

PREDICCIÓN DE PROPIEDADES MECÁNICAS APLICANDO UN SISTEMA DE INFERENCIA NEURO-DIFUSO EN MANUFACTURA ADITIVA

Barrionuevo, Germán O.¹

gobarrionuevo@uc.cl

<https://orcid.org/0000-0002-4613-3234>

¹Departamento de Ingeniería Mecánica y Metalúrgica, Escuela de Ingeniería, Pontificia Universidad Católica de Chile, Av. Vicuña Mackenna, 4860, Macul, Santiago, Chile

Recibido (06/05/20), Aceptado (22/05/20)

Resumen: En el presente trabajo se evalúa la aplicabilidad de una herramienta de inteligencia artificial para la predicción de propiedades mecánicas en manufactura aditiva (AM). La fabricación aditiva brinda la posibilidad de procesar varios materiales desde polímeros y cerámicos hasta metales, sin embargo, la utilización de esta tecnología se ve limitada debido a que las propiedades mecánicas no son homogéneas, debido principalmente a la naturaleza de fabricación por capas, ya que existe porosidad entre capas adyacentes lo cual incrementa la velocidad de degradación de materiales fabricados por AM. Para la predicción de la porosidad en probetas de acero inoxidable 316L fabricadas mediante fusión selectiva láser (SLM) se aplica una técnica de machine learning y se evalúa la precisión del sistema de inferencia neuro-difuso (ANFIS). Se utilizó un total de 64 conjuntos de datos, de los cuales el 80% se utilizó para entrenamiento, 10% para validación y 10% para predicción. Se evaluaron distintas configuraciones de hiperparámetros hasta obtener predicciones con mínimo error, se evaluó la precisión del sistema aplicando tres métricas estadísticas: error cuadrático medio (RMSE), error porcentual absoluto medio (MAPE) y el coeficiente de determinación (R2). Como conclusión se establece que la aplicación de ANFIS resulta fácil de implementar y la precisión alcanzada es de 1,364, 0,129 y 0,9998 para RMSE, MAPE y R2 respectivamente.

Palabras Clave: Manufactura aditiva, Fusión selectiva láser, Porosidad, Sistema de inferencia neuro-difuso.

PREDICTION OF MECHANICAL PROPERTIES APPLYING A NEURO-FUZZY INFERENCE SYSTEM IN ADDITIVE MANUFACTURING

Abstract: In this work the applicability of an artificial intelligence tool is evaluated for the prediction of mechanical properties in parts built by additive manufacturing (AM). The AM process brings the possibility to process many materials from polymers and ceramics to metals, however the applicability of this technology is limited due to the anisotropy inherent to the layered manufacturing process, which generate porosity between adjacent layers accelerating the degradation of the parts built. For the porosity prediction in samples of stainless steel 316L built by selective laser melting (SLM) a hybrid machine learning tool is applied. A total of 64 data sets were used, of which 80% was used for training, 10% for validation and 10% for prediction. Different hyperparameters configurations were evaluated until predictions were obtained with minimum error, the accuracy of the system was evaluated by applying three statistical metrics: mean square error (RMSE), mean absolute percentage error (MAPE) and the coefficient of determination (R2). In conclusion, it is established that the use of a neuro-fuzzy inference system is easy to implement, and the precision reached is 1,364, 0.129 and 0.9998 for RMSE, MAPE and R2 respectively.

Keywords: Additive manufacturing, Selective laser melting, Porosity, Neuro-fuzzy inference system.

I. INTRODUCCIÓN

La fabricación aditiva (AM), también denominada impresión 3D, se desarrolló inicialmente como una herramienta para prototipado [1]. AM amplía la libertad de diseño y brinda la posibilidad de procesar casi cualquier material, desde metales, polímeros, cerámicos hasta materiales compuestos [2]. Dentro de la fabricación metálica se puede distinguir entre dos grandes tecnologías, una donde se tiene un lecho de polvo metálico y a través de una fuente de calor se va fundiendo el material selectivamente y la segunda donde se deposita el material directamente [3]. La tecnología de fusión selectiva láser (SLM) es un proceso de fusión de lecho de polvo diseñado para usar un láser de alta densidad de potencia para fundir y fusionar regiones selectivas de polvo, capa por capa, según datos de diseño asistido por computadora (CAD), donde es posible construir geometrías complejas, imposibles de conseguir por procesos convencionales [4][5]. Para adoptar esta tecnología a la industria es necesario comprender cómo los parámetros de procesamiento, propiedades del material y condiciones ambientales afectan el desempeño de la pieza fabricada.

