

Mejora del mecanizado mediante el registro y análisis de variables de proceso en la nube

Improvement of machining through registration and analysis of process variables in the cloud



Mikel Casuso-Lomas¹, Txomin Ostra-Beldarrain¹, German Rodríguez-Canas¹, Fernando Veiga-Suárez¹, Mariluz Penalva-Oscoz¹ y Aitzol Lamikiz-Mentxaka²

¹ Tecnalia (España)

² Universidad del País Vasco UPV/EHU (España)

DOI: <http://dx.doi.org/10.6036/9398>

1. INTRODUCCIÓN

La industria en general y la ingeniería de fabricación en especial no son ajenos al cambio de contexto debido al incremento de la capacidad de conexión de máquinas y bienes de equipo a redes de comunicación con un coste cada vez más reducido. Todo ello resulta en un complejo escenario globalizado y dominado por el concepto de "Internet de las cosas" (en inglés: IoT), que podría denominarse "Internet of Production" (IoP) [1].

Este nuevo contexto presenta nuevas exigencias para las empresas que, independientemente de su sector, aspiren a mantenerse o crecer. Sin embargo, aparecen también nuevas oportunidades de mejora o desarrollo de nuevos productos/procesos.

1.1. ESTADO DEL ARTE EN MONITORIZACIÓN Y ANALÍTICA DE VARIABLES DE PROCESO EN MECANIZADO

El término Industria 4.0 fue acuñado por el gobierno alemán para describir la fábrica inteligente, una visión de la fabricación informatizada con todos los procesos interconectados por el IoT [2].

La consultoría McKinsey & Company publicó recientemente el extenso informe "Cómo Big Data puede mejorar el sector de Fabricación" [3], en el cual se recoge que los fabricantes tienen una cantidad de datos de la planta de fabricación que están empezando a ser utilizados para, una vez analizados, optimizar los medios productivos y los procesos. Las áreas principales en que Big Data puede mejorar

el funcionamiento de las máquinas y las plantas de producción son las siguientes:

- Previsión de la demanda de productos y de los sistemas de producción.
- Comprensión del funcionamiento de las máquinas y de la planta de producción.
- Provisión de mejores servicios y soporte a los clientes.

En las recientes ferias de máquina herramienta, los fabricantes mundiales líderes han potenciado la idea de que la conectividad de los datos es la clave para implementar la Industria 4.0. En concreto, la mayoría de ellos emplean el término Machine 4.0 para evidenciar que sus máquinas llevan implementados sensores para monitorizar los distintos componentes de la propia máquina y el proceso de mecanizado [4]. Los datos generados por estos sensores pueden ser transmitidos vía Internet a aplicaciones basadas en la nube, que funciona como repositorio remoto de datos y sirve para compartir recursos computacionales. Esto permite abordar aplicaciones para acceder a grandes volúmenes de datos y llevar a cabo una analítica de éstos ejecutando algoritmos computacionales que requieran de grandes recursos de procesado. Así, de los

datos se pueden extraer patrones de comportamiento de la máquina y/o proceso que empoderen al operario y posibiliten aumentar el rendimiento.

1.2. NUEVO ESCENARIO PARA LA MEJORA DE PROCESOS

Disponer de información objetiva y cuantitativa sobre la potencia demandada, nivel de vibración, tiempo real de ejecución, etc. para una pieza y/o herramienta dada es muy útil a la hora de definir nuevas piezas o mejorar piezas antiguas. Así, los nuevos procesos de fabricación disponen de una alta sensorización la cual genera un gran volumen de datos que, gracias a su modelado y análisis sistemático, aumenta el conocimiento sobre la pieza y el proceso, lo cual permite tomar decisiones que impacten en la productividad (Fig. 1) [5].

Precisamente, este es el objetivo del presente trabajo: optimizar diversos procesos de mecanizado a partir del análisis sistemático de grandes volúmenes de datos almacenados en la nube provenientes de una alta sensorización en máquina y pieza. Se trata de aplicar el concepto "IoP" a casos reales y concretos.

