
MACHINE LEARNING EN LA INDUSTRIA: EL CASO DE LA SIDERURGIA

ANA GONZÁLEZ-MARCOS

FERNANDO ALBA-ELÍAS

Universidad de La Rioja

En general, los procesos industriales actuales se caracterizan por poseer una elevada complejidad. Tanto es así, que muchos de ellos, a pesar de ser tradicionalmente utilizados, siguen sin comprenderse por completo. Uno de los principales problemas reside en que la naturaleza de las relaciones entre las entradas y salidas de los mismos es altamente no

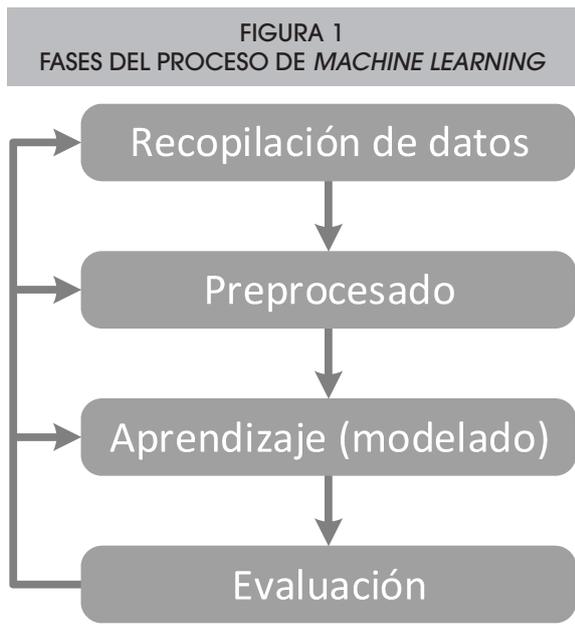
lineal, lo que limita la obtención de modelos analíticos basados en ecuaciones explícitas que definan su comportamiento. Afortunadamente, en la actualidad, existen otros enfoques que permiten abordar este problema, como la obtención de modelos basados en datos, dada la gran cantidad de información que se almacena hoy en día de los procesos industriales.

En este contexto, el *machine learning* o aprendizaje automático, una rama de la inteligencia artificial cuyo objetivo es descubrir patrones automáticamente a partir de un conjunto de datos, está marcando tendencias en este ámbito, ya que con el análisis de los grandes volúmenes de datos procedentes de procesos industriales es posible generar información muy valiosa acerca del comportamiento de dichos procesos, reduciendo la incertidumbre y ayudando en la toma de decisiones.

El campo de aplicación del *machine learning* es muy amplio, pudiéndose encontrar múltiples ejemplos relativos a distintos procesos industriales, los cuales abarcan desde la predicción de variables de proceso (Hatami *et al.*, 2016; D. Liu, Yuan, & Liao, 2009; Luo, Yan,

Hu, Zhou, & Pang, 2015; Valente, Mendonça, Pereira, & Felix, 2014; ZareNezhad & Aminian, 2010), que constituye el área de aplicación más dominante, hasta la monitorización y detección de fallos (Botre, Mansouri, Karim, Nounou, & Nounou, 2017; Van Impe & Gins, 2015; Wang, Feng, & Fan, 2015), pasando por la planificación de procesos (Akyol & Bayhan, 2007; Allahverdi, 2016; Z. Liu, Zhang, & Li, 2014), entre otros.

Uno de los sectores industriales en los que cada vez es más habitual el empleo de técnicas de *machine learning* es la siderurgia. A pesar de ser un sector «maduro» en términos tecnológicos, se encuentra en permanente desarrollo con el objetivo de adaptarse a los requerimientos de la demanda y las exigencias de la competencia. En la industria siderúrgica se ha invertido mucho esfuerzo en identificar las relaciones existentes entre las condiciones de operación y la calidad del producto final. Sin embargo, algunos problemas siguen sin resolverse, siendo la calidad de los productos muy dependiente de la experiencia e intuición de los operadores (Kano & Nakagawa, 2008). Por ello, se considera que las aproximaciones basadas en el análisis de datos de proceso pueden aportar soluciones.



Fuente: Elaboración propia

El presente trabajo tiene por objetivo exponer, a través de casos aplicados a la industria siderúrgica, el potencial de la aplicación de técnicas de *machine learning* en la solución a problemas reales.

EL PROCESO DE MACHINE LEARNING

El *machine learning* es un proceso de inducción de conocimiento, ya que permite obtener, por generalización, un enunciado general a partir de información no estructurada en forma de ejemplos o casos particulares. Teniendo en cuenta, por tanto, que es un proceso basado en el análisis de datos con el fin de aprender y aplicar el conocimiento adquirido en otros conjuntos de datos, el proceso a seguir podría dividirse en fases que se detallan a continuación (Figura 1).

Recopilación de datos

Una vez establecido el problema que se desea resolver mediante el empleo de técnicas de *machine learning*, el primer paso consiste en recopilar la mayor cantidad de datos posible sobre el proceso en cuestión. En algunos casos, la diversidad y el tamaño de las fuentes de datos hace que el proceso de recopilación de datos sea una tarea compleja. En cualquier caso, la identificación de los datos más relevantes, así como su disponibilidad, es una tarea que no se puede automatizar y que requiere un conocimiento experto del problema, así como decidir, entre otros aspectos, de qué fuentes se van a obtener los datos, cómo se van a organizar, cómo se van a mantener en el tiempo, con qué nivel de detalle se van a poder extraer, etc.

