



UNIVERSIDAD DE CANTABRIA
ESCUELA POLITÉCNICA DE INGENIERÍA MINAS
Y ENERGIA



TRABAJO FIN DE MÁSTER

OPTIMIZACIÓN DEL COMPORTAMIENTO FRENTE A FATIGA DEL ACERO PARA MUELLES MEDIANTE EL USO DE ALGORITMOS MACHINE LEARNING

Para acceder al título de:

Máster Universitario en Ingeniería de Minas

Autor: Isaac Rivas Pelayo

Director: Diego Ferreño Blanco

Carlos Thomas García

Ana Isabel Cimentada

Convocatoria: Septiembre 2021



Capítulo 1	INTRODUCCIÓN Y OBJETIVOS.....	1
1.1	Introducción.....	1
1.1.1	La fabricación de acero en GSW	2
1.1.2	¿Qué es el <i>Machine Learning</i> ?	2
Capítulo 2	ESTADO DEL ARTE	5
2.1	Introducción.....	5
2.2	El proceso de fabricación en Global Steel Wire	5
2.2.1	Horno eléctrico	5
2.2.2	Horno cuchara	16
2.2.3	Colada continua	23
2.2.4	Laminación en caliente	29
2.3	Caracterización de la resistencia frente a fatiga mediante curvas S-N	31
2.4	Un recorrido por el <i>Machine Learning</i>.....	34
2.4.1	Inteligencia artificial, Machine Learning, Deep Learning	34

Optimización del comportamiento frente a fatiga del acero para muelles mediante el uso de algoritmos *Machine Learning*

2.4.2	<i>Machine Learning</i> : otra forma de ver la programación de computadores	36
2.4.3	Aprendizaje supervisado y no supervisado.....	36
2.4.4	<i>Overfitting</i> y <i>underfitting</i>	39
2.4.5	Aprendizaje supervisado: principales algoritmos	40
2.4.5.1	Regresión lineal	40
2.4.5.2	Regresión logística	42
2.4.5.3	<i>k-Nearest Neighbors</i>	44
2.4.5.4	<i>Support Vector Machines</i>	45
2.4.5.5	Árboles de decisión	46
2.4.5.6	Métodos ensemble	48
2.4.5.7	Redes Neuronales Artificiales	49
2.4.6	Entrenamiento de un algoritmo de aprendizaje supervisado: <i>train, validation, test</i>	51
Capítulo 3 PROBLEMÁTICAS, MATERIALES Y MÉTODOS		53
3.1	Introducción.....	53
3.2	Problemática del acero de muelles.....	53
3.3	Materiales y métodos.....	56
3.3.1	Materiales y métodos del estudio sobre el acero de muelles: caracterización del comportamiento frente a fatiga.....	56
3.4	Algoritmos <i>Machine Learning</i>	60
3.4.1.1	Limpieza y preparación de los datos.....	60



Isaac Rivas Pelayo

3.4.1.2	Separación en conjuntos de <i>train</i> y de <i>test</i>	61
3.4.1.3	Preprocesado.....	61
3.4.1.4	Selección de métricas	62
3.4.1.5	Identificación de predictores según su importancia.....	64
3.4.1.6	<i>Partial Dependence Plots</i>	65
Capítulo 4 RESULTADOS Y DISCUSIÓN.....		66
4.1	Introducción.....	66
4.2	Modelado de la resistencia frente a fatiga.....	66
4.2.1	Resultados experimentales de la caracterización a fatiga	66
4.2.2	Desarrollo de un modelo <i>Machine Learning</i> de regresión para predecir la vida en fatiga	67
4.2.2.1	Preprocesado de los datos	68
4.2.2.2	Optimización de los algoritmos	68
4.2.2.3	Selección de atributos más relevantes	70
4.2.2.4	Influencia de los atributos relevantes sobre la vida a fatiga.....	70
4.3	Interpretación de los resultados en términos mecánicos y metalúrgicos.....	71
4.3.1.1	Distribución radial de la microdureza.....	75
4.3.1.2	Estudio de la rugosidad superficial	75
4.3.1.3	Análisis fractográfico.....	76
4.4	Discusión y conclusiones	77



Optimización del comportamiento frente a fatiga del acero para muelles mediante
el uso de algoritmos *Machine Learning*

Capítulo 5 CONCLUSIONES	78
BIBLIOGRAFÍA	80



Capítulo 1 INTRODUCCIÓN Y OBJETIVOS

1.1 Introducción

Los avances en la metalurgia han venido acompañados históricamente de progreso en las sociedades. Tan es así que se han designado diferentes periodos de la historia de las civilizaciones en función de su dominio de la metalurgia, distinguiéndose por ejemplo dentro de la prehistoria entre, la edad de piedra, la edad de bronce y la edad de hierro.

La metalurgia del hierro comenzó en Europa alrededor del siglo XI a. C procedente de Asia[1]. En un primer momento los utensilios fabricados en hierro no eran de gran calidad debido en gran parte, al elevado punto de fusión que presenta este elemento, en torno a 1.538 °C y las impurezas con motivo de la complejidad que supone extraer hierro puro de los distintos minerales existentes en la naturaleza.

Debido a su versatilidad y abundancia, el uso de hierro creció de forma incesante hasta nuestros días, dando lugar a una rama de la metalurgia que se centra únicamente en el aprovechamiento y tratamiento del hierro, la siderurgia.

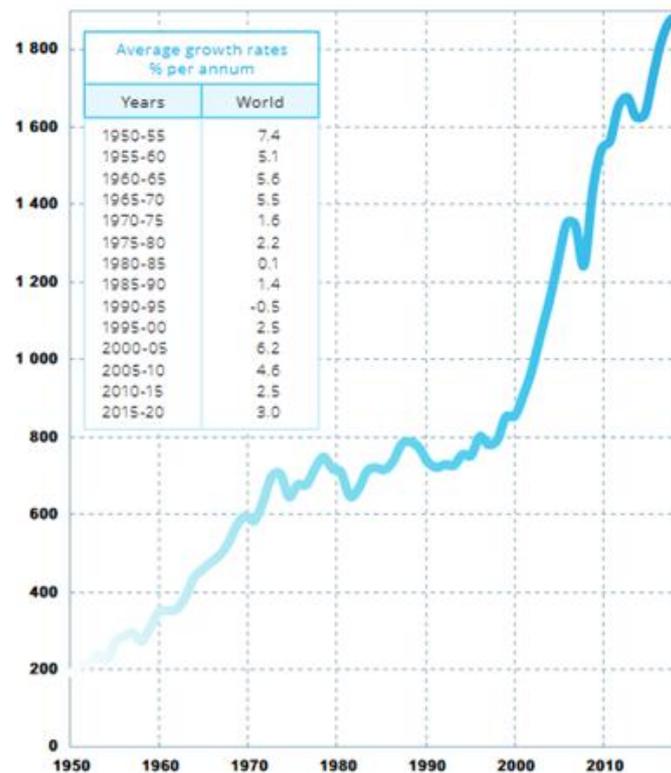


Figura 1.1 Evolución de la producción de toneladas de acero crudo a nivel mundial (en millones de toneladas)[2].

En la actualidad, la complejidad del proceso productivo unida a la fuerte competencia existente a nivel global por la demanda de un producto de gran calidad, hacen necesaria la inversión en nuevas tecnologías y la implementación de una continua mejora de los procesos productivos.

Resulta interesante la idea de aplicar la metodología *machine learning* al proceso productivo del acero debido a la gran cantidad de variables implicadas en la producción de éste y el bajo coste de implementación que supone, pudiendo conseguir por tanto grandes resultados a un coste muy interesante.

1.1.1 La fabricación de acero en GSW

Global Steel Wire (GSW) es una empresa integrada dentro del grupo siderúrgico Celsa que se encarga de fabricar palanquilla y aceros especiales destinados al sector de la automoción.

La fabricación de la palanquilla en GSW consta de tres procesos principales[3]:

1. Etapa de fusión: el acero se produce utilizando como materia principal la chatarra mediante un horno de arco eléctrico, un sistema formado por un recipiente, en el cual se introduce chatarra junto con elementos secundarios que tienen la finalidad de que el acero presente una calidad óptima. Entre estos componentes secundarios los más frecuentes son la cal, el coque, el espatoflúor, mineral de hierro, etc. La fusión del contenido del recipiente se produce debido a la acción de unos electrodos que al excitarse provocan la creación de un arco eléctrico capaz de fundir el contenido.
2. Etapa de afino: se realiza una adición de materiales al fundido con la finalidad de mejorar la composición química del mismo, realizar una desoxidación y una eliminación del azufre.
3. Colada continua: en esta etapa se forma la palanquilla, lingotes de acero de sección cuadrada de 180 x 180 mm de sección y una longitud de entre 10 y 13 m que se forman por el enfriamiento del acero a lo largo de la colada continua.

A través de la laminación en caliente de la palanquilla se consigue el producto final, el alambión. Al comienzo del tren de laminación, la palanquilla que presenta una sección cuadrada de 180 mm se calienta mediante un horno de largueros con calentamiento superior e inferior. Esta palanquilla se hace pasar por diversas líneas en función del producto final requerido, pudiendo conseguir un diámetro final que varía entre los 5,5 y los 52 mm.

Este alambión se almacena en rollos y se distribuye a los distintos clientes para fabricar una gran variedad de productos que van desde alambres, cables, tornillos o muelles.

Este TFM se va a centrar en el estudio de uno de los productos finales de este alambión, los muelles de suspensión utilizados en el sector de la automoción.

1.1.2 ¿Qué es el *Machine Learning*?

El *Machine Learning*, ML, que se podría traducir como el aprendizaje automático o aprendizaje de máquinas, es un campo que mezcla la estadística y la informática de forma



que se consiguen algoritmos capaces de analizar bases de datos de gran tamaño y extraer información de ellas.

El *machine learning* ha tenido un gran impacto en nuestra sociedad en las últimas décadas, esto se debe a que los datos generados han sufrido un gran aumento y se necesitan nuevas formas de afrontar el análisis de estos.

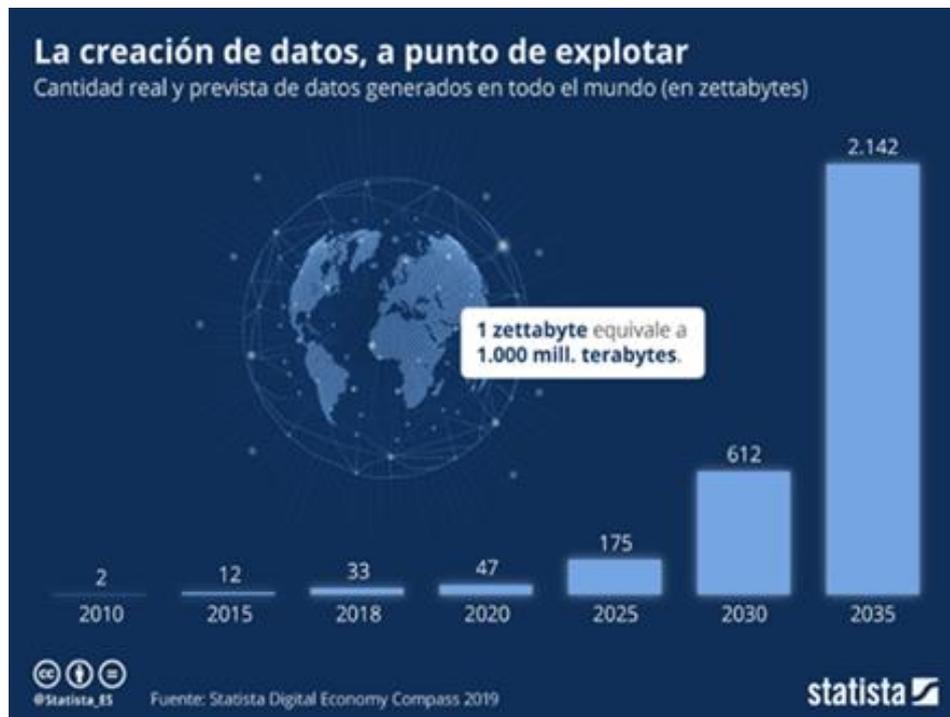


Figura 1.2 Evolución de la creación de datos[4]

Esto se explica con datos como los siguientes:

Datos obtenidos a nivel global por minutos[5].

- o En EE. UU. se usan 3.138.420 GB de datos en internet.
- o Se reproducen 97.222 horas de video en Netflix.
- o Se publican 49.380 fotos en Instagram.
- o Se producen 3.877.140 búsquedas en Google.
- o Amazon envía 1.111 paquetes y vende \$332.876.

Estos datos nos pueden dar una idea de la magnitud de información que se genera en el mundo y el porqué de la necesidad de la rápida implantación de técnicas de *machine learning*.

En la actualidad son muchos los ejemplos de usos reales en nuestra vida cotidiana de esta tecnología, algunos ejemplos pueden ser los siguientes[6]:

Optimización del comportamiento frente a fatiga del acero para muelles mediante el uso de algoritmos *Machine Learning*

- o Reconocimiento de imágenes: un ejemplo de ello es la tecnología de sugerencias al etiquetar personas en las imágenes de Facebook.
- o Reconocimiento de voz: en este campo existen desde programas capaces de convertir la voz en texto y viceversa hasta asistentes virtuales, como pueden ser Siri o Alexa, que nos permiten realizar distintas tareas exclusivamente con la voz.
- o Predicción del tráfico: Google Maps nos permite obtener la mejor ruta, evitando atascos, accidentes y otras incidencias gracias a que recopila y procesa datos sus usuarios en tiempo real.
- o Recomendaciones de compras: muchas empresas utilizan la información que aportan sus usuarios para poder realizar recomendaciones de productos y servicios en función de preferencias. Es el caso por ejemplo de las sugerencias de Netflix.
- o Mejoras en el correo electrónico: Gmail realiza un filtrado de todos los correos recibidos para identificar aquellos que puedan ser spam o potencialmente peligrosos.
- o Vehículos autónomos: algunas compañías de vehículos, como por ejemplo Tesla, están incorporando tecnologías de aprendizaje automático para que a través de cámaras y sensores incorporados en el coche puedan captar información del entorno y funcionar de forma autónoma.



2.1 Introducción

Debido al carácter multidisciplinar que presenta este documento, que se encuentra a medio camino entre la ciencia de datos y la ciencia de materiales, a continuación, se procede a realizar una breve introducción en los distintos ámbitos de conocimiento necesarios para la comprensión del estudio.

Se expondrán para comenzar conocimientos propios de la siderurgia, y más concretamente del proceso productivo del acero en la fábrica de GSW y de las principales etapas que este conlleva.

A continuación, se expondrá brevemente uno de los conceptos de ciencia de los materiales más relevantes y necesarios para la comprensión de este estudio, la caracterización de la resistencia frente a fatiga mediante curvas S-N.

Por último, se llevará a cabo una pequeña inmersión en el mundo de la ciencia de datos, centrándose en los principales algoritmos existentes dentro del campo del *machine learning*.

2.2 El proceso de fabricación en Global Steel Wire

A continuación, se procede a describir con mayor detalle las etapas para la fabricación de acero seguidas en GSW. El proceso comienza en la acería, con la obtención del acero fundido y se realiza en tres fases principales: horno eléctrico, horno cuchara y colada continua. Para terminar, se lleva a cabo un proceso de laminación en caliente, transformando la palanquilla cuadrada de 180 x180 mm de sección en alambón de distintos diámetros.

2.2.1 Horno eléctrico

Los primeros hornos eléctricos nacieron en 1907, de la mano de Paul Héroult, estableciéndose la primera planta comercial en EE. UU. Su utilización comenzó a expandirse tras la Segunda guerra mundial debido al bajo coste en relación con la capacidad de producción que presenta[7].

En la actualidad, la mayor parte del acero es producido utilizando hornos de arco eléctrico. Esto se debe a que presenta diferentes ventajas frente a su alternativa, el alto horno. Las ventajas más destacables son:

- Menor coste para su implementación.
- El coste de mantenimiento es menor que el de un alto horno
- Usa como materia prima la chatarra, lo cual le hace más sostenible para el medio ambiente.
- Presenta una mayor capacidad de producción.

La finalidad del horno de arco eléctrico se puede entender desde dos perspectivas: la operativa y la metalúrgica. Desde la perspectiva operativa, el proceso debe ser lo más

eficiente posible, fundiendo la carga lo más rápidamente posible y con el menor coste. Desde la perspectiva metalúrgica, se trata de conseguir un acero con la mayor calidad posible, para ello se debe hacer énfasis en:

- Controlar el contenido en elementos indeseables (S, Cu, P, Ni, Cr...) dentro del fundido pues que resultan muy difíciles de eliminar en etapas posteriores. Para esto es vital llevar a cabo una correcta clasificación de la chatarra, mezclando diferentes tipos de chatarra en función del acero que se desee obtener.
- Eliminar el fósforo del fundido. Esto se realiza añadiendo cal y manteniendo condiciones oxidantes durante el proceso.
- Controlar la temperatura y el aporte de oxígeno durante el proceso.

El horno de arco eléctrico existente en GSW tiene una capacidad de 150 Tm y posee tres electrodos cilíndricos de grafito. Su funcionamiento se basa en la formación de un arco entre los electrodos y la masa de chatarra, que se calienta principalmente por dos mecanismos; el paso de la corriente a través de la chatarra y la propia radiación generada por el arco. Del horno, el cual se puede observar un esquema en la Figura 2.1, Se pueden destacar las siguientes partes: los electrodos, la cuba, la solera y la bóveda.

- Los electrodos son cilindros de grafito, debido a su gran conductividad eléctrica y sus propiedades refractarias. Su tamaño es variable en función de la capacidad del horno. Se trata de elementos costosos y que necesitan ser reemplazados cada cierto tiempo, lo que supone una desventaja debido al elevado coste de los mismo y a la pérdida de producción durante las paradas. Como se puede ver en la Figura 2.1, los electrodos están sujetos mediante unas sujeciones a unos brazos que son los encargados de introducirlos y extraerlos por los orificios existentes en la bóveda.
- La cuba, es una estructura cilíndrica revestida de ladrillo refractario y refrigerada por agua. Presenta una serie de aberturas utilizadas para introducir la lanza toma muestras, realizar el análisis de oxígeno y la medición de temperaturas. Su tamaño varía en función de la capacidad del horno.
- La solera es la parte que está en contacto con el metal fundido, se encuentra en la parte inferior del horno. Está recubierta por un revestimiento de ladrillos refractarios generalmente de magnesita. Presenta una abertura conocida como EBT, utilizada para verter el acero líquido sobre la cuchara. Para ello, el horno se apoya sobre un balancín hidráulico que lo inclina, con una inclinación que no debe exceder los 15°, y lo vierte sobre la cuchara.
- La bóveda se encuentra situada en la parte superior y está conformada por paneles refrigerados por agua y un revestimiento refractario. Presenta cinco orificios, tres de ellos se utilizan para introducir los electrodos, otro es usado para la eliminación de gases y el quinto para la adición de los escorificantes (carbonato cálcico y óxido magnésico). El techo y los electrodos se pueden elevar y retirar para cargar chatarra y para las operaciones de mantenimiento.

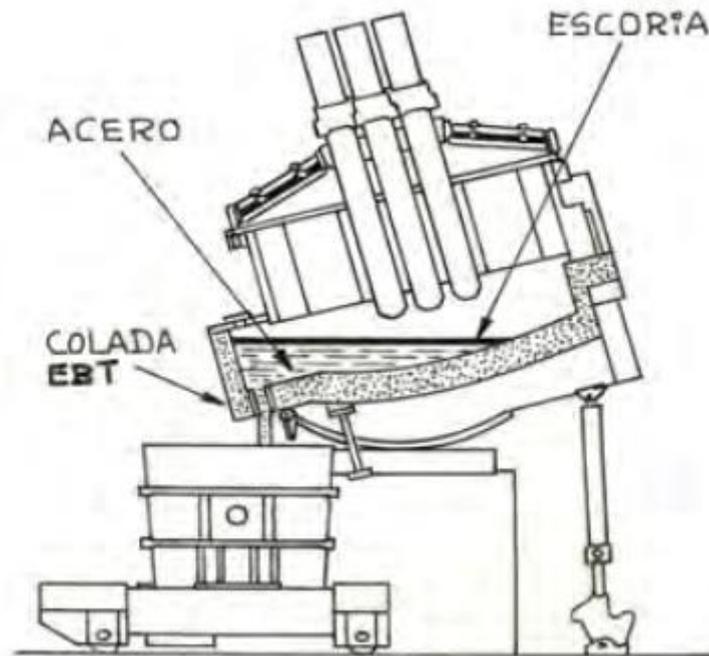


Figura 2.1 Ilustración que muestra la representación del horno de arco eléctrico, observándose en cómo se sitúan los electrodos[8].

La secuencia de funcionamiento del horno de arco eléctrico se puede dividir en cuatro etapas principales: carga, precalentamiento, fusión y vaciado.

El proceso se inicia cargando el material a través una cesta previamente seleccionada en el parque de chatarra. Esta cesta está formada por materiales previamente seleccionados en el parque de chatarra, de forma que se consiga una mezcla de materiales en el horno óptima, consiguiendo la calidad deseada al menor coste posible. En el parque de chatarra se distinguen dos tipos de carga, la chatarra, procedente del reciclado de materiales férricos, y los sustitutivos, obtenidos a partir del mineral de hierro. La chatarra, a su vez, está clasificada en diferentes grupos:

- En función de su procedencia, existe la chatarra de recuperación, referida a la chatarra generada durante el proceso siderúrgico (despunte de palanquilla, rechazos, fondos de cuchara, etc.), chatarra nueva, con la que se designa a aquella que se genera en procesos industriales de transformación, como la forja, la estampación, la mecanización, etc., y chatarra vieja, que es aquella que procede de la recuperación de productos de acero no utilizables (barcos, automóviles, maquinaria, etc.).
- En función de su composición, se distingue la chatarra de bajo nivel residuo frente a la de alto nivel de residuo.
- En función sus propiedades físicas, como forma, tamaño y densidad.

En la Figura 2.2 se observa una muestra de algunos de los tipos de chatarra empleados en GSW.

Entre los sustitutos de la chatarra el más frecuente es el arrabio, procedente del horno alto y caracterizado por tener muy bajo contenido de elementos residuales y un alto contenido en C. También se utilizan los llamados prerreducidos, procedentes de la reducción del mineral de hierro mediante procedimientos en los cuales no se llega a la fusión del metal ni a la reducción completa del mineral. La composición química de los prerreducidos depende del mineral de partida.

La Figura 2.3 muestra diferentes tipos de arrabio mientras que en la Figura 2.4 se ofrecen dos ejemplos de prerreducidos.



(a)



(b)



(c)



(d)

Figura 2.2 Cuatro ejemplos de chatarra empleados para la carga del horno de arco eléctrico de GSW. (a) Paquete 4A, (b) sobrantes de estampación, (c) despuntes y (d) embutición.



(a)



(b)



(c)



(d)

Figura 2.3 Cuatro ejemplos de arrabio empleado en GSW. (a) Pig iron, (b) granulated pig iron, (c) flat iron y (d) lingote de pig iron.



(a)



(b)

Figura 2.4 Dos ejemplos de prerreducidos empleados en GSW: (a) DRI, (b) GPI.

En GSW se utiliza un programa para seleccionar la composición de la carga en función de la calidad buscada. Este programa utiliza como variables los siguientes datos:

- El contenido de elementos residuales en la chatarra.
- El contenido de N, P y S en la chatarra.
- El precio de compra.
- Las mermas (rendimiento).
- El consumo de energía y electrodos.
- El consumo de cal y dolomía calcinada.
- El tamaño y la densidad, por su influencia sobre la productividad y el consumo eléctrico.

Cuando ya se ha seleccionado la chatarra que se va a utilizar para la colada, se carga en una cesta que se mueve mediante un puente grúa y se vierte el contenido mediante la abertura de la bóveda en el interior del horno. Esta operación se puede apreciar en la Figura 2.5.



Figura 2.5 *Proceso de carga mediante el vertido de la cesta de chatarra en el interior del horno*[9].

La operación de carga de chatarra a través de la cesta se realiza hasta en tres ocasiones hasta completar la capacidad del horno. Esta operación se realiza una vez se completa la fusión de la primera cesta de chatarra, abriéndose el techo y agregándose una nueva cesta de chatarra al horno.

Durante todo el proceso un programa informático ajusta en cada momento la tensión y la intensidad del horno debido a que el comportamiento de la carga a lo largo del proceso va variando. A lo largo del proceso de fusión de la chatarra se distinguen tres fases etapas:

- Al inicio del proceso, el horno estará lleno de una masa de material frío, por lo que se inicia buscando calentar esa masa e ir fundiendo el material para poder introducir completamente los electrodos. Esta etapa inicial se realiza con una potencia baja y un arco corto, tratando así de no dañar las paredes del horno.



- Una vez ya se ha conseguido calentar la masa y se han introducido los electrodos en el fundido, las paredes se encuentran protegidas por la chatarra así que se aumenta la potencia y se forma un arco largo. De esta forma se aumenta la velocidad de fusión.
- Para terminar cuando a medida que se va consiguiendo que toda la masa se funda, las paredes vuelven a quedar desprotegidas y ya que no queda material sólido, por lo que se procede a disminuir la potencia

De esta forma se consigue una mayor eficiencia durante la fusión y evitando riesgos por sobretensiones, sobrecalentamientos, daños estructurales, etc.

En cuanto al aporte energético de las reacciones químicas, el horno cuenta con un sistema de inyección de oxígeno, que favorece las condiciones de oxidación necesarias en el baño de fusión para la posterior reacción de oxidación exotérmica. A continuación, se pueden ver algunas de estas reacciones junto con su aporte energético.

1.	$\text{Si} + \text{O}_2 \rightarrow \text{SiO}_2 + 9,4 \text{ kWh/kg}$	Según su aportación de energía
2.	$2 \text{ Al} + 3/2 \text{ O}_2 \rightarrow \text{Al}_2\text{O}_3 + 8,7 \text{ kWh/kg}$	
3.	$2 \text{ P} + 5/2 \text{ O}_2 \rightarrow \text{P}_2\text{O}_5 + 7 \text{ kWh/kg}$	
4.	$\text{CO} + 1/2 \text{ O}_2 \rightarrow \text{CO}_2 + 5,9 \text{ kWh/kg}$	
5.	$2 \text{ Cr} + 3/2 \text{ O}_2 \rightarrow \text{Cr}_2\text{O}_3 + 3 \text{ kWh/kg}$	
6.	$\text{C} + 1/2 \text{ O}_2 \rightarrow \text{CO} + 2,7 \text{ kWh/kg}$	
7.	$\text{Mn} + 1/2 \text{ O}_2 \rightarrow \text{MnO} + 2 \text{ kWh/kg}$	
8.	$2 \text{ Fe} + 3/2 \text{ O}_2 \rightarrow \text{Fe}_2\text{O}_3 + 2 \text{ kWh/kg}$	
9.	$\text{Fe} + 1/2 \text{ O}_2 \rightarrow \text{FeO} + 1,3 \text{ kWh/kg}$	

Al usar energía química se reduce el consumo de materiales refractarios y al mismo se tiempo facilita la fusión de la carga, aumentando así la productividad del proceso. Además, se reduce la necesidad de energía eléctrica produciendo una reducción en el consumo de electrodos y ahorros económicos considerables. Esto explica la Figura 2.6 donde se observa como desde los años 70 ha disminuido el consumo de electricidad y aumentado el suministro de oxígeno.

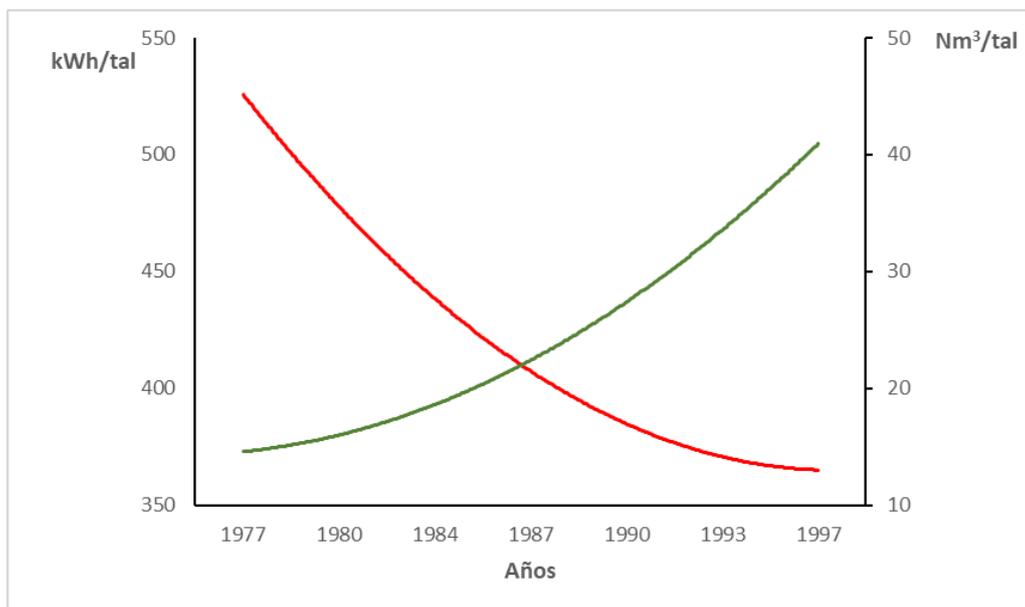


Figura 2.6 Desarrollo histórico del consumo de electricidad y oxígeno para la fusión de cargas en hornos de arco eléctrico.

Cuando se funde la chatarra, debido al aporte de energía eléctrica de los electrodos, la acción del quemador y la energía que aporta la reacción de oxidación, se le añade un compuesto escorificante, cuya finalidad es producir una escoria básica que favorezca la desfosforización del fundido. Por lo general se agrega cal, lo que aumentará el contenido de MgO en la escoria, reduciendo así la erosión del revestimiento de magnesita del horno. El escorificante se agrega a través del quinto orificio y el agente lubricante también se agrega a través del orificio.

El fósforo es generalmente un elemento dañino para el acero, reduciendo su ductilidad y tenacidad al frío. Las estimaciones indican que cada 0,01% de fósforo aumenta en 7 ° C la temperatura de transición dúctil-frágil. Debido a esto los aceros con alto contenido de fósforo pueden volverse quebradizos a temperatura ambiente. También, en aquellos aceros que sufren un tratamiento de temple y revenido, el fósforo promueve el desarrollo de la fragilización por revenido. Existen algunas excepciones (por ejemplo, aceros fácilmente mecanizables).