Las propiedades mecánicas dependen de la microestructura y en el caso de SLM debido al vertiginoso ciclo de calentamiento y enfriamiento producido por la interacción material-láser se generan mecanismos difíciles de controlar como la extensión de la piscina fundida, turbulencia, material sin fundir, oxidación del material, etc. [6]. Este comportamiento se repite capa a capa, lo cual hace que exista una fuerte anisotropía, debida principalmente a la evolución de la microestructura [3]. El crecimiento, morfología y orientación de grano dependen en gran medida del gradiente de temperatura y la tasa de solidificación [7]. Sin embargo, la evolución de esta tecnología permitirá generar piezas de repuestos para diversas maquinarias en particular la maquinaria agrícola y de esa manera reducir el lucro cesante producto de la maquinaria defectuosa cuya mantención se retrasa por falta de repuestos en el momento de la reparación.

Fusión selectiva láser: Efecto de los parámetros de fabricación

Para obtener piezas con propiedades mecánicas similares a las fabricadas convencionalmente es necesario reducir la porosidad, varios estudios realizados muestran el efecto de los parámetros de procesamiento sobre la microestructura, propiedades mecánicas, resis-

tencia a la corrosión y desgaste. Sun et al. [6] encontró que si se incrementa la potencia láser, el tamaño de grano también crece, mientras que si se incrementa la velocidad de escaneo, el tamaño de grano decrece, el refinamiento del grano mejora las propiedades mecánicas. Zhang et al. [8] analizó la influencia de la orientación y el ángulo de escaneo donde la máxima resistencia a la tensión se obtiene cuando la dirección de fabricación es perpendicular a la dirección de tracción, mientras que el ángulo de escaneo óptimo es de 30°. Salman et al. [9] recomienda girar 79° el ángulo de escaneo después de cada capa para reducir la formación de poros durante el procesamiento por SLM. Lin et al. [10] evalúan el efecto de la velocidad de impresión sobre la densidad relativa y resistencia a corrosión. Aunque se han investigado varios parámetros de fabricación para obtener piezas con densidad relativa superior al 99%, no existe un estudio sistematizado para la identificación del rango de parámetros con el cual es posible obtener máxima densificación y por consiguiente mejorar las propiedades mecánicas de piezas fabricadas por SLM.

Respecto a la estrategia de fabricación, no existe un consenso sobre qué técnica proyecta los mejores resultados [11]. Zhang et al. [8] examinan el efecto del ángulo de escaneo desde 0 hasta 90°, con incrementos sucesivos de 15° y de acuerdo a sus resultados la máxima densidad relativa se obtiene a los 30° con un patrón de escaneo unidireccional. En general se puede hablar de cuatro tipos de patrones de escaneo: unidireccional, zigzag, barrido transversal y patrón de islas o tablero de ajedrez. Salman et al. [9] concluye que las mejores propiedades mecánicas se obtienen con un patrón unidireccional siempre que se escanee el contorno previamente, ya que el contorno actúa como límite para la transferencia de calor.

Para evitar fenómenos no deseados como material sin fundir y salpicadura del material fundido, existe una ventana de procesamiento en función de la densidad de energía, dada por la ecuación

$$E = \frac{P}{h \times v \times l} , \quad (1)$$

Donde, E: es la densidad de energía [J/mm³], P: potencia láser [W], h: distancia entre escaneo [mm], v: velocidad de escaneo [mm/s] y l: altura de capa [mm].