Preprocesado

Confiar en que el adecuado diseño de una técnica de aprendizaje que actúe sobre los datos «brutos», va

a proporcionar resultados óptimos o, al menos, satisfactorios, supondría aceptar, de entrada, un principio erróneo: que se presenten como se presenten las cosas, con suficiente «potencia de cálculo» es posible extraer su contenido informacional. De hecho, en el caso concreto de datos procedentes de procesos industriales (generalmente capturados por sensores), esta afirmación es todavía más absurda, dadas algunas de las características que presentan:

- Datos ausentes (*missing values*). Los datos ausentes son un mal endémico en las bases de datos de sistemas reales, siendo muy habituales en los procesos industriales donde se producen fallos de muestreo, se introducen mal los datos manuales, se realizan conversiones incorrectas, etc. Muchas técnicas de *machine learning* no son capaces de aprender con la presencia de datos ausentes, por lo que es necesario analizarlos y tratarlos para solucionar este problema.
- Datos espurios (*outliers*). Los espurios son valores atípicos cuya desviación del resto de valores medidos resulta sensiblemente extraña frente al comportamiento general del conjunto. Los espurios pueden originarse por distintas razones, como errores en las mediciones, en la inserción de datos o en la transformación de los mismos, aunque también pueden ser debidos a sucesos inusuales. En los tres primeros casos, sería deseable que los espurios fueran detectados, analizados y eliminados, aunque antes de poder ser eliminados, es conveniente determinar su origen y solamente hacerlo cuando se tiene la certeza de las causas que los generan. En el cuarto, en cambio, pueden ser casos interesantes de analizar, ya que un estudio detallado puede aportar información valiosa sobre el proceso.
- Datos obtenidos con diferentes frecuencias de muestreo. En los procesos industriales es habitual que los sensores trabajen con diferentes frecuencias de muestreo, con lo que es vital sincronizarlos antes de pasar a la etapa de aprendizaje.

El objetivo fundamental de esta fase es facilitar la labor de construir modelos precisos y fiables, corrigiendo errores y extrayendo nuevas características. La etapa de análisis y preparación de los datos es una de las más importantes, y a la que más tiempo se dedica, dentro de todo proceso que pretenda extraer conocimiento, modelar un sistema o evaluarlo. Podría parecer una etapa trivial, pero es una tarea delicada, complicada y clave, ya que el conocimiento adquirido depende de la calidad de la información reflejada por el conjunto de datos empleado en la fase de aprendizaje.

Aprendizaje (modelado)

Mientras que las fases previas básicamente preparan los datos para el aprendizaje, la posible solución al problema se concreta en esta etapa. Dicha solución suele tener forma de modelo predictivo, a partir del cual se pretenden responder preguntas sobre datos futuros o

nuevos, como, por ejemplo, cuál es la temperatura idónea de un horno para calentar un producto correctamente, o cuántos productos saldrán con buena calidad bajo unas condiciones de fabricación determinadas.

Existen distintos tipos de algoritmos que pueden emplearse en el proceso de aprendizaje, si bien, de forma general, se distinguen dos enfoques principales:

- Aprendizaje supervisado. El proceso de aprendizaje está guiado por el conocimiento existente de la variable a modelar. Es decir, este tipo de aprendizaje requiere un conjunto de datos que contenga información del atributo objetivo (salidas) para cada uno de los ejemplos empleados en el entrenamiento del modelo (entradas).
- Aprendizaje no supervisado. Este aprendizaje se emplea, precisamente, cuando no existe (o no se requiere) un conjunto de datos con salidas definidas. En este caso, el objetivo es sacar conclusiones a partir de conjuntos de datos, sin conocimientos a priori, es decir, descubrir patrones, relaciones o tendencias presentes en los datos.

Cabe señalar que, junto con la solución, durante el proceso de *machine learning* se pueden generar nuevas percepciones, ideas y modelos secundarios, los cuales también son importantes con respecto al problema a resolver. En la práctica, tal como se puede observar en la Figura 1, es un proceso altamente dinámico e iterativo, ya que cualquier fase puede suscitar preguntas o ideas que necesitan ser investigadas o implementadas en una fase previa.

Evaluación

Antes de desarrollar la solución, es necesario evaluarla desde el punto de vista del problema original, para determinar si la solución encontrada es lo suficientemente buena como para ser desarrollada.

En el caso de que se tenga información de la variable a modelar (aprendizaje supervisado), el proceso de evaluación pasa por medir el error cometido en las predicciones realizadas por el modelo. Esta evaluación puede llevarse a cabo de diferentes maneras, siendo las siguientes, las más habituales:

- Evaluación mediante un conjunto de test. El conjunto de datos se divide en dos subconjuntos independientes: el de entrenamiento, usado únicamente en la fase de aprendizaje, y el de test, usado únicamente para estimar el error. El inconveniente (en ocasiones muy serio) de este estimador es que se reduce el tamaño efectivo del conjunto de aprendizaje.
- Evaluación mediante validación cruzada (*cross-validation*). En este caso, el conjunto de datos se divide en k subconjuntos disjuntos de similar tamaño (*k-fold cross validation*), de tal modo que, en cada iteración se construirá y evaluará un modelo, usando la unión de $k-1$ subconjuntos

para el aprendizaje y el restante como test. Al final, obteniendo la media aritmética de los ratios de error obtenidos se consigue el ratio de error para la muestra final.