2. MATERIALES Y MÉTODOS

2.1. PLATAFORMA DE ADQUISICIÓN Y GESTIÓN DE DATOS

El método que se ha seguido para conseguir los objetivos propuestos ha consistido en desarrollar y hacer uso de una Pla-

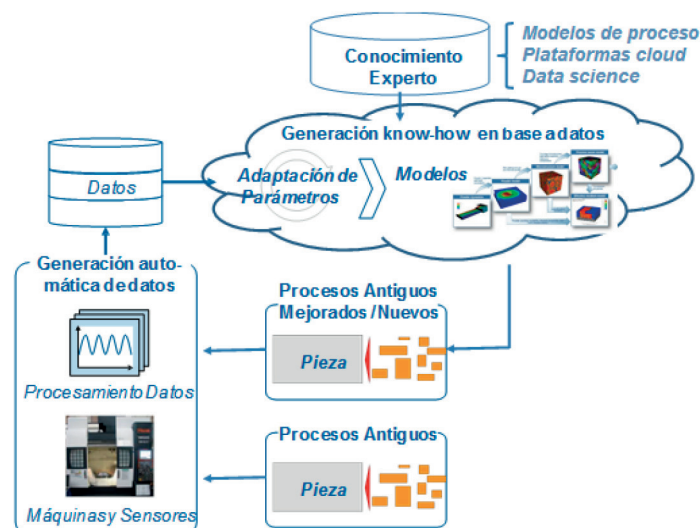


Fig. 1: Nuevo escenario para la definición de procesos de mecanizado

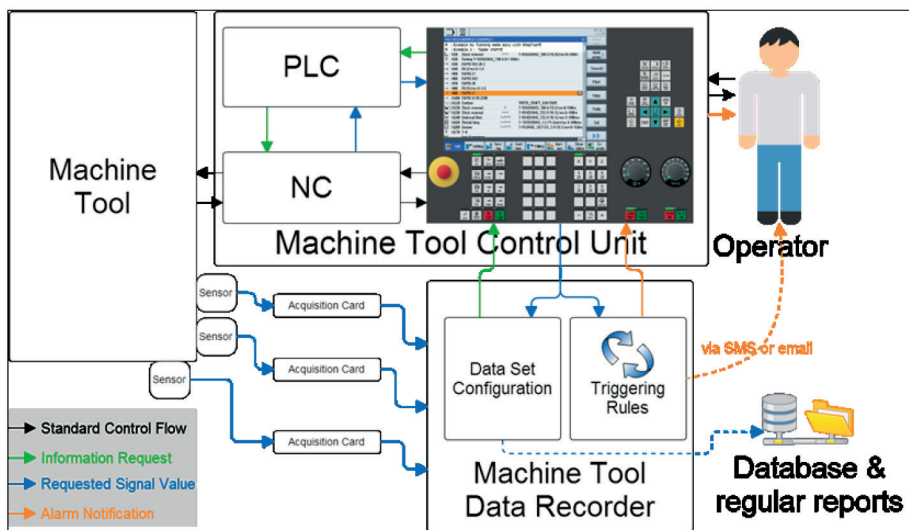


Fig. 2: Funcionamiento de la Plataforma de Adquisición de Datos

taforma de Adquisición de Datos (Fig. 2), la cual consta de un Registrador de Datos (*Data Recorder*) que procesa la información obtenida de la memoria del control de la máquina en cuestión (*Machine Tool*). Esta información proviene de la unidad de control de la máquina (*Control Unit*) y de los sensores incorporados a ella (*Sensor*). Para la adquisición de la señal proveniente de los sensores se utiliza la tarjeta de adquisición (*Acquisition Card*) entre el Registrador de Datos y el sensor, que calcula un valor medio a la frecuencia deseada y la almacena en un buffer para la transmisión. El Registrador de Datos puede realizar de forma automática varias tareas programadas para mejorar indicadores de salida fijados inicialmente por el operario (*Operator*).

El Registrador de Datos puede realizar el registro de hasta dos mil parámetros diferentes a una frecuencia nominal de 5 Hz, pudiendo aumentarse dicha frecuencia hasta 300 Hz. Para señales provenientes de sensores que necesitan una frecuencia más alta (acelerómetros o micrófonos), se pueden definir condiciones para activar el almacenamiento de hasta diez señales en un buffer a una velocidad superior, hasta 30 kHz.

