

(03-009) - Development of Artificial Intelligence (AI) Techniques for Implementation in Directed Energy Deposition (DED) Processes for Additive Manufacturing

Fernández-Zabalza , Aitor ¹; Veiga , Fernando ¹; Suarez, Alfredo ²; Alfaro, José Ramón ¹

¹ Department of Engineering, Public University of Navarre, Los Tejos Building, Campus Arrosadía, 31006 Pamplona, Navarra, Spain, ² TECNALIA, Basque Research and Technology Alliance (BRTA), Parque Científico, Parque Científico y Tecnológico de Gipuzkoa

This work focuses on the development of Artificial Intelligence (AI) techniques applied to directed energy deposition (DED) processes in additive manufacturing. The research aims to find correlations through AI models between process parameters and the geometry of the additive layer. By implementing machine learning algorithms, complex relationships are explored, linking factors such as deposition speed, temperature, and other process parameters to the geometric characteristics of the deposited layers. This approach optimizes the quality and efficiency of additive manufacturing by precisely understanding how adjustments in process parameters impact the final structure. Promising results indicate that AI plays a crucial role in the continuous improvement of DED processes, paving the way for a more efficient and precise additive manufacturing.

Keywords: Machine Learning; Additive Manufacturing; Directed Energy Deposition (DED); Artificial Intelligence (AI); Process Parameters; Optimization

Desarrollo de técnicas de Inteligencia Artificial (IA) para su implementación en los procesos de fabricación aditiva

Este trabajo se centra en el desarrollo de técnicas de Inteligencia Artificial (IA) aplicadas a los procesos de aporte por deposición de energía focalizada (DED) en la fabricación aditiva. La investigación se enfoca en la búsqueda de correlaciones mediante modelos de IA entre los parámetros del proceso y la geometría de la capa aditiva. A través de la implementación de algoritmos de aprendizaje automático, se exploran relaciones complejas que vinculan factores como la velocidad de deposición, la temperatura, y otros parámetros de proceso con las características geométricas de las capas depositadas. Este enfoque permite optimizar la calidad y eficiencia de la fabricación aditiva al comprender de manera precisa cómo los ajustes en los parámetros de proceso impactan en la estructura final. Los resultados prometedores indican que la IA desempeña un papel crucial en la mejora continua de los procesos DED, allanando el camino hacia una fabricación aditiva más eficiente y precisa.

Palabras clave: Aprendizaje automático; Fabricación aditiva; Aporte por deposición de energía focalizada (DED); Inteligencia Artificial (IA); Parámetros de proceso; Optimización

Correspondencia: Aitor Fernández - correo: fernandez.90050@e.unavarra.es



©2024 by the authors. Licensee AEIPRO, Spain. This article is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).

1. Introducción

En un contexto global de recursos limitados y creciente necesidad de sostenibilidad, la fabricación aditiva surge como una solución eficiente y precisa (García Gascón, 2023; Suárez et al., 2023). La tecnología de Deposición de Energía Focalizada con Arco Metálico (arc-DED) se destaca como un método innovador en la industria (Aldalur et al., 2022; Sood et al., 2023). El DED-arc, o Deposición de Energía Focalizada con Arco Metálico, es una técnica de fabricación aditiva que utiliza un arco eléctrico para fundir y depositar material metálico capa por capa. En este proceso, un arco eléctrico se genera entre un electrodo y el sustrato, creando un plasma de alta energía que funde el material de alimentación, que se suministra en forma de alambre o polvo, y lo deposita sobre la superficie de construcción. Esta técnica permite la fabricación de componentes metálicos con alta precisión y control, y se utiliza en una variedad de aplicaciones industriales, incluyendo la producción de piezas de alta complejidad y personalizadas. Dentro de los materiales que se pueden emplear en la fabricación DED-arc es el Invar36 compuesto por la unión del hierro (64%) y el níquel (36%), Invar 36 se distingue por su baja expansión térmica, una propiedad que la convierte en muy útil en aplicaciones con alta exigencia de precisión dimensional (Sokolowski et al., 1993). Desde instrumentos de medición de alta sensibilidad hasta componentes aeroespaciales de última generación, Invar 36 ostenta una alta confiabilidad.

Los avances tecnológicos adoptados en DED-arc posibilitan la creación de piezas de gran tamaño y geometrías complejas a velocidades de impresión aceptables, lo que permite que se plantee como una alternativa a las técnicas tradicionales (Chu, 2020; Huang et al., 2024a, 2024b; Veiga et al., 2022). Dentro de los procesos de fabricación aditiva el DED-arc se considera un proceso con alta tasa de deposición lo que reduce tiempos de producción, mejorando la eficiencia y reduciendo costos

La inteligencia artificial (IA), dada la disponibilidad de datos es una materia de gran interés en el contexto de la fabricación aditiva con objetivo de impulsar la eficiencia, precisión y flexibilidad a niveles superiores (He et al., 2023). Su capacidad para analizar datos, optimizar procesos y tomar decisiones en tiempo real se podría aplicar de forma directa en estos procesos. La IA puede analizar datos de impresión en tiempo real, como la temperatura del material, la velocidad de impresión y la geometría de la pieza, para realizar ajustes precisos y garantizar la calidad dimensional de cada componente (Oh et al., 2019). Esto permite la fabricación de piezas con tolerancias dimensionales extremadamente estrechas, satisfaciendo las necesidades de las aplicaciones más exigentes (Shevchik et al., 2019).

