

Sensor virtual inteligente para la inspección de calidad en sistemas robóticos de dispensación de adhesivos

Alfredo Rodríguez-Magdalena^{a,b,*}, Ignacio Díaz^b, Jose María Enguita^b

^aDepartamento de IT en Normagrup Technology. Parque tecnológico de Asturias. Calle Ablanal 1, 33428 Llanera (Asturias), España

^bÁrea de Ingeniería de Sistemas y Automática de la Universidad de Oviedo, Campus Universitario, 33204 Gijón, España

To cite this article: Rodríguez-Magdalena, A., Díaz I., Enguita J.M. 2025. Intelligent Virtual Sensor for Quality Inspection in Robotic Adhesive Dispensing Systems. Revista Iberoamericana de Automática e Informática Industrial 22, 241-252. <https://doi.org/10.4995/riai.2025.22961>

Resumen

La automatización de procesos de producción conlleva la eliminación de la supervisión humana directa, lo que exige el desarrollo de sistemas capaces de analizar la calidad de manera autónoma y en tiempo real. En este contexto, se propone el diseño de un sistema inteligente de inspección para la dispensación de adhesivo en un proceso de montaje de luminarias. El sistema parte de la observación de que los fluidos no newtonianos, como los utilizados en estos procesos, presentan una dinámica compleja influenciada por la reología, la gravedad y la geometría de aplicación, pudiendo manifestar comportamientos inestables que resultan en una deposición irregular causando ineficiencias. La solución propuesta se basa en un sistema de perfilometría láser 3D integrado sobre una célula robotizada, en la que un brazo manipulador desplaza el chasis de la luminaria bajo una válvula de dispensación de adhesivo. A partir de los perfiles generados durante el proceso, se extraen características representativas mediante técnicas de ingeniería de características y/o reducción de dimensionalidad. Estas se utilizan como entrada para un clasificador supervisado cuyo objetivo es evaluar, en tiempo real, si la dispensación se está realizando correctamente. En conjunto, se presenta una solución viable y escalable para entornos de fabricación flexible, orientada a la inspección autónoma de calidad en procesos de montaje robotizado.

Palabras clave: Robots manipuladores, detección y diagnóstico de fallos, supervisión de las condiciones, garantía de calidad y mantenimiento, instrumentos virtuales, sistemas N-dimensionales, percepción y detección, sistemas de fabricación flexible.

Intelligent Virtual Sensor for Quality Inspection in Robotic Adhesive Dispensing Systems

Abstract

The automation of production processes entails the elimination of direct human supervision, requiring the development of systems capable of autonomously assessing quality in real time. In this context, an intelligent inspection system is proposed for monitoring adhesive dispensing in a luminaire assembly process. The system is based on the observation that non-Newtonian fluids, such as those used in these processes, exhibit complex dynamics influenced by rheology, gravity, and application geometry, potentially leading to unstable behaviors and irregular deposition that compromise efficiency. The proposed solution employs a 3D laser profilometry system integrated into a robotic cell, where a manipulator arm moves the luminaire chassis beneath an adhesive dispensing valve. From the profiles acquired during the process, representative features are extracted through feature engineering and/or dimensionality reduction techniques. These are used as input to a supervised classifier designed to evaluate, in real time, whether the dispensing is being performed correctly. Overall, the work presents a scalable and practical solution for flexible manufacturing environments, aimed at autonomous quality inspection in robotic assembly processes.

Keywords: Robots manipulators, fault detection and diagnosis, condition monitoring, quality assurance and maintenance, virtual instruments, N-dimensional systems, perception and sensing, flexible manufacturing systems.

*Autor para correspondencia: a.rodmagdalena@gmail.com

Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

1. Introducción

El montaje de luminarias representa un caso de uso del paradigma de la fabricación flexible, ya que pueden encontrarse en una amplia variedad de tamaños, colores y diseños adaptados a diferentes aplicaciones, desde iluminación de emergencia, hasta iluminación de instalaciones arquitectónicas. Además de su diversidad en formas, su montaje puede realizarse mediante distintos métodos que garantizan su correcta integración en los entornos industriales y comerciales. Existen diversas técnicas de ensamblaje en la producción de luminarias, entre las que se encuentran los métodos de fijación mecánica, el encaje a presión y el uso de adhesivos (Adargoma Suarez Garcia et al., 2021). En este estudio, se considerará el ensamblaje mediante la última opción mencionada.

Dentro de los adhesivos utilizados en aplicaciones industriales, se pueden encontrar diversas formulaciones, tales como epóxicos, acrílicos y siliconas (Derebail et al., 1994). Para el ensamblaje de luminarias, los adhesivos de silicona presentan ventajas significativas en términos mecánicos, como su alta resistencia térmica, su flexibilidad estructural y su capacidad para absorber vibraciones, lo que contribuye a la durabilidad del sistema de iluminación. No obstante, la dispensación de estos compuestos adherentes presenta retos asociados a su viscosidad y comportamiento reológico, lo que puede afectar la calidad del cordón depositado si no se controla adecuadamente el proceso.

Este trabajo propone una solución robótica que automatiza la aplicación del material de unión en la línea de producción. Sin embargo, la ausencia de supervisión humana introduce desafíos adicionales que deben abordarse. En primer lugar, la aplicación del adhesivo debe realizarse con alta precisión, asegurando que el cordón se sitúe en el centro de la pista de deposición para garantizar la correcta adhesión de las tiras LED al chasis de la luminaria. Además, es fundamental controlar la cantidad de material depositado: un volumen insuficiente comprometería la adherencia mecánica, mientras que un exceso podría provocar derrames no deseados, afectando la funcionalidad y vida útil del producto. Por el otro lado, desde un punto de vista de diseño robótico, el sistema debe ser capaz de generar trayectorias adaptadas a las dimensiones específicas del chasis de la luminaria de tal forma que la silicona quede correctamente depositado en las zonas donde posteriormente habrá un circuito de iluminación LED.




Figura 1: Representación del sistema sujeto al estudio

El objetivo de este estudio es diseñar e implementar un sistema de control de calidad que determine si la dispensación se está realizando correctamente sobre el sistema mostrado en la Figura 1, proporcionando una base para futuras estrategias de control en lazo cerrado.

Las variables utilizadas para la inspección del proceso de distribución de adhesivos dependen de la tecnología de dispensación empleada (Burga and Tausek, 2003) y se derivan de principios de mecánica de fluidos como la presión, el caudal o parámetros reológicos. A través de ellos se permite modelar el comportamiento del adhesivo en distintas condiciones de operación (Chen et al., 2000; Chen, 2009). Estas variables incluyen la viscosidad del adhesivo, la presión de dispensación, el caudal de salida y la estabilidad del cordón depositado. Algunos estudios han propuesto la inducción de vibraciones en el fluido como mecanismo para controlar sus propiedades reológicas y mejorar la precisión en la deposición (Vaish et al., 2018). Sin embargo, estas estrategias suelen verse afectadas por la idealización de los modelos teóricos y la presencia de perturbaciones externas que pueden comprometer la estabilidad del sistema (Bogert et al., 2024; Razban et al., 1991).