La Plataforma está conectada a un servidor remoto vía Internet, al que se cargan todos los datos monitorizados desde el Registrador de Datos, permitiendo el almacenamiento y análisis de señales de manera remota y accesible mediante una comunicación basada en VPN (Virtual Private Network). La conexión entre el servidor y el Registrador de Datos es una conexión Ethernet. Para la recuperación de datos periódica, se ejecuta en segundo plano un script a través de solicitudes del servidor. De esta manera se pueden generar automáticamente informes generales, a

una frecuencia dada, en grupos de máquinas (máquinas que ejecutan el mismo trabajo, del mismo tipo, situadas en la misma área, etc.), así como informes detallados sobre casos específicos. En el servidor se pueden calcular en tiempo real diferentes indicadores sobre el funcionamiento de la máquina a través de los datos transmitidos desde el Registrador de Datos.

2.2. INTERFAZ PARA USUARIOS

La interfaz a la que acceden los usuarios vía web puede ser configurada en función de sus necesidades. Además, permite consultar y disponer de datos en directo del uso de las máquinas y datos relativos al histórico de producción, así como monitorizar variables en el tiempo. Todas las interfaces se han desarrollado con código de la compañía VIXION, spin-off nacida de TECNALIA.

3. RESULTADOS

En este apartado se muestran de forma resumida ejemplos de trabajos realizados en la mejora de procesos de mecanizado para diferentes aplicaciones y sectores. Todos los desarrollos han aprovechado la Plataforma de Adquisición de Datos, con el fin de mejorar aspectos como la productividad, robustez y calidad del proceso.

3.1. MECANIZADO DE SERIE LARGA EN AUTOMOCIÓN

El caso objeto de estudio ha sido el mecanizado de anillos de rodamiento para vehículos. Se trata de una operación de cilindrado exterior de anillos procedentes de un proceso previo de forjado en el que el que las dimensiones del material a mecanizar están fuera de los umbrales de tolerancia por 1-1,5 mm aproximadamente. El proceso se realiza en un torno

horizontal con alimentación automática de piezas, donde el tiempo de ciclo es de 4 s y el criterio de cambio de herramienta es de 500 piezas, esto es, de serie larga. Lo habitual en este tipo de operaciones era fijar un criterio de cambio de herramienta conservador, de forma que se daba prioridad a evitar paradas no programadas de la máquina o de la célula automatizada.

El trabajo realizado ha tenido como objetivo optimizar la vida de la herramienta. La variable más relacionada con el desgaste de la herramienta es la señal de carga del cabezal (Fig 3, izquierda), en concreto su máximo local, ya que presenta una tendencia ascendente durante el mecanizado de una serie, en concordancia con el aumento del desgaste. Se trata de un método indirecto para el control del desgaste, ya que se mide un parámetro del proceso de corte relacionado con éste [6].

La predicción de la vida útil remanente se ha realizado aplicando la siguiente metodología: caracterización, detección de valores atípicos, filtrado, detección de comportamiento anormal y predicción. Así, en primer lugar se ha definido un umbral a través del cálculo de la mediana, por el cual se han eliminado los valores de carga atípicos que quedaban fuera. Estos valores se detectaban debido a la relativa baja frecuencia de adquisición de datos (5 Hz). En segundo lugar, las señales se han filtrado aplicando un filtro Savitzky-Golay, que utiliza una aproximación polinomial de los datos más cercanos en el que se ajustan diferentes parámetros con base en la experiencia. A continuación, se ha utilizado el algoritmo *K-means* de clasificación supervisada (clusterización) que agrupa las series en *k* grupos basándose en sus características. De esta manera, se han eliminado las series que no cumplieran con los criterios establecidos. Por último, se ha desarrollado un modelo ARIMA (*Autoregressive Integral Moving Average*) aplicado a cada señal. Es un modelo autorregresivo integrado de promedio móvil que utiliza variaciones y regresiones de datos estadísticos con el fin de encontrar patrones para una predicción a futuro, en este caso, la vida útil de la herramienta.

La predicción se ha validado mediante ensayos en los que se ha prolongado el número de piezas de la serie con el fin de llevar la herramienta a valores de desgaste muy elevados.