Además, la IA puede optimizar la planificación de la impresión, la selección de materiales y la configuración de los parámetros de impresión para minimizar el tiempo de producción y el desperdicio de material (Zhou & Tian, 2021). Esto se traduce en una mayor eficiencia y una reducción significativa de los costos, impulsando la rentabilidad y la competitividad. Asimismo, la IA puede utilizarse para generar diseños de piezas complejos y personalizados que antes eran imposibles de fabricar con métodos tradicionales. Esto permite a los diseñadores explorar nuevas posibilidades y crear soluciones innovadoras a problemas específicos.

En definitiva, la IA se convierte en un aliado indispensable para la fabricación aditiva, impulsando la precisión, la eficiencia y la flexibilidad a niveles sin precedentes, gracias a su capacidad para analizar datos, optimizar procesos y tomar decisiones en tiempo real. La integración de la IA en la fabricación aditiva apenas comienza. La capacidad de arc-DED para crear geometrías complejas libera a los diseñadores de las limitaciones de las técnicas tradicionales. Las investigaciones actuales se centran en optimizar los parámetros del proceso

para lograr paredes geométricas precisas en piezas de Invar 36 (Fernández-Zabalza et al., 2024). El objetivo principal de este trabajo es desarrollar técnicas de Inteligencia Artificial (IA) aplicadas a los procesos de aporte por deposición de energía focalizada (DED) en la fabricación aditiva. La investigación se centra en encontrar correlaciones mediante modelos de IA entre los parámetros del proceso y la geometría de la capa aditiva. El propósito es optimizar la calidad y eficiencia de la fabricación aditiva al comprender cómo los ajustes en los parámetros de proceso afectan la estructura final de las piezas fabricadas. La novedad del enfoque de esta ponencia radica en la aplicación de la IA en el contexto específico de la fabricación aditiva arc-DED de Invar 36, lo que permite la optimización de procesos y la toma de decisiones más inteligentes para garantizar la calidad dimensional de las piezas fabricadas. Además, se presenta una comparación entre un modelo tradicional y un modelo de aprendizaje profundo para resolver un problema de predicción de la geometría del cordón, lo que proporciona una evaluación integral del rendimiento de ambos enfoques.

2. Materiales y Métodos

El material seleccionado para este artículo, Invar36, es una aleación de hierro y níquel conocida como FeNi36 cuya composición química se da en la Tabla 1. El material se emplea en forma de hilo (con referencia UNS K93600) de 1.2 mm de diámetro como base para la experimentación, combinándolo con una placa base de láminas de Invar de 8 mm de espesor (UTP A 8036 S).

Tabla 1: Composición química del alambre de invar utilizado durante la experimentación

C	Mn	Cr	Ni	Nb	Fe	Ti
0.22%	0.43%	0.01%	35.66%	1.38%	61.6%	0.53%

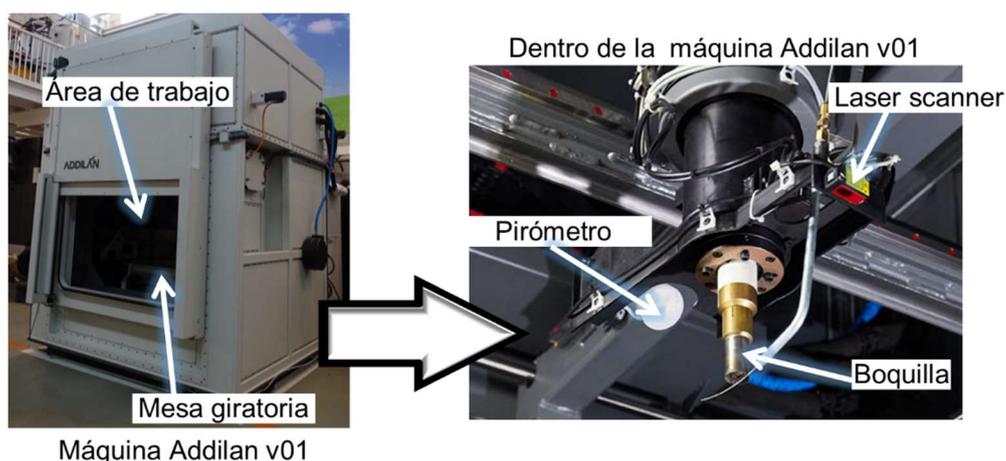
En general, el Invar 36 obtenido mediante fabricación aditiva DED muestra propiedades mecánicas comparables a las convencionales según lo que se muestra en la bibliografía, Tabla 2, incluyendo una alta resistencia a la tracción y límite elástico, junto con su característico coeficiente de expansión térmica bajo.

