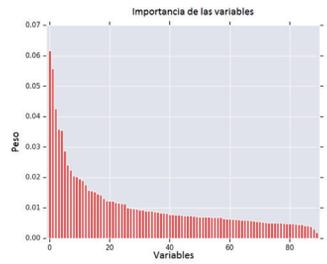
Motor de análisis basado en técnicas de aprendizaje automático para la identificación de variables críticas en procesos multietapa: aplicación a la instalación de remaches ciegos



Machine learning-based analysis engine to identify critical variables in multi-stage processes: application to the installation of blind fasteners

Maialen Murua-Etxeberria[1], Fernando Veiga-Suárez[1], Juan-Antonio Ortega-Lalmolda[2], Mariluz Penalva-Oscoz[1] y Alberto Diez-Olivan[1]

[1] TECNALIA. Basque Research and Technology Alliance (BRTA). Paseo Mikeletegi, 7 – 20009 San Sebastián (España).
[2] TECNALIA. Basque Research and Technology Alliance (BRTA). Avda. de Ranillas , 1 planta 1ª Oficinas C y D - 50018 Zaragoza (España).

DOI: http://dx.doi.org/10.6036/9403 | Recibido: 12/09/2019 • Inicio Evaluación: 16/09/2019 • Aceptado: 06/02/2020

ABSTRACT

- Quality control in manufacturing is a recurrent topic as the ultimate goals are to produce high quality products with less cost. Mostly, the problems related to manufacturing processes are addressed focusing on the process itself putting aside other operations that belong to the part's history. This research work presents a Machine Learning-based analysis engine for non-expert users which identifies relationships among variables throughout the manufacturing line. The developed tool was used to analyze the installation of blind fasteners in aeronautical structures, with the aim of identifying critical variables for the quality of the installed fastener, throughout the fastening and drilling stages. The results provide evidence that drilling stage affects to the fastening, especially to the formed head's diameter. Also, the most critical phase in fastening, which is when the plastic deformation occurs, was identified. The results also revealed that the chosen process parameters, thickness of the plate and the fastener type influence on the quality of the installed fastener.
- **Keywords:** Analysis Engine, Multi-Stage Processes, Critical Variables, Machine Learning, Blind Fasteners.

RESUMEN

El control de calidad en la fabricación es un tema recurrente, ya que los objetivos finales son producir productos de alta calidad a menor costo. Con demasiada frecuencia, los problemas relacionados con los procesos de fabricación se limitan a estudiar el proceso en cuestión, dejando de lado la sucesión de operaciones previas que conforman la historia de la pieza. En este trabajo se presenta un motor de análisis basado en técnicas de Aprendizaje Automático que permite identificar relaciones entre variables de la cadena de procesos asociada a una pieza. La herramienta desarrollada se ha utilizado para analizar la instalación en estructuras aeronáuticas de remaches ciegos con el fin de identificar variables críticas para la calidad de la instalación tanto durante el remachado como en la etapa previa de taladrado. Los resultados demuestran que la etapa de taladrado afecta al remachado, especialmente al diámetro de la cabeza formada. También se ha identificado la fase más crítica del remachado, que es la fase donde ocurre la deformación plástica. Los resultados también revelan que los parámetros de proceso seleccionados como el espesor de la placa y tipo de remache influyen en la calidad final del remache instalado.

Palabras clave: Motor de análisis, proceso multietapa, variables críticas, aprendizaje automático, remaches ciegos.

1. INTRODUCCIÓN

Los avances recientes en la industria manufacturera han disparado la capacidad de adquisición, almacenamiento y procesamiento de los datos. Además, gracias a las sofisticadas técnicas de análisis, las máquinas pueden actuar de manera más eficiente, colaborativa y comunicativa [1]. Hay innumerables investigaciones [2,3,4] que hacen uso de métodos de Inteligencia Artificial para modelar y optimizar los procesos de fabricación. Por lo tanto, hay una gran cantidad de trabajos de investigación respecto a operaciones de mecanizado que utilizan modelos de Aprendizaje Automático para generar conocimiento del proceso y extraer información acerca del rendimiento del proceso basado en los datos adquiridos. Es posible encontrar modelos relativamente simples como Regresión Múltiple o Polinómica [5,6] a otros más sofisticados, tales como las Redes Neuronales [3,4], las Redes Bayesianas [7], [8] los Árboles de Decisión o Máquinas de Vectores de Soporte [9].

Uno de los procesos de fabricación donde se aplican técnicas de Aprendizaje Automático es el mecanizado. La optimización de los parámetros de mecanizado ha sido objeto de diversas investigaciones [10,11] la adecuada optimización del proceso se ha convertido en una tarea desafiante, principalmente porque el mecanizado juega un papel importante en los aspectos económicos de las operaciones de corte de metales. Por ejemplo, en un proceso de torneado, los parámetros de corte, como la velocidad de corte, velocidad de avance y la profundidad de corte deben ser optimizados para lograr el mínimo coste de mecanizado y mínimo tiempo de producción [12]. Sin embargo, para lograr una optimización eficaz, es necesario entender cómo los parámetros de corte influyen en el proceso, y esto puede ser planteado como un problema de predicción.

Algunos autores realizaron un estudio sobre la aplicación de técnicas de *Soft Computing* en el mecanizado para realizar predicciones [13]. Se aplicaron técnicas de *Soft Computing* para procesos de mecanizado, que son preferibles que los modelos físicos, debido a la complejidad y la incertidumbre del proceso de mecanizado. Entre las técnicas analizadas [14], estaban la Lógica Difusa y las Redes Neuronales [15] para hacer predicciones en los procesos

de mecanizado de torneado, fresado, taladrado y rectificado. La predicción fue enfocado a la rugosidad de la superficie, el desgaste de la herramienta, la vida útil de la herramienta, el desgaste de la rueda, fuerza de corte y fuerzas de rectificado y perforación. Entre las técnicas para optimizar los parámetros de la red neuronal estaban los Algoritmos Genéticos [16], [17] el Recocido Simulado, la Optimización de la Colonia de Hormigas [18] y la Optimización por Enjambre de Partículas [19].