Entre los resultados, cabe destacar que debido a las variaciones en el material y en el proceso previo de forjado, se han observado variaciones significativas en la maquinabilidad de las piezas (diferencias en la carga media necesaria). Para

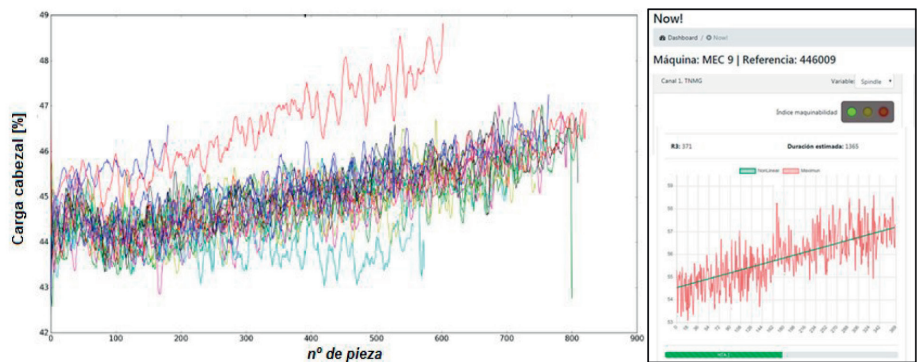


Fig. 3: Evolución de la carga máxima para diferentes series (izquierda) y su aplicación para predicción de vida útil (derecha)

poder clasificar estas variaciones se ha incluido un indicador de maquinabilidad, en forma de semáforo, que determina tres niveles de maquinabilidad: buena (verde), media (amarillo) y mala (rojo). Se calcula esta maquinabilidad basándose en la carga máxima media de las 50 primeras piezas de la serie. La interfaz de usuario de la Plataforma de Adquisición de Datos informa de forma continua del número de piezas remanente con la herramienta en uso (Fig. 3, derecha).

La predicción de la vida remanente de la herramienta ha permitido alargar el número de piezas en la mayoría de las series, consiguiendo una reducción de costes del proceso; debido, en primer lugar, a la reducción del gasto en herramienta, y, en segundo lugar, a la reducción de paradas de máquina para realizar el cambio de herramienta. El ahorro alcanzado ha sido de en torno al 6-8%.

3.2. MECANIZADO DE SERIE MEDIA EN SECTOR FERROVIARIO

Los conjuntos eje-rueda son componentes críticos para la seguridad en

un vehículo ferroviario y cualquier falla en servicio puede llevar a consecuencias catastróficas, por lo que se debe garantizar su alta calidad y la ausencia de defectos. Esto debe lograrse tanto mediante una fabricación por torneado muy específica como mediante la inspección adecuada.

Por tanto, el objetivo de este trabajo ha sido ofrecer una nueva estrategia de control de calidad multietapa para la producción en régimen de cero defectos (en inglés: ZDM) [7] durante el proceso de mecanizado de desbaste de la superficie del eje. Para ello se han recopilado a través de una red de sensores múltiples las siguientes señales: Par, Giro del cabezal, Potencia consumida por cada carro, *Feed/Spindle override* de los carros y cabezal, Herramienta(s) activa(s), Tiempos de parada, E/S de pieza (tiempo en máquina), Herramienta en movimiento sin arranque de viruta, Tiempos por plano, Tiempo de Setup. A estas señales se han aplicado herramientas de *knowledge extraction*, como por ejemplo análisis de correlación y modelos de análisis de varianza. Esto

representa una fuente nueva y relevante de conocimiento sobre las causas de la generación de defectos y sus mecanismos de propagación a lo largo de las líneas de producción. Este conocimiento debe ser extraído y estructurado para poder aprovecharlo en todos los desarrollos futuros, a través de sistemas ciberfísicos (en inglés: CPS) que utilizan el conocimiento sobre defectos para contrarrestar su generación y propagación. Esta metodología ha permitido determinar la degradación del estado de la herramienta por medio de la correlación existente con las señales de proceso adquiridas. Por tanto, el operario podría intervenir en el proceso, sustituyendo de una forma predictiva la herramienta antes de la producción de pieza defectuosa.

Los resultados del análisis de datos se materializan mediante: (i) la eliminación de datos redundantes para la gestión ágil y el flujo de la información de línea y la implementación lean de los modelos controlados por datos (por ejemplo, propagación de defectos, CPS), y (ii) la extensión de las capacidades de análisis a escenarios futuros mediante interfaces de usuario que proporcionen capacidades de análisis en planta a operadores y gerentes de producción.