ALGUNAS TÉCNICAS ÚTILES PARA MACHINE LEARNING

Entre las técnicas de *machine learning* más utilizadas en el modelado de procesos industriales se encuentran las redes neuronales, las máquinas de vectores soporte, los árboles de decisión o los *random forest*. Es importante señalar, no obstante, que ningún modelo o algoritmo puede o debe ser usado de modo exclusivo y que no existe el «mejor» modelo o algoritmo para un problema dado, ya que la propia naturaleza de los datos afectará a la elección de los modelos. De este modo, antes de seleccionar el algoritmo más adecuado para cada caso, es fundamental evaluar diferentes opciones (Ordieres-Meré, Martínez-De-Pisón-Ascacibar, González-Marcos, & Ortiz-Marcos, 2010).

Redes neuronales

Las redes neuronales, también llamadas «redes de neuronas artificiales» (*Artificial Neural Networks*, ANN), tratan de emular las características del cerebro para conseguir su sofisticada capacidad de procesamiento de información. De este modo, una red neuronal es un sistema de neuronas interconectadas que colaboran entre sí para producir un estímulo de salida. Representan, así, una forma especial de procesamiento de la información: paralela y distribuida (Haykin, 2009).

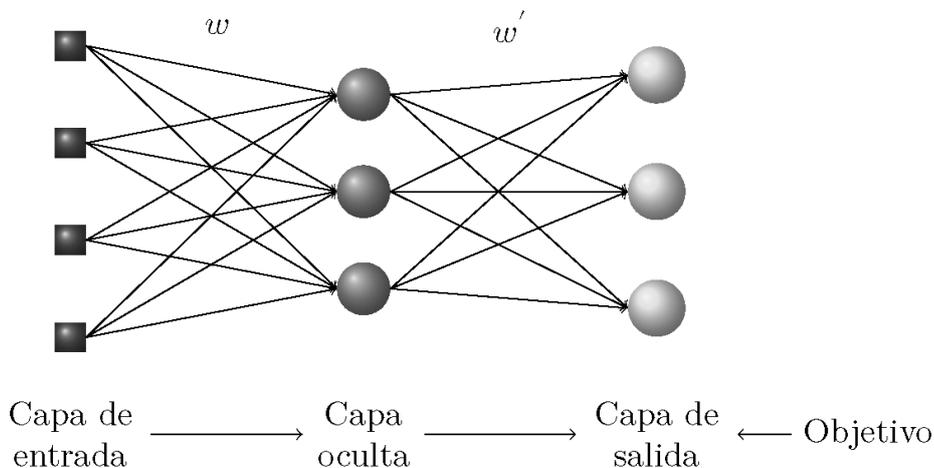
Con las redes neuronales es posible llevar a cabo tanto aprendizaje supervisado (representar relaciones complejas entre variables de entrada y salida) como no supervisado (clasificar conjuntos de datos para los que no se conoce a priori ningún tipo de organización).

En el modelado de procesos, una de las arquitecturas de redes más adecuada es la llamada red perceptrón multicapa (*MultiLayer Perceptron*, MLP) (Figura 2), por ser considerada un aproximador universal de funciones (Hornik, K., Stinchcombe, M. White, 1989). Más concretamente, una red MLP conteniendo al menos una capa oculta con suficientes unidades no lineales, puede aprender cualquier tipo de función o relación continua entre un grupo de variables de entrada y salida.

Máquinas de vectores soporte

Las máquinas de vectores soporte (*Support Vector Machines*, SVM) son modelos de aprendizaje supervisado basados en la teoría de aprendizaje estadístico. La idea básica en las SVM es aplicar un método lineal a los datos en un espacio de características de dimensión alta, el cual está relacionado de forma no lineal con el espacio de entradas. Es decir, el aprendizaje se consigue mediante una transformación no lineal del espacio de entradas en un espacio de características de dimensionalidad mucho mayor, donde sí es posible separar linealmente los ejemplos de entrenamiento

FIGURA 2
ESQUEMA DE UNA RED PERCEPTRÓN MULTICAPA CON UNA CAPA OCULTA



Fuente: Elaboración propia

(Figura 3). Esta transformación se realiza mediante un conjunto de funciones matemáticas conocidas como funciones núcleo (*kernel functions*).

Árboles de decisión

Los árboles de decisión son un método de aprendizaje inductivo supervisado ampliamente utilizado y popular. Un árbol de decisión aproxima funciones que toman valores discretos y se representa en forma de árbol (estructura jerárquica), donde cada nodo puede ser un «nodo hoja» o un «nodo de decisión». Mientras que un nodo hoja se refiere a una decisión (predicción), un nodo de decisión contiene una pregunta sobre una variable concreta y despliega una rama para cada posible respuesta (figura 4). Es decir, un árbol de decisión está compuesto por un conjunto de condiciones organizadas en una estructura jerárquica, de tal manera que la decisión final a tomar se puede determinar siguiendo las condiciones que se cumplen desde la raíz del árbol, hasta alguna de sus hojas. El aprendizaje en los árboles de decisión está ligado a la partición de los datos en grupos mediante un conjunto jerarquizados de condiciones excluyentes y exhaustivas.