Además de las variables derivadas de la mecánica de fluidos, existen enfoques de inspección centrados en la evaluación geométrica del cordón dispensado, algunos de los cuales son compartidos con técnicas desarrolladas en el ámbito de la inspección de soldaduras. En ambos dominios, resulta crítico monitorizar la continuidad, la forma y la estabilidad del cordón aplicado. Por ello, se han explorado métodos como la visión artificial con iluminación estructurada (Wang, 2024; Rout et al., 2019), la interferometría láser (Javadi et al., 2020; Iakovou et al., 2005) o la inspección ultrasónica (Vasilev et al., 2021), todos ellos comúnmente apoyados en algoritmos heurísticos para la detección de defectos. En este trabajo se opta por el uso de sensores láser de perfiles, que permiten caracterizar con alta precisión la morfología del adhesivo en términos de altura, anchura y continuidad, facilitando así el desarrollo de sistemas de supervisión automática y control en lazo cerrado basados en descriptores geométricos (Razban et al., 1995; Davies et al., 1996; Cruz et al., 2020).

La principal contribución de este trabajo consiste en el desarrollo de un sistema de clasificación basado en sensores de perfilometría láser 3D, orientado a monitorizar el estado de la dispensación de adhesivo con mayor adaptabilidad y precisión que los enfoques heurísticos tradicionales. El sistema propuesto permite detectar, en tiempo de ejecución, si el proceso se está realizando correctamente, abriendo la posibilidad de implementar en el futuro estrategias de control en lazo cerrado. Asimismo, proporciona una base para la toma de decisiones sobre la calidad del producto durante el montaje, como el descarte automático de piezas defectuosas o su reconducción a un estado válido que permita continuar con el proceso productivo.

El método planteado se ha diseñado para operar en líneas de ensamblaje robotizadas donde se dispensa adhesivo no newtoniano sobre bandejas de geometría conocida. Las condiciones operativas empleadas (presión, velocidad y distancia) reflejan valores habituales en planta. El modelo ha sido entrenado para detectar defectos relevantes a nivel de producción, como una deposición deficiente o la ausencia de adhesivo. Su generalización a otras geometrías o escenarios requeriría un nuevo entre-

namiento con datos específicos, aunque no depende de parámetros reológicos del material, lo que facilita su adaptación a distintos adhesivos.

Este artículo está organizado como sigue. En la Sección 2, se detallan los materiales empleados para el desarrollo del prototipo robótico. En la Sección 3 se desarrollará el agente inteligente, proporcionando también una descripción exhaustiva de su funcionamiento. En la Sección 4, se analiza la viabilidad de distintos modelos de aprendizaje automático, entrenados para cumplir con los plazos de respuesta requeridos y que, simultáneamente, ofrezcan un buen rendimiento. Finalmente, en la última sección se exponen las conclusiones del trabajo y se sugieren posibles mejoras para investigaciones futuras.

2. Descripción del prototipo robótico

En la Figura 3 se puede ver el prototipo diseñado para la producción de luminarias. Está conformado por un brazo robótico IRB 1300 de ABB cuya función es transportar la bandeja mientras los módulos de montaje le van acoplando los componentes pertinentes. En este caso se distinguen 5 módulos o subestaciones. En primer lugar se encontrará el módulo de carga, el cual es una pila de almacenaje FIFO de bandejas sin componentes. El robot deberá coger una bandeja con la herramienta de trabajo que se le ha acoplado. Esta se encuentra equipada con una serie de ventosas, válvulas de vacío y sensores inductivos para la correcta sujeción de la bandeja, tal y como se muestra en la Figura 2. Diseñada en SolidWorks y fabricada con perfilera de aluminio e impresión 3D. Cada bandeja sobre la que se depositará el material adhesivo cuenta con 6 pistas colocadas paralelamente entre sí a lo largo de su superficie (Figura 5). Una vez se ha cogido la bandeja, se moverá a la estación de deposición de adhesivo, en esta se hará pasar cada pista de la bandeja bajo la válvula de deposición abierta para que una cantidad precisa de material quede adherido a su superficie.




Figura 2: Herramienta de trabajo del robot manipulador

A continuación, se trasladará a un molde impreso en 3D sobre el que se encontrarán los circuitos de iluminación LED que deben ir ubicados en las pistas de deposición del chasis metálico. De esta forma los circuitos quedarán adheridos una vez se hayan pasado los rodillos del objeto de trabajo (Figura 2) sobre su superficie. Finalmente la bandeja es trasladada a una estan-

tería de secado para que el adhesivo haga efecto, y prosiga el proceso de ensamblaje.




Figura 3: Célula de montaje robotizada

El sistema de deposición está conformado por un depósito presurizado que contiene un bote de adhesivo. Dicho contenedor se encuentra conectado a una válvula de fluidos accionada por un relé conectado a la tarjeta de salidas digitales de la controladora del robot (Figura 3). En la Figura 4 se puede encontrar a la izquierda de la válvula de deposición de adhesivo el sensor que se encargará de recoger información sobre el proceso de dispensado de material. Este sensor es un OXP-200 RC05.004 de Baumer, que gracias a la intersección de 2 haces de luz láser es capaz de generar nubes de puntos que representan perfiles, los cuales son almacenados en un buffer interno con un tiempo de muestreo de 5 ms. La información se puede extraer mediante el uso de protocolos UDP y/o SDK empleando *Fast Ethernet*.




Figura 4: Sistema de deposición de adhesivo equipado con sensor perfilómetro

El programa implementado en la controladora del robot está compuesto por diversas tareas programadas en RAPID, el lenguaje de programación de RobotStudio. La principal es la tarea de movimiento del brazo robótico, que implementa toda la lógica de control necesaria para montar una luminaria. En este módulo se incluyen procedimientos para calcular las matrices de coordenadas de los puntos que el robot debe seguir (Figura 5), asegurando que todas las pistas de la bandeja pasen por

debajo de la válvula de deposición, además, para evitar que la rebaba de adhesivo producida por el cierre de la válvula manche el chasis de la luminaria se hace que el robot retroceda sobre la propia pista para que el excedente de material quede en la zona de deposición. También se han implementado interrupciones que permiten actualizar la velocidad del robot en tiempo real durante la etapa de dispensación de adhesivos. Finalmente, todos estos procedimientos se integran en un módulo encargado de ejecutar el movimiento del robot y coordinarlo con la electroválvula todo/nada encargada de dispensar el material.




Figura 5: Trayectoria de dispensación de adhesivo

Paralelamente, se ha desarrollado una tarea periódica que implementa una pasarela de comunicaciones mediante un socket TCP/IP. Esta funcionalidad permite extraer variables de la controladora del robot para ser utilizadas por un programa de adquisición de datos o cualquier interfaz de supervisión, facilitando así el análisis en tiempo real del proceso de montaje. Entre las variables extraídas se incluyen: el indicador de la fase del proceso en curso, el estado de la válvula de dispensación (abierta o cerrada), el estado del sensor inductivo encargado de detectar la presencia de la bandeja acoplada al brazo, y la pista específica sobre la que se está realizando la deposición del adhesivo.