3.3. RECTIFICADO DE ENGRANAJES PARA SECTOR EÓLICO

El rectificado de los flancos de engranajes de reductoras eólicas es una operación crítica. Una incorrecta ejecución implica daños en la capa superficial de la pieza que se traducen en piezas rechazadas o que, en el peor de los casos, producen paradas de la instalación eólica, con un elevado coste.

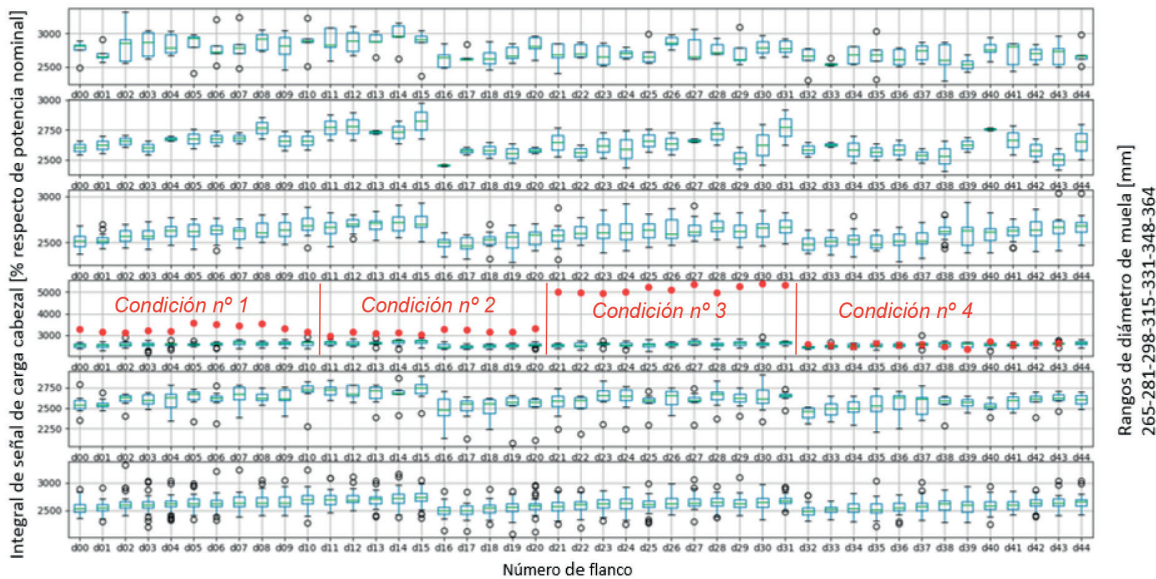


Fig. 4: Resultados de ensayos (puntos rojos) respecto del modelo de predicción (box-plot)

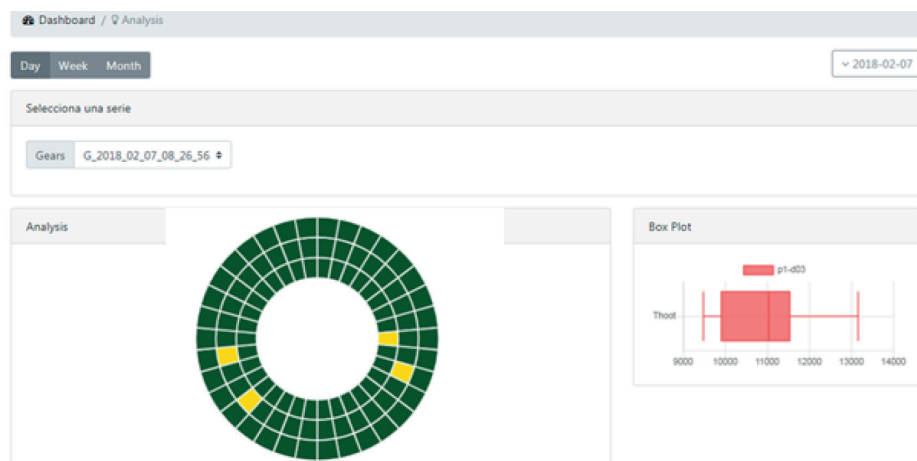


Fig. 5: Representación del rectificado de una pieza dentada

Con el objetivo de controlar la calidad de esta operación, se ha realizado un modelo de predicción de normalidad del proceso. Existen estudios que abordan el mismo problema analizando el nivel vibratorio [8], aunque en el presente caso se estudia la señal de carga (% respecto de la potencia nominal) del cabezal principal de la máquina, cuyas variables de entrada han sido: Referencia de la pieza, Número de flanco, Diámetro de la muela de rectificado, Carga máxima y media durante el proceso por flanco, Integral de la señal de carga.