Tabla 2: Propiedades térmicas y mecánicas del Invar en arc-DED datos registrados en (Veiga et al., 2022).

Muestra	Coef de expansión térmica 0–100 °C [10–6C–1]	Resistencia última a la tracción (MPa)	Elongación (%)
GMAW-WD (Jiao et al., 2023)	1.94	505 ± 2	29 ± 1
GMAW-BD (Jiao et al., 2023)	1.96		
CMT-WD (Horizontal) (Veiga et al., 2022)	1.54	533 ± 9	28 ± 2.5
CMT-BD (Vertical) (Veiga et al., 2022)	1.32		
Material laminado comercial (ASTM B753–07:2018)	2.29	518	34

La experimentación se llevó a cabo en el centro de fabricación Addilan V0.1, especializado en tecnología arc-DED, como el mostrado en la Figura 1. La configuración central incluye un generador EWM Titan XQ 400 AC puls DW, un alimentador de alambre M drive 4 Rob5 XR RE y un sistema de control y monitoreo. La instrumentación se completa con un perfilómetro láser Laser Scanner Q4 Series y un pirómetro Optris compacto para mediciones precisas. El modo de operación elegido fue el GMAW pulsado, permitiendo un control preciso del proceso de deposición.

Figura 1: Set-up experimental empleado en los ensayos



La investigación se enfocó en la producción de cordones iniciales para optimizar los parámetros de deposición, por lo que se ha decidido ensayar condiciones variables de velocidad de alimentación de hilo (3 niveles) y diferentes velocidades de avance transversal, según la Tabla 3. El perfilómetro láser se utiliza para evaluar la geometría de los cordones, posicionándose perpendicularmente al sustrato y siguiendo un movimiento similar al de la boquilla de la antorcha de soldadura.

Tabla 3: Parámetros comandados para la fabricación aditiva de los cordones

Prueba	Velocidad de alimentación del hilo (m/min)	Velocidad transversal (cm/min)	Corriente comandada (A)	Tensión comandada (V)
1	4	80	110	20
2	4	53	110	20
3	4	40	110	20
4	10	200	270	28
5	10	134	270	28
6	10	100	270	28
7	16	320	450	36
8	16	212	450	36
9	16	160	450	36

La relación entre la velocidad de alimentación del hilo y la velocidad de desplazamiento juega un papel crucial en la determinación de la geometría del cordón de soldadura, es por ello que es en este caso el *Ratio* lo que se plantea como variable a ensayar en 3 niveles. Esta relación define la cantidad de material depositado por unidad de longitud, impactando directamente en la forma final del cordón. Ajustar esta relación con precisión es fundamental para controlar parámetros como el ancho y la altura del cordón, los cuales a su vez influyen en la calidad de la soldadura y sus propiedades mecánicas.

$$\text{Ratio} = \frac{\text{Velocidad alimentación}}{\text{Velocidad de avance}} \quad (1)$$

$$\text{Ratio de deposición} = \frac{\text{Velocidad alimentación} \cdot \rho \cdot (\pi \cdot \phi^2 / 4)}{60} \quad (2)$$

Donde, ρ es la densidad del Invar y ϕ el diámetro del hilo. Para la energía por unidad de avance se tiene la siguiente ecuación (3).

$$\text{Energía por avance (kJ/cm)} = \frac{V \cdot I}{\text{Velocidad de avance}} \quad (3)$$

La Tabla 4 presenta los valores significativos derivados de las condiciones de ensayo, incluyendo el ratio de deposición (kg/h), el ratio, y la energía por longitud (kJ/cm). Siendo estos 2 primeros los valores que definen el diseño experimenta empleado siendo este ensayo un diseño 2 factorial a 3 niveles.

Tabla 4: Valores significativos derivados de las condiciones de ensayo

Prueba	Ratio de deposición (kg/h)	Ratio	Energía por longitud (kJ/cm)
1	2.2	5	16.5
2	2.2	7.5	24.9
3	2.2	10	33.0
4	5.5	5	22.7
5	5.5	7.5	33.9
6	5.5	10	45.4
7	8.8	5	30.4
8	8.8	7.5	45.8
9	8.8	10	60.8

3. Resultados

Esta sección presenta los resultados experimentales y las discusiones relacionadas con el proceso arc-DED aplicado al Invar. El apartado está estructurado en dos subsecciones interconectadas. La primera subsección profundiza en los resultados de medición del perfil del cordón, elucidando la geometría del cordón inicial y sus implicaciones para los parámetros

