiva a las posibles anomalías.

Hay que tener en cuenta que estos modelos pueden entrenarse y validarse de manera paralela al funcionamiento de la extrusora, por ejemplo, mediante un aprendizaje por refuerzo (*reinforcement learning*, en inglés), mejorando progresivamente el modelo en base a los datos capturados [Hoskins and Himmelblau, 1992]. De esta manera, podría compararse en tiempo real el comportamiento del modelo con el del sistema de control real de la extrusora, y validar su funcionamiento. Además, en caso de que el modelo muestre un comportamiento adecuado, puede integrarse de manera progresiva, combinándolo con el control real del sistema.

Por estos motivos, consideramos que el control automático de las máquinas es una línea de desarrollo muy interesante, y que, al poder realizarse de manera paralela al funcio-

namiento de las máquinas, puede integrarse de manera segura y controlada, sin suponer riesgos o costes económicos (más allá del contrato de los servicios encargados de generar y gestionar dichos modelos). Nuevamente, el diseño de estos sistemas y su aplicabilidad debería analizarse en colaboración con los expertos en el dominio. Por último, consideramos, para desarrollar este tipo de sistemas de control, podría ser necesario definir nuevos indicadores, lo que expondremos con mayor detalle en la Sección 8.2.3.

## 8.2. Propuestas de mejora respecto a la captura de los datos

Para poder realizar análisis adecuados o generar modelos funcionales y fiables, creemos que la calidad de los datos tiene margen de mejora, ya que consideramos que los datos actualmente disponibles son adecuados para la monitorización del proceso, pero no para un análisis como los que se desean plantear a largo plazo.

Como las necesidades o características del conjunto de datos varía dependiendo del procesamiento que se quiera realizar posteriormente, vamos a proponer mejoras para cada tipo de análisis planteado a lo largo del documento.

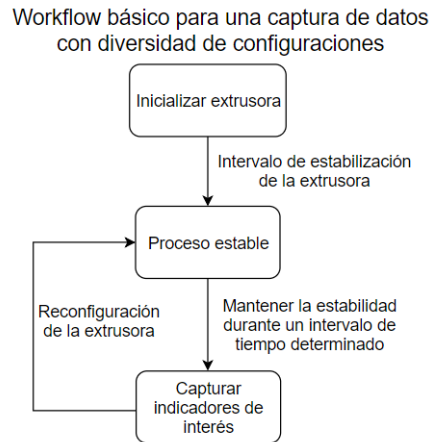
### 8.2.1. Mejoras en cuanto al análisis de temperaturas y configuración

En cuanto a las señales relacionadas con la configuración de la máquina (temperaturas, velocidad del husillo, etc.), como ya hemos mencionado con anterioridad, hemos observado que los datos únicamente muestran observaciones para una configuración determinada de la extrusora, donde las únicas variaciones notables se dan en los intervalos irregulares que, como ya sabemos, se deben a la parada del motor, por lo que no muestran información sobre el proceso mientras la máquina está en marcha. Esto lleva a que no sea posible analizar adecuadamente las relaciones entre las variables o generar modelos con una capacidad adecuada de generalización.

Para solventar esta limitación, consideramos que es necesario generar un conjunto de datos que refleje una mayor diversidad en cuanto a configuraciones. Una manera de lograr este conjunto de datos podría ser recopilar datos de diferentes extrusoras, siempre y cuando sean del mismo modelo, ya que las características del proceso varían de manera notable dependiendo del modelo de la extrusora, por lo que sus datos podrían no ser compatibles.

Otro modo de lograr un conjunto de datos heterogéneo sería directamente realizar un proceso experimental, estableciendo en una misma extrusora diferentes configuraciones





**Figura 8.3:** *Workflow* básico para una adecuada captura de los datos en cuanto a diversidad en las configuraciones.

y capturando en cada una de ellas los indicadores de interés. Hay que tener en cuenta que la extrusora necesita un intervalo de estabilización para que sus temperaturas se vuelvan estables tras un cambio, por lo que será necesario tener en cuenta este intervalo antes de realizar la captura de los datos. De esta manera, podremos comprobar de qué manera influye cada configuración en los diferentes indicadores de interés, como pueden ser la producción, el consumo de energía o la presión de fundido. En la Figura 8.3 mostramos un *workflow* básico para la generación de dicho conjunto de datos.

