

(07-006) - Automatic detection of sheet metal curvature using artificial vision techniques

García González, Javier ¹; Vergara González, Eliseo Pablo ¹; Alonso Iglesias, Guillermo ¹; Rodríguez Montequín, Vicente ¹; Mesa Fernández, José Manuel ¹

¹ Universidad de Oviedo

In the manufacturing of large tanks for the oil and gas industry, a considerable challenge arises in precisely measuring the curvature of each sheet metal. Each sheet is meticulously crafted into a curved form, ultimately becoming a section. These sections are subsequently assembled to attain the final shape of the tanks. Ensuring the requisite precision in the fabrication of these substantial tanks requires continuous oversight.

At present, this measurement process entails manual inspection using contact templates, resulting in a sampling-based evaluation dependent on the subjective judgment of operators. This methodology presents notable disadvantages, including prolonged manufacturing durations, heightened occupational hazards, and complexities in knowledge management for the company.

The incorporation of artificial vision, coupled with machine learning techniques, entails an improvement in efficiency. By combining photographic images with LiDAR technology, real-time and non-contact measurements are realized, minimizing disruptions in the production process.

In adherence to this methodology, a case study is executed in partnership with an international company within the gas and oil sector, showcasing the system's efficacy in attaining a precision of 1 centimeter through the utilization of cost-effective equipment. This achievement is realized without compromising the operational conditions of the facility.

Keywords: artificial vision; machine learning; LiDAR; bending process; non contact inspection

Detección automática de la curvatura de chapas metálicas mediante técnicas de visión artificial

Uno de los desafíos inherentes en el proceso de fabricación de depósitos de grandes dimensiones es la medición de la curvatura en cada una de las chapas metálicas, denominadas virolas, que serán ensambladas para la obtención de su forma final. La precisión necesaria para la manufactura de estos voluminosos tanques implica una supervisión constante.

En la actualidad, esta medición requiere de inspección manual mediante el uso de plantillas por contacto, ocasionando una medición por muestreo basada en el criterio subjetivo de los operarios. Este método presenta desventajas significativas, incluyendo aumento del tiempo de fabricación, mayor riesgo laboral y desafíos en la gestión del conocimiento por parte de la empresa.

La integración del uso de visión artificial junto con técnicas de aprendizaje automático supone una mejora en la eficiencia. Mediante la combinación de imágenes fotográficas y tecnología LiDAR se consigue una medición en tiempo real sin contacto, evitando interrupciones en el proceso productivo.



Bajo este enfoque se realiza un caso de estudio junto con una empresa internacional del sector del gas y el petróleo, demostrando la eficacia del sistema al alcanzar una precisión de 1 centímetro utilizando equipamiento de bajo coste, sin comprometer las condiciones operativas de la planta.

Palabras clave: visión artificial; aprendizaje automático; LiDAR; proceso de curvatura; inspección sin contacto

Correspondencia: Eliseo Pablo Vergara González, vergaraeliseo@uniovi.es

Agradecimientos: Este trabajo se ha realizado con la financiación proporcionada por SEKUENS (Agencia de Ciencia, Competitividad Empresarial e Innovación del Principado de Asturias) e IDESA TRC a través de las Primas Proof Of Concept edición 2022

1.- INTRODUCCIÓN

El proceso de fabricación de elementos cilíndricos a partir de una chapa metálica es un proceso con muy diferentes aplicaciones, que van desde la fabricación de grandes depósitos para el almacenamiento de líquidos y gases, hasta la producción de las diferentes secciones del casco resistente de un submarino, pasando por la fabricación de equipos utilizados en diferentes procesos tanto químicos como industriales - reactores, lavadores de gases, mezcladores, etc.- o de elementos estructurales para sistemas de energía eólica, por citar sólo algunos.

El curvado de la chapa plana hasta obtener un elemento cilíndrico se realiza mediante una máquina curvadora, la cual está formada por tres cilindros. La acción de estos tres cilindros logra que, mediante varias pasadas, la chapa inicialmente plana, acabe curvándose hasta el punto de poder soldar sus extremos, formando así un cilindro denominado "virola".

Figura 1: Curvado de una chapa para producir una virola



Durante el proceso de curvado la medición de la curvatura que va adoptando la chapa se realiza mediante el uso de una serie de plantillas curvas que poseen la curvatura correspondiente al de la circunferencia de la virola que se pretende lograr, de tal forma que el operario verifica en cada momento la curvatura que se va logrando. Esta medición

es discreta, ya que no se puede hacer un barrido completo del 100% de la superficie de la virola por una cuestión de tiempo de proceso, por lo que la medición se hace por muestreo.