El atractivo de esta técnica, a diferencia de otras, es que representa reglas del tipo «si-entonces» que son fáciles de interpretar y muy útiles para la toma de decisiones.

Random forest

Random forest es una técnica de agregación propuesta por (Breiman, 2001) y considerada como una de las herramientas de propósito general más precisas. Se basa en la realización de múltiples árboles de decisión sobre muestras de un conjunto de datos generadas mediante muestreo aleatorio con reposición. Su principio básico consiste en incorporar aleatoriedad en la construcción de cada árbol individual para mejorar la

precisión del modelo agregado. La decisión final del modelo se obtiene evaluando cada árbol de modo independiente y usando el voto mayoritario (en problemas de clasificación) o el promedio (en problemas de regresión) como respuesta.

Los *random forest* son rápidos, fáciles de implementar y proporcionan una buena capacidad predictiva incluso cuando hay más variables que observaciones y cuando la mayoría de las variables son ruido.

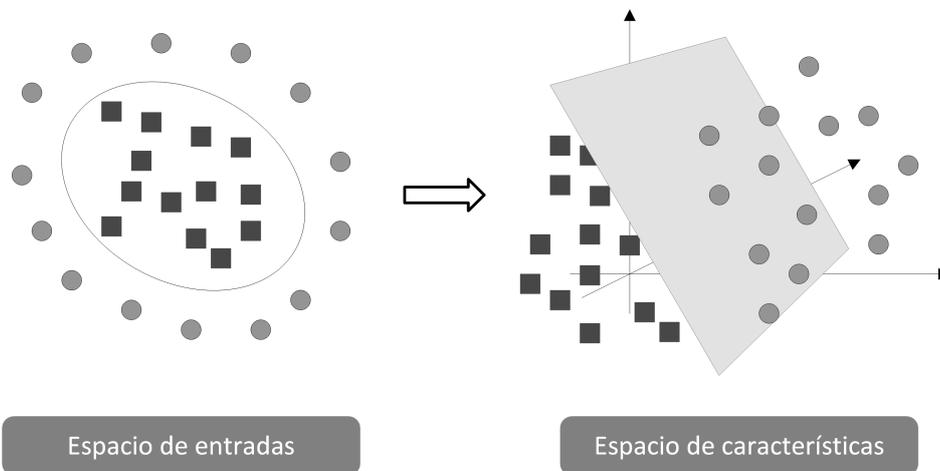
CASOS DE APLICACIÓN EN LA SIDERURGIA

El acero galvanizado es un producto con una fuerte demanda en sectores como la automoción, la fabricación de electrodomésticos y la construcción, por sus propiedades anticorrosión. Dadas las crecientes exigencias demandadas por parte de los clientes, las empresas plantean una estrategia de mejora continua en cada una de las fases de que consta el proceso de galvanizado.

La calidad del producto galvanizado se puede focalizar en dos aspectos fundamentales. Por un lado, en cuanto a las propiedades del acero, su calidad depende fundamentalmente de la composición química del acero, el proceso de fundición, los procesos de laminación y el tratamiento térmico que se realiza a la banda antes de su paso por la inmersión del baño de zinc líquido. Por otro lado, en relación a las características anticorrosivas, la calidad del producto viene marcada por el espesor del recubrimiento de zinc y por la uniformidad del mismo, y depende básicamente de la preparación superficial del metal base, el control de la temperatura de recubrimiento y homogeneización de la misma, la composición del baño, el control de las cuchillas de aire y la velocidad de la banda.

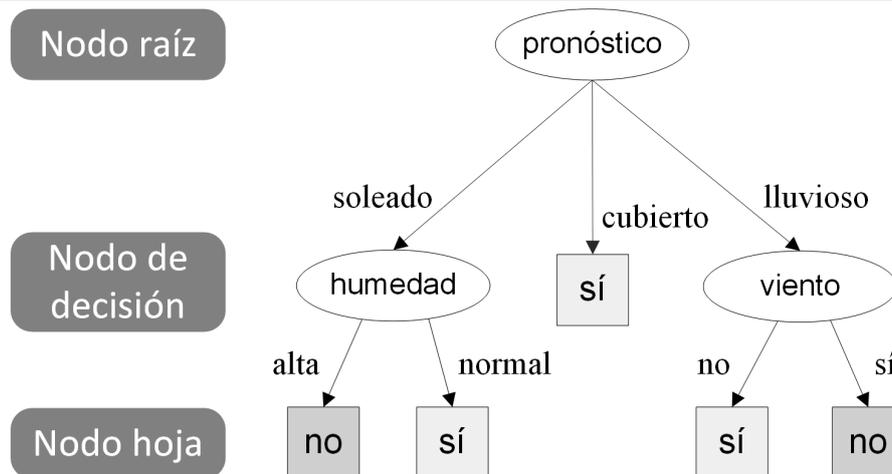
A continuación, se presentan algunos ejemplos de aplicación de técnicas de *machine learning* para solucio-

FIGURA 3
EJEMPLO DE TRANSFORMACIÓN DEL ESPACIO DE ENTRADAS EN UN ESPACIO DE CARACTERÍSTICAS DONDE EL CONJUNTO DE DATOS ES LINEALMENTE SEPARABLE



Fuente: Elaboración propia

FIGURA 4
EJEMPLO DE ESTRUCTURA DE UN ÁRBOL DE DECISIÓN



Fuente: Elaboración propia

nar diferentes problemas en distintos procesos de una línea de acero galvanizado.

