



Universidad Internacional de la Rioja
Escuela Superior de Ingeniería y
Tecnología

Máster Universitario en Inteligencia Artificial

**Monitorización del estado de calidad en
un proceso de laminación en caliente de
acero inoxidable mediante técnicas de
aprendizaje automático**

Trabajo Fin de Máster presentado por: Miguel Ángel González González
Tipo de trabajo: Comparativa de soluciones
Dirigido por: Xiomara Patricia Blanco Valencia
Fecha: 1 de febrero de 2023

Resumen

En la industria metalúrgica, los defectos que se producen durante la laminación en caliente tienen una notable relevancia ya que demasiadas veces no son detectables hasta etapas más avanzadas del proceso, con el consiguiente perjuicio. La solución más extendida en la industria es la utilización de Sistemas de Monitorización de Condiciones (SMC) que generan alarmas cuando una variable de proceso infringe los límites admisibles fijados en función del tipo de producto. En este trabajo, se propone una monitorización de estado de defecto basado en un modelo de aprendizaje automático como alternativa a los SMC. Este sistema proporcionaría un indicador de la propensión del sistema de fabricación a generar el defecto en los productos de acero. Además, serviría como una guía para conducir el sistema a un estado de menor riesgo gracias a un modelo explicativo y gráficas de dependencias parciales.

Palabras Clave: aprendizaje automático, acero inoxidable, laminación en caliente

Abstract

Regarding the metallurgical industry, defects produced during hot rolling processes are of the utmost importance because too often they are not detectable until more advanced stages of the process, with the consequent added cost. The most extended solution is based on Monitoring Condition Systems (MCS) that trigger alarms when a process variable violates the admissible limits set according to the type of product. In this work, a defect-related state monitoring system based on machine learning is proposed as an alternative to MCS. This system would provide an indicator of the propensity of the production system to produce a defect in steel products along with a guide to steer the production system to a safer one thanks to an explainer model and partial dependence plots.

Palabras Clave: machine learning, stainless steel, hot rolling

Índice de contenidos

1. Introducción	1
1.1. Motivación	1
1.2. Planteamiento del problema	2
1.3. Estructura de la memoria	3
2. Contexto y Estado del Arte	5
2.1. Proceso de fabricación y generación de los datos	5
2.2. Estado del arte	7
3. Objetivos	15
3.1. Objetivo general	15
3.2. Objetivos específicos	16
3.3. Metodología del trabajo	16
4. Desarrollo del trabajo	21
4.1. Análisis Exploratorio de los Datos	22
4.1.1. Transformación de los datos	22
4.1.2. Visualizaciones generales y análisis de correlaciones	24
4.1.3. Aprendizaje no supervisado: Mapas Autoorganizados	29
4.2. Modelado	34
4.3. Evaluación	38
4.3.1. Evaluación de los modelos de clasificación de <i>astillado</i>	39
4.3.2. Evaluación de los modelos de regresión de <i>probabilidad_astillado</i>	41
4.3.3. Comparación de los modelos de clasificación de defecto con los modelos de regresión de <i>probabilidad_astillado</i> como clasifica- dores de <i>astillado</i>	46

4.3.4. Selección de modelo y determinación del umbral de detección óptimo	51
4.4. Indicador del estado de calidad del proceso	57
4.5. Explicación del modelo	60
4.5.1. Importancia de las variables basada en permutación	60
4.5.2. Perfiles de dependencias parciales	63
4.5.3. Gráficos de descomposición	66
4.5.4. Gráficos de Ceteris Paribus	67
4.6. Despliegue	72
5. Conclusiones y Trabajo Futuro	77
Bibliografía	81
6. Anexo. Artículo de investigación	87

Índice de figuras

2.1. Esquema del proceso productivo objeto de estudio.	5
2.2. Calificación del defecto “Astillado”.	6
2.3. Arquitectura informática para la adquisición y almacenamiento de información de proceso.	7
2.4. Integración de bases de datos de características y proceso con herramientas de Ciencia de Datos.	8
4.1. Astillado respecto a diámetro.	25
4.2. Unidades producidas en función del diámetro.	25
4.3. Astillado respecto al tipo de acero.	26
4.4. Unidades producidas en función del tipo de acero.	26
4.5. Frecuencia relativa del astillado en función del diámetro y tipo de acero.	27
4.6. Correlaciones superiores a 0.8 entre variables.	28
4.7. Variables con mayor correlación con astillado.	30
4.8. Variables con mayor correlación con probabilidad astillado.	30
4.9. Mapas de color correspondientes a temperaturas en horno, dúo y caja 01.	32
4.10. Mapas Autoorganizados correspondientes a bobinadoras y al bloque.	32
4.11. Mapas Autoorganizados correspondientes a bobinadoras y al bloque con aprendizaje supervisado.	33
4.12. Mapas Autoorganizados correspondientes a bobinadoras y al bloque con aprendizaje supervisado.	34
4.13. Característica operativa del receptor: predicción astillado para bobinadoras.	40
4.14. Área bajo curva ROC: predicción astillado para bobinadoras.	40
4.15. Característica operativa del receptor: predicción astillado para bloque.	41
4.16. Área bajo curva ROC: predicción astillado para bloque.	42

4.17. Raíz de Error Cuadrático Medio: predicción de la probabilidad de astillado para bobinadoras.	43
4.18. Coeficiente de Determinación ó R^2 : predicción de la probabilidad de astillado para bobinadoras.	43
4.19. Raíz de Error Cuadrático Medio: predicción de la probabilidad de astillado para el bloque.	44
4.20. Coeficiente de Determinación ó R^2 : predicción de la probabilidad de astillado para el bloque.	44
4.21. Valor predicho contra valor real: predicción de la probabilidad de astillado para bobinadoras.	45
4.22. Valor predicho contra valor real: predicción de la probabilidad de astillado para el bloque.	46
4.23. Diagrama de cajas de la probabilidad de defecto predicha en función del astillado real para bobinadoras.	47
4.24. Diagrama de cajas de la probabilidad de defecto predicha en función del astillado real para el bloque.	47
4.25. Comparación curvas ROC del modelo de regresión de probabilidad_astillado como modelo de clasificación y del modelo de clasificación para bobinadoras.	49
4.26. Comparación curvas ROC del modelo de regresión de probabilidad_astillado como modelo de clasificación y del modelo de clasificación para el bloque.	49
4.27. Comparación del área bajo la curva ROC de ambas modalidades de clasificación y de los distintos algoritmos considerados para bobinadoras.	50
4.28. Comparación del área bajo la curva ROC de ambas modalidades de clasificación y de los distintos algoritmos considerados para el bloque.	51
4.29. Bootstrapping del área bajo la curva ROC para la comparación de las dos modalidades de predicción de astillado para bobinadoras.	53

4.30. Bootstrapping del área bajo la curva ROC para la comparación de las dos modalidades de predicción de astillado para el bloque.	54
4.31. Coste del clasificador en función del umbral de detección, para bobinadoras.	56
4.32. Coste del clasificador en función del umbral de detección, para el bloque.	56
4.33. Importancia de variables en bobinadoras.	62
4.34. Importancia de variables en el bloque.	62
4.35. Importancia de variables para el acero 076 en bobinadoras.	63
4.36. Importancia de variables para el acero 076 en el bloque.	64
4.37. Importancia de variables de cajas de laminación y alargamientos para la laminación del diámetro 15.	65
4.38. Gráfico de dependencias parciales para temperaturas, permanencia y gas en horno + dúo para bobinadoras.	66
4.39. Gráfico de dependencias parciales para temperaturas, permanencia y gas en horno + dúo para el bloque.	67
4.40. Gráfico de dependencias parciales para las variables específicas de bobinadoras.	68
4.41. Gráfico de dependencias parciales para las variables específicas del bloque.	69
4.42. Gráfico de dependencias parciales para las variables de cajas de laminación en la fabricación del diámetro 15.	69
4.43. Gráfico de dependencias parciales para las variables de composición química en la fabricación del tipo de acero 076 en el bloque.	70
4.44. Gráfico de descomposición.	70
4.45. Gráfico de descomposición.	71
4.46. Gráfico Ceteris Paribus de un rollo laminado en bobinadoras.	71
4.47. Gráfico Ceteris Paribus de un rollo laminado en el bloque, acero 076.	72
4.48. Gráfico Ceteris Paribus de un rollo laminado en el bloque, diámetro 15.	73

Índice de tablas

2.1. Estado del arte de soluciones de predicción de defectos en la fabricación de productos de acero	13
4.1. Matriz de confusión para la predicción del astillado mediante mapa autoorganizado para bobinadoras	33
4.2. Matriz de confusión para la predicción del astillado mediante mapa autoorganizado para el bloque	33
4.3. Matriz de confusión para la predicción del astillado mediante modelo de regresión, algoritmo de Bosques Aleatorios, para bobinadoras	57
4.4. Matriz de confusión para la predicción del astillado mediante modelo de regresión, algoritmo de Bosques Aleatorios, para el bloque	57
4.5. Matriz de confusión para la predicción del astillado mediante modelo de regresión, algoritmo de Bosques Aleatorios, para tipo de acero 076	59
4.6. Reglas del Sistema de Monitorización de Condiciones para prevenir el astillado para el tipo de acero 076.	59
4.7. Matriz de confusión según las reglas del Sistema de Monitorización de Condiciones para tipo de acero 076	59

Miguel Ángel González González
Monitorización del estado de calidad en un proceso de laminación en caliente de acero inoxidable
mediante técnicas de aprendizaje automático

1. Introducción

1.1 Motivación

La exigencia de calidad en la industria metalúrgica es cada vez mayor. Los defectos que se producen durante la colada continua y la laminación en caliente tienen un fuerte impacto negativo en la fabricación y procesado en frío de productos de acero. Los defectos no solo tienen un coste en cuanto al desperdicio de material o la necesidad de procesos adicionales necesarios para su eliminación, sino que suponen además un enorme impacto medioambiental. La industria metalúrgica es una de las industrias con mayor demanda energética y con mayores emisiones de gases que causan el efecto invernadero. Sin embargo, la variabilidad de composiciones químicas, la extremada complejidad de los procesos y la diversidad de los productos producidos dificulta el análisis de los procesos y los factores que inciden en la presencia de los distintos defectos.

Durante la deformación del metal, debido a las fuerzas de compresión ejercidas por los rodillos de laminación en caliente, se producen esfuerzos cortantes superficiales como consecuencia de la fricción entre los rodillos y el metal. Varios parámetros influyen, tales como el factor de reducción, alargamiento, velocidad, temperatura, microestructura, etc. Para abordar el análisis de estos factores suelen utilizarse simulaciones mediante modelado por elementos finitos que consideran el compromiso entre el comportamiento dúctil y el endurecimiento del metal durante su laminación, así como métodos experimentales (Dwivedi et al., 2017; Ervasti y Ståhlberg, 2000; González-Castillo et al., 2021; Drobne et al., 2017; Commission et al., 2009; Mirjana, 2007).

Sin embargo, el enfoque seguido en este trabajo es diferente. La utilización combinada de modelos matemáticos junto con métodos de aprendizaje automático permitiría abordar la problemática desde una perspectiva más global así como encontrar las dependencias multidimensionales entre defectos y la composición química junto con la infor-

mación de proceso para paliar la complejidad de los modelos de simulación y el elevado coste de los experimentos. Este enfoque está en línea con la actual tendencia de generar información útil a partir de los datos que habilite una toma de decisiones más eficaz.

1.2 Planteamiento del problema

El enfoque habitual es, después del pertinente análisis exploratorio de datos, construir un modelo de predicción de defectos mediante aprendizaje automático supervisado de tipo clasificación donde cada instancia consiste en una palanquilla laminada junto con sus características, composición y variables de proceso, mientras que la variable a predecir es la presencia o ausencia del defecto considerado. Para ello se entrenan varios modelos diferentes con un conjunto de datos reservados para el entrenamiento y se evalúan con un conjunto de datos diferente, seleccionando aquel que evidencia mejor desempeño para ser desplegado y puesto en producción. Los inconvenientes habituales en este tipo de aproximaciones es el desequilibrio de clases (generalmente el número de instancias con defecto es mucho menor) y su solapamiento (Napierala y Stefanowski, 2015; Krawczyk, 2016; Xiong et al., 2010). A estos inconvenientes podemos añadir la incertidumbre en la calificación del defecto que es realizada por diferentes inspectores humanos. La salida probabilística del modelo de clasificación podría servir como indicador del estado del proceso en relación con el defecto considerado: cuanto mayor sea su valor, más probable que aparezca el defecto. De esta forma, este indicador del estado del proceso podría guiar la modificación de las consignas de trabajo para llevar al proceso a un estado más seguro.

Sin embargo, en este trabajo consideraremos un enfoque alternativo que será comparado con el anterior. Determinaremos un indicador del estado del proceso de laminación en caliente basado en el porcentaje de rollos procesados defectuosos que será calculado mediante una media móvil. Cuanto mayor sea este indicador, podemos suponer más marcadas las condiciones que favorecen la aparición del defecto que son compartidas por los productos que son procesados en proximidad temporal. Así, convertimos un pro-

blema de aprendizaje automático de clasificación en otro de regresión que predice este indicador de estado. Compararemos el indicador así obtenido con la salida probabilística del modelo de clasificación anterior para evaluar cuál tiene mejor desempeño en la predicción de defectos utilizando distintas métricas de modelos de clasificación. Asimismo, se comparará el desempeño del mejor modelo obtenido con un Sistema de Monitorización de Condiciones que ha sido aplicado en la industria para la laminación de cierto tipo de acero.

Finalizaremos con un análisis explicativo del mejor modelo predictivo obtenido que muestre la influencia de cada variable en la aparición del defecto proporcionando así una guía que permita conducir el estado del proceso en relación con la calidad a una situación más segura.

1.3 Estructura de la memoria

En el capítulo 1, introductorio, se ha expuesto la problemática asociada a la aparición de defectos en el proceso de laminación en caliente en la fabricación de acero inoxidable, exponiendo distintas formas de abordarla y justificando la utilización de técnicas de aprendizaje automático. Como planteamiento del problema se ha optado por contraponer la solución habitual consistente en obtener un modelo de predicción mediante algoritmos de clasificación, con una solución basada en algoritmos de regresión que predigan un indicador de riesgo de aparición del defecto y comparar el modelo más eficiente con un Sistema de Monitorización de Condiciones de aplicación real.

En el segundo capítulo se describe el contexto y el estado del arte. En la primera sección se explicara cómo se desarrolla el proceso de fabricación y cómo se generan los datos que serán utilizados en el entrenamiento y evaluación de los modelos. La siguiente sección describe el estado del arte relativo a la aplicación de técnicas de aprendizaje automático en la predicción de defectos en procesos de fabricación del acero, con especial atención a la laminación en caliente.

El tercer capítulo expondrá los objetivos general y específicos y detallará la metodo-

logía de trabajo a seguir.

El desarrollo del trabajo centra el cuarto capítulo, cuya estructura sigue, de forma general, la metodología CRISP-DM, es decir, dedica secciones al análisis exploratorio de datos, modelado, evaluación, explicación y despliegue. Adicionalmente, se analiza la salida del modelo de predicción como indicador del estado de calidad del proceso. El análisis exploratorio de datos incluye la transformación de los datos, visualizaciones varias, análisis de correlaciones y el uso de Mapas Autoorganizados en modo supervisado y no supervisado. El objetivo último de este capítulo es la comparación de dos aproximaciones diferentes para resolver el problema de la construcción del modelo de predicción de astillado, buscando una solución adecuada al problema de determinación de un indicador del estado del proceso, así como comparar el desempeño de este indicador con un Sistema de Monitorización de Condiciones de aplicación real. Finalmente, se expondrán las técnicas de explicación del modelo que permitirían guiar el sistema productivo a un estado libre de defectos.

El trabajo finaliza con las conclusiones y líneas de trabajo futuras.

2. Contexto y Estado del Arte

2.1 Proceso de fabricación y generación de los datos

Los datos de composición química y de proceso se han obtenido de una fábrica de producción de producto largo de acero inoxidable utilizando palanquillas como materia prima. Éstas son barras de acero inoxidable fabricadas a partir de acero en crudo, que no tienen las esquinas pulidas. Tienen una sección cuadrada de 200 mm y longitud entre 5 y 8 metros, y son suministradas desde otra fábrica que realiza la colada continua, que es el proceso de fabricación consistente en la solidificación del metal fundido en la palanquilla, tocho o planchón para su posterior laminado en caliente. La laminación en caliente consiste en el calentamiento de la palanquilla en un horno de calentamiento que permita la reducción y conformación de la sección de la palanquilla mediante la compresión realizada por diversas cajas laminadoras. Finalmente, un inspector humano identifica y califica la calidad del rollo de alambρόn resultante mediante un software de trazabilidad que asegura la correcta identificación del producto a lo largo del proceso. La figura 2.1 muestra un esquema del proceso de laminación en caliente objeto de este estudio.

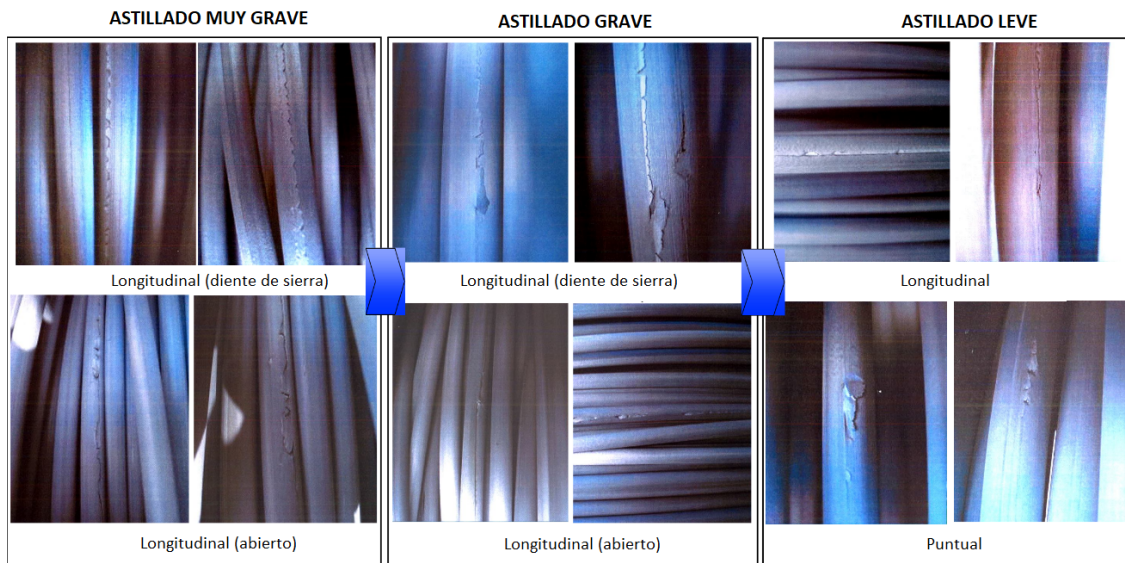
Figura 2.1: Esquema del proceso productivo objeto de estudio.



Fuente: Elaboración propia.

Uno de los defectos característicos es el astillado que consiste en una rotura más o menos grave detectable en la superficie del material. Si no es grave, el problema se puede eliminar descortezando el rollo lo cual supone un coste adicional. Si el astillado es grave, el rollo es rechazado como chatarra. La figura 2.2 muestra los criterios de calificación del

Figura 2.2: Calificación del defecto “Astillado”.



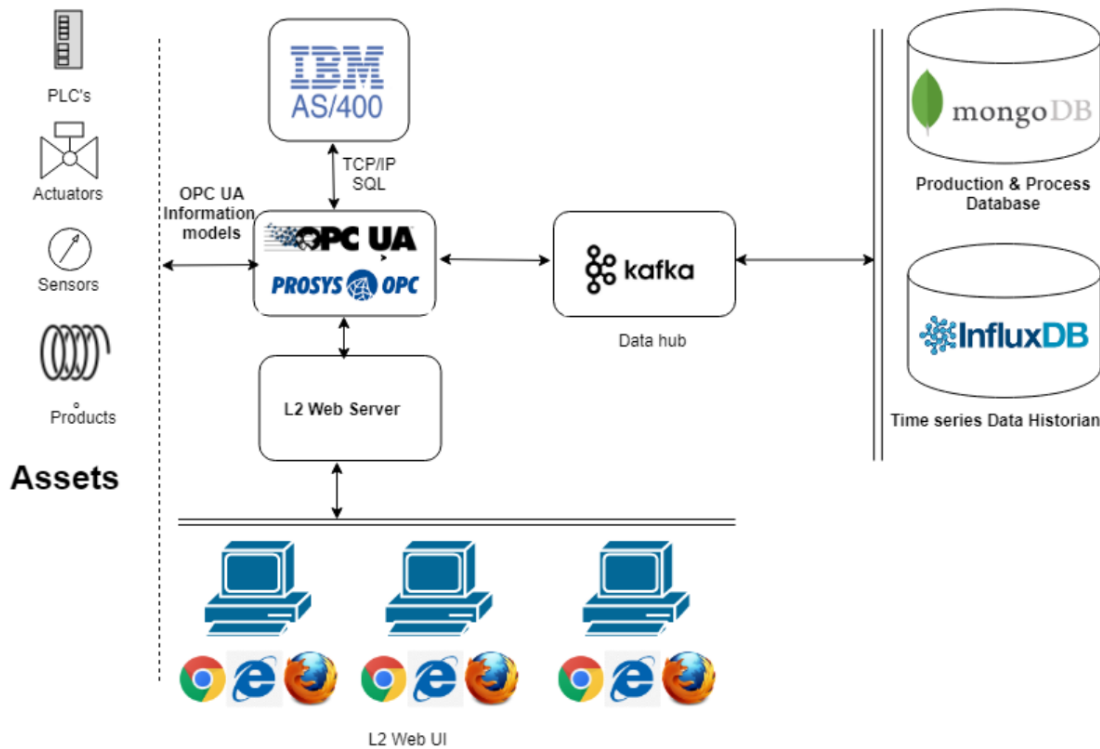
Fuente: Elaboración propia.

defecto *astillado*.

El proceso de laminación en caliente distingue dos caminos de proceso. Cuando el diámetro del alambón es igual o superior a 16 mm. el proceso de laminación en caliente termina en una pareja de bobinadoras e inmersión en agua para continuar después a las etapas de inspección, flejado, compactado, pesado y etiquetado. Si el diámetro es inferior a 16 mm., el proceso requiere una laminación adicional en un bloque de finalización, inmersión en una balsa de agua y dispositivo de formación de espiras. A continuación es inspeccionado, flejado, compactado, pesado y etiquetado. Por esta razón se considerarán dos procesos de laminación diferentes en función del diámetro: bobinadoras y bloque.