Hay que tener en cuenta que el número de combinaciones posibles para cada variable de configuración incrementa de manera exponencial a medida que aumentamos el número de variables o el número de posibles valores por variable, lo que supone un mayor coste económico y un mayor gasto en recursos como energía o materia prima. Por tanto, creemos conveniente un diseño adecuado del proceso de experimentación, asesorado por expertos en el dominio, para evaluar qué tipo de combinaciones conviene evaluar, posibilitando así definir un conjunto de configuraciones limitado pero significativo.

### 8.2.2. Mejoras en cuanto al mantenimiento predictivo

En cuanto al mantenimiento predictivo, consideramos que, de acuerdo con los datos analizados, la atención principal se centra en la alarma y sus causas de activación. Como ya hemos comentado, en los datos utilizados para el análisis solamente tenemos información acerca del estado de la alarma (activa o inactiva), sin más información acerca de la causa o el intervalo de duración de cada suceso. Hay que tener en cuenta que dichos sucesos

suponen la activación de la alarma durante un intervalo, por lo que existe la posibilidad de que ocurran solapamientos. Por este motivo, consideramos que es necesario conocer tanto el instante inicial como final de cada uno de estos sucesos.

Una vez consigamos dicha información, el siguiente paso sería definir adecuadamente qué tipo de sucesos se quieren analizar, ya que, de acuerdo con la información proporcionada por los expertos, existen más de 150 sucesos diferentes que pueden suponer la activación de la alarma (cada uno con un código asignado), de los cuales un conjunto son considerados graves (los cuales suponen la parada de la extrusora) mientras que el resto son considerados advertencias leves. Por otro lado, hay que tener en cuenta que algunas de estas alarmas no son causadas por un comportamiento erróneo de la extrusora, sino por la manipulación de alguno de los elementos de la máquina (por ejemplo, la apertura de algunas puertas de la máquina).

Por estos motivos, creemos que es necesario definir qué sucesos tienen relación con los indicadores que describen el estado de la extrusora, para poder así clasificar que tipo de errores pueden predecirse y cuales no. De un modo similar, puede ser conveniente definir para cada suceso qué indicadores tienen una relación directa, facilitando así la creación de herramientas de predicción más especializadas. Esto podría definirse tanto manualmente (en base al conocimiento de los expertos) como automáticamente, analizando la relación entre las variables mediante técnicas de análisis de datos.

### 8.2.3. Mejoras en cuanto a la optimización de recursos y control automático

Para realizar un análisis enfocado a la optimización de recursos, consideramos que es necesario capturar el consumo de los diferentes elementos de la extrusora. Si bien ya disponemos de datos como el consumo del motor, no tenemos información acerca del consumo de las resistencias eléctricas o de los sistemas de ventilación, por lo que no es posible determinar, por ejemplo, qué configuraciones son las que suponen un menor consumo energético.

En cuanto a los análisis dirigidos al control automático de las extrusoras, también sería necesario conocer este tipo de indicadores, ya que permitirían conocer, por ejemplo, cómo se realiza el control de los sistemas de calefacción, lo que sería básico para poder entrenar un modelo de minería de datos con esa finalidad.

Por estos motivos, consideramos que podría ser necesario incluir indicadores relaciona-

dos con el consumo energético de los diferentes componentes de la extrusora, así como indicadores que reflejen información acerca del sistema de control de las mismas.



# **Anexos**



### Extrusión


---

En nuestro contexto, la extrusión es un proceso de transformación de materiales plásticos, llevado a cabo mediante una máquina industrial especializada denominada extrusora.

En este proceso, en general, el plástico se introduce en la extrusora mediante una tolva, la cual conduce al material a un cilindro hueco. Una vez dentro, el material es desplazado hacia la salida mediante un husillo. A medida que el material avanza, la superficie del cilindro es calentada mediante elementos térmicos (resistencias), lo que causa un aumento en la temperatura del material, provocando que este se funda. Una vez llegado al final del husillo, el material entrará en una pieza conocida como cabezal, la cual contiene una boquilla por la que el material saldrá al exterior. En nuestro caso, el material se expulsará por la boquilla a unos moldes, los cuales tendrán la forma de la botella que se quiera producir, y, por último, se inflará utilizando un sistema de soplado, provocando que el plástico se adapte a la forma del molde, y consiguiendo así la forma de la botella. En la Figura [A.1](#) podemos visualizar los elementos principales de una extrusora, que se explicarán a continuación.