Estimación de la capacidad de limpieza de la línea de decapado

Las bobinas de acero se obtienen mediante la transformación de productos semiacabados (planchones y palanquillas) en el proceso de laminación en caliente. En este proceso, los productos semiacabados se calientan primero en hornos, donde son llevados a temperaturas de laminación. Este tratamiento metalúrgico permite, por medio de la oxidación generada, remover pequeños defectos superficiales y ablandar el acero para facilitar los procesos de trefilado y conformado. A continuación, el formato se transforma

mecánicamente hasta la forma y tamaño deseados al pasar a través de los cilindros de la unidad de laminación, que reducen la sección transversal del acero mediante la presión ejercida por éstos.

Uno de los problemas que pueden presentarse en la laminación en caliente es la aparición de defectos superficiales en forma de incrustaciones de óxidos formadas durante los procesos de recalentamiento y laminado. Con el fin de eliminar estos óxidos, así como otras impurezas, las bobinas de acero pasan por una línea de decapado que se encarga de limpiar su superficie empleando ácido clorhídrico. Tras esta limpieza, las bobinas de acero se someten a distintos procesos de acabado, según el destino final del producto. Sin embargo, en ocasiones, el rendimiento de los procedimientos de lim-

pieza no es adecuado, con lo que no todas las bobinas fabricadas cumplen los criterios de calidad superficial.

Una propuesta planteada en (González-Marcos, Ordieres-Meré, Alba-Elías, Martínez-de-Pisón, & Castejón-Limas, 2014) para solucionar este problema, consiste en la creación de modelos basados en SVM con los que predecir la capacidad de limpieza de la línea de decapado. En este caso, el proceso de aprendizaje se basa en la información proporcionada por los sistemas automáticos de inspección de superficies, junto con los parámetros de procesamiento de la laminación en caliente y de la línea de decapado. Dada la bondad del modelo generado, con un error relativo en torno al 6%, es posible analizar la sensibilidad en el grado de limpieza alcanzado en términos de variación de velocidad (que se relaciona directamente con la productividad de las instalaciones) para evaluar diferentes estrategias de proceso. Así, por ejemplo, en el caso analizado, se observó que era posible aumentar la velocidad un 26% para el 96% de las bobinas, ya que solo el 4% de ellas tendrían defectos superficiales tras la línea de decapado.

El impacto económico de la mejora proporcionada por un sistema de este tipo puede ser valorado en varios millones de dólares estadounidenses al año, ya que permite incrementar la velocidad de la línea sin un aumento en los defectos superficiales, así como degradar las bobinas de acero en una etapa temprana, evitando procesos adicionales como recubrimientos, etc.

Modelado de velocidad de la banda de acero en el horno de recocido ↓

En el galvanizado por inmersión en caliente, un proceso clave para obtener las propiedades deseadas, así como una buena adherencia del recubrimiento de zinc, es el tratamiento térmico al que se someten las bandas de acero antes de su inmersión en el pote de zinc. Actualmente, la temperatura de la banda en el horno de proceso se consigue cambiando únicamente la temperatura de consigna del horno. Ya en (Martínez-de-Pisón, 2003), se propone un control más eficiente de la temperatura, para asegurar que la temperatura real de la banda a la salida de la zona de calentamiento del horno se aproxime a la deseada, si, además de la temperatura, se regula la velocidad de la banda dentro del horno. En este sentido, y como una mejora más en el control del ciclo de recocido, en (Pernía-Espinoza, Castejón-Limas, González-Marcos, & Lobato-Rubio, 2005) se propone un modelo robusto de la velocidad de la banda dentro del horno de recocido, con el que conseguir temperaturas de salida de la banda de acero más adecuadas.

Dicho modelo de velocidad fue creado mediante redes neuronales. En primer lugar, y durante la fase de preparación de los datos, se constató que el conjunto de datos utilizado contenía un pequeño porcentaje de muestras, un 3%, con valores de velocidad fuera del rango normal de funcionamiento de la línea. Estos valores eran debidos a fenómenos transitorios que pue-

den darse en la línea, tales como la soldadura de una bobina o la incorporación de una bobina atípica (con dimensiones inusuales). Ante esta situación, en la que no es extraño que disminuya la velocidad de forma brusca, era conveniente que el modelo neuronal aprendiera la relación entre la temperatura y la velocidad en estos casos. Sin embargo, para que su presencia en el entrenamiento no afectara negativamente al modelo, resultaba adecuada la utilización de algoritmos robustos.

En el entrenamiento se emplearon redes MLP con siete entradas, quince neuronas en la capa oculta y una salida. Una vez finalizado el aprendizaje, se obtuvo un 4,43% de error medio relativo con los patrones de test, lo que reflejaba el buen comportamiento del modelo neuronal desarrollado y la posibilidad de controlar de un modo más eficiente la temperatura de las bobinas a la salida del horno, consiguiendo, de esta manera, temperaturas más adecuadas que las obtenidas al cambiar únicamente la temperatura de consigna del horno.

Además, este modelo podría ser utilizado para establecer estrategias de funcionamiento de la línea, para establecer el orden en el que procesar las bobinas, previsualizar las condiciones de velocidad de la línea en condiciones transitorias, etc.