Un sistema informático realiza la trazabilidad completa de cada palanquilla/rollo a lo largo del proceso, incorporando a cada producto una estadística de las variables de proceso. Este sistema informático, además, estima la temperatura de calentamiento en el corazón de la palanquilla así como en su exterior utilizando el método de elementos finitos y un modelo del intercambio de calor por radiación en el horno. Cuando está habilitado, el módulo del Sistema de Monitorización de Condiciones comprueba en línea si se produce una desviación en el proceso de acuerdo a las especificaciones del Departamento Técnico y, si es así, genera una alarma que informa al operador sobre la acción a

Figura 2.3: Arquitectura informática para la adquisición y almacenamiento de información de proceso.



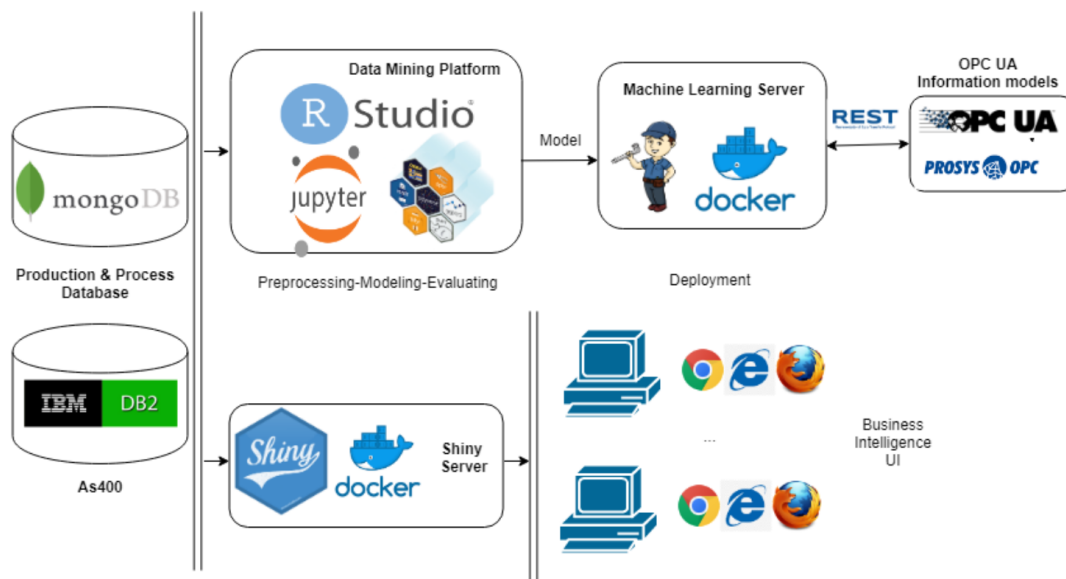
Fuente: Elaboración propia.

realizar. Además, almacena esta información estadística de proceso en una base de datos NoSQL para ser explotada posteriormente combinada con otras informaciones. La figura 2.3 muestra un esquema de la arquitectura informática que permite la inserción de información de proceso contextualizada para cada producto procesado en bases de datos con propósitos específicos: una base de datos No-SQL para información estadística de proceso e InfluxDB para series de tiempo. La figura 2.4 muestra la integración de las bases de datos con la plataforma de Ciencia de Datos para la analítica de datos y la puesta en producción de los modelos predictivos.

2.2 Estado del arte

Mirjana (2007) realiza un análisis exhaustivo de los defectos que se producen durante la laminación en caliente de barras y alambroón de acero. Explica que el diseño de la configuración de rodillos es determinante para la forma y calidad del producto laminado,

Figura 2.4: Integración de bases de datos de características y proceso con herramientas de Ciencia de Datos.



Fuente: Elaboración propia.

enumerando algunas variables influyentes tales como el ratio de reducción de área, la tasa de deformación, el histórico de temperatura y la composición química. Establece una clasificación de defectos que se pueden producir en la laminación de barra y alambρόn dividiéndolos según su origen: defectos producidos en la metalurgia o por su composición química, defectos debidos a una práctica de laminación inadecuada y defectos como consecuencia de un diseño deficiente de configuración de rodillos. Dentro de los defectos metalúrgicos, menciona las grietas longitudinales (longitudinal surface cracks) en la planquilla, difíciles de eliminar y que continúan como defectos en el rollo o barra laminada. Por otra parte, las grietas (cracks), los arañazos (scratches), las aletas (fins), los pliegues (laps), las grietas transversales (corner cracks), los astillados (slivers) y la porosidad (porosity) se originan por una laminación incorrecta o por superficies de rodillos defectuosas. Estos defectos se propagan extendiéndose a lo largo de la pieza durante el resto de la laminación. Sin embargo, los defectos en ocasiones presentan apariencias similares que, junto a diferencias de criterio por parte de los inspectores humanos, contribuye a crear cierta incertidumbre en esta calificación (Yun et al., 2008).

Cser et al. (1999) realizan una síntesis general de las líneas principales de investigación relativas al uso de la minería de datos y otras técnicas de inteligencia artificial para la predicción de defectos así como para la comprensión de sus causas subyacentes en el proceso de laminación en caliente de acero. Proponen una monitorización del estado del proceso relacionado con la calidad de la producción apoyándose en Mapas Autoorganizados que permiten reconocer dependencias ocultas que influyen en los parámetros de calidad. Asimismo, señalan la utilización creciente de Redes Neuronales para la predicción de variables de proceso en combinación con modelos matemáticos de los procesos. También destacan el valor de la minería de datos para el análisis de la influencia de diferentes parámetros y variables del proceso como alternativa a los caros experimentos de laboratorio.

El objetivo de Haapamäki et al. (2005) es identificar las condiciones de proceso de alto riesgo así como la parte del proceso que favorece la aparición del óxido. Los modelos de predicción se implementan mediante Redes Neuronales utilizando un sistema de visión por computador para etiquetar las instancias con defecto así como un conjunto de datos a partir de un proceso de laminación en caliente real. Los datos utilizados consistían en valores estadísticos relativos a la composición, dimensiones, temperaturas, fuerzas y velocidades de laminación así como flujos y presiones de las cajas de agua de enfriamiento. La variable objetivo era el contaje del defecto de óxido que era obtenido mediante el sistema automático de inspección de defectos. Los resultados obtenidos señalan una importancia compleja debida al efecto de la temperatura. El mejor modelo basado en Mapas Autoorganizados tuvo una sensibilidad de 0,54 y precisión de 0,88. La red neuronal proporcionó una sensibilidad de 0,16 y una precisión de 0,27. En otro trabajo, Haapamäki y Röning (2005) utilizaron Algoritmos Genéticos como alternativa a las Redes Neuronales para obtener una solución matemática para la formación del óxido.

El modelo desarrollado por Sayed y Hamid (2010) predice defectos de hoyuelos y ampollas en productos de acero de bajo contenido en carbono, los cuales, cuando se producen, requieren el rectificado de la superficie para eliminarlos. Un modelo de minería

de datos basado en Árboles de Decisión, Redes Neuronales y Reglas de Asociación predice la aparición del defecto a partir de información del análisis del material junto con información de proceso. El conjunto de datos incluye la composición química así como parámetros efectivos del proceso de colada. El modelo de reglas de asociación, que fue el que tuvo el mejor desempeño para los productos de bajo carbono, tuvo una exactitud de 0,64. Para productos de muy bajo carbono, el mejor modelo fue de árboles de decisión, con una exactitud de 0,83. Finalmente, la red neuronal ofreció la mejor exactitud para productos con molibdeno, con una exactitud de 0,76.

Vlado et al. (2011) predicen la evolución de grietas longitudinales y transversales en la superficie de una plancha continua de acero colado durante la laminación en caliente en relación con una simulación numérica y un modelo de aprendizaje automático basado en árboles de decisión.

El trabajo de Hietaniemi et al. (2008) trata sobre la predicción de defectos en pletinas de acero utilizando Redes Neuronales y Máquinas de Vectores de Soporte combinadas con métodos de selección de características. Los defectos son, frecuentemente, debidos a temperaturas inadecuadas o medidas dimensionales, y suponen un sobre coste por el requerimiento de un proceso manual de inspección y las pérdidas por postprocesado del material defectuoso. Se utilizaron datos de una fábrica de laminación de pletinas de Finlandia que incluía temperaturas a lo largo del proceso, velocidades y tiempos. El desempeño logrado fue evaluado con una sensibilidad de 0,73 con Redes Neuronales y de 0,71 con Máquinas de Vectores de Soporte. La precisión fue de 0,48 y 0,50, respectivamente. Como método de aprendizaje no supervisado, se utilizaron Mapas Autoorganizados.

Lieber et al. (2013) inciden en la predicción de la calidad física de productos intermedios en procesos interrelacionados de fabricación de productos de acero mediante procesos de laminación en caliente como uno de los proósitos principales de su trabajo. Para ello utilizan una combinación de métodos de minería de datos supervisada (Árboles de Decisión, k-Vecinos, Máquinas de Vector de Soporte) y no supervisada (k-Vecinos, Mapas Autoorganizados). El modelo que mejor predijo la dimensión final del producto fue

el algoritmo de k-Vecinos con una exactitud de 0,97.

En (Jokhakar y Patel, 2015) el defecto a predecir es la desviación de temperatura de bobinado en la producción de bobinas de acero. Los autores presentan un modelo de aprendizaje automático basado en Bosques Aleatorios cuyos resultados se traducen en reglas para generar nuevos modelos de control. Como métrica de desempeño, publican un área bajo la curva ROC de 0,833.

Ruiz et al. (2021) proponen un modelo de clasificación para la predicción de presencia de inclusiones a partir de un conjunto de datos que incluye información experimental de acero conformado en frío fabricado mediante un horno de arco eléctrico y laminado en caliente. Evaluaron distintos algoritmos tales como Regresión Logística, k-Vecinos Más Próximos, Árbol de Decisión, Bosques Aleatorios, AdaBoost, Potenciación de Gradiente, Clasificador por Vectores de Soporte y Redes Neuronales, optando finalmente por los Bosques Aleatorios. Además, utilizaron el método de la característica de la permutación para identificar las variables que influyen en el defecto así como gráficos de dependencias parciales para determinar el impacto de las variables en la presencia del defecto. El mejor resultado se obtuvo con Bosques Aleatorios, con un área bajo la curva ROC de 0,822, una sensibilidad de 0,709 y una precisión de 0,749.

El trabajo presentado por Takalo-Mattila et al. (2022) consiste en un sistema de predicción de calidad en el acero basado en Árboles de Potenciación de Gradiente (gradient boosting trees) con el objetivo de detectar defectos superficiales en las primeras etapas del proceso de fabricación. Los datos se obtuvieron de una fábrica de producción de acero. El modelo se integró con una herramienta de monitorización de calidad con el propósito de centrar la atención durante la tarea de inspección en aquellos productos con mayor riesgo de presentar defectos según la predicción del modelo. Finalmente, se utilizó una herramienta de explicación de modelos para obtener mayor conocimiento sobre la relación de las variables de proceso y los defectos superficiales. El modelo obtenido fue finalmente desplegado en producción. La métrica de desempeño empleada fue el área bajo la curva ROC, con un valor de 0.81 y de 0,71 para cada uno de los conjuntos de datos

utilizados.

La tabla 2.1 muestra un resumen del estado del arte relativo a la predicción de defectos en procesos de producción de productos de acero que fue anteriormente descrito. Los distintos trabajos que abordan esta problemática siguen unas líneas generales comunes, consistentes en la predicción de defectos superficiales mediante algoritmos de aprendizaje automático a partir de información característica de la materia prima así como de información del proceso. En algún caso se complementan con modelos matemáticos o técnicas de aprendizaje no supervisado para facilitar el análisis exploratorio o proporcionar claves para el posterior aprendizaje supervisado. En lo relativo al desempeño de las distintas soluciones, resulta complicado comparar los resultados obtenidos porque los defectos a predecir, los procesos y las métricas son diferentes. De forma general, podríamos decir que los modelos más eficaces arrojan un área bajo la curva ROC próxima al 0,8.

Por otra parte, no siempre se hace explícito el propósito último del modelo de predicción. Es necesario que éste ayude a evitar, de una forma u otra, que se produzca el defecto. No aporta mucho valor predecir un defecto cuando el proceso de producción se ha completado y el daño está hecho. Así, Haapamäki et al. (2005) indican que su propuesta permitiría reconocer las condiciones del proceso que favorecen la aparición del defecto, así como la etapa del proceso en el que se producen. Esta es la solución que además se aproxima más a la propuesta de Cser et al. (1999) en cuanto a la monitorización en línea del estado del proceso relacionado con la calidad de la producción. Otras aplicaciones se refieren al aumento del conocimiento del proceso creando reglas de cara a nuevos modelos de control (Sayed y Hamid, 2010) o mediante la utilización de herramientas de explicación de modelos (Ruiz et al., 2021; Takalo-Mattila et al., 2022).

Este trabajo incidirá en la creación de un indicador del estado del proceso relacionado con la aparición del defecto de astillado siguiendo así el enfoque de Cser et al. (1999) y planteará además una alternativa al habitual modelo supervisado de clasificación. Asimismo, extenderá la aplicación de técnicas de aprendizaje automático a la predicción de defectos en la producción de acero inoxidable en aras de una mejor comprensión de las

causas de su aparición.

Tabla 2.1: Estado del arte de soluciones de predicción de defectos en la fabricación de productos de acero

Trabajo	Proceso	Defectos	Aprendizaje supervisado	Aprendizaje no supervisado	Desempeño
Haapamäki et al. (2005)	Laminación en caliente	Óxido	Red neuronal	Mapas Autoorganizados	0,54 (TPR) y 0,88 (PPV)
Haapamäki y Rönning (2005)	Laminación en caliente	Óxido	Modelo matemático de predicción de óxido resuelto mediante Algoritmos Genéticos	Mapas Autoorganizados	
Sayed y Hamid (2010)	Colada continua	hoyuelos y ampollas	Árboles de Decisión, Redes Neuronales y Reglas de Asociación		0,64, 0,83 y 0,76 (ACC)
Vlado et al. (2011)	Laminación en caliente	Grietas longitudinales y transversales	Árboles de Decisión		
Hietaniemi et al. (2008)	Laminación en caliente		Redes neuronales y Máquinas de Vectores de Soporte		0,73 (TPR) y 0,48 (PPV)
Lieber et al. (2013)	Laminación en caliente		Árboles de Decisión, k-Vecinos, Máquinas de Vectores de Soporte	k-Vecinos, Mapas Autoorganizados	0,97 (ACC)
Jokhakar y Patel (2015)	Laminación en caliente	Desviación de temperatura de bobinado	Bosques Aleatorios		0,83 (AUC)
Ruiz et al. (2021)	Horno de arco eléctrico y laminación en caliente	Inclusiones	Regresión Logística, k-Vecinos Más Próximos, Árbol de Decisión, Bosques Aleatorios, AdaBoost, Potenciación de Gradiente, Clasificador por Vectores de Soporte y Redes Neuronales		0,82 (AUC), 0,71 (TPR) y 0,75 (PPV)
Takalo-Mattila et al. (2022)	Colada continua		Árboles de Potenciación de Gradiente		0,81 (AUC)

Nota: En la columna de desempeño, TPR es sensibilidad, PPV es precisión, AUC es área bajo la curva ROC y ACC es exactitud.

Fuente: Elaboración propia.

Miguel Ángel González González
Monitorización del estado de calidad en un proceso de laminación en caliente de acero inoxidable
mediante técnicas de aprendizaje automático

3. Objetivos

En este capítulo se enuncian los objetivos general y específicos, así como la descripción de la metodología de trabajo a seguir, en el marco de la creación de un indicador del estado de proceso relacionado con el defecto de astillado durante el calentamiento y laminación en caliente de rollos de acero inoxidable.

3.1 Objetivo general

La contribución de este trabajo consistirá en:

- Extender la aplicación de técnicas de aprendizaje automático para la predicción de cierto tipo de defectos superficiales, los astillados, en procesos de laminación en caliente de acero inoxidable.
- Desarrollar la propuesta relativa a la monitorización del estado del proceso creando un indicador vinculado a la probabilidad de aparición del defecto mediante técnicas de aprendizaje automático. Este indicador permitiría la observación de una variable de estado oculta del sistema de fabricación, determinado por las características del producto procesado y por las variables de proceso, que indica la propensión del sistema a causar la aparición del defecto. El siguiente apartado, que describe los objetivos específicos, ofrece más detalles sobre este proceso.
- Comparar el desempeño del indicador de defecto con un Sistema de Monitorización de Condiciones que ha sido aplicado en la industria para la laminación de cierto tipo de acero. Para ello, consideraremos este sistema como un clasificador basado en reglas.
- Proporcionar una guía basada en esta variable de estado, junto con un modelo explicativo con gráficas de dependencias parciales, que indicaría a qué valores hay que guiar ciertas variables de proceso para llevar al sistema a un estado más seguro.

3.2 Objetivos específicos

La predicción de defectos mediante técnicas de aprendizaje automático suele abordarse mediante la construcción y evaluación de un modelo supervisado de clasificación. Éste será el enfoque a seguir en la primera parte del desarrollo de este trabajo, y para ello se entrenarán, evaluarán y compararán diferentes algoritmos de aprendizaje automático de clasificación.

Sin embargo, también se determinará un indicador de estado que mida el riesgo de aparición del defecto. Este indicador será predicho utilizando algoritmos de aprendizaje automático de regresión. Igualmente, se entrenarán, evaluarán y compararán diferentes algoritmos de aprendizaje automático de regresión.

Posteriormente, se compararán las dos opciones con el objetivo común de predecir el estado de defecto en el conjunto de datos de test. Para ello, se utilizará el valor del indicador como la probabilidad de que cada instancia a predecir corresponda a la clase positiva, es decir, sea defectuosa.

Por último, se comparará el desempeño y coste asociado del modelo obtenido mediante aprendizaje automático con modelo de clasificación basado en las reglas de un Sistema de Monitorización de Condiciones. Para ello se calcularán las métricas de desempeño como clasificador y el coste debido a los falsos positivos y negativos.

La siguiente sección expondrá de forma precisa la metodología del trabajo a seguir.

3.3 Metodología del trabajo

En primer lugar se hará referencia a las fuentes de datos. Las estadísticas de información de proceso están disponibles en una base de datos NoSQL mientras que la información sobre las características y calidad de los productos residen en la base de datos DB2 del sistema informático de gestión de recursos de la compañía. La población estudiada data desde junio hasta mediados de octubre del 2022. Estas serán nuestras fuentes de datos. El conjunto de datos se divide en dos: uno relativo a la laminación en caliente siguiendo el proceso de bobinadoras y otro para el proceso del bloque. Se utilizará como

variable a predecir la calificación de defecto, en la opción de modelo de clasificación, y el indicador de probabilidad defecto en la opción del modelo de regresión. Los atributos o predictores serán las estadísticas de proceso durante su calentamiento en el horno (tiempos y temperaturas), características dimensionales, composición química y variables de proceso durante la laminación en caliente. Estas últimas son diferentes según el camino bobinadoras o bloque. El preprocesamiento de los atributos incluirá un escalado y una codificación de variables categóricas de tipo one-hot.

La metodología para la obtención de los modelos de aprendizaje automático es CRISP-DM ó Cross Industry Standard Process for Data Mining (Gallardo Arancibia, 2009) en la que se siguen iterativamente las fases que se relacionan a continuación: comprensión de los objetivos del proyecto, estudio y comprensión de los datos, análisis de los datos y selección de características, modelado y evaluación. El modelo resultante será desplegado. La consulta de los datos, limpieza, análisis exploratorio así como el entrenamiento, evaluación y selección de modelos será realizado utilizando el ecosistema del lenguaje R, en particular con la colección de librerías de tidyverse (Wickham et al., 2019) y mlr3 (Lang et al., 2019).

Siguiendo las líneas planteadas en el estado del arte, durante en análisis exploratorio de datos utilizaremos mapas Autoorganizados(Kohonen, 1995), que permiten agrupar los datos utilizando un algoritmo de red neuronal no supervisado que crea representaciones internas organizadas espacialmente preservando las propiedades topológicas de los datos de entrada de modo que pueden ser visualizados en mapas de dos dimensiones. Nos serviremos de la librería en R kohonen (Wehrens y Buydens, 2007; Wehrens y Kruisselbrink, 2018)

Los algoritmos utilizados son **ranger**(Wright y Ziegler, 2017) que es una implementación de Bosques Aleatorios(Breiman, 2001), **rpart**(Therneau y Atkinson, 2019) que son Árboles de Decisión, **xgboost**(Chen y Guestrin, 2016; Chen et al., 2022) que es un algoritmo de Potenciación de Gradiente Extremo, **glmnet**(Friedman et al., 2010) ó Modelo Lineal Generalizado, **kknn**(Schliep y Hechenbichler, 2016) ó Clasificación de k-vecinos y

svm (Dimitriadou et al., 2009) ó Máquinas de Vectores de Soporte (Cortes y Vapnik, 1995).

El área bajo la curva ROC (Característica Operativa del Receptor) será utilizada como métrica de comparación de los modelos de clasificación mientras que el desempeño de los modelos de regresión será evaluado mediante la raíz del error cuadrático medio y mediante el coeficiente de determinación ó R^2 . Asimismo, el valor continuo generado por el modelo de regresión será utilizado como la predicción de probabilidad de defecto de un modelo de clasificación, lo que permitirá la selección del mejor modelo entre las opciones de clasificación y de regresión como modelos de predicción de defecto utilizando como métrica el área bajo la curva ROC. Para ello realizaremos un test estadístico que ponga a prueba que hay una mejor en el desempeño de ambas opciones. Realizaremos 10000 remuestreos con repetición del conjunto de datos de test, y para cada conjunto muestral calcularemos el área bajo la curva ROC mediante las dos opciones: modelo de clasificación de defecto y modelo de regresión de probabilidad de defecto. Posteriormente, se realizará la prueba t de Student mediante la función `R t.test` donde la hipótesis nula consiste en que no hay diferencia entre ambas distribuciones.

El siguiente paso será comparar el mejor modelo con un sistema de reglas de un Sistema de Monitorización de Condiciones que ha sido aplicado en la industria para la laminación de cierto tipo de acero. Podemos considerar la activación de las alarmas por infracción de límites como una predicción de defecto. Es decir, el Sistema de Monitorización de Condiciones se comporta como un clasificador basado en reglas y, consiguientemente, su desempeño puede evaluarse con las mismas métricas que cualquier modelo de clasificación. Obviamente, los datos con los que se realizará la evaluación no estarán influidos por la habilitación de este sistema, sino que se aplicarán sus reglas a los valores de las variables de proceso registradas. La comparación se realizará basada en el coste total debido a los falsos positivos y falsos negativos de las dos soluciones y aplicando un test estadístico como el descrito con anterioridad.