3. Agente inteligente

En esta sección se describe el diseño del sistema inteligente de control de calidad. Primero, se detalla el procedimiento de adquisición de datos a partir del sensor de perfilometría durante la fase de dispensación. A continuación, se expone el proceso de tratamiento de la información, que incluye la extracción de características representativas y la reducción de la dimensionalidad de los perfiles adquiridos. Finalmente, se presentan los modelos de clasificación evaluados, justificando su selección y analizando su rendimiento en el contexto del sistema propuesto.

3.1. Adquisición de datos

A nivel operativo, el sistema cuenta con tres variables exógenas que afectan directamente la calidad del adhesivo depositado (Figura 6). La primera es la presión del circuito de deposición (P_{deposito}), la cual puede tomar valores entre 0 y 6 bares

y se ajusta manualmente mediante un regulador de presión. La segunda variable es la distancia entre la boca de salida de la válvula y la bandeja donde se deposita el material (Δd). Puede ser establecida mediante el programa de control del robot y está comprendida entre 2 y 20 cm. Finalmente, la tercera variable es la velocidad lineal del brazo robótico bajo la válvula de deposición (v_{robot}), que también es controlable desde el software del robot. Y operará en el rango de 300 a 1000 mm/s debido a que si se emplean velocidades más altas, los cordones de adhesivo se pueden romper, y si se va a velocidades más bajas se desperdiciaría demasiado material. Estas variables son críticas para garantizar una deposición uniforme del adhesivo y minimizar defectos en la aplicación del material y en base a ellas se construyeron los conjuntos de datos con los que se diseñará el sistema inteligente.




Figura 6: Circuito de deposición de adhesivo

Para la captura de datos, se han realizado una serie de experimentos, considerando un experimento como la dispensación de adhesivo sobre las seis pistas de una bandeja bajo unas condiciones operativas seleccionadas dentro del espacio definido por las variables exógenas del proceso (P_{deposito} , v_{robot} y Δd). Estas condiciones se han escogido para cubrir distintos escenarios de funcionamiento que puedan representar tanto comportamientos normales como anómalos en la aplicación del adhesivo. Cada experimento genera seis tablas, una por cada pista de deposición, en las que se almacena en cada fila el perfil leído por el sensor, su timestamp, la presión a la que se realizó la deposición, la distancia a la boca de deposición y la velocidad del brazo robótico. En la Figura 7, se ilustra una medición típica de un perfil capturado por el sensor. Este sensor opera proyectando dos haces de luz láser sobre la pista de deposición, generando un perfil en coordenadas bidimensionales que representa la morfología del cordón de adhesivo sobre el plano xz .

Desde el punto de vista de la implementación, se ha diseñado un programa que, mediante la pasarela de comunicaciones, monitoriza en el estado del robot. Este sistema detecta cuándo el robot entra en la etapa de deposición de adhesivos, cuándo la válvula de dispensación está abierta y en qué pista se encuentra el brazo robótico. Siempre que se esté dispensando




Figura 7: Proyección en dos dimensiones de la sección transversal del chasis de la luminaria, donde se representa la pista de deposición y el cordón de adhesivo.

material, se da la orden al sensor para que almacene las mediciones en su buffer interno.

Una vez se cierra la válvula, durante el intervalo de tiempo en el que el brazo robótico cambia de pista para iniciar una nueva deposición, el sistema extrae los datos almacenados en el buffer y construye la tabla correspondiente a la pista recién completada. Finalmente, al concluir las seis deposiciones, las tablas generadas se exportan a ficheros de texto para su posterior procesamiento y análisis.

En total, se han llevado a cabo 13 experimentos organizados en cuatro tandas. En la primera tanda, se realizaron deposiciones a 6 bares de presión y 900 mm/s de velocidad, variando únicamente la diferencia de altura. En cada pista, se introdujo una rampa en la que la distancia inicial correspondía a la mínima distancia de seguridad y, al final, se incrementaba en 5, 10, 15 o 20 cm, dependiendo del experimento. En la segunda tanda, se mantuvieron constantes la presión y la distancia, introduciendo escalones de velocidad dentro del rango de 300 a 1000 mm/s para evaluar su impacto en la deposición. La tercera tanda de experimentos se centró en mantener constantes todos los parámetros excepto la presión, que se fue variando entre 5 y 6 bares, lo que permitió analizar su influencia en la calidad del adhesivo depositado. Finalmente, en la cuarta tanda se realizaron mediciones sin dispensar adhesivo, proporcionando datos de referencia para la identificación de problemas de obstrucciones en el sistema de deposición. No se consideraron presiones inferiores a 5 bares, ya que implicarían una reducción significativa del caudal, lo que ralentizaría el proceso de producción y comprometería el rendimiento de la célula robotizada. En cuanto a la velocidad lineal del robot, las velocidades inferiores a 300 mm/s generan sobreaplicaciones y mayor desperdicio de adhesivo, mientras que velocidades superiores a 1000 mm/s pueden provocar roturas en el cordón dispensado debidas a la alta tracción. En conjunto, la campaña experimental se ha diseñado para cubrir el rango operativo habitual del sistema, de modo que el modelo resultante sea aplicable a condiciones representativas de la producción real.

3.2. Procesamiento de la información

A continuación, se presenta el procedimiento seguido para el tratamiento de los perfiles generados por el sensor de perfilometría láser durante la etapa de dispensación. Sobre estos perfiles tratados, se definen dos estrategias distintas de extracción de características que permiten expresar la información de manera estructurada para su posterior clasificación. De este modo, se puede representar el estado del proceso de tres formas diferentes: utilizando directamente los datos en crudo, empleando descriptores físicos obtenidos mediante ingeniería de características, o mediante una representación reducida a través de técnicas de reducción de dimensionalidad. Esta aproximación permite comparar el rendimiento de cada representación con distintos algoritmos de clasificación, evaluando así cuál resulta más adecuada para el diagnóstico del sistema.

A la derecha de la Figura 7 se puede ver un ejemplo de una medida efectuada por el sensor en una operación normal de inyección de material. Sobre este, se puede observar que tiene un ruido considerable. Como este no tiene ningún tipo de importancia para las mediciones se reducirá en gran medida mediante el uso de un filtro de media móvil de fase 0 con una ventana de trabajo de 5 valores.

El perfil a tratar presenta fuertes cambios en la curvatura próxima a los puntos críticos. Calculando su derivada y obteniendo los extremos locales a partir de cierto umbral podrían ser ubicados. Las líneas discontinuas de la Figura 8 de los extremos corresponden al tramo de *pista de deposición de material*, mientras que las líneas discontinuas del centro serán las que ubicarán el *hilo de material adhesivo*.

Para obtener esa derivada numérica hay que tener en cuenta que los datos no están equiespaciados sobre el eje x debido a los métodos de muestreo espacial empleados por el sensor. Una forma de solventar este problema es mediante la derivación de un polinomio de interpolación de Lagrange de segundo orden, tal y como se muestra en (Chapra and Canale, 2010).