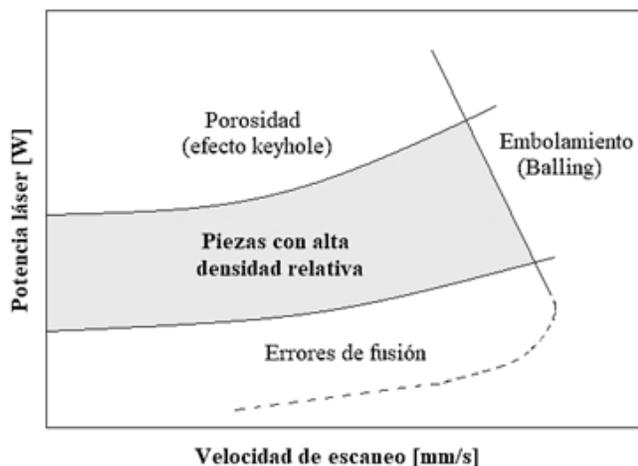


Figura 1. Efecto de la interacción potencia láser-velocidad de escaneo sobre la calidad de un material procesado por SLM

De acuerdo a Bourell et al. [12], los parámetros que definen la calidad de un material procesado por SLM es la potencia láser y la velocidad de escaneo (Figura 1), donde si la potencia del láser es baja y la velocidad de barrido es alta se origina el fenómeno de embolamiento (balling) y por el contrario si la potencia del láser es alta y la velocidad es baja se genera evaporación del material (efecto keyhole) [5].

Inteligencia artificial en procesos de manufactura

Debido a la necesidad de optimizar los procesos de fabricación y gracias al incremento del poder computacional, algoritmos de inteligencia artificial (IA) se han empleado para procesamiento de materiales. IA se refiere a la capacidad de un computador para aprender una tarea específica a partir de datos [13]. Una de las técnicas de IA más empleada es el aprendizaje automático o machine learning (ML), los algoritmos de ML utilizan métodos computacionales para aprender información directamente de los datos sin depender de una ecuación o modelo predeterminado [14]. Dentro de los algoritmos de ML, los modelos híbridos destacan por su flexibilidad, ya que una parte puede actuar como estimador o predictor, y otra parte actuar como optimizador [15]. Las redes neuronales artificiales (ANN) tienen la capacidad de aprender y entrenarse por sí mismas, se destacan en áreas donde la solución es difícil de expresar en algoritmos tradicionales [16]. Por otro lado, la lógica difusa (FL) es un método de razonamiento que se asemeja al razonamiento humano, FL permite confiar en la experiencia de expertos que ya conocen el proceso, diferente a las redes neuronales, que toma datos de entrenamiento y generan modelos cercanos [13][16]. Los sistemas neuro-difusos son sistemas inteligentes

híbridos que integran los principios ANN y FL y tiene el potencial de capturar los beneficios de ambos en un solo marco [16]. Un sistema adaptativo de inferencia neuro-difusa (ANFIS), es un modelo híbrido de ML que se ha aplicado en diferentes áreas para la optimización y predicción en procesamiento de materiales e ingeniería [17][18], detección de enfermedades [19], predicción de velocidad [20], control de calidad [21], consume energético [15], etc.

Gracias a la optimización de algoritmos de ML, se ha incrementado el desarrollo de técnicas para el modelado y predicción en procesos de manufactura, Sen et al. [22] aplicaron ANFIS para predecir el rendimiento de una fresadora CNC en Inconel 690, evaluando la rugosidad, fuerza y temperatura de corte, se utilizaron 29 conjuntos de datos y la arquitectura de la red consistía de 5 capas: capa de entrada, la capa de fusificación, la capa del proceso de inferencia, la capa de des-fusificación y la capa de salida. Las predicciones alcanzaron valores alentadores con un error inferior al 3.8%. Saw et al. [23] definieron parámetros de procesamiento óptimos en el proceso de perforación para reducir el desgaste de la herramienta, se utilizó 27 conjuntos de datos para el entrenamiento, y 15 conjuntos de datos para testeo y verificación, aplicaron un enfoque híbrido entre ANFIS y algoritmos genéticos, obteniendo predicciones con un error relativo inferior al 3%. Garg et al. [24] aplicaron la metodología de superficie de respuesta (RSM) para alimentar una ANN y predecir la rugosidad y ondulación de la superficie de una pieza fabricada por SLM, se utilizó un total de 27 conjuntos de datos para el proceso de entrenamiento de los cuales se seleccionó 5 para verificación. Zhang et al. [25] desarrollaron un modelo de predicción de resistencia a la tracción basado en aprendizaje profundo o deep learning (DL) en modelado por deposición fundida (FDM), considerando las propiedades del material, parámetros del proceso y señales de sensores para alimentar la red neuronal. El error porcentual absoluto medio (MAPE) obtenido fue inferior al 7%.