Sea p_a el porcentaje de astillados calculado como el ratio de falsos negativos respecto al total; p_r el porcentaje de recuperación calculado como la relación de verdaderos positi-

vos y falsos positivos respecto al total; r_s el sobrecoste unitario de reproceso de los rollos con defecto.; C_u el coste unitario producto correcto y C_r el coste de cada reproceso. Se ignoran las pérdidas por chatarra debidas a defectos graves.

$$p_a = \frac{FN}{T} \quad (3.1)$$

$$p_r = \frac{TP + FP}{T} \quad (3.2)$$

$$Coste = (1 - p_a)C_u + p_r C_r + p_a(1 + r_s)C_u \quad (3.3)$$

donde FN es el número de falsos negativos, TP el número de verdaderos positivos, FP el número de falsos positivos y T el número total de instancias de test.

Se realizará un test estadístico que valide si existe una diferencia estadísticamente significativa en los costes incurridos por ambos sistemas. Se realizarán 10000 remuestreos con repetición del conjunto de datos de test, y para cada conjunto muestral calcularemos FN, TP y FP según el modelo de aprendizaje automático y según el conjunto de reglas del Sistema de Monitorización de Condiciones. Posteriormente, se realizará la prueba t de Student mediante la función R `t.test` donde la hipótesis nula consiste en que no hay diferencia entre ambas distribuciones.

Finalmente, el modelo de aprendizaje automático generado será interpretado mediante DALEX (Biecek, 2018) lo que permitirá, por una parte, profundizar en el conocimiento sobre la relación de los distintos atributos y la aparición del defecto, y por otra, como orientación sobre la selección y transformación de atributos más adecuados.

Miguel Ángel González González
Monitorización del estado de calidad en un proceso de laminación en caliente de acero inoxidable
mediante técnicas de aprendizaje automático

4. Desarrollo del trabajo

El desarrollo del trabajo comenzará con un análisis exploratorio de los datos, posterior a la adquisición de los mismos. La primera parte consistirá en la transformación de los datos, resolviendo el problema de datos perdidos y seleccionando o creando nuevas variables. A continuación se realizarán distintas visualizaciones, se hará un análisis de correlaciones y se aplicarán técnicas de aprendizaje no supervisado, como los Mapas Autoorganizados.

Durante el proceso de modelado, se entrenarán varios algoritmos en las dos modalidades: el modelo de clasificación de astillado y el modelo de regresión de probabilidad de astillado.

A la etapa de modelado, seguirá la de evaluación y selección del mejor modelo. Se compararán los resultados de los diferentes modelos de clasificación utilizando como métrica el área bajo la curva ROC y se compararán los modelos de regresión mediante la raíz del error cuadrático medio y el coeficiente de determinación. A continuación, se compararán los distintos modelos como clasificadores, utilizando la predicción de probabilidad de astillado como la probabilidad de pertenencia a la clase positiva, es decir, el astillado. Finalmente se determinará el umbral de detección que minimice el coste total de los errores de predicción, falsos positivos y falsos negativos. Tanto en el modelado como en la evaluación, se utilizarán dos conjuntos de datos diferentes: uno para los rollos laminados en bobinadoras y otro para los productos procesados en el bloque. La realización de un test de Student del área bajo la curva ROC junto con un remuestreo con repetición del conjunto de datos de test permitirá la selección del mejor modelo.

Una vez seleccionado el mejor modelo para la predicción de astillado mediante aprendizaje automático, se comparará con un clasificador basado en reglas de acuerdo a un Sistema de Monitorización de Condiciones. Con este fin se llevará a cabo un test de Student del coste debido a los errores de predicción junto con un remuestreo con repe-

tición del conjunto de datos de test.

El capítulo dedicado al desarrollo finaliza con una explicación de la puesta en producción el modelo resultante, incluyendo herramientas de visualización de alto nivel que habiliten la toma de decisiones, facilitadas por métodos de interpretación del modelo predictivo. Los mejores modelos a aprendizaje automático suelen ser modelos de caja negra en los que es difícil determinar la relación entre los atributos y la salida del modelo de predicción. Existen diferentes técnicas, agnósticas al modelo, que permiten analizar estas relaciones. Así, proporcionan una guía que permitiría conducir al sistema productivo a un estado que ofrezca una mejor calidad de los productos. Se utilizarán gráficos de importancia de variables basadas en permutación, perfiles de dependencias parciales, gráficos de descomposición y perfiles Ceteris Paribus.

4.1 Análisis Exploratorio de los Datos

El proceso básico del Análisis Exploratorio de los Datos incluye una etapa de transformación de datos en la que se eliminan los valores faltantes o anómalos, se crean variables más útiles y se realiza una selección de predictores. Este proceso requiere además distintas visualizaciones que permitan el análisis y comprensión del problema mediante la información que los datos proporcionan en cuanto a estructura, relación entre variables y patrones. Este análisis será complementado con la creación de Mapas Autoorganizados, tanto en modo no supervisado como supervisado.

4.1.1 Transformación de los datos

El conjunto de datos inicial consta de 17675 instancias y 622 atributos seleccionados con base en el criterio del experto de dominio. Agruparemos estas variables según los siguientes grupos:

1. *Características*. Incluye variables relativas a las características físicas de la palanquilla original, pesos de entrada y salida así como el tipo del producto y diámetro al que fue asignada.

2. *Composición química*. Incluye valores de composición química así como valores químicos elaborados.
3. *Recepción*. Códigos de calidad de recepción de palanquilla. Han sido transformados en codificación one-hot.
4. *Horno*. Valores medidos de tiempos, temperaturas y caudales de gas en el horno de recalentamiento de palanquillas así como temperaturas estimadas obtenidas mediante un modelo matemático de estimación del calentamiento de las mismas.
5. *Dúo*. Valores de proceso en el desbaste del dúo incluyendo fallos, luces, intensidades, temperaturas de pasada y tiempos.
6. *Laminación general*. Alargamientos, intensidades, alturas de lazo, tiros, pares, temperaturas y tiempos de las cajas de laminación, así como velocidades de entrada y salida del tren.
7. *Bobinadoras*. Diferentes variables de proceso de las bobinadoras incluyendo cajas de agua, enfriamiento, temperaturas y tiempos.
8. *Bloque*. Alargamientos, intensidades, alturas de lazo, tiros, pares, temperaturas y tiempos de las cajas del bloque, incluyendo cajas de agua, temperaturas y tiempos.

La primera tarea de la transformación de variables consiste en obtener la variable a predecir, la que indica que el rollo producido ha sido calificado como astillado. Para ello se comprueba si en alguno de los códigos de calificación del inspector aparece el código que indica este defecto. La inspección se realiza en dos etapas del proceso, al final del proceso de laminación con el rollo en negro o después del decapado donde es más sencillo apreciarlo. Será el resultado de esta última inspección la que será utilizada. Consiguientemente, se eliminan todas las instancias que no han sido inspeccionadas después del decapado. Posteriormente, se calcula la variable indicativa de probabilidad de astillado para cada rollo como el porcentaje de rollos con astillado de los cinco rollos más próximos

en el tiempo al dado.

Asimismo, se realiza la codificación one-hot de los códigos de recepción de la palanquilla, se calculan los retardos en las medidas de temperatura a lo largo del proceso de laminación y se eliminan todos aquellos atributos con un porcentaje de valores faltantes superior al 20 %. El tratamiento de los valores perdidos termina con la eliminación de todas las instancias con valores perdidos.

Finalmente, se separa el conjunto de datos en dos partes, una relativa a la laminación en bobinadoras y otra en el bloque. El conjunto de datos dedicado al proceso en bobinadoras tiene 2792 instancias y 260 atributos, mientras que el relativo al bloque cuenta con 10174 instancias y 310 atributos.

4.1.2 Visualizaciones generales y análisis de correlaciones

La figura 4.1 muestra el porcentaje de instancias defectuosas en función del diámetro. En principio, se observa que los diámetros inferiores a 14.5 son menos problemáticos siendo 14.5 el que mayor porcentaje arroja. Recordemos que los diámetros inferiores a 16 son los se laminan en la sección del bloque mientras que los diámetros iguales o superiores a 16 por bobinadoras. Es decir, parece que los productos procesados por el bloque tienen los mejores pero también los peores porcentajes de defecto, empeorando con el aumento del diámetro. Sin embargo, este argumento se debilita al observar la figura 4.2 que señala el número de unidades producidas y defectuosas: los elevados porcentajes de defecto no son fiables debido al reducido número de ejemplares que corresponden a su medida. De acuerdo a este gráfico, los diámetros más problemáticos resultan ser el 11, 13, 15, 17 y, especialmente, el 21 para los cuales tenemos una mayor confianza por el número de rollos que considera. Con menos dudas, los diámetros más eficientes son los inferiores o iguales a 8,5.

Por otra parte, la figura 4.3 muestra el porcentaje de instancias defectuosas en función del tipo de acero mientras que la figura 4.4 indica el número de unidades producidas, distinguiendo las defectuosas, en función del tipo de acero. Los tipos de acero con mayor

Figura 4.1: Astillado respecto a diámetro.

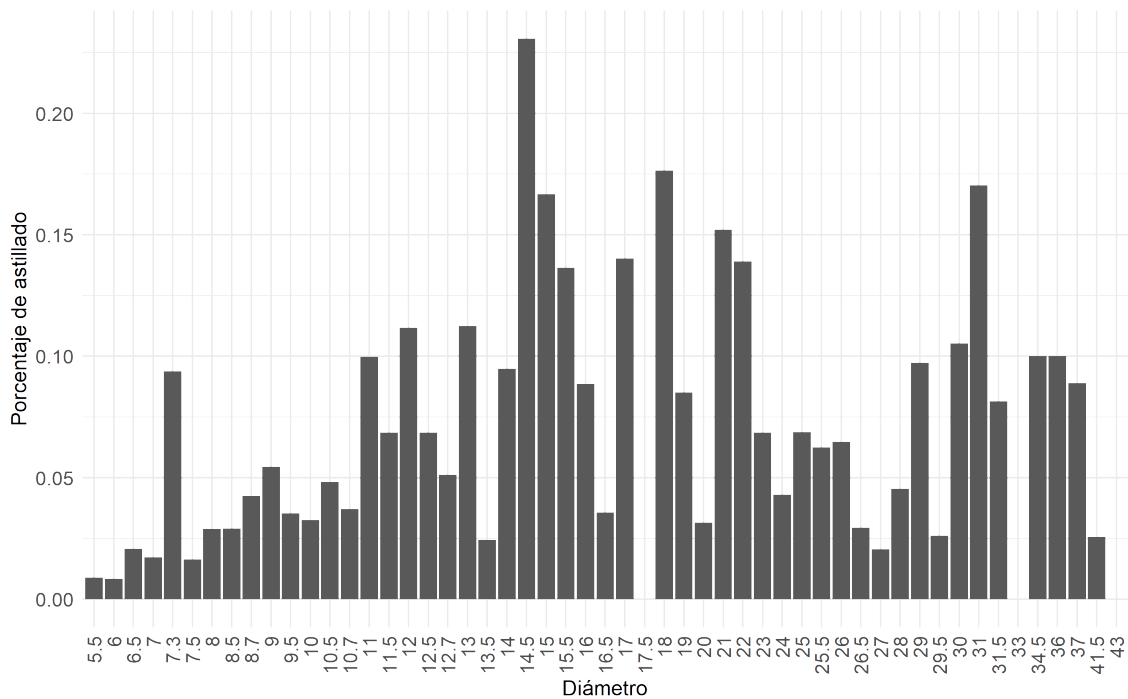



Figura 4.2: Unidades producidas en función del diámetro.



incidencia son el 076, 903, 915 y 917.

Finalmente, la figura 4.5 muestra la incidencia del astillado en función del tipo de acero y del diámetro. En gris se muestran aquellas combinaciones de tipo de acero y diá-

Figura 4.3: Astillado respecto al tipo de acero.






Figura 4.4: Unidades producidas en función del tipo de acero.



metro sin representación.

Figura 4.5: Frecuencia relativa del astillado en función del diámetro y tipo de acero.




A continuación, calcularemos y visualizaremos la correlación entre las variables.

- Entre pares de variables numéricas se calculará el coeficiente de correlación de Spearman, mediante la función `cor` con parámetro `method="spearman"` (R Core Team, 2021)
- Entre variables categóricas se calculará la V de Cramér basada en la estadística χ^2 de Pearson (Cramer, 1946) mediante la función `cramerV` (Mangiafico, 2022).
- Entre una variable categórica y otra numérica, mediante el análisis de varianza de una vía (One-Way ANOVA). Para ello se extrae la estadística R^2 del resumen (función `summary`) del modelo obtenido con la función `lm` (R Core Team, 2021).

Obtenemos una matriz de correlación cuadrada de dimensión 326 que no es posible visualizar de forma matricial. Una alternativa es representarla como una red en la que solo se consideran los nodos o variables unidos por correlaciones superiores a cierto valor, en

este caso 0.8. Para ello, utilizaremos el paquete qgraph (Epskamp et al., 2012). La figura 4.6 muestra las correlaciones entre variables superiores a 0.8.

Figura 4.6: Correlaciones superiores a 0.8 entre variables.



Generalmente corresponden a similitudes de valores entre cajas de laminación que se justifica porque su regulación en la automatización está ligada. También se reconocen similitudes entre temperaturas entre dos puntos consecutivos del proceso. Sería conveniente eliminar aquellas variables con fuertes correlaciones. Sin embargo, el propósito de este trabajo no es encontrar el mejor modelo de clasificación, sino comparar entre dos opciones: un modelo supervisado de clasificación de defecto y un modelo de regresión que estime la probabilidad de defecto. Las dos opciones tendrán que resolver la selección óptima de características.

Se observan los siguientes agrupamientos:

- Velocidades de las cajas de laminación.
- Velocidad de salida del tren ligada a la infravelocidad y periodo de wobulación de bobinadoras, por una parte, y al alargamiento, velocidad, intensidad y par en el bloque.

- Tiro en las cajas 01, 02, 03 04 y 05.
- Intensidades entre distintas pasadas del dúo.
- Intensidades en las cajas 01, 02, 03 y 04.
- Pesos en entrada y salida y retardos entre punta y cola de los pirómetros de laminación.
- Temperatura estimada en el corazón, temperatura en las segunda y quinta pasada del dúo, temperaturas medidas en el horno en calentamiento e igualación y temperaturas de punta y cola en la caja 01.
- Intensidades y pares en las cajas 10 y 11.
- Velocidades máximas en las últimas pasadas del dúo.
- Pares promedio, máximo y mínimo en las cajas 01 a 04.

En la figura 4.7 muestran las variables más correladas con el astillado mientras que en la figura 4.8 muestra las variables más correladas con la probabilidad de defecto. Las correlaciones no son muy elevadas, pero se observan diferencias importantes entre las variables más correladas con las variables astillado y probabilidad de astillado.

4.1.3 Aprendizaje no supervisado: Mapas Autoorganizados

En el capítulo relativo al análisis del estado del arte, varios autores hicieron referencia a la utilización de Mapas Autoorganizados para reconocer dependencias ocultas que influyen en la calidad de los productos fabricados. En la descripción de la metodología de trabajo, se indicó que se utilizarían Mapas Autoorganizados durante el análisis exploratorio de datos y que, con este fin, sería utilizada la librería en R kohonen (Wehrens y Buydens, 2007; Wehrens y Kruisselbrink, 2018)

Los Mapas Autoorganizados fueron presentados por Teuvo Kohonen en 1982 (Kohonen, 1982). Se trata de una red neuronal que utiliza aprendizaje competitivo para ajustar

Monitorización del estado de calidad en un proceso de laminación en caliente de acero inoxidable mediante técnicas de aprendizaje automático

Figura 4.7: Variables con mayor correlación con astillado.

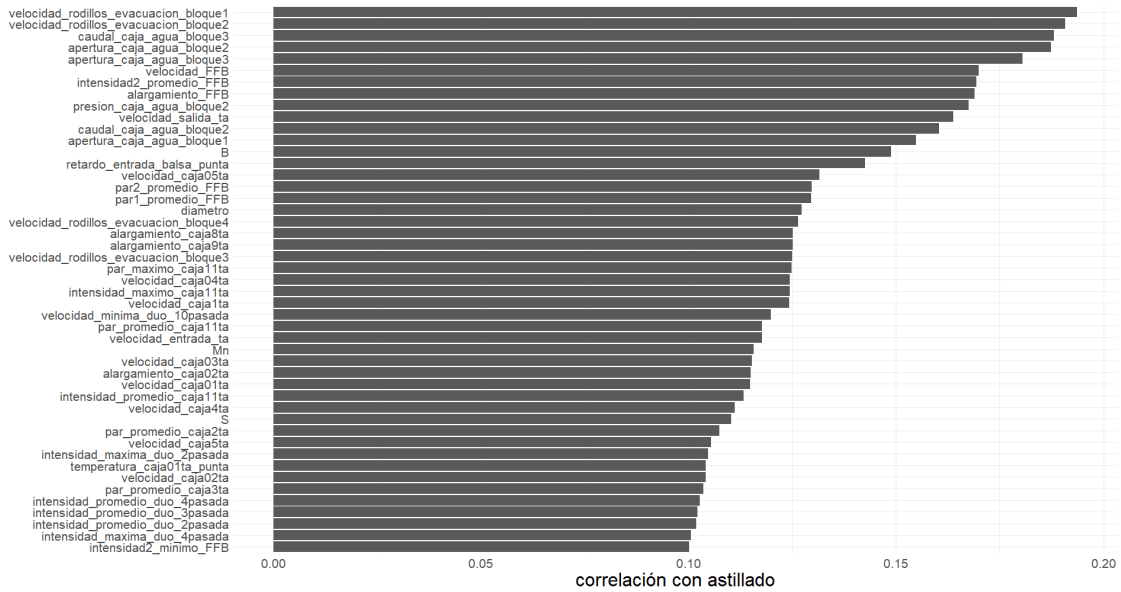



Figura 4.8: Variables con mayor correlación con probabilidad astillado.



sus pesos con el fin de crear una representación organizada espacialmente que permita la reducción de dimensión de los datos. Como no utiliza la propagación hacia atrás de errores ni el método del gradiente descendente, es capaz de conservar las propiedades topológicas del espacio de entrada. Consta de dos capas importantes, la de entrada y la de salida, también denominada mapa de características. Cada instancia en la entrada compete por su representación en la salida, de modo que se van ajustando los pesos que

minimicen la distancia entre el vector más próximo en la salida y la entrada.

Se prefiere al Análisis de Componentes Principales (ACP) como técnica de compresión de datos cuando estos tienen muchas dimensiones que son útiles. El número de componentes principales extraídos con ACP aumenta con el número de variables del conjunto de datos y éstos son combinaciones lineales de las variables extraídas. Dado que las variables no son generalmente combinaciones lineales de otras, estas limitaciones generalmente dificultan el análisis de datos multivariable, mientras que los Mapas Autoorganizados reconocen relaciones no lineales entre variables y permiten la representación en un mapa bidimensional. (Yin, 2007; Das et al., 2016).

La figura 4.9 muestra los mapas de color correspondiente a las variables de temperatura estimada en el corazón en la salida del horno, temperaturas medidas mediante termopares en las distintas zonas del mismo y temperaturas medidas mediante pirómetros en la segunda y quinta pasada del dúo y en la caja de laminación 01. Para ello calcula el promedio del valor de cada variable indicada agrupado con base en la unidad del mapa autoorganizado correspondiente que finalmente convierte a un color. Puede observarse la similitud entre ellas como consecuencia de la fuerte correlación que habíamos señalado en la sección anterior. De forma similar podrían observarse correlaciones entre otras variables.

La figura 4.10 muestra los Mapas Autoorganizados correspondientes a bobinadoras y al bloque, en celdas de 10x7 y 10x13, respectivamente. En rojo se señalan las instancias defectuosas mientras que en gris se grafican las instancias correctas, las cuales han sido asignadas a determinada unidad por la red según su similaridad topológica. No se reconoce una distribución de las instancias con astillado que indique que los Mapas Autoorganizados han reconocido un patrón que pueda relacionarse con el defecto, si bien sí se reconocen unidades con una mayor concentración de instancias defectuosas.

A continuación, utilizaremos los Mapas Autoorganizados en modo supervisado, de modo que pueda ser evaluada su capacidad predictora. Para ello, utilizaremos la función xyf . La figura 4.11 muestra los Mapas Autoorganizados correspondientes a bobinadoras

Figura 4.9: Mapas de color correspondientes a temperaturas en horno, dúo y caja 01.