El proceso de desfosforización del fundido se puede ver en la Figura 2.7. Para empezar, el P se oxida (con el oxígeno introducido mediante las lanzas, el oxígeno del óxido de hierro en la escoria y el oxígeno disuelto en el acero fundido) produciendo P₂O₅, que luego se combina con la cal para formar compuestos estables que formaran parte de la escoria. De esta manera se disminuirá el contenido en fosforo del acero.



Figura 2.7 Diagrama esquemático del proceso de desfosforización del acero.

Se deben promover algunos factores en el proceso de desfosforización:

- Se requieren condiciones muy oxidantes que se logran introduciendo oxígeno a lo largo del proceso.
- Se requiere que la escoria tenga una alta alcalinidad, que se logra utilizando cal como escorificante.
- Se requiere que la temperatura del fundido no sobrepase los 1550° , evitando así que el fósforo se vuelva a disolver en el acero.
- Se requiere una buena agitación del fundido de forma que se incremente el contacto entre el metal y la escoria generando una mejor absorción del P_2O_5 .

En contra, se deben evitar algunos factores:

- Altos contenidos en Mn, C y Si, que son compuestos fácilmente oxidables y disminuyen la capacidad de absorción del P
- Gran cantidad de SiO_2 y Al_2O_3 en la escoria, puesto que reduce la efectividad de la cal.
- Escorias saturadas en P_2O_5 .

El uso de recarburante como aditivo para aportar carbono se explica por diferentes razones. Por un lado, genera energía, debido a que el carbono se oxida con facilidad; genera como productos CO y CO_2 que favorecen la generación de espuma en la escoria. Este se utiliza también en las etapas finales del proceso reduciendo la oxidación del fundido. La escoria aporta numerosas ventajas:

- Puesto que los electrodos están inmersos en la escoria, el revestimiento del horno está protegido de la radiación provocada por el arco.
- Al trabajar con potencias altas se generan arcos largos consiguiendo una pérdida de energía.
- Impide la introducción de N_2 en el fundido.
- Actúa como aislante acústico.

Optimización del comportamiento frente a fatiga del acero para muelles mediante el uso de algoritmos *Machine Learning*

- Facilita la operación reduciendo el movimiento de los electrodos y las variaciones de voltaje.

Existen diversos factores que afectan directamente a la espumación de la escoria:

- Viscosidad de la escoria. Como se muestra en la Figura 2.8, un aumento en la viscosidad conduce a un aumento de la velocidad de formación de espuma. A medida que aumenta la viscosidad, la velocidad de drenaje disminuye, lo que hace que las burbujas permanezcan más tiempo en la escoria, lo que aumenta su altura y estabilidad. Por el contrario, una viscosidad excesiva genera una escoria más frágil disminuyendo la velocidad ascensional de la burbuja.

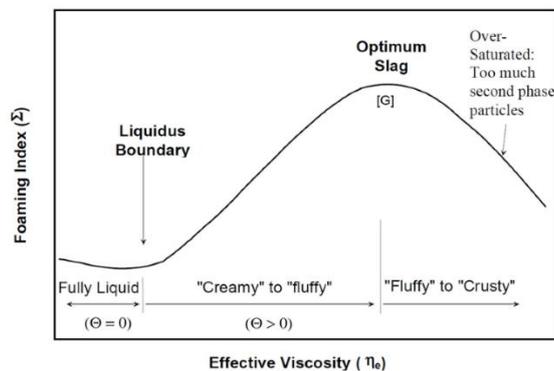


Figura 2.8 Efecto de la viscosidad en el índice de formación de espuma. Puede observarse que hay una viscosidad óptima que maximiza el valor del índice de formación de espuma[10].

- Basicidad (CaO/SiO_2). La alcalinidad se encuentra estrechamente relacionada con la viscosidad y con la formación de espuma en la escoria. La escoria ácida causa la ruptura de los enlaces de la sílice debido al aumento de CaO , esto tiene como consecuencia una disminución en el índice de formación de espuma. Por el contrario, la escoria alcalina, causa un aumento de la viscosidad debido a la saturación en óxidos, lo que conduce a una precipitación de la fase sólida dificultando la espumación.

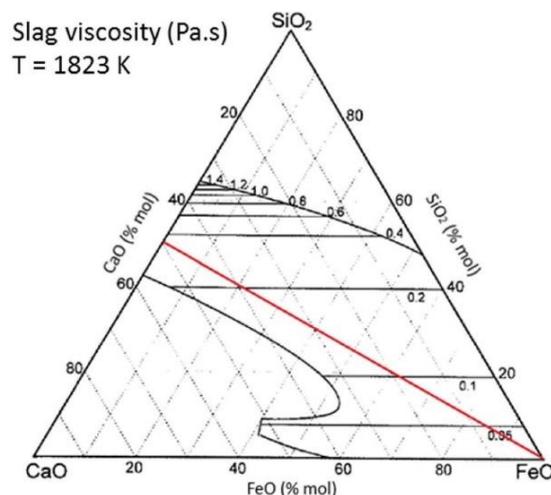


Figura 2.9 Diagrama ternario que muestra el efecto del contenido de FeO sobre la basicidad[10].



- Velocidad del gas. Para obtener escoria de espuma de alta calidad, es necesario que existan burbujas de CO. Las burbujas generadas a velocidades de gas bajas producen escoria espumada muy estable, que tarda mucho en explotar incluso cuando el caudal de gas se reduce drásticamente. Por el contrario, velocidades altas de gas generan una escoria expandida, turbulenta, con mucho espaciamiento y baja estabilidad.
- Tamaño de las burbujas. Las burbujas pequeñas producen una espuma mejor que las grandes. La causa es que mientras las pequeñas generan huecos esféricos, las grandes los generan poliédricos, lo que tiene menos estabilidad.
- Calidad del carbón espumante. La velocidad de reacción se ve favorecida por las partículas de menor tamaño. Esto es debido a que el área de contacto aumenta. Tamaños demasiado pequeños tampoco son beneficiosos puesto que pueden ser absorbidas por el sistema de extracción de gases.

Debido a la relevancia que tiene para el proceso la espumación de la escoria se han desarrollado varios procesos para cuantificar su calidad. Cabe destacar los siguientes:

- Control por medición sonora. Se basa en el aislamiento sonoro que produce la escoria, de forma que mide el nivel de ruido generado por el arco.
- Control por medición de los humos emitidos por el cuarto orificio. Se basa en la temperatura generada por la reacción de CO y el O₂ del ambiente. El volumen de CO generado varía en función de la calidad de la escoria.
- Control por la actividad de oxígeno. Para cada una de las calidades del acero, se determina el valor objetivo de la actividad del oxígeno en el fundido. Para lograr estos valores, la relación entre el flujo de inyección de O₂ y C debe conocerse con precisión.

La inyección de oxígeno y carbono al proceso se produce por medio de lanzas que pueden ser de dos tipos:

- Las lanzas consumibles se introducen en el fundido normalmente a través de la puerta del horno. Las puede operar una persona o estar automatizadas.
- Las lanzas supersónicas no se meten en el fundido y se operan de forma automática.

A lo largo de todo el proceso se llevan a cabo diferentes controles para comprobar la calidad del fundido, se controla la temperatura del fundido y los niveles del oxígeno a lo largo de todo el proceso. Al terminar cada colada se toma una muestra de la escoria para por su relevancia en el proceso y se toman las medidas necesarias.

Para terminar, una vez conseguidas las condiciones del fundido deseadas el acero está listo para pasar al siguiente proceso, el horno de cuchara. Para esto, se vuelca la masa de acero fundida sobre el horno cuchara, prestando especial atención a que la escoria no caiga en el horno cuchara ya que afectaría su calidad. Existen dos tipos de sistemas de control principales para evitar la escoria:

- Sistemas de detección electromagnética (ejemplo es la tecnología AMEPA ESD, *Electromagnetic Slag Detection*[11]), son sistemas que se basan en las variaciones del campo magnético generadas por el aumento en el contenido de escoria en el fundido. Funciona colocándose un detector electromagnético en el fondo de la cuchara, que emite una alarma al detectar el paso de escoria, cerrando automáticamente el paso.
- Sistemas termográficos, (ejemplo es la tecnología AMEPA TSD, *Thermographic Slag Detection*[11]) basados en el hecho de que las características de radiación térmica del acero y la escoria en el rango de infrarrojos superior son significativamente diferentes a la misma temperatura. Este sistema está formado por una cámara de infrarrojos (instalada en el interior de una carcasa refrigerada para protegerla del calor y la radiación) que detecta la existencia de escoria en el fundido.

Es importante que durante el volcado del acero en el horno cuchara no se generen gran cantidad de burbujas de aire puesto que el nitrógeno contenido en el aire se absorbe en parte por el acero, reduciendo la ductilidad y aumentando la fragilidad, lo que afecta negativamente a las propiedades mecánicas. Por eso, es importante que el fundido contenga una cierta cantidad de oxígeno[12] y azufre disuelto, compuestos que como se puede observar en la Figura 2.10 con el caso del oxígeno, disminuyen la absorción de nitrógeno.

También hay que tener en cuenta el contenido en humedad de las adiciones que se utilizan para favorecer el proceso de desoxidación y mejorar la calidad del acero durante el proceso de volcado, puesto que el acero fundido acaba absorbiendo parte de este hidrógeno. El hidrógeno genera lo que se conoce como manchas brillantes, que reducen la tenacidad y ductilidad del acero.

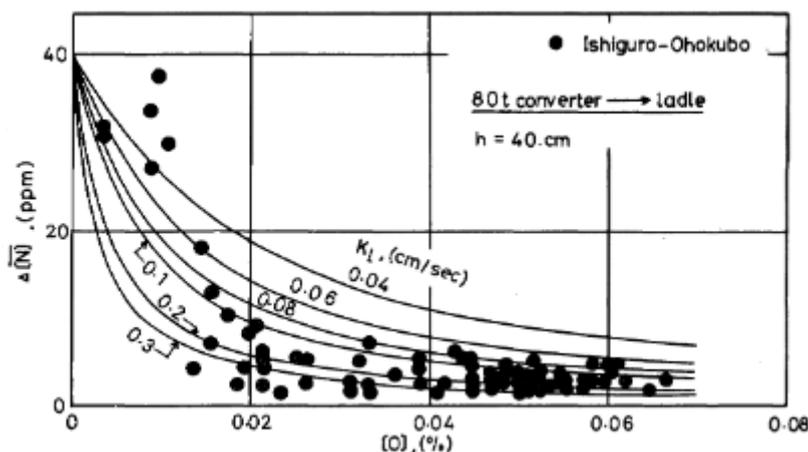


Figura 2.10 Relación existente entre la cantidad de oxígeno disuelto y el nitrógeno absorbido por parte del acero[12].

2.2.2 Horno cuchara

La industria siderúrgica experimentó un gran avance en los procesos de acería durante la segunda mitad del siglo XX. Los consumos de energía, electrodos y la duración de las



coladas se redujeron considerablemente, lo que supuso un gran avance para las acerías que funcionaban con hornos de arco eléctrico.

También durante esta época se produjeron cambios en el proceso productivo del acero mediante el horno de arco eléctrico, que hasta ese momento estaba conformado principalmente por las siguientes etapas[13]:

1. Se realizaba el proceso de carga del horno con la chatarra y los compuestos adicionales.
2. Se llevaba a cabo la fusión de la carga.
3. Se realizaba una etapa oxidante, en la que se descarburaba y se desfosforaba el fundido.
4. Se realizaba una operación de desescoriado.
5. Se realizaba una etapa reductora, en la que se desoxidaba y desulfuraba el fundido.
6. Se ajustaba la composición del fundido.
7. Se realizaba la basculación del horno en la cuchara, la cual una vez cargada se podía trasladar a la zona de moldes en caso de realizarse una fundición por moldeos, a la zona de lingoteras o a la zona de colada continua para la fabricación de palanquilla.

Con la aparición de los transformadores UHP en la década de los 60, que convierten a los hornos en máquinas para fundir y oxidar, surge la metalurgia secundaria, en la cual el refinamiento del acero se realiza en otros equipos, los denominados hornos cuchara o de afino.

La implementación de los hornos de afino supuso numerosas ventajas en el proceso de producción del acero mediante hornos de arco eléctrico[13].

Desde el punto de vista productivo se pueden destacar las siguientes ventajas:

- Disminución de los tiempos de colada.
- Mayor flexibilidad.
- Trabajo más fácil con sistemas de colada continua.
- Optimización de las operaciones de acería.
- Mejor aprovechamiento de los equipos productivos.

Desde el punto de vista económico:

- Permite realizar un mayor control de las temperaturas, lo que produce un ahorro de energía.
- Permite el uso de ferroaleaciones más baratas y una mayor recuperación de estas.
- Requiere menores controles de calidad debido al aumento en la eficiencia del proceso

Desde el punto de vista de la calidad:

- Permite conseguir una mayor precisión en la composición en función del acero deseado.
- Permite obtener contenidos de carbono menores.
- Permite conseguir una mayor desfosforización.
- Facilita las operaciones de la etapa reductora (desoxidación y desulfuración).
- Permite mejorar la desgasificación del fundido, lo que redundará en menores contenidos en hidrógeno y nitrógeno y aceros de mayor calidad.

También permite la implementación de procesos de afinado en vacío, que, debido a la extracción de los gases, reducen el contenido en inclusiones no metálicas. Esto es debido por un lado a que la extracción del oxígeno reduce considerablemente la formación de óxidos y por otro lado a que este proceso de vacío facilita la flotación de las inclusiones y su implementación en la escoria.

Este modelo productivo se diseñó principalmente para fabricar aceros especiales pero debido a la mejora de la calidad que aportan en la actualidad se utilizan en la práctica totalidad de las acerías de arco eléctrico.

El horno de afinado tiene similitudes con el horno de arco eléctrico ya que consiste en un recipiente cilíndrico de techo abierto por donde se introducen los electrodos. El cuerpo está formado por láminas de acero revestidas con materiales refractarios de grosor y tipología variables en función de la ubicación, debido a que el desgaste no es homogéneo. La bóveda se encuentra refrigerada por agua. Una vez realizada la metalurgia secundaria se transporta el fundido dentro de este horno hasta la colada continua. En la Figura 2.11 se observa una representación de un horno cuchara.

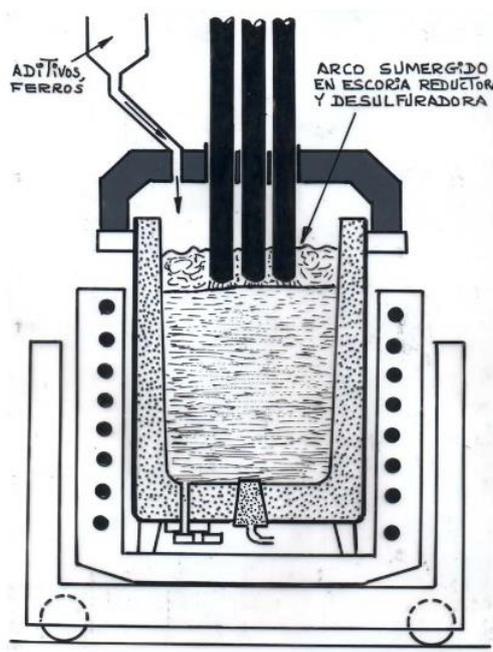


Figura 2.11 Representación esquemática de un horno cuchara[13].



Entre las partes principales de un horno de afino destacan las siguientes: cuchara, bóveda, brazo portaelectrodos, electrodos, buza, equipo de inyección de gas inerte, sistema de extracción de gases, sistema de tolvas pesadoras para adición de ferroaleaciones, máquina de inyección de envainados y el carro portacuchara. En la Figura 2.12 se muestra un esquema del corte de un horno de afino junto con algunas de sus principales partes.



Figura 2.12 Representación de un horno cuchara en el que se indican algunas de sus principales partes[14].

Los electrodos pueden provocar un sobrecalentamiento del acero en áreas cercanas al arco. Para evitar estos cambios térmicos entre las distintas zonas del horno y obtener una composición uniforme del fundido se recurre a la agitación de este. Se pueden encontrar varias metodologías, entre las que cabe destacar[13]:

- Agitación por lanza de argón: se trata de la alternativa más barata y sencilla, presenta buen contacto entre el metal y la escoria y protege el refractario. Tiene la ventaja que, como todos los métodos de agitación de gas inerte, favorece el proceso de flotación y desulfuración de las inclusiones. Como desventaja fundamental no puede evitar la absorción de N_2 y O_2 y favorece un desgaste del refractario en la zona de insuflado.
- Agitación por medio de la inyección de argón a través de tapones refractarios porosos montados en la solera: se trata del sistema empleado en GSW. Presenta algunas ventajas como que minimiza las zonas muertas, favorece el contacto entre el metal y la escoria, previene la rotura de la escoria y tiene menor coste que la agitación magnética. Al tratarse de un procedimiento de agitación con gas inerte, favorece la eliminación de inclusiones y la desulfuración del acero. Entre los inconvenientes, esta técnica produce un mayor desgaste del refractario en la zona del tapón y se corre el riesgo de perforación de la cuchara.

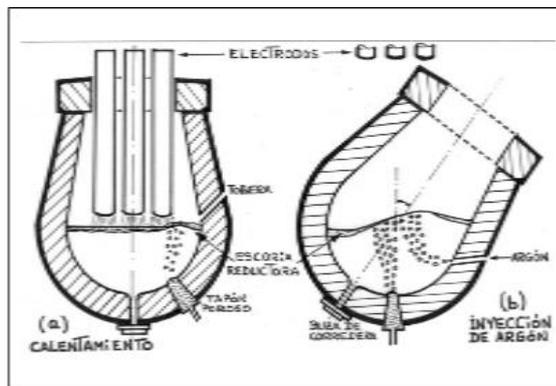


Figura 2.13 Ilustración donde se muestra un ejemplo de inyección de argón a través de tapones refractarios porosos montados en la solera[13].

- Agitación magnética: se trata de la alternativa más costosa. El procedimiento más antiguo es mediante una bobina electromagnética situada bajo la solera del horno. La corriente alterna de baja frecuencia circula a través de la bobina, creando una fuerte agitación magnética en el fundido existente en el horno. La agitación produce un contacto efectivo entre el acero y la escoria que flota sobre él, acelerando así la reacción metalúrgica de la fundición. Este procedimiento evita la reoxidación del fundido por el contacto con la atmósfera.
- . La Figura 2.14, muestra una representación de una buza, parte a través de la que se produce la salida del acero del horno.



Figura 2.14 Representación de las partes principales de una buza[14].

El proceso del horno de cuchara comienza volcando el acero del horno de fusión a una cuchara precalentada. Debido a su alta conductividad térmica, este precalentamiento es fundamental para evitar una pérdida excesiva de calor a través del material refractario que protege la cuchara. Se pueden utilizar modelos matemáticos que tenga en cuenta las



diferentes variables involucradas para predecir la pérdida de calor durante y después del vuelco. Las principales variables a tener en cuenta son:

- La temperatura de la cuchara antes del vuelco.
- Los espesores del revestimiento.
- El espesor de la capa de escoria.
- Los tiempos de espera de la cuchara.
- Las condiciones de agitación.
- Los efectos térmicos de las adiciones.

El acero que se obtiene directamente del horno de fusión está altamente oxidado y presenta un gran contenido de azufre, lo que deberá ser mitigado para evitar un impacto negativo sobre las características del producto final. En términos de oxígeno, el hierro líquido a 1539°C y presión atmosférica puede contener hasta un 0,1600% de oxígeno disuelto. Después de la solidificación la solubilidad cae al 0,0030%, formando una solución sobresaturada. El oxígeno libre comienza a reaccionar con el carbono para formar monóxido de carbono CO. Para reducir la creación de poros causada por la formación de CO, su concentración debe reducirse antes de que el acero solidifique, por eso, durante la desgasificación del horno de fusión, se inicia el proceso de desoxidación del acero que se completará en el horno cuchara. Al verter el fundido en la cuchara, se añaden los óxidos necesarios para formar la escoria sintética, generalmente cal, dolomita y aleaciones de hierro para ajustar la composición del acero y favorecer su desoxidación. Los principales desoxidantes utilizados son los siguientes:

- El carbono se utiliza como desoxidante debido a que genera un producto gaseoso, lo cual no favorece la generación de inclusiones. Tiende a usarse como primera desoxidación antes de añadir las ferroaleaciones. Su uso está limitado por el contenido en carbono requerido en el acero
- El aluminio consigue reducir el oxígeno residual a un valor mínimo. La mayoría de las inclusiones formadas por el aluminio sedimentan rápidamente en forma de alúmina o aluminato.
- El silicio es uno de los desoxidantes más consumido. En contacto con el manganeso tiende a generar inclusiones de silicato de manganeso.
- El manganeso se usa debido a que mejora sustancialmente las propiedades desoxidantes del silicio y el aluminio.
- El Ferro Silicio Manganeso (FeSiMn) se utiliza ya que se difunde en el fundido con mayor velocidad que la adición de FeSi y FeMn por separado. Esto se debe a que tiene una densidad mayor por lo que penetra mejor en el fundido, proporcionando una desoxidación más uniforme.

Es primordial que la escoria se encuentre completamente desoxidada para una buena desoxidación, de forma que el contenido de óxido de hierro sea el menor posible y la actividad de CaO la mayor. También se requerirá una escoria bien proporcionada con una

parte poco viscosa para retener las impurezas generadas en la desoxidación y otra parte de la escoria de alta viscosidad que no desgaste excesivamente el refractario. El cumplimiento de estos estándares creará las mejores condiciones para reducir el oxígeno del fundido y promover la desulfuración. Con la escoria libre de óxido, el contenido en FeO existente en el acero se dividirá entre el acero y la escoria. Si se agrega un agente reductor a la escoria ya oxidada, existen condiciones para absorber una nueva cantidad de óxido de hierro del baño de metal, reduciendo así el contenido de oxígeno en el acero. Además, los ferros que tiene una mayor afinidad por el oxígeno que el hierro agregado durante el vuelco formarán óxidos que entrarán en la escoria, reduciendo así el contenido de oxígeno.

Una vez el acero se encuentra desoxidado y antes de la desulfuración, se agregan los aditivos necesarios para completar el ajuste de composición. A continuación, comienza el proceso de desulfuración. Para acelerar la reacción entre la escoria y el baño de acero, se inyecta gas argón a través del tapón poroso para agitar el fundido al mismo tiempo que el acero se calienta mediante tres electrodos. La reacción de desulfuración típica es: $\text{FeS} + \text{CaO} \rightarrow \text{CaS} + \text{FeO}$. Una vez completada la desulfuración, se volverán a agregar diferentes ferroaleaciones para encontrar la composición requerida, y se iniciará una fase de agitación suave, sin usar los electrodos y sin triturar la escoria para capturar las inclusiones.

Las posibles inclusiones que se pueden presentar en el acero se pueden clasificar de diferentes formas[15]:

- Atendiendo a su composición se pueden clasificar en tres grandes grupos; óxidos, nitruros metálicos y sulfuros.
- Atendiendo a la etapa del proceso en la que se generan se pueden clasificar como primarias, que son aquellas que se generan antes del comienzo de la solidificación, y secundarias, que son aquellas que se generan después del comienzo de la solidificación.
- Atendiendo a su origen se pueden clasificar como endógenas, que son aquellas que se dan como resultado de la combinación de O, N y S con elementos metálicos que se agregan al fundido, e inclusiones exógenas, provienen de la erosión del refractario, de la escoria atrapada en el fundido o son causadas por la reoxidación del acero en contacto con el aire. Son inclusiones más desiguales en composición y microestructura. En términos generales, pueden ser más grandes que las endógenas y son más dañinas para el comportamiento mecánico del acero.
- Atendiendo a su tamaño se pueden clasificar en microinclusiones que son las más abundantes, se distribuyen uniformemente y son menos dañinas para el acero y las macroinclusiones, que presentan una distribución fuertemente aleatoria, y son más perjudiciales ya que originan discontinuidades en el acero que pueden dar lugar al fallo del material y a defectos en el producto final.

Desde el punto de vista de la producción y la calidad, la eliminación de las inclusiones en el horno cuchara es muy importante. En el proceso de colada continua, las inclusiones pueden causar la obstrucción de la boquilla, lo que reduce la productividad del proceso. Su presencia también afectará negativamente la resistencia mecánica, la tenacidad a la



fractura y la vida a la fatiga del acero. Algunas como las alúminas, pueden resultar perjudiciales en varios ámbitos. Al ser sólidas a temperatura de fundición pueden obstruir la buza; también, durante la laminación, debido a su baja deformabilidad, se fragmentan y pueden ser motivo de rotura durante el proceso de trefilado. Debido a que en la práctica resulta inasumible su total eliminación, se trata de buscar modificar su composición y morfología para minimizar los daños, tanto en la productividad del proceso como sobre la calidad del acero. Un buen ejemplo es el uso de calcio en el proceso para transformar las inclusiones de alúmina, que se encuentran en estado sólido en el fundido, en aluminatos de calcio, que son líquidos. También si el aluminato que se forma es rico en CaO ayuda a absorber azufre.

Una vez finalizada la etapa de flotación y modificación de las inclusiones se realiza el último ajuste de composición. Para acabar la metalurgia secundaria, se ajusta la temperatura para proceder a su transporte hacia la etapa de colada continua

2.2.3 Colada continua

La colada continua surge como evolución a la fabricación de acero en lingoteras, en la cual el acero fundido se vertía en unas lingoteras y se dejaba enfriar, consiguiendo así lingotes. En la década de 1960 se extendió un proceso ideado por H Bessemer basado en dos rodillos contrarrotatorios sobre los que se volcaba el acero fundido y que formaba palanquillas o planchones como se ve en la Figura 2.15.

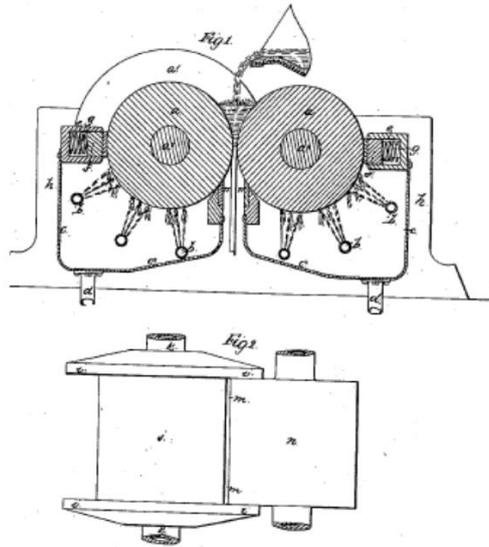


Figura 2.15 Esquema original del sistema de colada continua ideado por H. Bessemer[16].

Este método ideado por H. Bessemer dio lugar a los procesos de colada continua actuales. La colada continua supuso un gran avance ya que presenta rendimientos mayores, el producto es de mayor calidad y ahorra energía debido a que elimina calentamientos intermedios. La implementación de esta tecnología está creciendo, y actualmente el 95% del acero mundial se fabrica de acuerdo con este procedimiento, y solo el 5% se fabrica

con lingotes de acero. En la colada continua se generan diferentes tipos de productos (*billet*, *slab* o *bloom*) según su geometría, los cuales se pueden observar en la Figura 2.16.

Las *billets*, son productos de sección inferior a 180 mm, cuadrada o redonda, y se utilizan para fabricar productos largos, que pueden ser barras, alambρόn o perfiles. Las *slabs*, son productos de 250 mm de espesor y entre 750 y 2000 mm de anchura, son productos semi-terminados que pasan por un proceso de laminado en caliente, y podrán convertirse en bobinas o placas. Por último, los *bloom* son productos de sección rectangular superior a 180 mm, y se utilizan para producir perfiles estructurales de un tamaño mayor al de las *slabs*. Últimamente se está avanzando en nuevos diseños y las piezas de fundición se adaptan cada vez más a los productos finales, como los perfiles, reduciendo el número de transferencias de calor y reduciendo los costes de laminación.

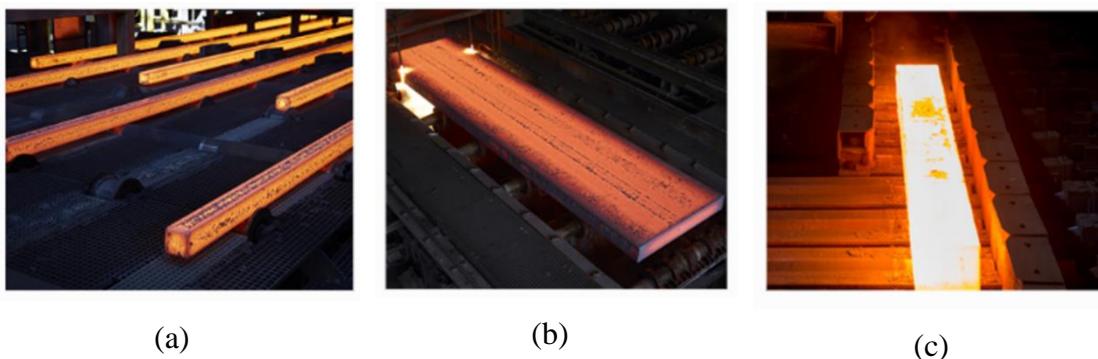


Figura 2.16 Fotografías que muestran los tres productos intermedios que pueden obtenerse tras la colada continua: (a) *billet*, (b) *slab* y (c) *bloom*.

En la fábrica de GSW se fabrican *billets* de 180 mm de lado y sección cuadrada. La Figura 2.17 muestra un esquema de la instalación donde se indican las diferentes partes que la componen. El proceso comienza con el volcado del acero sobre la artesa, que a través de una instalación curva lo distribuye en las diferentes líneas y termina cortando la palanquilla en posición horizontal. Este tipo de instalaciones son más eficientes que las verticales, ya que, en las instalaciones verticales, la distancia entre el molde y el área de corte es tan pequeña que se debe utilizar un avance muy lento para asegurar la completa solidificación del acero durante el corte. Presentan la desventaja que, en un dispositivo con curvatura la presión que ejerce el acero fundido sobre la capa solidificada hará que la palanquilla se hinche, dando lugar a defectos como grietas o segregación. Los diferentes más relevantes de la instalación de colada continua son:

- La cuchara, es el recipiente en el que se realiza la metalurgia secundaria y en el cual se transporta el fundido hasta la colada continua.
- La torre giratoria se utiliza para volcar la cuchara.
- La artesa es el recipiente donde se vuelca el fundido y distribuye entre las distintas líneas de la instalación proporcionando acero continuamente a la colada.
- El molde o lingotera se fabrica con chapa de cobre refrigerada por agua y da forma al producto final. Aquí se produce la llamada solidificación primaria.