Figura 2: Operario comprobando la curvatura obtenida tras una pasada inicial entre los cilindros



Aunque preciso, este método presenta una serie de desventajas, entre las que destacan la gestión del conocimiento y el tiempo de proceso dedicado a la comprobación manual de la curvatura, así como la extensión de la comprobación.

La deformación que se puede producir en la virola es uno de los problemas principales, puesto que al tratarse de elementos de gran tamaño todos los procesos que se realizan sobre ella pueden provocarlas. Los requisitos contractuales exigidos por los clientes hacen que el mantenimiento de las dimensiones sea una característica fundamental que se ha de verificar de forma continuada durante el ciclo de producción.

Esta comunicación describe el proceso seguido para diseñar, desarrollar y validar un sistema digital sin contacto que permite realizar de forma automática la comprobación del curvado de las virolas, en la fase de recilindrado, sin intervención humana, y con la restricción de que este sea de muy bajo coste. El proyecto realizado tiene el carácter de prueba de concepto.

2.- SISTEMA BASADO EN VISIÓN ARTIFICIAL

Nos encontramos ante un caso evidente de aplicación de técnicas de visión artificial, pero, por desgracia, los sensores de las cámaras digitales sufren serias limitaciones en entornos industriales si estos no están lo suficientemente controlados, caso que no es viable en esta aplicación por las características propias de la planta objeto del estudio y del movimiento de los materiales dentro de ella.

2.1.- Limitaciones de los sensores digitales en entornos industriales

Estas limitaciones de los sensores digitales están relacionadas, básicamente, con la escasa iluminación y que pudiera dar lugar a imágenes que no tuvieran la calidad y resolución necesaria para la aplicación, al menos, sin incorporar un sistema de

iluminación adicional, algo que, como punto de partida, se considera poco interesante, ya que podría molestar el trabajo habitual en la planta como consecuencia de posibles deslumbramientos, además del gasto de energía y de coste que su instalación conllevaría, todo ello sin contar con la necesaria disponibilidad de espacio en el lugar apropiado.

Entre estas limitaciones podemos destacar las siguientes:

Limitación por contraste de luces y bajo rango dinámico. Debe tenerse en cuenta que, aunque la iluminación en una planta industrial sea la ideal para el trabajo de los operarios bajo cualquier condición, los sensores digitales que incorporan las cámaras de fotografía y de vídeo, ven la “realidad” de una forma muy diferente. Podemos decir que un ojo humano sano es capaz de identificar hasta 15 pasos de iluminación. Por el contrario, una moderna cámara de fotografía puede reconocer, únicamente, entre 5 y 8 pasos de iluminación. Es decir, el *rango dinámico* del sensor es muy inferior al del ojo humano

Por otro lado, en una nave industrial, la iluminación acostumbra a tener grandes contrastes desde el punto de vista de un sensor digital, lo que acentúa el problema anteriormente citado.

Limitación por bajo nivel de iluminación. Además del problema del rango dinámico, existe el problema del propio nivel de iluminación que el sensor capta. Si este nivel de iluminación es bajo aparecerá un problema de ruido electrónico en las imágenes que degradará las mismas hasta hacerla inutilizable.

Este ruido, que distorsiona las imágenes y reduce su calidad, es debido, entre otras fuentes, a la corriente inversa que circula por el circuito de cada fotocelda del sensor de la cámara, que en situaciones en que el número de fotones que alcanza al sensor es bajo, esta corriente puede llegar a ser casi del mismo orden que la corriente principal detectada por el sensor.

Limitación por tamaño del sensor. Ya se ha visto como un número escaso de fotones puede hacer que la calidad de la imagen se degrade hasta hacerla inutilizable.

Esto tiene una relación directa con el tamaño del propio sensor. Así, un sensor de mayor tamaño tendrá fotoceldas -básicamente un fotodiodo- de mayor tamaño, logrando que en condiciones de poca luz cada fotodiodo capte un número de fotones suficiente para evitar el ruido electrónico, por lo que su relación señal/ruido será alta

Por el contrario, sensores de pequeño tamaño tendrán, generalmente, fotoceldas de pequeño tamaño, por lo que tendrán dificultades para captar un número suficiente de fotones que impidan que se degrade la calidad de la imagen. En este caso, la relación señal ruido, será baja.