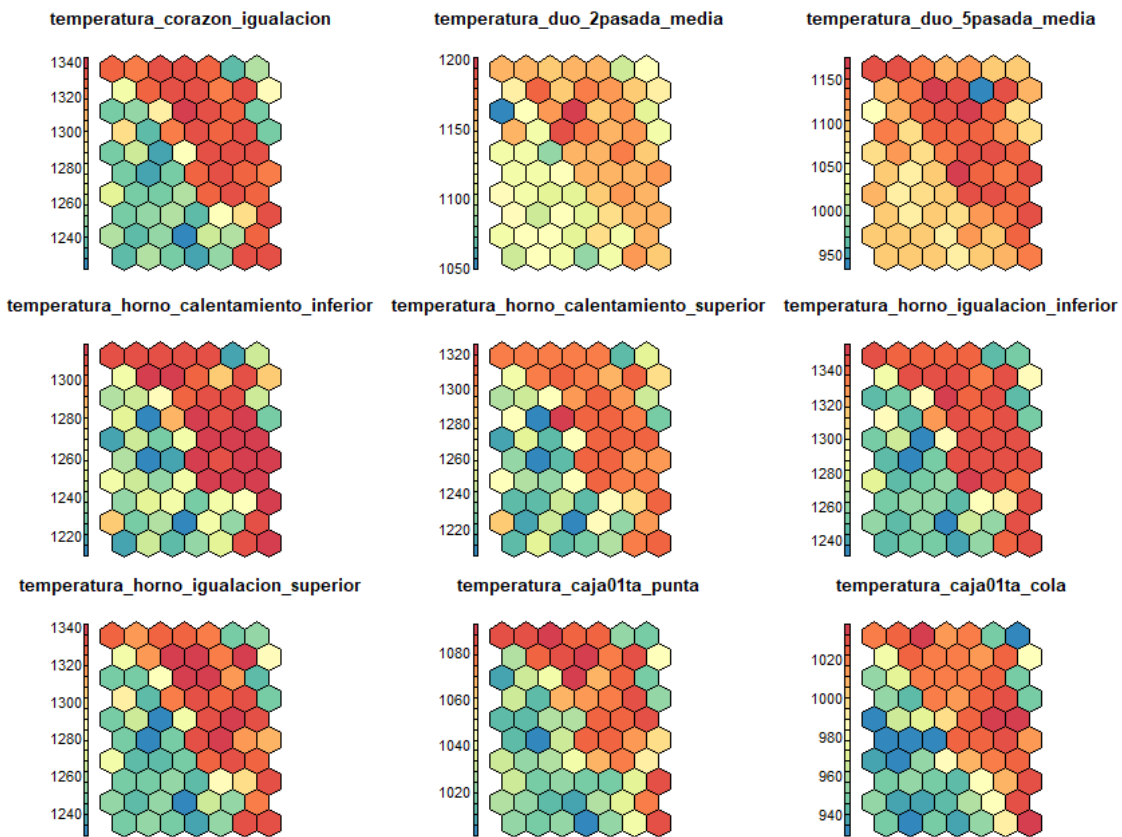
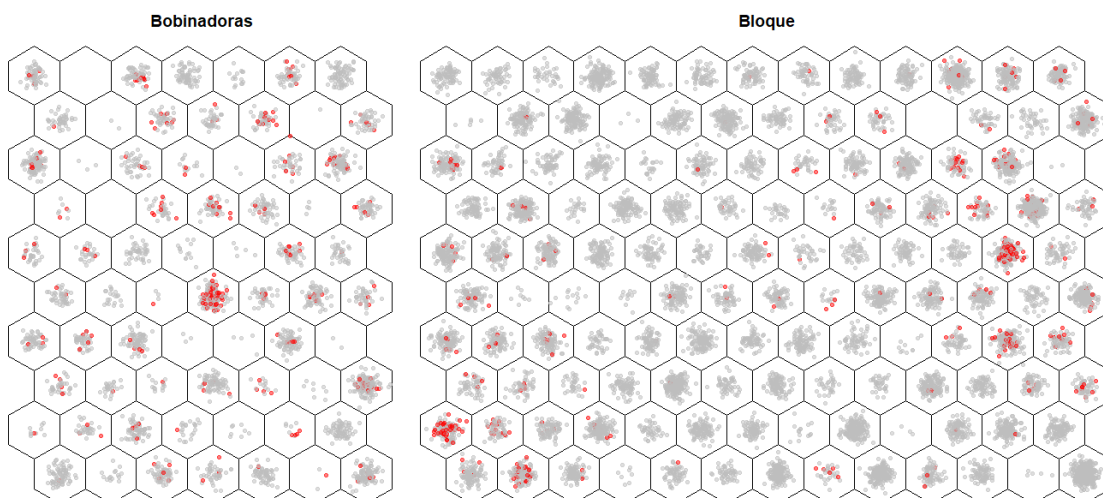


Figura 4.10: Mapas Autoorganizados correspondientes a bobinadoras y al bloque.



y al bloque, en celdas de 10x7 y 10x13, respectivamente con aprendizaje supervisado. Al igual que la anterior, en rojo se señalan las instancias defectuosas mientras que en gris se grafican las instancias correctas. Obsérvese cómo se concentran todas las instancias de-

fectuosas en una unidad. La similitud de los mapas de color de temperaturas en horno y proceso representados en la figura 4.12 confirman la fuerte correlación de estas variables.

Las tablas 4.1 y 4.2 muestran las matrices de confusión de los Mapas Autoorgani-

Figura 4.11: Mapas Autoorganizados correspondientes a bobinadoras y al bloque con aprendizaje supervisado.




Tabla 4.1: Matriz de confusión para la predicción del astillado mediante mapa autoorganizado para bobinadoras

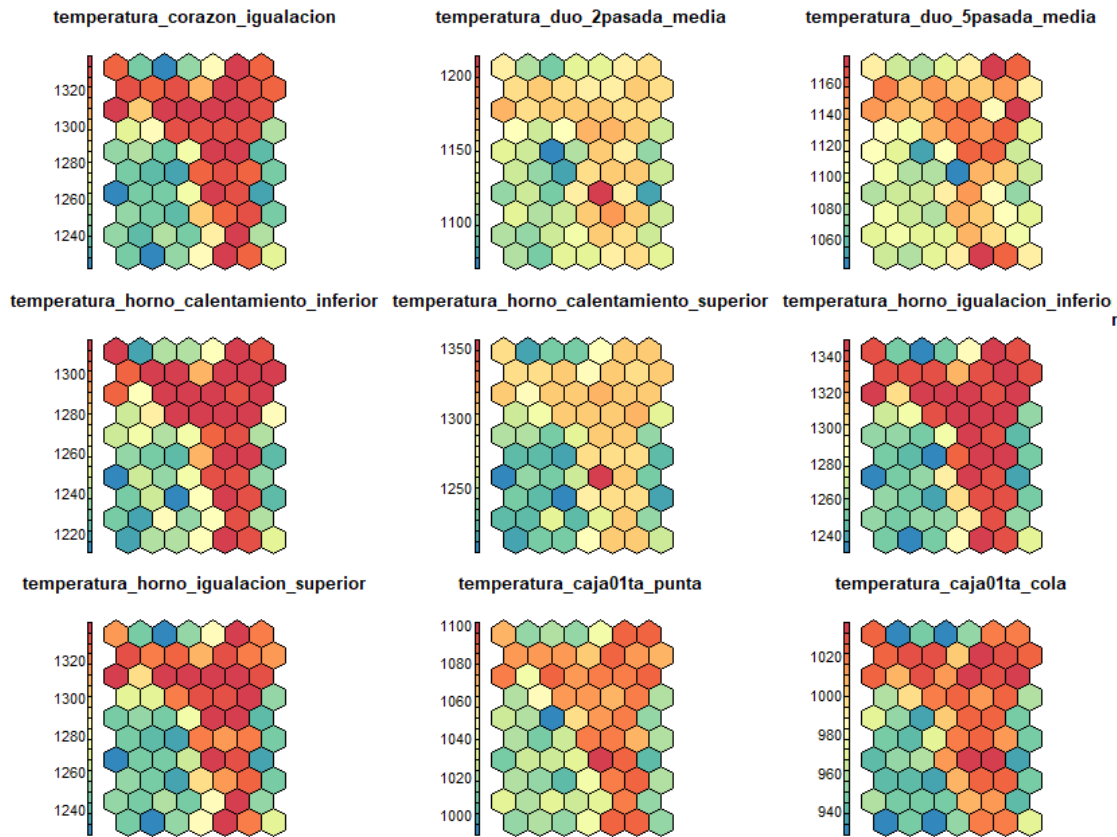
		Astillado calificado		Total
		Positivo	Negativo	
Astillado predicho	Positivo	5	78	83
	Negativo	9	160	169
Total		14	238	252

Tabla 4.2: Matriz de confusión para la predicción del astillado mediante mapa autoorganizado para el bloque

		Astillado calificado		Total
		Positivo	Negativo	
Astillado predicho	Positivo	10	303	313
	Negativo	26	673	699
Total		36	976	1012

zados de bobinadoras y bloque entrenados en modo supervisado. En el primer caso, la sensibilidad resultante es del 36 % con precisión de 65 %, mientras que para el bloque

Figura 4.12: Mapas Autoorganizados correspondientes a bobinadoras y al bloque con aprendizaje supervisado.



resulta una sensibilidad del 28 % y una precisión del 67 %. En la sección siguiente avanzaremos en el entrenamiento de modelos con mayor poder predictivo.

4.2 Modelado

Disponemos de dos conjuntos de datos, uno para rollos laminados en bobinadoras y otro para productos procesados en el bloque. En cada uno de ellos existe una variable categórica, *astillado*, que indica si el rollo correspondiente fue calificado como astillado y *probabilidad_astillado*, una variable numérica calculada como el porcentaje de astillados en el entorno temporal del rollo correspondiente. Entrenaremos modelos supervisados, de clasificación para *astillado* o regresión para *probabilidad_astillado*, utilizando algoritmos **ranger**(Wright y Ziegler, 2017), **rpart**(Therneau y Atkinson, 2019), **xgboost**(Chen y Guestrin, 2016; Chen et al., 2022), **glmnet**(Friedman et al., 2010), **kknn**(Schliep y Hechen-

bichler, 2016) y *svm* (Dimitriadou et al., 2009). El desarrollo será llevado a cabo mediante *mlr3* (Lang et al., 2019), un conjunto de paquetes en lenguaje R, con diseño orientado a objetos R6, con herramientas que permiten el preprocesamiento, ajuste de parámetros, selección de características, entrenamiento, evaluación y visualización relativa a la construcción de modelos de aprendizaje automático.

Se crearán cuatro objetos *Task*, combinando los conjuntos de datos de bobinadoras o bloque y la variable a predecir. El listado 4.1 ilustra la creación de la tarea de bobinadoras para predecir el astillado, así como la división de las tareas de entrenamiento y test. Para ello se instancia un objeto de tipo *TaskClassif*.

Listado 4.1: Creación de tarea y división en conjuntos de datos de entrenamiento y evaluación para clasificación

```

1 # Inicialización de la tarea a partir del conjunto de datos df.bob
2 # La variable a predecir es astillado, y el valor positivo 'Y'
3 tarea.bob.astillado <- mlr3::TaskClassif$new(
4     id = "tarea.bob.astillado",
5     backend = df.bob %>%
6         dplyr::select(-probabilidad_astillado,-acero),
7     target = "astillado",
8     positive='Y'
9 )
10 # División del conjunto de datos en los conjuntos de entrenamiento y test
11 # Creación de tareas con estos conjuntos
12 holdout <- rsmp("holdout", ratio = 0.8)
13 holdout$instantiate(task = tarea.bob.astillado)
14 train.bob.astillado <- holdout$train_set(i = 1)
15 test.bob.astillado <- holdout$test_set(i = 1)
16 tarea.bob.astillado.train <- tarea.bob.astillado$clone()$filter(train.bob.astillado)
17 tarea.bob.astillado.test <- tarea.bob.astillado$clone()$filter(test.bob.astillado)

```

Para cada tarea u objeto *Task*, se crearán los distintos objetos *Learner* que definen el algoritmo de aprendizaje. El objeto *Learner* es encapsulado en un objeto *Graph* que combina las tuberías de preprocesamiento y de ajuste del modelo. El preprocesamiento, en este caso, consiste en escalado y codificación one-hot. LA función *Its* permite encapsular el objeto *Graph* en un objeto *TuningSpace* que devuelve el espacio de ajuste de

hiperparámetros correspondiente a cada algoritmo. Ésto proporciona un nivel de abstracción que evita la engorrosa especificación de hiperparámetros y sus límites o valores discretos a evaluar por el método de autoajuste. Finalmente, el objeto *AutoTuner* encapsula al anterior, aumentándolo para permitir el ajuste de los hiperparámetros. Se ha establecido como método de autoajuste la optimización bayesiana multiobjetivo, validación cruzada de 5 iteraciones y 3 repeticiones y métrica de desempeño de clasificación: área bajo la curva ROC. El listado 4.2 ilustra la creación de los objetos necesarios para el preprocesamiento, entrenamiento y autoajuste para el algoritmo de clasificación *ranger*.

Listado 4.2: Creación del algoritmo de aprendizaje e instancia de autoajuste de parámetros en clasificación

```

1 # Preprocesamiento
2 preproces <- po("scale", param_vals = list(center = TRUE, scale = TRUE)) %>%
3   po("encode", param_vals = list(method = "one-hot"))
4 # Algoritmo de clasificación ranger
5 graph.lrn.ranger <- GraphLearner$new(preproces %>%
6   lts(lrn("classif.ranger", predict_type = "prob")), predict_type = "prob")
7 # Creación del objeto para autoajuste de la tarea de clasificación
8 tuner.ranger.bob.astillado = auto_tuner(
9   method = "mbo",
10  learner = graph.lrn.ranger,
11  resampling = rsmpl("repeated_cv", folds = 5, repeats=3),
12  measure = msr("classif.auc"),
13  term_evals = 30
14 )
15 # Autoajuste
16 tuner.ranger.bob.astillado$train(task = tarea.bob.astillado.train)

```

Una vez que se ha completado el autoajuste y se han determinado los hiperparámetros que optimizan la métrica de desempeño indicada, se realiza una validación cruzada que facilite la comparación entre los modelos de clasificación y permita la selección del mejor modelo. El listado 4.3 realiza una validación cruzada de 10 iteraciones y 3 repeticiones con el modelo final obtenido anteriormente.

Listado 4.3: Validación cruzada con el modelo resultante de clasificación

```

1 res.ranger.bob.astillado <- resample(

```



```

2     task = tarea.bob.astillado.train,
3     learner = tuner.ranger.bob.astillado,
4     resampling = rsmp("repeated_cv", folds = 10, repeats=3),
5     store_models = FALSE
6 )

```

La creación de las tareas para la predicción de *probabilidad_astillado* es algo diferente. En el listado 4.4 se ilustra cómo se instancia un objeto de tipo *TaskRegr* para crear la tarea de predicción por regresión. Igualmente se separan los conjunto de datos que utilizaremos para construir el modelo y para evaluar y seleccionar el mejor.

Listado 4.4: Creación de tarea y división en conjuntos de datos de entrenamiento y evaluación para regresión

```

1 # Inicialización de la tarea a partir del conjunto de datos df.bob
2 # La variable a predecir es probabilidad_astillado
3 tarea.bob.probabilidad_astillado <- mlr3::TaskRegr$new(
4     id = "tarea.bob.probabilidad_astillado",
5     backend = df.bob %>% dplyr::select(-astillado,-acero),
6     target = "probabilidad_astillado"
7 )
8 # División del conjunto de datos en los conjuntos de entrenamiento y test
9 # Creación de tareas con estos conjuntos
10 holdout <- rsmp("holdout", ratio = 0.8)
11 holdout$instantiate(task = tarea.bob.probabilidad_astillado)
12 train.bob.probabilidad_astillado <- holdout$train_set(i = 1)
13 test.bob.probabilidad_astillado <- holdout$test_set(i = 1)
14 tarea.bob.probabilidad_astillado.train <- tarea.bob.probabilidad_astillado$
15     clone()$filter(train.bob.probabilidad_astillado)
16 tarea.bob.probabilidad_astillado.test <- tarea.bob.probabilidad_astillado$
17     clone()$filter(test.bob.probabilidad_astillado)

```

La implementación de la construcción del modelo con autoajuste de hiperparámetros en regresión también tiene algunas diferencias, como se observa en el listado 4.5.

Listado 4.5: Creación del algoritmo de aprendizaje e instancia de autoajuste de parámetros en regresión

```

1 # Preprocesamiento
2 preproces <- po("scale", param_vals = list(center = TRUE, scale = TRUE)) %>%
3     po("encode", param_vals = list(method = "one-hot"))

```

```

4 # Algoritmo de clasificación ranger
5 graph.lrn.ranger <- GraphLearner$new(preproces_pipeline %>>%
6   lts(lrn("regr.ranger")))
7 # Creación del objeto para autoajuste de la tarea de regresión
8 tuner.ranger.bob.probabilidad_astillado = auto_tuner(
9   method = "mbo",
10  learner = graph.lrn.ranger,
11  resampling = rsmpl("repeated_cv", folds = 5, repeats=3),
12  measure = msr("regr.rmse"),
13  term_evals = 30
14 )
15 # Autoajuste
16 tuner.ranger.bob.probabilidad_astillado$
17   train(task = tarea.bob.probabilidad_astillado.train)

```

Finalmente, se realiza la validación cruzada con el modelo resultante como se ve en el listado 4.6.

Listado 4.6: Validación cruzada con el modelo resultante de clasificación

```

1 res.ranger.bob.probabilidad_astillado <- resample(
2   task = tarea.bob.probabilidad_astillado.train,
3   learner = tuner.ranger.bob.probabilidad_astillado,
4   resampling = rsmpl("repeated_cv", folds = 10, repeats=3),
5   store_models = FALSE
6 )

```

4.3 Evaluación

En esta sección se evaluarán los distintos modelos de acuerdo a las dos opciones de modelado que hemos seguido: modelo supervisado de clasificación de *astillado* y modelo supervisado de regresión de *probabilidad_astillado*. Para ello serán graficados los valores de las métricas de desempeño correspondientes, área bajo la curva ROC y raíz de valor cuadrático medio, obtenidos mediante la validación cruzada del modelo final.

Finalmente, los modelos de clasificación y regresión serán comparados entre sí como clasificadores del defecto *astillado* utilizando una métrica común, la curva ROC y el área bajo ésta. Para ello, se utilizará el valor predicho por el modelo de regresión, *probabilidad_astillado*, como la probabilidad de cada instancia de pertenecer a la clase positiva

de un modelo de clasificación.

4.3.1 Evaluación de los modelos de clasificación de astillado

La figura 4.13 muestra una comparación de la característica operativa del receptor o curva ROC para la predicción de *astillado* en el conjunto de datos correspondiente a bobinadoras, mientras que la figura 4.14 muestra los distintos valores del área bajo la curva ROC obtenidos durante la validación cruzada para los modelos de clasificación entrenados.

La Característica Operativa de Receptor, o curva ROC, es un gráfico que representa la tasa de falsos positivos (FPR) en el eje horizontal y la tasa de verdaderos positivos o sensibilidad (TPR) en el eje vertical para cada valor del umbral de decisión del clasificador con el que se compara la salida de probabilidad de que una instancia corresponda a la clase positiva.

$$FPR = \frac{FP}{FP + TN} \quad (4.1)$$

donde FP es el número de falsos positivos y TN el número de verdaderos negativos.

$$TPR = \frac{TP}{FP + FN} \quad (4.2)$$

donde TP es el número de verdaderos positivos y FN el número de falsos negativos.

Cuanto mayor sea la sensibilidad o tasa de verdaderos positivos, mayor capacidad tendrá el clasificador de reconocer la clase positiva. Cuanto menor sea la tasa de falsos positivos, mayor es la capacidad del clasificador de predecir certeramente instancias como clase positiva, es decir, menor será el número de falsos positivos.

Los mejores resultados se obtienen con los algoritmos de Bosques Aleatorios (ranger) y de Potenciación de Gradiente Extremo (xgboost). Sin embargo, son bastante malos y exhiben una gran dispersión durante la validación cruzada, especialmente la Máquina de Vectores de Soporte (svm). El peor resultado es producido por los Árboles de Decisión (rpart).

Figura 4.13: Característica operativa del receptor: predicción astillado para bobinadoras.





Figura 4.14: Área bajo curva ROC: predicción astillado para bobinadoras.




Los resultados del modelo de clasificación son mucho mejores para el conjunto de datos del bloque. Las figuras 4.15 y 4.14 muestran la comparación de la curva ROC y el

área bajo su curva relativos a la predicción de *astillado* en el conjunto de datos correspondiente al bloque, para los modelos de clasificación entrenados.

Nuevamente, los mejores modelos resultan ser los Bosques Aleatorios y la Máquina

Figura 4.15: Característica operativa del receptor: predicción *astillado* para bloque.




de Potenciación de Gradiente Extremo, si bien ésta última con demasiada dispersión en la validación cruzada. Los Bosques Aleatorios presentan unos resultados más compactos y ligeramente mejores mientras que la Máquina de Vectores de Soporte arroja el peor desempeño tanto en la métrica como en su dispersión durante la validación cruzada.

Tanto por el valor de la métrica de área bajo la curva ROC como por su menor varianza, podemos considerar que los Bosques Aleatorios o ranger es el modelo seleccionado como clasificador de la clase *astillado*.

4.3.2 Evaluación de los modelos de regresión de probabilidad_*astillado*

En este apartado abordaremos el análisis del desempeño de los distintos algoritmos como predictores de *probabilidad_astillado*. Las figuras 4.17 y 4.18 muestran respectiva-

Figura 4.16: Área bajo curva ROC: predicción astillado para bloque.



mente la comparación de los algoritmos de regresión en términos de raíz de error cuadrático medio y de coeficiente de determinación ó R^2 .

Referente al conjunto de datos de bobinadoras, los Bosques Aleatorios y Máquinas de Potenciación de Gradiente Extremo tienen el mejor desempeño como predictores de la probabilidad de astillado con el menor error cuadrático medio y el mayor coeficiente de determinación. A la cola se encuentran el Modelo Lineal Generalizado y la Máquina de Vectores de Soporte. El análisis es idéntico al considerar el conjunto de datos del bloque, como se hace patente en las figuras 4.19 y 4.20. Sin embargo, el desempeño es mejor que con el conjunto de datos anterior.

Al igual que sucedió con el clasificador de defecto, el algoritmo de Bosques Aleatorios (ranger) predice mejor la probabilidad de defecto que habíamos estimado como el porcentaje de rollos defectuosos en el entorno temporal de producción.

Las figuras 4.21 y 4.22 muestran el gráfico de puntos con los valores de probabilidad de astillado calculada como porcentaje de defectos contra la probabilidad de astillado predicha por el modelo de Bosques Aleatorios. Los puntos están coloreados en función

Figura 4.17: Raíz de Error Cuadrático Medio: predicción de la probabilidad de astillado para bobinadoras.




Figura 4.18: Coeficiente de Determinación ó R^2 : predicción de la probabilidad de astillado para bobinadoras.




Figura 4.19: Raíz de Error Cuadrático Medio: predicción de la probabilidad de astillado para el bloque.






Figura 4.20: Coeficiente de Determinación ó R^2 : predicción de la probabilidad de astillado para el bloque.



de si fueron o no astillado.