Se han realizado dos análisis sobre estas variables. En primer lugar, se ha realizado un análisis de componentes principales (en inglés: PCA), que ha permitido agrupar los datos en diferentes rangos de diámetro de muela. A continuación, basándose en diagramas de tipo *box-plot*, que consisten en representar gráficamente datos numéricos a través de sus cuartiles, se han establecido los umbrales de normalidad de la operación. Este modelo de predicción requiere un número de muestras fiables, es decir, de datos obtenidos durante la ejecución de piezas correctas. Una vez obtenido un primer modelo, es posible alimentarlo de forma continua con más datos de piezas correctas.

Las pruebas de validación del modelo han consistido en aplicar 4 condiciones de proceso durante el rectificado de una pieza de 45 dientes, de forma que se ha dividido el proceso en 3 grupos de 11 dientes y otro de 12 dientes. Estas 4 condiciones han sido las siguientes:

- Flancos 1-11: rectificado desde bruto con diamantados de acabado.
- Flancos 12-22: aumento de profundidad de pasada en un 42% respecto de condiciones de referencia.
- Flancos 23-33: aumento de profundidad de pasada en un 150%.
- Flancos 34-45: condiciones de referencia.

En la Fig. 4 se observan los puntos (en rojo) sobre el diagrama *box-plot* para una de las pasadas, de semidesbaste del proceso. Se observa claramente que la predicción para las condiciones nº1, nº2 y nº3 se ubica fuera de la normalidad establecida por el *box-plot*, como era de esperar.

El usuario puede analizar a través de la interfaz desarrollada si una ejecución o pieza ha entrado en los umbrales de normalidad establecidos. La aplicación permite seleccionar un intervalo de tiempo de producción y la ejecución de una pieza dada. La aplicación representa gráficamente un diagrama circular que emula la geometría de una pieza dentada (Fig. 5). Cada segmento del diagrama corresponde a un número de flanco y secuencia de rectificado (desbaste, semi-desbaste y acabado). Los colores informan si el proceso de rectificado para ese flanco y secuencia ha sido normal (verde), límite (amarillo), o fuera de la normalidad (rojo).

3.4. FRESADO DE PIEZAS FABRICADAS POR FABRICACIÓN ADITIVA

El mecanizado de piezas metálicas obtenidas mediante técnicas de fabricación aditiva presenta peculiaridades (como variaciones en la dureza, o poros) que conllevan afrontar retos diferenciados respecto del mecanizado de piezas tradicional. Los retos principales son los siguientes:

- Conocer la geometría de la pieza para estimar las creces de mecanizado.
- Fijar el cero en una pieza con una forma cercana a la final.
- Fijar las condiciones de mecanizado.
- Asegurar si el mecanizado de las piezas subsiguientes presentará un patrón similar y estable.

El trabajo realizado ha supuesto afrontar estos retos, a partir del mecanizado de una pieza una de cuyas caras ha

sido reparada mediante LMD (*Laser Metal Deposition*). Por esto, el objetivo del trabajo ha sido doble: primero, referenciar la geometría obtenida respecto de las coordenadas máquina; y después, establecer la normalidad de la operación.

Para el primer objetivo se ha integrado un sistema de visión en el centro de mecanizado basado en la técnica de luz estructurada. Esto ha permitido obtener una nube de puntos referenciados respecto de coordenadas máquina. Con la nube de puntos se ha podido realizar el matching entre la pieza medida y la pieza antes de ser aportada. También se ha podido hallar la ubicación del centro de la pieza para definir un cero de pieza o programa.

Para el segundo objetivo, se ha creado un modelo estadístico entrenado con un número de ejecuciones mínimo, que ha tenido en cuenta la señal de carga del cabezal de corte y el nivel de vibraciones durante el proceso de mecanizado. Así, se ha elaborado un diagrama de Gauss que establece la normalidad de la operación y permite comparar nuevas operaciones.

Los controles de calidad realizados a las piezas fresadas dentro de los umbrales de normalidad así establecidos han sido positivos, lo cual ha servido para validar el modelo.