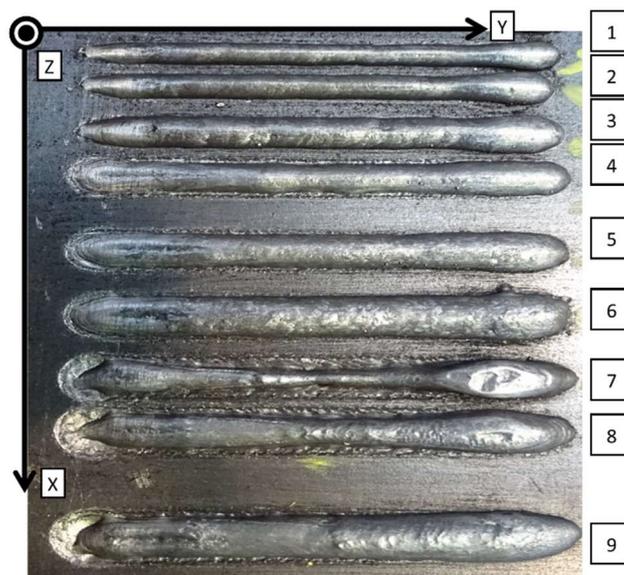
del proceso y la adquisición y análisis de señales internas de la máquina. En el final del apartado se explora la posible aplicación de la inteligencia artificial para la estimación de altura y anchura del cordón.

3.1 Datos medidos en el set-up experimental planteado

El cordón cero, el primer paso de material depositado durante el arc-DED, es crucial para determinar la geometría final y las propiedades del material depositado. Medir y modelar con precisión la geometría del cordón cero es esencial para optimizar los parámetros del arc-DED y garantizar la calidad consistente de las piezas. El proceso arc-DED presenta desafíos para lograr una geometría de cordón de soldadura consistente, especialmente en las etapas de inicio (inicio del arco) y final (extinción del arco) debido al charco de fusión dinámico.

La Figura 2 muestra los cordones depositados y su correspondiente número de ensayo. Cada cordón depositado está etiquetado con un número de ensayo específico, lo que permite identificar y asociar cada cordón con sus condiciones de ensayo particulares. La geometría del cordón varía a lo largo de su trayectoria, con tendencias de acumulación de material en la parte posterior, lo que resulta en una sobredimensión. La sección media alcanza un estado más estable, caracterizado por una geometría uniforme, mientras que la sección final refleja estrechamiento y descenso debido a la reducción del flujo de material y la extinción del arco.

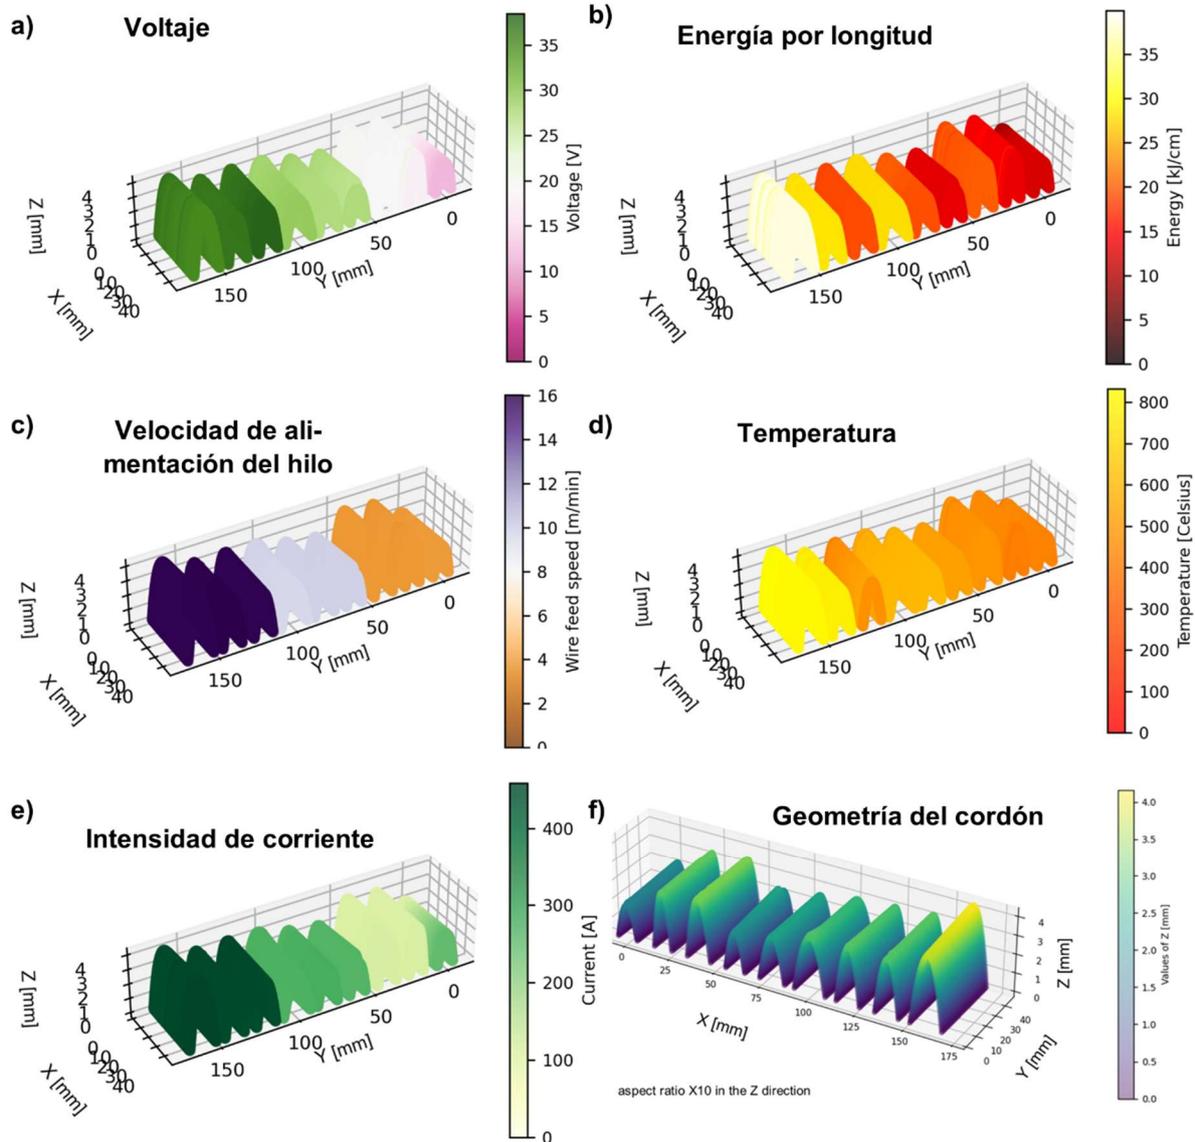
Figura 2: Cordones medidos depuestos y número de ensayo