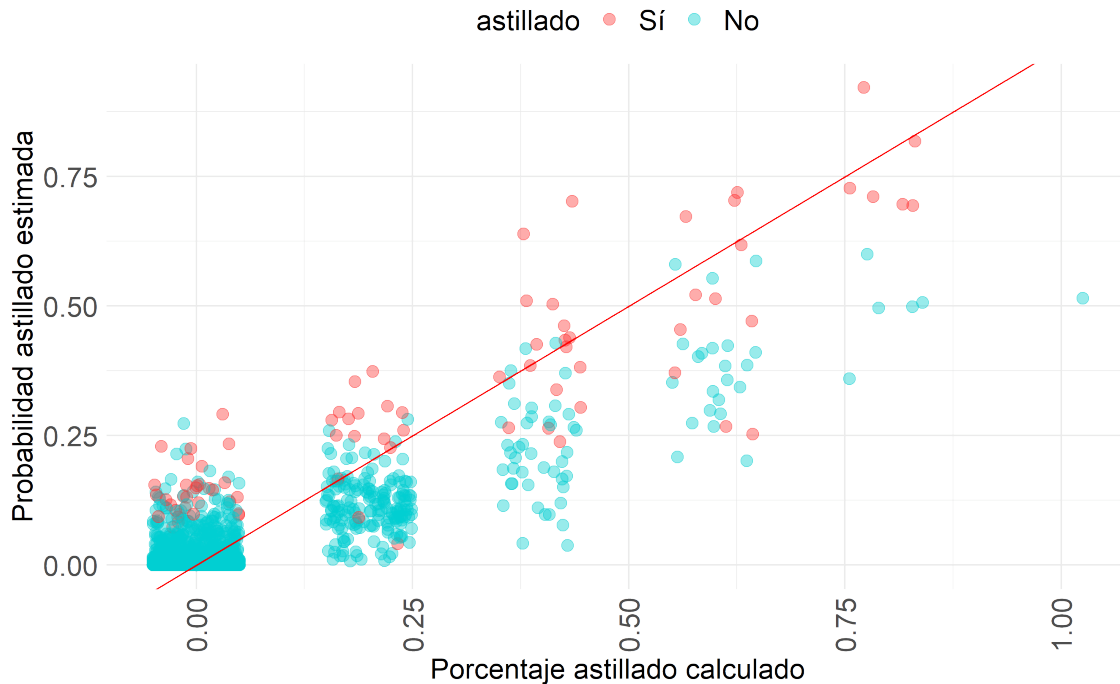
La dispersión que se observa en el eje de abscisas en torno a los valores de 0 a 1 en pasos de 0,2 es artificial ya que se ha creado con el fin de clarificar el gráfico. En realidad, los valores reales coinciden exactamente con estos valores discretos por la manera en que fueron calculados. Esta discretización es asimismo responsable de parte de la disgregación que se observa en la predicción. A pesar de ello, los valores de *probabilidad_astillado* predichos tienden a tomar un valor mayor cuando el rollo tiene astillado, circunstancia que era desconocida para el modelo predictivo, lo cual es interesante pero también conveniente. Ésto sugiere que el modelo está capturando el patrón que favorece la aparición del defecto.

Figura 4.21: Valor predicho contra valor real: predicción de la probabilidad de astillado para bobinadoras.



Siguiendo esta línea de pensamiento, se ha graficado la relación entre la probabilidad de defecto predicha en función de la clase astillado en las figuras 4.23 y 4.24. En el siguiente apartado, plantaremos utilizar la probabilidad de defecto predicha como probabilidad de pertenencia a la clase positiva de un clasificador de defecto y compararemos

Figura 4.22: Valor predicho contra valor real: predicción de la probabilidad de astillado para el bloque.



su desempeño con el clasificador de astillado basado en Bosques Aleatorios seleccionado anteriormente.

4.3.3 Comparación de los modelos de clasificación de defecto con los modelos de regresión de probabilidad_astillado como clasificadores de astillado

Para construir una curva ROC de un clasificador se precisa, para el conjunto de datos a evaluar, los valores de probabilidad de pertenencia a la clase positiva y la clase real a la que pertenecían las instancias correspondientes. Para ello utilizaremos las librerías *ROCR*(Sing et al., 2005) y *purrr*(Henry y Wickham, 2022). El listado 4.7 muestra el código que realiza la predicción de la probabilidad de pertenencia a la clase positiva de un clasificador de defecto así como la construcción de la curva ROC mientras que 4.9 lista el código correspondiente para realizar el mismo cometido a partir de un modelo de regresión que predice la probabilidad de pertenencia a la clase positiva.

Figura 4.23: Diagrama de cajas de la probabilidad de defecto predicha en función del astillado real para bobinadoras.

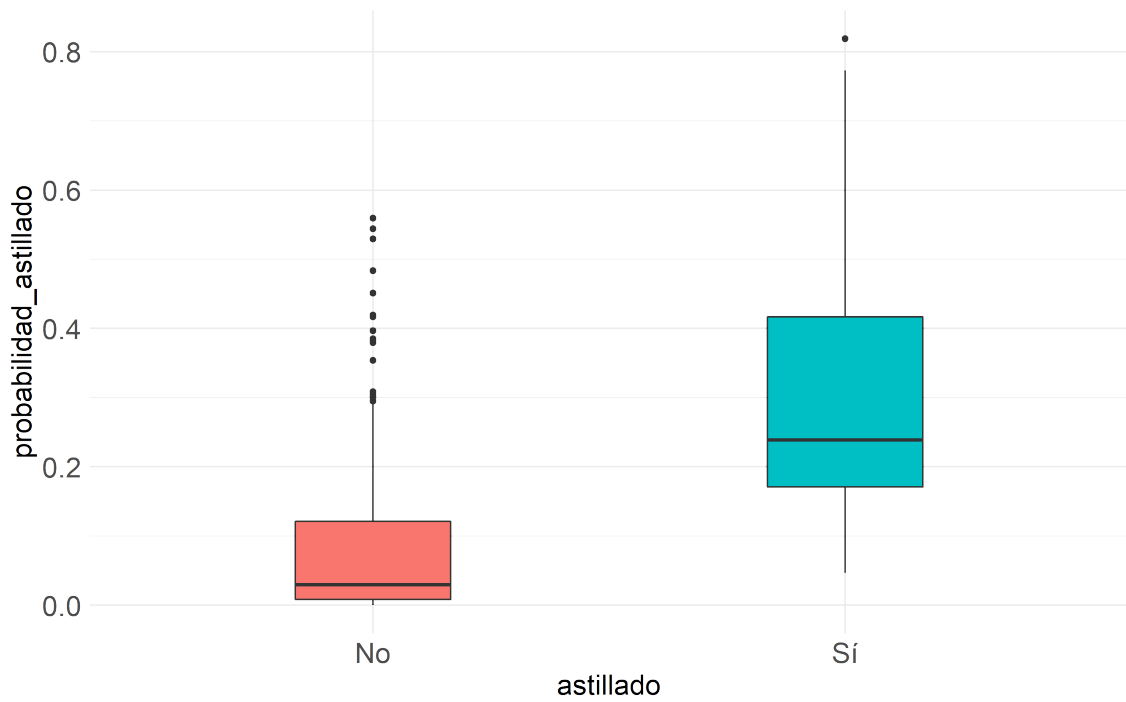
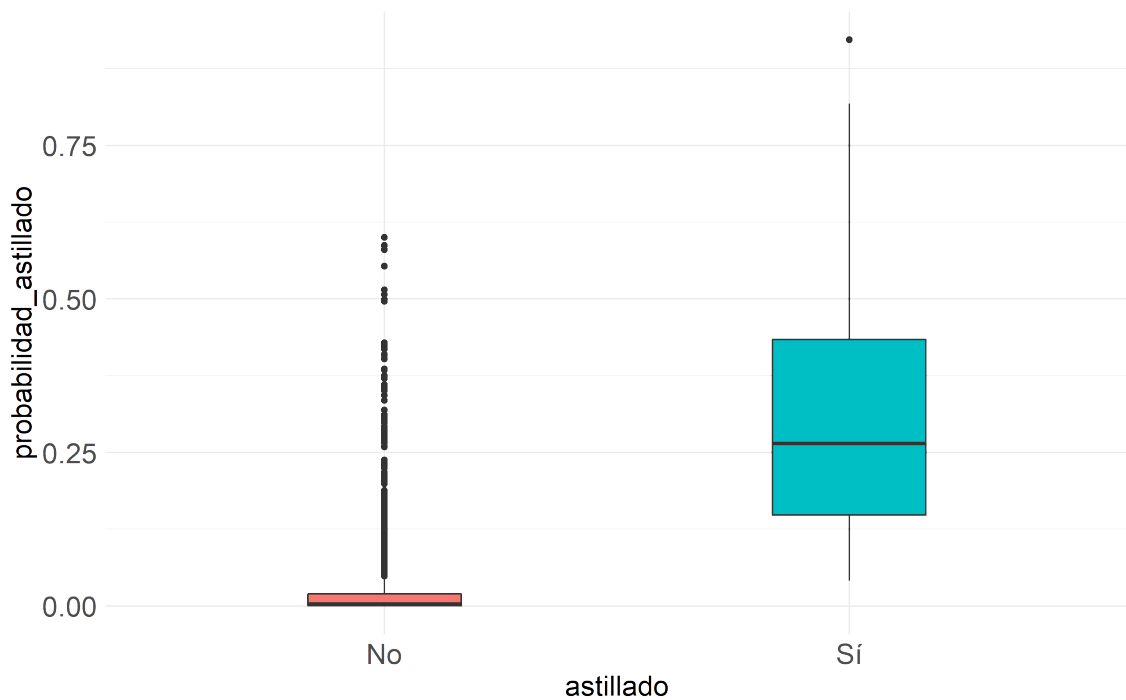


Figura 4.24: Diagrama de cajas de la probabilidad de defecto predicha en función del astillado real para el bloque.



Listado 4.7: Código en R para curva ROC del modelo de clasificación de astillado

```
1 tuner.ranger.bob.astillado$predict(tarea.bob.astillado.test) %>%
2   as.data.table() %>%
3   dplyr::mutate(probabilidad_astillado=prob.Y) %>%
4   dplyr::mutate(astillado=truth) %>%
5   list() %>%
6   purrr::map(~ fortify(performance(prediction(.x$probabilidad_astillado,
7     .x$astillado), "tpr", "fpr"))) %>%
8   map_df(I, .id = "metodo") %>%
9   ggplot(aes(x=False.positive.rate,y=True.positive.rate,color=metodo))+
10  geom_line()
```

Listado 4.8: Código en R para curva ROC del modelo de regresión de probabilidad_astillado como modelo de clasificación

```
1 tuner.ranger.bob.probabilidad_astillado$predict(tarea.bob.probabilidad_astillado.test)%>%
2   as.data.table() %>%
3   dplyr::mutate(probabilidad_astillado=response) %>%
4   dplyr::mutate(astillado=astillado=df.bob %>% slice(test.bob.
5     probabilidad_astillado) %>% pull(astillado)) %>%
6   list() %>%
7   purrr::map(~ fortify(performance(prediction(.x$probabilidad_astillado,
8     .x$astillado), "tpr", "fpr"))) %>%
9   map_df(I, .id = "metodo") %>%
10  ggplot(aes(x=False.positive.rate,y=True.positive.rate,color=metodo))+
    geom_line()
```

Las figuras 4.25 y 4.26 muestran la comparación de las curvas ROC de las dos soluciones consideradas: el modelo clasificador de defecto que fue entrenado inicialmente y el modelo de regresión de la probabilidad de astillado como clasificador del astillado, ambos utilizando el algoritmo de Bosques Aleatorios (ranger). Puede constatarse que el modelo de regresión supone una mejora sensible en la capacidad de predicción del astillado para ambos conjuntos de datos, tanto de bobinadoras como del bloque.

A continuación, seremos más exhaustivos en la comparación de las dos modalidades de clasificación de defecto (clasificación al uso y regresión como probabilidad de pertenencia a clase positiva) para todos los algoritmos utilizados en la construcción de modelos de clasificación y regresión, como se ilustra en las figuras 4.27 y 4.28. La modalidad de

Figura 4.25: Comparación curvas ROC del modelo de regresión de probabilidad_astillado como modelo de clasificación y del modelo de clasificación para bobinadoras.


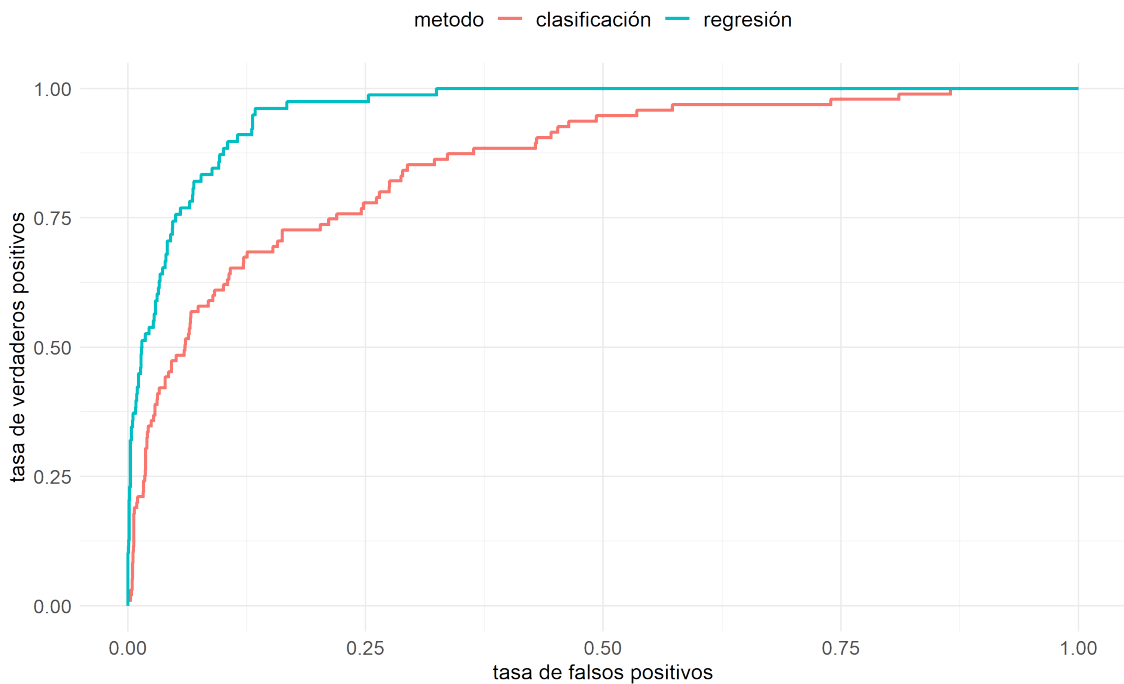


Figura 4.26: Comparación curvas ROC del modelo de regresión de probabilidad_astillado como modelo de clasificación y del modelo de clasificación para el bloque.



regresión proporciona un desempeño sensiblemente mejor que el modelo de clasificación que se sirve del mismo algoritmo, continuando en cabeza el algoritmo de Bosques Aleatorios, bastante igualado con la Máquina de Potenciación de Gradiente Extremo. El valor del área bajo la curva ROC para el conjunto de datos de bobinadoras es ligeramente inferior a 0,9, con un orden comparable al desempeño publicado para soluciones similares de predicción de defectos del estado del arte. Sin embargo, para el conjunto de datos del bloque, es un resultado bastante notable. Posiblemente, el elemento clave de esta distinción sea número de instancias presentes en cada conjunto de datos, bastante superior para el bloque. Otra explicación podría estar en que, a pesar de contar con muchas variables comunes, tales como el calentamiento en el horno, el dúo o las primeras cajas de la laminación en caliente, existan variables exclusivas al bloque que influyan de una forma más destacado en el resultado de la calidad.

Figura 4.27: Comparación del área bajo la curva ROC de ambas modalidades de clasificación y de los distintos algoritmos considerados para bobinadoras.





Figura 4.28: Comparación del área bajo la curva ROC de ambas modalidades de clasificación y de los distintos algoritmos considerados para el bloque.



4.3.4 Selección de modelo y determinación del umbral de detección óptimo

En el apartado anterior se realizó una comparación de los modelos de clasificación de astillado y de los modelos de regresión la probabilidad de astillado como modelos de predicción de astillado. Para ello, se convirtió la salida del modelo de regresión en la probabilidad de pertenencia a la clase positiva. Los resultados, para los conjuntos de datos de boninadoras y del bloque, se muestran en las figuras 4.27 y 4.28. En ambos casos, el algoritmo de Bosques Aleatorios (ranger) entrenado para predecir la probabilidad de astillado, es decir, la opción de regresión, resultó la mejor, seguida de cerca por la Máquina de Potenciación de Gradiente Extremo (xgboost).

Sin embargo, para no dejar a la simple apreciación, la conclusión de que la opción de regresión es mejor que la de clasificación habitual para implementar un clasificador de astillado, se va a realizar una validación estadística de esta hipótesis. La razón para ello es que, al comparar simplemente dos valores numéricos, es decir, las métricas de

clasificación, no estamos considerando la variación que se puede producir, y que la diferencia observada no sea estadísticamente relevante. Para ello utilizaremos el método de bootstrap, generando distintos conjuntos de datos realizando remuestreo con repetición del conjunto de datos de test inicial utilizando la librería *Rsampling*. A partir de cada uno de estos conjuntos de datos artificiales, se calculará el área bajo la curva ROC utilizando las dos modalidades de predicción consideradas, clasificación y regresión, utilizando el algoritmo de Bosques Aleatorios. El listado 4.9 muestra el código en R para realizar el bootstrapping y el test estadístico mientras que las figuras 4.29 y 4.30 grafican la distribución de los valores del área bajo la curva ROC para los remuestreos aleatorios con repetición del correspondiente conjunto de datos de test.

Listado 4.9: Validación estadística de la hipótesis de que el método de regresión es mejor que el de clasificación para la predicción de defectos en base a la métrica del área bajo la curva ROC

```
1 calcula_auc.bob.regr<-function(df){
2   prob<-tuner.ranger.bob.probabilidad_astillado$
3     predict_newdata(df %>% select(-astillado,-probabilidad_astillado))$
4       response
5   truth<-df %>% pull(astillado)
6   fortify(performance(prediction(prob,truth),"auc")) %>%
7     pull(Area.under.the.ROC.curve)
8 }
9 calcula_auc.bob.classif<-function(df){
10  prob<-tuner.ranger.bob.astillado$
11    predict_newdata(df %>% select(-astillado,-probabilidad_astillado))$prob
12    [,1]
13  truth<-df %>% pull(astillado)
14  fortify(performance(prediction(prob,truth),"auc")) %>%
15    pull(Area.under.the.ROC.curve)
16 }
17 auc.regresion.bob<-Rsampling(
18   type="rows_as_units",
19   dataframe=df.bob %>% slice(test.bob.astillado) %>% as.data.frame(),
20   statistics = calcula_auc.bob.regr,
21   ntrials=10000,
22   replace = TRUE)
23 auc.clasificacion.bob<-Rsampling(
```




```

22     type="rows_as_units",
23     dataframe=df.bob %>% slice(test.bob.astillado) %>% as.data.frame(),
24     statistics = calcula_auc.bob.classif,
25     ntrials=10000,
26     replace = TRUE)
27 auc.bob<-rbind(data.frame(auc=auc.regresion.bob,tipo='regresión'),
28               data.frame(auc=auc.clasificacion.bob,tipo='clasificación'))
29 t.test(auc.clasificacion.bob,auc.regresion.bob,alternative='less')

```


Figura 4.29: Bootstrapping del área bajo la curva ROC para la comparación de las dos modalidades de predicción de astillado para bobinadoras.



Puede observarse cierto solapamiento entre la distribución de la métrica de clasificación de las modalidades de clasificación y regresión con el conjunto de datos de bobinadoras, así como una mucho mayor dispersión con el algoritmo de clasificación. Se realizará la prueba t de Student mediante la función R *t.test* donde la hipótesis nula consiste en que no hay diferencia entre ambas distribuciones. Como puede comprobarse, la hipótesis nula es rechazada por el test, por lo que se valida la hipótesis alternativa por la cual hay diferencia significativa estadísticamente entre ambas distribuciones.

Su salida, para el conjunto de datos de bobinadoras:

Figura 4.30: Bootstrapping del área bajo la curva ROC para la comparación de las dos modalidades de predicción de astillado para el bloque.



Welch Two Sample t-test

```
data: auc.clasificacion.bob and auc.regresion.bob
t = -245.95, df = 15924, p-value < 2.2e-16
alternative hypothesis: true difference in means is less than 0
95 percent confidence interval:
-Inf -0.1154602
sample estimates:
mean of x mean of y
0.7150880 0.8313256
```

Y para el conjunto de datos del bloque:

Welch Two Sample t-test

```
data: auc.clasificacion.blq and auc.regresion.blq
t = -422.98, df = 12242, p-value < 2.2e-16
alternative hypothesis: true difference in means is less than 0
95 percent confidence interval:
-Inf -0.08736793
sample estimates:
mean of x mean of y
0.8586832 0.9463923
```

De acuerdo a los resultados de la comparación de modelos y a la validación estadística

ca realizada, se concluye que el modelo de aprendizaje automático para la predicción de astillado que proporcionará un indicación del estado del sistema de fabricación en relación con este defecto será el que utilice el algoritmo de Bosques Aleatorios (ranger) en la modalidad de regresión, es decir, para la predicción de defecto calculada como el porcentaje de rollos defectuosos en la vecindad temporal. A continuación se determinará el umbral de detección óptimo de este clasificador.

La modificación del umbral de detección del modelo de clasificación determina un valor de sensibilidad y especificidad de acuerdo a la curva ROC, y consiguientemente, un porcentaje de falsos negativos y de falsos positivos. Cada falso positivo, es decir, una instancia clasificada como defectuosa sin serlo y cada falso negativo, es decir, una instancia que escapa a la detección, tienen su coste respectivo. El valor del umbral de detección que minimiza el coste neto, será el umbral óptimo de detección.

Se calculará el coste debido a los errores del clasificador mediante la ecuación 3.3. A cada valor del umbral de detección le corresponde un valor de coste del clasificador. En las figuras 4.31 y 4.32 se grafica esta relación y la obtención del umbral de detección que minimiza el coste del clasificador, para los conjuntos de datos de bobinadoras y del bloque.

Las tablas 4.3 y 4.4 muestran las matrices de confusión del clasificador de defecto obtenido mediante los modelos de regresión de predicción de *probabilidad_astillado* y el umbral de detección que minimiza el coste del clasificador calculado mediante la ecuación 3.3. Las sensibilidades obtenidas son 0,77 y 0,74, con precisiones de 0,37 y 0,38, respectivamente. Son valores muy similares, aunque el área bajo la curva para el bloque es mucho mejor que para bobinadoras. La razón se debe a que el conjunto de datos del bloque está mucho más desequilibrado, con muchos más negativos.

Figura 4.31: Coste del clasificador en función del umbral de detección, para bobinadoras.




Figura 4.32: Coste del clasificador en función del umbral de detección, para el bloque.




Tabla 4.3: Matriz de confusión para la predicción del astillado mediante modelo de regresión, algoritmo de Bosques Aleatorios, para bobinadoras

		Astillado calificado		Total
		Positivo	Negativo	
Astillado predicho	Positivo	49	82	131
	Negativo	15	423	438
Total		64	505	569

Tabla 4.4: Matriz de confusión para la predicción del astillado mediante modelo de regresión, algoritmo de Bosques Aleatorios, para el bloque

		Astillado calificado		Total
		Positivo	Negativo	
Astillado predicho	Positivo	58	96	154
	Negativo	20	1929	1949
Total		78	2025	2103

4.4 Indicador del estado de calidad del proceso

En el apartado anterior, se determinó el umbral de detección a partir de la predicción de la probabilidad de astillado en base a los costes de falsos positivos y falsos negativos. Este valor, calculado en línea, puede servir como indicador del estado del proceso en relación con la aparición del defecto astillado y como aviso de la necesidad de realizar correcciones en el proceso para corregirlo. En el siguiente apartado, se propondrá una guía de corrección a partir de la explicación del modelo.