Además, hay otros trabajos de investigación que hacen uso de técnicas estadísticas, tales como test estadísticos [10], análisis de correlación o análisis de la varianza (ANOVA) [20] para detectar variables de mayor influencia en los procesos de fabricación. Aunque estos métodos estadísticos ofrecen la oportunidad de interpretar los resultados más fácilmente que los métodos basados en Aprendizaje Automático, hay un aumento en el número de investigaciones [21,22], que se basan en técnicas de Aprendizaje Automático. Los Árboles de Decisión, por ejemplo, ofrecen la oportunidad de saber cómo afecta cada variable de entrada en la variable de salida, mediante la interpretación de las reglas del árbol generado o conociendo los pesos de las variables de entrada en el mismo.

La mayoría de las investigaciones que hacen uso de técnicas Aprendizaje Automático para analizar los datos, se centran en una sola etapa del proceso de fabricación y son menos abundantes los que tienen en cuenta el efecto global de toda la línea de producción [23,24]. Estos trabajos de investigación se centran en el desarrollo de modelos para la generación y propagación de los errores en el tiempo para casos específicos, pero no ofrecen un enfoque generalista a toda la línea del análisis. Además, estos modelos deben ofrecer información acerca de la relación entre las variables, para interpretar lo que está sucediendo en el proceso.

En esta investigación, se ha desarrollado un motor de análisis basado en técnicas de Aprendizaje Automático para usuarios no expertos en el análisis de datos, para detectar variables de proceso críticas en la línea de producción. El análisis puede enfocarse en un proceso particular o examinar los procesos anteriores de la línea. Para ese propósito, se han utilizado los Bosques Aleatorios, que se basan en los Árboles de Decisión, a fin de interpretar la relación generada entre las variables de entrada y la variable de salida.

El proceso de remachado es un proceso complejo que implica varios campos del conocimiento como materiales metálicos, materiales compuestos, mecánica clásica, mecanizado y fabricación, entre otros. Cabe señalar que no es fácil elaborar un modelo predictivo de la calidad del remache, incluyendo el efecto de los parámetros de proceso y el diagrama de la instalación, debido al comportamiento no lineal del mecanismo de remachado. Por esta razón, este problema es adecuado para tratar con técnicas de Aprendizaje Automático y ha sido por eso elegido como caso de estudio. Aunque los remaches ciegos son una interesante solución de unión en la industria aeroespacial debido a sus ventajas para la automatización, la inspección en línea de su instalación todavía no es factible [25]. Hasta la fecha, el proceso de remachado y la etapa previa de taladrado se han analizado y tratado por separado [26, 27]. Analizando las dos etapas consecutivas de manera conjunta, las variables de taladrado que afectan a la instalación de remaches podrían ser identificadas y tomadas en consideración. Este proceso representa un significativo y simple caso de uso para la herramienta desarrollada.

2. MÉTODOS

El motor de análisis pretende detectar las relaciones de dependencia entre las variables de proceso y las variables relacionadas con la calidad de la pieza final para identificar las variables críticas. Para ello, un motor de análisis ha sido creado para usuarios no expertos en el análisis de datos. La principal ventaja que ofrece la herramienta es que no es necesario para usuarios no expertos tener conocimientos de programación. La herramienta es muy intuitiva gracias a su interfaz amigable, donde el usuario configura las variables de entrada y salida, y algunos otros parámetros relacionados con la validación del modelo escribiéndolos o uniendo las flechas de las cajas.

2.1. HERRAMIENTA DESARROLLADA

La herramienta desarrollada ofrece dos diferentes funcionalidades, la generación del modelo y la verificación del modelo. El primero tiene como objetivo el aprendizaje de una función f y la validación de la calidad de esta. También ofrece la oportunidad de conocer las variables más significativas en el modelo para identificar las variables críticas del proceso. La segunda funcionalidad es utilizar un modelo entrenado previamente con los nuevos datos. Dependiendo de la calidad del modelo actual, el usuario puede decidir si el modelo todavía encaja bien, o es necesario generar uno nuevo.

Hay algunas etapas, como el análisis exploratorio de datos, el pre-procesamiento o la limpieza de los datos, que se consideran etapas anteriores al Aprendizaje Automático, que no están incluidas en la herramienta. Hay herramientas específicas para este fin, tales como el *Machine Learning* Studio de Azure o librerías de los lenguajes de programación R y Python.

Para el entrenamiento de los datos en las correspondientes tareas de clasificación y regresión, se utilizan los Bosques Aleatorios [28,29]. Pertenecen a la familia de los algoritmos de *Ensemble Learning* [30] que combina los Árboles de Decisión, con la votación de mayoría (clasificación), o calculando el promedio (regresión). Las siguientes mediciones son utilizadas para realizar la validación del modelo generado: R^2 tanto para la regresión y la clasificación, la precisión en la clasificación y la raíz del error cuadrático medio (RECM) en regresión.

R^2: Mide cuan bien se replican los valores observados, basado en la proporción total de la varianza de los valores explicada por el modelo [31].

Precisión: Proporción de las observaciones correctamente clasificadas por el modelo, frente a todas las observaciones.

Raíz del error cuadrático medio (RECM): Es la desviación estándar de los residuos, los errores de predicción, definida en la ecuación (1).

$$RECM = \sqrt{\frac{\sum_{t=1}^{n}(\hat{y}_t - y_t)^2}{n}} \quad (1) \qquad (1)$$

Donde n es el número de observaciones, y_t el valor real observado y $\hat{y}$ el valor predicho por el modelo.