Limitación por distancia al objeto. Dejando de lado la posibilidad de que la planta no disponga de suficiente iluminación también entraría en juego otro factor: la distancia entre la cámara y el objeto de interés.

Dado que el sensor de una cámara dispondrá de un determinado número de fotoceldas, en caso de que este sensor se encuentre a una distancia mayor, cada fotocelda abarcará una mayor superficie de la imagen, resultando en una menor resolución.

2.2.- Formas de superar estas limitaciones

Si bien parecería que todas estas limitaciones impedirían el uso de un equipo de visión artificial en esta aplicación, al menos sin un sistema de iluminación adicional, lo cierto es que es posible utilizar algunas estrategias para limitar en lo posible estas.

A.- Para superar la limitación del reducido rango dinámico, debe seleccionarse una cámara que posea la posibilidad de tomar imágenes de alto rango dinámico HDR (*High Dynamic Range*).

B.- Para superar tanto la limitación del efecto debido al bajo nivel de iluminación como a la limitación del tamaño del sensor, ya que su efecto es el mismo: producir ruido electrónico que merma la calidad de la imagen, debe seleccionarse una cámara con un sensor lo más grande posible, y si no es posible, el sensor debería tener un número reducido de megapíxeles. Para un sensor típico actual, un número adecuado debería estar entre 5 y 8 Mpx.

C.- Para superar la limitación de la distancia a la virola, poco puede hacerse más allá que tratar de buscar la mejor localización física para la cámara.

2.3.- Elección del equipo

Se pueden apreciar tres tipos de cámaras utilizables en sistemas de visión.

En primer lugar, se consideró un tipo de cámaras de muy bajo precio, pero en este caso se presentó la duda de la resistencia que pudieran tener en un entorno industrial.

En otro extremo se consideraron cámaras de mayores prestaciones sin embargo no se consideraron como una opción interesante. Su alto precio tampoco las convierte en las mejores candidatas de acuerdo con el contexto y planteamiento del proyecto como prueba de concepto.

Finalmente, se analizaron cámaras de vídeo cuya finalidad acostumbra a ser la video vigilancia, las cuales, dado que suelen ser instaladas en exteriores, ya incorporan o viene acompañadas de algún tipo de sistema físico tanto para su instalación como para su protección.

Figura 3: Cámara BOSCH NDE-5703-A. A la izquierda sin domo protector.



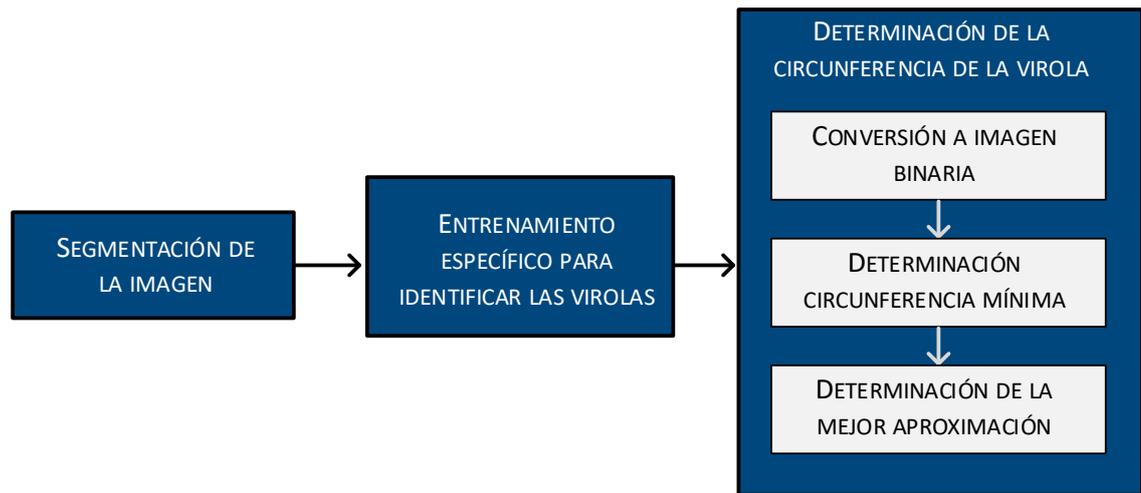
De entre ellas se eligió la cámara **NDE-5703-A**, de la marca **BOSCH**. Esta cámara se trata de una cámara de vigilancia profesional para realizar seguimiento en exteriores, que monta un sensor de 1/2,7". Posee un objetivo zoom de 3,2-10,5mm, y una protección IP66, además de contar con un domo de protección.