Existen otras alternativas a este indicador. Una de las más extendidas en los procesos industriales son los Sistema de Monitorización de Condiciones (SMC). Estos sistemas consisten en el establecimiento de un conjunto de alarmas que comprueban que las variables de proceso no se alejan de unos límites preestablecidos que dependen de las características del producto a producir. Estos límites suelen obtenerse mediante costosos experimentos. Sin embargo, este conjunto de reglas puede asimilarse a un modelo de clasificación cuyo desempeño puede determinarse calculando el número de verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos y, con éstos, el coste del clasificador de acuerdo a la ecuación 3.3. Es improbable que un clasificador sim-

ple basado en reglas tenga un desempeño superior a un modelo supervisado mediante aprendizaje automático. Incluso, podría suceder que la puesta en producción de un sistema de monitorización de condiciones suponga un sobrecoste si no se ha realizado un estudio adecuado del desempeño del mismo como clasificador y del coste que conlleva. Para ilustrar esta problemática, se va a comparar el modelo de predicción de astillado que hemos obtenido con un conjunto de reglas que estuvo vigente para cierto tipo de acero, el 076, con el expreso propósito de reducir el número de astillados.

La tabla 4.5 muestra la matriz de confusión del clasificador de defecto obtenido mediante el modelo de regresión de predicción de *probabilidad_astillado* y el umbral de detección que minimiza el coste del clasificador, para el tipo de acero 076. El coste unitario es 2134.

Por otra parte, el conjunto de reglas del sistema de monitorización de condiciones, que debe cumplir el proceso, se muestra en la tabla 4.6. La tabla 4.7 muestra la matriz de confusión correspondiente, con coste unitario 2142. Para convertir este conjunto de reglas en un clasificador, podemos considerar que, si se incumplen, se predice la aparición del astillado.

El coste de la solución basada en las reglas del Sistema de Monitorización de Condiciones es superior debido al mayor número de falsos positivos y falsos negativos. La diferencia, de 2134 a 2142, no parece muy importante pero ha de tenerse en cuenta un peso muy importante del coste de la materia prima. Prueba de ello es que hay una diferencia significativa en el poder predictivo de ambos clasificadores. El desempeño del clasificador basado en el modelo de regresión tiene una sensibilidad de 0,72 con una precisión de 0,24, mientras que la del modelo basado en reglas tiene una sensibilidad de 0,43 y una precisión de 0,10. Una ventaja adicional es la capacidad que ofrece el modelo basado en la predicción de *probabilidad_astillado* para ofrecer una guía que permita la corrección del sistema a un estado más seguro, frente a la más limitada del modelo basado en reglas que únicamente ofrece indicación para las variables consideradas en las reglas que, como hemos visto, es bastante más limitado en su capacidad predictiva.

En el próximo apartado, profundizaremos en las herramientas que ofrecen esta guía de corrección del sistema basada en técnicas de interpretación de modelos de aprendizaje automático.

Tabla 4.5: Matriz de confusión para la predicción del astillado mediante modelo de regresión, algoritmo de Bosques Aleatorios, para tipo de acero 076

		Astillado calificado		Total
		Positivo	Negativo	
Astillado predicho	Positivo	49	153	202
	Negativo	19	512	531
Total		68	665	733

Tabla 4.6: Reglas del Sistema de Monitorización de Condiciones para prevenir el astillado para el tipo de acero 076.

1. permanencia_igualacion + permanencia_calentamiento ≤ 300
2. permanencia_igualacion ≤ 120
3. temperatura_corazon_igualacion >1320
4. temperatura_bobinadorasCola >1020 , si $16 \leq \text{diametro} \leq 26,5$
5. temperatura_bobinadorasCola >990 , si $27 \leq \text{diametro} \leq 30,5$
6. temperatura_bobinadorasCola >950 , si $31 \leq \text{diametro} \leq 41,5$
7. temperatura_entrada_bloqueCola >1040 , si $5,5 \leq \text{diametro} \leq 6$
8. temperatura_entrada_bloqueCola >1020 , si $6,5 \leq \text{diametro} \leq 15,5$

Tabla 4.7: Matriz de confusión según las reglas del Sistema de Monitorización de Condiciones para tipo de acero 076

		Astillado calificado		Total
		Positivo	Negativo	
Astillado predicho	Positivo	29	234	263
	Negativo	39	431	470
Total		68	665	733

4.5 Explicación del modelo

Generalmente, los modelos de aprendizaje automático que ofrecen mejores resultados suelen ser muy flexibles y difícilmente interpretables, y por esta razón son denominados modelos de caja negra. Con el fin de interpretarlos se han desarrollado gramáticas agnósticas para la exploración y explicación de modelos como la implementada en la librería *DALEX*(Biecek, 2018). Para ello ofrece distintos métodos como los gráficos de dependencias parciales, gráficos de efectos locales acumulados, gráficos de unificación de caminos, gráficos de descomposición y gráficos de importancia de variables.

El primer paso necesario es crear un objeto *explainer* a partir del modelo final y del conjunto de datos para el cual se desea restringir la explicación. La razón por la que se desea esta restricción es por asegurar la consistencia de las variables de proceso según el tipo de producto a analizar. El listado 4.10 muestra el código que permite la creación de este objeto limitado al tipo de acero 076.

Listado 4.10: Creación del explicador

```
1 idx.bob.076 <- df.bob%>% pull(acero) %in% c("076")
2 modelo <- tuner.ranger.bob.probabilidad_astillado$learner
3 datos <- tarea.bob.probabilidad_astillado$data() %>% slice(which(idx.bob.076))
4 exp.ranger.bob.probabilidad_astillado.076 <- explain_mlr3(modelo,
5   data      = datos,
6   y         = datos %>% pull(probabilidad_astillado),
7   label     = "exp.ranger.bob.probabilidad_astillado.076",
8   colorize  = FALSE)
```

4.5.1 Importancia de las variables basada en permutación

Para obtener la importancia de variables, el método basado en permutación anula el efecto de cada variable y evalúa la pérdida de poder de predicción realizando una mezcla aleatoria de los valores en esta variable. Con objeto de obtener esta indicación de importancia se utilizará la función *model_parts*. Las figuras 4.33 y 4.34 muestran las 20 variables más importantes para bobinadoras y en el bloque.

Obsérvese la importancia de varias variables del proceso de calentamiento en el horno tales como tiempos de permanencia, temperaturas en ciertas zonas y, curiosamente, valores estadísticos del gas en ciertas zonas. Este último dato es relevante porque el modelo matemático que realiza la estimación de temperaturas de calentamiento de palanquilla en el horno no tiene en cuenta los caudales de gas que, por otra parte, parecen importantes en el resultado de calidad final. En el conjunto de variables relativo a bobinadoras destaca la importancia del código de recepción P803, código de calidad de palanquilla que significa "palanquilla torcida", mientras que para el bloque se acusa la importancia de variables en la parte del acabado final, tales como caudales y presiones de cajas de agua y velocidades, pares y alargamientos en las cajas del bloque. Igualmente, en función del tipo de acero, la variación de ciertos componentes químicos parece tener gran influencia, como el vanadio, el níquel, el boro o el azufre. Sin embargo, la fuerte correlación entre variables de proceso podría estar confundiendo la determinación de su importancia. Incluso aunque mermase el poder predictivo del modelo, sería conveniente limitar los atributos reduciendo la influencia de esta correlación.

No obstante, si limitamos el explorador a los conjuntos de datos relativos al tipo de acero 076, obtenemos otros gráficos de importancia de variables. Dado que el tipo de acero determina la consigna de calentamiento en el horno, tendremos ahí cierta uniformidad en los datos relativos a la composición química, calentamiento en el horno y temperaturas a lo largo del proceso. Sin embargo, las variables procedentes de las cajas de laminación varían en función del diámetro del producto final. Por esta razón, estas variables serán excluidas de los gráficos de importancia de variables de las figuras 4.35 y 4.36. Para bobinadoras, destaca la permanencia en el horno y los caudales de gas en las distintas zonas del horno, así como algunas variables de composición química. Respecto al bloque, prevalecen variables relativas a las cajas de agua, pero también caudales del gas en el horno

. La figura 4.37 muestra las variables más significativas, en cuanto a cajas de laminación, en la laminación del diámetro 15 donde se pone de manifiesto que la variable más

Figura 4.33: Importancia de variables en bobinadoras.

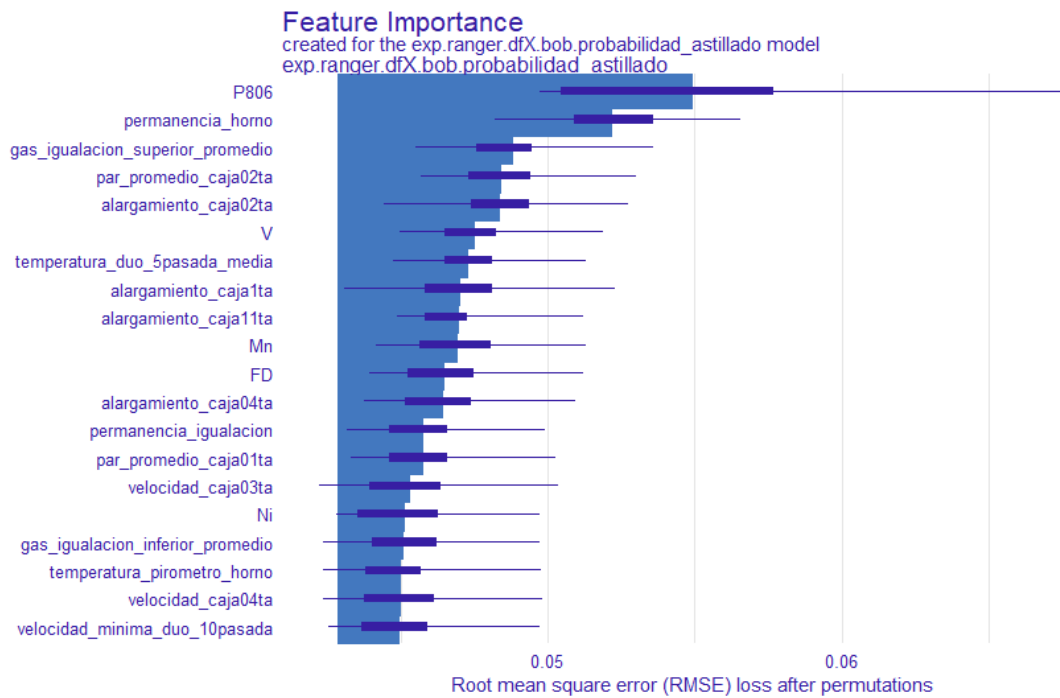




Figura 4.34: Importancia de variables en el bloque.



influyente en la aparición del defecto de astillado es la velocidad en el bloque, seguida por los alargamientos en las cajas 1 y 03.

Figura 4.35: Importancia de variables para el acero 076 en bobinadoras.




4.5.2 Perfiles de dependencias parciales

Los gráficos de dependencias parciales muestran cómo la variable a predecir, es decir, *probabilidad_astillado*, se comporta ante la variación de un atributo determinado. Proporcionan una guía de la corrección necesaria en esta variable particular para reducir la probabilidad de defecto. Para obtener esta visualización se utiliza la función *model_profile*. Vemos algunos ejemplos.

Las figuras 4.38 y 4.39 muestran los gráficos de dependencias parciales para la temperatura estimada en el corazón, la permanencia en el horno, el caudal de gas en la zona superior de igualación y el promedio de temperatura en la quinta pasada del dúo, para el conjunto de datos de bobinadoras y del bloque con tipo de acero 076. Se observa que la permanencia en el horno es de la mayor importancia, que no debe ser inferior a 200 mi-

Figura 4.36: Importancia de variables para el acero 076 en el bloque.




nutos ni debe exceder los 300 o 400 minutos, que un caudal de gas excesivo en el horno es dañino, y que la temperatura de calentamiento debe estar en cierto rango, entre 1325 y 1330 grados según la temperatura estimada en el corazón, o sobre 1150 en la quinta pasada del dúo. La correlación entre ambas es alta, superior al 85 %. El caudal de gas no tiene influencia en el cálculo de la temperatura estimada en el corazón, pero podría verse reflejado en la temperatura media del dúo.

En lo que respecta a las variables específicas de bobinadoras, tipo de acero 076, la figura 4.40 llama la atención sobre la permanencia en la balsa de bobinadoras, que no debe ser inferior a los 60 segundos.

Por otra parte, en la figura 4.41 se muestran los gráficos de dependencias parciales de las variables más relevantes, específicas del bloque, para el tipo de acero 076. El gráfico revela la importancia de los caudales de las cajas 1 y 3, de las presiones en la 2 y 3, y

Figura 4.37: Importancia de variables de cajas de laminación y alargamientos para la laminación del diámetro 15.




de la velocidad de los rodillos de evacuación del bloque.

Si limitamos nuestra atención a las cajas de laminación, es conveniente restringir el análisis de dependencias parciales a un determinado diámetro ya que la configuración de las cajas es únicamente dependiente de éste. La figura 4.42 muestra las variables más importantes relativas a cajas de laminación en la producción de rollos de diámetro 15. La velocidad en el bloque es la variable más influyente en la aparición del astillado y el gráfico de dependencias parciales correspondiente indica que no debería ser inferior a 12500. Otras variables relevantes para este defecto son los alargamientos, principalmente en las cajas 1 y 03, para las que el gráfico de dependencias parciales señala el rango de trabajo más seguro.

Finalmente, la figura 4.43 grafica las dependencias parciales de las variables químicas

Figura 4.38: Gráfico de dependencias parciales para temperaturas, permanencia y gas en horno + dúo para bobinadoras.



más importantes en la laminación en el bloque señalando unos límites superiores que, de ser superados, incrementan la probabilidad de presentar astillado.


4.5.3 Gráficos de descomposición

Los gráficos de composición proporcionan la contribución de cada atributo en la predicción de la probabilidad de defecto para una instancia o rollo en particular. Para obtenerlos, se utiliza la función *predict_parts* pasando como parámetros el explicador y la instancia a predecir.

La figura 4.44 muestra el gráfico de descomposición relativo a un rollo laminado en bobinadoras con una predicción de probabilidad de defecto elevada. Observamos un gran contribución debida a una insuficiente permanencia en el horno y en la balsa de bobinadoras.

La figura 4.45 muestra el gráfico de descomposición de un rollo laminado en el bloque. El caudal en la caja de agua 3 era nulo, lo cual favorece significativamente la aparición del defecto según comprobamos en la figura 4.41. Las composiciones de azufre

Figura 4.39: Gráfico de dependencias parciales para temperaturas, permanencia y gas en horno + dúo para el bloque.

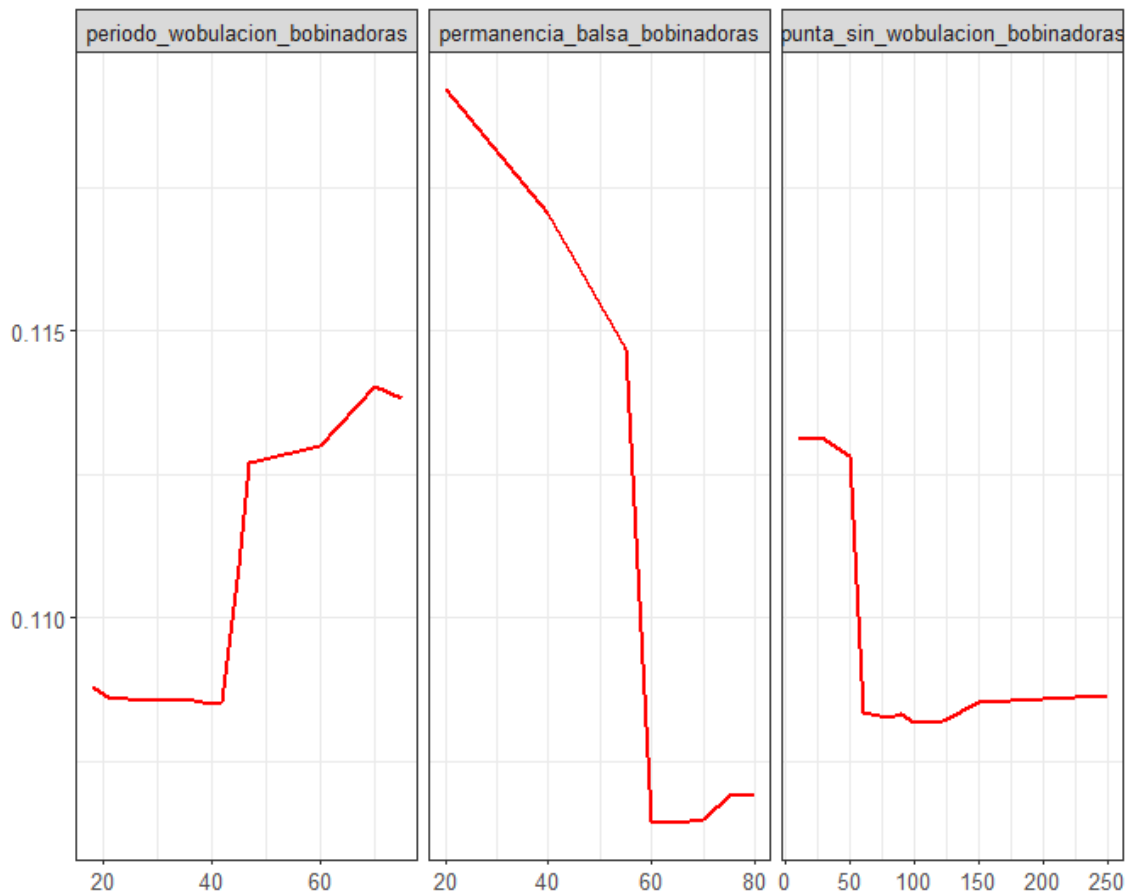


y carbono, cuyo gráfico de dependencias parciales es representado en la figura 4.43, tienen valores que influyen negativamente en la calidad resultante. Si centramos ahora nuestra atención en variables que toman valores particulares en función del diámetro, como las señaladas en la figura 4.42, comprobamos que la contribución al defecto de la velocidad en el bloque se debe a que su bajo valor está en una zona con alta probabilidad de defecto.

4.5.4 Gráficos de Ceteris Paribus

Existen otras visualizaciones o herramientas útiles. Los perfiles Ceteris Paribus (expresión latina que significa "siendo el resto de las cosas iguales") muestran la respuesta del modelo alrededor de una observación particular, es decir, sobre un punto del espacio de

Figura 4.40: Gráfico de dependencias parciales para las variables específicas de bobinadoras.



características. Grafican la variación de la respuesta en función de la variación de cierto atributo y consideran que el resto de variables no varían.

La 4.46 muestra un gráfico Ceteris Paribus mediante la función *predict_profile* pasando como parámetro un explicador construido con los rollos laminados en bobinadoras con tipo de acero 076 así como la información de proceso del rollo correspondiente e indicando como variables a visualizar el caudal de gas promedio en la zona de igualación superior, la permanencia en la balsa de bobinadoras, la permanencia en el horno y la velocidad mínima en la pasada 10 del dúo. EL caudal de gas promedio está en una zona más segura, circunstancia que también se aprecia en la figura 4.44, mientras que el resto de variables tienen valores que influyen en una probabilidad de defecto mayor.

Por otra parte, la figura 4.47 muestra el gráfico Ceteris Paribus con el explicador

Figura 4.41: Gráfico de dependencias parciales para las variables específicas del bloque.




Figura 4.42: Gráfico de dependencias parciales para las variables de cajas de laminación en la fabricación del diámetro 15.

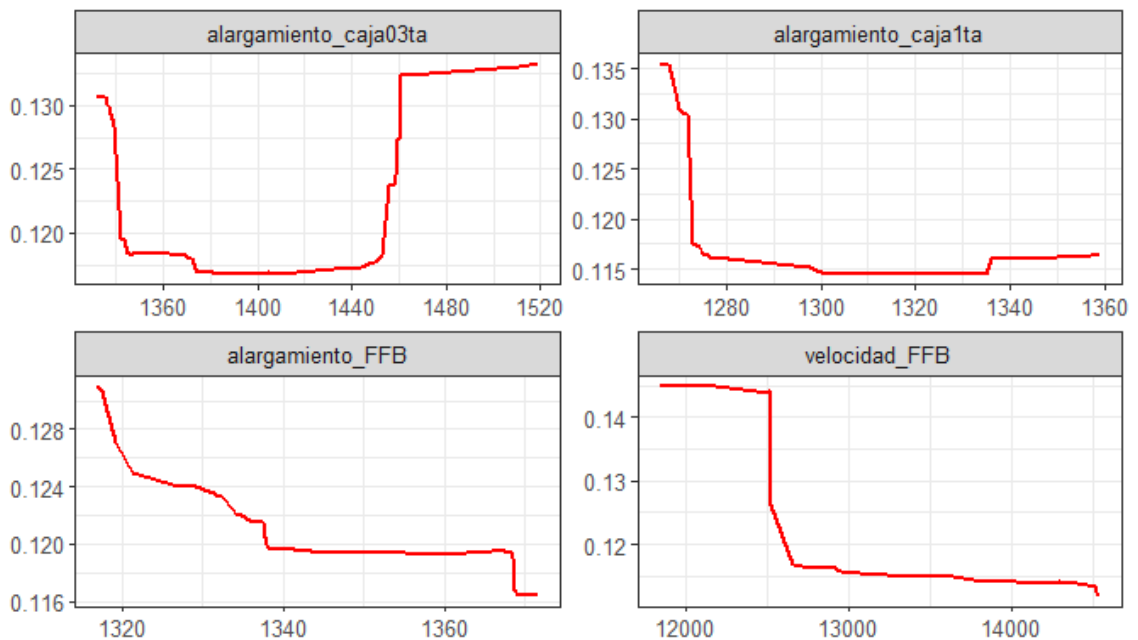


Figura 4.43: Gráfico de dependencias parciales para las variables de composición química en la fabricación del tipo de acero 076 en el bloque.