2.1.1. Integración del motor de análisis

El motor de análisis se ha integrado en una plataforma online desarrollada en colaboración con otros socios del proyecto europeo ForZDM [32]. La plataforma ofrece algoritmos integrados en servicios web REST, permitiendo el uso de otras herramientas, como el acceso a los datos procedentes de distintas fuentes, otros servicios REST o cargar datos directamente a la plataforma. Esta arquitectura ofrece como novedad, la integración de los datos de proceso en tiempo real con el off-line de mediciones de calidad de la pieza final.

Los modelos generados en la etapa de aprendizaje se guardan en el servidor. Así, es posible verificar el modelo con datos

nuevos, siempre que el usuario desee. La plataforma tiene una interfaz de usuario donde cada algoritmo se presenta como una etapa que incluye algunas entradas y salidas. Estas etapas pueden ser conectadas entre ellas en cascada, donde finalmente aparece un componente de visualización que permite acceder a una tabla con los resultados o a una figura. Las funcionalidades de la herramienta se han programado utilizando el módulo scikit-learn [33] del lenguaje de programación de Python.

3. INSTALACIÓN DE REMACHES CIEGOS: UN CASO DE ESTUDIO

Los remaches ciegos son un tipo particular de remaches mecánicos donde el remache es introducido desde la cara delantera del ensamblaje. La comunidad científica ha hecho un gran esfuerzo para comprender y modelar [30] el proceso de remachado, así como el desarrollo de métodos para evaluar las uniones realizadas con remaches.

3.1. DESCRIPCIÓN DE LA BASE DE DATOS

La base de datos utilizada para el estudio está compuesta de 463 remaches y 112 variables, obtenida de un procedimiento experimental real. En la Tabla I, se muestran las principales condiciones de los ensayos, donde " Prueba N" es el número de ensayos, "Espesor" indica el espesor de la placa, el "Remache teórico" es un rango de espesores en cual el remache puede instalarse, "Remache Instalado" indica el espesor en que se instaló el remache y el "Lote" es el lote utilizado, A o B.

La Tabla I muestra también los resultados de los ensayos. En cuanto a la "Selección Código Remache", AIRE es un remache instalado sin la presencia de la placa, GRANDE es un remache cuyo agarre (relacionado con la longitud del remache) es mucho más largo que el deseable para el espesor de la placa, NOK es un remache seleccionado incorrectamente con un agarre un poco inadecuado para el espesor de la placa, OK es un remache correctamente seleccionado y PEQUEÑO es un remache cuyo agarre es mucho menor de lo que sería deseable para el espesor de la placa. El "Resultado Inst." indica si el remache no fue instalado (NO INSTALADO), si se ha instalado correctamente (OK) o no se instaló correctamente (NOK). El "Grupo" clasifica los resultados de instalación basados en la selección del código del remache y la calidad resultante de la instalación y "N. Inst." se refiere la cantidad de remaches que pertenecen a cada uno de los grupos.

Las variables utilizadas en el análisis se clasifican en distintos grupos, como se muestra en la Tabla II. Las variables de entrada son los relativos a las medidas de los agujeros, los descriptores de la señal y las condiciones de los ensayos. Las variables de salida son las mediciones de los remaches y el grupo de los remaches (variable "Grupo" de la Tabla I.).

Antes del análisis, se ha realizado el preprocesamiento de las señales monitorizadas: filtrado de las señales, el alineamiento de las señales, la normalización de los ejes X e Y y la extracción de los descriptores. Fig.1. a) muestra una de las curvas de par-ángulo monitorizado.

La curva-par de la señal se divide en 6 segmentos, en los que distintos descriptores han sido extraídos. Estas secciones corresponden a las diferentes etapas del remache ciego en la instalación: 1- Se inicia la instalación (cambio en la pendiente), 2- Se detiene la rotación de la cabeza (calculado el máximo de la tendencia de la señal), 3- Contacto de la cabeza (cambio en la pendiente de valores positivos), 4- Formación de la cabeza (aumento en el pendiente), 5- Instalación terminada (valor de par máximo) y 6- Husi-

Las condiciones del procedimiento experimental					Resultados de las pruebas			
Prueba N	**Espesor**	**Remache Teórico**	**Remache Instalado**	**Lote**	**Selección Código Remache**	**Resultado Int.**	**Grupo**	**N. Inst.**
0-59	0	G0	G300/G350/G400	A/B	AIRE	NO INSTALADO	1	60
60 - 119	2,3	G100	G300/G350/G400	A/B	GRANDE	OK	2	0
120-179	3,2	G150	G300/G350/G400	A/B	GRANDE	NOK	3	120
180-219	8,89	G350	G350/G400	A/B	NOK	OK	4	53
220-279	8,26	G350	G300/G350/G400	A/B	NOK	NOK	5	47
280-319	7,62	G350	G300/G350	A/B	OK	OK	6	96
320-359	10,16	G400	G350/G400	A/B	OK	NOK	7	4
360-399	11,43	G450	G350/G400	A/B	PEQUEÑO	OK	8	0
					PEQUEÑO	NOK	9	20

Tabla I: Resumen de las principales condiciones de los ensayos y los resultados de ellos

	Grupo de variables	**Número de variables**	**Variables**
Variables de entrada	Condiciones de los ensayos	4	El espesor de la placa Tipo de remache Código de agarre del remache Lote
	Descriptores de la señal monitorizada	90	Los detalles en la Tabla III.
	Las medidas de los agujeros	3	Diámetro de agujero Profundidad del agujero Profundidad del avellanado
Las variables de salida	Las mediciones del remache	3	Diámetro de la cabeza La altura de la cabeza Altura del vástago
	Los grupos del remache	1	Los detalles en la Tabla I