3.5. MANDRINADO PROFUNDO PARA EL SECTOR OIL & GAS

El sector Oil&Gas demanda tubos mandrinados de diversos diámetros (100-600 mm) y longitudes (8-12 m). El principal reto del mandrinado profundo de este tipo de tubos es garantizar una estabilidad de proceso que permita alcanzar las tolerancias (de pocas décimas de milímetro) y acabados exigidos. En algunas aplicaciones se exige que los conductos tengan un espesor pequeño, lo cual reduce la rigidez del tubo y aumenta la posibilidad de aparición de problemas de vibración. Además, en esta clase de mecanizados largos (de varias horas) es difícil conocer el nivel de desgaste de la herramienta de corte.

Así, el trabajo realizado ha tenido como objetivo controlar el desgaste de la herramienta de corte, a partir de sus niveles de vibración y consumo eléctrico. La medición de la vibración se ha dividido en dos etapas. En primer lugar, se ha caracterizado dinámicamente la máquina con la pieza amarrada. Esto ha permitido conocer las frecuencias naturales del sistema. En segundo lugar, se ha medido, mediante un acelerómetro ubicado en la base de la barra de mandrinado, el nivel de vibración durante el mecanizado de varias piezas tipo. Esto ha permitido identificar

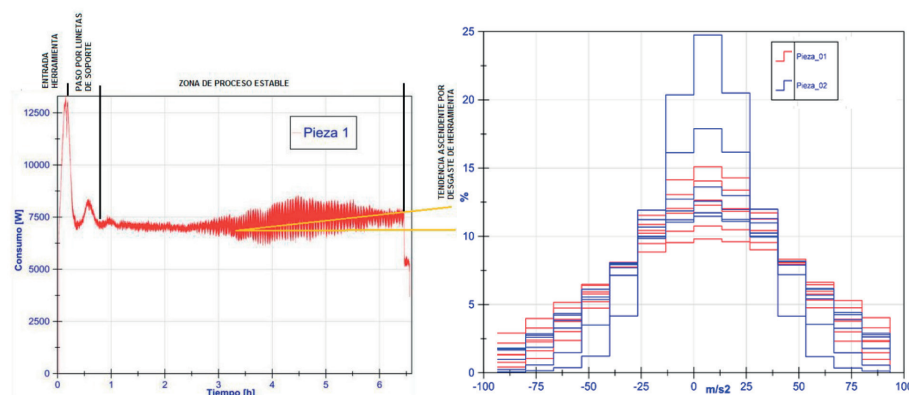


Fig. 6: Consumo eléctrico durante el mandrinado (izquierda) y kurtosis de la señal de aceleración para 2 piezas en diferentes momentos del mandrinado (derecha)

las frecuencias y amplitudes de vibración, diferenciando así las frecuencias de proceso respecto de las del sistema.

El análisis de estas dos señales (aceleración y consumo), almacenadas en la Plataforma de Adquisición de Datos, ha permitido diferenciar y clasificar los fenómenos ocurridos durante el proceso de mandrinado. En la Fig. 6 (izquierda) se muestra la división básica de una señal típica del valor del consumo durante la operación de mandrinado de 6 h de duración de un tubo de 6 m de longitud y 550 mm de diámetro. Se observa que el consumo presenta valores inicialmente elevados hasta que se estabiliza el proceso. El paso de la herramienta por la zona de las lunetas de apoyo del tubo genera también un aumento del consumo significativo. Posteriormente, se alcanza una fase estable del consumo, que va aumentando ligeramente, pudiéndose asociar este aumento con el desgaste de la herramienta.

En cuanto al análisis de la señal de aceleración durante la fase estable del proceso (donde no se dan vibraciones naturales del sistema), ha consistido en obtener valores estadísticos y analizar su evolución. El valor empleado para esto ha sido la kurtosis [6]. Ésta presenta una evolución hacia una forma más apuntada (Fig. 6, derecha) a medida que el nivel de desgaste aumenta, de forma que permite estimar si la herramienta se va desgastando durante la operación. Así, un aumento dado del consumo y la forma de kurtosis sirve para conocer el estado de la herramienta.

A través de la interfaz de usuario, el operario puede identificar las distintas zonas de mandrinado y fijar sus umbrales de referencia. Éstos se calculan mediante el análisis histórico de los datos almacenados en el servidor.