#### A.1. Elementos principales de una extrusora

Para entender mejor el funcionamiento de las extrusoras, se van a presentar los elementos principales de las mismas, explicando de manera más concreta las características principales de cada uno de ellos, así como la influencia en el proceso.



**Figura A.1:** Esquema general de una extrusora. La imagen original ha sido extraída de [Beltrán and Marcilla, 2012] (página 104).

- Tolva de alimentación

La tolva es el elemento utilizado para introducir el material en el cilindro. Para unir esta pieza con el cilindro, se utiliza una garganta de alimentación, la cual suele diseñarse con el objetivo de proporcionar un flujo constante de material.

- Cilindro

El cilindro (o cilindro de calefacción) es el contenedor que alberga el husillo, por lo que proporcionará el entorno de traslado y transformación del material. Para la calefacción del cilindro, el sistema más utilizado es el basado en resistencias eléctricas circulares, las que se ubican a lo largo del cilindro, como se muestra en la Figura A.1.


Estas resistencias se controlan de manera independiente, lo que permite lograr un gradiente de temperatura adecuado a lo largo del cilindro. Además del calor generado por estas resistencias, dentro del cilindro pueden ocurrir fenómenos emisores de calor, que pueden desestabilizar la temperatura. Por este motivo, es común instalar un sistema de enfriamiento en el cilindro (principalmente mediante ventiladores), con la finalidad de lograr un mayor control en la temperatura y contrarrestar el efecto de dichos fenómenos.

- Husillo

El husillo consiste en un cilindro rodeado de un filete helicoidal, cuya principal función es transportar, calentar y mezclar el material. Las características principales de un husillo, tal y como se muestra en la Figura A.2, son las siguientes: longitud ( $L$ ), diámetro ( $D$ ), ángulo del filete ( $\Omega$ ) y el avance ( $w$ , también conocido como paso). Hay que tener en cuenta que el paso no suele ser constante en toda la longitud



del husillo, y, por tanto, las características del transporte del material (velocidad, presión, etc.) serán diferentes dependiendo de la zona.



**Figura A.2:** Características principales de un husillo de extrusión. La imagen original ha sido extraída de [Beltrán and Marcilla, 2012] (página 108).

- Filtros y plato rompedor


Estas dos piezas están situadas al final del cilindro, dando comienzo al cabezal. El propósito principal de los filtros es retener cualquier contaminante que pueda influir en la calidad del producto, y, el del plato, servir de soporte para los filtros.

- Cabezal y boquilla

El cabezal es el elemento situado al final del cilindro, es decir, el elemento final del proceso de extrusión. La función principal del cabezal es la de transportar el material a la boquilla manteniendo un flujo uniforme, permitiendo así una dosificación constante. Por otro lado, la función de la boquilla es la de expulsar el material al exterior, controlando al mismo tiempo características como la forma o la cantidad de material extruido. El diseño de los elementos principales del cabezal se puede visualizar de manera más precisa en la Figura A.3.

## A.2. Modelos de desplazamiento del material


Debido a las transformaciones que sufre el material a lo largo del proceso de extrusión, la mecánica del desplazamiento es diferente dependiendo de la zona. En general, los modelos utilizados para calcular de manera precisa estos desplazamientos son complejos, y, por tanto, en la práctica es frecuente utilizar modelos simplificados. Si bien es cierto que en este TFG no se han realizado estos cálculos con un nivel de precisión tan elevado como los proporcionados por dichos modelos, se van a presentar brevemente los conceptos básicos. El objetivo de esto es poder proporcionar al lector una idea general de cómo es



**Figura A.3:** Elementos principales del cabezal de una extrusora. La imagen original ha sido extraída de [Beltrán and Marcilla, 2012] (página 113).

el comportamiento del material a lo largo del proceso, de manera que le permita también ser consciente de las simplificaciones que hemos utilizado en nuestro proyecto.