Reducción de problemas de adherencia del recubrimiento de zinc ↓

Las experiencias presentadas hasta el momento, se centran sobre todo en el modelado de sistemas, el cual constituye una de las aplicaciones más interesantes del proceso de *machine learning* en el ámbito industrial. Sin embargo, estas técnicas también pueden emplearse en el desarrollo de otras aplicaciones. A continuación, se expone el trabajo desarrollado en (Martínez-de-Pisón, Ordieres, Pernía, Alba, & Torre, 2007), donde se plantea la identificación de las causas que originan las pérdidas de calidad en el recubrimiento de zinc de nuevos aceros de la línea de galvanizado objeto de estudio, mediante el empleo de árboles de decisión.

La calidad, espesor y uniformidad del recubrimiento de zinc se ven influenciados por múltiples factores (preparación superficial del metal base, control de la temperatura de recubrimiento y homogeneización de la misma, composición del baño, control de las cuchillas de aire y la velocidad de la banda), siendo el ajuste de todos los parámetros para cada tipo de bobina una tarea muy laboriosa. Con el fin de facilitar la identificación de las condiciones que potenciaban los problemas de adherencia de la bobinas, en (Martínez-de-Pisón *et al.*, 2007) se propone un proceso iterativo de creación y análisis de árboles de decisión.

A lo largo del estudio realizado, se obtuvieron resultados que coincidían con el conocimiento propio de los técnicos de la planta: las variaciones en la velocidad de la banda y la temperatura del baño de zinc fueron las primeras variables que los árboles de decisión detectaron como más 'influyentes' a la hora de explicar

las causas de fallos de adherencia. Sin embargo, con la metodología utilizada, se aportó un valor añadido, ya que además de confirmar la influencia de estas variables en los problemas de adherencia, se establecieron los valores que mejor 'discriminaban' las bobinas en las que aparecieron 'irregularidades' de adherencia del recubrimiento de zinc frente a las que no tuvieron. Además, se detectaron relaciones entre variables, como, por ejemplo, entre la velocidad de la banda, la temperatura del pote de zinc y la temperatura del horno, que podían resultar muy interesantes para comprender mejor el funcionamiento del proceso.

Estimación de las propiedades mecánicas de las bobinas de acero galvanizado ↓

Las propiedades mecánicas de las bobinas de acero galvanizado (límite elástico, resistencia a la rotura, alargamiento, etc.), no se pueden medir directamente, sino que deben llevarse a cabo ensayos en un laboratorio, empleando métodos destructivos, tras el proceso de galvanizado. En este caso, el problema que se plantea es la necesidad de adoptar un control en lazo abierto, al no ser posible aplicar una estrategia de control clásica.

Las propiedades mecánicas de las bobinas de acero galvanizado pueden verse afectadas a lo largo de todo el proceso de fabricación, desde la obtención del acero (que determina la composición química de la colada) hasta, prácticamente, el momento en el que se convierte en producto acabado (bien en forma de bobinas o de chapas galvanizadas). Por ello, en (González-Marcos, Alba-Elías, Castejón-Limas, Ordieres-Meré, 2011) se propone la creación de modelos basados en redes neuronales capaces de predecir on-line dichas propiedades mecánicas, a partir de los datos procedentes del proceso de fabricación. De esta forma, sería posible una mejora en los sistemas de control actuales, la cual repercutiría en la calidad del producto final, siendo éste uno de los objetivos básicos de todo proceso industrial.

Siguiendo el esquema general del proceso de *machine learning*, en primer lugar, se analizó y preparó el conjunto de datos, como paso previo al modelado, mediante el empleo de técnicas de visualización, de identificación de espurios y de identificación de clases de comportamiento. Tras eliminar los espurios y dividir el conjunto de patrones en las clases detectadas, se procedió a la construcción de los modelos de propiedades mecánicas. Para ello, se utilizaron nuevamente redes MLP con 32 entradas, un número variable de neuronas en la capa oculta y una salida.

De todas las redes entrenadas para cada caso, las mejores ofrecieron resultados bastante buenos, siendo los errores medios relativos de los patrones de test, es decir, de los nunca vistos por la red durante el entrenamiento, no superiores al 4% para casi todas las propiedades mecánicas analizadas, encontrándose dentro de los límites de tolerancia admitidos. Las ventajas de estos modelos son evidentes, si se tiene en cuenta que la medición de estas propiedades supone un coste

económico y temporal: se podrían tomar decisiones adecuadas en tiempo real de una forma más económica.

Cerrojo artificial en el *Skin-Pass* ↓

Un ejemplo de la generación de nuevas percepciones, ideas, etc., que se generan a lo largo del proceso de *machine learning*, lo constituye el desarrollo de un 'cerrojo artificial' para el *skin-pass*, una sección de la línea de acero galvanizado que se utiliza para dotar al material de las características mecánicas y de rugosidad superficial adecuadas.

La idea de crear este cerrojo surgió como consecuencia de los buenos resultados obtenidos en la predicción de las propiedades mecánicas de las bobinas a partir de los datos de proceso. Lo que se pretendía en este caso era buscar una solución a un problema que se presenta esporádicamente, pero cuyas consecuencias pueden llegar a ser graves: el etiquetado incorrecto del grado de acero de una bobina. Para tratar de detectar estos errores, se desarrolló de un 'cerrojo artificial' para el *skin-pass* (González-Marcos, Ordieres-Meré, Pernía-Espinoza, & Torre-Suárez, 2008).