3.- METODOLOGÍA DE TRABAJO

Considerando la problemática abordada, se estimó que el flujo de trabajo adecuado para obtener el mejor modelo basado en visión artificial debía seguir el siguiente esquema:

- A.- Segmentación de la imagen.
- B.- Entrenamiento específico para identificar las virolas.
- C.- Determinación de la circunferencia de las virolas.

Figura 4: Esquema de la metodología de trabajo aplicada al problema



4.- DESARROLLO DEL MODELO

En aplicación de la metodología anterior, el modelo se ha desarrollado siguiendo los pasos que a continuación se explican más detalladamente.

4.1.- Segmentación de la imagen

Este proceso de segmentación consiste en dividir la imagen en sus partes constituyentes hasta un nivel de subdivisión tal en el que se aíslen las regiones u objetos de interés.

No existe un criterio único a la hora de clasificar los diferentes tipos de segmentación existentes, pero se considera que los principales podrían ser la **segmentación basada en regiones**, como es el caso de las librerías *OpenCV*, *scikit-image*, *SimpleCV* y los algoritmos SLIC (*Simple Linear Iterative Clustering*) (Achanta et al., 2012) y *K-means*; la **segmentación asistida** que implica la interacción humana, como es el caso de *CVAT*, *Labelme*, *Labelbox*, *RectLabel* y *VGG Image Annotator (VIA)*; la **segmentación semántica**, que asigna etiquetas semánticas a cada píxel de la imagen, sobresaliendo TensorFlow, PyTorch, Keras, OpenCV y redes neuronales convolucionales (CNN) como U-Net y Fully Convolutional Networks (FCN) (Long et al., 2015); la **segmentación de instancia**, que identifica y diferencia instancias individuales de un objeto. Se utilizan comúnmente *Detectron2* y *OpenCV* para la aplicación de Mask R-CNN (He et al., 2018) y YOLACT; y, finalmente, la **segmentación panóptica**, una aproximación avanzada que combina la segmentación semántica e instanciada (*MMDetection* y *Detectron2*)

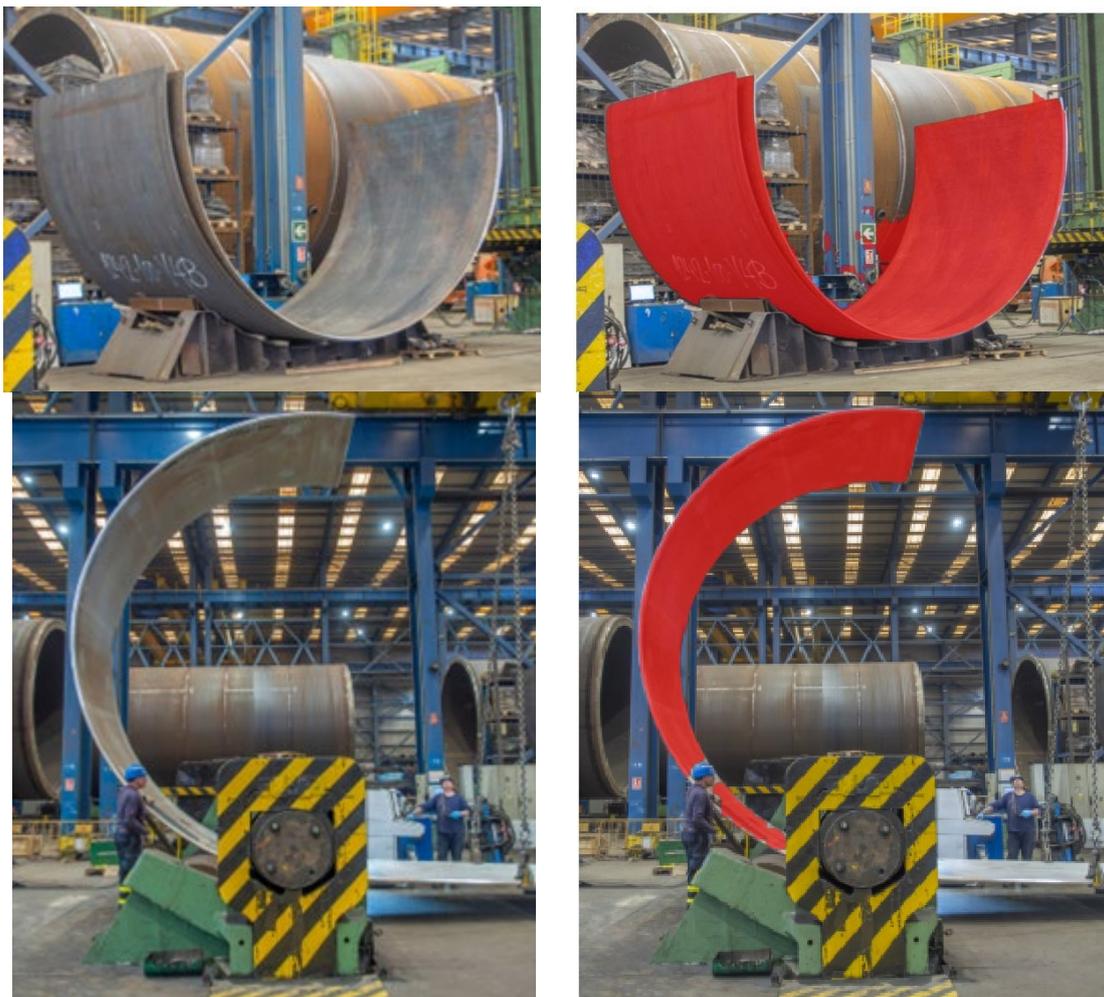
En consonancia con las constantes y rápidas innovaciones en este campo, se ha considerado que la opción más adecuada es integrar todas estas tecnologías en torno a un punto común como **SA** (*Segment Anything*) (Kirillov et al., 2023), el cual tendrá que ser convenientemente adaptado al caso particular de la presente prueba de concepto.