Generalmente, podemos distinguir 3 zonas principales en una extrusora, tal y como se muestra en la Figura A.4: la zona de alimentación, la zona de transición y la zona de dosificación. En cada una de ellas, las características del desplazamiento son diferentes, por lo que se van a presentar de manera individual.



**Figura A.4:** Representación de las 3 zonas principales en una extrusora y la evolución de la presión a lo largo del proceso, utilizando el husillo como referencia. La imagen original ha sido extraída de [Beltrán and Marcilla, 2012] (página 106).

#### ■ Zona de alimentación

Esta zona comienza una vez que el plástico ha sido introducido en la tolva, y termina cuando una parte del material comienza a fundirse (dicho de manera más

precisa, cuando empieza a formarse una capa de material fundido en la superficie cilindro). Por tanto, podemos considerar que, en esta zona, el estado del material será principalmente sólido.

Al entrar por la tolva, el transporte del material estará basado en un flujo por gravedad, pero una vez llegado al cilindro, comenzará un flujo inducido por arrastre. En este segundo flujo, el material sufrirá dos fuerzas de fricción principales: una en la superficie del cilindro y otra en la superficie del husillo. A pesar de que no resulta intuitivo, de estas dos fuerzas, la que producirá un avance del material hacia la salida será la fricción con el cilindro, mientras que la fricción con el husillo provocará una fuerza retardante <sup>1</sup>.

Por tanto, en la zona de alimentación, los factores principales que intervienen en el desplazamiento serán:

- La densidad del material (teniendo en cuenta también el aire entre las partículas).
- El factor de compresión del material.
- Los coeficientes de fricción que afectan al material: la fricción con el cilindro, la fricción con el husillo y la fricción entre partículas.

#### ■ Zona de transición


Esta zona comenzará cuando se empiece a formar una fina capa de material fundido en la superficie del cilindro, y terminará cuando el material esté completamente fundido. La distancia entre la zona en la que comienza el proceso de fusión y la zona en la que termina se conoce como *longitud de fusión* (véase la Figura A.6).

Al comienzo de la zona de transición, la capa de material formada en la superficie del cilindro será fina, y aumentará su grosor según vayamos avanzando en el cilindro, hasta el punto de cubrir totalmente la distancia radial entre el cilindro y el husillo ( $\delta$ , véase la Figura A.5). Los fragmentos sólidos, sin embargo, se acumularán en el husillo, formando una capa sólida (también denominado *lecho sólido*), acompañada de un pozo de material fundido, tal y como se muestra en la Figura A.5.

En esta situación, el pozo de material fundido será cada vez más ancho, ejerciendo una mayor presión a la capa sólida. Debido a ello, la anchura del lecho sólido


---

<sup>1</sup> La explicación de este fenómeno puede entenderse de manera intuitiva llevándolo al extremo: si la fricción del plástico respecto al cilindro fuera nula, y alta respecto al husillo, el material se mantendría girando constantemente con el husillo, sin avanzar hacia delante.



**Figura A.5:** Características principales del modelo de desplazamiento durante la zona de transición. La imagen original ha sido extraída de [Beltrán and Marcilla, 2012] (página 123).

irá reduciéndose, llegando a derretirse por completo, como se muestra en la Figura A.6. Como resultado de tales fenómenos, aparecerán factores que influyan de manera significativa en la temperatura (además del calor generado por el sistema de calefacción), por ejemplo, el aumento de la presión en las diferentes zonas.



**Figura A.6:** Representación gráfica de la *longitud de fundido* en la zona de transición. La imagen original ha sido extraída de [Beltrán and Marcilla, 2012] (página 124).

Como podemos ver, modelar de manera precisa el desplazamiento del material en esta zona es complejo ya que forman parte un gran número de características dinámicas.

#### ■ Zona de dosificado


Esta última zona comenzará cuando el material esté completamente fundido, es decir, al completarse por completo la fusión. En este caso, los factores principales que influyen en el desplazamiento del material serán solamente las características físicas del husillo y su velocidad de giro. Sin embargo, hay que tener en cuenta que

el material estará en estado líquido, por lo que la mecánica del desplazamiento será compleja.