La aplicabilidad de DL requiere de una gran cantidad de datos, un extenso proceso de entrenamiento y un alto poder computacional. Uno de los objetivos de este trabajo es evaluar la precisión de un sistema híbrido de ML que permita predecir la densidad relativa en piezas fabricadas por SLM, por esta razón, ANFIS aparece como una buena solución ya que brinda ciertas ventajas respecto a otras herramientas de ML, es muy útil cuando no se cuenta con una gran cantidad de conjunto de datos, su proceso de entrenamiento es muy fácil y ya que es una red neuronal optimizada, ayuda al algoritmo a ser más rápido y más preciso en términos de eficiencia

[26][27]. En el desarrollo del presente trabajo se aplica (ANFIS) para la predicción de la densidad relativa en probetas de acero inoxidable 316L fabricadas mediante fusión selectiva láser. Se toma como parámetros de entrenamiento la potencia láser, velocidad de escaneo, altura de capa y distancia entre escaneos. Se utiliza un total de 64 conjuntos de datos para el entrenamiento, validación y predicción y se evalúa la precisión del sistema aplicando diferentes métricas estadísticas.

II. METODOLOGÍA

A. Generación de base de datos

Para la generación de la base de datos se realizó una exhaustiva búsqueda bibliográfica de piezas de acero inoxidable 316L procesadas por SLM (Tabla I), se consolidó un total de 64 conjunto de datos, 80% fueron empleados para entrenamiento, 10% para validación y 10% para la predicción.

Tabla I. Referencias para la generación de la base de datos

Conjunto de datos	Referencia	Año
7	[8]	2019
4	[9]	2019
5	[10]	2019
16	[28]	2020
4	[29]	2014
23	[30]	2017
5	[31]	2016

B. Entrenamiento y validación

Se implementó un sistema adaptativo de inferencia neuro-difuso (ANFIS) en Matlab de tipo Takagi-Sugeno para el entrenamiento, validación y predicción de la densidad relativa en probetas de acero inoxidable 316L fabricadas mediante SLM, los parámetros de entrada para alimentar el sistema fueron la potencia láser, velocidad de escaneo, altura de capa y distancia entre pasadas, con un rango de datos de acuerdo a la Tabla II. La variable de salida es la densidad relativa, donde el valor mínimo, media y valor máximo es de 91.20, 97.153 y 99.90% respectivamente.

Tabla II. Rango de parámetros de entrada

Parámetros	Rango		
	min	media	max
Potencia láser (W)	25	122	220
Velocidad de escaneo (mm/s)	111	590	1700
Altura de capa (mm)	0.02	0.035	0.05
Distancia entre pasadas (mm)	0.03	0.088	0.15

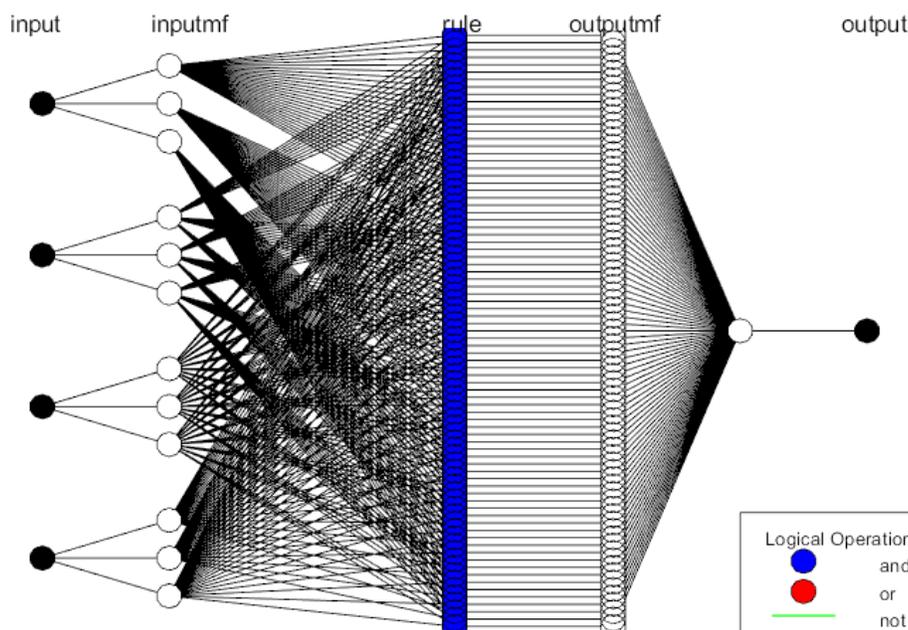


Figura 2. Arquitectura del sistema utilizado para el entrenamiento.