Tabla II. Clasificación de las variables utilizadas en el análisis

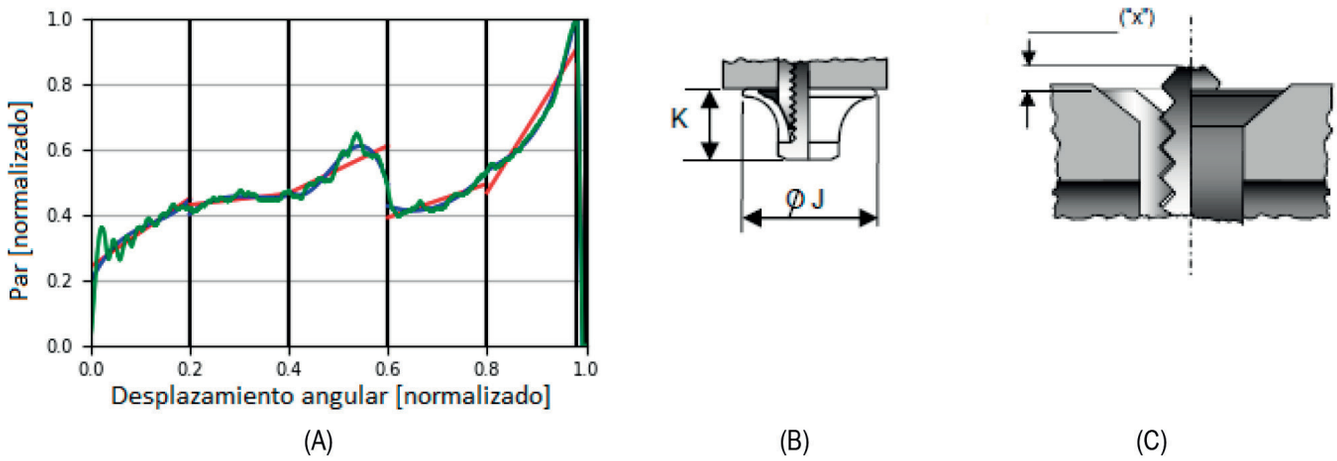


Fig. 1: a) Ejemplo de una curva de par-ángulo monitorizado; (b) el diámetro de la cabeza formada (J) y la altura de la cabeza formada (K); (c) rotura de la longitud del vástago (X)

llo apagado (valor del par llega a casi cero). La Tabla III muestra los descriptores extraídos para cada segmento, como son 6 segmentos y 15 descriptores, en total 90 descriptores son considerados.

Respecto a los agujeros, se han medido el promedio del diámetro del agujero, la profundidad del agujero y la profundidad del avellanado. Por otro lado, en cuanto a la calidad final del remache, se evalúa midiendo las dimensiones (diámetro y altura) de la cabeza formada, así como la rotura del vástago que sobresale de la cara frontal del ensamblaje. Fig.1. b) y Fig.1. c) muestran el remache ciego roscado utilizado para el estudio después de completar la instalación, donde la medida *J* indica el diámetro de la cabeza de la cara posterior, y medición *K* indica la longitud de la cabeza desde la parte de atrás.

3.2. RESULTADOS Y DISCUSIÓN

Para el estudio de las variables críticas en el proceso de instalación de remaches ciegos se proponen tres escenarios diferentes: 1) La influencia de las medidas de los agujeros en la calidad del remache instalado; 2) Influencia de la señal monitorizada en la calidad del remache instalado; 3) Influencia de las condiciones de los ensayos en la calidad del remache instalado.

3.2.1. Las medidas de los agujeros

En esta sección se analiza la influencia que tienen las tres variables relacionadas con la medición del agujero (diámetro del agujero, profundidad del agujero y profundidad del avellanado) en cada una de las variables relacionadas con la calidad de la instalación del remache (diámetro de la cabeza, la altura de la cabeza y la altura del vástago). Como las tres variables de salida son variables cuantitativas, se han construido modelos de regresión y se utilizaron las mediciones correspondientes para llevar a cabo la bondad de ajuste del modelo. La Tabla 4 muestra las mediciones obtenidas para los modelos generados para cada variable. Como puede observarse, el R^2 es inferior en los modelos con respecto a las medidas de los agujeros que los modelos relacionados con las condiciones de los ensayos, siendo la más alta para el diámetro de la cabeza (0,53). Es decir, las variables relacionadas con la medición del agujero pueden predecir mejor la cabeza del diámetro que la altura de la cabeza y la altura del vástago.

El RECM indica la desviación estándar de los residuos (errores de predicción), siendo la más baja para el diámetro de la cabeza (0,31 mm) seguido por la altura de la cabeza (0,5 mm) y la altura del vástago (0,53 mm). A partir de estos resultados se puede concluir que, a pesar de los bajos valores de R^2, las mediciones del agujero tienen alguna influencia en la calidad final del remache instalado, en particular sobre los valores de la cabeza formada.

En cuanto a cómo afectan las variables de entrada en la variable de salida, se ha encontrado un patrón similar en los tres modelos generados. Fig.2. a) muestra la importancia de las variables predictoras o variables de entrada, para el diámetro de la cabeza. Como se puede observar, el orden de importancia de mayor a menor es la siguiente: la profundidad del avellanado, la profundidad del agujero y el diámetro del agujero. Es decir, para tener un

Número	Tipo	Nombre
1, 2	Máximo y mínimo del par en el segmento.	$Tmax_i$-$Tmin_i$
3, 4	Desplazamientos angulares correspondientes a los valores de par máximo y mínimo en el segmento *i*	$AngDispMax_i$, $AngDispMin_i$
5	El área bajo la curva de par-ángulo dentro del segmento *i*	AUC_i
6-10	Los parámetros asociados a la correlación lineal (pendiente, intercepto, R, R^2, error cuadrático medio (ECM)	A partir $[ax+b]_i$ a, b, R, R^2 y ECM
11-15	Los parámetros asociados a un polinomio de tercer orden (parámetros del modelo y ECM)	A partir $[ax^3+bx^2+cx+d]_i$ a, b, c, d y ECM