El modelo SA es un modelo fundacional para segmentación compuesto por tres módulos principales: un codificador de imágenes, un codificador de indicaciones y un decodificador de máscaras. La codificación de la imagen junto con la codificación de posibles indicaciones, como pueden ser límites a tener en cuenta o zonas a excluir, permiten al decodificador generar las máscaras de segmentación necesarias. Este tipo de modelos son entrenados con una gran cantidad de datos no etiquetados mediante aprendizaje autosupervisado, lo que permite su posterior adaptación a una amplia gama de tareas más específicas.

4.2.- Entrenamiento

La segmentación de la imagen, a pesar de basarse en un algoritmo de visión artificial lo suficientemente capaz de identificar los principales elementos en una imagen, desconoce lo que es una “virola”, por lo que se hace necesario personalizar el modelo mediante el entrenamiento basado en imágenes de las virolas.

Figura 5: Ejemplos del resultado del entrenamiento del algoritmo de segmentación



Para el entrenamiento se han utilizado diversas fotografías capturadas durante las visitas a las instalaciones. En dichas imágenes se encuentran virolas vistas desde diferentes puntos de vista con el fin de que el sistema permita reconocer una virola en cualquier posición de la cámara.

4.3.- Determinación de la circunferencia de la virola

Aunque la segmentación resulta suficientemente precisa, es cierto que es un proceso que no es sencillo y puede agregar píxeles erróneos.

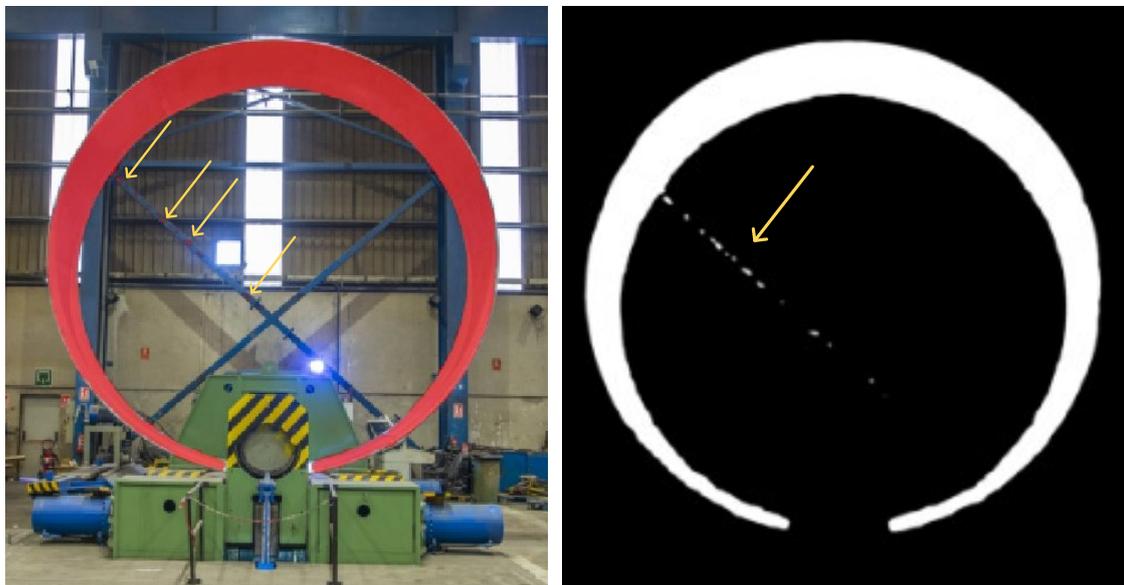
Antes de proceder a la medición de la curvatura de la virola, es crucial eliminar cualquier región errónea identificada en la segmentación mediante la combinación de diversas técnicas de refinamiento. Este paso es fundamental para garantizar la precisión y fiabilidad de los resultados de medición.