- El falso lingote es una parte del molde que evita que el acero se derrame al inicio de cada colada.
- Los rodillos se encargan de soportar la presión ferroestática a la vez que permiten el avance del acero y le dan forma.
- El sistema de refrigeración
- La arrastradora y la enderezadora se encargan de cambiar de una posición vertical a una horizontal e impulsar a la palanquilla.
- En el oxicorte corta la palanquilla en el tamaño requerido.
- La desbarbadora, retira las rebabas de las palanquillas producidas durante el oxicorte.
- El transferidor lleva las palanquillas al enfriadero que es el lugar donde se almacenan tras terminar todo el proceso.

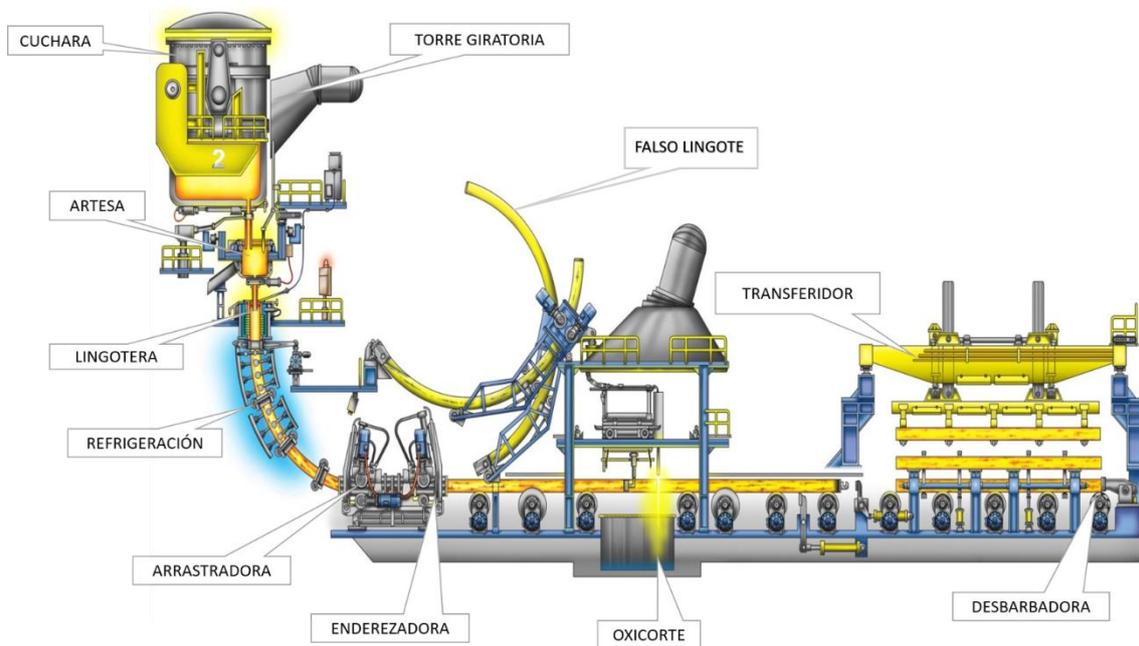


Figura 2.17 Representación de los componentes que integran la instalación de colada continua de GSW.

El proceso de colada continua se ejecuta de forma que, la cuchara del horno de afinado se desplaza mediante rieles hasta la zona de colada continua. Con la cuchara en la zona de colada continua, una grúa la levanta hasta la torre giratoria, que está formada por dos brazos, uno sujeta la cuchara que está colando mientras el otro sujeta otra cuchara llena. Cuando se termina de volcar la primera cuchara, la torre rota 180° para posicionar la otra cuchara sobre la artesa, de esta forma se consigue que el aporte de material sea continuo y no haya interrupciones. La cuchara presenta un mecanismo de abertura que se compone de dos placas con un orificio central como se puede observar en la Figura 2.18(a). La placa inferior se desplaza en el eje horizontal sobre la placa superior que se mantiene inmóvil, regulando el caudal aportado como se puede observar en la Figura 2.18 (b) La

placa inferior se cerrara totalmente cuando el sistema AMEPA detecte el flujo de escoria hacia la artesa.

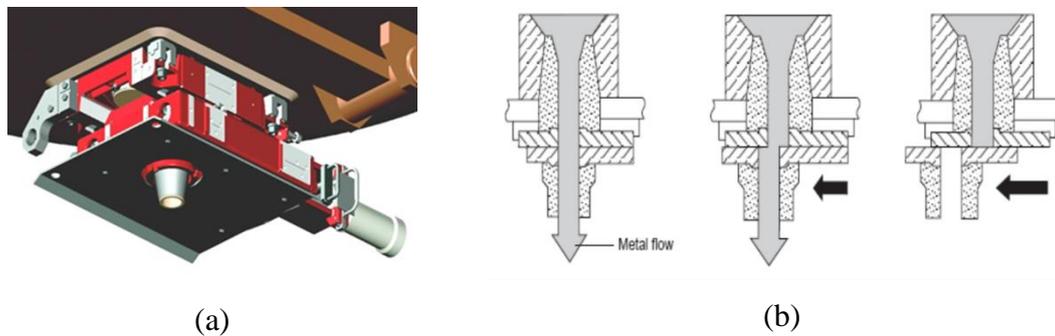


Figura 2.18 (a) Representación del mecanismo de apertura de la cuchara. (b) Diagrama del proceso de apertura de la cuchara.

Debido a que, como ya se ha comentado anteriormente, el contacto entre el acero fundido y la atmosfera es perjudicial debido a la oxidación y la absorción de nitrógeno por parte de este, se utiliza un tubo de protección. En la Figura 2.19 se aprecian diferentes soluciones existentes para evitar la entrada de aire en la cuchara.

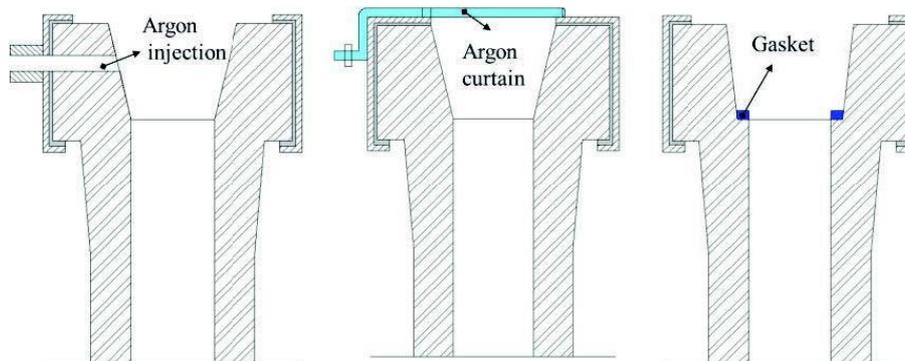


Figura 2.19 Distintas soluciones para evitar la entrada de aire en la cuchara[17].

El acero volcado por la cuchara caerá sobre la artesa que deberá estar previamente calentada para evitar cambios bruscos de temperatura, debiendo mantenerse siempre la temperatura del acero por encima de su temperatura de *liquidus* para un correcto colado de este, pero sin ser esta demasiado alta, lo que afectaría negativamente a la calidad de la palanquilla.

Los objetivos principales de la artesa son:

- Servir como depósito de acero fundido de manera que no se interrumpa la alimentación al sistema cuando se produce el cambio de cuchara.
- Distribuir el acero de forma uniforme entre las distintas líneas que conforman el sistema.



- La artesa cumple una función metalúrgica, favoreciendo la interacción entre la escoria y el acero fundido.

La escoria presente en la artesa se encuentra cubriendo al acero y distribuida de forma laminar en dos capas, una capa superior sólida que funciona como aislante térmico, y una capa inferior líquida que absorbe impurezas y reduce el contenido en inclusiones a la vez que protege de la oxidación. El interior de la artesa está cubierto por refractario para resistir altas temperaturas. Los revestimientos que presenta son de tres tipos:

- Revestimiento formado por hormigón refractario, fibras cerámicas o ladrillos de baja densidad con un espesor de entre 10 a 30 mm.
- Revestimiento de seguridad formado generalmente por ladrillos de alúmina con un espesor de entre 100 y 200 mm.
- Revestimiento de trabajo formado por una masa de magnesita de entre 50 y 90 mm.

Una vez el acero se encuentra en la artesa, este será distribuido entre los moldes presentes en las diferentes líneas que forman la colada continua. La finalidad del molde es producir una capa superficial de acero sólida, sin defectos que puedan provocar problemas de calidad en la palanquilla y lo suficientemente gruesa para resistir la presión que el acero líquido ejerce cuando sale del molde. Esto se consigue fabricando los moldes con paredes de cobre, que tiene una excelente conductividad térmica y que además se encuentran refrigerados por agua. Así se genera lo que se conoce como refrigeración primaria, que es consecuencia del contacto entre el acero fundido y las paredes del molde refrigerado. Las paredes del molde se lubrican con aceite y el molde acompaña en el movimiento descendente a la palanquilla, realizándose a veces movimientos bruscos ascendentes que separan las paredes del molde de la palanquilla.

Se debe controlar que el caudal en la artesa sea igual que la velocidad a la que los rodillos extraen el acero. Existen varios mecanismos de regulación, por ejemplo, para aceros que no requieran altas prestaciones o poco propensos a oxidarse, se puede utilizar un sistema de buza calibrada que controla los cambios de nivel de acero en el molde a través de la a la que avanza la colada. Este mecanismo puede afectar a la velocidad superficial y a la oxidación del acero ya que en ocasiones genera variaciones en la velocidad.

Cuando el acero sale del molde la capa de acero sólida es muy fina, de aproximadamente 10 mm, por lo que se rocía con agua la superficie del acero para favorecer su enfriamiento. Este es el proceso conocido como solidificación secundaria y en él se producirá el enfriamiento final de la palanquilla adaptándose la velocidad de avance en función del grosor de la capa superficial de acero de forma que se previenen así posibles roturas. A parte de regular la velocidad de avance, los rodillos ayudan a prevenir roturas en la palanquilla, de forma que, en los tramos finales de la línea, cuando la palanquilla ya está más fría y solidificada aumenta la separación entre ellos. En la Figura 2.20 se muestra una imagen que ilustra los principales fenómenos que ocurren en el molde.

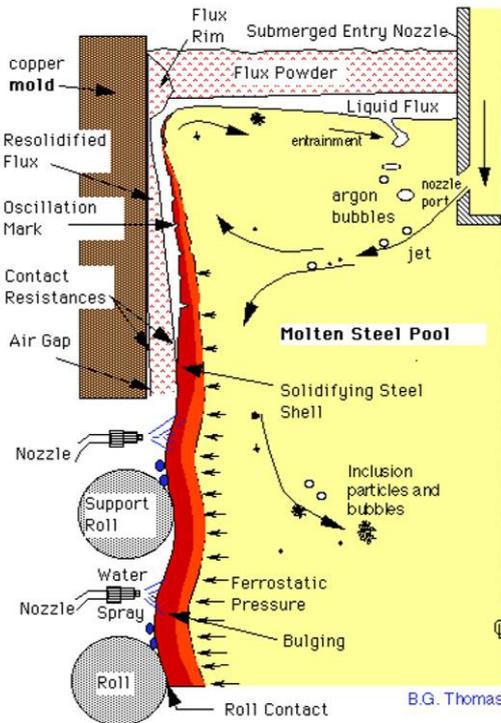


Figura 2.20 Imagen esquemática que muestra la secuencia de fenómenos e interacciones que se producen en el acero del molde[18].

Una vez terminada la solidificación secundaria y la palanquilla se encuentra en estado sólido con el producto solidificado, se traslada mediante rodillos a la zona de oxicorte, donde según la longitud deseada. Para terminar, se desbarba y se llevan al enfriadero.

El proceso de colada continua afecta ampliamente en la microestructura final de la palanquilla, presentando en la mayoría de los casos una estructura dendrítica parecida a la de la Figura 2.21.

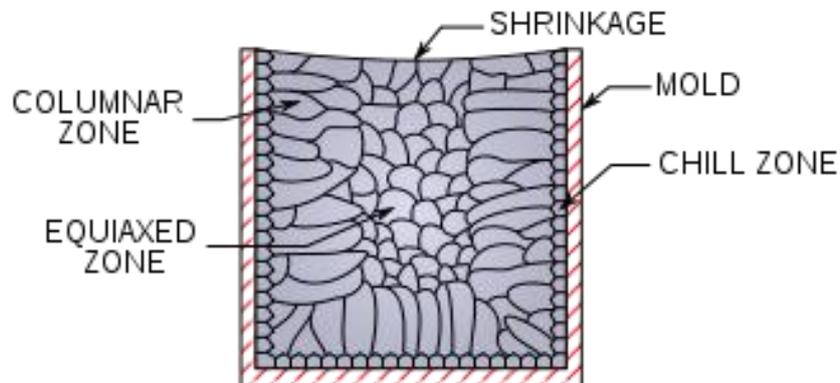


Figura 2.21 Microestructura de los aceros fabricados por colada continua[19].



De la Figura 2.21, se pueden destacar las siguientes zonas:

- El borde exterior de la palanquilla está formado por granos de pequeño tamaño y sin orientación preferente. Esto se debe a que enfriamientos lentos favorecen la formación de cristales grandes. Por el contrario, enfriamientos rápidos, como los que se producen en la capa superficial de la palanquilla debido a la acción de los moldes de cobre refrigerados, producen cristales pequeños. Esta zona exterior se conoce como zona de *chill*.
- La zona columnar ocupa la mayor parte de la sección de la palanquilla, y está formada por granos alargados y que se orientan hacia el centro de la pieza. Estos granos crecen entre la zona de *chill* y la zona equiaxial, y se generan por una velocidad de enfriamiento intermedia.
- La zona equiaxial se encuentra en el núcleo de la palanquilla, y está formada por granos de mayor tamaño debido a que se forman con una menor velocidad de enfriamiento. Estos granos tienen una orientación aleatoria.

La microestructura presente en la palanquilla influye significativamente en las propiedades finales. Los tamaños de las diferentes zonas varían en función del proceso de colada continua, de forma que por ejemplo en aceros cuya temperatura está muy por encima de la temperatura de *liquidus* dan lugar a zonas columnares mayores, lo que afecta negativamente a las propiedades del acero. La agitación electromagnética en el molde favorece la formación de mayores zonas equiaxiales debido que favorece la difusión de temperatura. La agitación magnética también puede generar efectos perniciosos, favoreciendo que se generen turbulencias y se formen inclusiones en la parte superficial de la palanquilla.

2.2.4 Laminación en caliente

La laminación en caliente es básicamente una técnica de conformado del acero mediante la cual, aprovechando la ductilidad del acero, se puede transformar el acero de una sección inicial cuadrada en el caso de la palanquilla a otra final circular en el caso del alambión. Esto se consigue haciendo pasar el material caliente, a una temperatura que oscila entre los 800° y los 1250°, entre dos o más cilindros que giran en sentido opuesto entre sí y a la misma velocidad. La distancia entre estos cilindros enfrentados es menor al grosor inicial de la palanquilla, obligándola a reducir su tamaño a medida que va avanzando cilindros[20]. Para conseguir la transición de una sección inicial cuadrada como es la de la palanquilla a una circular como la del alambión de utilizan unos cilindros acanalados. La Figura 2.22 muestra un esquema del funcionamiento de los rodillos.

Las características que debe cumplir el alambión dependen de las necesidades del cliente, pudiendo elegir entre:

- El cliente podrá solicitar diferentes diámetros, longitudes de alambre o tamaño de rollos.
- El enfriamiento del acero durante el proceso de laminado puede generar diferentes tipos de calidades.

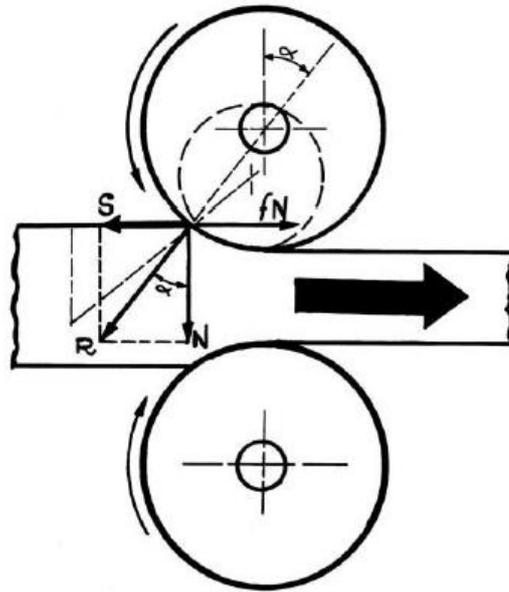


Figura 2.22 Representación del funcionamiento de los rodillos[20].

En la figura Figura 2.23 se puede ver un esquema de la instalación de laminación junto con sus principales componentes que existe en GSW

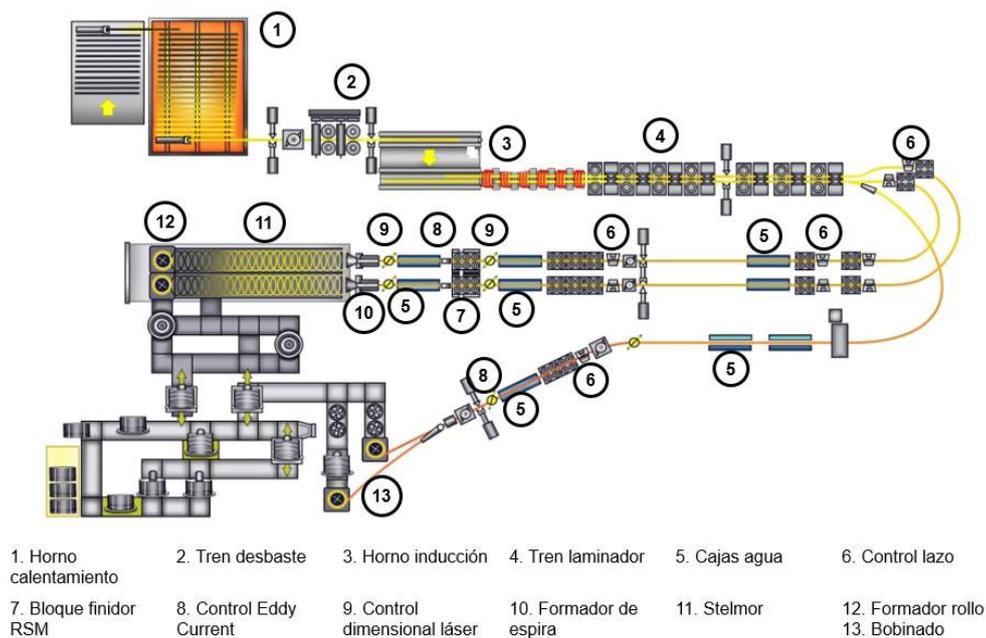


Figura 2.23 Esquema del tren de laminación de GSW.



2.3 Caracterización de la resistencia frente a fatiga mediante curvas S-N

Las curvas S-N, son conocidas también como curvas de Wöhler, en honor al ingeniero August Wöhler, quien realizó numerosos estudios y avances en el campo de la fatiga de materiales[21]. Las mismas se obtienen experimentalmente tras someter a diferentes probetas sin defectos a cargas cíclicas constantes hasta la rotura de estas.

Las cargas a aplicar, que se traducen en tensiones para el material constituyente del componente a evaluar, pueden ser aplicadas bajo diversos patrones. La Figura 2.24 presenta un ciclo de fatiga, de los aplicados. Normalmente, las curvas S-N se obtienen imponiendo una tensión media nula, $S_m=0$ (equivalentemente, una relación tensional $R=-1$).

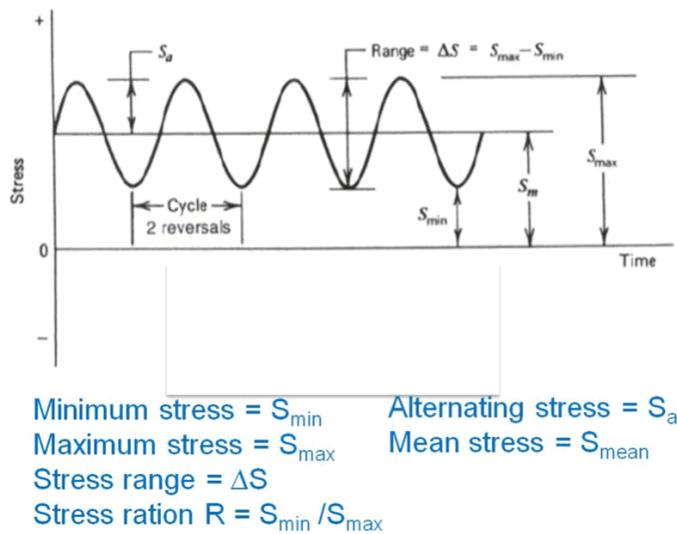


Figura 2.24 Gráfica donde se muestran las definiciones comúnmente usadas en la caracterización a fatiga[22].

Para la representación final de la vida a fatiga se utilizan las citadas curvas de Wöhler, que son, básicamente, un diagrama en donde se muestra la amplitud de tensión S_a (en ordenadas) frente al número de ciclos soportados hasta rotura (en abscisas), N .

En la vida en fatiga de los elementos se pueden distinguir principalmente dos etapas:

- Un periodo de iniciación que produce la formación de microfisuras
- Un periodo de crecimiento de macrofisuras que conduce a la rotura.

Esta segunda etapa es relativamente breve para probetas no entalladas. En la Figura 2.25 se recogen resultados experimentales obtenidos sobre una aleación de aluminio 2024-T3 que evidencian algunas ideas clave para entender las características básicas de las curvas S-N:

- En términos prácticos la vida total a fatiga es aproximadamente igual al número de ciclos consumido en la fase de iniciación, ya que la experiencia relata consumos del 90% de la vida en fatiga para esta.
- Por otro lado, la necesidad de superar un umbral tensional para activar la fatiga puesto que, si la amplitud es inferior a un determinado valor (unos 180 MPa en el caso de la Figura 2.25), el crecimiento de las microgrietas se ve impedido. En aceros y aleaciones de titanio, la curva S-N se hace horizontal para valores elevados del número de ciclos; existe por lo tanto una amplitud de tensión límite, denominada límite de fatiga, por debajo de la cual la rotura por fatiga no se produce.

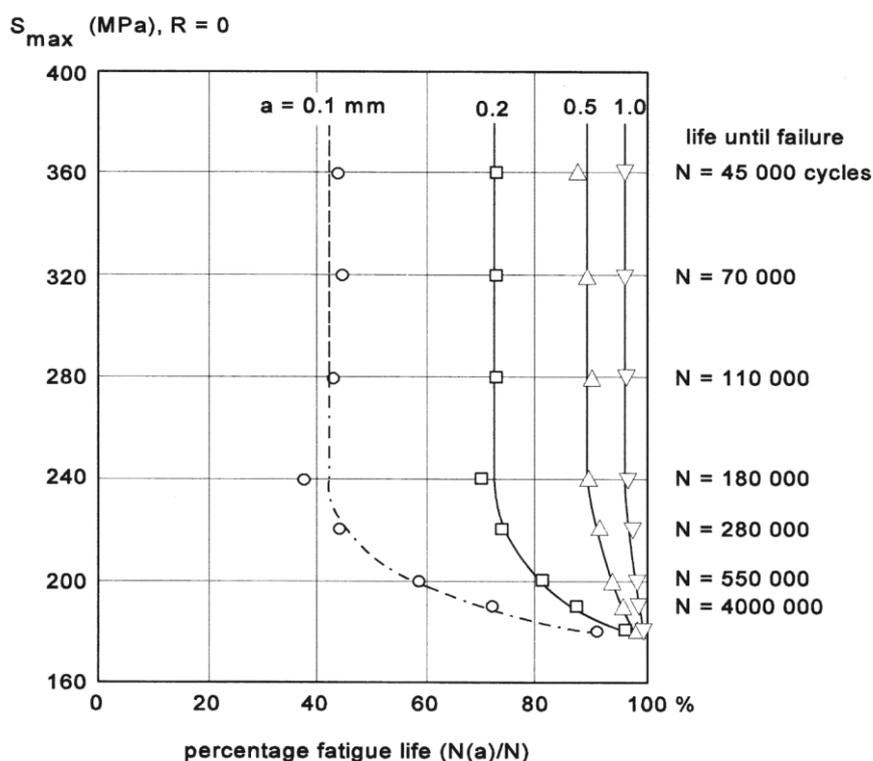


Figura 2.25 Gráfica con los resultados experimentales obtenidos mediante ensayos de fatiga realizados en probetas de la aleación de aluminio 2024-T3[23].

Existe, por otro lado, la diferenciación entre fatiga de bajo y de alto número de ciclos, respectivamente (*Low Cycle Fatigue*, LCF, y *High Cycle Fatigue*, HCF). La Figura 2.1 permite distinguir dos regiones sombreadas que se corresponden con LCF y HCF. La fatiga de bajo número de ciclos se asocia con estados tensionales durante el ensayo que producen la plastificación de la probeta; por el contrario, en fatiga de alto número de ciclos el material no supera nunca su límite elástico. Aunque no puede establecerse una frontera nítida entre estos dos ámbitos, se asume que por debajo de 10^4 ciclos el comportamiento se corresponde con LCF mientras que por encima de 10^5 ciclos el material habitualmente trabaja en condiciones de HCF. La relación entre la amplitud de tensión y el número de ciclos hasta rotura en régimen HCF suele modelarse empleando la ley de Basquin, que se recoge en la ecuación (2.1); los parámetros del modelo, C_1 y C_2 ,



se determinan a través de un ajuste de los datos experimentales. La Figura 2.1 muestra también el límite de fatiga del material, S_f ; nótese que para su determinación ha sido necesario llevar a cabo tres ensayos en los cuales, a pesar de haber aplicado más de 10^7 ciclos, no ha sido posible romper las correspondientes probetas.

$$(2.1) \quad (S_a)^{C_1} N = C_2$$

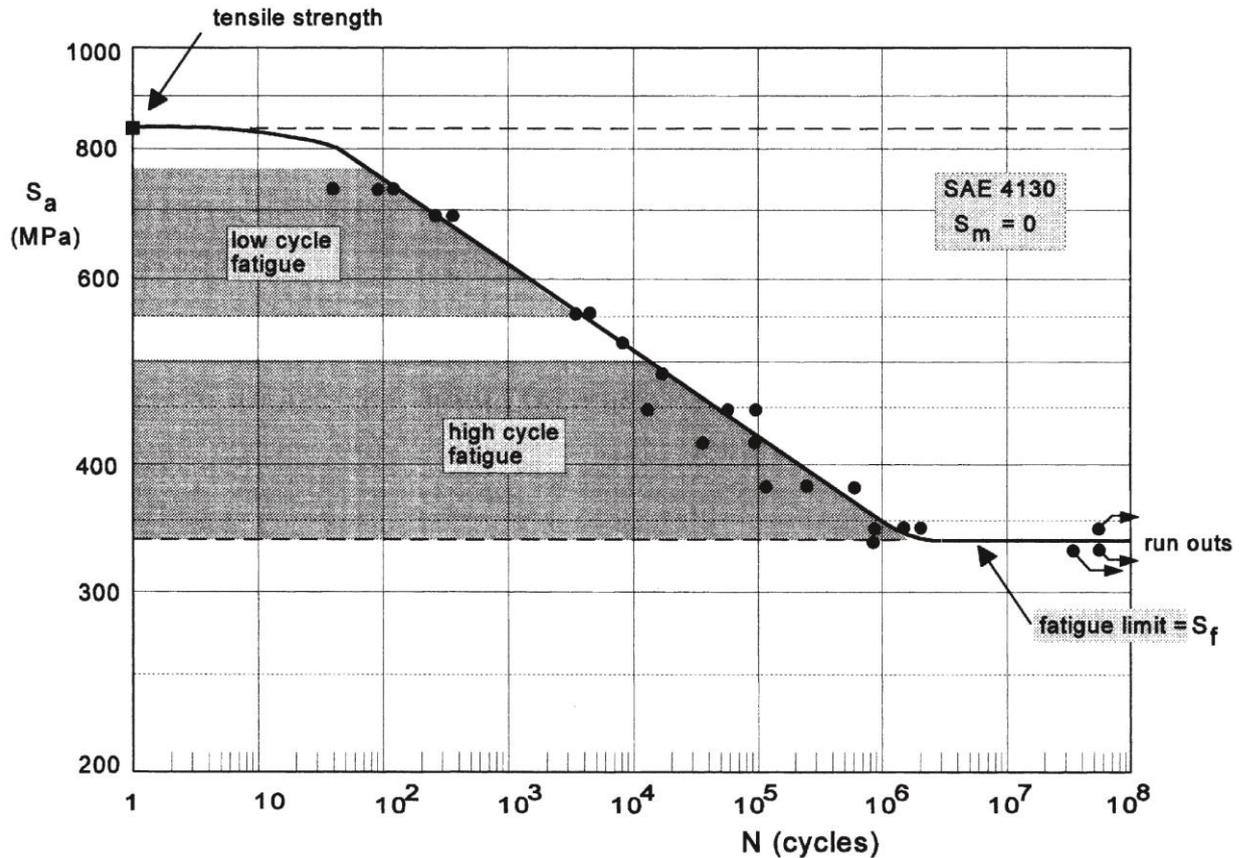
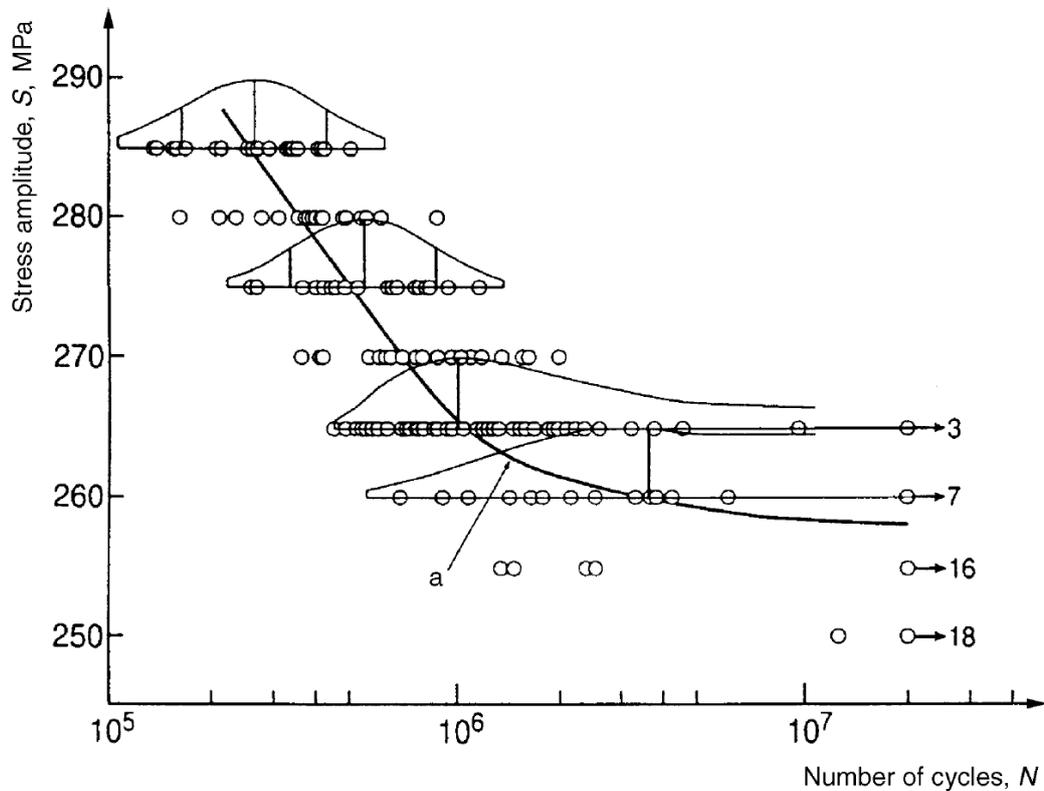


Figura 2.26 Gráfica de la curva S-N para un acero de baja aleación (SAE 4130)[23].