Figura 8: Búsqueda de puntos críticos sobre perfil de adhesivo

La señal adquirida por el sensor de perfilometría láser está sujeta a la presencia de ruido aleatorio que se manifiesta a lo largo del perfil espacial. Este ruido no es un artefacto puntual, sino una consecuencia inherente al propio proceso de adquisición óptica, como ha sido modelado y validado en estudios recientes sobre sistemas de proyección de franjas (Lv and Kema, 2023). La operación de derivación, al realzar las variaciones locales, amplifica también el contenido de alta frecuencia, incluyendo el ruido. En consecuencia, resulta necesario aplicar filtros de paso bajo que permitan atenuar dichas componentes sin comprometer la estructura general de la señal. En este trabajo, se ha empleado un filtro FIR tipo SINC con una frecuencia de corte ajustada al 16 % del número de puntos del perfil, de acuerdo con las recomendaciones de (Smith, 1997), con el objetivo de mejorar la robustez del proceso de búsqueda de puntos críticos.




Figura 9: Rotación del perfil mediante SVD

Aun teniendo el perfil procesado, se puede observar que presenta una cierta inclinación sobre el eje x. Esto afectará negativamente al cálculo de la integral, pues habrá un área no deseada que se incluirá en ese cálculo. Para solucionar dicho inconveniente se emplearán las propiedades geométricas que ofrece la SVD (*Singular Value Decomposition*).

$$X = U \cdot \Sigma \cdot V^T \quad (1)$$

Donde las columnas de U y V conforman bases ortonormalizadas del espacio en columnas y filas de X , respectivamente (Klema and Laub, 1980). En este contexto, U es la proyección de los puntos del perfil ortonormalizados sobre el eje dominante, Σ una matriz diagonal que contiene los valores singulares de los datos y V es una matriz de rotación. Si se efectúa un producto matricial entre U y Σ se obtendría la proyección de los datos sobre el eje x , tal y como se muestra en la Figura 9. Llegado este punto se puede proceder al cálculo de las características que conformarán el tercer conjunto de datos a evaluar (detallado más adelante). Partiendo de que la posición del cordón de material adherente es conocido, se integrarán todos los puntos pertenecientes a este para obtener la sección transversal. Y se efectuará la diferencia de distancia entre el extremo izquierdo de la pista de deposición y el punto medio de la zona del cordón.

De forma alternativa, se estudiará la reducción de la dimensión de los perfiles **rotados** de adhesivo como etapa de extracción de características mediante la SVD, aprovechando su capacidad para generar aproximaciones de bajo orden de matrices. Cerciorándose que la matriz a descomponer tiene una estructura espacio-temporal, donde cada fila representa un punto en el espacio de un perfil y cada columna corresponde a su evolución temporal (Figura 10). Se puede expresar en términos de tres componentes principales: una matriz de vectores singulares izquierdos $\hat{U}$ que contiene los modos espaciales de los perfiles, una matriz diagonal de valores singulares $\hat{\Sigma}$ y una matriz de vectores singulares derechos $\hat{V}^T$ de la cual cada columna representa la combinación lineal de los modos espaciales en cada instante temporal. Mediante el truncamiento de $\hat{\Sigma}$ a un rango reducido, es posible obtener una aproximación de bajo orden que retiene las dinámicas predominantes del sistema, descartando el ruido y las componentes menos significativas (Golub and Kahan, 1965; Sirovich and Kirby, 1987). De esta forma, $\tilde{V}^T$ será la matriz de cambio de base del espacio de alta a baja dimensión.




Figura 10: Reducción de la dimensión mediante SVD (Brunton and Kutz, 2022)

Dicha descomposición matricial se puede expresar como una suma de matrices de rango unitario (2):

$$X \approx \tilde{X} = \sum_{k=1}^r \sigma_k u_k v_k^T \quad (2)$$

3.3. Selección del clasificador

Para la selección del clasificador más adecuado se utilizarán tres conjuntos de datos, cada uno generado desde una etapa específica de la etapa de procesamiento. El primer conjunto de

datos, etiquetado como **DS1**, corresponde a los perfiles procesados, sin aplicar técnicas de reducción o extracción de características. Este dataset contiene 501 características, de las cuales 500 representan los puntos de los perfiles y una corresponde a la velocidad del brazo robótico. El segundo conjunto, etiquetado como **DS2**, es el resultado de aplicar la reducción de dimensionalidad mediante la SVD. Este dataset se compone de 16 características, 15 de las cuales representan las principales componentes del perfil (ver Figura 15) y una corresponde a la velocidad del brazo robótico. Finalmente, el tercer conjunto de datos, etiquetado como **DS3**, se obtiene aplicando una estrategia de extracción de características diseñada específicamente para el proceso. Este conjunto contiene tres características: la sección transversal del hilo de adhesivo, la posición del adhesivo en la pista y la velocidad del brazo robótico. En todos los conjuntos de datos se ha contemplado la inclusión de las variables exógenas, en este caso únicamente se incluye la velocidad del brazo robótico, el resto de parámetros no se incluye debido a que no se pueden medir durante el proceso. Los tres *datasets* contienen aproximadamente 12,000 muestras cada uno. Para el entrenamiento de los modelos se ha empleado la técnica de validación Hold-out con selección de muestras aleatoria, destinando un 20 % de las muestras a validación y el resto a entrenamiento. Previamente, todos los datos han sido normalizados utilizando una transformación Z-Score, eliminando la media y escalando según la desviación típica para garantizar una adecuada homogeneización de las variables.




Figura 11: En las tres gráficas, el eje de abscisas se corresponde con el eje y de la Figura 7, el de ordenadas se asocia al eje x y la altura con el eje z . Todo ello en mm . En la parte superior, distribución tridimensional del adhesivo a lo largo de la pista de deposición de material mostrando oscilaciones propias de un flujo inestable, lo que genera un uso excesivo de material y compromete la uniformidad en la adhesión de los circuitos al chasis metálico. En el medio, distribución tridimensional de adhesivo óptima. En la parte inferior, distribución tridimensional de adhesivo con imperfecciones debido a la existencia de burbujas de aire en el circuito de dispensación.

De cara a la inspección de la calidad de la deposición, el sistema de clasificación debe diferenciar los datos en tres clases (*Flujo Estable*, *Flujo Inestable* y *Burbujas de Aire*), es importante destacar que existe un desequilibrio significativo entre estas. Las etiquetas de *Flujo Estable* representan el 62,64 % de los datos, las de *Flujo Inestable* el 35,81 % y las de *Burbujas de*

Aire el 1,56 %. Por tanto, la métrica seleccionada para evaluar el rendimiento de los modelos es el *F1-Score ponderado*, ya que permite evaluar tanto la exactitud como el balance en las predicciones, especialmente en escenarios de clases desbalanceadas. Se calculará a partir de la implementación en *scikit-learn* de la precisión y la sensibilidad.