De manera simplificada, podemos asumir que existen tres flujos principales en cuanto al desplazamiento del material:

- Flujo de fricción o arrastre, como consecuencia de la fricción con el husillo y el cilindro.
- Flujo de retroceso, como consecuencia de la diferencia de presión entre la zona inicial de la extrusora y el cabezal.
- Flujo de fugas, que ocurrirá entre el cilindro y los filetes del husillo como consecuencia de los gradientes de presión a lo largo del husillo.

Mientras que el primer flujo es el responsable del avance del material en dirección al cabezal, los otros dos causarán un flujo contrario. La Figura A.7 muestra gráficamente los perfiles de velocidad de estos flujos.



**Figura A.7:** Representación gráfica de los perfiles de velocidad de los flujos principales presentes en la zona de dosificación. La imagen original ha sido extraída de [Beltrán and Marcilla, 2012] (página 128).

Como el desplazamiento será el resultado de la suma de estos flujos, la dirección del material no será uniforme, y, por tanto, estimar el movimiento de cada trozo de material será nuevamente un proceso de alta complejidad.

Teniendo en cuenta el modelo de desplazamiento presentado en esta sección (el cual es frecuentemente utilizado en la práctica, y que contiene múltiples simplificaciones), es evidente que calcular de manera precisa el recorrido del material no es trivial, y, hoy en día, estos cálculos se realizan utilizando principalmente aproximaciones por medio de simuladores especializados. En este TFG, sin embargo, realizaremos los cálculos mediante un modelo muy simplificado, el que tendrá en cuenta únicamente las características principales de la extrusora (geometría de los elementos principales, velocidad de giro, etc.), no solo por la dificultad, sino también debido a que no disponemos de toda la información necesaria para realizar los cálculos en base al modelo presentado.



---

### Problemas de optimización y metaheurísticos

---

Esta sección tiene como objetivo presentar las nociones básicas de los métodos de optimización combinatoria conocidos como metaheurísticos, de modo que sirva como introducción a este tipo de recursos computacionales.

#### B.1. Conceptos básicos

Los metaheurísticos son algoritmos de búsqueda definidos de manera general para poder ser adaptados a diferentes problemas de optimización combinatoria, donde la finalidad es encontrar soluciones que minimicen<sup>1</sup> una función determinada, es decir,

$$s^* = \underset{s \in S}{\text{mín}} f(s),$$

siendo  $S$  el conjunto de soluciones posibles al problema (también conocido como espacio de soluciones),  $f(s)$  la función que queremos minimizar (la que se conoce como función objetivo) y  $s^*$  una solución óptima al problema. Para emplear el uso de metaheurísticos, es necesario formalizar matemáticamente el problema, mediante los siguientes pasos:

- Definir la codificación de las soluciones, las que, en nuestro caso, representarán configuraciones de la extrusora. Si, por simplicidad, únicamente consideramos co-

---

<sup>1</sup>En este documento vamos a asumir que el objetivo es minimizar la función objetivo. En caso de que se quiera maximizar una función objetivo  $f(s)$ , podemos generar simplemente una función  $f'(s) = -f(s)$  para mantener la notación.

mo configuración las temperaturas de las diferentes zonas, podemos definir la solución como  $s = (T_1, \dots, T_N)$ , donde  $T_i \in \mathbb{R}$  corresponde a la temperatura en la Zona  $i$ .

Hay que tener en cuenta que no todas las posibles soluciones son viables, ya que, por características físicas o mecánicas, las configuraciones de las máquinas pueden estar sujetas a restricciones, como por ejemplo, que la diferencia de temperatura entre dos zonas consecutivas sea menor a un umbral determinado. Por este motivo, es necesario también definir qué soluciones son viables, lo que deberá realizarse en base al conocimiento de los expertos.

- Definir una o más funciones objetivo, las cuales determinarán la calidad de una solución. En nuestro caso, estas funciones podrían evaluar, por ejemplo, el coste energético que supone una configuración, o la producción de botellas por hora esperada.