Los datos analizados y tratados durante el proceso de fabricación de los cordones se muestran en un contexto tridimensional con ejes cartesianos X, Y y Z en milímetros en la Figura 3. Este gráfico tridimensional muestra la evolución de seis parámetros clave del proceso a lo largo del tiempo. Cada una de las variables recogidas se representa en un subapartado, y la intensidad del color en el gráfico representa el valor de la propiedad en cada punto tridimensional. En la Figura 3, las variables representadas son las siguientes: (a) el voltaje, medido en el equipo de soldadura, que permanece constante durante la mayor parte del proceso; (b) la energía por unidad de longitud, calculada a partir de diferentes medidas siguiendo la ecuación (3), que es mayor en las capas inferiores debido al sustrato más frío, y luego disminuye su valor; (c) la velocidad de avance del hilo, medida en el alimentador de hilo; (d) la temperatura, medida por el pirómetro, que aumenta en la zona donde es más alta en la sección transversal; (e) la corriente medida en el generador; y (f) la geometría del cordón, medida en los puntos de control que configuran una medición aproximada del cordón cero

La medición de la geometría de los cordones de la Figura 2 implica escanear su superficie con un perfilómetro láser en 46 puntos de control en la sección media. Se calcula el centro del cordón de los puntos del perfil para determinar el perfil transversal del cordón. Se realizan ajustes para establecer el plano sustrato de referencia, esencial para mediciones y análisis precisos. A partir de la referencia y el centro se calcula altura y anchura del cordón. Se muestra en Figura 3f la geometría no como la nube de puntos si no como el cordón que formarían esos 46 perfiles modelizados según su altura y anchura siguiendo una forma parabólica, este método esta mejor expresado por los autores (Fernández-Zabalza et al., 2024).

Figura 3: Variables registradas durante el proceso de fabricación:



3.2 Aplicación de inteligencia artificial para la modelización de la geometría del cordón en aditivo arc-DED

En esta subsección, se presenta una aplicación de inteligencia artificial que utiliza datos para monitorear y analizar continuamente la geometría del cordón de soldadura sin necesidad de sensores físicos. La aplicación emplea un modelo de red neuronal entrenado en un conjunto de datos que incluye mediciones de cordones de soldadura obtenidas con sensores físicos y perfilómetros. Este modelo aprende a mapear las relaciones complejas entre los parámetros

del proceso y la geometría del cordón, permitiendo predecir la geometría del cordón para nuevas condiciones de proceso.

El modelo de TensorFlow utiliza una arquitectura más compleja con capas ocultas y requiere un proceso iterativo de entrenamiento con iteraciones y tamaños de lote. En este modelo, se utilizan dos capas ocultas con 64 neuronas cada una, activadas por la función de activación ReLU. Estas capas son responsables de procesar la entrada y extraer características importantes del conjunto de datos. Se utiliza la función de pérdida de error cuadrático medio (MSE), que calcula la diferencia entre las predicciones del modelo y los valores reales. El modelo se compila con el optimizador Adam, que ajusta los pesos del modelo durante el proceso de entrenamiento para minimizar la función de pérdida. Además, el modelo se entrena durante 100 iteraciones, lo que significa que pasa por todo el conjunto de datos de entrenamiento 100 veces, y el tamaño del lote se establece en 32.