Tabla III: Descriptores extraídos de las señales par-ángulo

	Las medidas de los agujeros		Condiciones de los ensayos	
	R^2	RECM	R^2	RECM
Diámetro de la cabeza	0.53	0.31	0.75	0.2
La altura de la cabeza	0.42	0.5	0.64	0.36
Altura del vástago	0.46	0.53	0.67	0.36

Tabla 4:. R^2 y RECM para los tres modelos generados de los indicadores de calidad del remache instalado, utilizando como variables predictoras medidas de los agujeros y condiciones de los ensayos

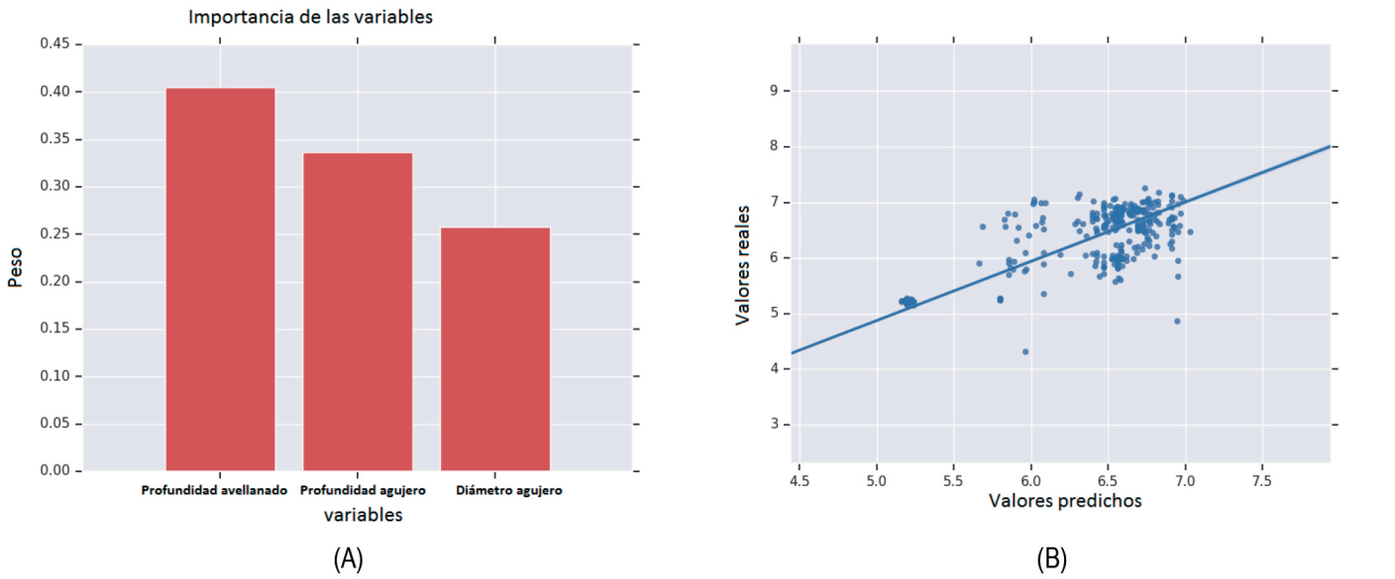


Fig. 2. (a) El peso de las variables de entrada, profundidad del avellanado, la profundidad del agujero y el diámetro del agujero, en el modelo generado para el diámetro de la cabeza del remache; (b) Los valores reales y los valores predichos por el modelo generado para el diámetro de la cabeza del remache

diámetro del cabeza adecuado, hay que poner mayor énfasis en la profundidad del avellanado y la profundidad del agujero. Este patrón se repite para la altura del vástago, sin embargo, para la altura de la cabeza, la profundidad del agujero tiene más influencia que la profundidad del avellanado. A fin de tener un mejor entendimiento de la calidad de las predicciones, Fig. 2. b) muestra los valores reales versus los valores predichos para el diámetro de la cabeza formada. Los puntos que están más cerca de la línea de regresión son predichos por el modelo con mayor precisión que los otros que están más lejos.

La menor contribución del diámetro del agujero puede explicarse por el hecho de que los remaches que se utilizan no se expanden radialmente a lo largo de la instalación. Por tanto, el diámetro del agujero no es una variable tan crítica para la instalación resultante. Con respecto a las otras dos variables analizadas, la profundidad del avellanado y la profundidad del agujero, definen junto a la longitud del remache el código de remache a utilizar, por lo que se debe esperar a tener una influencia sobre la calidad de la instalación del remache.

A partir de los resultados que se muestran en esta sección, cabe señalar que el proceso de taladrado tiene una influencia en la unión en términos de su resistencia estática y fatiga, como se sugiere en [35], sino que también afecta de manera significativa el desempeño correcto del proceso de remachado.

3.2.2. Descriptores de la señal monitorizada

En esta sección, se analiza la influencia que tienen los 90 descriptores obtenidos de la señal monitorizada par-ángulo en la variable grupo. Esta variable distingue los remaches en 9 clases o categorías según el tipo de instalación y la calidad de la instalación. Como la variable es cualitativa, se construye un modelo de clasificación y se realizan mediciones de la calidad de los modelos generados. En este caso, el R^2= 0.78, es superior a los R^2 obtenidos en la sección anterior, aunque suele ser habitual obtener mejores resultados en clasificación que en modelos de regresión para los Árboles de Decisión. La precisión obtenida es de 86%, es decir, el 86% de los remaches se clasificaron en el grupo correcto al que pertenecen. Es evidente que la señal monitorizada correspondiente a la instalación de un remache tiene una gran influencia sobre la calidad del remache.