Este 'cerrojo' consiste en un modelo capaz de predecir on-line el alargamiento de las bobinas de acero en el *skin-pass*, a partir de los datos procedentes del proceso de fabricación y de su composición química. De esta forma, una diferencia significativa entre el alargamiento estimado por el modelo y el medido realmente, indicaría que lo que se está procesando es diferente de lo previsto, haciéndose necesario sacar la bobina de la línea para someterla a análisis más exhaustivos.

Una vez más, se aplicó la metodología general de *machine learning*: tras el análisis y preparación inicial de los datos, se entrenaron distintas redes neuronales MLP para obtener los modelos deseados. Los pequeños errores obtenidos en la estimación del alargamiento en el *skin-pass* indicaban la bondad de los modelos, pero no la calidad del cerrojo. Es decir, para poder utilizar los modelos propuestos como detectores de bobinas erróneamente etiquetadas, resultaba imprescindible que fueran capaces, no sólo de estimar correctamente el alargamiento de las bobinas «buenas», sino de obtener alargamientos significativamente diferentes a los reales cuando la composición química era incorrecta. Con objeto de comprobar, sobre la línea de producción, la utilidad de los modelos desarrollados para resolver el problema planteado, se analizó su comportamiento con bobinas cuya composición se sabía de antemano que era incorrecta. De esta forma, fue posible contrastar la validez del cerrojo, así como establecer el umbral entre bobinas correctamente secuenciadas y las que provienen de una inversión de secuencia.

CONCLUSIONES ↓

En este trabajo se han presentado diferentes tipos de problemas reales en el sector siderúrgico que pueden beneficiarse del empleo de técnicas de

machine learning, como ejemplos prácticos de aplicación de estas técnicas en procesos industriales.

En primer lugar, se aborda el problema de la calidad superficial de las bobinas de acero tras el proceso de laminación en caliente. Como una posible solución a la incertidumbre que presenta el proceso de limpieza en la línea de decapado, se propone la creación de un modelo basado en SVM con el que predecir la capacidad de limpieza de dicha línea.

Otro problema abordado es el de la adherencia del recubrimiento de zinc y, por tanto, las características anticorrosivas de las bobinas. Para lograr una buena adherencia, es clave el tratamiento térmico al que se someten las bandas de acero antes de su inmersión en el pote de zinc. En este sentido, se plantea la creación de un modelo neuronal robusto de la velocidad de la banda dentro del horno de recocido, con el que conseguir temperaturas de salida de la de la banda de acero más adecuadas. También se propone un estudio mediante árboles de decisión, para determinar qué variables tienen mayor influencia en la calidad del recubrimiento y poder, de esta manera, establecer reglas de aplicación en la reducción del número de bobinas con problemas de adherencia.

Posteriormente, se trata el problema de las propiedades mecánicas, ya que no es posible medirlas directamente, sino que deben llevarse a cabo ensayos en un laboratorio, empleando métodos destructivos, tras el proceso de galvanizado. Para conocer en tiempo real las propiedades mecánicas de las bobinas de acero galvanizado, se propone la creación de un modelo basado en redes neuronales, capaz de predecir dichas propiedades mecánicas, a partir de los datos procedentes del proceso de fabricación.

Por último, se plantea un «cerrojo artificial» para el *skin-pass*, una sección de la línea de acero galvanizado que se utiliza para dotar al material de las características mecánicas y de rugosidad superficial adecuadas, para tratar de resolver un problema de baja ocurrencia, pero de graves consecuencias: el etiquetado incorrecto del grado de acero de una bobina.

A través de estos ejemplos se ha pretendido mostrar que el *machine learning* abre un mundo de oportunidades para muchos procesos industriales. Afortunadamente, la industria está reconociendo los beneficios que el empleo de estas técnicas puede reportar. A modo de ejemplo, el sector siderúrgico ya ha aprovechado algunas de estas técnicas, aplicándolas con éxito en problemas complejos.

BIBLIOGRAFÍA

AKYOL, D. E., & BAYHAN, G. M. (2007). «A review on evolution of production scheduling with neural networks». *Com-*

puters & Industrial Engineering, 53(1), 95–122. <https://doi.org/10.1016/j.cie.2007.04.006>

ALLAVERDI, A. (2016). «A survey of scheduling problems with no-wait in process». *European Journal of Operational Research*, 255(3), 665–686. <https://doi.org/10.1016/j.ejor.2016.05.036>

BOTRE, C., MANSOURI, M., KARIM, M. N., NOUNOU, H., & NOUNOU, M. (2017). «Multiscale PLS-based GLRT for fault detection of chemical processes». *Journal of Loss Prevention in the Process Industries*, 46, 143–153. <https://doi.org/10.1016/j.jlp.2017.01.008>

BREIMAN, L. (2001). «Random Forests». *European Journal of Mathematics*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>

GONZÁLEZ-MARCOS, Ana, ALBA-ELÍAS, Fernando, CASTEJÓN-LIMAS, Manuel, ORDIERES-MERÉ, J. (2011). «Development of neural network-based models to predict mechanical properties of hot dip galvanised steel coils». *International Journal of Data Mining, Modelling and Management*, 3(4), 389–405. <https://doi.org/10.1504/IJDMMM.2011.042936>