De la Figura 2.26 se puede destacar también la aleatoriedad vinculada al fenómeno de fatiga. Así pues, como se ve en la Figura 2.26, los ensayos realizados a la misma amplitud no tienen que producir los mismos ciclos a rotura, hecho que se ve incrementado al reducirse la amplitud de tensiones; produciéndola máxima incertidumbre en la región próxima al límite de fatiga, pudiendo encontrar que tras someterse a un mismo historial de cargas el resultado de varios componentes tenga una variabilidad considerable (suele trabajarse con un orden de magnitud de 10). La Figura 2.27 muestra un ejemplo sacado de la norma BS ISO 12107:2003[24]. En la normativa se considera N como una variable aleatoria que seguiría una distribución lognormal., mientras tanto ,otros autores[25] proponen una distribución de Weibull.



a median curve

Figura 2.27 Ejemplo de curva S-N donde se observa la aleatoriedad existente en el número de ciclos para aquellos ensayos realizados con la misma amplitud de tensión. Se aprecia que la dispersión aumenta al reducir la amplitud de tensión[24].

2.4 Un recorrido por el *Machine Learning*

2.4.1 Inteligencia artificial, Machine Learning, Deep Learning

La inteligencia artificial promete cambiar nuestras vidas en las próximas décadas y llevarnos a una nueva era de progreso, dando lugar al comienzo de lo que muchos consideran como la cuarta revolución industrial. Esto se debe a que la inteligencia artificial tiene una capacidad de recoger, procesar y analizar datos muy superiores a la de los seres humanos, permitiéndonos cuantificar mucho mejor todo lo que nos rodea. Esto ha provocado que hoy en día se escuche hablar de términos como Inteligencia Artificial, *Machine Learning*, *ML*, o *Deep Learning*, *DL*, como si fuesen lo mismo, y no lo son. La inteligencia artificial pretende imitar el comportamiento del ser humano, mientras el *machine learning* y el *deep learning* son técnicas que se engloban dentro de la inteligencia artificial[26]. La Figura 2.28 muestra un esquema de cómo se relacionan estos tres conceptos entre sí. En ella se puede ver cómo, la inteligencia artificial es un tema que incluye el *machine learning* y el *machine learning* incluye el *deep learning*.

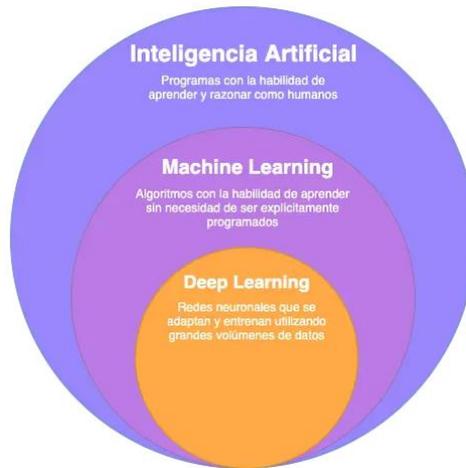


Figura 2.28 Esquema que ilustra las características que definen la AI, el Machine Learning y el Deep Learning, así como la relación existente entre ellos[26].

Ya en 1950, Alan Turing desarrolla la prueba de Turing, una prueba de la capacidad de una máquina para exhibir un comportamiento inteligente indistinguible al que tendría un ser humano. Poco después, en 1952 Arthur Samuel escribe un algoritmo capaz de jugar a las damas, aprendiendo tras cada partida y mejorando su juego. Así, en la Figura 2.29 se puede ver un esquema que muestra el desarrollo desde la década de 1950 de la inteligencia artificial.

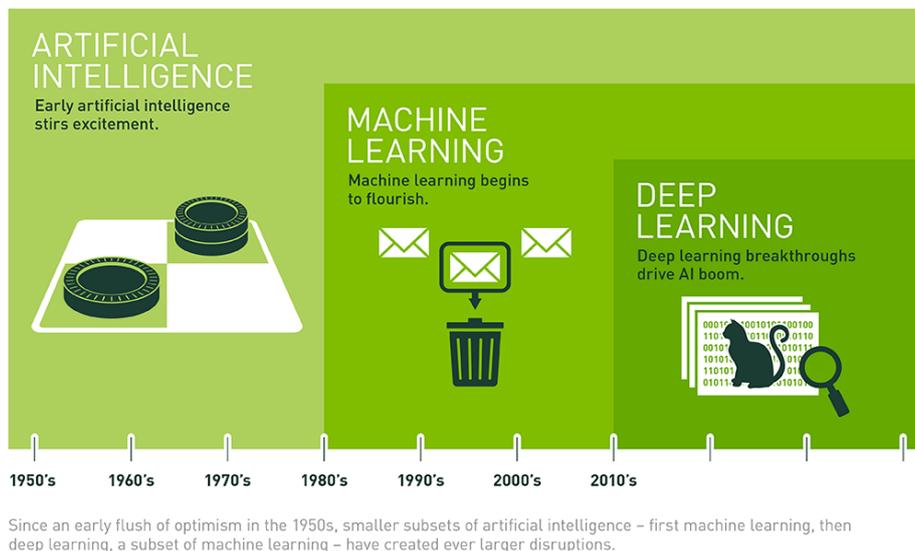


Figura 2.29 Desarrollo histórico de la Inteligencia artificial, el machine learning y el deep learning[27].

2.4.2 *Machine Learning*: otra forma de ver la programación de computadores

El *machine learning* supone una revolución en la forma de entender la programación. Los procedimientos de programación clásicos necesitan que el programador implemente las reglas necesarias para procesar los datos, es decir son procesos manuales, puesto que se introducen los datos de entrada (*inputs*), se codifican las reglas y obtenemos unos datos de salida (*outputs*). En cambio, mediante *machine learning* los algoritmos son capaces por sí solos de deducir las reglas subyacentes en los datos, por lo tanto, introduciendo los datos de entrada y salida un algoritmo crea un programa. La Figura 2.30 resume la diferencia entre las dos formas de programación.

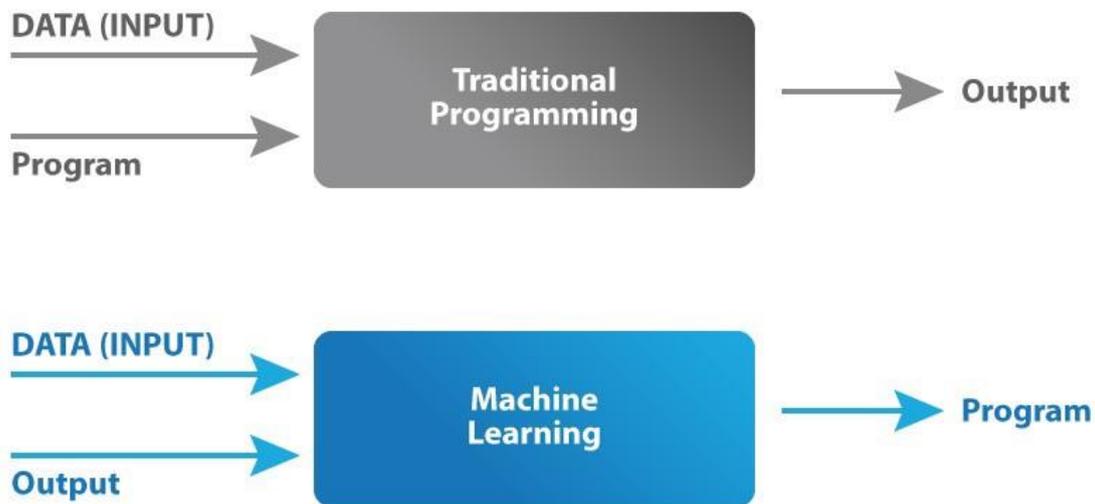


Figura 2.30 Ilustración que muestra la diferencia entre *Machine Learning* y la Programación Tradicional[28].

El *machine learning* por tanto resulta una herramienta extremadamente útil hoy en día que se dispone de una gran cantidad de datos, siendo capaz de identificar patrones dentro de los datos y tomar decisiones sin prácticamente la intervención humana. Algunos ejemplos de situaciones en las que el *machine learning* es especialmente útil son:

- Problemas que llevan implícitos la resolución de una gran cantidad de reglas.
- Situaciones difíciles de afrontar mediante enfoques tradicionales.
- Entornos cambiantes.
- Extracción de patrones de grandes volúmenes de datos (*data mining*)

2.4.3 Aprendizaje supervisado y no supervisado

Como se puede observar en la Figura 2.31 se pueden clasificar principalmente los modelos de *machine learning* en dos grandes grupos: modelos de aprendizaje supervisado y modelos de aprendizaje no supervisado.

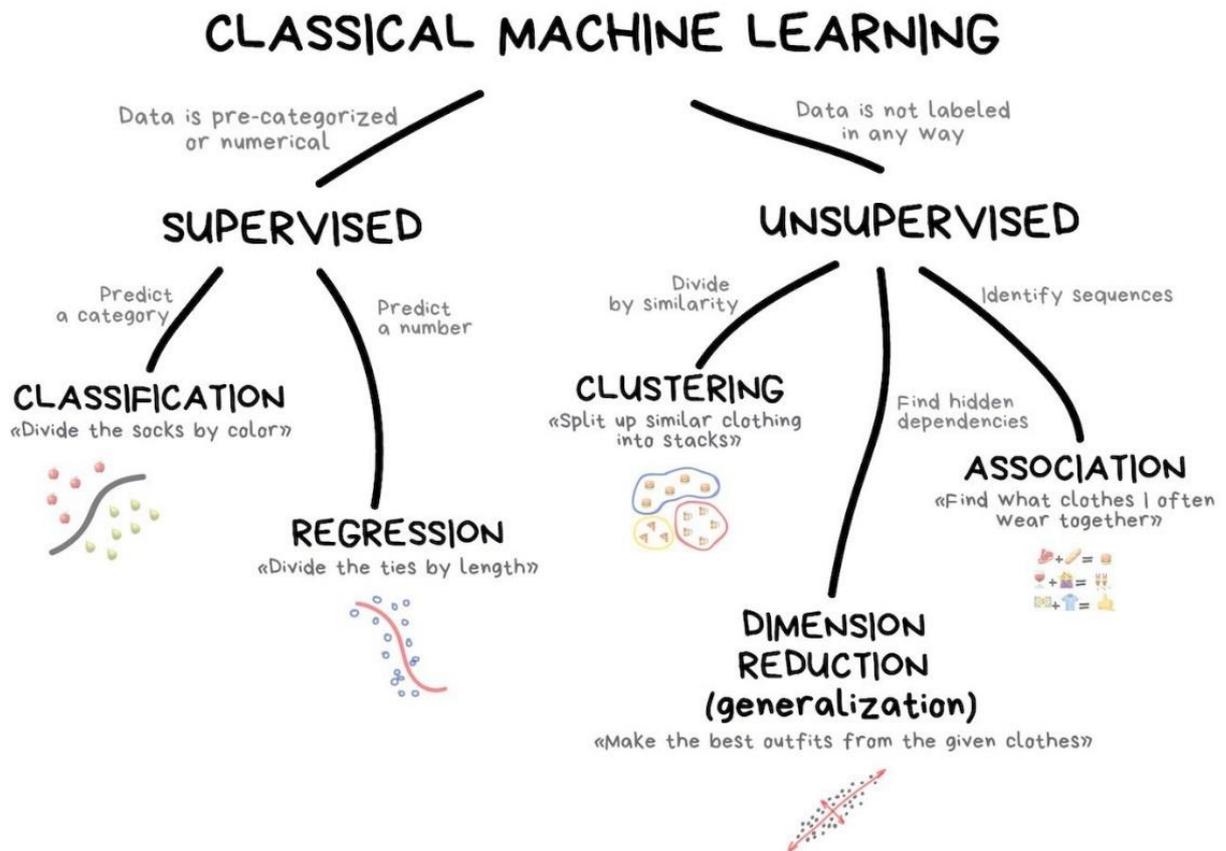


Figura 2.31 Ilustración que muestra la clasificación fundamental de los modelos de machine learning[29].

Los modelos de aprendizaje supervisado son modelos en los cuales el algoritmo se entrena con datos conocidos, que pueden ser valores numéricos (problemas de regresión) o etiquetas de clase (problemas de clasificación), para tratar de generar un programa capaz de predecir el valor de cualquier entrada en base a lo aprendido con los datos introducidos durante el entrenamiento. El aprendizaje no supervisado por su parte trata a los datos de entrada como variables aleatorias y construye un modelo a partir de ellos.

En la Figura 2.32 se muestra una ilustración en la que se observa la diferencia existente entre un ejercicio de clasificación (izquierda) y uno de regresión (derecha). En el caso del algoritmo de clasificación, el conjunto de datos (*dataset*) presenta círculos de dos colores, verdes y azules y estos han sido separados por una línea en dos grupos, existiendo a la izquierda de la línea un mayor número de círculos verdes y a la derecha un mayor número de círculos azules. Por otro lado, el algoritmo de regresión trata de generar una función entre la variable representadas en el eje de abscisas y el *output*, que tiene que ser numérico.

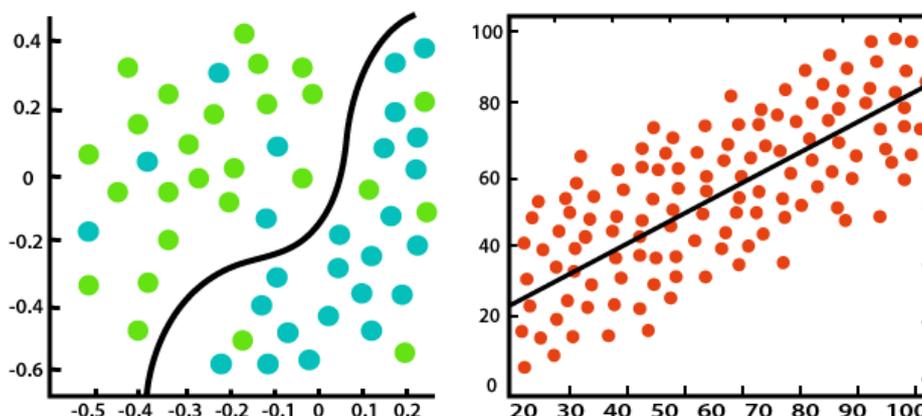


Figura 2.32 Ilustración que muestra un ejemplo de algoritmo de clasificación (izquierda) y uno de regresión (derecha)[30].

En la Tabla 2.1 se observa una comparación de las principales diferencias entre los algoritmos de regresión y clasificación[31].

Algoritmo de regresión	Algoritmo de clasificación
El resultado es una variable numérica continua.	El resultado es una variable discreta (una categoría).
El objetivo del algoritmo es obtener el mejor ajuste entre los predictores y el predictando.	El algoritmo proporciona fronteras de separación entre las diferentes categorías.
Entre los scores para evaluar la calidad del algoritmo destacan: R^2 , <i>Root Mean Square Error</i> , <i>Mean Absolute Error</i> , etc.	Los scores más habituales son: <i>accuracy</i> , <i>ROC curve</i> , <i>ROC AUC</i> , <i>Precision</i> , <i>Recall</i> , etc.
Entre las aplicaciones más notables cabe destacar la predicción meteorológica.	Se emplea con asiduidad en ámbitos como reconocimiento de voz o diagnóstico médico.

Tabla 2.1. Principales diferencias entre los algoritmos de regresión y de clasificación.

A continuación, se explican brevemente los algoritmos de aprendizaje no supervisado presentes en la Figura 2.31 que son, algoritmos de *clustering*, de reducción de la dimensionalidad y de asociación.

Los algoritmos de *clustering* tienen como propósito dividir la población observada en varios grupos para que los datos de cada grupo sean más similares entre sí que los datos que pertenecen a otros grupos. Básicamente, se trata de agrupar los datos en función de su similitud. En la Figura 2.33 se muestra como ejemplo el resultado de aplicar el algoritmo *K-means*, (un popular algoritmo de *clustering*), sobre una población de observaciones con dos características

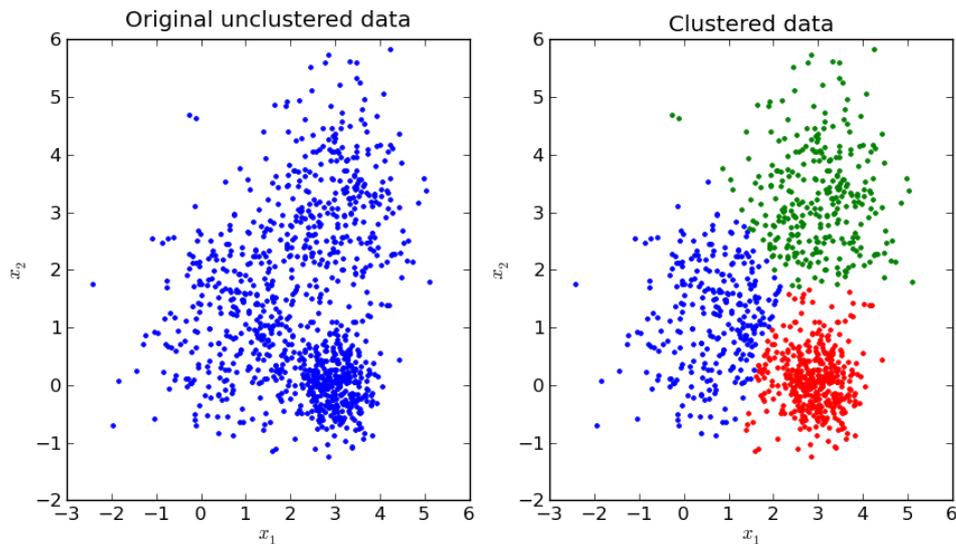


Figura 2.33 Aplicación del algoritmo de clustering *k*-means a un conjunto de datos. El resultado ha sido la agrupación de los datos en tres grupos o clusters[32].

Los algoritmos de reducción de la dimensionalidad tratan de reducir el número de características (*features*) empleando un menor número de ellas y perdiendo la menor información posible. Esto es muy útil para conseguir eliminar *features* que no aportan información relevante al sistema pero que pueden generar ruido, lo que dificulta la capacidad de predicción de los algoritmos. Es habitual encontrarse con problemas de aprendizaje supervisado en los cuales el número de *features* es muy elevado. Resulta muy útil antes de utilizar algoritmos de aprendizaje supervisado con gran número de *features*.

Se pueden distinguir principalmente dos grandes grupos de técnicas de procedimientos de reducción de la dimensionalidad: los llamados *feature selection* y los *feature extraction*. Por ejemplo, en los *feature selection*, el algoritmo filtra del *dataset* original aquellas *features* poco relevantes o redundantes y selecciona un número reducido de nuevas *features* a partir de las originales.

2.4.4 *Overfitting* y *underfitting*

Se conoce como *overfitting* o sobreajuste al modelo que funciona correctamente con los datos de entrenamiento, pero es incapaz de predecir correctamente los datos de test, dando lugar a un modelo inservible. Esto se produce cuando se entrena con muchos datos que no están correctamente clasificados, generando ruido en el modelo y causando que el modelo no categorice correctamente los datos. También puede producirse el fenómeno contrario, que el conjunto de datos sea demasiado pequeño o no sea representativo, lo que da lugar a modelos con malos ajustes.

Para disminuir el *overfitting* las principales acciones son[31]:

- Realizar simplificaciones del modelo (pasar de un modelo polinómico de alto grado a uno lineal).
- Reducir el número de atributos en los datos de entrenamiento.
- Imponer restricciones que limiten la flexibilidad del modelo reduciendo la capacidad de este de aprender del ruido.
- En caso de bases de datos pequeñas, reunir una mayor cantidad de datos.
- Reducir el ruido en los datos de entrenamiento, eliminando *outliners* o datos erróneos.

El caso puesto al overfitting es el *underfitting*. Esta situación ocurre cuando el modelo es excesivamente simple y no puede identificar el patrón y la estructura detrás de los datos. Las principales acciones para disminuir este problema son:

- Elegir un modelo que sea más potente, flexible y adaptable a los datos.
- Utilizar las posibilidades que ofrece el *feature engineering* para proporcionar mejores atributos para el algoritmo.
- En caso de haber regularizado el modelo reducir la intensidad de esta.

La Figura 2.34 muestra una ilustración en la que se observa un ejemplo de overfitting y *underfitting*.

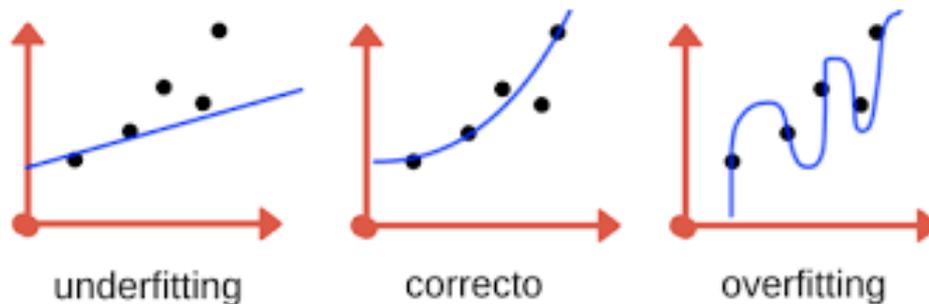


Figura 2.34 Ejemplo de ajuste correcto, *underfitting* y *overfitting*[33].

2.4.5 Aprendizaje supervisado: principales algoritmos

En este apartado se procede a exponer brevemente algunos de los algoritmos de aprendizaje supervisado más relevantes.

2.4.5.1 Regresión lineal

La regresión lineal simple asume una relación matemática lineal entre la variable dependiente o respuesta (Y) y la variable independiente o predictora (X). Para todas las observaciones (X_i, Y_i) puede establecerse una expresión (2.2) donde β_0 es la ordenada en el origen y β_1 la pendiente de la recta de ajuste. El residuo o error aleatorio, ϵ_i , representa la diferencia entre el valor ajustado por la recta y el valor real. El error aleatorio es



impredecible, por ello solo es posible obtener una estimación \hat{Y}_i de la respuesta. β_0 y β_1 representan los parámetros de este modelo[34].

$$(2.2) \quad Y_i = \beta_0 + \beta_1 \cdot X_i + \varepsilon_i \quad \rightarrow \quad \hat{Y}_i = \beta_0 + \beta_1 \cdot X_i$$

La regresión lineal múltiple es una versión extendida de la regresión simple en la cual el valor de la variable dependiente (Y) se determina mediante una relación lineal a partir de un conjunto de predictores (X_1, X_2, \dots, X_n). Un modelo lineal múltiple se representa por medio de la ecuación general (2.3):

$$(2.3) \quad Y_i = \beta_0 + \sum_{j=1}^n \beta_j \cdot X_{ji} + \varepsilon_i \quad \rightarrow \quad \hat{Y}_i = \beta_0 + \sum_{j=1}^n \beta_j \cdot X_{ji}$$

Cada uno de los coeficientes parciales de regresión, β_j , representa la variación experimentada por la variable dependiente Y_i tras incrementar en una unidad el valor de la variable predictora X_{ji} , manteniéndose constantes el resto de las variables. No tiene sentido hacer comparaciones entre los coeficientes parciales de regresión puesto que su magnitud depende de las unidades en las que se haya expresado su correspondiente predictor X_{ji} .

El valor de los coeficientes β_i se puede estimar a través del procedimiento de mínimos cuadrados, que consiste en minimizar la suma de los cuadrados de los residuos, ε_i .

La calidad de ajuste del modelo lineal puede expresarse mediante diferentes indicadores, incluido el coeficiente de determinación, R^2 . Para comprender su significado es necesario introducir las siguientes definiciones:

- **SSR** (*regression sum of squares*), mostrada en la ecuación (2.4), cuantifica, para cada observación, la distancia existente entre el valor de la regresión, \hat{Y}_i , y la recta horizontal correspondiente con el valor medio \bar{Y} de las observaciones; esta recta se asocia con una correlación nula entre los predictores y el predictando.

$$(2.4) \quad SSR = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2$$

- **SSE** (*error sum of squares*), mostrada en la ecuación (2.5), cuantifica la distancia entre las observaciones Y_i y la estimación dada por la regresión, \hat{Y}_i .

$$(2.5) \quad SSE = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

- **SST** (*total sum of squares*), mostrada en la ecuación (2.6), evalúa la diferencia entre las observaciones Y_i y el valor medio \bar{Y} .

$$(2.6) \quad SST = \sum_{i=1}^n (Y_i - \bar{Y})^2$$

En la Figura 2.35 se muestra gráficamente el significado de los términos definidos anteriormente. La optimización de los parámetros de la regresión se basa en minimizar el valor de SSE. Cuando $SSE=0$, la correlación es perfecta, es decir, los residuos ε_i de todas las observaciones son nulos.

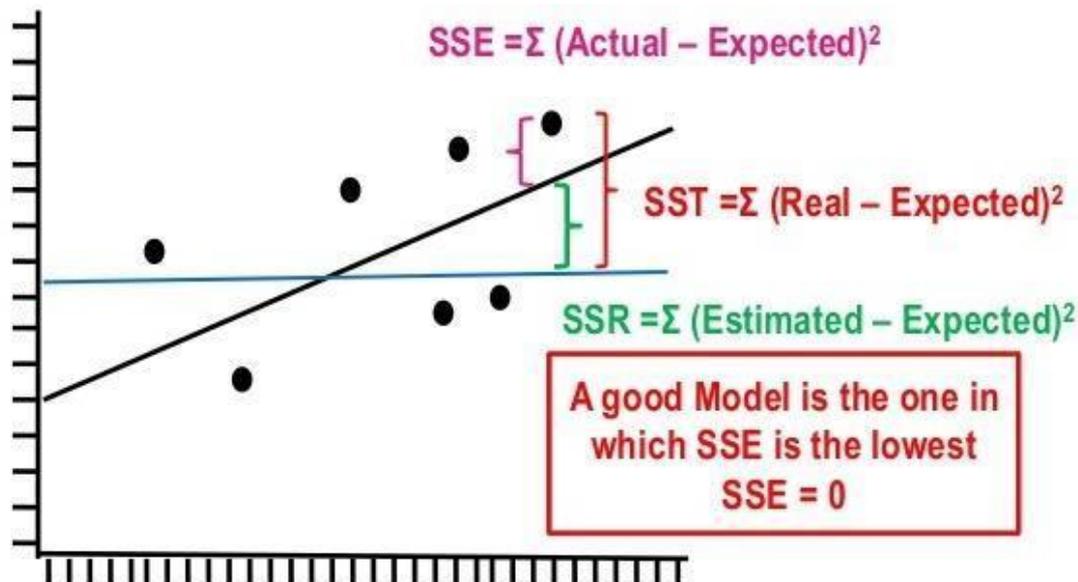


Figura 2.35 Representación gráfica del significado de los términos SSR, SSE y SST empleados para definir el coeficiente de determinación, R^2 [35].

Puede demostrarse fácilmente como se ve en la ecuación (2.7) la relación entre SST, SSR y SSE.

$$(2.7) \quad SST = SSR + SSE$$

El coeficiente de determinación puede expresarse como en la expresión (2.8). De esta forma, para una correlación perfecta $SSE=0$ y, lo que resulta en, $R^2=1$.

$$(2.8) \quad R^2 = \frac{SSR}{SST} = \frac{SST - SSE}{SST} = 1 - \frac{SSE}{SST}$$

2.4.5.2 Regresión logística

La regresión logística es aquella que permite evaluar la probabilidad de que una variable discreta binaria que puede adoptar los valores $Y=0$ o $Y=1$ pertenezca a la clase “1”, en función del valor de una variable continua, X . En la Figura 2.36 se puede observar ejemplo de una clasificación binaria. En este tipo de problemas se trata de obtener una aplicación que tome valores de la variable X y devuelva resultados (continuos) en el intervalo $[0,1]$. Si se empleara una aproximación lineal, como la que se representa en la parte izquierda, se obtendría una función no acotada, pudiendo tomar valores menores que 0 o mayores que 1; sin embargo, la función sigmoide $\sigma(x)$, también llamada curva S , véase la ecuación (2.9), representada en la parte izquierda, sí que respeta este requisito. Esta función contiene dos parámetros (a,b) que se ajustan a partir de las observaciones.