Conversión a imagen binaria

Inicialmente, transformar la imagen en una representación binaria, resaltando los píxeles detectados por el algoritmo de segmentación en blanco y el resto en negro, simplifica la eliminación de elementos erróneamente categorizados como parte de la virola.

Con la imagen convertida a formato binario se procede a la identificación de todos los contornos presentes en la misma, sin discriminar su forma, con el propósito de obtener una visión completa y detallada de la estructura representada en la imagen.

Figura 6: Conversión a imagen binaria, a partir de la imagen segmentada, donde se observan píxeles que no corresponden a la virola, sino a la estructura posterior de la nave

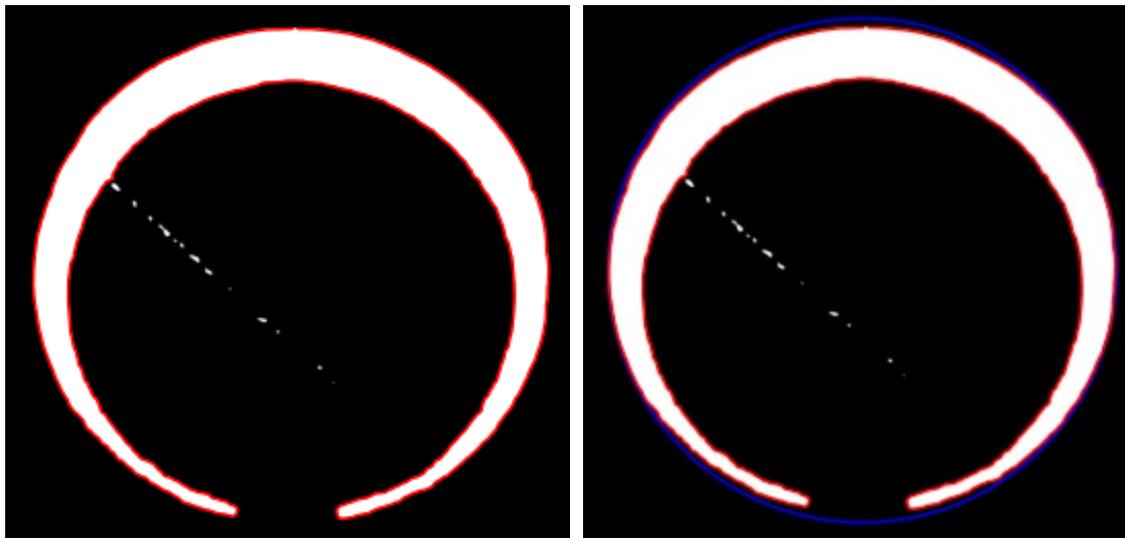


Determinación de la circunferencia mínima

La utilización de la mínima circunferencia como criterio de selección se basa en el cálculo del círculo mínimo que encierra todo el contenido presente en una imagen. Como resultado, se obtienen las coordenadas del centro y el radio del círculo que confinan todos los contornos disponibles. Este círculo mínimo está diseñado para rodear el

contenido de forma óptima, lo que implica que su borde toca los puntos más externos de los contornos disponibles.

Figura 7: Detección de contornos y aplicación del criterio de mínima circunferencia (azul)



Determinación de la mejor aproximación

Al llegar a este punto, tras completar la secuencia de pasos anteriores, se obtienen los puntos finales que delimitan la superficie de la virola. Estos puntos se utilizan para verificar si las mediciones de los diámetros cumplen con los estándares de circularidad establecidos durante la fase de diseño de la estructura.