GONZÁLEZ-MARCOS, A., ORDIERES-MERÉ, J., ALBA-ELÍAS, F., MARTÍNEZ-DE-PISÓN, F. J., & CASTEJÓN-LIMAS, M. (2014). «Advanced predictive system using artificial intelligence for cleaning of steel coils». *Ironmaking & Steelmaking*, 41(4), 262–269. <https://doi.org/10.1179/1743281213Y.0000000130>

GONZÁLEZ-MARCOS, A., ORDIERES-MERÉ, J. B., PERNÍA-ESPINOZA, A. V., & TORRE-SUÁREZ, V. (2008). «Development of an artificial lock for the skin-pass section in a hot dip galvanising line». *Revista de Metalurgia (Madrid)*, 44(1), 29–38. Retrieved from <http://www.scopus.com/scopus/inward/record.url?eid=2-s2.0-41749083028&partnerID=40&rel=R8.0.0>

HATAMI, S., GHADERI-ARDAKANI, A., NIKNEJAD-KHOMAMI, M., KARIMI-MALEKABADI, F., RASAEI, M. R., & MOHAMMADI, A. H. (2016). «On the prediction of CO₂ corrosion in petroleum industry». *The Journal of Supercritical Fluids*, 117, 108–112. <https://doi.org/10.1016/j.supflu.2016.05.047>

HAYKIN, S. (2009). *Neural networks and learning machines* (3rd Ed.). Financial Times Prentice Hall.

HORNİK, K., STINCHCOMBE, M. WHITE, H. (1989). «Multilayer feedforward networks are universal approximators». *Neural Networks*, 2(5), 359–366.

KANO, M., & NAKAGAWA, Y. (2008). «Data-based process monitoring, process control, and quality improvement: Recent developments and applications in steel industry». *Computers and Chemical Engineering*, 32(1–2), 12–24. <https://doi.org/10.1016/j.compchemeng.2007.07.005>

LIU, D., YUAN, Y., & LIAO, S. (2009). «Artificial neural network vs. nonlinear regression for gold content estimation in pyrometallurgy». *Expert Systems with Applications*, 36(7), 10397–10400. <https://doi.org/10.1016/j.eswa.2009.01.038>

LIU, Z., ZHANG, Y., & LI, M. (2014). Integrated scheduling of ready-mixed concrete production and delivery. *Automation in Construction*, 48, 31–43. <https://doi.org/10.1016/j.autcon.2014.08.004>

LUO, M., YAN, H. C., HU, B., ZHOU, J. H., & PANG, C. K. (2015). «A data-driven two-stage maintenance framework for degradation prediction in semiconductor manufacturing industries». *Computers and Industrial Engineering*, 85, 414–422. <https://doi.org/10.1016/j.cie.2015.04.008>

MARTÍNEZ-DE-PISÓN, F. J. (2003). *Optimización mediante técnicas de minería de datos del ciclo de recocido de una*

línea de galvanizado. Tesis doctoral. University of La Rioja, Spain.

MARTÍNEZ-DE-PISÓN, F. J., ORDIERES, J., PERNÍA, A., ALBA, F., & TORRE, V. (2007). Reducción de problemas de adherencia en procesos de galvanizado mediante técnicas de minería de datos, *43*(5), 325–336.

ORDIERES-MERÉ, J., MARTÍNEZ-DE-PISÓN-ASCACIBAR, F. J., GONZÁLEZ-MARCOS, A., & ORTIZ-MARCOS, I. (2010). «Comparison of models created for the prediction of the mechanical properties of galvanized steel coils». *Journal of Intelligent Manufacturing*, *21*(4), 403–421. <https://doi.org/10.1007/s10845-008-0189-y>

PERNÍA-ESPINOZA, A., CASTEJÓN-LIMAS, M., GONZÁLEZ-MARCOS, A., & LOBATO-RUBIO, V. (2005). «Steel annealing furnace robust neural network model». *Iron-making and Steelmaking*, *32*(5), 418–426. Retrieved from <http://www.scopus.com/scopus/inward/record.url?eid=2-s2.0-27644466573&partnerID=40&rel=R7.0.0>

VALENTE, G. F. S., MENDONÇA, R. C. S., PEREIRA, J. A. M., & FELIX, L. B. (2014). «Artificial neural network prediction of

chemical oxygen demand in dairy industry effluent treated by electrocoagulation». *Separation and Purification Technology*, *132*, 627–633. <https://doi.org/10.1016/j.seppur.2014.05.053>

VAN IMPE, J., & GINS, G. (2015). «An extensive reference dataset for fault detection and identification in batch processes». *Chemometrics and Intelligent Laboratory Systems*, *148*, 20–31. <https://doi.org/10.1016/j.chemolab.2015.08.019>

WANG, X., FENG, H., & FAN, Y. (2015). «Fault detection and classification for complex processes using semi-supervised learning algorithm». *Chemometrics and Intelligent Laboratory Systems*, *149*, 24–32. <https://doi.org/10.1016/j.chemolab.2015.10.019>

ZARENEZHAD, B., & AMINIAN, A. (2010). «A multi-layer feed forward neural network model for accurate prediction of flue gas sulfuric acid dew points in process industries». *Applied Thermal Engineering*, *30*(6–7), 692–696. <https://doi.org/10.1016/j.applthermaleng.2009.11.017>