Para cada conjunto de datos, se evaluará el rendimiento de una variedad de algoritmos de clasificación: regresión logística (LR), predictor Naive Bayes Gaussiano (GNB), K-vecinos más cercanos (KNN), árbol de decisión (DT), bosque aleatorio (RF), máquina de soporte vectorial (SVM), clasificador optimizado por descenso del gradiente estocástico (SGD), clasificador AdaBoost (ADA), clasificador XGBoost (XGB) y perceptrón multicapa (MLP). Estos modelos, implementados en la librería *scikit-learn* y detallados en (James et al., 2021; Hastie et al., 2009), serán entrenados y validados con el objetivo de identificar el más adecuado para el problema planteado (Soofi and Awan, 2017; Hunter et al., 2012). De cara a la búsqueda de hiperparámetros de los modelos, se ha empleado una estrategia de búsqueda aleatoria (random search) con el objetivo de explorar eficientemente el espacio de configuraciones posibles sin incurrir en un coste computacional excesivo (Luo, 2016).

Además, se incluye una cuarta métrica esencial en este contexto: el tiempo de predicción sobre los datos de test. Si bien el modelo final está destinado a integrarse en un sistema en tiempo real, los equipos empleados para las pruebas no operan sobre sistemas operativos deterministas, por lo que los tiempos de cómputo obtenidos deben considerarse como estimaciones orientativas. Estos se han calculado en tres plataformas diferentes: el primero, un procesador Apple Silicon M3 Max con 48 GB de memoria unificada sobre macOS Sequoia 15.3.1 (Equipo 1 en Tabla 1); el segundo, un computador con procesador Intel Core i5 de 4ª generación con 4 núcleos, 8 GB de RAM y una GPU NVIDIA Quadro K600 bajo Ubuntu 18.04 (Equipo 2 en Tabla 1); y el tercero, un equipo de alto rendimiento con CPU Intel Core i7 de 14ª generación con 28 núcleos, 32 GB de RAM y una GPU NVIDIA RTX 4070 SUPER con soporte CUDA bajo Ubuntu 22.04 (Equipo 3 en Tabla 1). En todos los casos, las mediciones se realizaron en un entorno controlado, minimizando la carga de procesos en segundo plano para reducir interferencias. A pesar de estas precauciones, se insiste en que los tiempos presentados son solo indicativos y se utilizarán exclusivamente para comparar la eficiencia relativa entre clasificadores.

4. Resultados y discusión

Con el fin de comprender la influencia de las variables operativas sobre la calidad de la dispensación de adhesivo, se ha llevado a cabo un estudio sistemático considerando tres variables exógenas: la presión del circuito de dispensación, la distancia entre la boquilla de la válvula y la pista de deposición, y la velocidad lineal del extremo del robot manipulador.

En relación con la presión, en la Figura 12 se muestran los resultados obtenidos de la fase de adquisición de datos, los cuales presentan una correlación directa con la estabilidad del cordón de adhesivo. En términos generales, una disminución de la presión implica una reducción del caudal de material dispensado, lo que favorece el establecimiento de un régimen de flujo

más laminar. Bajo estas condiciones, el adhesivo presenta una mayor coherencia morfológica y una menor susceptibilidad a la aparición de irregularidades, incrementando así la calidad de la deposición. No obstante, este efecto estabilizador presenta una contrapartida importante desde el punto de vista productivo: una menor presión obliga a reducir la velocidad de desplazamiento del robot para evitar la ruptura del hilo de adhesivo, lo que impacta negativamente en el tiempo de ciclo del sistema.




Figura 12: Comparativa visual de la estabilidad del cordón de adhesivo en función de dos condiciones operativas clave: la presión del sistema de dispensación (P_{deposito}) y la distancia entre la válvula y la superficie de aplicación (Δd). Se presentan cuatro ejemplos correspondientes a combinaciones de presión (5 y 6 bar) y distancia (2 y 20 cm). Las imágenes están representadas con la misma escala cromática empleada en la Figura 11, donde los colores más cálidos indican mayores concentraciones de material.

Por otra parte, se ha evidenciado que el aumento de la distancia entre la válvula y la pista de deposición introduce un factor desestabilizador significativo. A medida que se incrementa la altura de aplicación, el tiempo de vuelo del adhesivo se prolonga, permitiendo que los efectos de la gravedad y los esfuerzos cortantes internos del fluido no newtoniano alteren su trayectoria. Esto se traduce en desviaciones laterales, secciones transversales irregulares y un mayor grado de dispersión, afectando negativamente la adherencia y estética del cordón formado.

La variable que presenta un comportamiento más relevante es la velocidad de desplazamiento lineal del extremo del robot. A velocidades reducidas, el sistema tiende a exhibir fenómenos de flujo inestable, manifestados en secciones transversales de mayor área y mayor variabilidad geométrica. En contraste, a medida que se incrementa la velocidad, se observa una estabilización progresiva del flujo, lo cual se refleja en una disminución de la sección del cordón y una mayor regularidad en su trayectoria. Este fenómeno ha sido analizado mediante técnicas de análisis armónico aplicadas a las señales de sección transversal y posición lateral del cordón a lo largo del tiempo. En particular, se ha observado que los armónicos de baja frecuencia, asociados a oscilaciones indeseadas, son más prominentes en regímenes de baja velocidad.

En la Figura 13 se presentan cuatro gráficas que muestran la evolución de distintas características extraídas a lo largo del tiempo, resultado de la aplicación del método de segmentación temporal basada en ventanas deslizantes sobre las variables fundamentales obtenidas en la etapa de extracción de características: la sección transversal del cordón de adhesivo y la posición

lateral del hilo con respecto al eje de referencia de la pista de deposición. Cada gráfica representa una métrica específica agregada por ventana, calculada a partir de los perfiles reconstruidos por el sensor de perfilometría 3D.




Figura 13: Monitorización del sistema ante v_{robot} variable, P_{deposito} constante a 6 bares y Δd constante a la distancia mínima de seguridad

En concreto, las dos primeras gráficas de la Figura 13 corresponden a estadísticas derivadas de la sección transversal, entre las que se encuentran el valor medio y el contenido armónico (medido a través del valor eficaz en la banda de 1 a 8 Hz). Las dos gráficas siguientes reflejan las mismas métricas, pero aplicadas a la posición lateral del hilo dentro de la pista. Permitiendo identificar patrones distintivos en la morfología del cordón y en su trayectoria, facilitando la identificación de posibles estados de inestabilidad en el proceso de dispensación.

El análisis de estas curvas permite observar cómo ciertos segmentos del proceso presentan valores elevados en los armónicos, lo que sugiere la aparición de oscilaciones periódicas que pueden asociarse con fenómenos de flujo inestable. Asimismo, se puede apreciar cómo la sección media y la posición tienden a estabilizarse en determinados intervalos, coincidiendo con regímenes operativos más favorables.