Para ello será necesario detectar en base a los puntos de interés la superficie curva que mejor se adapta y establecer una correspondencia entre los píxeles de la imagen y una unidad de longitud del sistema métrico, utilizando una referencia conocida presente en la misma fotografía.

Utilizando esta circunferencia ajustada se lleva a cabo una comparación con el objetivo de diseño definido durante el proceso de fabricación. Si dicha comparación ofrece un error que supera la tolerancia admitida, es necesario proceder a un análisis adicional para identificar las posibles causas de la discrepancia.

Una vez realizada la conversión de píxeles a centímetros en base a la situación conocida, se obtiene como resultado un error de +1,5 cm en la comparación del diámetro esperado respecto al medido por el modelo de visión artificial.

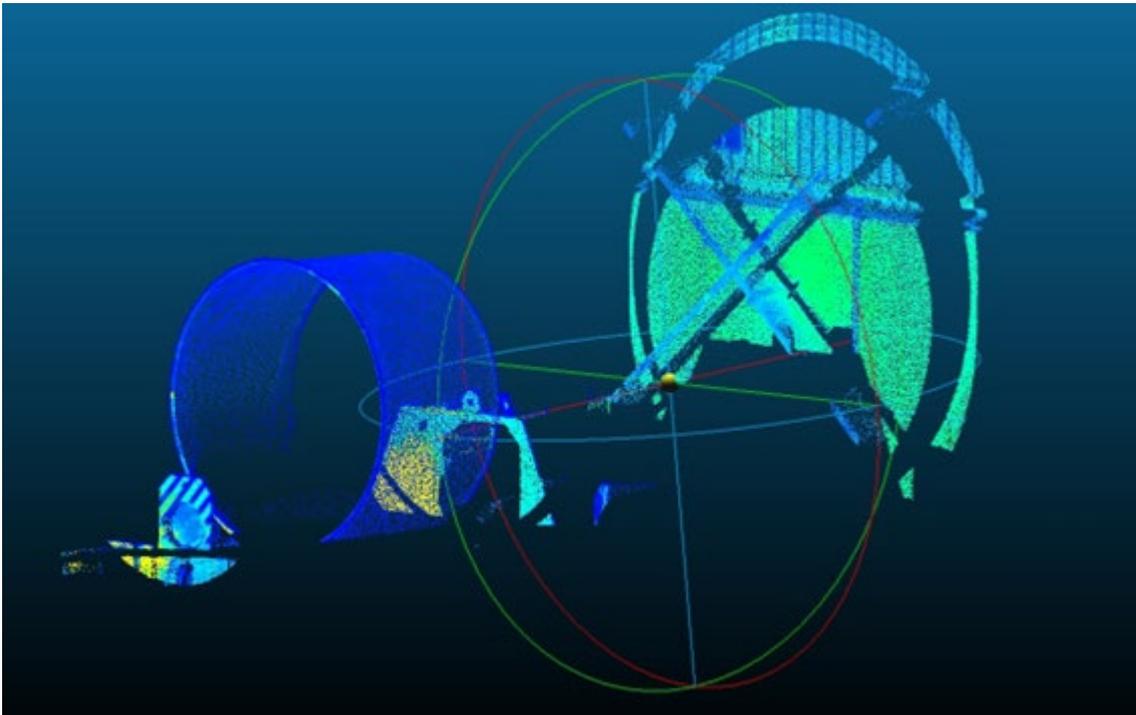
Por tanto, con el uso de técnicas de procesamiento de imágenes de vanguardia y algoritmos de aprendizaje profundo el modelo logra interpretar y procesar datos visuales de manera sistemática, ofreciendo resultados fiables, pero sin llegar al nivel de precisión necesaria para poder automatizar actualmente el proceso industrial analizado, ya que requiere una precisión más cercana a las unidades de milímetro que a las unidades de centímetro.

5.- VALIDACIÓN DEL MODELOS MEDIANTE SISTEMA LIDAR

Con el fin de confirmar la calidad de las mediciones mediante este sistema se procedió a realizar un análisis mediante un sistema LiDAR (*Light Detection And Ranging*) que

utiliza la luz láser para obtener una muestra densa de la superficie de los objetos produciendo mediciones en los ejes X, Y y Z.