Figura 4.44: Gráfico de descomposición.



calculado para el acero 076 y para las variables del caudal de agua en la caja 3 del bloque, el caudal de gas en la zona de igualación superior y las composiciones de azufre y carbono para cierto rollo con diámetro 15 y tipo de acero 076 que ilustra que todos sus

Figura 4.45: Gráfico de descomposición.





Figura 4.46: Gráfico Ceteris Paribus de un rollo laminado en bobinadoras.




valores favorecen el astillado. En la figura 4.48 se muestra el gráfico Ceteris Paribus con el explicador obtenido para las observaciones laminadas con diámetro 15. Las variables graficadas son el alargamiento en la caja 1, el alargamiento en el bloque, la velocidad en el bloque, las velocidades máximas en la tercera y cuarta pasada del dúo y la velocidad

mínima en la última pasada. Todas ellas contribuyen a incrementar la probabilidad de que el rollo presente astillado, siendo la velocidad en el bloque la más influyente.


Éstos son unos simples ejemplos que ilustran cómo las herramientas de explicación de modelos pueden proporcionar una mayor profundidad de comprensión del problema que se está modelando además de facilitar una guía de corrección. Sería conveniente utilizar una herramienta de visualización web flexible que permita obtener las visualizaciones con facilidad y de acuerdo a las necesidades puntuales del operador, asistiendo su comprensión y toma de decisiones.

Figura 4.47: Gráfico *Ceteris Paribus* de un rollo laminado en el bloque, acero 076.



4.6 Despliegue

El despliegue del modelo se realizará en un contenedor Docker, utilizando la librería Plumber (Schloerke y Allen, 2022) para exponer la predicción como un servicio REST. El modelo entrenado finalmente seleccionado es guardado como fichero rds. Posteriormente se crea un script en R que cargue el modelo y la tarea y exponga como servicio REST su predicción pasando como parámetros un data.frame con el valor de los atributos de la instancia a predecir, como se ve en el listado 4.11.

Figura 4.48: Gráfico Ceteris Paribus de un rollo laminado en el bloque, diámetro 15.

A continuación, se crea un contenedor Docker que incluya una instalación de R junto con las librerías necesarias, los ficheros rds del modelo y de la tarea y que utilice la librería plumber para exponer el servicio REST de predicción. Docker es una herramienta software que permite crear y desplegar entornos de ejecución aislados para ejecutar aplicaciones y sus dependencias (Nüst et al., 2020). El dockerfile permite seleccionar la imagen base, la instalación de librerías, la estructura de carpetas, copia de archivos que incluirá el modelo y el script que implementa el servicio REST y, finalmente, la exposición mediante plumber del método mediante el puerto especificado. En el listado 4.12 puede verse un ejemplo del contenido del dockerfile.

Una vez creado el contenedor Docker y ejecutado, el servicio REST de predicción del modelo ya está desplegado y disponible para ser consumido.

Listado 4.11: *api.R: Script que permite exponer como servicio REST la predicción del modelo*

```

1 tarea<-readRDS("./datos/tarea_probabilidad_astillado.rds")
2 modelo<-readRDS("./datos/modelo.rds")
3
4 ## @post /prediccion
5 prediccion<-function(data){
6   tryCatch({

```

```

7         res<-modelo$modelo$learner$predict_newdata(rollo,tarea$
           task_probabilidad_astillado.train)
8         return(list(probabilidad_astillado=res$response,name=data$name))
9     },error=function(e){
10         cat(file=stderr(),"Error en ","prediccion",":",e$message," \n")
11         stop(e)
12     })
13 }

```

Listado 4.12: Dockerfile

```

1 FROM r-base:latest
2
3 RUN apt-get update && \
4 apt-get -y install default-jre && \
5 apt-get -y install default-jdk && \
6 apt-get -y install r-base && \
7 apt-get -y install r-base-dev
8
9 RUN R CMD javareconf
10 RUN apt-get update
11 RUN apt-get -y install r-cran-rjava
12 RUN apt-get install libssl-dev -y
13 RUN apt-get install libsasl2-dev -y
14 RUN apt-get install libcurl4-openssl-dev -y
15 RUN apt-get install libsodium-dev -y
16 RUN apt-get install libxml2-dev -y
17
18 #Instalar las librerías necesarias
19 RUN R -e "install.packages('jsonlite',repos='http://cran.r-project.org')"
20 RUN R -e "install.packages('dplyr',repos='http://cran.r-project.org')"
21 RUN R -e "install.packages('RJDBC',repos='http://cran.r-project.org')"
22 RUN R -e "install.packages('rJava',repos='http://cran.r-project.org')"
23 RUN R -e "install.packages('lubridate',repos='http://cran.r-project.org')"
24 RUN R -e "install.packages('tidyr',repos='http://cran.r-project.org')"
25 RUN R -e "install.packages('mongolite',repos='http://cran.r-project.org')"
26 RUN R -e "install.packages('plumber',repos='http://cran.r-project.org')"
27 RUN R -e "install.packages('influxdb',repos='http://cran.r-project.org')"
28 RUN R -e "install.packages('purrr',repos='http://cran.r-project.org')"
29 RUN R -e "install.packages('FNN',repos='http://cran.r-project.org')"
30 RUN R -e "install.packages('readr',repos='http://cran.r-project.org')"
31 RUN R -e "install.packages('forcats',repos='http://cran.r-project.org')"
32 RUN R -e "install.packages('broom',repos='http://cran.r-project.org')"
33 RUN R -e "install.packages('ROCR',repos='http://cran.r-project.org')"
34 RUN R -e "install.packages('rapportools',repos='http://cran.r-project.org')"
35 RUN R -e "install.packages('stringr',repos='http://cran.r-project.org')"
36 RUN R -e "install.packages('rvest',repos='http://cran.r-project.org')"

```

```

37 RUN R -e "install.packages('tidyverse',repos='http://cran.r-project.org')"
38 RUN R -e "install.packages('RcppRoll',repos='http://cran.r-project.org')"
39 RUN R -e "install.packages('remotes',repos='http://cran.r-project.org')"
40 RUN R -e "install.packages('DALEX',repos='http://cran.r-project.org')"
41 RUN R -e "install.packages('DALEXtra',repos='http://cran.r-project.org')"
42 RUN R -e "install.packages('mlr3',repos='http://cran.r-project.org')"
43 RUN R -e "install.packages('mlr3verse',repos='http://cran.r-project.org')"
44 RUN R -e "remotes::install_github('mlr-org/mlr3learners', dependencies = TRUE)"
45
46 RUN R -e "options(java.parameters = c('-XX:+UseConcMarkSweepGC', '-Xmx8192m'))"
47
48 #Copiar la carpeta actual al path de la aplicación
49 COPY . /usr/local/src/app
50 #Establecer el directorio actual de la app
51 WORKDIR /usr/local/src/app
52
53 # Plumb y ejecutar servidor
54 EXPOSE 6000
55 ENTRYPOINT ["R", "-e", \
56 "pr <- plumber::plumb('api.R'); pr$run(host='0.0.0.0', port=6000)"]

```

Por otra parte, se requiere una herramienta de visualización flexible que permita obtener gráficos de forma interactiva. Shiny(Chang et al., 2022) es una librería que permite implementar aplicaciones web interactivas utilizando librerías de R. El usuario puede configurar las visualizaciones mediante controles tales como botones, listas desplegables, listas de selección y otros controles.

5. Conclusiones y Trabajo Futuro

Este trabajo tiene varios objetivos:

- Construir un modelo de aprendizaje automático que prediga la aparición del defecto astillado.
- Lograr un indicador que permita observar el estado de calidad, relativa al defecto astillado, del proceso de calentamiento de palanquillas y laminación en caliente.
- Comparar el poder predictivo y coste de los errores de predicción de un modelo basado en aprendizaje automático con un clasificador de defecto basado en las reglas de un Sistema de Monitorización de Condiciones.
- Proporcionar una guía visual que permita la corrección del sistema a un estado seguro.

Durante el proceso de análisis exploratorio se emplearon Mapas Autoorganizados en modo no supervisado y en modo supervisado. El modelo supervisado basado en Mapas Autoorganizados proporcionó un desempeño con un poder predictivo insuficiente.

En la siguiente etapa, se abordó la construcción de un modelo de predicción de astillado siguiendo dos enfoques diferentes.

- Modelo de clasificación que prediga la clase con defecto.
- Modelo de regresión que prediga el porcentaje de defectos en un entorno temporal de cada observación y utilizar ese valor como la probabilidad de pertenencia a la clase con defecto.

Se probaron diferentes algoritmos para cada una de las dos modalidades descritas anteriormente resultando el algoritmo de Bosques Aleatorios el más eficiente. Posteriormente, se comparó el desempeño como clasificador para ambas opciones. El modelo de

predicción de la probabilidad de astillado proporcionó el mejor desempeño medido con la métrica del área bajo la curva ROC. Una de los inconvenientes que se hizo manifiesto es que el área bajo la curva ROC puede resultar válido para comparar varios algoritmos bajo el mismo conjunto de datos, pero es inadecuado para comparar entre modelos que utilizan distintos conjuntos, especialmente si éstos están desequilibrados.

La probabilidad de defecto predicha con el modelo de regresión puede utilizarse como indicador del estado del proceso de fabricación. Se calculó un umbral de detección a partir de los costes de falsos positivos y falsos negativos. A continuación, se comparó con otra opción muy presente en la industria: un sistema de monitorización de condiciones que informe sobre desviaciones de las variables de proceso en función del tipo de producto. El indicador basado en el modelo de aprendizaje automático es mejor clasificador e incurre en menor coste.

El índice calculado como la probabilidad de defecto tomará un valor en función de la composición química y las estadísticas de las variables de proceso referidas a los productos. Si este adquiere un valor alto, será indicativo de que existe una propensión del sistema a producir el defecto y será necesario realizar alguna acción correctiva que lleve al sistema a un estado seguro. Las herramientas de explicación de modelos de aprendizaje automático permite generar visualizaciones que muestren las distintas contribuciones de las variables de proceso en la predicción del defecto y, consiguientemente, proporcionan una indicación de su sentido de modificación para corregirlo. Con este fin, pueden utilizarse gráficos de dependencias parciales o de Ceteris Paribus.

Uno de los principales inconvenientes del desarrollo es que no se prestó atención a la selección de variables ya que el objetivo último no era obtener el mejor modelo, sino la comparación de opciones: modelo de clasificación con modelo de regresión y modelo de aprendizaje automático con Sistema de Monitorización de Condiciones. Sin embargo, la alta correlación entre las variables dificulta la explicación del modelo.

Como líneas de trabajo futuro, se plantean las siguientes:

- Comprobar si mejora el poder predictivo si se dividen los conjuntos de datos en

Monitorización del estado de calidad en un proceso de laminación en caliente de acero inoxidable mediante técnicas de aprendizaje automático

función del diámetro y/o tipo de acero, construyendo los modelos correspondientes.

- Modelar la gravedad del defecto. Podría proporcionar un modelo sensible que evitase los defectos con mayor impacto económico.
- Extender el estudio a otros defectos, al menos los más frecuentes. Puede suceder que exista relación entre ellos.

Bibliografía

- Biecek, P. (2018). Dalex: Explainers for complex predictive models in r. *Journal of Machine Learning Research*, 19(84), 1–5. Descargado de <http://jmlr.org/papers/v19/18-416.html>
- Breiman, L. (2001, 10). Random forests. *Machine Learning*, 45, 5-32. doi: 10.1023/A:1010950718922
- Chang, W., Cheng, J., Allaire, J., Sievert, C., Schloerke, B., Xie, Y., ... Borges, B. (2022). shiny: Web application framework for r [Manual de software informático]. Descargado de <https://shiny.rstudio.com/> (R package version 1.7.4)
- Chen, T., y Guestrin, C. (2016). XGBoost: A scalable tree boosting system. En *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785–794). New York, NY, USA: ACM. Descargado de <http://doi.acm.org/10.1145/2939672.2939785> doi: 10.1145/2939672.2939785
- Chen, T., He, T., Benesty, M., Khotilovich, V., Tang, Y., Cho, H., ... Yuan, J. (2022). xgboost: Extreme gradient boosting [Manual de software informático]. Descargado de <https://CRAN.R-project.org/package=xgboost> (R package version 1.6.0.1)
- Commission, E., for Research, D.-G., Innovation, Farrugia, D., Santisteban, V., y Husain, Z. (2009). *Pacrolp, the prediction and avoidance of cracking in long product hot rolling*. Publications Office.
- Cortes, C., y Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3),

Miguel Ángel González González
Monitorización del estado de calidad en un proceso de laminación en caliente de acero inoxidable
mediante técnicas de aprendizaje automático
273–297.

Cramer, H. (1946). *Mathematical methods of statistics / by harald cramer* [Book]. Princeton University Press Princeton.

Cser, L., Korhonen, A., Simula, O., y Ruha, P. (1999). Process state monitoring based on data mining in hot rolling..

Das, G., Chattopadhyay, M., y Gupta, S. (2016, 07). A comparison of self-organising maps and principal components analysis. *International Journal of Market Research*, 58. doi: 10.2501/IJMR-2016-039

Dimitriadou, E., Hornik, K., Leisch, F., Meyer, D., y Weingessel, A. (2009, 11). E1071: Misc functions of the department of statistics (e1071), tu wien. En (Vol. 1).

Drobne, M., Urska, K., Tercej, M., Fajfar, P., y Ltd, T. (2017). Thermal crack propagation during hot rolling and its influence on cast iron work roll degradation. *Proceedings of the Metal*.

Dwivedi, S., Rana, R., Rana, A., Rajpurohit, S., y Purohit, R. (2017, 12). Investigation of damage in small deformation in hot rolling process using fem. *Materials Today: Proceedings*, 4, 2360-2372. doi: 10.1016/j.matpr.2017.02.085

Epskamp, S., Cramer, A. O. J., Waldorp, L. J., Schmittmann, V. D., y Borsboom, D. (2012). qgraph: Network visualizations of relationships in psychometric data. *Journal of Statistical Software*, 48(4), 1–18.

Ervasti, E., y Ståhlberg, U. (2000, 04). Transversal cracks and their behaviour in the hot rolling of steel slabs. *Journal of Materials Processing Technology - J MATER PROCESS TECHNOL*, 101, 312-321. doi: 10.1016/S0924-0136(99)00481-1

Friedman, J., Hastie, T., y Tibshirani, R. (2010). Regularization paths for generalized linear

- models via coordinate descent. *Journal of Statistical Software*, 33(1), 1–22. Descargado de <https://www.jstatsoft.org/v33/i01/> doi: 10.18637/jss.v033.i01
- Gallardo Arancibia, J. A. (2009). *Metodología para la definición de requisitos en proyectos de data mining*. Descargado de <https://oa.upm.es/1946/>
- González-Castillo, A., Cruz-Rivera, J., Ramos-Azpeitia, M., Garnica, P., Garay-Reyes, C., Pacheco-Cedeño, J., y Hernandez-Rivera, J. (2021, 05). 3d-fem simulation of hot rolling process and characterization of the resultant microstructure of a light-weight mn steel. *Crystals*, 11, 569. doi: 10.3390/cryst11050569
- Haapamäki, J., y Röning, J. (2005, 01). Genetic algorithms in hot steel rolling for scale defect prediction. En (Vol. 5, p. 1-4).
- Haapamäki, J., Tamminen, S., y Röning, J. (2005, 01). Data mining methods in hot steel rolling for scale defect prediction. En (p. 90-94).
- Henry, L., y Wickham, H. (2022). purrr: Functional programming tools [Manual de software informático]. (<http://purrr.tidyverse.org>, <https://github.com/tidyverse/purrr>)
- Hietaniemi, M., Elsilä, U., Laurinen, P., y Röning, J. (2008, 01). Defect prediction in hot strip rolling using ann and svm. En (Vol. 173, p. 44-51). doi: 10.3233/978-1-58603-867-0-44
- Jokhakar, V., y Patel, S. (2015, 1). Mild steel defect diagnosis using tree ensemble. *VNSGU Journal of Science and Technology*, 4(1), 141-152.
- Kohonen, T. (1982). "self-organized formation of topologically correct feature maps", biological cybernetics, vol. 43, pp. 59-69.
- Kohonen, T. (1995). Self-organizing maps. En *Springer series in information sciences*.
- Krawczyk, B. (2016). Learning from imbalanced data: open challenges and future direc-

tions. *Progress in Artificial Intelligence*, 5, 221-232.

Lang, M., Binder, M., Richter, J., Schratz, P., Pfisterer, F., Coors, S., ... Bischl, B. (2019, dec).

mlr3: A modern object-oriented machine learning framework in R. *Journal of Open Source Software*. doi: 10.21105/joss.01903

Lieber, D., Stolpe, M., Konrad, B., Deuse, J., y Morik, K. (2013). Quality prediction

in interlinked manufacturing processes based on supervised and unsupervised machine learning. *Procedia CIRP*, 7, 193-198. Descargado de <https://www.sciencedirect.com/science/article/pii/S2212827113002400>

(Forty Sixth CIRP Conference on Manufacturing Systems 2013) doi: <https://doi.org/10.1016/j.procir.2013.05.033>

Mangiafico, S. (2022). rcompanion: Functions to support extension education program

evaluation [Manual de software informático]. Descargado de <https://CRAN.R-project.org/package=rcompanion> (R package version 2.4.18)

Mirjana, F. (2007, 01). Evolution of artificial defects during shape rolling.

Napierala, K., y Stefanowski, J. (2015). Types of minority class examples and their influen-

ce on learning classifiers from imbalanced data. *Journal of Intelligent Information Systems*, 46, 563-597.

Nüst, D., Sochat, V., Marwick, B., Eglén, S., Head, T., Hirst, T., y Evans, B. (2020, 04). *Ten*

simple rules for writing dockerfiles for reproducible data science. doi: 10.31219/osf.io/fsd7t

R Core Team. (2021). R: A language and environment for statistical computing [Manual de

software informático]. Vienna, Austria. Descargado de <https://www.R-project.org/>

- Ruiz, E., Ferreño, D., Cuartas, M., Lloret, L., Ruiz del Árbol, P. M., López, A., ... Gutiérrez-Solana, F. (2021). Machine learning methods for the prediction of the inclusion content of clean steel fabricated by electric arc furnace and rolling. *Metals*, 11(6). doi: 10.3390/met11060914
- Sayed, M., y Hamid, R. (2010, 10). Applying data mining methods to predict defects on steel surface. *Journal of Theoretical and Applied Information Technology*, 20, 87-92.
- Schliep, K., y Hechenbichler, K. (2016). kkn: Weighted k-nearest neighbors [Manual de software informático]. Descargado de <https://CRAN.R-project.org/package=kkn> (R package version 1.3.1)
- Schloerke, B., y Allen, J. (2022). plumber: An api generator for r [Manual de software informático]. Descargado de <https://CRAN.R-project.org/package=plumber> (R package version 1.2.1)
- Sing, T., Sander, O., Beerenwinkel, N., y Lengauer, T. (2005). ROCR: visualizing classifier performance in r. *Bioinformatics*, 21(20), 7881. Descargado de <http://rocr.bioinf.mpi-sb.mpg.de>
- Takalo-Mattila, J., Heiskanen, M., Kyllönen, V., Määtä, L., y Bogdanoff, A. (2022). Explainable steel quality prediction system based on gradient boosting decision trees. *IEEE Access*, 10, 68099-68110. doi: 10.1109/ACCESS.2022.3185607
- Therneau, T., y Atkinson, B. (2019). rpart: Recursive partitioning and regression trees [Manual de software informático]. Descargado de <https://CRAN.R-project.org/package=rpart> (R package version 4.1-15)
- Vlado, M., Bidulský, R., Gulová, L., Machova, K., Bidulská, J., Valíček, J., y Sas, J. (2011, 04).

The production of cracks evolution in continuously cast steel slab. *High Temperature Materials and Processes*, 30. doi: 10.1515/htmp.2011.014

Wehrens, R., y Buydens, L. M. C. (2007). Self- and super-organizing maps in R: The kohonen package. *Journal of Statistical Software*, 21(5), 1–19. doi: 10.18637/jss.v021.i05

Wehrens, R., y Kruisselbrink, J. (2018). Flexible self-organizing maps in kohonen 3.0. *Journal of Statistical Software*, 87(7), 1–18. doi: 10.18637/jss.v087.i07

Wickham, H., Averick, M., Bryan, J., Chang, W., McGowan, L. D., François, R., ... Yutani, H. (2019). Welcome to the tidyverse. *Journal of Open Source Software*, 4(43), 1686. doi: 10.21105/joss.01686

Wright, M. N., y Ziegler, A. (2017). ranger: A fast implementation of random forests for high dimensional data in C++ and R. *Journal of Statistical Software*, 77(1), 1–17. doi: 10.18637/jss.v077.i01

Xiong, H., Wu, J., y Liu, L. (2010). Classification with class overlapping: A systematic study..

Yin, H. (2007, 09). Learning nonlinear principal manifolds by self-organising maps. En (Vol. 60, p. 68-95). doi: 10.1007/978-3-540-73750-6_3

Yun, J. P., Choi, S., Seo, B., Park, C., y woo Kim, S. (2008). Defects detection of billet surface using optimized gabor filters. *IFAC Proceedings Volumes*, 41, 77-82.

6. Anexo. Artículo de investigación

A continuación se incluye un artículo de investigación que resume el trabajo realizado y los principales resultados obtenidos.

Determinación de un indicador de calidad en la laminación en caliente de acero inoxidable mediante aprendizaje automático

Miguel Ángel González González

Universidad Internacional de la Rioja, Logroño (España)

1 de febrero de 2023

RESUMEN

Se presenta la obtención de un indicador del estado de un proceso de fabricación de rollos de acero inoxidable relativo a la aparición de un defecto que repercute muy negativamente en la calidad del producto: el astillado. Como primera aproximación, este indicador se obtendría a partir de la probabilidad de pertenencia a la clase positiva de un modelo de clasificación obtenido mediante aprendizaje supervisado. Sin embargo, el desarrollo realizado evidencia que la salida de un modelo de regresión que prediga el porcentaje de defectos ofrece mejor resultado. La solución propuesta prueba también mejor poder de predicción y menor coste que otras alternativas más extendidas en la industria, tales como los sistemas de monitorización de condiciones.

Asimismo, se propone un sistema de explicación agnóstico al modelo que proporcione una guía de corrección del proceso mediante gráficos de importancia de variables, de dependencias parciales, de descomposición y de *Ceteris Paribus*.

I. INTRODUCCIÓN

Como sucede en cualquier proceso productivo, la calidad de los productos es uno de los requisitos principales pues repercute en los costes de fabricación, en la generación de desperdicios, en el impacto ambiental y en la percepción del cliente. Existe una estrecha relación entre la presencia de defectos en los productos y las características de la materia prima y/o el modo en que ha sido llevado a cabo el proceso. Sin embargo, la gran variabilidad y complejidad de éstos dificulta enormemente el reconocimiento de patrones que intervienen, cuyo conocimiento y control permitiría la mejora de la calidad resultante.