La Figura 14 representa la evolución temporal del perfil del cordón de adhesivo en tres dimensiones. Permite observar de forma directa y visualmente intuitiva la dinámica del proceso de dispensación en condiciones reales de operación. En esta representación se aprecia cómo varía la altura del cordón a lo largo de la pista de deposición, revelando regiones donde el flujo se comporta de forma más estable (con alturas constantes y trayectoria centrada) y otras donde aparecen fluctuaciones que indican inestabilidad en la deposición. Estas oscilaciones no solo afectan la altura, sino también la trayectoria del hilo, provocando desplazamientos laterales respecto al eje central. Esta información coincide con lo mostrado en las gráficas de la Figura 13, donde se observa cómo, en determinados intervalos temporales, aumenta el valor medio de la sección, así como la energía contenida en los armónicos de la señal, tanto en sección co-

mo en posición. En particular, los incrementos en la suma de armónicos en dichas gráficas corroboran la presencia de patrones oscilatorios que se observan en la evolución tridimensional del cordón. Así, mientras que la Figura 14 proporciona una visión detallada de un caso específico en el dominio espacio-temporal, las gráficas en ventana agregan esta información en forma de descriptores cuantificables, facilitando su uso en tareas de clasificación automática y evaluación de la calidad del proceso.




Figura 14: Respuesta ante escalón de velocidad ascendente

Teniendo en cuenta las implicaciones anteriores, se concluye que, desde una perspectiva de operación eficiente, es recomendable fijar la presión del sistema a un valor alto que garantice un caudal suficiente para sostener una velocidad elevada sin comprometer la integridad del cordón. Del mismo modo, se recomienda minimizar la distancia entre la válvula y la pista de deposición para reducir la exposición del adhesivo a perturbaciones externas. Bajo este enfoque, la velocidad lineal del robot se establece como única variable ajustable a lo largo del proceso, permitiendo modular la respuesta del sistema en función de las condiciones locales sin afectar negativamente la productividad general del sistema.




Figura 15: Selección del rango r en la SVD, destacando $r = 14$ como truncamiento final óptimo.

En el proceso de reducción de dimensionalidad mediante la SVD, una de las decisiones clave es la selección del rango r en el que se truncará la matriz. Existen numerosos métodos para determinar este rango, con el objetivo de separar la información relevante del ruido inherente en los datos. Para este estudio, se ha optado por un enfoque que calcula un rango óptimo basado en la identificación de los valores singulares que representan la información significativa, descartando las componentes asociadas al ruido (Gavish and Donoho, 2014).

En la gráfica de valores singulares (Figura 15), se observa un decrecimiento progresivo de los valores, lo que permite identificar un truncamiento óptimo en $r = 184$ mediante el método empleado, que separa la señal del ruido en la matriz aplicando la ecuación (2). Sin embargo, para esta aplicación, no es necesario conservar tantos detalles, por lo que se decidió reducir el orden de la aproximación matricial a $r = 14$. Aunque esta reducción implica una pérdida parcial de información, sigue siendo suficiente para capturar las características principales necesarias, mejorando la eficiencia computacional del sistema.

Los resultados presentados en la Tabla 1, y las matrices de confusión correspondientes representadas en la Figura 16 permiten realizar una evaluación comparativa entre los modelos de clasificación entrenados sobre los tres conjuntos de datos definidos (DS1, DS2 y DS3). Esta evaluación se ha llevado a cabo teniendo en cuenta tanto el rendimiento predictivo (F1-Score) como la viabilidad temporal (tiempo de inferencia).

Uno de los hallazgos más consistentes es que los modelos entrenados sobre el dataset reducido mediante descomposición en valores singulares (DS2) ofrecen el mejor compromiso entre rendimiento y eficiencia computacional. Esta estrategia de preprocesamiento, que permite capturar las componentes más informativas de la variabilidad del sistema, ha demostrado mejorar la discriminación entre clases al tiempo que reduce la dimensionalidad del espacio de entrada, facilitando una inferencia más rápida.

En cuanto a los algoritmos evaluados, los modelos basados en árboles de decisión, en particular XGBoost y DT, destacan por su excelente rendimiento en los tres datasets. XGBoost alcanza el valor más alto de F1-Score en DS1 y DS2 (99.61 % y 99.47 % respectivamente), manteniendo tiempos de predicción suficientemente bajos como para operar dentro de los márgenes exigidos por el sistema (inferiores a 5 ms en todos los equipos). El modelo basado en DT también ofrece un rendimiento notable, con F1-Scores superiores al 97 % y tiempos de inferencia aún más reducidos (0.26 ms en DS2 sobre el equipo 1), lo que lo convierte en una opción altamente recomendable para su implementación en sistemas embebidos con recursos limitados.

Sin embargo, la inspección de la Figura 16 revela un matiz interesante respecto al comportamiento de otros clasificadores. En concreto, el MLP, si bien presenta un F1-Score ligeramente inferior al de XGBoost en los tres datasets, muestra una matriz de confusión más equilibrada, con menor número de falsos positivos y falsos negativos en las clases minoritarias, particularmente en la detección de burbujas de aire. Este comportamiento sugiere que el MLP posee una mayor capacidad para generalizar en regiones del espacio de características donde las clases están menos representadas, lo que puede resultar ventajoso en contextos donde las consecuencias de una mala clasificación son asimétricas.

Tabla 1: Comparación de métricas de los modelos de clasificación seleccionados y tiempos de predicción en distintos computadores.

Modelo	Dataset	F1-Score [%]	Equipo 1 [ms]	Equipo 2 [ms]	Equipo 3 [ms]
LR	DS1	93.77	2.52	7.73	1.81
	DS2	89.49	0.14	0.46	0.19
	DS3	81.72	0.12	0.38	0.15
GNB	DS1	67.98	16.31	37.64	23.85
	DS2	85.17	1.46	3.05	0.52
	DS3	83.01	0.30	0.81	0.31
KNN	DS1	97.15	307.38	379.42	125.02
	DS2	99.49	151.76	114.98	84.38
	DS3	87.00	58.85	173.33	47.02
DT	DS1	98.17	1.47	3.29	1.80
	DS2	97.63	0.26	0.69	0.33
	DS3	83.41	0.34	0.72	0.31
RF	DS1	98.99	23.57	48.00	19.76
	DS2	99.33	20.81	28.64	13.61
	DS3	86.31	30.19	39.38	20.56
SVM	DS1	93.39	2656.05	4730.49	1159.04
	DS2	81.10	299.06	932.49	262.93
	DS3	81.10	291.95	518.62	177.67
SGD	DS1	92.41	0.93	6.73	1.50
	DS2	88.03	0.16	0.52	0.21
	DS3	54.02	0.12	0.45	0.16
AdaBoost	DS1	80.57	59.75	170.39	38.29
	DS2	77.59	16.12	20.34	7.19
	DS3	74.47	12.58	18.35	6.11
XGBoost	DS1	99.61	3.69	16.90	2.24
	DS2	99.47	2.02	11.73	1.31
	DS3	87.13	1.59	11.70	1.19
MLP	DS1	98.67	4.91	15.90	4.04
	DS2	92.48	1.64	4.96	1.22
	DS3	65.70	2.76	2.54	0.95

Modelos basados en SVM y KNN, aunque ofrecen buenos resultados en cuanto a precisión, son descartados debido a sus elevados tiempos de predicción, que los hacen inviables para una ejecución temporalmente exigente. En particular, SVM alcanza latencias superiores a los 4 segundos en el equipo de menor rendimiento. El SGD, en el otro extremo, destaca por ser el modelo más eficiente temporalmente, pero su rendimiento es inadecuado, con F1-Scores inferiores al 55 % en el dataset DS3.