La Figura 3 muestra la importancia de las variables de entrada en función del peso que tienen en el modelo generado. Como se puede observar, hay 5 variables que predominan sobre el resto de las variables: tiempo máximo (segmento 5), el coeficiente *b* de *[ax+b]* (segmento 6), *ECM* de *[ax+b]* (segmento 5), área (segmento 5), coeficiente *a* de *[ax+b]* (segmento 6), mínimo desplazamiento angular (segmento 5) y *R* de *[ax+b]* (segmento 5). Se puede concluir que el segmento 5 y 6 son más importantes para determinar la calidad del remache, que los otros segmentos. Ciertamente, los segmentos 5 y 6 debían proporcionar la mayor cantidad de información sobre la calidad de las instalaciones, ya que es el período donde la deformación plástica tiene lugar, de modo que se forma la cabeza del remache y el vástago se rompe.

3.2.3. Condiciones de los ensayos

En esta sección, se analiza la influencia que tienen las variables relacionadas con las condiciones de los ensayos sobre las mediciones de los remaches instalados. Como las tres variables son cuantitativas, se construyeron modelos de regresión y donde las

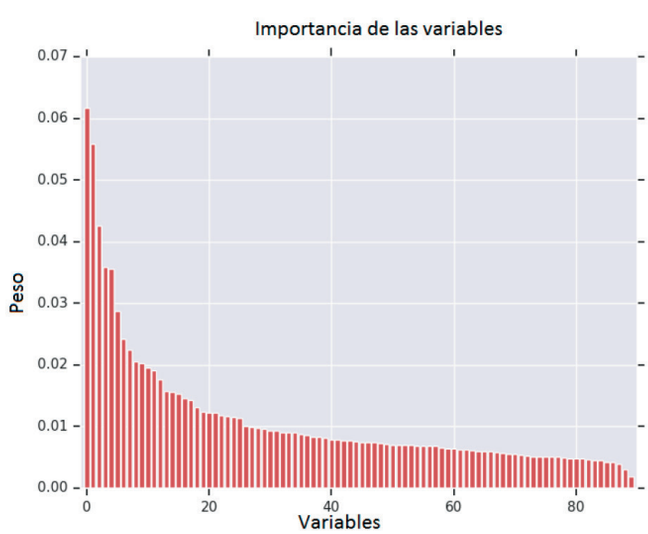


Fig. 3. El peso de las variables de entrada en el modelo generado. Las dos primeras variables corresponden al tiempo máximo del segmento 5 y coeficiente b de la ecuación ax+b del segmento 6

mediciones correspondientes se han utilizado para realizar la bondad de ajuste del modelo. En la Tabla IV. se muestran el R^2 y RECM, para los tres modelos generados. En este caso, los R^2 obtenidos son superiores a los obtenidos para las medidas de los agujeros. También, en este caso, el máximo es para el diámetro de la cabeza (0,75), seguido por la altura del vástago (0,67) y la altura de la cabeza (0,64).

En cuanto a la RECM, el menor se ha obtenido para el diámetro de la cabeza (0.2 mm), mientras que para la altura de la cabeza y la altura del vástago se ha obtenido lo mismo (0,36 mm). En cuanto a la importancia de las variables de entrada, se ha obtenido un patrón similar para los tres modelos generados: El espesor de la placa, tipo de remache, código de agarre del remache y código de lote. Por encima de todo, el espesor de la placa y el tipo de remache son los más críticos, como puede observarse en la Fig.4.a), puesto que tienen mucho más peso que el resto de las variables. Fig. 4.b) muestra los valores reales versus los predichos para el diámetro de la cabeza del remache.

Respecto al caso de uso analizado, se han planteado tres escenarios diferentes para el estudio de variables críticas en el proceso. En primer lugar, las mediciones de los agujeros están relacionados con las mediciones de los remaches, es decir, la influencia de la anterior etapa de taladrado en el remachado. Se constató que las medidas de los agujeros del taladrado afectan a la calidad del remache, especialmente para el diámetro de cabeza formada, siendo las variables más críticas la profundidad del vástago y la profundidad del agujero. La menor contribución del diámetro del agujero al modelo está relacionada con el hecho de que las fijaciones empleadas no se expanden radialmente a lo largo de la instalación.

En el segundo escenario planteado, los descriptores de la señal monitorizada estaban relacionados con la calidad final del remache, una sola etapa de análisis. A partir de este análisis, puede concluirse que los segmentos 5 y 6 son críticos para clasificar qué tipo de remache se va a obtener dependiendo de su calidad. Estos segmentos son más importantes porque dentro de ese período, la