La validación del modelo se ha realizado mediante mandrinados profundos con condiciones de corte más agresivas de

lo habitual, en los cuales se ha observado un aumento tanto de consumo eléctrico como de kurtosis en coherencia con el mayor desgaste de la herramienta.

4. CONCLUSIÓN

Los cinco casos de mecanizado objeto de estudio muestran cómo el análisis y monitorización de variables de proceso almacenadas en un servidor, obtenidas gracias a una alta sensorización en la máquina y en la pieza, permite mejorar los procesos actuales y futuros de mecanizado, para ámbitos industriales muy diversos.

Se observa que estos casos de mejora son coherentes con las áreas en que Big Data puede mejorar los procesos productivos. Así, se ha demostrado que es posible optimizar el uso de herramientas de corte, mediante la previsión de su vida útil (en el torneado de series largas y repetitivas como las del sector de automoción, en el mandrinado profundo de tubos de bajos espesores y estrictas tolerancias). Se ha demostrado que es posible también maximizar la calidad y eficiencia de una línea de producción ferroviaria, contrarrestando la generación y propagación de defectos, gracias a una mejor comprensión de su funcionamiento a partir del estudio de datos holísticos procedentes de varios sensores y máquinas de la línea. Además, se ha demostrado que el uso de técnicas estadísticas de variables de proceso permite clasificar operaciones de rectificado dentro de una normalidad sobre la cual comparar y validar procesos futuros. En el caso de piezas realizadas por fabricación aditiva, las cuales presentan un alto grado de incertidumbre sobre su estado e integridad superficial, el uso de sistemas de visión artificial facilita la puesta a punto del mecanizado, y después el análisis de las variables de proceso permite caracterizarlo y establecer sus criterios de normalidad, proveyendo un mejor servicio

para los clientes que optan por esta forma emergente de fabricación.

REFERENCIAS

- [1] Brecher C, Klocke F, Schmitt R, Schuh G. Internet of Production für agile Unternehmen: AWK Aachener Werkzeugmaschinen-Kolloquium. Aachen. Aprimus Verlag. 2017. 496p. ISBN: 978-3-86359-512-8.
- [2] Kagermann H, Wahlster W, Helbig J. Recommendations for Implementing the Strategic Initiative INDUSTRIE 4.0. National Academy of Science and Engineering. 2013. 82p.
- [3] Auschitzky E, Hammer M, Rajagopaul A. How big data can improve manufacturing. McKinsey & Company. 2014.
- [4] Xu, Xun. "Machine Tool 4.0 for the New Era of Manufacturing". The International Journal of Advanced Manufacturing Technology. Vol. 92(5) p.1893-1900. 2015. DOI: <https://doi.org/10.1007/s00170-017-0300-7>.
- [5] Zheng P, Wang H, Sang Z, et al. "Smart Manufacturing Systems for Industry 4.0: Conceptual Framework, Scenarios, and Future Perspectives". Frontiers of Mechanical Engineering. Vol. 13(2) p.137-150. 2018. DOI: <https://doi.org/10.1007/s11465-018-0499-5>
- [6] Ambhore N, Kamble D, Chincharikar S, Wayal V. "Tool Condition Monitoring System: A Review". Materials Today: Proceedings. Vol. 2 p.3419-3428. 2015. DOI: <http://dx.doi.org/10.1016/j.matpr.2015.07.317>.
- [7] Eger F, Coupek D, Caputo D, et al. "Zero Defect Manufacturing Strategies for Reduction of Scrap and Inspection Effort in Multi-Stage Production Systems". Procedia CIRP. Vol.67 p.368-373. 2018. DOI: <https://doi.org/10.1016/j.procir.2017.12.228>.
- [8] Gryllias K, Kilundu B, Devos S, et al. "Condition Monitoring of Gear Grinding Processes". International Conference Surveillance. Vol. 9. INSA Euro-Mediterranean. 2017.

AGRADECIMIENTOS

Los autores agradecen el apoyo recibido desde el Gobierno Vasco a través de la Agencia Vasca de Desarrollo Empresarial (SPRI), el proyecto PROCODA (KK-2019/00004) del programa ELKARTEK, y los proyectos para el apoyo a la I+D Empresarial INSIGHTS del programa HAZITEK 2016 y KENTU del programa HAZITEK 2018.