Por ello, se selecciona el clasificador **DT** entrenado sobre el conjunto **DS2** como el modelo más adecuado debido a su buen rendimiento y facilidad de implementación. Su configuración no limita la profundidad del árbol, utiliza la ganancia de información como criterio de partición, exigiendo un mínimo de 10 muestras por nodo para su división y permite hojas con una única observación, lo que garantiza sensibilidad frente a patrones poco frecuentes.

Además del análisis en entorno de desarrollo, se ha llevado a cabo una implementación preliminar del sistema en tiempo real sobre el Equipo 2, aprovechando la posibilidad que ofrece este sistema operativo de acceder al reloj de alta resolución del sistema mediante interfaces específicas. Para ello, se ha

exportado el modelo entrenado sobre el conjunto de datos DS2 utilizando el clasificador de árbol de decisión, debido a su bajo tiempo de inferencia y estructura lógica interpretable. Se ha desarrollado un programa en C++ basado en un bucle infinito gobernado por retardos absolutos en POSIX.




Figura 17: Histograma de mediciones temporales efectuadas sobre la implementación del Algoritmo 1.




Figura 16: Matriz de matrices de confusión normalizadas por filas. En el eje de las abscisas se muestran las predicciones de los modelos y en el de las ordenadas se muestran las etiquetas reales de los datos.

Algoritmo 1: Procedimiento de ejecución en tiempo real del sistema de clasificación

```

Inicializar variables y estructuras de datos;
Cargar matriz de cambio de base  $\tilde{V}^T$ ;
Establecer período de control  $T$ ;
Obtener instante de inicio  $t_k$  utilizando
    CLOCK_REALTIME;
mientras el sistema permanezca en ejecución hacer
    perfil  $\leftarrow$  sensor.leerPerfil();
    // Se trabaja con la zona de interés
    perfil  $\leftarrow$  obtenerElementosCentrales(500);
    // Aplicar filtro de media móvil
    perfil  $\leftarrow$  filtfilt(perfil, [0,2,0,2,0,2,0,2]);
    // Corregir orientación mediante SVD (1)
    // Sabiendo que perfil =  $U \cdot \Sigma \cdot V$ 
    perfilRot  $\leftarrow U \cdot \Sigma$ ;
    // Proyectar el perfil al espacio
    // reducido utilizando  $\tilde{V}^T$ 
    //  $\mathbb{R}^{500} \rightarrow \mathbb{R}^{15}$ 
     $\alpha \leftarrow \tilde{V}^T \times$  perfilRot;
    // Componer vector de características
     $x \leftarrow [\alpha, v_{\text{robot}}]$ ;
    // Ejecutar predicción
     $\hat{y} \leftarrow DT.prededir(x)$ ;
    Transmitir resultado;
    // Calcular siguiente instante temporal
     $t_k \leftarrow t_k + T$ ;
    // Bloquear la ejecución
    Ejecutar retardo absoluto hasta alcanzar  $t_k$ ;

```

El Algoritmo 1 describe el procedimiento implementado para la ejecución del sistema de clasificación en un entorno en tiempo real. En cada ciclo, se adquiere un nuevo perfil del cordón de adhesivo desde el sensor, del cual se selecciona su región central y se filtra mediante un operador de media móvil para reducir el ruido. A continuación, se corrige su orientación utilizando una SVD, y el resultado se proyecta al espacio re-

ducido definido por la matriz $\tilde{V}^T$, obtenida en la fase de entrenamiento. El vector resultante se complementa con la velocidad actual del robot para formar el vector de características de entrada al clasificador. Finalmente, se ejecuta una predicción utilizando un árbol de decisión entrenado previamente, y se transmite el resultado.

En la Figura 17 se representa el histograma de tiempos de ejecución del sistema en su implementación de tiempo real, evaluada en un entorno controlado en el que se ejecutaba exclusivamente el programa de supervisión. Se llevaron a cabo 1000 iteraciones del ciclo principal de control, registrando el tiempo total requerido para completar cada bucle. El análisis revela que aproximadamente 5 ms se emplean de forma constante en la adquisición del perfil por parte del sensor, mientras que el tiempo restante se destina al tratamiento del perfil, su proyección en un espacio de baja dimensión y la ejecución del clasificador. Incluso en el peor de los casos, asumiendo un tiempo máximo de 20 ms por predicción, si se considera una velocidad lineal del extremo del robot de 1000 mm/s y una longitud de pista de 500 mm (revisar Figura 5), sería posible realizar hasta 25 comprobaciones durante una única deposición. Esta frecuencia de supervisión se considera adecuada para garantizar el correcto funcionamiento del sistema en tiempo de ejecución.

5. Conclusiones

En conclusión, este trabajo ha presentado el diseño y la implementación de un sistema de inspección inteligente orientado a operar como sensor virtual de calidad en un entorno robotizado de montaje de luminarias. A partir de los perfiles generados por un sensor de perfilometría láser, se han desarrollado y evaluado diferentes estrategias de representación de datos, desde el uso directo de perfiles crudos hasta la extracción de características e implementación de técnicas de reducción de dimensión, con el objetivo de alimentar modelos de clasificación que permitan identificar el estado del cordón de adhesivo durante su dispensación. El enfoque propuesto, basado en el uso de la

SVD como técnica de reducción de la dimensión, ha demostrado ofrecer una representación eficiente y compacta de los datos, facilitando su integración en modelos de aprendizaje automático en tiempo real.

Entre los modelos evaluados, los clasificadores basados en árboles de decisión, en particular DT y XGBoost, han mostrado el mejor equilibrio entre precisión y coste computacional, lo que los posiciona como candidatos óptimos para su ejecución en sistemas con restricciones temporales. No obstante, se ha observado que el MLP ofrece una mayor sensibilidad en la detección de clases minoritarias, lo que podría resultar útil en aplicaciones donde el coste de una clasificación errónea sea elevado, siempre que se pueda asumir su mayor demanda computacional. Finalmente, se ha validado la viabilidad del sistema en un entorno Linux en tiempo real mediante la implementación de un lazo de control periódico sincronizado con el reloj del sistema, consolidando así el diseño funcional del sensor virtual como herramienta de diagnóstico en línea. Estos resultados sientan las bases para futuras mejoras orientadas al cierre del lazo de control y a la generalización del sistema a diferentes configuraciones industriales.

Agradecimientos

Me gustaría agradecer a *Normagrup Technology*, promotor de esta investigación, por haber destinado recursos no solo al desarrollo de este sistema de montaje si no al estudio y a la innovación para optimizar su funcionamiento.