Para la generación del conjunto de datos de entrenamiento se aleatorizó la base de datos y se tomaron los primeros 48 conjuntos de datos, equivalentes a 240 valores. Para la generación del sistema de inferencia se evaluaron distintas configuraciones de funciones de membresía tipo triangular, trapezoidal, de campana y distribución gaussiana. El método de entrenamiento escogido fue tipo híbrido, la tolerancia del error fue de 1×10^{-5} y 10 iteraciones o épocas. La arquitectura del sistema se indica en la Figura 2, donde en la capa inicial se encuentra los parámetros de entrada, en la siguiente capa se tiene las funciones de membresía para el proceso de fusificación, la capa de reglas corresponde al sistema de inferencia, en la siguiente capas se realiza el proceso de des-fusificación y la capa final se tiene la respuesta del sistema, en este caso la densidad relativa.

Una vez definida la arquitectura del sistema, se da inicio el entrenamiento hasta que el sistema alcance la precisión esperada. El proceso de validación se lo realizó con un total de ocho conjuntos de datos, equivalente a 40 datos; durante esta etapa es posible modificar parámetros del sistema para obtener una mejor precisión.

C. Predicción y evaluación de la precisión del sistema

Se evaluó la precisión del sistema utilizando tres métricas estadísticas: error cuadrático medio (RMSE), error porcentual absoluto medio (MAPE) y el coeficiente de determinación (R^2). Se utilizó un total de ocho conjuntos de datos, equivalente a 40 datos. Las métricas se determinan de acuerdo con la ecuación (2), (3) y (4):

$$RMSE = \sqrt{\frac{1}{N} \sum_i (e_i - p_i)^2} \quad (2)$$

$$MAPE = \frac{1}{N} \sum_i \frac{(e_i - p_i)}{p_i} \times 100 \quad (3)$$

$$R^2 = 1 - \left(\frac{\sum_i (e_i - p_i)^2}{\sum_i p_i^2} \right) \quad (4)$$

Donde e_i es el valor esperado, p_i es la predicción y N el número de datos utilizados.

III. RESULTADOS Y DISCUSIÓN

Los valores de densidad relativa, así como su frecuencia se detallan en la Figura 3. La evaluación de los hiperparámetros se muestra en la Tabla III, así como los parámetros de entrenamiento y validación. La evaluación de la precisión del sistema se indica en la Tabla IV. Más del 85% de los valores de densidad relativa se concentran entre 95,2 y 99,5 %, aunque este porcentaje representa una porosidad entre 0,5 y 4,8% que parecería un valor bajo, la existencia de porosidad entre capas adyacentes actúa como concentrador de tensiones, acelerando la degradación del material [32]. Además, gracias al incremento de investigaciones sobre AM y la optimización del proceso de SLM, se observa que un 25% del conjunto de datos empleado alcanza una densidad superior al 99%, mejorando las propiedades mecánicas como la resistencia a la tensión y maximizando la dureza, lo cual promueve la inclusión de esta tecnología en la industria.

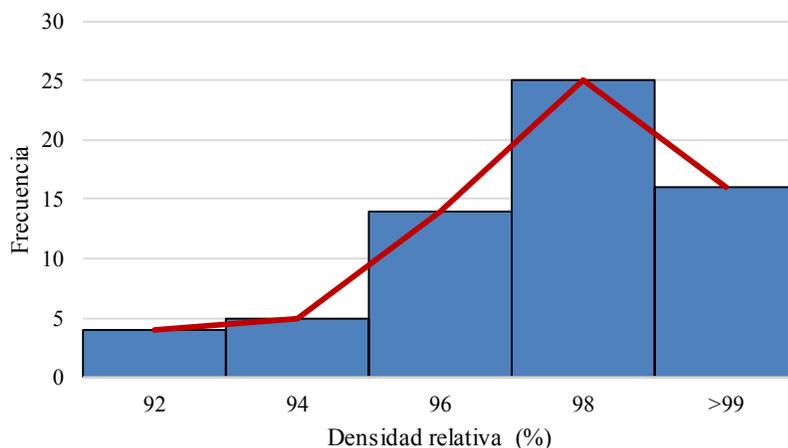


Figura 3. Histograma y polígono de frecuencias de densidad relativa.