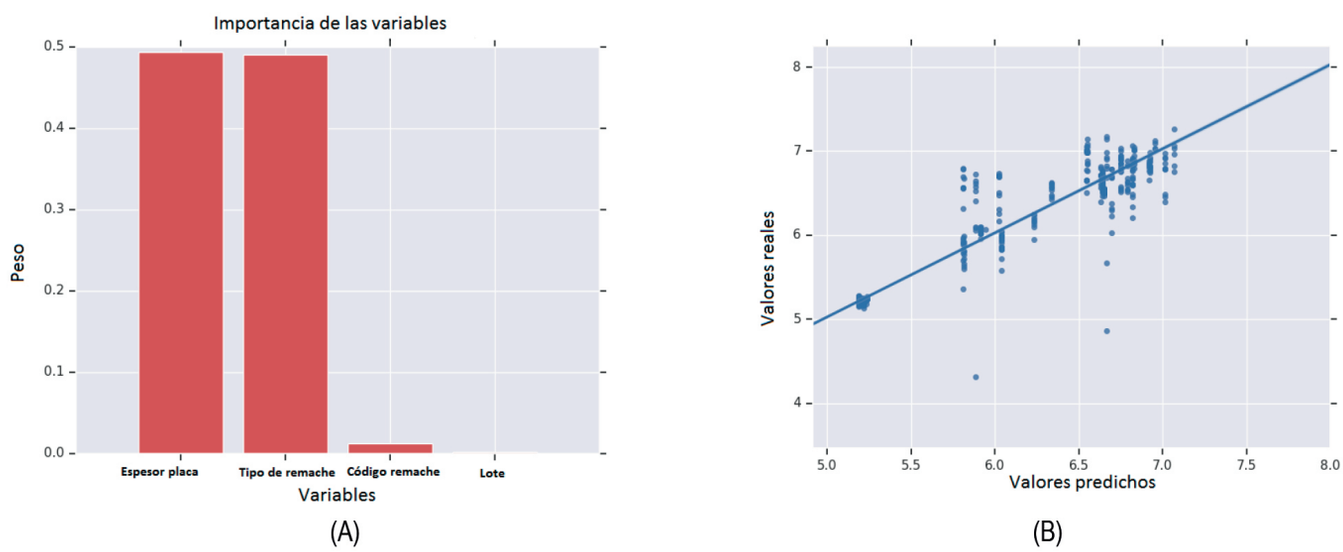


Fig. 4. (A) El peso de las variables de entrada, el espesor de la placa, tipo de remache, tipo de agarre del remache y código de lote, en el modelo generado para el diámetro de la cabeza del remache; b) Los valores reales y los valores predichos por el modelo generado para el diámetro de la cabeza del remache

La metodología propuesta en este artículo nos permite discriminar las variables que tienen mayor correlación con la correcta instalación del remache en este caso de uso. La influencia en el proceso, de la relación entre el espesor de la placa y el tipo de remache, está demostrado en trabajos anteriores [35]. En otro trabajo de investigación, Camacho et al. [26] llevan a cabo un sistema de vigilancia basado en la determinación de la correcta selección del tipo de remache para el espesor de la placa en la que se efectúa la operación.

deformación plástica tiene lugar, de modo que la cabeza del remache se está generando y el vástago se rompe.

Por último, en el tercer escenario, se analiza la influencia que tienen las condiciones de los ensayos en las mediciones de los remaches. Se ha comprobado que las variables relacionadas con las condiciones de los ensayos afectan a la calidad final del remache, y como ocurre en el primer escenario, especialmente, para el diámetro de la cabeza formada. En este caso, las variables más importantes son el espesor de la placa y el tipo de remache.

4. CONCLUSIONES

En este trabajo de investigación, se ha desarrollado un motor de análisis para identificar las variables críticas en un proceso industrial multi-etapa utilizando técnicas basadas en Aprendizaje Automático. Se ha utilizado un proceso de instalación de remaches ciegos como caso de estudio, ya que es un proceso que se conforma de varias fases, en las que las variables de diferentes etapas pueden afectar a la calidad final del remache instalado. El motor de análisis se divide en varias categorías, siguiendo un flujo de trabajo común en Aprendizaje Automático. Además, es fácil de usar y está orientado a usuarios no expertos en el análisis de datos.

REFERENCIAS

[1] Lee J, Bagheri B, Kao HA. "A cyber-physical systems architecture for industry 4.0-based manufacturing systems". Manufacturing Letters. 2015. Vol. 3. p.18-23. DOI: https://doi.org/10.1016/j.mfglet.2014.12.001
[2] Murua M, Suárez A, López de Lacalle LN et al. "Feature extraction-based prediction of tool wear of Inconel 718 in face turning". Insight-Non-Destructive Testing and Condition Monitoring. 2018. Vol. 60. p. 443-450. DOI: https://doi.org/10.1784/insi.2018.60.8.443
[3] Ezugwu E, Fadare D, Bonney J et al. "Modelling the correlation between cutting and process parameters in high-speed machining of Inconel 718 alloy using an artificial neural network". Machine Tools & Manufacture. 2005. Vol. 45. p. 1375-1385. DOI: https://doi.org/10.1016/j.ijmachtools.2005.02.004
[4] Rangwala S, Dornfeld D. "Learning and optimization of machining operations