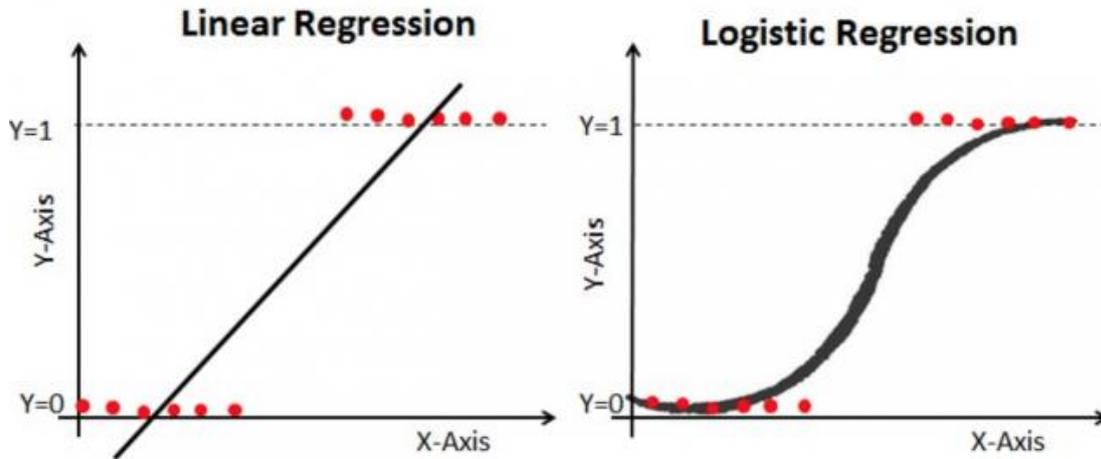


Figura 2.36 Ilustración donde se puede observar la diferencia entre el resultado de una regresión lineal y una regresión logística mediante una función sigmoide en problema de clasificación binaria[36].

$$(2.9) \quad \sigma(x) = \frac{1}{1+e^{-(a+bx)}}$$

Como se ha indicado anteriormente, la función sigmoide permite efectuar una regresión sobre el intervalo [0,1]. Sin embargo, para poder llevar a cabo la clasificación es preciso que esta aplicación se haga sobre los valores discretos {0,1}. Para ello es preciso introducir un umbral (*threshold*), como se describe en la Figura 2.37. De esta forma, aquellas observaciones con una probabilidad superior al umbral (que en el caso de la figura toma un valor arbitrario de 0.5) se les asigna la categoría “1” mientras que al resto se les asigna la clase “0”. Este procedimiento permite, por lo tanto, convertir el algoritmo de regresión representado por la función sigmoide, en un algoritmo de clasificación binaria.

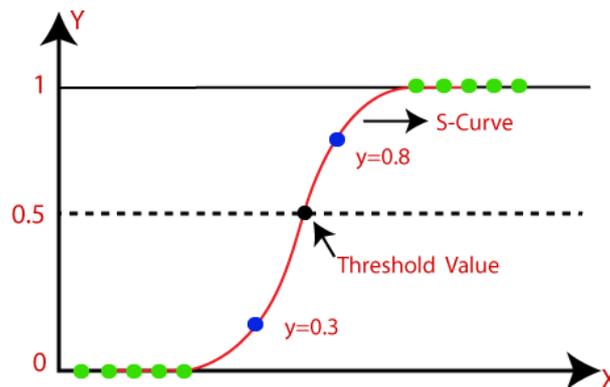


Figura 2.37 La función sigmoide permite asignar una probabilidad a cada observación (valor de la variable predictora, X). Al introducir un umbral (0.5 en el caso de la figura) es posible asignar a cada observación una categoría discreta. Por este motivo, la regresión logística es, en realidad, un algoritmo de clasificación[37].

La biblioteca *Scikit-Learn* incorpora el algoritmo de regresión logística incluyendo las características anteriormente mencionadas así como muchas otras de carácter complementario.

2.4.5.3 *k-Nearest Neighbors*

K-Nearest-Neighbors (KNN) es un ejemplo de algoritmo IBL (*Instance Based Learning*) o algoritmo basado en instancias. En estos algoritmos se crea un modelo a partir de una base de datos y se agregan nuevos datos comparando su similitud con las muestras ya existentes para encontrar los que mejor se asemejan y hacer la predicción. Pueden utilizarse tanto para problemas de clasificación como de regresión. La base de este algoritmo es muy simple, se basa en que los objetos similares suelen encontrarse más cercanos que los objetos diferentes. En la Figura 2.38 se muestra un ejemplo de funcionamiento de este algoritmo en un ejercicio de clasificación donde se ha establecido un número de vecinos $K=3$. La figura muestra tres nuevas observaciones a clasificar, representadas cada una por una estrella. Se puede observar que se han determinado $K=3$ vecinos más cercanos para cada una de ellas. Los vecinos de la que se encuentra en la esquina superior izquierda son dos triángulos rojos y un círculo azul. Dado que la mayoría de los vecinos de esta observación son triángulos rojos, se le asigna esta categoría durante el proceso de clasificación. En el caso de la estrella de esquina inferior derecha sucede lo contrario, asignándosele por tanto un círculo azul.

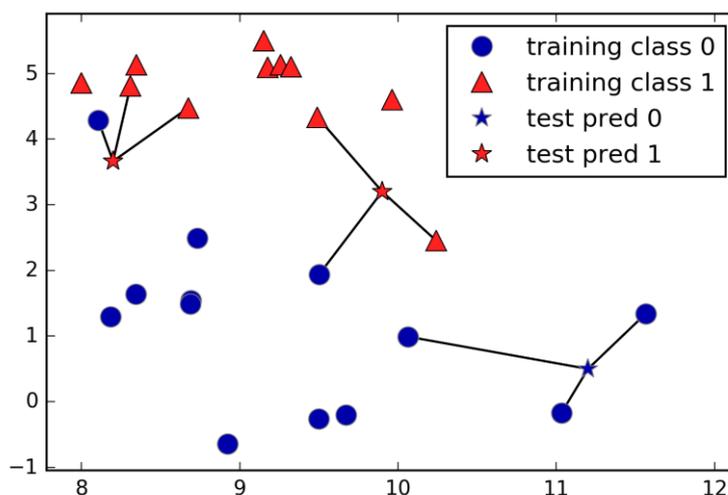


Figura 2.38 Ejemplo del funcionamiento del algoritmo KNN[31].

El número de vecinos cercanos, K , suele ser el principal hiperparámetro a optimizar en este algoritmo. Si se fija un número muy reducido, aumenta la probabilidad de que se produzca un fenómeno de *overfitting*, generándose un modelo sin capacidad para generalizar. Mientras que, con un valor de K muy alto ocurre lo contrario, y da lugar a un modelo muy sesgado con baja capacidad predictiva. Otro parámetro de gran relevancia para este algoritmo es la métrica empleada para definir la distancia en el hiperespacio de las *features*, para lo que suele utilizarse la distancia euclídea.

Entre las ventajas de los algoritmos KNN destaca que se basan en un concepto simple y son fáciles de implementar. La principal desventaja es que requiere mucha memoria y recursos de procesamiento, lo que la hace idónea para conjuntos de datos pequeños con pocos predictores[31].



2.4.5.4 Support Vector Machines

El procedimiento *Support Vector Machines* (SVM) fue desarrollado en la década de los 90 en los AT&T Bell Labs. Originalmente se desarrolló como un método de clasificación binaria extendiéndose su aplicación en problemas de clasificación múltiple y regresión. Estos algoritmos se fundamentan en el concepto del hiperplano, el cual proporciona una separación óptima del hiperespacio de las *features* en dos categorías. El concepto de hiperplano se puede expresar como un subespacio plano y afín de dimensiones $p-1$ de un espacio p -dimensional. El término afín significa que el subespacio no tiene por qué pasar por el origen. En la Figura 2.39 se muestra un ejemplo de separación en un espacio bidimensional (donde el hiperplano será una recta) y tridimensional (donde el hiperplano será un plano).

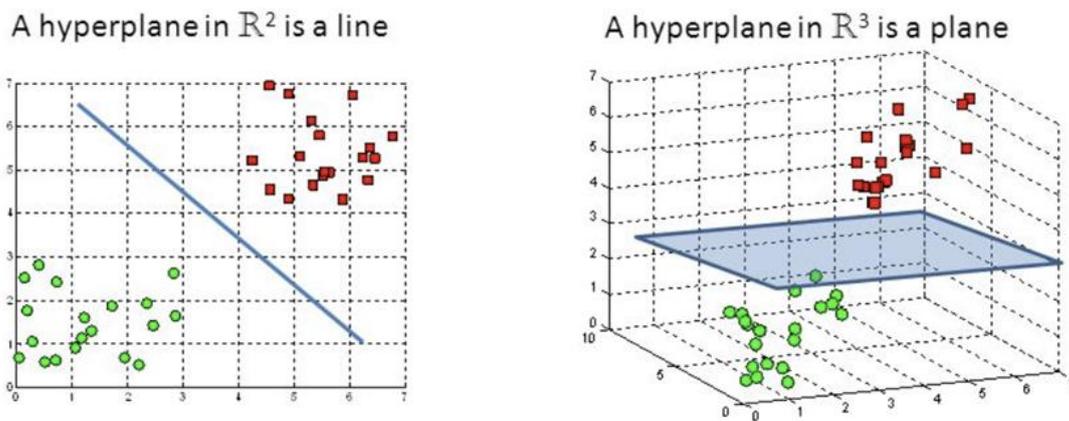


Figura 2.39 En un ejercicio de clasificación con dos *features*, la separación realiza mediante una recta. En un problema con tres *features* se hará mediante un plano[38].

Como se puede observar en la Figura 2.40, existen infinitos hiperplanos que permitan la separación de las *features*, lo que conduce a uno de los conceptos fundamentales del SVM, el hiperplano óptimo de separación, que es aquel definido como aquel que presenta el mayor margen de separación entre las *features*.

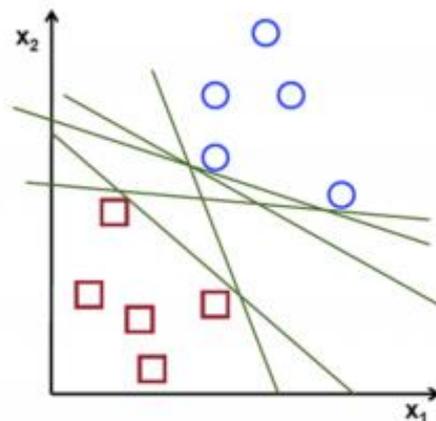


Figura 2.40 Ilustración donde se pueden ver diferentes hiperplanos existentes para un mismo dataset[38].

El hiperplano se calcula a través de la distancia perpendicular entre cada observación y un determinado hiperplano. En la Figura 2.41 se muestra un ejemplo de hiperplano óptimo de separación. Las observaciones utilizadas para calcular el hiperplano se denominan vectores soporte (en el caso de la Figura 2.41, los dos cuadrados rojos y el círculo azul equidistantes frente al hiperplano óptimo) y los cambios de los vectores soporte conlleva cambios en el hiperplano mientras que cambios en las observaciones que no son vector soporte no tienen impacto alguno sobre el hiperplano.

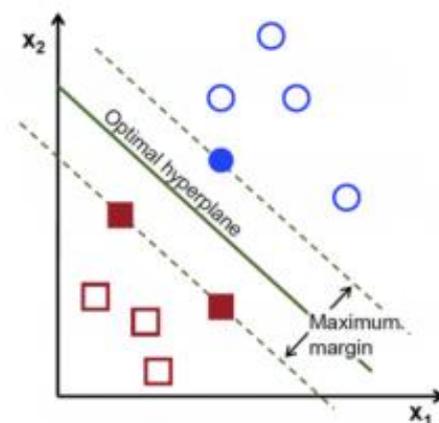


Figura 2.41 Ejemplo de hiperplano óptimo de separación[38].

Cuando se trabaja con problemas reales, casi nunca es posible conseguir una separación perfecta de las *features*. A parte, un hiperplano trazado de esta forma sería muy sensible a los cambios en los datos, dando lugar a problemas de *overfitting*. En estos casos se recurre a lo que esto se conoce como un margen suave (*soft margin*), que será un hiperplano que separe las *features* de la forma más óptima posible aun asumiendo errores. Se incorpora por tanto un parámetro, C ($0 \leq C \leq \infty$), que permite establecer la rigurosidad del *soft margin*[31]. Cuando $C = \infty$, no se permiten errores. Esto se consigue con un número de vectores soporte reducido. Cuando C se aproxima a cero, se permiten más errores, dando lugar a un hiperplano definido por más puntos y un el modelo con mayor sesgo y una menor varianza.

2.4.5.5 Árboles de decisión

Los árboles de decisión al igual que los ya mencionados algoritmos de *K-Nearest-Neighbors* (KNN) son algoritmos IBL. Los árboles de decisión separan el espacio de los predictores en regiones sencillas y homogéneas, facilitando la predicción de la respuesta. Originalmente fueron concebidos para la resolución de problemas de clasificación, pero en la actualidad se utilizan también como algoritmos de regresión.

Los árboles de decisión están formados por ramas y nodos, realizándose la lectura de estos de arriba hacia abajo. Se pueden destacar las siguientes partes:

- El nodo raíz es el nodo principal de un árbol, en él se produce la primera división en función de las variables más importantes



- Los nodos internos muestran las características a tener en cuenta a la hora de tomar una decisión.
- Las ramas muestran la decisión en función de una condición.
- Los nodos finales se encuentran en la parte más profunda del árbol y muestran la decisión final.

La Figura 2.42 muestra un ejemplo de un árbol de decisión sobre un problema de clasificación para un conjunto de datos formado por 100 observaciones con dos variables predictoras, $X[0]$ y $X[1]$, y una variable cualitativa discreta como respuesta. El nodo raíz muestra los datos de estudio, con 50 círculos azules y 50 triángulos rojos, y la condición seleccionada por el algoritmo para realizar la primera división. Los nodos internos muestran cómo se distribuyen los datos en función de si cumplen o no la condición inicial; por ejemplo, en el nodo de la izquierda hay 34 observaciones donde $X[1] \leq 0.0596$, de las cuales 2 son círculos azules y 32 son triángulos rojos. Por otro lado, en el nodo de la derecha se observan 66 observaciones donde $X[1] > 0.0596$, donde 48 de ellas son círculos azules y 18 a triángulos rojos.

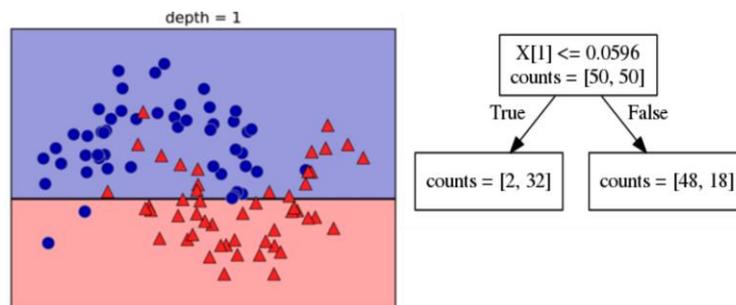


Figura 2.42 Ilustración que muestra la construcción de un árbol de decisión, mostrando el resultado obtenido tras una división (observándose un predominio de los círculos azules en la zona superior y triángulos rojos en la inferior)[31].

Se puede mejorar el modelo anterior repitiendo el proceso de división en ambas regiones. La Figura 2.43 muestra el resultado de, como a medida que se aumentan las divisiones, se vuelven cada vez más homogéneas, consiguiéndose mayor precisión.

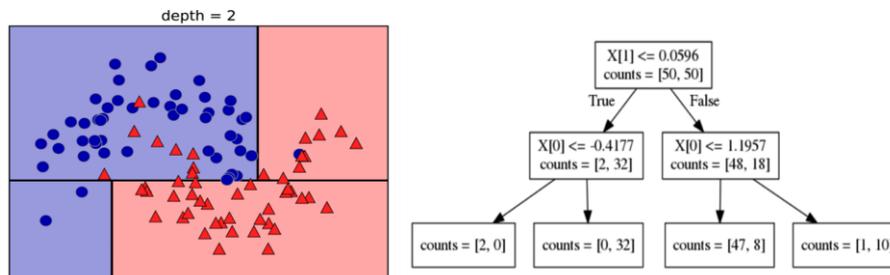


Figura 2.43 Ilustración donde se muestra como mejora la precisión a medida que aumentan las divisiones, mostrando el resultado obtenido tras dos divisiones[31].

Este proceso de división se puede continuar hasta conseguir que en los nodos finales solo existan observaciones de una clase como se ve en la Figura 2.44. Estos modelos suelen acabar sufriendo problemas de overfitting y teniendo poca capacidad de predicción

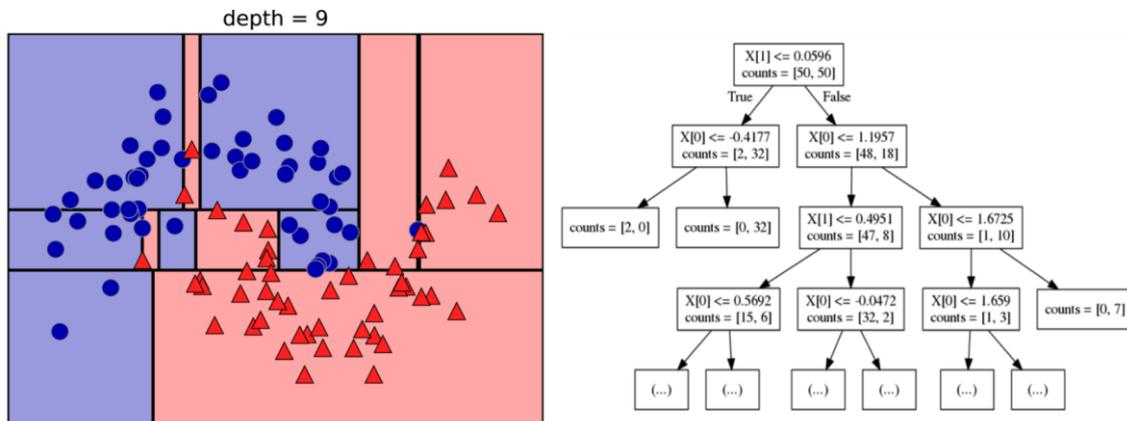


Figura 2.44 Ilustración que muestra cómo tras muchas divisiones puede llegarse a un modelo que presente únicamente observaciones de una clase en los nodos finales[31].

Entre las principales ventajas de los árboles de decisión pueden citarse las siguientes[31]:

- Son modelos de fácil construcción, interpretación y visualización.
- La distribución de los datos no tiene que cumplir ninguna condición.
- Requieren menor trabajo de curado y preprocesado de los datos.
- Toleran bien la presencia de valores atípicos y *outliners*.
- Son buenos en el reconocimiento de variables importantes, pudiendo seleccionar predictores automáticamente,

Como principal desventaja se puede destacar su tendencia al overfitting.

2.4.5.6 Métodos ensemble

Los métodos ensemble son aquellos que utilizan la combinación de múltiples algoritmos para generar un modelo con una mayor predicción que la obtenida a través de un único algoritmo. Generalmente suelen usarse como algoritmos de base los árboles de decisión ya que son algoritmos rápidos y simples. Principalmente se distinguen dos procedimientos para definir un ensemble; *Bagging* y *boosting*[31].

El método *bagging* o *bootstrap aggregation* utiliza muestras extraídas del conjunto de datos de entrenamiento como si fueran el conjunto completo. De esta forma se entrenan al mismo tiempo muchos árboles diferentes a través de muestras de datos del conjunto original. La clasificación final se puede hacer en base de la predicción mayoritaria de los árboles o puede hacerse basándose en la probabilidad asignada por cada árbol a las variables. Este método es muy eficaz en modelos complejos y con tendencia al sobreajuste. Las principales etapas de este método son:

1. Partiendo de un conjunto de entrenamiento, X , de tamaño n , se forman m nuevos conjuntos de entrenamiento, denominados X_i , de tamaño n' , de los cuales se toman al azar elementos de X de manera uniforme y con reemplazo,



encontrándose de esta forma algunos datos del conjunto original repetidos en los nuevos conjuntos generados.

2. Para valores de n grandes y con $n' = n$ se cumplirá que cada X_i tenga $1 - 1/e$ elementos de X , lo da como resultado un 63,2% de elementos únicos en X_i .
3. Se construirán m modelos de aprendizaje, siendo la respuesta generada mediante promedio de la predicción de cada uno de los modelos.

El método *boosting* a diferencia del de *bagging* trabaja con en conjunto completo de datos. Este método varía el peso de los datos, de forma que, el peso de los objetos que están mal clasificados por el predictor aumenta en cada iteración, por lo que en la construcción del próximo predictor, estos objetos serán más importantes y tendrán más probabilidades de ser bien clasificarlos. Se trata por tanto de un método iterativo en el cual en cada iteración se van corrigiendo los errores anteriores.

En la Figura 2.45 se puede ver una imagen que muestra un esquema con el funcionamiento de cada modelo.

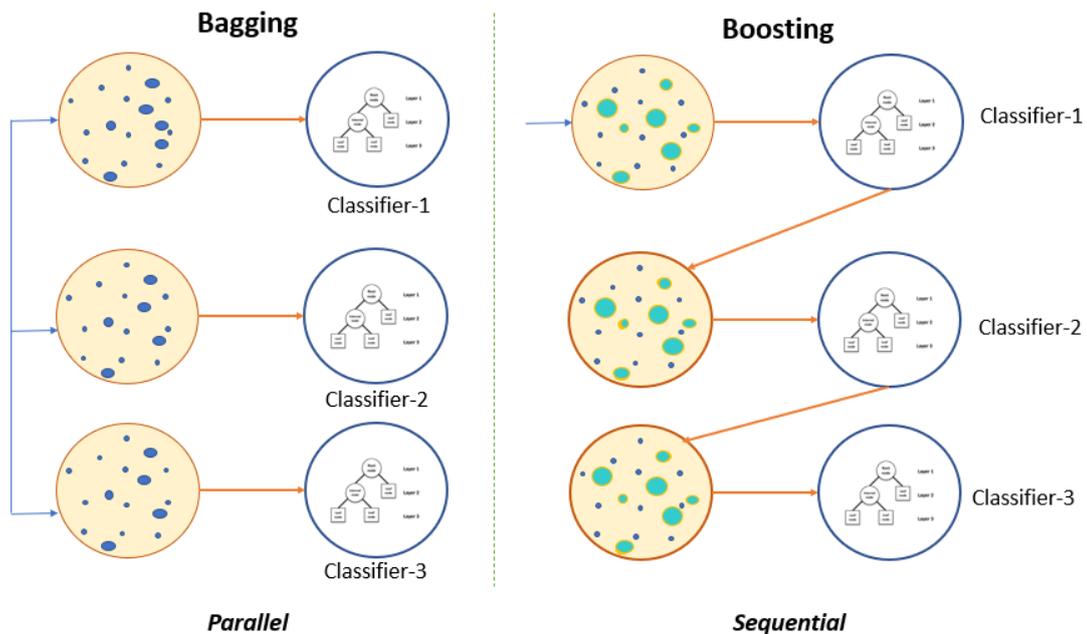


Figura 2.45 Ilustración de los métodos de bagging (izquierda) y boosting (derecha)[39].

2.4.5.7 Redes Neuronales Artificiales

Las redes neuronales artificiales (*Artificial Neural Networks*, ANN) son modelos cuyo funcionamiento está basado en el sistema nervioso, tratando de simular la forma en la que el cerebro procesa la información. En un cerebro humano hay presentes unas 10^{11} neuronas interconectadas entre sí, estando cada neurona conectada con otras 7000. Las neuronas intercambian información entre ellas a través de impulsos electroquímicos, recibiendo la información (*inputs*) a través de unas estructuras denominadas dendritas y transmitiéndolas a la siguiente neurona (*outputs*) a través de otra estructura denominada axón.

En computación, una neurona se simula a través de lo que se denomina el perceptrón, que, a través de unos valores numéricos de entrada al núcleo (*inputs*), donde son ponderados mediante unos pesos y un término independiente. A este resultado se aplica una función, imitando el funcionamiento de la sinapsis, que produce el resultado del perceptrón (*output*). En la Figura 2.47 se puede muestra una ilustración con el funcionamiento del perceptrón, donde se ve como las variables $\{x_i\}$ representan los valores numéricos de entrada, $\{w_i\}$ los pesos y ‘b’ es el término independiente. En esta ocasión la función de activación es una función escalón que se activa al superar un cierto umbral, pudiendo existir otras como la función tangente hiperbólica

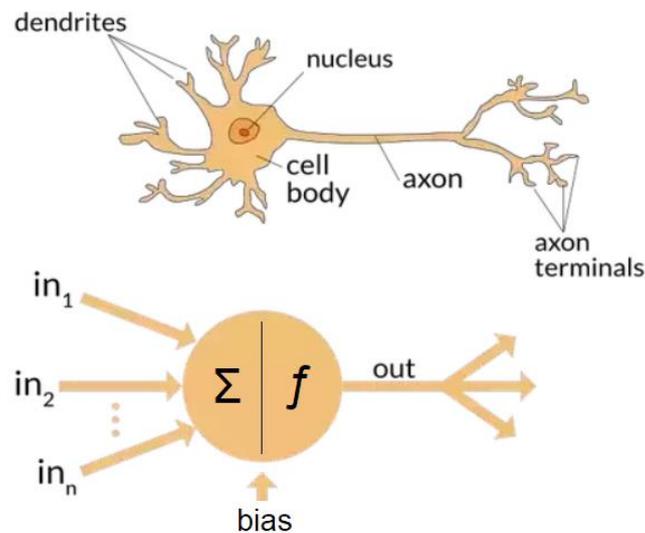


Figura 2.46 Ilustración que muestra las semejanzas entre una neurona y un perceptrón[40].

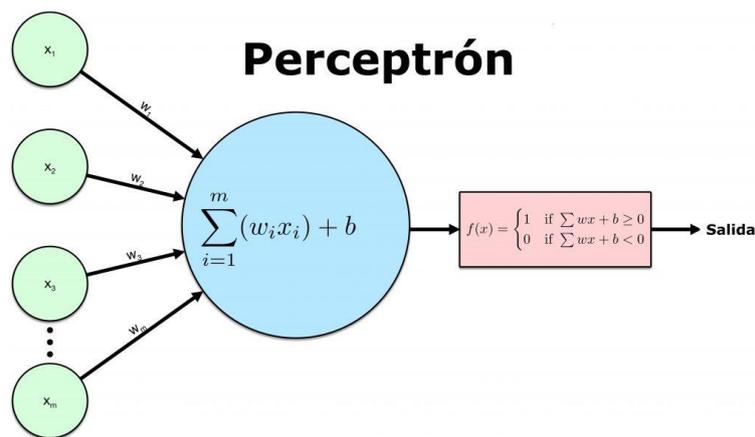


Figura 2.47 Funcionamiento básico de un perceptrón[41].

Un perceptrón simple presenta el problema de no poder resolver problemas no lineales, lo que se soluciona mediante la utilización de varias capas, lo que se denomina perceptrones multicapa o *Multilayer Perceptron*. Un perceptrón multicapa funciona de forma que, la capa de entrada recibe la información de entrada. En la primera capa oculta la información de entrada se procesa y envía a la siguiente capa, donde se repetirá el proceso hasta conseguir un resultado (*output*). El entrenamiento de la red neuronal tiene



como objetivo ajustar los pesos hasta que el algoritmo sea capaz predecir los valores de salida. En la Figura 2.48 se muestra un esquema de una red neural.

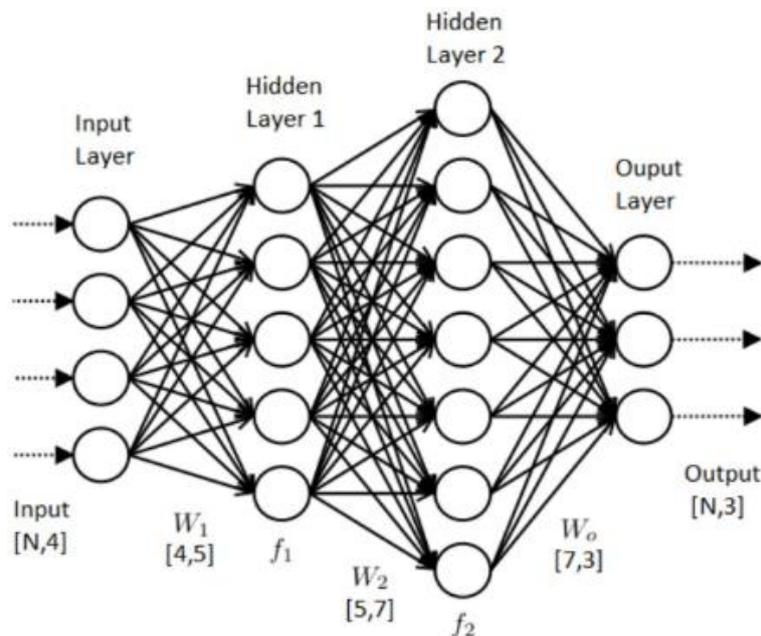


Figura 2.48 Esquema de una red neuronal multicapa[42].

2.4.6 Entrenamiento de un algoritmo de aprendizaje supervisado: *train, validation, test*

Para el entrenamiento de un algoritmo de *machine learning* se divide el conjunto de datos (*dataset*) en dos grupos; un primer conjunto será el de los datos utilizados para entrenar el modelo (conjunto de *train*) y el otro conjunto se para la evaluación de la capacidad de predicción del modelo (conjunto de *test*). Generalmente estos conjuntos se suelen dividir de forma que un 75% del *dataset* se utiliza como de datos de entrenamiento y un 25% de datos de test. El error en el conjunto de test se denomina error de generalización. Cuando el algoritmo presenta un error reducido en el conjunto de datos de entrenamiento, pero elevado en el conjunto de tes, se habla de *overfitting*, cuando presenta lo contrario el algoritmo presentara *underfitting*.

Los datos del conjunto de *train* permite afinar los valores de los parámetros e hiperparámetros del algoritmo, entendiéndose como parámetros del modelo aquellas variables cuya configuración es interna al modelo, es decir, pueden ser estimadas a partir de los datos. Los hiperparámetros del modelo son aquellas variables cuya configuración es externa al modelo y no pueden estimarse a partir de los datos, debiendo ser especificados manualmente. Para evaluar los hiperparámetros en ocasiones se selecciona un conjunto de datos denominado conjunto de validación o *validation set*.

Para, denominado de validación (*validation set*). En definitiva, los hiperparámetros se seleccionan sobre el *validation dataset* y la calidad final del modelo (el error de generalización) sobre el *test dataset*.

Una técnica utilizada frecuentemente para maximizar el aprovechamiento de los datos es la validación cruzada. La validación cruzada divide los datos en distintos subconjuntos, entrenando un modelo en cada subconjunto y evaluándolo con los complementarios. En la Figura 2.49 se observa cómo se utiliza el 75% de los datos para el entrenamiento del modelo 1 mientras que se utiliza el primer 25% para la evaluación del mismo. Esto se realiza de forma complementaria en los otros 3 modelos restantes.



Figura 2.49 Ejemplo de repartición de los datos en una validación cruzada[43].

En la Figura 2.50 se muestra en esquema con los pasos más importantes para el entrenamiento de un modelo de *machine learning*.