Referencias

- Adargoma Suarez Garcia, L., Espinosa Escudero, M.D.M., Dominguez So-
monte, M., 2021. ASSESSMENT OF ASSEMBLY PROCEDURES
IN FUSED DEPOSITION MODELLING PARTS. *DYNA* 96, 39–43.
doi:10.6036/9569.
- Bogert, W.v.d., Lorenz, J., Yi, X., Shih, A.J., Fazeli, N., 2024. Lumped-
Parameter Modeling and Control for Robotic High-Viscosity Fluid De-
position. *IEEE Robotics and Automation Letters* 9, 1953–1960.
doi:10.1109/LRA.2024.3349931.
- Brunton, S.L., Kutz, J.N., 2022. *Data-Driven Science and Engineering*. 2 ed.,
Cambridge University Press.
- Burga, R., Tausek, A., 2003. Control of adhesive dispensing parameters dur-
ing transition from research to production environments, in: *Proceedings of
the 5th Electronics Packaging Technology Conference (EPTC 2003)*, IEEE,
Singapore. pp. 671–674. doi:10.1109/EPTC.2003.1271604.
- Chapra, S.C., Canale, R.P., 2010. *Numerical methods for engineers*. McGraw-
Hill Higher Education.
- Chen, X., Shoenau, G., Zhang, W., 2000. Modeling of time-pressure fluid dis-
pensing processes. *IEEE Transactions on Electronics Packaging Manufac-
turing* 23, 300–305. doi:10.1109/6104.895075.
- Chen, X.B., 2009. Modeling and control of fluid dispensing processes: a state-
of-the-art review. *The International Journal of Advanced Manufacturing
Technology* 43, 276–286. doi:10.1007/s00170-008-1700-5.
- Cruz, Y.J., Rivas, M., Quiza, R., Beruvides, G., Haber, R.E., 2020. Compu-
ter vision system for welding inspection of liquefied petroleum gas pressure
vessels based on combined digital image processing and deep learning tech-
niques. *Sensors* 20. doi:10.3390/s20164505.
- Davies, B., Harris, S., Razban, A., Efstathiou, J., 1996. Application experience
of a robotic cell for automated adhesive dispensing. *Mathematics and Com-
puters in Simulation* 41, 419–427. doi:10.1016/0378-4754(95)00089-5.
- Derebail, A., Srihari, K., Emerson, C.R., 1994. An adhesive selection
advisor for PCB assembly using surface mount technology. *The In-
ternational Journal of Advanced Manufacturing Technology* 9, 93–105.
doi:10.1007/BF01750416.
- Gavish, M., Donoho, D.L., 2014. The Optimal Hard Threshold for Singular Va-
lues is $\sqrt{4/\log(3)}$. *IEEE Transactions on Information Theory* 60, 5040–
5053. doi:10.1109/TIT.2014.2323359.
- Golub, G., Kahan, W., 1965. Calculating the singular values and pseudo-inverse
of a matrix. *Journal of the Society for Industrial and Applied Mathematics
Series B Numerical Analysis* 2, 205–224. doi:10.1137/0702016.
- Hastie, T., Tibshirani, R., Friedman, J., 2009. *The Elements of Statistical Lear-
ning*. Springer Series in Statistics, Springer New York, New York, NY.
doi:10.1007/978-0-387-84858-7.
- Hunter, D., Yu, H., Pukish, III, M.S., Kolbusz, J., Wilamowski, B.M., 2012.
Selection of proper neural network sizes and architectures—a compa-
rative study. *IEEE Transactions on Industrial Informatics* 8, 228–240.
doi:10.1109/TII.2012.2187914.
- Iakovou, D., Aarts, R., Meijer, J., 2005. Sensor integration for robotic laser
welding processes. *IEEE Electron Device Letters* doi:10.2351/1.5060477.
- James, G., Witten, D., Hastie, T., Tibshirani, R., 2021. *An Introduction to Statis-
tical Learning: with Applications in R*. Springer Texts in Statistics, Springer
US, New York, NY. doi:10.1007/978-1-0716-1418-1.
- Javadi, Y., Mohseni, E., Macleod, C., Lines, D., Vasilev, M., Mineo,
C., Foster, E., Pierce, S., Gachagan, A., 2020. Continuous moni-
toring of an intentionally-manufactured crack using an automated welding
and in-process inspection system. *Materials & Design* 191, 108655.
doi:10.1016/j.matdes.2020.108655.
- Klema, V., Laub, A., 1980. The singular value decomposition: Its computation
and some applications. *IEEE Transactions on Automatic Control* 25, 164–
176. doi:10.1109/TAC.1980.1102314.
- Luo, G., 2016. A review of automatic selection methods for machine lear-
ning algorithms and hyper-parameter values. *Network Modeling Analysis
in Health Informatics and Bioinformatics* 5, 18. doi:10.1007/s13721-016-
0125-6.
- Lv, S., Kemao, Q., 2023. Modeling the measurement precision of Frin-
ge Projection Profilometry. *Light: Science & Applications* 12, 257.
doi:10.1038/s41377-023-01294-0.
- Razban, A., Davies, B., Harris, S., Efstathiou, J., 1995. Control of an automa-
ted dispensing cell with vision controlled feedback. *Control Engineering
Practice* 3, 1217–1223. doi:10.1016/0967-0661(95)00120-J.
- Razban, A., Sezgin, O., Davies, B., 1991. Real time control of automated adhe-
sive dispensing, in: *Third International Conference on Software Engineering
for Real Time Systems*, 1991., IET. pp. 145–150.
- Rout, A., Deepak, B., Biswal, B., 2019. Advances in weld seam tracking tech-
niques for robotic welding: A review. *Robotics and Computer-Integrated
Manufacturing* doi:10.1016/J.RCIM.2018.08.003.
- Sirovich, L., Kirby, M., 1987. Low-dimensional procedure for the cha-
racterization of human faces. *J. Opt. Soc. Am. A* 4, 519–524.
doi:10.1364/JOSAA.4.000519.
- Smith, S.W., 1997. *The scientist and engineer's guide to digital signal proces-
sing*. 1. ed ed., California Technical Publ, San Diego, Calif.
- Soofi, A.A., Awan, A., 2017. Classification techniques in machine learning:
Applications and issues. *Journal of Basic amp; Applied Sciences* 13,
459–465.
- Vaish, A., Yang Lee, S., Valdivia Alvarado, P., 2018. Viscosity Control of Pseu-
doplastic Polymer Mixtures for Applications in Additive-Manufacturing.
doi:10.26153/TSW/17019.
- Vasilev, M., Macleod, C., Loukas, C., Javadi, Y., Vithanage, R., Lines, D., Moh-
seni, E., Pierce, S., Gachagan, A., 2021. Sensor-Enabled Multi-Robot Sys-
tem for Automated Welding and In-Process Ultrasonic NDE. *Sensors (Bas-
el, Switzerland)* 21. doi:10.3390/s21155077.
- Wang, Z., 2024. The active visual sensing methods for robo-
tic welding: review, tutorial and prospect. *ArXiv abs/2405.00685*.
doi:10.48550/arXiv.2405.00685.