Figura 8: Imagen 3D obtenida por el LiDAR de la maquina de recilindrado y la virola



Se utilizó para ello un equipo LiDAR Tele-15 de la empresa Livox. La tecnología utilizada por el LiDAR Livox Tele-15 permite una nube de puntos de alta densidad que es aproximadamente cinco veces más densa en el mismo período que otro modelo equivalente del mismo fabricante.

Las trayectorias y patrones de barrido son únicos, es decir, estas trayectorias de escaneo no se repiten durante el uso, por lo que se utiliza el término “patrones de escaneo no repetitivos”.

En comparación con los métodos de barrido mecánico habituales aplicados en la mayoría de los sensores LiDAR del mercado, los “patrones de escaneo no repetitivos” ofrecen una cobertura del FOV que aumenta significativamente con el tiempo al no ser repetitivos.

Se debe tener en cuenta que, debido a la complejidad del problema, se plantearon únicamente las técnicas y algoritmos que han demostrado ofrecer resultados relevantes y significativos en la identificación de los patrones específicos de la virola dentro del conjunto de datos del LiDAR, descartando el resto de las técnicas estudiadas por el Grupo de Investigación:

Para la búsqueda de soluciones destacaron: **RANSAC** (*Random Sample Consensus*); **algoritmo de Levenberg-Marquardt** (LMA) (Gavin, 2022); **algoritmo de clustering DBSCAN** (*Density-based spatial clustering of applications with noise*) (Deng, 2020); **mínimos cuadrados**; y **redes neuronales convolucionales 3D** (3D CNN) (Rao & Liu, 2020)

La Figura 8, muestra la nube de puntos capturada por el LiDAR. Se observa la propia virola sobre la máquina de recilindrado, así como la parte posterior de la planta, donde se aprecia la “cruz de San Andrés” de la estructura de la nave.

Utilizando este sistema se obtuvieron mediciones que confirmaban la calidad de las mediciones realizadas mediante e modelo de visión artificial desarrollado.

6.- CONCLUSIONES

Se han desarrollado modelos de monitorización de la circularidad de las virolas para la solución tecnológica propuesta y comprobada la validez de un sistema basado en visión artificial para determinar la circularidad de la cara frontal de la virola. El modelo desarrollado es capaz de determinar, debido a sus bajos tiempos de computación, dicha circularidad en tiempo real, lo que permitiría al operario tomar decisiones durante el propio proceso de recilindrado.

Se ha demostrado la viabilidad de la propuesta para un proceso industrial como el aquí analizado, sin necesidad de ningún cambio estructural en la planta ni influencia negativa sobre el propio flujo de trabajo de los operarios.

Sin embargo, se ha podido comprobar que la utilización de una cámara de bajo coste, como la aquí propuesta, en un entorno no controlado -es decir, sin una iluminación dedicada, ni un fondo homogéneo y sin contraste- genera una serie de problemas en la calidad de las imágenes no siempre sencillos de solucionar en un entorno industrial.

5.- REFERENCIAS

Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., & Süsstrunk, S. (Eds.). (2012). SLIC Superpixels Compared to State-of-the-art Superpixel Methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. <https://doi.org/10.1109/TPAMI.2012.120>

Deng, D. (2020). DBSCAN Clustering Algorithm Based on Density. *2020 7th International Forum on Electrical Engineering and Automation (IFEEA)*, 949-953. <https://doi.org/10.1109/IFEEA51475.2020.00199>

Gavin, H. P. (2022). *The Levenberg-Marquardt algorithm for nonlinear least squares curve-fitting problems*.

He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2018). *Mask R-CNN* (arXiv:1703.06870). arXiv. <https://doi.org/10.48550/arXiv.1703.06870>

Kirillov, A., Mintun, E., Ravi, N., Mao, H., Rolland, C., Gustafson, L., Xiao, T., Whitehead, S., Berg, A. C., Lo, W.-Y., Dollár, P., & Girshick, R. (2023). *Segment Anything* (arXiv:2304.02643). arXiv. <http://arxiv.org/abs/2304.02643>

Long, J., Shelhamer, E., & Darrell, T. (2015). *Fully Convolutional Networks for Semantic Segmentation* (arXiv:1411.4038). arXiv. <https://doi.org/10.48550/arXiv.1411.4038>

Rao, C., & Liu, Y. (2020). *Three-dimensional convolutional neural network (3D-CNN) for heterogeneous material homogenization* (arXiv:2002.07600). arXiv. <https://doi.org/10.48550/arXiv.2002.07600>.

**Comunicación alineada con los
Objetivos de Desarrollo
Sostenible**