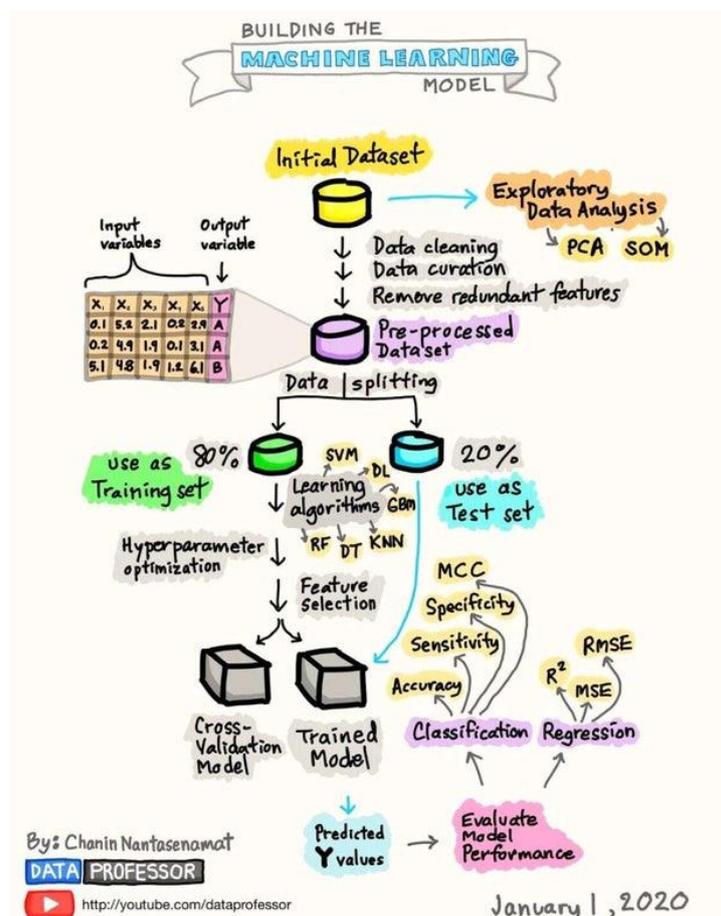


Figura 2.50 Esquema del proceso a seguir para la construcción de un modelo machine learning[44].



Capítulo 3 PROBLEMÁTICAS, MATERIALES Y MÉTODOS

3.1 Introducción

En este capítulo que se presenta a continuación se ahonda en los materiales y procedimientos empleados en el estudio. El capítulo se ha estructurado de forma que se comienza explicando la problemática existente en el acero de los muelles, así como los fundamentos teóricos y prácticos en los que se basa este estudio. Para terminar, se explica el procedimiento seguido para el tratamiento de los datos utilizando la metodología *machine learning*.

3.2 Problemática del acero de muelles

El sistema de suspensión de un vehículo está formado por numerosos elementos mecánicos, siendo los muelles uno de los principales. Los muelles o resortes juegan un papel fundamental por distintas razones, por el lado de la seguridad, tienen la misión de mantener el contacto del neumático con el asfalto, asegurar la estabilidad del vehículo proporcionar un mayor control sobre el mismo. Por otro lado, juegan un papel importante en el confort de los ocupantes, absorbiendo gran parte de las irregularidades presentes en las carreteras. Para asegurar que el muelle trabaje dentro del rango de movimiento para el que fue diseñado se utilizan los amortiguadores, que evitan elongaciones excesivas de este. En la Figura 3.1 se puede ver un esquema con las partes más relevantes del sistema de suspensión de un vehículo.

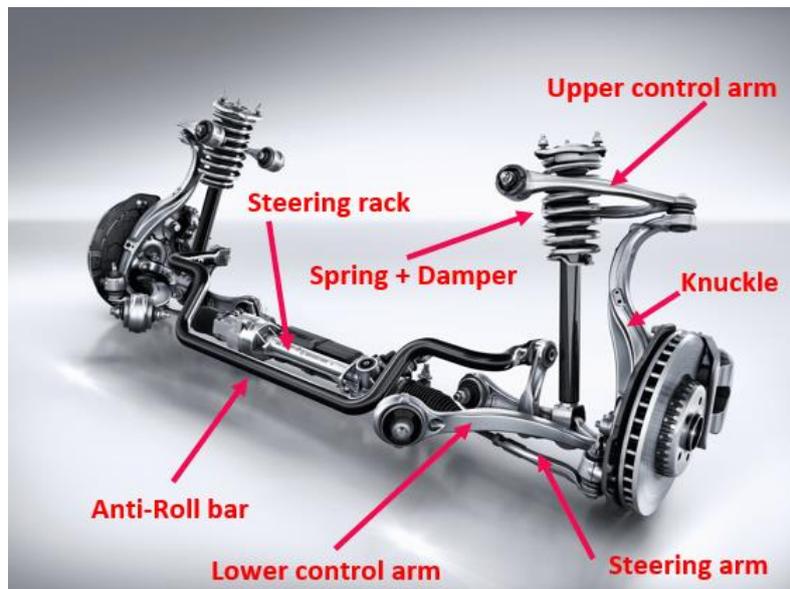


Figura 3.1 Componentes del sistema de suspensión en un automóvil[45].

Los muelles se fabrican en base a alambres de acero con diámetros de entre 10 y 15 mm enrollado de forma helicoidal. Los muelles actúan básicamente almacenando energía mediante la deformación elástica al verse sometidos a un esfuerzo, liberándola y recuperando su forma original una vez cesa el esfuerzo. Hay que tener en cuenta que la

rigidez, entendiéndose esta como la resistencia a la deformación elástica, del muelle depende del diámetro del alambre y de las características geométricas del muelle. Al variar estas características se pueden dar lugar a distintos tipos de muelles como los que se observan en la Figura 3.2.

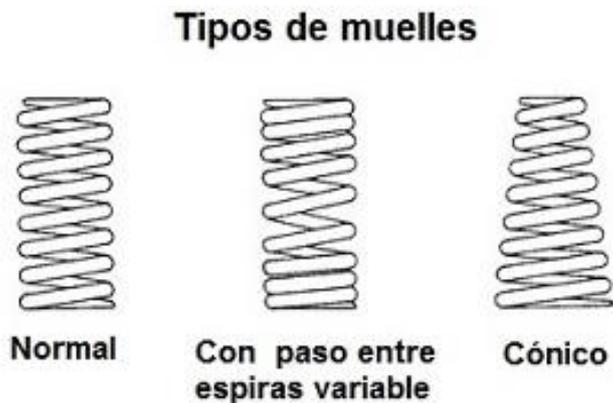


Figura 3.2 Diferentes tipologías de muelles existentes en el mercado[46].

Generalmente los muelles utilizados en los sistemas de suspensión de vehículos están diseñados para trabajar en compresión. En la Figura 3.3 se observan los esfuerzos presentes en el muelle al ser sometido a una carga junto con los estados tensionales resultantes en cada sección. Puede verse que para equilibrar la fuerza de compresión actuante F , se requiere un esfuerzo cortante de valor F y un par de torsión de valor $F \cdot r$, siendo " r " es el radio medio de la espira. También se pueden apreciar el estado de tensión asociado con cada una de estas dos tensiones, en una sección transversal de alambre (en un diámetro perpendicular al eje del muelle). Como se observa, la tensión tangencial máxima se produce en la fibra más interna del alambre. Para realizar un cálculo aproximado que nos permita estimar el valor de la tensión se puede recurrir al principio de superposición, donde la tensión máxima total será la resultante de la suma que se obtiene a partir del cortante ($\tau_{d,max}$) que se puede ver en la ecuación (3.1), y del torsor ($\tau_{t,max}$), ecuación (3.2)[47].

$$(3.1) \quad \tau_{d,max} = \frac{4F}{3A} = \frac{4F}{3\left(\frac{\pi D^2}{4}\right)} = \frac{16 F}{3\pi D^2}$$

$$(3.2) \quad \tau_{t,max} = \frac{TR}{J} = \frac{\left(\frac{F \cdot d}{2}\right) \frac{D}{2}}{\frac{\pi D^4}{32}} = \frac{8 F d}{\pi D^3}$$

donde R es el radio y D diámetro del alambre, d es el diámetro del muelle y J representa la inercia polar de la sección resistente. Se puede aproximar el resultado de forma que, ecuación (3.3):

$$(3.3) \quad \tau_{max} = \tau_{d,max} + \tau_{t,max} = \frac{8 F}{\pi D^2} \left(\frac{2}{3} + \frac{d}{D} \right)$$

Al tener en cuenta el denominado efecto de curvatura, por el cual el esfuerzo en el interior del muelle se ve incrementado y disminuye en la parte exterior se puede utilizar la ecuación (3.4), atribuida a A.M. Wahl[48]. Ese efecto es relevante en condiciones de fatiga.



$$(3.4) \quad \tau_{max} = k_w \frac{8 F d}{\pi D^3}$$

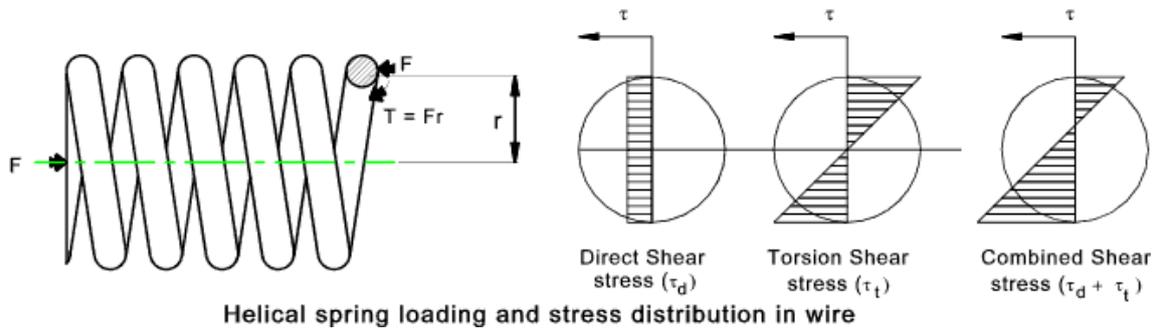


Figura 3.3 Ilustración que muestra el efecto del esfuerzo cortante y el momento torsor actuante sobre la sección normal de un muelle junto con la distribución de tensiones presente en el mismo[49].

Estos componentes se ven sometidos a cargas cíclicas a lo largo de su vida útil, lo que provoca que la fatiga termine siendo el principal mecanismo de rotura de los muelles. La rotura por fatiga puede tener dos orígenes, defectología superficial o presencia de inclusiones no metálicas en su interior. Así pues, en la Figura 3.4 se muestra una fotografía de un componente tras la rotura observándose cómo un defecto superficial supuso la rotura del muelle debido a un fenómeno de fatiga.

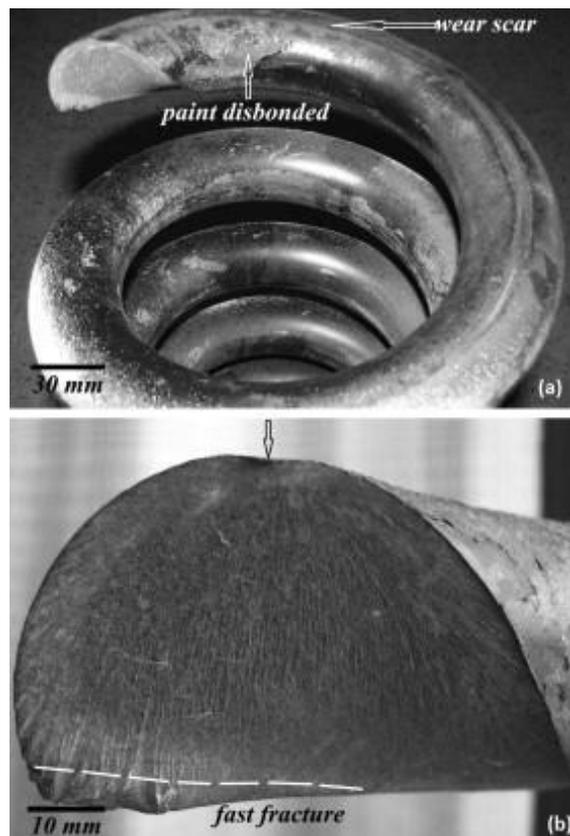


Figura 3.4 (a) Fotografía de un muelle en el que se observa una rotura por fatiga. (b) Imagen extraída del SEM en la que se aprecia la zona de la superficie donde se inicia la fatiga[50].

En la Figura 3.5 se muestran algunos ejemplos de imágenes obtenidas a través del SEM que muestran a las inclusiones como fenómenos causantes de la rotura del elemento.

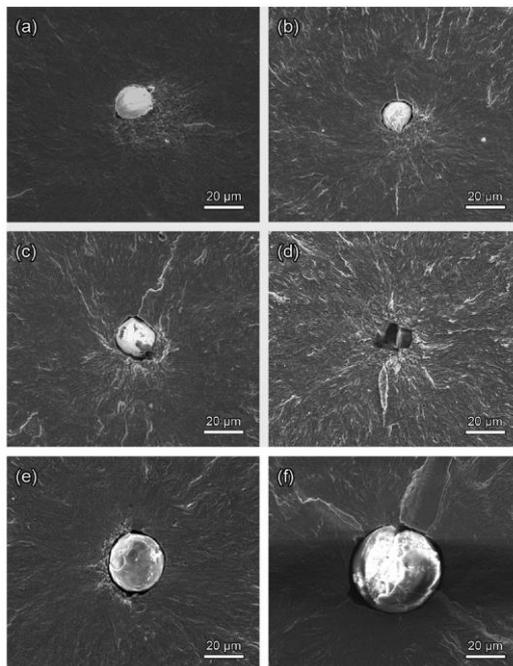


Figura 3.5 Ilustración que muestra algunas inclusiones no metálicas como responsables de la iniciación de fallo por fatiga[51].

Este trabajo tiene como objetivo mejorar el rendimiento a la fatiga de los muelles de suspensión fabricados por MUBEA utilizando alambra de acero 54SiCr6 de alta calidad proporcionado por GSW. Se han caracterizado mediante ensayos de flexión rotatoria la resistencia a la fatiga de un gran número de barras de acero para muelles de diferentes coladas de GSW en sus condiciones finales de fabricación. Los resultados obtenidos se han modelado mediante *machine learning* para optimizar su comportamiento y determinar las variables más relevantes.

3.3 Materiales y métodos

En este apartado se presentarán las características de los materiales caracterizados y las técnicas experimentales implementadas para tal propósito.

3.3.1 Materiales y métodos del estudio sobre el acero de muelles: caracterización del comportamiento frente a fatiga

La composición del acero del alambra de calidad C54SiCr6 fabricado por GSW y empleado por MUBEA para la fabricación de los muelles es la que se muestra en la Tabla 3.1



	Min	Max
C	0,54	0,56
Mn	0,67	0,72
Si	1,4	1,5
P		0,015
S		0,015
Cr	0,65	0,7
Ni		0,08
Cu		0,08
Mo		0,02
Sn		0,015
Al		0,002
V		0,01
N		0,007
B		0,0005
Pb		0,03

Tabla 3.1. *Composición química (% en peso) especificada para el acero de muelles C54SiCr6.*

MUBEA somete al alambroón a diferentes etapas para transformarlo en muelles de calidad que puedan ser empleados en los sistemas de suspensión de los vehículos. En la Figura 3.6 se puede observar un esquema con las principales etapas llevadas a cabo por MUBEA.

- El proceso se inicia con un enderezado del rollo de alambroón y un decapado mecánico para eliminar las posibles impurezas presentes. Tras esto, se pasa el alambroón por un control a través de corrientes inducidas para detectar posibles defectos, parándose la línea y corrigiéndose el defecto en caso de encontrar alguno. Para terminar esta primera etapa el material se calibra y se vuelve a enrollar.
- En la segunda etapa el material se desenrolla y se somete a un tratamiento de temple y revenido por inducción. Tras esto se pasa por un segundo control de defectos, donde en caso de ser encontrado algún defecto, se etiqueta y los muelles fabricados con este material serán eliminados. El material se vuelve a enrollar.

Optimización del comportamiento frente a fatiga del acero para muelles mediante el uso de algoritmos *Machine Learning*

- La última etapa se realiza tras haber reposado el material para eliminar posibles tensiones residuales, procediéndose al conformado del muelle sobre el que se aplica un tratamiento de granallado superficial (*shot peening*) para finalmente pintar el muelle para prevenir la corrosión de este.

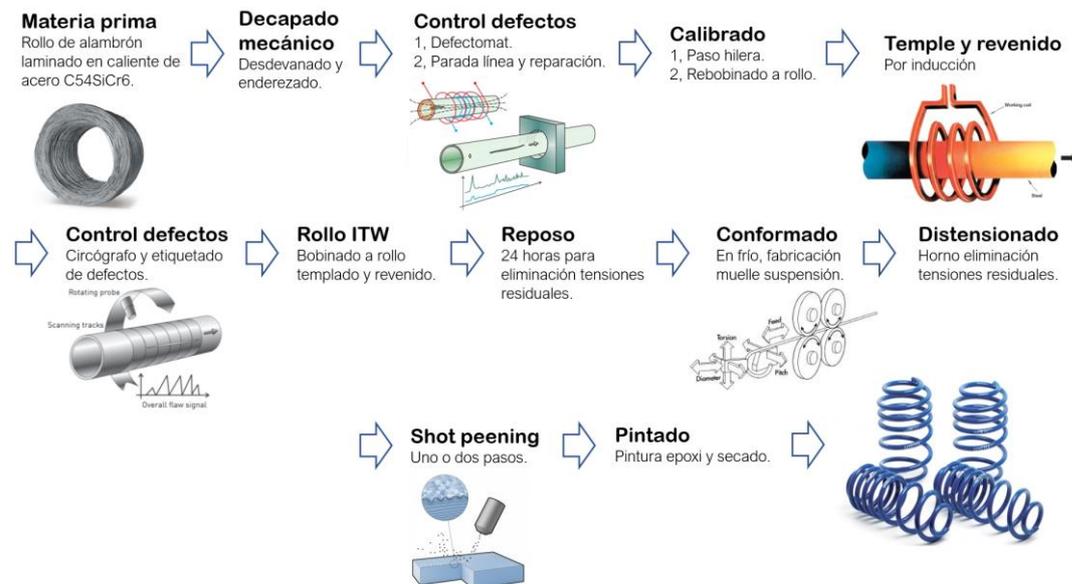


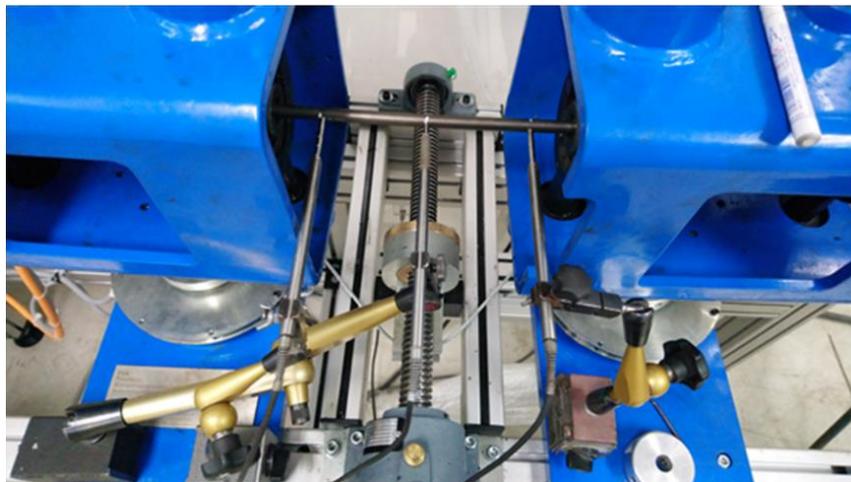
Figura 3.6 Ilustración que muestra las diferentes etapas que componen el proceso de fabricación de los muelles a partir de alambrión en las instalaciones de MUBEA.

Las barras utilizadas en el LADICIM para la caracterización del compartimiento frente a fatiga son barras rectas, proporcionadas por MUBEA e iguales a las empleadas por ellos para fabricación de muelles, salvo que no han sido sometidas al proceso de bobinado, lo que no parece que deba influir en su comportamiento mecánico ya que, tras el proceso de bobinado se eliminan mediante un tratamiento térmico las posibles tensiones residuales presentes en los mismos.

La caracterización del comportamiento a fatiga se ha realizado mediante el ensayo de flexión rotatoria, regulado por la norma ISO 1143:2010[52]. Este método se consiste en flectar una barra de alambrión de aproximadamente 1,5 metros de largo y diámetros que varían entre los 10 y los 13 mm mientras se hace girar a la misma alrededor de su eje. Como la probeta se encuentra sometida a esfuerzos de flexión, las tensiones máximas se producirán en el contorno de la barra. En la Figura 3.7(a) se muestra una fotografía de la máquina empleada para la ejecución de los ensayos. Esta máquina fue calibrada para comprobar la calidad precisión del momento flector obtenido. Esta calibración se realizó sometiendo una barra de acero calibrado a momentos flectores crecientes, desde 0 hasta 50 N.m en intervalos de 5 N.m, en la cual se midió la deflexión. Como se puede ver en la Figura 3.7 (b), la flecha se determinó utilizando 3 LVDT, situando uno en el centro, lugar que presenta la flecha máxima, y uno en cada uno de los extremos de la barra.



(a)



(b)

Figura 3.7 Ilustración donde se observa la maquina utilizada para la realización de los ensayos de fatiga rotatoria. Se muestra también el montaje utilizado para la calibración de la máquina.

Basándose en los datos históricos de los ensayos de calidad realizados en MUBEA, se estableció un valor de amplitud de tensiones $\sigma_a=400$ MPa. Los resultados obtenidos se compararon con los que se pueden extraer utilizando las expresiones teóricas derivadas de la resistencia de materiales[47]. La Figura 3.8 muestra la buena relación existente entre los resultados obtenidos experimental y teóricamente.

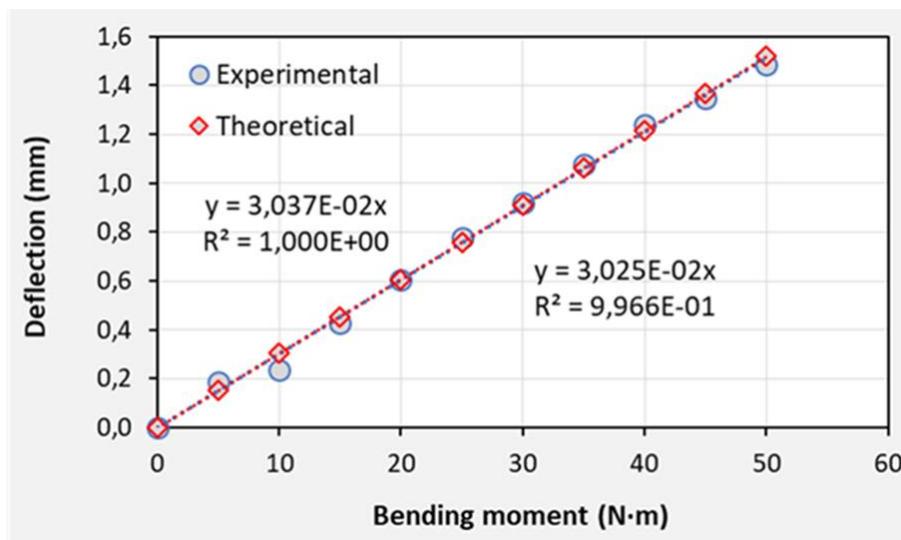


Figura 3.8 Gráfico donde se puede observar la buena relación existente entre la flecha en la barra calculada mediante expresiones empíricas y la flecha obtenida experimentalmente en la máquina de fatiga rotatoria existente en el LADICIM.

Para este estudio se han caracterizado dos rollos de cada colada, uno de una de las líneas centrales de la colada continua y el otro de una línea exterior, pudiendo así evaluar la posible diferencia existente entre material de distintas líneas. Se han caracterizado 27 de variables de procesado y un total de 529 ensayos.

3.4 Algoritmos *Machine Learning*

Este apartado comienza mostrando las tareas de limpieza y preparación de los datos llevadas a cabo sobre los *datasets*. Posteriormente, se presentan los algoritmos implementados para el modelado de los datos. Por último, se introducen dos herramientas utilizadas en la interpretación de los modelos de *machine learning*. Por un lado, las técnicas de *feature importance* y de *permutation importance*, que permiten identificar los atributos más relevantes sobre el valor de la variable objetivo; por otro lado, las *partial dependence plots*, que proporcionan la relación de dependencia entre cada variable y el objetivo.

3.4.1.1 Limpieza y preparación de los datos

En todos los proyectos de *machine learning* la preparación de los datos es una de las tareas principales ya que, de su calidad dependerá la precisión del modelo obtenido. Las tareas más importantes que se realizan durante esta etapa son[53]:

- Clasificación de las variables en cuantitativas, que pueden ser continuas (aquellas que pueden tomar infinitos valores dentro de un intervalo de datos) y discretas (aquellas que pueden tomar un número finito de valores dentro de un intervalo de datos) o cualitativas, que pueden a su vez ser ordinales (aquella que se puede dividir en diferentes niveles) o nominales (aquella que presenta cualidades no numéricas y sin ningún criterio de orden).
- Imputación de datos perdidos. Los *datasets* con frecuencia suelen presentar datos perdidos que suponen un problema para su análisis. En grandes conjuntos de datos,



que presentan una proporción de pérdida pequeña se puede recurrir a la eliminación de estos, pero en conjuntos pequeños o con gran proporción de pérdida se requiere una solución, ya que no es asumible la pérdida de información. Para este estudio solo se han eliminado aquellas variables que presentaban un alto porcentaje de valores perdidos (por encima del 60%). Para el resto de las variables se ha recurrido a las técnicas de imputación de datos perdidos.

- Detección y eliminación de *outliners*. Los *outliners* o valores atípicos son valores que se escapan del rango normal de valores presentes dentro de nuestro *dataset*. Estos valores se pueden deberse a multitud de causas, como pueden ser errores en la toma de datos, fallos al cargar los mismo, defectos en las muestras, etc. Cualquiera sea el motivo de la presencia de estos en nuestro *dataset*, se requiere de la detección y eliminación de estos, puesto que pueden afectar a la capacidad predictiva del modelo. Existen métodos estadísticos que ayudan a la detección de *outliners*, como el *z-score*, que indica el número de desviaciones estándar que se aleja un valor de la media; solíéndose desechar aquellos valores que presentan un rango de $|z| > 3$.
- Eliminación de valores con varianzas nulas o cercanas a cero puesto que su valor será igual o prácticamente igual para todas las observaciones, lo que introduce ruido en nuestro modelo
- Detección de multicolinealidad: la multicolinealidad se puede entender como una fuerte relación existente entre variables independientes, de forma que se entorpece la predicción de la variación de los valores de la variable dependiente. Para la detección de multicolinealidad en este estudio se ha utilizado el coeficiente de correlación lineal de Pearson, eliminándose una de las variables en observaciones donde se han detectado correlaciones superiores a 0.7.

3.4.1.2 Separación en conjuntos de *train* y de *test*

Una vez curados los datos, estos se separan aleatoriamente en dos conjuntos: uno de *train* y otro de *test*, aplicando una relación 75/25. Como ya se ha explicado en el apartado 2.4.6, se usarán los datos de *train* para entrenar los diferentes algoritmos y generar el modelo, mientras que los datos de *test* se reservarán para evaluar su capacidad predictiva, asegurándose así una evaluación no sesgada del modelo.

3.4.1.3 Preprocesado

El siguiente paso es realizar las tareas de preprocesado, incluyéndose aquí todas las transformaciones necesarias en los datos, para que el algoritmo de *machine learning* los interprete de la manera más eficiente posible. El procesado de datos se aplica inicialmente sobre el conjunto de *train* para después aplicarse al conjunto de *test*. Las principales partes del preprocesado son [31], [54]:

- Transformación de las variables categóricas en numéricas. En este estudio se ha realizado a través del algoritmo *one-hot-encoding* que consiste en crear una columna nueva para cada valor distinto presente en las características que se están codificando.

- Los *datasets* que tienen características con valores numéricos incluidas en un intervalo similar generan algoritmos más precisos, debido a que, de no ser así los predictores con mayor varianza suelen sobreponderarse en el modelo, infravalorando el resto de las variables y sesgando el resultado del análisis. Las dos principales acciones para corregir este problema son; la normalización, mostrada en la fórmula (3.5), consiste en escalar cada característica para que sus valores pertenezcan al intervalo [0,1]; y la estandarización, presentada en la fórmula (3.6), restando la media de la muestra y dividiendo el resultado por la desviación estándar de la muestra.

$$(3.5) \quad X \rightarrow \frac{X - X_{min}}{X_{max} - X_{min}}$$

$$(3.6) \quad X \rightarrow \frac{X - \mu}{\sigma}$$

3.4.1.4 Selección de métricas

Antes de empezar el entrenamiento del modelo se deben seleccionar las métricas que se van a utilizar para evaluar su rendimiento. En este estudio se ha utilizado el coeficiente de determinación, R², y el error cuadrático medio en los problemas de regresión donde la variable a predecir es un valor numérico. Por otro lado, se ha utilizado la matriz de confusión para problemas de clasificación donde la variable a predecir es categórica. En la Figura 3.9 se observa un ejemplo de matriz de confusión para una variable binaria, con dos posibles resultados, positivo (P) y negativo (N).

Matriz de confusión		Estimado por el modelo			
		Negativo (N)	Positivo (P)		
Real	Negativo	a: (TN)	b: (FP)	Precisión ("precision") Porcentaje predicciones positivas correctas:	d/(b+d)
	Positivo	c: (FN)	d: (TP)		
		Sensibilidad, exhaustividad ("Recall") Porcentaje casos positivos detectados	Especificidad ("Specificity") Porcentaje casos negativos detectados	Exactitud ("accuracy") Porcentaje de predicciones correctas (No sirve en datasets poco equilibrados)	
		d/(d+c)	a/(a+b)	(a+d)/(a+b+c+d)	

Figura 3.9 Ejemplo de matriz de confusión para una variable binaria junto con algunas de sus principales métricas[55].