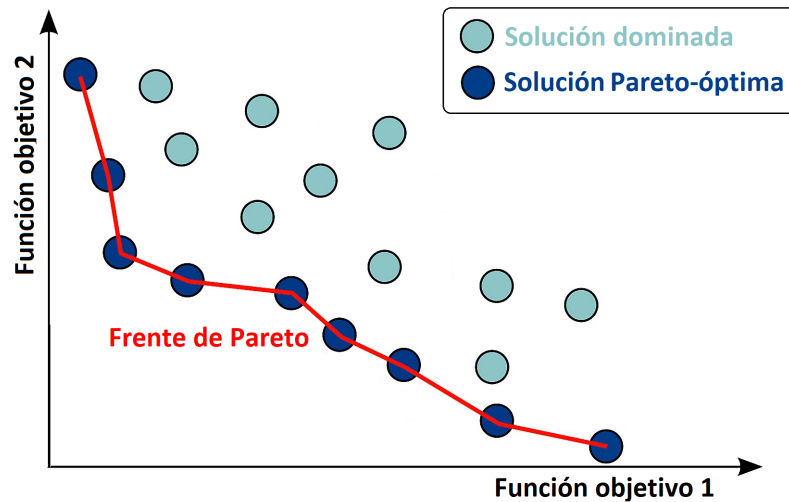
Una vez modelados estos componentes, la búsqueda puede realizarse en base a diferentes estrategias, cuyo objetivo es guiar la búsqueda de manera inteligente, procurando mejorar iterativamente la calidad de las soluciones. Hoy en día existen múltiples estrategias diferentes, entre otros, la búsqueda tabú [Glover et al., 1989], los algoritmos genéticos [Mitchell, 1996] o los *Estimation of Distribution Algorithms* [Larrañaga and Lozano, 2002].

## B.2. Problemas de optimización multiobjetivo

En la sección anterior hemos considerado únicamente una función objetivo en los problemas de optimización. Sin embargo, en los problemas reales suele ser necesario considerar más de un objetivo, por lo que surge la necesidad de minimizar múltiples funciones. En nuestro caso, estas funciones podrían representar, entre otros, el coste energético de los elementos mecánicos, la tasa de producción o la cantidad de materia prima desechada.

Sin embargo, la resolución de problemas de optimización con múltiples funciones objetivo es una tarea compleja, ya que requiere guiar la búsqueda teniendo en cuenta cada una de dichas funciones. Además, en estos casos no es trivial decidir qué solución es mejor que otra, ya que, dependiendo de la función objetivo con la que la evaluemos, la calidad de una solución puede variar. Para comprender mejor las características de este tipos de problemas, presentaremos brevemente los conceptos básicos:





**Figura B.1:** Representación gráfica de un conjunto de soluciones para un problema de optimización de dos funciones objetivo.

- Dominancia de Pareto

Siendo  $s_1$  y  $s_2$  dos soluciones a un problema de optimización multiobjetivo, se dice que  $s_1$  domina a  $s_2$  solución si y solo si para cualquier función objetivo se cumple que  $f_i(s_1) \leq f_i(s_2)$ , y, para al menos una, se cumple que  $f_i(s_1) < f_i(s_2)$ , por lo que, en este caso, podemos determinar que  $s_1$  es mejor solución que  $s_2$ .

- Optimalidad de Pareto

Siendo  $s_1$  una solución a un problema de optimización multiobjetivo, se dice que  $s$  es *Pareto-óptima* si y solo si no existe una solución  $s_2$  que domine a  $s_1$ .

- Frente de Pareto

Denominamos frente de Pareto al conjunto de soluciones que son Pareto-óptimas. Como cada una de estas soluciones minimiza en mayor medida que el resto alguna de las funciones objetivo, no podemos determinar cuál es mejor que otra. Por este motivo, el frente de Pareto suele ser de gran interés en este tipo de problemas, ya que permite considerar múltiples alternativas de distintas características.

En la Figura B.1 se presentan estos conceptos de manera gráfica, donde se muestran diferentes soluciones para un problema de dos funciones objetivo, (como podrían ser el coste energético y la tasa de producción que supondría una configuración de la extrusora).

Nuevamente, existen diferentes metaheurísticos adaptados a la resolución de estos problemas, como por ejemplo, el método *MOEA/D* [Zhang and Li, 2007]. Por tanto, con-

sideramos que, de cara a nuestro proyecto, puede ser interesante utilizar estas nociones para modelar los procesos de optimización, en base a las características, restricciones u objetivos que los expertos consideren adecuados.