Para el proceso de entrenamiento se evaluaron cuatro tipos de funciones de membresía, las funciones de tipo gaussiana presentan RMSE de 0,4742 para entre-

namiento, sin embargo, para el proceso de validación el valor de RMSE es de 9,6519. Para el tipo trapezoidal el valor de RMSE para el entrenamiento es de 0,5973 y

para evaluación RMSE de 7,41. Para el tipo triangular, se tiene RMSE de 0,4749 y 6,4328 para entrenamiento y validación respectivamente. Por tanto las funciones de membresía de tipo triangular presentan la mayor precisión, estos valores van en acuerdo con [23], donde se tiene que las funciones de tipo triangular presentan

menor RMSE en comparación con las funciones de tipo gaussiana y de campana. En este trabajo las funciones de campana generalizada presentan la menor precisión con un RMSE de 129,54 para validación y 0,4753 para entrenamiento.

Tabla III. Parámetros de evaluación para el entrenamiento y validación del sistema

Funciones de membresía		Parámetros de entrenamiento			Evaluación de la precisión (RMSE)	
Tipo	Número	Método de entrenamiento	Tolerancia del error	Épocas	Entrenamiento	Evaluación
campana	3	Híbrido	0,0001	10	0,47532	129,54
gauss	3	Híbrido	0,000001	5	0,47425	12,2122
gauss2	3	Híbrido	0,00001	10	0,47428	9,6519
trapezoidal	3	Híbrido	0,000001	5	0,59727	7,4123
triangular	3	Híbrido	0,000001	5	0,47489	6,4328

Para la evaluación de la precisión de las predicciones de densidad relativa, se aplicaron diferentes métricas para evitar sesgos estadísticos [17]. La precisión alcanzada RMSE es de 1,3646, MAPE de 0,1298 y R2 de 0,9998.

Tabla IV. Evaluación de la precisión del sistema de inferencia neuro-difuso

Valor esperado	Predicción	Parámetros de evaluación	
97	97,20		
95,9	95,52	RMSE	1,3646
97,7	94,60		
98,46	98,90	MAPE	0,1298
94,3	96,42		
99	98,95	R²	0,9998
98,84	99,21		
98,6	98,08		

IV. CONCLUSIONES

Este trabajo evaluó la aplicabilidad de un sistema de inferencia neuro-difuso para la predicción de la densidad relativa en probetas de acero inoxidable 316L fabricadas mediante SLM, se puede establecer las siguientes conclusiones:

A. La máxima densidad relativa se obtiene con una potencia láser mayor a 100 W, velocidad de escaneo entre 500 y 700 mm/s, altura de capa entre 0,02 y 0,03 mm y distancia entre pasadas de 0,08 mm.

B. La configuración de las funciones de membresía

muestra que con el tipo triangular se obtiene el menor error cuadrático medio RMSE = 0,4789 para entrenamiento y RMSE = 6,4328 para validación. Utilizando funciones de membresía de tipo trapezoidal se obtuvo RMSE = 0,5973 para entrenamiento y RMSE = 7,4123 para validación.

C. La precisión del sistema se evaluó aplicando tres métricas estadísticas, donde se obtuvo RMSE = 1,3646, MAPE = 0,1298 y R2 = 0,9998 utilizando funciones de membresía triangular, mientras que para el tipo trapezoidal se obtuvo un valor de RMSE = 2,1779.

RECONOCIMIENTO

El presente trabajo se desarrolló gracias al apoyo financiero por parte de la Secretaria de Educación Superior, Ciencia, Tecnología e Innovación, beca N° AR-SEQ-BEC-000329-2017.