Por otro lado, el modelo de regresión lineal es un modelo más simple que no tiene capas ocultas y se entrena de manera analítica. En la regresión lineal, la función de pérdida también es el error cuadrático medio (MSE), que calcula la diferencia entre las predicciones del modelo y los valores reales. El optimizador utilizado en este caso es el algoritmo de mínimos cuadrados ordinarios (OLS), que encuentra los coeficientes que minimizan la suma de los cuadrados de las diferencias entre las predicciones del modelo y los valores reales. No hay conceptos de iteraciones o tamaños de lote en la regresión lineal, ya que el modelo se entrena de manera analítica, utilizando todas las muestras de datos a la vez. Los resultados se comparan evaluando el error cuadrático medio (MSE) de cada modelo. Los resultados obtenidos muestran que el modelo de TensorFlow tiene un MSE de 0.166, mientras que el modelo de regresión lineal tiene un MSE de 0.179, lo que indica que el modelo de TensorFlow tiene un mejor rendimiento en la predicción de la geometría del cordón de soldadura.

En resumen, el modelo de TensorFlow y la regresión lineal son enfoques distintos para la predicción de la geometría del cordón de soldadura. Mientras que el primero emplea una arquitectura más compleja con capas ocultas y requiere un proceso iterativo de entrenamiento, la regresión lineal es un modelo más simple que se entrena de manera analítica, sin capas ocultas y sin la necesidad de iteraciones o tamaños de lote. La siguiente Tabla 5, resume algunas de las características de la red neuronal empleada.

Tabla 5: Características de la red neuronal empleada

Característica	Detalle	Característica	Detalle
Tipo de red neuronal	Red neuronal prealimentada	Optimizador	Adam
Arquitectura	Feed Forward (Red Neuronal de Avance)	Número de épocas	100
Capas ocultas	2	Tamaño del lote	32
Neuronas por capa oculta	64	Datos de entrada	Pose robot [X, Y, Z, W, P, R] Caudal Gas, Amperaje, Voltaje, Velocidad, Alimentación Hilo y Temperatura pirómetro
Función de activación	ReLU (Rectified Linear Activation)	Total de datos medidos	414

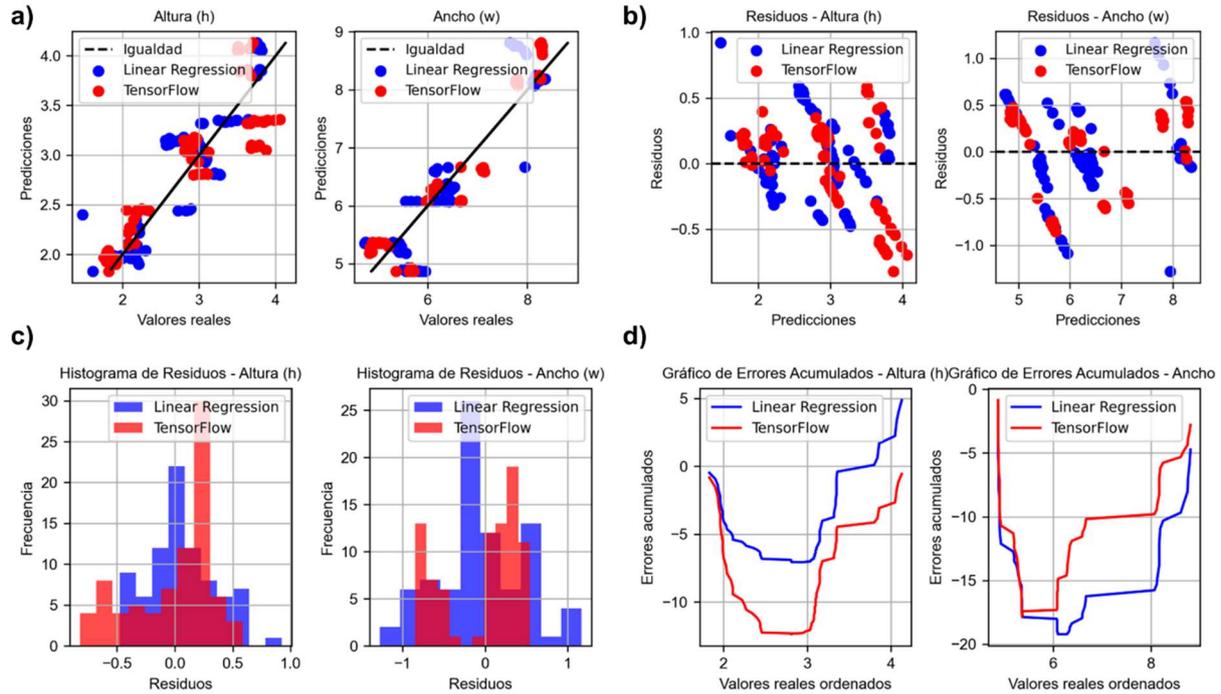
La Figura 4 muestra la comparación entre las predicciones realizadas por los modelos de regresión lineal y TensorFlow en relación con los valores reales para dos características del