using computing abilities of neural networks". IEEE Trans Syst Man Cybern, 1989. Vol. 19. p. 299–314. https://ieeexplore.ieee.org/document/31035
[5] Feng C-X, Wang X-F. "Surface roughness predictive modelling: neural networks versus regression. IEE Trans. 2003. Vol. 35. p.11–27. DOI: https://doi.org/10.1080/07408170304433
[6] Sikdar S, Chen M. "Relationship between tool flank wear area and component forces in single point turning". Journal of Materials Processing Technology. 2002. Vol. 128. p. 210–215. DOI:https://doi.org/10.1016/S0924-0136(02)00453-3
[7] Correa M, Bielza C, Pamies-Teixeira J. "Comparison of bayesian networks and artificial neural networks for quality detection in a machining process". Expert Systems with Applications. 2009. Vol. 36. p. 7270–7279. DOI: https://doi.org/10.1016/j.eswa.2008.09.024
[8] Kilundu B, Dehombreaux P, Chiementin X. "Tool wear monitoring by machine learning techniques and singular spectrum analysis". Mechanical Systems and Signal Processing. 2011. Vol. 25. p. 400–415. DOI: https://doi.org/10.1016/j.ymssp.2010.07.014
[9] Shi D, Gindy N. "Tool wear predictive model based on least squares support vector machines". Mechanical systems and signal processing. 2007. Vol. 21. p.1799–1814. DOI: https://doi.org/10.1016/j.ymssp.2006.07.016
[10] Lavanya K M, Suresh R K, Priya A K et al. "Optimization of process parameters in turning operation of AISI-1016 Alloy steels with CBN using taguchi method and anova". Journal of Mechanical and Civil Engineering. 2003. Vol.7. p. 24-27. DOI: https://doi.org/10.9790/1684-0722427
[11] Baskar N, Asokan P, Prabhaharan G et al. "Optimization of machining parameters of milling operations using non-conventional methods". Int J Adv Manuf Technol. 2005. Vol. 25. p.1078-1088. https://link.springer.com/article/10.1007/s00170-003-1939-9
[12] Sahoo P. "Optimization of turning parameters for surface roughness using RSM and GA. Advances in Production Engineering & Management". 2011. Vol. 6. p.197-208.
[13] Chandrasekaran M, Muralidhar M, Krishna CM et al. "Application of soft computing techniques in machining performance prediction and optimization: a literature review". Int J Adv Manuf Technol. 2010. Vol. 46. p. 445-464. https://link.springer.com/article/10.1007/s00170-009-2104-x
[14] Abburi NR, Dixit US. "A knowledge based system for the prediction of surface roughness in turning process". Robot Comput Integr Manuf. 2006. Vol.22. p. 363–372. https://www.sciencedirect.com/science/article/pii/S0736584505000621
[15] Zhong ZW, Khoo LP, Han ST. "Prediction of surface roughness of turned surfaces using neural networks". Int J Adv Manuf Technol. 2006. Vol.28. p. 688-693. https://link.springer.com/article/10.1007/s00170-004-2429-4
[16] Nandi AK, Pratihar DK. "An expert system based on FBFN using GA to predict surface finish in ultra-precision turning". J Mater Process Technol. 2004. Vol. 155-156. p.1150-1156. DOI: https://doi.org/10.1016/j.jmatprotec.2004.04.408
[17] Wang ZG, Wong YS, Rahman M. "Optimisation of multipass milling using genetic algorithm and simulated annealing". Int J Adv Manuf Technol. 2004. Vol. 24. p.727-732. https://link.springer.com/article/10.1007/s00170-003-1789-5
[18] Vijayakumar K, Prabhaharan G, Asokan P et al. "Optimization of multi-pass turning operations using ant colony system". Int J Mach Tools Manuf. 2003. Vol. 43. p.1633-1639. https://www.sciencedirect.com/science/article/pii/S0890695503000816
[19] Meissner M, Schmuker M, Schneider G. "Optimized Particle Swarm Optimization and its application to artificial neural network training." BMC bioinformatics. 2006. Vol. 7. p. 1-125.
[20] Pawade R, Joshi S S, Brahmankar P. "Effect of machining parameters and cutting edge geometry on surface integrity of high-speed turned Inconel 718". Machine Tools & Manufacture. 2008. Vol. 48. p.15–28. DOI: https://doi.org/10.1016/j.ijmachtools.2007.08.004
[21] Peters H, Link N, Heckenthaler T. "Application of Data Mining Techniques to Find Correlation Between Quality Data and Process Variables". IFAC Proceedings Volumes. 2001. Vol. 34. p.193-198. DOI: https://doi.org/10.1016/S1474-6670(17)33205-6
[22] Hall M A. "Correlation-based feature selection for machine learning". PhD Dissertation. University of Waikato (New Zealand). 2009.
[23] X. Zuo, B. Li, J. Yan. "Error sensitivity analysis and precision distribution for multi-operation machining processes based on error propagation model". Int. J. Adv. Manuf. Technol. 2016. Vol. 86. p. 269-280. DOI: https://doi.org/10.1007/s00170-015-8154-3
[24] Chien C-F, Wang W-C, Cheng J-C. "Data mining for yield enhancement in semiconductor manufacturing and an empirical study". Expert Systems with Applications. 2007. Vol. 33. p. 192-198. DOI: https://doi.org/10.1016/j.eswa.2006.04.014
[25] Diez-Olivan A, Penalva M, Veiga F. et al. "Kernel density-based pattern classification in blind fasteners installation". In HAIS 2017: Hybrid Artificial Intelligent Systems. 2017.p.195-206.
[26] Camacho J, Rivero A, Veiga F et al. "A non-destructive quality assessment for blind-fastener installations based on the combination of ultrasound techniques and real-time monitoring of the fastening process ". The International Journal of Advanced Manufacturing Technology. 2016. Vol. 84. p. 1057-1066. DOI: https://doi.org/10.1007/s00170-015-7795-6
[27] Camacho J, Veiga F, Penalva M L et al. "On-line monitoring of blind fastener installation process". Materials. 2019. Vol. 12. DOI: https://doi.org/10.3390/ma12071157
[28] Breiman L. "Random forests". Machine Learning. 2001. Vol. 45. p. 5–32.
[29] Wu D, Jennings J C, Terpenny R.X et al. "A Comparative Study on Machine Learning Algorithms for Smart Manufacturing: Tool Wear Prediction Using Random Forests". ASME. J. Manuf. Sci. Eng. 2017. Vol.139. p.1-10. DOI: https://doi.org/10.1115/1.4036350
[30] Zhang C, Ma Y. "Ensemble machine learning: methods and applications". Springer Science & Business Media. 2012.
[31] Seber G A, Lee A J. "Linear Regression Analysis". Wiley. 2003.
[32] "ForZDM – Integrated zero defect manufacturing solution for high value multi-stage manufacturing systems". Funded under H2020-EU.2.1.5.1 Technologies for Factories of the Future, call H2020-FoF-2016, contract No. 723698. https://forzdmproject.eu/
[33] Pedregosa F, Varoquaux G, Gramfort A et al. Scikit-learn: Machine learning in Python. Journal of Machine Learning Research. 2011. Vol. 12. p. 2825–2830. http://www.jmlr.org/papers/v12/pedregosa11a
[34] Zitoune R, Krishnaraj V, Collombet F et al. "Experimental and numerical analysis on drilling of carbon fibre reinforced plastic and aluminium stacks". Compos. Struct. 2016. Vol. 146, p. 148–158. https://www.sciencedirect.com/science/article/pii/S0263822316301404
[35] Saygin C, Mohan D, Sarangapani J "Real-time detection of grip length during fastening of bolted joints: a Mahalanobis-Taguchi system (MTS) based approach". Journal of Intelligent Manufacturing. 2010, Vol. 21(4), p. 377–392. https://link.springer.com/article/10.1007%2Fs10845-008-0186-1.

AGRADECIMIENTOS

Este proyecto ha recibido financiación de la Unión Europea 2020 programa de investigación e innovación en virtud de acuerdos de subvención nº 686827 y nº 723698.