A los profesores Magdalena Walczak y Jorge Ramos por sus oportunas asesorías en el desarrollo de la presente investigación.

REFERENCIAS

[1] A. Alafaghani, A. Qattawi, B. Alrawi, and A. Guzman, "Experimental Optimization of Fused Deposition Modelling Processing Parameters: A Design-for-Manufacturing Approach," *Procedia Manuf.*, vol. 10, pp. 791–803, 2017.

- [2]M. Rinaldi, T. Ghidini, F. Cecchini, A. Brandao, and F. Nanni, "Additive layer manufacturing of poly (ether ether ketone) via FDM," *Compos. Part B Eng.*, vol. 145, no. December 2017, pp. 162–172, 2018.
- [3]N. Li et al., "Progress in additive manufacturing on new materials: A review," *J. Mater. Sci. Technol.*, vol. 35, no. 2, pp. 242–269, 2019.
- [4]Y. Zhu, J. Zou, and H. Yang, "Wear performance of metal parts fabricated by selective laser melting: a literature review," *J. Zhejiang Univ. A*, vol. 19, no. 2, pp. 95–110, 2018.
- [5]C. Y. Yap et al., "Review of selective laser melting: Materials and applications," *Appl. Phys. Rev.*, vol. 2, no. 4, 2015.
- [6]X. Zhang, C. J. Yocom, B. Mao, and Y. Liao, "Microstructure evolution during selective laser melting of metallic materials: A review," *J. Laser Appl.*, vol. 31, no. 3, p. 031201, 2019.
- [7]J. Zhang, B. Song, Q. Wei, D. Bourell, and Y. Shi, "A review of selective laser melting of aluminum alloys: Processing, microstructure, property and developing trends," *J. Mater. Sci. Technol.*, vol. 35, no. 2, pp. 270–284, 2019.
- [8]Z. Zhang, B. Chu, L. Wang, and Z. Lu, "Comprehensive effects of placement orientation and scanning angle on mechanical properties and behavior of 316L stainless steel based on the selective laser melting process," *J. Alloys Compd.*, vol. 791, pp. 166–175, 2019.
- [9]O. O. Salman et al., "Impact of the scanning strategy on the mechanical behavior of 316L steel synthesized by selective laser melting," *J. Manuf. Process.*, vol. 45, no. July, pp. 255–261, 2019.
- [10]K. Lin et al., "Selective laser melting processing of 316L stainless steel: effect of microstructural differences along building direction on corrosion behavior," *Int. J. Adv. Manuf. Technol.*, vol. 104, no. 5–8, pp. 2669–2679, 2019.
- [11]F. Bartolomeu et al., "Predictive models for physical and mechanical properties of Ti6Al4V produced by Selective Laser Melting," *Mater. Sci. Eng. A*, vol. 663, pp. 181–192, 2016.
- [12]D. Bourell, J. Coholich, A. Chalancon, and A. Bhat, "Evaluation of energy density measures and validation for powder bed fusion of polyamide," *CIRP Ann. - Manuf. Technol.*, vol. 66, no. 1, pp. 217–220, 2017.
- [13]N. Siddique and H. Adeli, *Computational Intelligence: Synergies of Fuzzy Logic*. 2013.
- [14]S. M. Chelly and C. Denis, "Introducing Machine Learning," *Med. Sci. Sports Exerc.*, vol. 33, no. 2, pp. 326–333, 2001.
- [15]A. Mosavi, M. Salimi, S. F. Ardabili, T. Rabczuk, S. Shamshirband, and A. R. Varkonyi-Koczy, "State of the art of machine learning models in energy systems, a systematic review," *Energies*, vol. 12, no. 7, 2019.
- [16]G. Casalino, "Computational intelligence for smart laser materials processing," *Opt. Laser Technol.*, vol. 100, pp. 165–175, 2018.
- [17]J. Mathew, J. Griffin, M. Alamaniotis, S. Kanarachos, and M. E. Fitzpatrick, "Prediction of welding residual stresses using machine learning: Comparison between neural networks and neuro-fuzzy systems," *Appl. Soft Comput. J.*, vol. 70, pp. 131–146, 2018.
- [18]M. F. A. Zaharuddin, D. Kim, and S. Rhee, "An ANFIS based approach for predicting the weld strength of resistance spot welding in artificial intelligence development," *J. Mech. Sci. Technol.*, vol. 31, no. 11, pp. 5467–5476, 2017.
- [19]M. L. Huang, H. Y. Chen, and J. J. Huang, "Glaucoma detection using adaptive neuro-fuzzy inference system," *Expert Syst. Appl.*, vol. 32, no. 2, pp. 458–468, 2007.
- [20]M. Valčić, R. Antonić, and V. Tomas, "ANFIS based model for ship speed prediction," *Brodogradnja*, vol. 62, no. 4, pp. 373–382, 2011.
- [21]C.-W. Huang, L. Baron, M. Balazinski, and S. Achiche, "Comprehensive model optimization in pulp quality prediction: a machine learning approach," *PeerJ Prepr.*, pp. 1–18, 2017.
- [22]B. Sen, U. K. Mandal, and S. P. Mondal, "Advancement of an intelligent system based on ANFIS for predicting machining performance parameters of Inconel 690 – A perspective of metaheuristic approach," *Meas. J. Int. Meas. Confed.*, vol. 109, pp. 9–17, 2017.
- [23]L. H. Saw et al., "Sensitivity analysis of drill wear and optimization using Adaptive Neuro fuzzy –genetic algorithm technique toward sustainable machining," *J. Clean. Prod.*, vol. 172, pp. 3289–3298, 2018.
- [24]A. Garg, J. S. L. Lam, and M. M. Savalani, "Laser power based surface characteristics models for 3-D printing process," *J. Intell. Manuf.*, vol. 29, no. 6, pp. 1191–1202, 2018.
- [25]J. Zhang, P. Wang, and R. X. Gao, "Deep learning-based tensile strength prediction in fused deposition modeling," *Comput. Ind.*, vol. 107, pp. 11–21, 2019.
- [26]N. Mathur, I. Glesk, and A. Buis, "Comparison of adaptive neuro-fuzzy inference system (ANFIS) and Gaussian processes for machine learning (GPML) algorithms for the prediction of skin temperature in lower limb prostheses," *Med. Eng. Phys.*, vol. 38, no. 10, pp. 1083–1089, 2016.
- [27]G. O. Barrionuevo and J. A. Ramos-Grez, "Machine Learning for Optimizing Technological Properties of Wood Composite Filament-Timberfill Fabricated by