cordón de soldadura: altura (h) y ancho (w). En la Figura 4a, se representa un gráfico de dispersión donde en el eje x se encuentran los valores reales de la altura del cordón de soldadura (h), mientras que en el eje y se muestran las predicciones realizadas por los modelos. Los puntos azules representan las predicciones del modelo de regresión lineal, mientras que los puntos rojos representan las predicciones del modelo de TensorFlow. Cada punto en el gráfico representa una observación en el conjunto de datos de prueba. La leyenda indica qué color corresponde a qué modelo. En ambos gráficos, la cercanía de los puntos a la línea diagonal de igualdad (representada por una línea punteada negra) indica una mayor precisión en las predicciones. Idealmente, todas las predicciones deberían estar alineadas con esta línea, lo que indicaría una correspondencia perfecta entre las predicciones y los valores reales. Se observa una mayor precisión del modelo TensorFlow aunque existe cierta infraestimación cuando los valores de altura (h) son mayores a 3.5 mm. Esta apreciación y la distribución de los residuos para todo los valores se observa en mejor medida en la Figura 4b, en donde nuevamente, los puntos azules corresponden a los residuos propios de las predicciones del modelo de regresión lineal, mientras que los puntos rojos corresponden a los residuos de las predicciones del modelo de TensorFlow.

Además de los gráficos de dispersión, el análisis incluye un histograma de residuos Figura 4c y un gráfico de errores acumulados, Figura 4d, para evaluar la precisión de las predicciones de los modelos. En el histograma de residuos, se representan las diferencias entre los valores reales y las predicciones realizadas por los modelos. Cada barra en el histograma muestra la frecuencia con la que ocurre una determinada diferencia entre los valores reales y las predicciones. Idealmente, los residuos deberían distribuirse alrededor de cero, lo que indicaría que las predicciones son precisas y no presentan sesgo sistemático. En el caso de la distribución de los residuos en el caso de TensorFlow se muestra un patrón particular, podría indicar que el modelo tiene dificultades para predecir ciertas características del cordón de soldadura. Por ejemplo, a la hora de analizar la forma del histograma de Tensorflow para el ancho la forma es claramente bimodal asimétrica.

Por otro lado, el gráfico de errores acumulados Figura 4d muestra cómo se acumulan los errores a medida que los valores reales aumentan. Se observa como los predictores tiende a infravalorar el parámetro en un rango más amplio de datos. Estos gráficos permiten visualizar y comparar visualmente la capacidad predictiva de ambos modelos para las características de altura y ancho del cordón de soldadura.

Figura 4: Variables registradas durante el proceso de fabricación:



4. Conclusiones

Nuestro artículo presenta una aplicación de inteligencia artificial para el monitoreo y análisis continuo de la geometría del cordón de soldadura en procesos de fabricación aditiva. Esta aplicación utiliza un modelo de red neuronal entrenado en datos recopilados mediante sensores físicos para predecir la geometría del cordón de soldadura, que se contrasta con los datos del perfilómetro, en función de los parámetros del proceso. Luego, se comparan dos modelos de predicción: uno de regresión lineal y otro de red neuronal básico. Se evalúa la precisión de ambos modelos mediante la medición del error cuadrático medio (MSE) y se analizan gráficamente las predicciones frente a los valores reales, así como la distribución de los residuos y la acumulación de errores en función de los valores reales. Algunas conclusiones son:

- El estudio se centró en ensayos de fabricación aditiva de cordones de soldadura utilizando la aleación Invar36, explorando diferentes condiciones de velocidad de alimentación del hilo (3 niveles 4, 10, 16 m/min) y ratio (5, 7.5 y 10) para ensayar en diferentes condiciones.
- Los datos analizados revelan una evolución significativa de los parámetros clave del proceso a lo largo del tiempo, mostrando cómo la geometría del cordón varía a lo largo de su trayectoria. La medición de la geometría del cordón, realizada con un perfilómetro láser en múltiples puntos de control, proporciona una comprensión detallada de la forma y las dimensiones del cordón, esencial para evaluar la calidad y la consistencia de la soldadura obtenida mediante arc-DED.
- La aplicación de inteligencia artificial utiliza un modelo de red neuronal entrenado en datos de geometría del cordón de soldadura demuestra una mejora significativa en la predicción de esta geometría en comparación con la regresión lineal. El modelo de TensorFlow, con capas ocultas, función de pérdida MSE, optimizador Adam, y entrenamiento iterativo durante 100 iteraciones con un tamaño de lote de 32, muestra un MSE de 0.166, mientras que la regresión lineal tiene un MSE de 0.179. Esto indica

un mejor rendimiento del modelo de TensorFlow. Los gráficos de dispersión, histograma de residuos y gráfico de errores acumulados proporcionan una comparación visual y cuantitativa de la precisión de ambos modelos, mostrando la mayor precisión del modelo de TensorFlow en general, aunque con ciertas limitaciones en la predicción de ciertas características del cordón de soldadura, como se refleja en la forma del histograma de residuos y el patrón de acumulación de errores en el gráfico de errores acumulados.