La matriz de confusión se interpreta de forma que, en la diagonal principal de la matriz se muestran los valores estimados correctamente por el modelo que pueden ser, *True Negative*, TN (aquellos valores que el modelo clasifica como negativos y son negativos en la realidad) y *True Positive*, TP (aquellos valores que el modelo clasifica como positivos y son positivos en la realidad). Por el contrario, en la diagonal secundaria se muestran los errores cometidos por el sistema, estos pueden ser *False Positives*, FP



(aquellos valores que el modelo clasifica como positivos y son negativos en la realidad) y *False Negatives*, FN (aquellos valores que el modelo clasifica como negativos y son positivos en la realidad). Las principales métricas que se pueden extraer de la matriz de confusión son las siguientes[56]:

- La exactitud o *Accuracy* representa la proporción de predicciones correctas frente al número total de observaciones, véase la fórmula (3.7). Esta métrica no es aconsejable cuando hay un sobre peso muy grande en una de las variables, ya que podría darse el caso de que con un *accuracy* elevado la capacidad de predicción sea mala.

$$(3.7) \quad Accuracy = \frac{TP+TN}{TP+FP+FN+TN}$$

- La sensibilidad, exhaustividad o *Recall*, representa la proporción de observaciones positivas bien clasificadas, TP, que el modelo es capaz de detectar de entre todas las observaciones, ecuación (3.8).

$$(3.8) \quad Recall = \frac{TP}{P} = \frac{TP}{TP+FN}$$

- La precisión, representa la proporción de aciertos entre las observaciones que el modelo predice como positivas, TP+FP, ecuación (3.9).

$$(3.9) \quad Precision = \frac{TP}{pred(P)} = \frac{TP}{TP+FP}$$

- La Especificidad o *Specificity* representa la proporción de observaciones negativas bien clasificadas, TN, que el modelo es capaz de detectar de entre todas las observaciones negativas, ecuación (3.10),

$$(3.10) \quad Specificity = \frac{TN}{N} = \frac{TN}{TN+FP}$$

- El F1 score, es una combinación de las métricas de *Precision* y *Recall* que resulta de gran utilidad cuando la distribución de las clases es desigual, ecuación (3.11)

$$(3.11) \quad F1 = \frac{2 \cdot Recall \cdot Precision}{Recall + Precision}$$

Las técnicas correctivas empleadas en este estudio se explican a continuación:

- Selección de las métricas más adecuadas. De las métricas utilizadas en este estudio, las que suelen ser consideradas como más robustas frente a conjuntos de datos desbalanceados son la precisión, la sensibilidad y el F1 score. En problemas de clasificación se suele hacer uso de las curvas que representan la precisión y la sensibilidad en función del *threshold*, como se puede observar en la Figura 3.10.

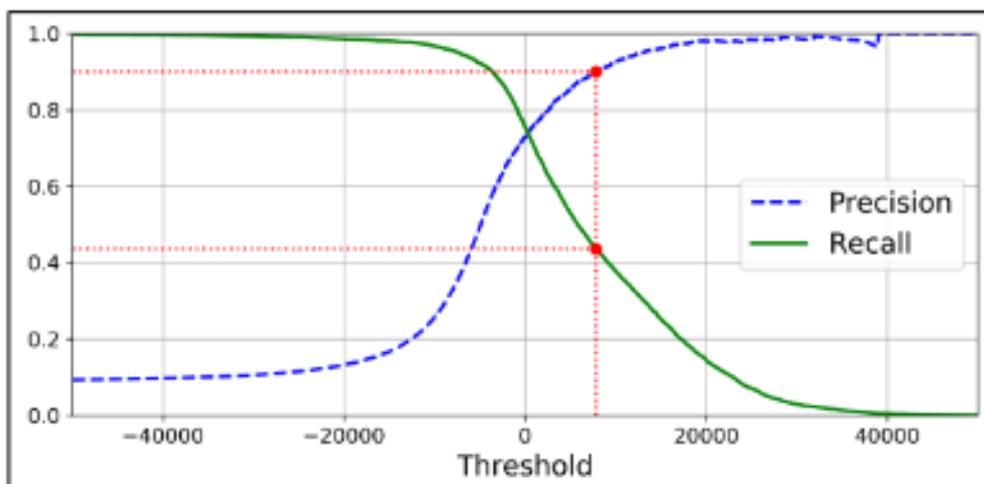


Figura 3.10 Ilustración que muestra un ejemplo de gráfica con la apariencia típica de una curva Precisión-Sensibilidad[54].

- Remuestreo o *resampling* del *dataset*. Es una técnica que se basa en alterar el *dataset* con el objetivo de hacerlo más equilibrado. Las dos variantes más utilizadas son el *oversampling* y el *undersampling*. El *oversampling* consiste en incrementar las observaciones de la clase minoritaria para equilibrar total o parcialmente el tamaño de las clases. El *undersampling* consiste en reducir el tamaño de la clase mayoritaria.
- Asignación de pesos. Basa su funcionamiento en asociar pesos a cada instancia, modificándose estos en cada iteración durante el entrenamiento del clasificador. Se parte de todas las instancias con el mismo peso y después de cada iteración, en función del error cometido en la clasificación, se reajustan los pesos con el objetivo de reducir el error. *Adaboost* es un ejemplo de este tipo de algoritmos.

3.4.1.5 Identificación de predictores según su importancia

Es muy importante conocer cuáles son las variables que tienen mayor relevancia en nuestro modelo. A continuación, se describen algunas de las técnicas más destacadas para clasificar los predictores según su influencia sobre el predictando.

La primera de las técnicas es la denominada *Permutation Importance* (PI). Esta técnica se basa en alterar algunas de las variables del *dataset* y aplicarle el modelo ya entrenado. De esta forma si ese predictor era de importancia para el modelo, el error en la predicción se incrementará.

Otra de las técnicas ampliamente utilizadas es *Feature Importance* (FI). Esta técnica es aplicada en modelos basados en ensembles de árboles de decisión. La construcción de un árbol de decisión se basa en hacer divisiones (*splits*) que maximicen la reducción de impureza o, equivalentemente, la ganancia de información (es decir, que den lugar a nodos lo más homogéneos posible). La métrica *feature importance* representa la reducción promedio de impureza para cada *feature* tras recorrer todos los árboles del ensemble.



3.4.1.6 *Partial Dependence Plots*

La técnica de *Partial Dependence Plot* (PDP), muestra la influencia marginal de una variable en el valor predicho por el modelo ,es decir, esta técnica muestra gráficamente cómo varía la predicción de un modelo en función del valor que toma dicha variable[57].

Esta técnica presenta dos características importantes:

- Es un método agnóstico, lo que significa que puede aplicarse sobre cualquier algoritmo
- Es un método global, esto quiere decir que se genera utilizando la totalidad de las observaciones permitiendo comprender cómo una variable influye sobre el target con respecto a la población.

La variable *feature* no debe estar correlacionada con el resto de las variables, de lo contrario, al establecer el valor de una determinada *feature* en todas de las etapas del proceso de generación de la PDP se tendrían que haber determinado también los valores de las otras *features* correlacionadas. De otro modo, como las otras variables no se alteran cuando se está generando la *partial dependence plot*, indirectamente se están introduciendo observaciones imposibles en el *dataset*.

Capítulo 4 RESULTADOS Y DISCUSIÓN

4.1 Introducción

En este capítulo se presentan los resultados analíticos y experimentales obtenidos la fase experimental. La información está estructurada en este apartado siguiendo un esquema similar al del Capítulo 3.

4.2 Modelado de la resistencia frente a fatiga

Los resultados obtenidos se presentan de la siguiente manera:

- En la sección 4.2.1, se muestran los resultados obtenidos en los ensayos de fatiga por flexión rotatoria.
- En la sección 4.2.2, se explica el modelo *machine learning* creado para predecir la vida en fatiga.
- En la sección 4.3, se expone el estudio mecánico y metalúrgico llevado a cabo para determinar las posibles causas de la variabilidad existente en el comportamiento a fatiga obtenido en los ensayos experimentales de fatiga por flexión rotatoria.

4.2.1 Resultados experimentales de la caracterización a fatiga

Se ha llevado a cabo un estudio fractográfico basándose en las imágenes obtenidas mediante microscopía SEM de la superficie de fractura de todas las probetas, revelando que la totalidad de las roturas se había iniciado en la superficie de estas, no existiendo ningún caso donde se haya originado a partir de una inclusión no metálica. Por tanto, se puede concluir que bajo las condiciones experimentales impuestas ($R=-1$ y $\sigma_a=400$ MPa), el estado de plastificación local en la superficie de las probetas representa el micromecanismo de iniciación predominante en este material.

En la Figura 4.1 se muestra un gráfico con los *boxplots* de cada uno de los 27 grupos de muestras caracterizados mediante ensayos de fatiga rotatoria (compuesto cada grupo por aproximadamente 20 muestras), los resultados de la vida total en fatiga obtenidos. Se puede observar que existe una gran variabilidad en la vida a fatiga entre los diferentes grupos no siendo tan grande dentro de las muestras de un mismo grupo. De esta forma, mientras algunos grupos presentan vida en fatiga mayores a los 60000 ciclos, otros difícilmente superan los 20000 ciclos. La Figura 4.2 muestra un histograma donde se puede observar una distribución bimodal para la vida en fatiga, con un primer valor modal aproximadamente de 30000 ciclos y un segundo cercano a los 50000 ciclos., lo que representa una diferencia de 20000 ciclos, justificación suficiente para proseguir con la investigación.

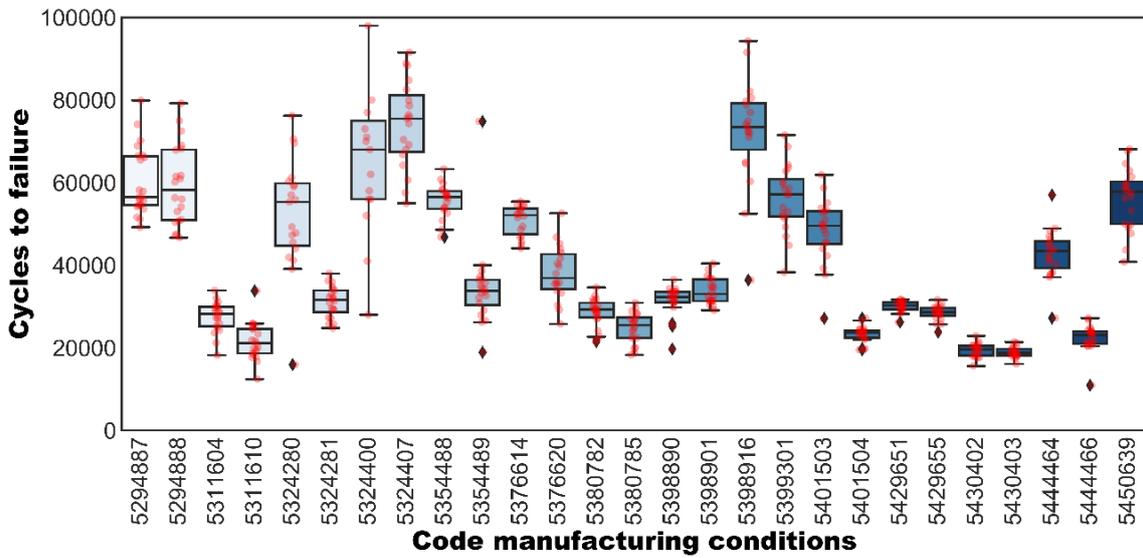


Figura 4.1 Ilustración que muestra los boxplots que representan los resultados de los ensayos de fatiga para cada uno de los 27 grupos de muestras ensayados.

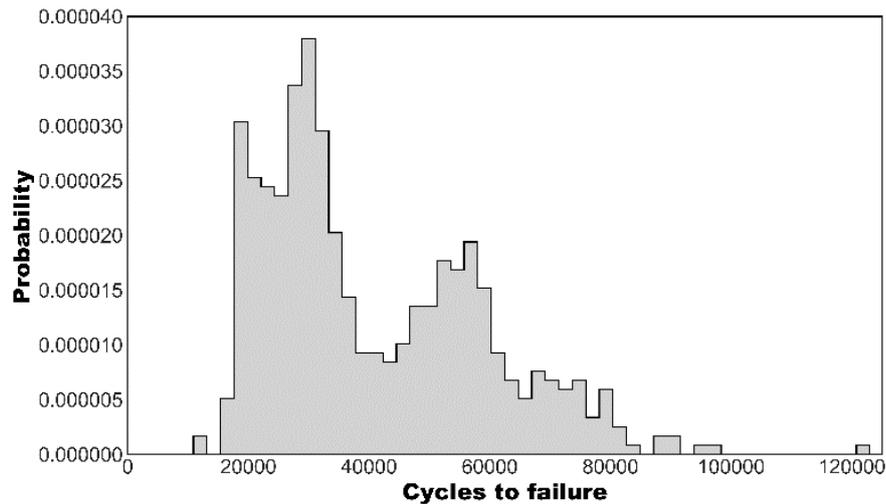


Figura 4.2 Histograma de la distribución de la vida en fatiga obtenida para los 529 ensayos realizados.

4.2.2 Desarrollo de un modelo *Machine Learning* de regresión para predecir la vida en fatiga

En un principio se trató de afrontar el estudio con un *dataset* donde se incluían las 277 *features* que podían influir en el resultado, incluyéndose aquí variables de proceso de GSW y MUBEA, así como aquellas asociadas al proceso experimental. Los resultados obtenidos fueron desfavorables, no consiguiéndose un modelo capaz de generar predicciones certeras. Esto se debe posiblemente a que el número de características es demasiado grande en comparación con las observaciones disponibles. Se realizó estudio

en profundidad basado en criterios técnicos para tratar de identificar las variables principales del proceso, decidiendo que, ya que la totalidad de las roturas se había iniciado en la superficie, y que los procesos de fabricación de MUBEA incluían numerosas transformaciones que afectaban a la superficie del material (tratamientos térmicos, decapados, shot peening, etc) resultaba interesante centrarse en 20 variables del proceso de fabricación de MUBEA. Se generó un nuevo *dataset* sobre el que trabajar con estas 20 variables.

4.2.2.1 Preprocesado de los datos

La decisión de trabajar con un *dataset* simplificado facilita y agiliza los trabajos de limpieza y curado de datos. Se utilizaron las siguientes técnicas de preprocesado para mejorar la calidad del modelo;

- Detección y corrección de valores atípicos (*outliers*) y otros errores contenidos en el *dataset*.
- Utilización de la matriz de correlación de Pearson del conjunto de datos para la detección de variables correlacionadas. Se ha encontrado correlación por ejemplo entre el diámetro de las barras y el momento flector aplicado, lo cual tiene bastante sentido ya que la amplitud de tensión ha sido igual en todos los ensayos ($\sigma_a=400$ MPa). Se ha eliminado una de las *features* de las parejas con un coeficiente de correlación superior (en valor absoluto) a 0,60.
- Para la estandarización de las variables se ha empleado el *StandardScaler* de *Scikit-Learn*, que normaliza las variables restando la media y dividiendo por la desviación estándar.
- La imputación de *missing data* se llevó a cabo mediante el procedimiento *KNNImputer* de *Scikit-Learn*, en el cual los valores ausentes se estiman mediante el algoritmo KNN.
- En la codificación de las variables categóricas, los atributos ordinales se convirtieron usando el *LabelEncoder* de *Scikit-Learn*, y las variables nominales se usó el *OneHotEncoder* de *Scikit-Learn*.

4.2.2.2 Optimización de los algoritmos

Se probó la eficacia de ocho algoritmos. De esta forma, sin optimizar sus hiperparámetros se obtuvieron los resultados presentados en la Tabla 4.1. Como se puede observar en la Tabla 4.1, las métricas utilizadas para evaluar la calidad de los diferentes modelos fueron el coeficiente de determinación R^2 , el error cuadrático medio (RMSE) y el error absoluto medio (MAE). Los algoritmos KNN, RF y GB ofrecen, aun sin optimizar los hiperparámetros, muy buenos resultados.



<i>Regressor</i>	R²	RMSE	MAE
<i>Linear Regression</i>	0,703	9893	6987
<i>K-Nearest Neighbors (KNN)</i>	0,855	6630	4930
<i>Decision Tree (DT)</i>	0,778	8339	5698
<i>Support Vector Regressor (SVR)</i>	-0,057	18663	14925
<i>Random Forest (RF)</i>	0,854	6644	4907
<i>AdaBoost (AB)</i>	0,718	9633	6560
<i>Gradient Boosting (GB)</i>	0,859	6607	4966
<i>Multi Layer Perceptron (MLP)</i>	-4,199	41386	37426

Tabla 4.1. Resultados obtenidos en el conjunto de test para los ocho algoritmos utilizados.

Tras la optimización de los algoritmos de KNN, RF y GB mediante *Grid Search* y *Cross Validation* (*K-fold*, $K=3$), se obtuvieron los resultados que se muestran en la Tabla 4.2. El algoritmo seleccionado por su mejor calidad en la predicción fue *Gradient Boosting*. La Figura 4.3 muestra un *scatterplot* donde se compara, para las observaciones pertenecientes al conjunto de *test*, los resultados experimentales obtenidos para la vida total en fatiga (abscisas) frente a las predicciones derivadas a partir del modelo *Gradient Boosting* (ordenadas). Se puede comprobar que el ajuste de las precisiones es muy bueno y observar la presencia de dos regiones modales similares a las observadas en el histograma de la Figura 4.2.

Regressor	R²	RMSE	MAE
K-Nearest Neighbors (KNN)	0,868	6598	4840
Random Forest (RF)	0,877	6417	4630
Gradient Boosting (GB)	0,877	6354	4584

Tabla 4.2. Tabla con los resultados obtenidos en el conjunto de test para los algoritmos de regresión KNN, RF y GB optimizados mediante *Grid Search* y *Cross Validation*.

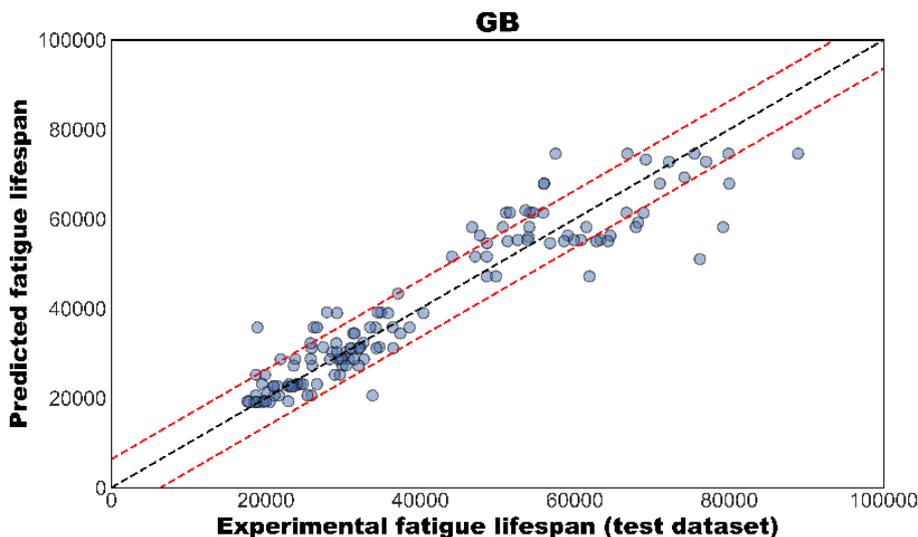


Figura 4.3 Diagrama de dispersión que relaciona los resultados experimentales de la vida total a fatiga (abscisas) con las predicciones obtenidas a partir del algoritmo Gradient Boosting.

4.2.2.3 Selección de atributos más relevantes

Se utilizaron los algoritmos *feature importance* y *permutation importance* para la selección de las variables más relevantes sobre la vida total en fatiga. Ambos procedimientos han proporcionado resultados similares, destacando la variable ‘tensión_V_SLM’, aplicada en MUBEA durante un tratamiento térmico por inducción denominado SLM que, en ocasiones, se aplica sobre el material tras la fase de temple y revenido. Los resultados se muestran en la Figura 4.4.

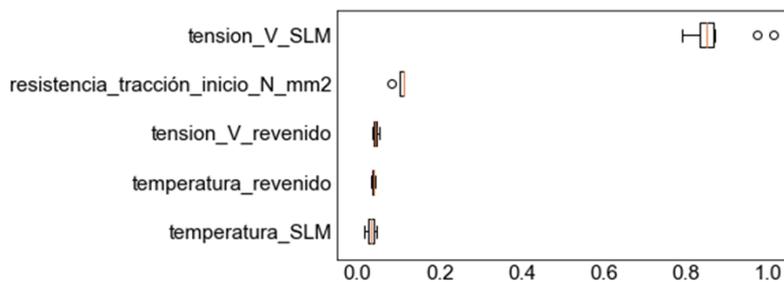


Figura 4.4 Ilustración que muestra la clasificación obtenida mediante el algoritmo *Permutation Importance* de las variables de proceso en función de su relevancia sobre la vida a fatiga determinada experimentalmente mediante ensayos de fatiga por flexión rotatoria.

4.2.2.4 Influencia de los atributos relevantes sobre la vida a fatiga

Para asegurar los resultados obtenidos a través de los algoritmos de *feature importance* y *permutation importance*, que destacan la importancia de la variable ‘tensión_V_SLM’, se ha obtenido la *partial dependence plot* de esta variable, la cual se muestra en la Figura 4.5. Así puede comprobarse como, cuanto mayor es esta variable, menor es la vida en fatiga del material, reduciéndose en promedio más de 40000 ciclos, lo que a su vez es consistente con lo mostrado en las gráficas vistas en apartados anteriores.

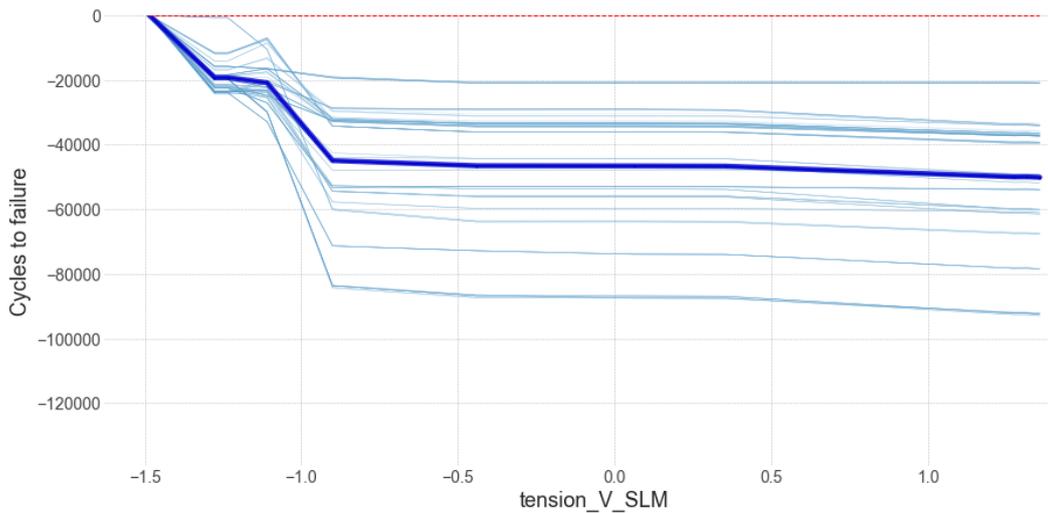


Figura 4.5 Ilustración de la Partial Dependence Plot de la variable 'tension_V_SLM', donde se muestra la influencia sobre la vida total en fatiga obtenida experimentalmente mediante los ensayos de fatiga por flexión rotatoria.

4.3 Interpretación de los resultados en términos mecánicos y metalúrgicos

El tratamiento SLM (*Surface Layer Modification*) consiste básicamente en un reblandecimiento superficial acompañado de un endurecimiento de la región central, tal y como se muestra en la Figura 4.6. Su objetivo es la prevención de la formación de grietas y la reducción de su velocidad de propagación cuando estas se generan.

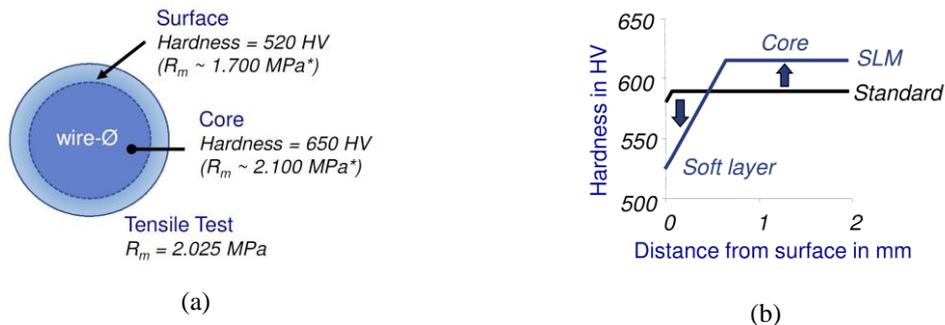


Figura 4.6 Ilustración que muestra el efecto del tratamiento SLM[58].

Según varios estudios existentes desarrollados por MUBEA en colaboración con la *Universitat Siegën*[58], [59], este reblandecimiento superficial se consigue mediante un tratamiento térmico adicional por inducción que se aplica tras el de temple y revenido (como se mostró anteriormente en la Figura 3.6). Estos estudios indican que, el SLM es beneficioso por varios motivos.

Por un lado, es beneficioso ya que, al reducir la dureza (junto con el límite elástico y la resistencia a tracción) aumenta la tenacidad a fractura K_{Ic} del material. Este efecto se muestra en la gráfica de la Figura 4.7.

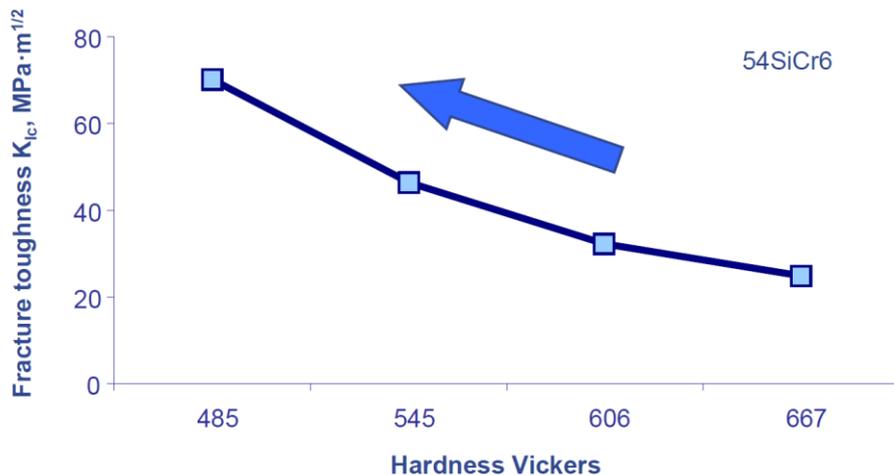


Figura 4.7 Ilustración que muestra una gráfica en la que se muestra como la dureza y la tenacidad a fractura presentan una relación inversa[58].

La segunda ventaja se debe a que, una vez generada la grieta, la velocidad de propagación de esta se reduce debido al reblandecimiento de la zona. Se puede ver como en uno de los estudios se obtienen experimentalmente las curvas de la velocidad de propagación, da/dN de probetas sometidas a diferentes tratamientos térmicos, entre las que se incluye el tratamiento SLM. Para ello, como se observa en la Figura 4.8 se lleva a cabo la austenización de unas barras de acero de 17 mm de diámetro calentándolas a una temperatura de 900° y templándolas en agua. A continuación, se han sometido a un tratamiento de revenido a varias temperaturas, superiores a los 400°, obteniéndose cinco grupos de barras con resistencias a tracción de 1700, 1900, 2000, 2100 y 2200 MPa. Únicamente una parte del material fue sometido al tratamiento de SLM teniendo este una resistencia media de unos 2000 MPa.

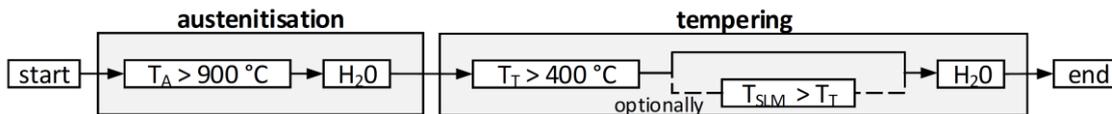


Figura 4.8 Esquema con el diagrama de trabajo seguido durante el estudio[59].

Por último, como se muestra en la Figura 4.9, se han mecanizado probetas de flexión en tres puntos entalladas, que han sido prefisuradas mediante fatiga. Ensayando estas probetas usando ASTM E647[60] se han obtenido las curvas da/dN y las leyes de Paris para cada material.

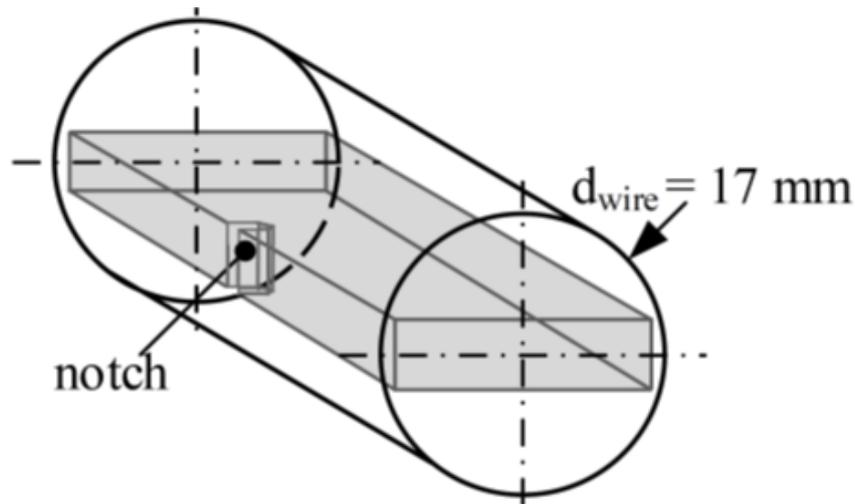


Figura 4.9 Ilustración que muestra la geometría de las probetas de flexión en tres puntos utilizadas para obtener las curvas de propagación $da-dN$, y las leyes de Paris[59].

A través del análisis de las curvas $da-dN$ obtenidas para los distintos materiales, las cuales pueden verse en la Figura 4.10 se deduce que la velocidad de propagación aumenta con la resistencia mecánica del material. En caso del material sometido al tratamiento de SLM, se observa que su comportamiento es similar al material que presenta una resistencia a tracción de 2000 MPa, obteniéndose una velocidad de propagación algo menor hasta los 2,8 mm de profundidad y siendo la velocidad ligeramente superior en el tramo final. Estos resultados son coherentes ya que en los primeros milímetros el material se encuentra reblandecido por el tratamiento SLM, dándose la situación opuesta en la zona central, donde como ya se mencionó anteriormente, se encuentra endurecido.

Nótese que el trabajo experimental llevado a cabo por Tump y Brandt se centra exclusivamente en la velocidad de propagación de fisuras en condiciones de fatiga pero ignora el fenómeno de la iniciación de grieta.