Fused Deposition Modeling BT - Applied Technologies,” 2020, pp. 119–132.

[28]T. Larimian, M. Kannan, D. Grzesiak, B. AlMangour, and T. Borkar, “Effect of energy density and scanning strategy on densification, microstructure and mechanical properties of 316L stainless steel processed via selective laser melting,” *Mater. Sci. Eng. A*, vol. 770, no. June 2019, p. 138455, 2020.

[29]Y. Sun, A. Moroz, and K. Alrbaey, “Sliding wear characteristics and corrosion behaviour of selective laser melted 316L stainless steel,” *J. Mater. Eng. Perform.*, vol. 23, no. 2, pp. 518–526, 2014.

[30]X. Qi, H. Feng, and L. Liu, “Microstructure and

mechanical properties of 316L stainless steel produced by selective laser melting,” *AIP Conf. Proc.*, vol. 2154, pp. 2117–2131, 2019.

[31]A. Röttger, K. Geenen, M. Windmann, F. Binner, and W. Theisen, “Comparison of microstructure and mechanical properties of 316 L austenitic steel processed by selective laser melting with hot-isostatic pressed and cast material,” *Mater. Sci. Eng. A*, vol. 678, no. April, pp. 365–376, 2016.

[32]B. Zhang, Y. Li, and Q. Bai, “Defect Formation Mechanisms in Selective Laser Melting: A Review,” *Chinese J. Mech. Eng. (English Ed.)*, vol. 30, no. 3, pp. 515–527, 2017.

RESUMEN CURRICULAR



Germán Omar Barrionuevo, Ingeniero en Mecatrónica, Magister en Manufactura y Diseño asistidos por computador por la Universidad de las Fuerzas Armadas - ESPE, candidato a Doctor en Ciencias de la Ingeniería por la Pontificia Universidad Católica de Chile. Su área de investigación es la optimización de procesos de manufactura aplicando algoritmos de inteligencia artificial.