En la fabricación de rollos de acero inoxidable, uno de los procesos más importantes es el calentamiento de palanquillas y su laminación en caliente, que produce una deformación

del metal caliente que pueden causar la aparición de ciertos defectos, como el astillado. En este proceso intervienen variables de difícil modelado, tales como factores de reducción, alargamientos, velocidades, temperaturas, microestructura o composición química, por citar algunos.

En este artículo se plantea la construcción de un modelo de predicción del defecto astillado que, por una parte, proporcione una indicación del estado del proceso en relación con la aparición de este defecto y, por otra parte, permita reconocer las dependencias multidimensionales del defecto con la composición química y estadísticas de variables de proceso que guíen la corrección a un estado más seguro. Se comparará el desempeño de un modelo de regresión que prediga la probabilidad de defecto a partir del porcentaje de defectos respecto a un mode-

unir
LA UNIVERSIDAD
EN INTERNET

PALABRAS CLAVE

aprendizaje automático, acero inoxidable, laminación en caliente, calidad

lo de clasificación de astillado.

La información de composición química y de proceso se ha obtenido de una fábrica española de rollos de acero inoxidable. La laminación en caliente consiste en el calentamiento de la materia prima, grandes tochos de acero denominados palanquillas, en un horno de calentamiento para su posterior conformación mediante la laminación en varias cajas laminadoras consecutivas. Finalmente, un operador humano inspecciona el rollo producido y califica su calidad mediante un sistema informático de trazabilidad.

Se considerarán dos procesos de laminación diferentes en función del diámetro: bobinadoras y bloque. En el primero, la laminación en caliente termina en una pareja de bobinadoras e inmersión en agua. En el segundo, se requiere una laminación en un bloque de finalización, para continuar en una inmersión en agua y formación de espiras.

II. ESTADO DEL ARTE

El diseño de la configuración de rodillos determina la forma y calidad del producto laminado, de modo que hay varias variables que influyen en el resultado tales como el ratio de reducción de área, la tasa de deformación, el histórico de temperatura y la composición química[1]. Los defectos pueden ser producidos en la metalurgia o por su composición química, pero también debidos a una práctica de laminación inadecuada o como consecuencia de un diseño deficiente de configuración de rodillos.

En [2] se realiza un resumen de las líneas principales de investigación relativas al uso de la inteligencia artificial en relación con el proceso de laminación en caliente del acero. Las propuestas principales consisten en la monitorización del estado de calidad del proceso apoyándose en Mapas Autoorganizados, la utilización de modelos predictivos, principalmente Redes Neuronales, para la predicción de variables de proceso en combinación con modelos matemáticos de los procesos y el valor de la minería de datos para el análisis de la influencia de diferentes parámetros y variables del proceso en la calidad.

Existen diferentes propuestas orientadas a

utilizar técnicas de aprendizaje automático para la predicción de diferentes tipos de defectos tales como óxido[3, 4], hoyuelos y ampollas[5], grietas[6], desviación de temperatura[7], inclusiones[8] u otros[9, 10, 11]. Todos ellos siguen unas líneas generales comunes, consistentes en la predicción de defectos superficiales mediante algoritmos de aprendizaje automático a partir de composición química e información del proceso, complementada en algún caso con modelos matemáticos o técnicas de aprendizaje no supervisado. La comparación del desempeño de las distintas soluciones es problemática por la diversidad de los procesos y defectos a predecir. De forma general, podríamos decir que los modelos más eficaces arrojan un área bajo la curva ROC próxima al 0,8.

Se espera que el objetivo último del modelo de predicción sea, de alguna forma, evitar que éste se produzca finalmente. Sin embargo, éste propósito apenas se hace explícito en los trabajos consultados. En alguna ocasión, se apunta que la solución permitiría reconocer las condiciones del proceso que favorecen la aparición del defecto, así como la etapa del proceso en el que se producen[3]. Otras, la justifican por señalar un conocimiento más profundo del proceso, bien de cara a la creación de nuevas reglas de control[5], bien por la utilización de herramientas de explicación de modelos [8, 11]. Nuestra propuesta procurará incidir en la creación de un indicador del estado de calidad del proceso como alternativa a las reglas de los sistemas de monitorización de condiciones. Igualmente, se planteará una implementación alternativa a los habituales modelos de clasificación supervisados.

III. OBJETIVOS Y METODOLOGÍA

El objetivo principal de este artículo consistirá en la monitorización del estado del proceso creando un indicador vinculado a la probabilidad de aparición del defecto obtenido a partir de las presentes condiciones de laminación, aplicando técnicas de aprendizaje automático en el marco de procesos de laminación en caliente de acero inoxidable. Esta variable de estado, junto con un modelo explicativo, apoyado

por gráficas de dependencias parciales, indicaría cómo modificar algunas variables de proceso conduciendo al sistema a un estado más seguro. En este sentido, la contribución más importante será mostrar sus ventajas frente a otras aproximaciones más extendidas en la industria, como las reglas de los sistemas de monitorización de condiciones. Estos sistemas consisten en la comprobación de que ciertas variables de proceso están dentro de un rango determinado dependiente del tipo de producto a procesar.

La obtención del indicador de estado corresponde a los objetivos específicos y será generado como la probabilidad de pertenencia a la clase positiva de un modelo de clasificación supervisado para el defecto astillado. En la primera parte del desarrollo de este trabajo se entrenarán, evaluarán y compararán diferentes algoritmos de aprendizaje automático de clasificación. Sin embargo, también considerará como alternativa la obtención de la probabilidad de defecto a partir del porcentaje de defectos en torno a cada rollo laminado. Este indicador será predicho utilizando algoritmos de aprendizaje automático de regresión, para lo cual se entrenarán, evaluarán y compararán diferentes algoritmos de aprendizaje automático de regresión. Finalmente, se compararán las dos opciones con el objetivo común de predecir el estado de defecto en el conjunto de datos de test.

La población estudiada data desde junio hasta mediados de octubre del 2022. El conjunto de datos se divide en dos: uno relativo a la laminación en caliente siguiendo el proceso de bobinadoras y otro para el proceso del bloque. Se utilizará como variable a predecir la clasificación de defecto, en la opción de modelo de clasificación, y el indicador de probabilidad de defecto en la opción del modelo de regresión calculado como el porcentaje de defectos considerando cinco rollos en el entorno temporal del dado. Las variables predictoras serán las estadísticas de proceso durante su calentamiento en el horno (tiempos y temperaturas), características dimensionales, composición química y variables de proceso durante la laminación en caliente. Estas últimas son diferentes según el camino bobinadoras o bloque. El preprocesamiento de las variables predictoras incluirá un

escalado y una codificación de variables categóricas de tipo one-hot.

La metodología para la obtención de los modelos de aprendizaje automático es CRISP-DM ó Cross Industry Standard Process for Data Mining [12]. La consulta de los datos, limpieza, análisis exploratorio así como el entrenamiento, evaluación y selección de modelos será realizado utilizando el ecosistema del lenguaje R, en particular con la colección de librerías de tidyverse [13] y mlr3 [14]. Los algoritmos utilizados son ranger[15], rpart[16], xgboost[17, 18], glmnet[19], kkn[20] y svm[21].

Se utilizará el área bajo la curva ROC como métrica de comparación y selección de los modelos de clasificación, mientras que la raíz del error cuadrático medio y el coeficiente de determinación ó R^2 se utilizarán en la comparación y selección de los modelos de regresión. Finalmente, el valor predicho por el modelo de regresión será utilizado como la probabilidad de pertenencia a la clase positiva de un modelo de clasificación, lo que permitirá la comparación del mejor modelo de clasificación y del mejor modelo de regresión como modelos de predicción de defecto utilizando el área bajo la curva ROC.

El modelo finalmente seleccionado será interpretado mediante DALEX [22] generando gráficos de importancia de variables basadas en permutación, perfiles de dependencias parciales, gráficos de descomposición y perfiles Ceteris Paribus.

IV. EVALUACIÓN

En este apartado mostraremos los resultados obtenidos en la evaluación de las diferentes opciones y modelos.

A. Modelos de clasificación de defecto

En las figuras 1 y 2 se muestran el área bajo la curva ROC de los diferentes modelos de clasificación del defecto astillado.

B. Modelos de regresión de probabilidad de defecto

En las figuras 3 y 4 se muestra la raíz del error cuadrático medio de los diferentes mode-

Figura 1: Área bajo curva ROC: predicción astillado para bobinadoras.






Figura 2: Área bajo curva ROC: predicción astillado para bloque.



los de regresión de la probabilidad de astillado.

Figura 3: Raíz de Error Cuadrático Medio: predicción de la probabilidad de astillado para bobinadoras.



C. Comparación de modelos

En las figuras 5 y 6 se muestra el área bajo la curva ROC de los modelos de clasificación y de los modelos de regresión como modelos de clasificación de defecto.

Figura 4: Raíz de Error Cuadrático Medio: predicción de la probabilidad de astillado para el bloque.




Figura 5: Comparación del área bajo la curva ROC de ambas modalidades de clasificación y de los distintos algoritmos considerados para bobinadoras.





Figura 6: Comparación del área bajo la curva ROC de ambas modalidades de clasificación y de los distintos algoritmos considerados para bobinadoras.



V. ANÁLISIS DE RESULTADOS

A la luz de la evaluación realizada en la sección anterior, puede comprobarse que el algoritmo *ranger* ofrece el mejor desempeño tanto en las opciones de clasificación como de regre-

sión, y que la utilización de la predicción del porcentaje de defecto del modelo de regresión como probabilidad de pertenencia a clase de un clasificador de defecto tiene mayor poder predictivo que el correspondiente modelo de clasificación. El modelo finalmente seleccionado será el modelo de regresión y su predicción será la indicación de estado de calidad de defecto astillado. Como todo modelo de clasificación, su desempeño puede caracterizarse considerando el porcentaje de observaciones en cuya predicción se equivoca, lo cual supone un coste. La tabla 1 muestra la matriz de confusión del clasificador de defecto obtenido mediante el modelo de regresión de predicción de *probabilidad_astillado* y el umbral de detección que minimiza el coste del clasificador, para el tipo de acero 076.

Cuadro 1: Matriz de confusión para la predicción del astillado mediante modelo de regresión, algoritmo de Bosques Aleatorios, para tipo de acero 076

Predicción	Astillado calificado		Total
	Positivo	Negativo	
Positivo	49	153	202
Negativo	19	512	531
Total	68	665	733

Por otra parte, uno de los sistemas más extendidos en la industria para la mejora de la calidad de los productos son los sistemas de monitorización de condiciones. Éstos establecen un conjunto de alarmas que comprueban que las variables de proceso no se alejan de unos límites preestablecidos que dependen de las características del producto a producir, es decir, realizan una predicción del defecto en base a reglas y su desempeño puede evaluarse igualmente según sus errores de predicción e incurrir en un coste. La tabla 2 muestra un conjunto de reglas de un sistema de monitorización de condiciones para la fabricación del tipo de acero inoxidable 076 y la tabla 3 muestra la matriz de confusión correspondiente.

Cuadro 2: Reglas del Sistema de Monitorización de Condiciones para prevenir el astillado para el tipo de acero 076.

1. permanencia_igualacion + permanencia_calentamiento ≤ 300
2. permanencia_igualacion ≤ 120
3. temperatura_corazon_igualacion > 1320
4. temperatura_bobinadoras_cola > 1020 , si $16 \leq$ diametro $\leq 26,5$
5. temperatura_bobinadoras_cola > 990 , si $27 \leq$ diametro $\leq 30,5$
6. temperatura_bobinadoras_cola > 950 , si $31 \leq$ diametro $\leq 41,5$
7. temperatura_entrada_bloque_cola > 1040 , si $5,5 \leq$ diametro ≤ 6
8. temperatura_entrada_bloque_cola > 1020 , si $6,5 \leq$ diametro $\leq 15,5$

Cuadro 3: Matriz de confusión según las reglas del Sistema de Monitorización de Condiciones para tipo de acero 076

Predicción	Astillado calificado		Total
	Positivo	Negativo	
Positivo	29	234	263
Negativo	39	431	470
Total	68	665	733

El desempeño del clasificador basado en el modelo de regresión tiene una sensibilidad de 0,72 con una precisión de 0,24, mientras que la del modelo basado en reglas tiene una sensibilidad de 0,43 y una precisión de 0,10. Una ventaja adicional es la capacidad que ofrece el modelo basado en aprendizaje automático para ofrecer una guía que permita la corrección del sistema a un estado más seguro, frente a la más limitada del modelo basado en reglas que únicamente ofrece indicación para las variables consideradas en las reglas, cuyo poder predictivo es, como hemos visto, bastante más limitado.

Sea p_a el porcentaje de astillados calculado como el ratio de falsos negativos respecto al total; p_r el porcentaje de recuperación calculado como la relación de verdaderos positivos y falsos positivos respecto al total; r_s el sobrecoste unitario de reproceso de los rollos con defecto.; C_u el coste unitario producto correcto y C_r el coste de cada reproceso. Se

ignoran las pérdidas por chatarra debidas a defectos graves.

$$p_a = \frac{FN}{T} \quad (1)$$


$$p_r = \frac{TP + FP}{T} \quad (2)$$

$$Coste = (1 - p_a)C_u + p_r C_r + p_a(1 + r_s)C_u \quad (3)$$

donde FN es el número falsos negativos, TP el de verdaderos positivos, FP el de falsos positivos y T el total de observaciones de test.

Obtendremos sendos conjuntos de datos con el valor de astillado y el valor de astillado predicho utilizando el modelo basado en aprendizaje automático y el conjunto de reglas del sistema de monitorización de condiciones, integrando los datos y modelos de bobinadoras y del bloque. Posteriormente utilizaremos el método de bootstrap, generando distintos conjuntos de datos utilizando la librería *Rsampling*. A partir de cada uno de estos conjuntos de datos artificiales, se calculará el coste correspondiente. La figura 7 muestra la distribución de los valores de coste para los remuestreos aleatorios para ambas opciones.

Figura 7: Bootstrapping del coste para la comparación de las dos modalidades de predicción de astillado.



Se realiza la prueba t de Student mediante la función R *t.test* donde la hipótesis nula consiste en que no hay diferencia entre ambas distribuciones. Como puede comprobarse, la hipótesis


nula es rechazada por el test, por lo que se valida la hipótesis alternativa por la cual hay diferencia significativa estadísticamente entre ambas distribuciones y que la opción basada en el modelo de aprendizaje automático es superior.

Welch Two Sample t-test

```
data: coste.076.rgr and coste.076.reglas
t = -255.55, df = 19080, p-value < 2.2e-16
alternative hypothesis:
true difference in means is less than 0
95 percent confidence interval:
-Inf -5.271623
sample estimates:
mean of x mean of y
2134.801 2140.107
```


Se han desarrollado gramáticas agnósticas para la exploración y explicación de modelos de aprendizaje automático como la implementada en la librería *DALEX*[22], que ofrece distintos métodos de análisis como los gráficos de dependencias parciales, gráficos de efectos locales acumulados, gráficos de unificación de caminos, gráficos de descomposición y gráficos de importancia de variables. La figura 8 muestra los gráficos de dependencias parciales para la temperatura estimada en el corazón, la permanencia en el horno, el caudal de gas en la zona superior de igualación y el promedio de temperatura en la quinta pasada del dúo, para el conjunto de datos del bloque con tipo de acero 076.

Figura 8: Gráfico de dependencias parciales para temperaturas, permanencia y gas en horno + dúo para el bloque.



Respecto a un rollo concreto, los perfiles Ceteris Paribus muestran la respuesta del modelo alrededor de esta observación particular y grafican la evolución de la respuesta en función de la variación de ciertas variables predictoras considerando que el resto no varían. la figura 9 muestra el gráfico Ceteris Paribus con un explicador calculado para el acero 076 y para las variables del caudal de agua en la caja 3 del bloque, el caudal de gas en la zona de igualación superior y las composiciones de azufre y carbono para cierto rollo con diámetro 15 y tipo de acero 076 que ilustra cómo sus valores favorecen el astillado.

Figura 9: Gráfico Ceteris Paribus de un rollo laminado en el bloque, acero 076.



VI. CONCLUSIONES

Este trabajo tiene como objetivos construir un modelo de aprendizaje automático que prediga la aparición del defecto astillado, obtener un indicador que permita observar el estado de calidad en el proceso de laminación en caliente como alternativa a los sistemas de monitorización de condiciones y proporcionar una guía que permita la corrección del sistema a un estado seguro.

Con este propósito, se abordó la construcción de un modelo de predicción de astillado siguiendo dos enfoques diferentes: modelo de clasificación que prediga la clase con defecto y modelo de regresión que prediga el porcentaje de defectos en un entorno temporal de cada observación y utilizar ese valor como la probabilidad de pertenencia a la clase con defecto. El algoritmo de Bosques Aleatorios aplicado en la

construcción del modelo de regresión resultó el más eficiente.

A continuación, se comparó con otra opción muy presente en la industria: un sistema de monitorización de condiciones que informe sobre desviaciones de las variables de proceso en función del tipo de producto. El indicador basado en el modelo de aprendizaje automático es mejor clasificador e incurre en menor coste.

Como líneas de trabajo futuro, se plantea comprobar si mejora el poder predictivo dividiendo los conjuntos de datos en función del diámetro y/o tipo de acero, modelar su gravedad y extender el estudio a otros defectos.

Referencias

- [1] Filipovic Mirjana. Evolution of artificial defects during shape rolling. 01 2007.
- [2] L. Cser, Antti Korhonen, Olli Simula, and Paavo Ruha. Process state monitoring based on data mining in hot rolling. 1999.
- [3] Jarno Haapamäki, Satu Tamminen, and Juha Röning. Data mining methods in hot steel rolling for scale defect prediction. pages 90–94, 01 2005.
- [4] Jarno Haapamäki and Juha Röning. Genetic algorithms in hot steel rolling for scale defect prediction. volume 5, pages 1–4, 01 2005.
- [5] M.S. Sayed and R.E. Hamid. Applying data mining methods to predict defects on steel surface. *Journal of Theoretical and Applied Information Technology*, 20:87–92, 10 2010.
- [6] Martin Vlado, Robert Bidulský, Lucia Gulová, Kristina Machova, Jana Bidulská, Jan Valíček, and Jan Sas. The production of cracks evolution in continuously cast steel slab. *High Temperature Materials and Processes*, 30, 04 2011.
- [7] Veena Jokhakar and S.V. Patel. Mild steel defect diagnosis using tree ensemble. *VNSGU Journal of Science and Technology*, 4(1):141–152, 1 2015.

- [8] Estela Ruiz, Diego Ferreño, Miguel Cuartas, Lara Lloret, Pablo M. Ruiz del Árbol, Ana López, Francesc Esteve, and Federico Gutiérrez-Solana. Machine learning methods for the prediction of the inclusion content of clean steel fabricated by electric arc furnace and rolling. *Metals*, 11(6), 2021.
- [9] Manu Hietaniemi, Ulla Elsilä, Perttu Laurinen, and Juha Röning. Defect prediction in hot strip rolling using ann and svm. volume 173, pages 44–51, 01 2008.
- [10] Daniel Lieber, Marco Stolpe, Benedikt Konrad, Jochen Deuse, and Katharina Morik. Quality prediction in interlinked manufacturing processes based on supervised and unsupervised machine learning. *Procedia CIRP*, 7:193–198, 2013. Forty Sixth CIRP Conference on Manufacturing Systems 2013.
- [11] Janne Takalo-Mattila, Mikko Heiskanen, Vesa Kyllönen, Leena Määttä, and Agne Bogdanoff. Explainable steel quality prediction system based on gradient boosting decision trees. *IEEE Access*, 10:68099–68110, 2022.
- [12] José Alberto Gallardo Arancibia. Metodología para la definición de requisitos en proyectos de data mining. 2009.
- [13] Hadley Wickham, Mara Averick, Jennifer Bryan, Winston Chang, Lucy D’Agostino McGowan, Romain François, Garrett Grommund, Alex Hayes, Lionel Henry, Jim Hester, Max Kuhn, Thomas Lin Pedersen, Evan Miller, Stephan Milton Bache, Kirill Müller, Jeroen Ooms, David Robinson, Dana Paige Seidel, Vitalie Spinu, Kohske Takahashi, Davis Vaughan, Claus Wilke, Kara Woo, and Hiroaki Yutani. Welcome to the tidyverse. *Journal of Open Source Software*, 4(43):1686, 2019.
- [14] Michel Lang, Martin Binder, Jakob Richter, Patrick Schratz, Florian Pfisterer, Stefan Coors, Quay Au, Giuseppe Casalicchio, Lars Kotthoff, and Bernd Bischl. mlr3: A modern object-oriented machine learning framework in R. *Journal of Open Source Software*, dec 2019.
- [15] Marvin N. Wright and Andreas Ziegler. ranger: A fast implementation of random forests for high dimensional data in C++ and R. *Journal of Statistical Software*, 77(1):1–17, 2017.
- [16] Terry Therneau and Beth Atkinson. *rpart: Recursive Partitioning and Regression Trees*, 2019. R package version 4.1-15.
- [17] Tianqi Chen and Carlos Guestrin. XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, KDD ’16*, pages 785–794, New York, NY, USA, 2016. ACM.
- [18] Tianqi Chen, Tong He, Michael Benesty, Vadim Khotilovich, Yuan Tang, Hyunsu Cho, Kailong Chen, Rory Mitchell, Ignacio Cano, Tianyi Zhou, Mu Li, Junyuan Xie, Min Lin, Yifeng Geng, Yutian Li, and Jiaming Yuan. *xgboost: Extreme Gradient Boosting*, 2022. R package version 1.6.0.1.
- [19] Jerome Friedman, Trevor Hastie, and Robert Tibshirani. Regularization paths for generalized linear models via coordinate descent. *Journal of Statistical Software*, 33(1):1–22, 2010.
- [20] Klaus Schliep and Klaus Hechenbichler. *kknn: Weighted k-Nearest Neighbors*, 2016. R package version 1.3.1.
- [21] Evgenia Dimitriadou, Kurt Hornik, Friedrich Leisch, David Meyer, and Andreas Weingessel. *E1071: Misc Functions of the Department of Statistics (E1071), TU Wien*, volume 1. 11 2009.
- [22] Przemyslaw Biecek. Dalex: Explainers for complex predictive models in r. *Journal of Machine Learning Research*, 19(84):1–5, 2018.