### Implementación

---

Para el desarrollo del proyecto ha sido utilizado principalmente el lenguaje de programación *R*, por contener múltiples funcionalidades y paquetes enfocados a la estadística y a la minería de datos. De entre todos los paquetes utilizados, destacamos los siguientes:

- El paquete *ImputeTS* [Moritz, 2018], el que contiene múltiples técnicas de imputación de valores perdidos.
- Los paquetes *bnlearn* [Scutari, 2018] y *gRain* [Højsgaard, 2016], ya que son los utilizados para la generación de redes Bayesianas, y los que proporcionan múltiples métodos de aprendizaje, inferencia y muestreo.
- El paquete *neuralnet* [Fritsch et al., 2016], utilizado para la implementación de las redes neuronales artificiales.

Por otro lado, las técnicas de preprocesado han sido integradas en un servicio web en colaboración con el grupo de investigación BDI<sup>1</sup>, el cual es utilizado en una plataforma web (desarrollada también por el mismo grupo) destinada a proporcionar funcionalidades como la recomendación de técnicas de reducción o servicios de limpieza de datos.

---

<sup>1</sup><http://bdi.si.ehu.es/bdi/>



---

## Bibliografía

---

- [Beltrán and Marcilla, 2012] Beltrán, M. and Marcilla, A. (2012). *Tecnología de Polímeros*. Universidad de Alicante.
- [Castillo et al., 1998] Castillo, E., Gutierrez, J. M., and Hadi, A. S. (1998). *Sistemas Expertos y Modelos de Redes Probabilísticas*. Academia Española de Ingeniería.
- [Cybenko, 1989] Cybenko, G. (1989). *Approximation by Superpositions of a Sigmoidal Function*. Mathematics of Control, Signals and Systems. Springer-Verlag.
- [Durbin and Koopman, 2012] Durbin, J. and Koopman, S. J. (2012). *Time Series Analysis by State Space Methods*. Oxford Statistical Science Series. OUP Oxford.
- [Esnaola-Gonzalez et al., 2016] Esnaola-Gonzalez, I., Bermúdez, J., Fernandez, I., and Arnaiz, A. (2016). *Semantic Prediction Assistant Approach applied to Energy Efficiency in Tertiary Buildings*.
- [Fausett, 1993] Fausett, L. V. (1993). *Fundamentals of Neural Networks: Architectures, Algorithms And Applications*. Pearson.
- [Fawcett, 2006] Fawcett, T. (2006). *An introduction to ROC analysis*. Elsevier.
- [Fritsch et al., 2016] Fritsch, S., Guenther, F., Suling, M., and Mueller, S. M. (2016). *neuralnet*. R package, Version 1.3-0.  
<https://cran.r-project.org/web/packages/neuralnet/neuralnet.pdf>.
- [Glover et al., 1989] Glover, F., Laguna, M., and Martí, R. (1989). *Tabu Search*. ORSA Journal on Computing, Vol. 1, No. 3.
- [Gupta et al., 2001] Gupta, A., Mehrotra, K., and Mohan, C. K. (2001). *A Clustering based Discretization for Supervised Learning*. Springer.