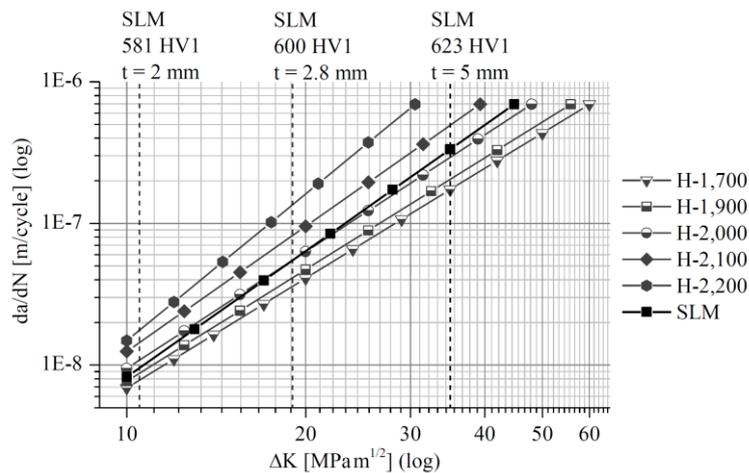


Figura 4.10 Gráfica donde se recogen las diferentes curvas de velocidad propagación, $da-dN$, de las probetas extraídas de los materiales sometidos a distintos tratamientos térmicos[59].

Estos trabajos únicamente se centran en la velocidad de propagación de las fisuras bajo condiciones de fatiga sin entrar en el fenómeno de la iniciación de la grieta.

Tras esta exposición se puede entender que, los resultados obtenidos a partir de modelos de *machine learning* basados en los datos recogidos en la campaña experimental realizada en el LADICIM se contradicen con los expuestos en los estudios anteriormente citados[58], [59].

Es necesario, por lo tanto, obtener una interpretación científicamente fundamentada que permita comprender el origen de esta discrepancia, así como las verdaderas causas que explican el comportamiento del material. Para tratar de comprender esta discrepancia se han realizado diagramas de violín, que se muestran en la Figura 4.11, donde se muestra la distribución de la resistencia a fatiga obtenida mediante los ensayos de flexión rotatoria distinguiéndose entre aquellas probetas que carecen (izquierda) o que han recibido (derecha) el tratamiento SLM. Los resultados obtenidos con los diagramas de violín de la Figura 4.11 son coherentes con el histograma de la Figura 4.2, pudiéndose ver como los datos que se recogen en el primer valor modal observado en el histograma (observaciones que oscilan en el rango de los 20000 a los 40000 ciclos) se corresponden con los del diagrama de la derecha, formados por el material que había recibido el tratamiento SLM, mientras que los del segundo valor modal (observaciones que oscilan en el rango de los 50000 a los 70000 ciclos) se identifican con el diagrama de violín de la izquierda, formados por material que no había recibido el tratamiento SLM.

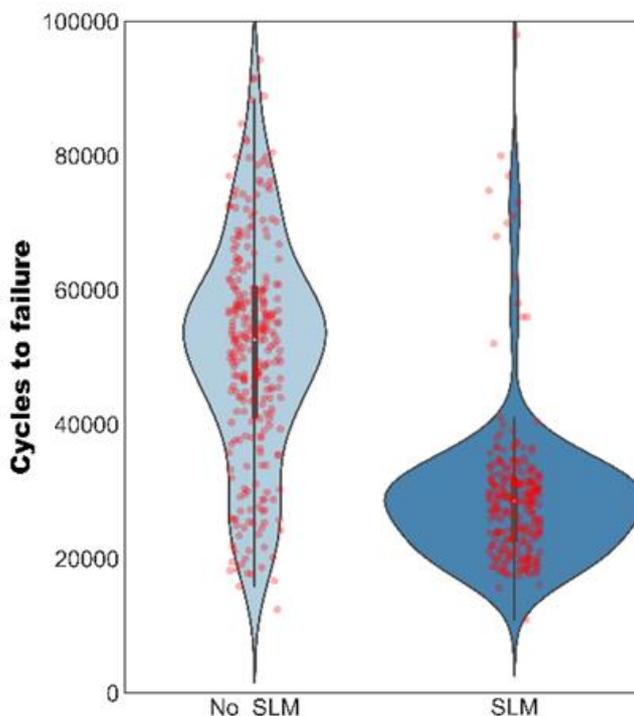


Figura 4.11 Ilustración que muestra mediante diagramas de violín la distribución de los resultados de la vida a fatiga de aquellas probetas que no han recibido el tratamiento SLM (izquierda) y las que sí lo han recibido (derecha).



4.3.1.1 Distribución radial de la microdureza

Para ahondar en la comprensión de la influencia del tratamiento SLM sobre el comportamiento mecánico del material, se han realizado diversos ensayos de microdureza Vickers con el fin de obtener los perfiles radiales de microdureza de una serie de muestras procedentes de barras de la misma colada de GSW, que son están compuestos por el mismo tipo de acero, pero han sido tratadas de forma diferente en MUBEA, teniendo uno de los grupos el tratamiento SLM y el otro no (coladas *Heat_1* y *Heat_2*). Los perfiles de microdurezas obtenidos se muestran en la Figura 4.12, en ellos se puede observar como en las dos coladas analizadas, el material no sometido a SLM presenta una dureza constante con la profundidad con unos valores comprendidos entre 600 y 630 Vickers. Por su parte, en el material tratado con SLM se observa como la dureza crece desde los 540 Vickers hasta 640 Vickers en los primeros 1.5 mm; manteniéndose después en un rango comprendido entre los 630 y 645 Vickers. Estos resultados encajan con lo expuesto anteriormente.

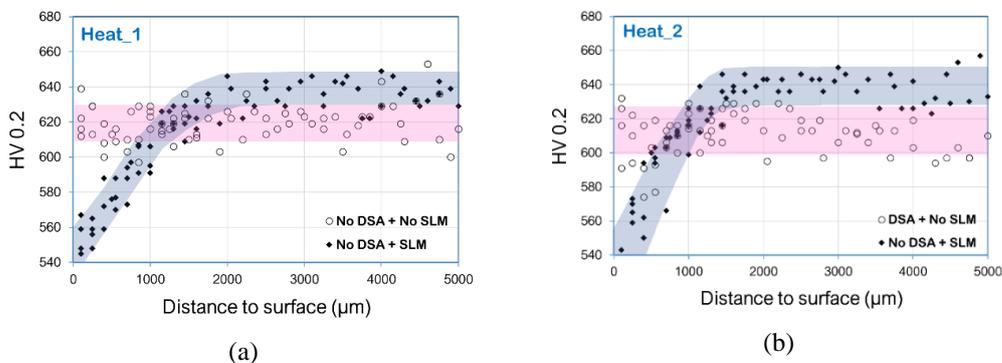


Figura 4.12 Ilustración que muestra los perfiles de microdureza Vickers obtenidos en secciones transversales de probetas procedentes de dos coladas diferentes, de las cuales un grupo de barras presentaba el tratamiento SLM y otro no.

4.3.1.2 Estudio de la rugosidad superficial

Debido a que el acabado superficial influye en gran medida sobre la iniciación de la grieta, se realizó un estudio de la rugosidad superficial en diversas barras procedentes de las coladas *Heat_1* y *Heat_2*, presentando algunas de ellas el tratamiento SLM y otras no. Las medidas de la rugosidad han sido obtenidas de los extremos de las barras, evitando así la posible influencia derivada del rozamiento de la barra con los apoyos de la máquina de fatiga rotatoria. En la Figura 4.13 se muestra en forma de *boxplots* los resultados obtenidos, siendo los dos primeros correspondientes al material procedente de la colada *Heat_1* y los dos últimos de la colada *Heat_2*.

Se puede observar cómo existe una clara relación entre la rugosidad superficial y el tratamiento SLM, obteniéndose valores de Ra (siendo Ra la rugosidad media aritmética en un segmento de 25 mm) comprendidos entre 2,5 y 4 para las barras sin tratamiento SLM, y valores de Ra comprendidos entre los 3,25 y 5,5 para las barras con tratamiento SLM. Igualmente se puede observar como la mediana de las barras sin SLM se encuentra

en un valor de Ra cercano a los 3,25 para las dos coladas, mientras que las barras con tratamiento SLM presenta una mediana cercana a 4,25.

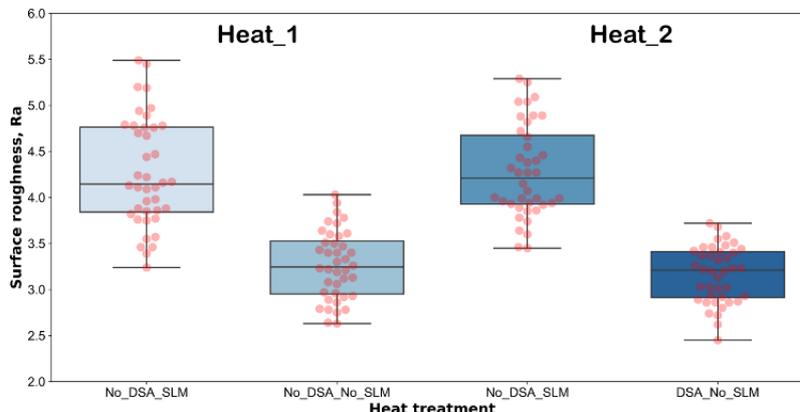


Figura 4.13 Ilustración donde se muestran los boxplots de los resultados de la dureza superficial, R_a , de diferentes muestras, con y sin SLM, procedentes de las coladas Heat_1 y Heat_2.

4.3.1.3 Análisis fractográfico

Por último, se ha realizado una evaluación fractográfica sobre diversas superficies de rotura de barras procedentes de la colada Heat_1, con y sin tratamiento SLM, para tratar de hallar diferencias en los micromecanismos de rotura que puedan explicar la variabilidad observada en la vida a fatiga. Se ha observado que, tal y como se muestra en la Figura 4.14, el proceso de iniciación de la grieta en barras que no han sido sometidas al tratamiento de SLM se da mediante un único punto de iniciación, mientras que, por el contrario, en barras que han sido sometidas al tratamiento SLM, se pueden observar múltiples puntos de iniciación.

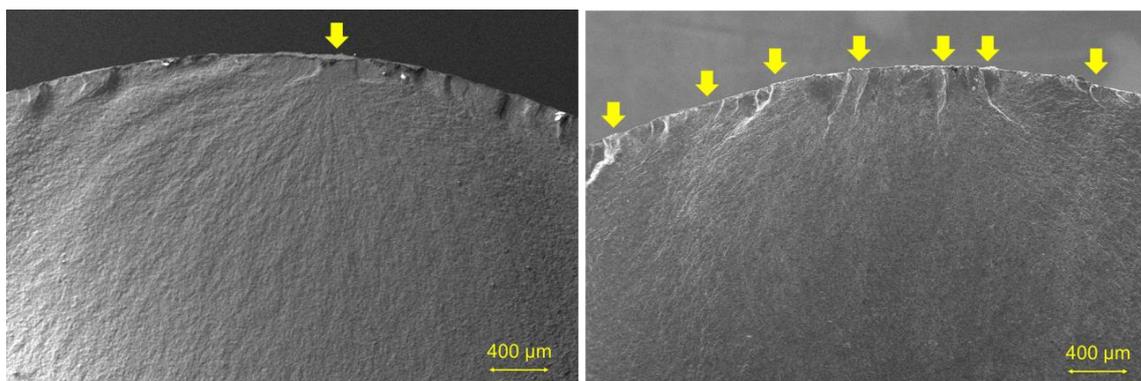


Figura 4.14 Ilustración donde se muestra las fractografías de dos superficies de rotura de la colada Heat_1, correspondiéndose una de ellas (la izquierda) a una barra no sometida al tratamiento SLM y la otra (la derecha) a una barra que si ha sido sometida al tratamiento SLM.

Esto provoca que, como se puede observar en la Figura 4.15, la barra que presenta el tratamiento SLM, y por tanto varios puntos de iniciación de la rotura, tenga una velocidad de crecimiento de la grieta mayor debido a que, estas múltiples zonas de crecimiento de grieta convergerán en una única zona.

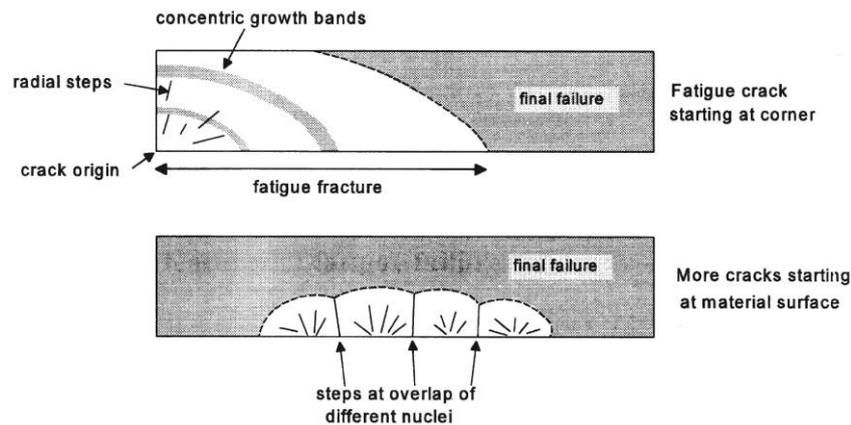


Figura 4.15 La figura describe los aspectos macroscópicos asociados con una rotura por fatiga que se inicia en un único punto frente a un proceso de fatiga con múltiples iniciadores[23].

4.4 Discusión y conclusiones

De lo mostrado anteriormente se pueden extraer las siguientes conclusiones:

- Las Figura 4.2 y Figura 4.11 muestran la diferencia en la vida a fatiga existente entre las barras sometidas al tratamiento SLM y las que no han sido sometidas a este mismo tratamiento.
- De la Figura 4.12 se deduce que el tratamiento SLM genera un reblandecimiento en la superficie de las barras que alcanza los 2 primeros milímetros de profundidad. Estas conclusiones están alineadas con los resultados obtenidos por los estudios de referencia[58], [59].
- La Figura 4.13 indica que existe una mayor rugosidad en barras que presentan el tratamiento SLM que en aquellas que no lo han recibido. Esto se ha comprobado realizando ensayos de rugosidad en barras procedente de las coladas *Heat_1* y *Heat_2*, de las cuales algunas de las barras habían sido tratadas con el tratamiento SLM y otras no.
- En la Figura 4.14 se muestra el estudio fractográfico dos superficies de rotura pertenecientes a la colada *Heat_1*, se observa como en la superficie de rotura procedente de una barra sin SLM solo existe un punto de iniciación de la fisura, observándose múltiples puntos en la superficie de la barra tratada con SLM. Los resultados eran similares para otras superficies analizadas.

Los resultados anteriormente presentados son coherentes con los fundamentos de los fenómenos de fatiga, explicando como el reblandecimiento superficial y el aumento de la rugosidad causados por el SLM favorecen la iniciación del proceso de fisura (proceso que puede llegar a consumir el 90% de la vida en fatiga de un componente hasta rotura), afectando de forma negativa a la vida en fatiga del material.

Este estudio ahonda en las investigaciones de Tump y Brandt, explicadas con anterioridad, y que se centran la afección del tratamiento SLM sobre la propagación de la fisura, sin tener en cuenta el fenómeno de la iniciación.

Capítulo 5 CONCLUSIONES

Los resultados mostrados en este estudio se apoyan en una campaña experimental llevada a cabo en el LADICIM donde se han realizado 529 ensayos de fatiga por flexión rotatoria, utilizando una amplitud tensional de 400 MPa. Durante esta campaña se han caracterizado 27 combinaciones de parámetros de proceso, obteniéndose en base a estos datos un *dataset* que ha permitido entrenar un modelo de regresión basado en el algoritmo *gradient boosting*. Este modelo ha aportado información sobre las variables más influyentes en la vida a fatiga del material. Una vez conocidas las variables más relevantes y realizado un estudio con toda la información, se pueden extraer de este estudio las siguientes conclusiones:

- El estudio fractográfico utilizando imágenes obtenidas mediante microscopía SEM confirma que, todas las roturas obtenidas mediante ensayos de fatiga rotatoria han tenido su origen en la superficie de la barra, no debiéndose ninguna de ellas a una inclusión no metálica. Cabe resaltar la gran variabilidad existente en la vida a fatiga del material, pudiendo verse una distribución bimodal con valores 20000 y 50000 ciclos hasta rotura.
- En el desarrollo del modelo de *machine learning* se partió de un *dataset* inicial con 277 variables que incluían variables del proceso de GSW, Mubea y algunas asociadas a la propia fase experimental. Tras conocerse que la totalidad de las roturas se habían iniciado en superficie, se decidió crear un nuevo *dataset* centrándose en las 20 variables del proceso de MUBEA, puesto que es allí donde se realizan diversos tratamientos térmicos y superficiales. El modelo de *machine learning* creado a partir de este *dataset* obtuvo un coeficiente de determinación, $R^2=0,877$. Este modelo ha identificado al tratamiento SLM como el variable más influyente en la vida a fatiga del material, obteniéndose hasta en 40000 ciclos la vida a fatiga del material que presenta este tratamiento.
- El proceso SLM (*Surface Layer Modification*) es un tratamiento térmico de revenido que se aplica después del revenido convencional, y que tiene como objetivo el reblandecimiento de la superficie del material hasta una profundidad de unos pocos milímetros. Según los estudios realizados por MUBEA en colaboración con la *Universität Siegen*, este tratamiento busca aumentar la tenacidad del material así como disminuir la velocidad de propagación de las fisuras mediante fatiga. La discrepancia entre los resultados obtenidos en estos estudios y los datos arrojados por el modelo *machine learning* conducen a realizar una nueva campaña experimental para aclarar estas diferencias, procediéndose a lo siguiente:
 - En primer lugar, basándose en los datos arrojados por el modelo de *machine learning*, se han separado las observaciones en dos grupos en función de si habían recibido o no el tratamiento SLM. Se ha observado como aquellas barras que si habían recibido el tratamiento SLM presentan una vida a fatiga bastante menor (con una vida media a fatiga de aproximadamente 20000 ciclos) que las barras que habían sido sometidas a SLM (con vidas a fatiga medias de entorno a los 50000 ciclos)



- Para comprender mejor la influencia del tratamiento SLM sobre la superficie del material se han realizado diversos ensayos de microdureza Vickers obteniéndose los perfiles radiales de microdureza de una serie de muestras procedentes de barras de la misma colada de GSW. Los resultados indican que se produce un reblandecimiento superficial del material hasta una profundidad cercana a los 2 mm. También se observa que, mientras en el material que no presenta el tratamiento SLM la dureza permanece constante entorno a los 620 HV, en el material con SLM la dureza aumenta desde los 550 HV en la parte superficial hasta los 640 HV. Esto juega un papel importante ya que el proceso de iniciación de la fisura abarca la mayor parte de la vida a fatiga de un elemento, viéndose el fenómeno de la iniciación estrechamente ligado a la calidad superficial y al límite elástico del material (resultando más sensible a la iniciación aquellos materiales con límites elásticos bajos).
- Los ensayos de rugosidad superficial muestran que, el tratamiento de *shot peening*, es más severo en barras con el tratamiento SLM, apreciándose diferencias significativas entre la rugosidad superficial de las barras tratadas con SLM y aquellas que no lo están, siendo la rugosidad superior en las barras que presentan el tratamiento SLM, lo que es totalmente comprensible debido a que su superficie se encuentra reblandecida. Esta mayor rugosidad indica también la presencia de una mayor tensión superficial, lo cual puede dar lugar a la aparición de concentradores de tensiones en las microcavidades asociadas al *shot peening*, facilitando la iniciación de las fisuras

Este estudio muestra un pequeño avance en el conocimiento de las variables que influyen en la vida a fatiga del acero para muelles de automoción. Cabe destacar la función del tratamiento SLM, que repercute negativamente en la vida a fatiga del material, lo que invita a replantearse su uso dentro del proceso de fabricación.

BIBLIOGRAFÍA

- [1] “Metalurgia - Wikipedia, la enciclopedia libre.” <https://es.wikipedia.org/wiki/Metalurgia> (accessed Jun. 12, 2021).
- [2] World Steel Association, “World Steel Association in Figures 2019,” *World Steel Assoc.*, pp. 1–30, 2019.
- [3] “• Gráfico: A la espera de un Big Bang de datos | Statista.” <https://es.statista.com/grafico/17734/cantidad-real-y-prevista-de-datos-generados-en-todo-el-mundo/>.
- [4] “Web oficial de CELSA GROUP,” 2021. <https://www.celsagroup.com/>.
- [5] “¿Cuántos datos se producen en un minuto?” <https://business-intelligence.grupobit.net/blog/cuantos-datos-se-producen-en-un-minuto>.
- [6] “7 aplicaciones prácticas del Machine Learning en la vida cotidiana que pocos conocen.” <https://www.ticpymes.es/tecnologia/noticias/1122555049504/7-aplicaciones-practicas-del-machine-learning-vida-cotidiana-pocos-conocen.1.html>.
- [7] “Horno de arco eléctrico - Wikipedia, la enciclopedia libre.” https://es.wikipedia.org/wiki/Horno_de_arco_eléctrico (accessed Jun. 13, 2021).
- [8] J. L. E. Berciano, E. T. Guerra, S. de E. de Bengy, and D. F. Segovia, “Monografías sobre tecnología del acero. Parte I: Acería eléctrica,” p. 230, 2009.
- [9] “Sidenor decide aumentar hasta 40 millones su inversión en la planta de Basauri | El Correo.” <https://www.elcorreo.com/bizkaia/economia/201704/29/sidenor-decide-aumentar-hasta-20170428225059.html> (accessed Jun. 15, 2021).



- [10] R. A. M. de Almeida, D. Vieira, W. V. Bielefeldt, and A. C. F. Vilela, “Slag Foaming Fundamentals - A Critical Assessment,” *Mater. Res.*, vol. 20, pp. 474–480, 2017.
- [11] “AMEPA measuring technology for the steel, aluminium and automotive industries.” <https://amepa.de/en/> (accessed Jun. 21, 2021).
- [12] T. Choh, K. Iwata, and M. Inouye, “Estimation of Oxygen and Nitrogen Absorption of Liquid Steel during Tapping from Converter*,” 1983.
- [13] J. Luis, E. Berciano, and E. T. Guerra, “Monografías sobre Tecnología del Acero. Parte II METALURGIA SECUNDARIA.”
- [14] “Cucharas de acero,” *Krosaki AMR Refractarios S.A.U.* .
- [15] A. L. Vasconcellos Da Costa E Silva, “Non-metallic inclusions in steels - Origin and control,” *J. Mater. Res. Technol.*, vol. 7, no. 3, pp. 283–299, 2018, doi: 10.1016/j.jmrt.2018.04.003.
- [16] H. Bessemer, “Improvement in the manufacture of iron and steel,” Jul. 1865.
- [17] J. Zhang, Q. Liu, S. Yang, Z. Chen, J. Li, and Z. Jiang, “Advances in Ladle Shroud as A Functional Device in Tundish Metallurgy: A Review,” *ISIJ Int.*, vol. advpub, 2019, doi: 10.2355/isijinternational.ISIJINT-2019-044.
- [18] B. G. Thomas, “Review on Modeling and Simulation of Continuous Casting,” *Steel Res. Int.*, vol. 89, no. 1, pp. 1–21, 2018, doi: 10.1002/srin.201700312.
- [19] “Casting (metalworking) - Wikipedia.” [https://en.wikipedia.org/wiki/Casting_\(metalworking\)?uselang=ca](https://en.wikipedia.org/wiki/Casting_(metalworking)?uselang=ca) (accessed Jun. 24, 2021).

- [20] J. L. Enríquez Berciano, E. Tremps Guerra, D. Fernández Segovia, and S. de Elío de Bengy, “Laminacion,” *Univ. Politec. Madrid*, p. 244, 2010.
- [21] “August Wöhler - Wikipedia, la enciclopedia libre.” https://es.wikipedia.org/wiki/August_Wöhler (accessed Jun. 25, 2021).
- [22] “Fatigue - Impact Solutions - cyclic loading and unloading.” <https://www.impact-solutions.co.uk/fatigue/> (accessed Jun. 26, 2021).
- [23] J. Schijve, *Fatigue of Structures and Materials*, Second Edi. Springer Science+Business Media, B.V., 2009.
- [24] “BS ISO 12107:2003. Metallic materials — Fatigue testing — Statistical planning and analysis of data,” in *BSI Catalogue*, 2003, p. 26.
- [25] E. Castillo and A. Fernandez-Canteli, *A Unified Statistical Methodology for Modeling Fatigue Damage*. Springer Netherlands, 2009.
- [26] “Machine Learning y Deep Learning: ¿Cuáles son sus ventajas?” <https://blog.infaimon.com/ventajas-del-machine-learning-y-deep-learning-para-la-evolucion-de-la-vision-artificial/> (accessed Jun. 28, 2021).
- [27] M. Copeland, “What’s the Difference Between Artificial Intelligence, Machine Learning and Deep Learning?,” *nVIDIA*, 2016. .
- [28] “Difference between Artificial Intelligence and Machine Learning | by Prakash verma | Medium.” <https://medium.com/@prakash507979/difference-between-artificial-intelligence-and-machine-learning-7e3a2b9d319a> (accessed Jun. 28, 2021).
- [29] Andy Casey, “Machine learning overview.” <https://astrowizici.st/teaching/phs5000/10/> (accessed Jul. 01, 2021).



- [30] “algoritmos de regresión | Blog de www.datlas.mx.” <https://blogdatlas.wordpress.com/tag/algoritmos-de-regresion/> (accessed Jul. 05, 2021).
- [31] S. Guido and A. Müller, *Introduction to Machine Learning with Python. A Guide for Data Scientists*. O’Reilly Media, 2016.
- [32] “A Beginner’s Guide to Customer Segmentation with k-Means Clustering | by Bryan Tan | Medium.” <https://medium.com/@BryanJr/customer-segmentation-with-k-means-clustering-8167c8bd833b> (accessed Jul. 11, 2021).
- [33] “Qué es overfitting y underfitting y cómo solucionarlo | Aprende Machine Learning.” <https://www.aprendemachinlearning.com/que-es-overfitting-y-underfitting-y-como-solucionarlo/> (accessed Jul. 15, 2021).
- [34] N. Kottegoda, *Applied Statistics for Civil and Environmental*. 2008.
- [35] Sara Garcia Condado, “Generalización de variables medioambientales mediante interpolación GIS,” Universidad Politécnica de Madrid, 2016.
- [36] A. Chugh, “Logistic Regression.” <https://aakarshachugh.wordpress.com/2018/06/01/logistic-regression/> (accessed Jul. 18, 2021).
- [37] “Logistic Regression in Machine Learning,” *java T point*. .
- [38] “Support Vector Machine | Semantic portal — learn smart!” <http://semantic-portal.net/base-machine-learning-in-python-svm> (accessed Jul. 19, 2021).
- [39] G. Singhal, “Ensemble Methods in Machine Learning: Bagging Versus Boosting,” *Pluralsight*, 2020. .

- [40] R. Nagyfi, “The differences between Artificial and Biological Neural Networks,” *Towards Data Science*, 2018. .
- [41] J. M. Alvarez, “El perceptrón como neurona artificial,” *Blog de José Mariano Álvarez*, 2018. .
- [42] A. Manero-Bastin, “How to Configure the Number of Layers and Nodes in a Neural Network,” *Data Science Central*, 2019. .
- [43] “Validación cruzada - Amazon Machine Learning.” https://docs.aws.amazon.com/es_es/machine-learning/latest/dg/cross-validation.html (accessed Jul. 23, 2021).
- [44] C. Nantasenamat, “Building The Machine Learning Model,” 2020. .
- [45] “Auto Tuning Part 2: Suspension Elements - EngineeringClicks.” <https://www.engineeringclicks.com/auto-tuning-suspension-elements/> (accessed Jul. 28, 2021).
- [46] “Sistema de Suspensión en los Vehículos.” <https://ingemecanica.com/tutorialsemanal/tutorialn73.html> (accessed Jul. 30, 2021).
- [47] T. Timoshenko, *Strength of Materials*, Third Edit. CBS Publishers & Distributors, 2002.
- [48] Society of Automotive Engineers. Spring Committee, *Spring Design Manual AE-21*. SAE International, 1996.
- [49] “Helical Springs - Roy Mech.” https://roytech.org/Useful_Tables/Springs/Springs_helical.html (accessed Jul. 30, 2021).



- [50] Y. Zhu, Y. Wang, and Y. Huang, “Failure analysis of a helical compression spring for a heavy vehicle’s suspension system,” *Case Stud. Eng. Fail. Anal.*, vol. 2, no. 2, pp. 169–173, 2014, doi: 10.1016/j.csefa.2014.08.001.
- [51] U. Karr *et al.*, “Inclusion initiated fracture in spring steel under axial and torsion very high cycle fatigue loading at different load ratios,” *Int. J. Fatigue*, vol. 134, no. February, p. 105525, 2020, doi: 10.1016/j.ijfatigue.2020.105525.
- [52] “ISO 1143:2010 Metallic materials — Rotating bar bending fatigue testing,” ISO International Organization for Standardization, 2010, p. 26.
- [53] J. Amat Rodrigo, “Machine learning con Python y Scikit-learn,” *Ciencia de Datos, Estadística, Machine Learning y Programación*. .
- [54] A. Geron, *Hands-On Machine Learning with Scikit-Learn and TensorFlow*, O’Reilly M. 2017.
- [55] “Cómo interpretar la matriz de confusión: ejemplo práctico - Think Big Empresas.” <https://empresas.blogthinkbig.com/como-interpretar-la-matriz-de-confusion-ejemplo-practico/> (accessed Aug. 03, 2021).
- [56] “Evaluation of binary classifiers - Wikipedia.” https://en.wikipedia.org/wiki/Evaluation_of_binary_classifiers (accessed Aug. 13, 2021).
- [57] J. H. Friedman, “Greedy Function Approximation: A Gradient Boosting Machine,” *Ann. Stat.*, vol. 29, no. 5, pp. 1189–1232, Feb. 2001.
- [58] A. Tump, T. Bauschke, and R. Brandt, “Graded High-Strength Steels for Improved Corrosion Resistance through Inductive Heat Treatment,” in *Materials Science Engineering (MSE 2014)*, 2014, p. 13.

- [59] A. Tump and R. Brandt, “Graded High-Strength Spring-Steels by a Special Inductive Heat Treatment,” in *18th Chemnitz Seminar on Materials Engineering*, 2016, p. 6.
- [60] “Standard Test Method for Measurement of Fatigue Crack Growth Rates,” in *ASTM Book of Standards Volume: 03.01*, West Conshohocken, PA: ASTM International, 2015.