Este enfoque proporciona una alternativa basada en datos a los sensores físicos tradicionales y ofrece una herramienta potencialmente más eficiente para el control de calidad en procesos de soldadura. Se ha estudiado una variedad de condiciones de fabricación, considerando la velocidad de alimentación y la velocidad del alambre en la deposición de Invar.

Referencias

- Aldalur, E., Suárez, A., & Veiga, F. (2022). Thermal expansion behaviour of Invar 36 alloy parts fabricated by wire-arc additive manufacturing. *Journal of Materials Research and Technology*, 19, 3634-3645. <https://doi.org/10.1016/j.jmrt.2022.06.114>
- Chu, J. B. (Jeffrey B. (2020). *Investigating the feasibility and impact of integrating wire-arc additive manufacturing in aerospace tooling applications* [Thesis, Massachusetts Institute of Technology]. <https://dspace.mit.edu/handle/1721.1/126954>
- Fernández-Zabalza, A., Veiga, F., Suárez, A., & López, J. R. A. (2024). The Use of Virtual Sensors for Bead Size Measurements in Wire-Arc Directed Energy Deposition. *Applied Sciences*, 14(5), Article 5. <https://doi.org/10.3390/app14051972>
- García Gascón, C. (2023). *Diseño y fabricación de moldes para materiales compuestos en fabricación aditiva de gran formato: Hacia la economía circular del proceso*. [Tesis de Doctorado, Universitat Politècnica de València] <https://riunet.upv.es/handle/10251/195432>
- He, F., Yuan, L., Mu, H., Ros, M., Ding, D., Pan, Z., & Li, H. (2023). Research and application of artificial intelligence techniques for wire arc additive manufacturing: A state-of-the-art review. *Robotics and Computer-Integrated Manufacturing*, 82, 102525. <https://doi.org/10.1016/j.rcim.2023.102525>
- Huang, G., He, G., Gong, X., He, Y., Liu, Y., & Huang, K. (2024a). Additive manufacturing of invar 36 alloy. *Journal of Materials Research and Technology*. <https://doi.org/10.1016/j.jmrt.2024.02.221>
- Jiao, G., Fang, X., Chen, X., Xi, N., Zhang, M., Liu, Y., Wu, H., & Huang, K. (2023). The origin of low thermal expansion coefficient and enhanced tensile properties of Invar alloy fabricated by directed energy deposition. *Journal of Materials Processing Technology*, 317, 117994. <https://doi.org/10.1016/j.jmatprotec.2023.117994>
- Oh, Y., Busogi, M., Ransikarbum, K., Shin, D., Kwon, D., & Kim, N. (2019). Real-time quality monitoring and control system using an integrated cost effective support vector machine. *Journal of Mechanical Science and Technology*, 33(12), 6009-6020. <https://doi.org/10.1007/s12206-019-1145-9>
- Shevchik, S. A., Masinelli, G., Kenel, C., Leinenbach, C., & Wasmer, K. (2019). Deep Learning for In Situ and Real-Time Quality Monitoring in Additive Manufacturing Using Acoustic Emission. *IEEE Transactions on Industrial Informatics*, 15(9), 5194-5203. <https://doi.org/10.1109/TII.2019.2910524>
- Sokolowski, W. M., Jacobs, S. F., Lane, M. S., O'Donnell, T. P., & Hsieh, C. (1993). Dimensional stability of high-purity Invar 36. *Quality and Reliability for Optical Systems*, 1993, 115-126. <https://doi.org/10.1117/12.164978>
- Sood, A., Schimmel, J., Ferreira, V. M., Bosman, M., Goulas, C., Popovich, V., & Hermans, M. J. M. (2023). Directed energy deposition of Invar 36 alloy using cold wire pulsed gas tungsten arc welding: Effect of heat input on the microstructure and functional

- behaviour. *Journal of Materials Research and Technology*, 25, 6183-6197. <https://doi.org/10.1016/j.jmrt.2023.06.280>
- Suárez, A., Ramiro, P., Veiga, F., Ballesteros, T., & Villanueva, P. (2023). Benefits of Aeronautical Preform Manufacturing through Arc-Directed Energy Deposition Manufacturing. *Materials*, 16(22), Article 22. <https://doi.org/10.3390/ma16227177>
- Veiga, F., Suárez, A., Artaza, T., & Aldalur, E. (2022). Effect of the Heat Input on Wire-Arc Additive Manufacturing of Invar 36 Alloy: Microstructure and Mechanical Properties. *Welding in the World*, 66(6), 1081-1091. <https://doi.org/10.1007/s40194-022-01295-4>
- Zhou, B., & Tian, T. (2021). A path planning method of lattice structural components for additive manufacturing. *The International Journal of Advanced Manufacturing Technology*, 116(5), 1467-1490. <https://doi.org/10.1007/s00170-021-07092-5>

Communication aligned with the Sustainable Development Goals