- [Højsgaard, 2016] Højsgaard, S. (2016). *bnlearn*. R package, Version 1.3-0.  
<https://cran.r-project.org/web/packages/gRain/gRain.pdf>.
- [Hornik, 1991] Hornik, K. (1991). *Approximation Capabilities of Multilayer Feedforward Networks*. Pergamon Press.
- [Hoskins and Himmelblau, 1992] Hoskins, J. C. and Himmelblau, D. M. (1992). *Process control via artificial neural networks and reinforcement learning*. Elsevier.
- [Jalalinejad et al., 2007] Jalalinejad, F., Jalali-Farahania, F., Mostoufi, N., and Sotudeh-Gharebagh, R. (2007). *Ant Colony Optimization: A Leading Algorithm in Future Optimization of Chemical Processes*. 17th European Symposium on Computed Aided Process Engineering, Volume 24. Elsevier.
- [Kagermann et al., 2013] Kagermann, H., Wahlster, W., and Helbig, J. (2013). *Recommendations for implementing the strategic initiative Industrie 4.0: Final report of the Industrie 4.0 Working Group, 2013*. Acatech (German Academy of Science and Engineering).
- [Larrañaga and Lozano, 2002] Larrañaga, P. and Lozano, J. A. (2002). *Estimation of Distribution Algorithms: a New Tool for Evolutionary Computation*. Springer.
- [Maybeck, 2012] Maybeck, P. (2012). *Stochastic models, estimation and control, Volume 1*. Academic Press.
- [Minsky, 1961] Minsky, M. (1961). *Steps toward artificial intelligence*. Proceedings of the Institute of Radio Engineers.
- [Mitchell, 1996] Mitchell, M. (1996). *An Introduction to Genetic Algorithms*. MIT Press.
- [Moritz, 2018] Moritz, S. (2018). *ImputeTS*. R package, Version 2.6.  
<https://cran.r-project.org/web/packages/imputeTS/imputeTS.pdf>.
- [Niu et al., 2011] Niu, Z., Shi, S., Sun, J., and He, X. (2011). *A Survey of Outlier Detection Methodologies and Their Applications*. Springer.
- [Otero, 1998] Otero, F. (1998). *Use of Neural Networks in Process Engineering. Thermodynamics, diffusion, and process control and simulation applications*. Instituto Colombiano del Petróleo (ICP).
- [Piché et al., 1999] Piché, S., Keeler, J., Martin, G., Boe, G., Johnson, D., and Gerules, M. (1999). *Neural Network Based Model Predictive Control*. MIT Press Cambridge.

- [Powers, 2011] Powers, D. M. W. (2011). *Evaluation: From Precision, Recall and F-measure to Roc, Informedness, Markedness and Correlation*.
- [Pérez et al., 2009] Pérez, A., Larrañaga, P., and Inza, I. (2009). *Bayesian classifiers based on kernel density estimation: Flexible classifiers*. Elsevier.
- [Qin and Badgwell, 1997] Qin, S. J. and Badgwell, T. A. (1997). *An overview of industrial model predictive control technology*. Chemical Process Control - AIChE Symposium Series.
- [Riedmiller and Braun, 1993] Riedmiller, M. and Braun, H. (1993). *A direct adaptive method for faster backpropagation learning: The RPROP algorithm*. Springer.
- [Rojas, 1996] Rojas, R. (1996). *Neural Networks: A Systematic Introduction*. Springer.
- [Rosenblatt, 1957] Rosenblatt, F. (1957). *The perceptron: a perceiving and recognizing automaton*. Cornell Aeronautical Laboratory, Inc.
- [Russell and Norvig, 1995] Russell, S. and Norvig, P. (1995). *Artificial Intelligence: A Modern Approach*. Prentice Hall.
- [Scutari, 2018] Scutari, M. (2018). *bnlearn*. R package, Version 4.3.  
<https://cran.r-project.org/web/packages/bnlearn/bnlearn.pdf>.
- [Shearer, 2000] Shearer, C. (2000). *The CRISP-DM Model: The New Blueprint for Data Mining*. Journal of Data Warehousing, Volume 5, Number 4.
- [Tuzlukov, 2010] Tuzlukov, V. (2010). *Signal Processing Noise*. CRC Press.
- [Valadi and Siarry, 2014] Valadi, J. and Siarry, P. (2014). *Applications of Metaheuristics in Process Engineering*. Springer.
- [Welch and Bishop, 2001] Welch, G. and Bishop, G. (2001). *An Introduction to the Kalman Filter*. SIGGRAPH, Course 8.
- [Yang and Webb, 2001] Yang, Y. and Webb, G. I. (2001). *Proportional k-Interval Discretization for Naive-Bayes Classifiers*. Springer.
- [Yule, 1919] Yule, G. U. (1919). *An introduction to the theory of statistics*. Charles Griffin and Company, Limited.

- [Zhang and Li, 2007] Zhang, Q. and Li, H. (2007). *MOEA/D: A Multiobjective Evolutionary Algorithm Based on Decomposition*. IEEE Transactions on Evolutionary Computation, Volume 11.
- [Zhu and Wu, 2004] Zhu, X. and Wu, X. (2004). *Class Noise vs. Attribute Noise: A Quantitative Study*. Kluwer Academic Publishers.