

Predicción paramétrica del grado de porosidad en piezas fabricadas mediante el proceso de SLM empleando redes neuronales

Parametric prediction of porosity in parts manufactured by the SLM process using neural networks

J.M. Cisneros Villarreal^{1,2}, Luis Amezcua-Brooks¹, L.A. Reyes-Osorio^{1,2,*}, P. del C. Zambrano-Robledo^{1,2}, C. Garza-Rodríguez^{1,2}, O. López-Botello^{2,3}

¹Universidad Autónoma de Nuevo León, Facultad de Ingeniería Mecánica y Eléctrica
Centro de Investigación e Innovación en Ingeniería Aeronáutica
Ave. Pedro de Alba S/N, Cd. Universitaria, San Nicolás de los Garza, Nuevo León, 66455, México
²Laboratorio Nacional de Manufactura Aditiva y Digital (MADiT), México
³Tecnológico de Monterrey, Escuela de Ingeniería y Ciencias
Ave. Eugenio Garza Sada 2501 Sur, Monterrey, Nuevo León, 64849, México.
*larturoreyes@gmail.com

Resumen

Optimizar parámetros de fabricación en el proceso de fusión selectiva por láser (SLM) es fundamental para la obtención de geometrías con máxima densidad. El objetivo de esta investigación fue construir dos tipos de redes neuronales artificiales (RNA), Perceptrón Multicapa (MLP) y ADALINE, capaces de modelar el proceso de SLM. Se utilizó una base de datos del proceso y se identificaron parámetros esenciales con los cuales se entrenaron las RNA, por último se validó de la predicción obtenida. El error medio absoluto resultante fue menor al 1%. Al emplear las RNA se identificaron parámetros óptimos y se predijo la reducción en la porosidad de las piezas fabricadas en AISI 316L por el proceso de SLM. Se concluyó que utilizar RNA como una herramienta complementaria de optimización es eficiente en los modelos de predicción del proceso de SLM.

Abstract

Optimizing manufacturing parameters in the selective laser melting process (SLM) is essential for obtaining geometries with maximum density. The objective of this research was to build different artificial neural networks (ANN) that would allow predicting SLM process performance. A database of the process was generated and essential parameters were identified with which an ANN was trained; finally, the prediction obtained was validated. The mean absolute error obtained was less than 1%. Employing ANN, optimal parameters were identified and a reduction in the porosity of the pieces manufactured in AISI 316L by the SLM process was predicted. It was concluded that using ANN as a complementary optimization tool is efficient in the prediction models of the SLM process.

Palabras clave:

Redes Neuronales, Manufactura Aditiva, Acero inoxidable

Keywords:

Additive Manufacturing, SLM, Neural Networks, Stainless Steel

Introducción

La Manufactura Aditiva (MA) es definida por la Sociedad Americana para Pruebas y Materiales (ASTM, por sus siglas en inglés) como el proceso de unir materiales para construir objetos desde un modelo digital en tres dimensiones, usualmente capa por capa, en oposición a los métodos de manufactura por desprendimiento de material [1]. La MA es útil para la industria aeroespacial debido a la capacidad de fabricar piezas con una geometría compleja y/o la capacidad de fabricar pequeños volúmenes de piezas sin la necesidad de herramientas. Airbus Filtron posee varias máquinas SLS / SLM, lo que refuerza el argumento de que esta rama de la manufactura crecerá en uso para aplicaciones aeroespaciales [2].

El éxito de la consolidación de SLM está fuertemente influenciado por los fenómenos que ocurren durante el procesamiento y parece ser un problema de optimización, ya que la calidad de solidificación depende de dichos fenómenos [3,

4, 5]. Aunque se confirma que existe una gran multitud de parámetros, investigaciones previas aseguran que sólo una pequeña cantidad de los parámetros (mostrados en la Figura 1) influyen en las propiedades finales de la pieza creada mediante el proceso de SLM. De acuerdo a estas investigaciones, los parámetros que se utilizan para optimizar el proceso, son la potencia de láser (PL), estrategia de escaneo (SS), velocidad de escaneo (VE) y área de sombreado (HS) [17, 18, 19, 20].

Los procesos de optimización suelen requerir de técnicas que permitan ajustarse a datos altamente no lineales. Uno de los métodos de modelado no lineal más usado en los últimos años corresponde con las redes neuronales. La red neuronal más popular con propagación hacia atrás es la Perceptrón Multicapa (MLP). Este tipo de redes se compone de varias capas de nodos interconectados con funciones no lineales, de

transferencia o activación. Las MLP son de gran utilidad ya que se consideran como un aproximador universal. No existe ninguna restricción en cuanto al número de neuronas que puede tener cada una de las capas que integran la red, pero se debe escoger cuidadosamente toda la estructura según la aplicación a diseñar para que el entrenamiento pueda cumplir su objetivo y lo haga en un tiempo razonable [6, 7, 8].



Figura 1. Diagrama de los parámetros que intervienen en el proceso de SLM

Este modelo utiliza el algoritmo de retropropagación (backpropagation) que es de aprendizaje supervisado. Consiste en calcular la salida para cada entrada del conjunto de entrenamiento. Subsecuentemente se obtiene el error cuadrático producido por la salida deseada y la obtenida de todas las entradas, y se van calculando los errores hacia atrás. De esta manera se calcula la actualización de los pesos sinápticos [9]. Además este tipo de red cuenta con bias, las cuales son un valor de sesgo que permite cambiar la función de activación, lo que puede ser fundamental para un aprendizaje exitoso. Para aplicar el algoritmo general todas las funciones de activación deben ser diferenciables y es aconsejable utilizar la misma función de activación en cada capa [10, 11].

Las MLP son útiles para resolver casi cualquier tipo de problema y el factor primordial para obtener un buen desempeño es definir su estructura y configuración. Existen muchos estudios para tratar de determinar exactamente el número de neuronas y capas requeridas para este modelo pero ninguno sirve para absolutamente todas las aplicaciones [12]. De forma habitual se utilizan dos procedimientos para determinar el número de capas y de neuronas requeridas. El primero consiste en partir del modelo más básico posible e ir incrementando neuronas y capas hasta que la respuesta sea aceptable. La segunda forma de determinar la arquitectura es realizar lo inverso, iniciar con un modelo muy robusto e ir disminuyendo sus capas y neuronas mientras que el resultado continúe siendo aceptable [13].

El modelo de redes neuronales ADALINE es generalmente usado para Filtros Adaptivos, Control Automático y Procesamiento Digital de Señales y optimización de procesos. Su nombre proviene de las siglas anglosajonas "Adaptive Linear Combiner" o "Adaptive Linear Neuron" que se interpreta como un elemento o neurona de comportamiento lineal y de adaptación [14]. Su estructura es similar a la del Per-

ceptrón, con la diferencia que utiliza la función de activación lineal. Esta función permite que la salida pueda variar continua y linealmente. Su principal desventaja, al igual que el Perceptrón Monocapa, es que su conjunto de entrenamiento debe poseer separabilidad lineal [15].

Debido a que se consideran redes neuronas con respuestas de procesamiento gradual, es posible utilizar funciones de transferencia de forma sigmoideal como la función logística $\gamma(z) = 1/(1+e^{-z})$ o la tangente hiperbólica $\gamma(z) = \tanh(z)$. La Figura 2 muestra gráfica típica de la forma sigmoideal, mientras que en la Figura 3 se aprecia la de la tangente hiperbólica [16].

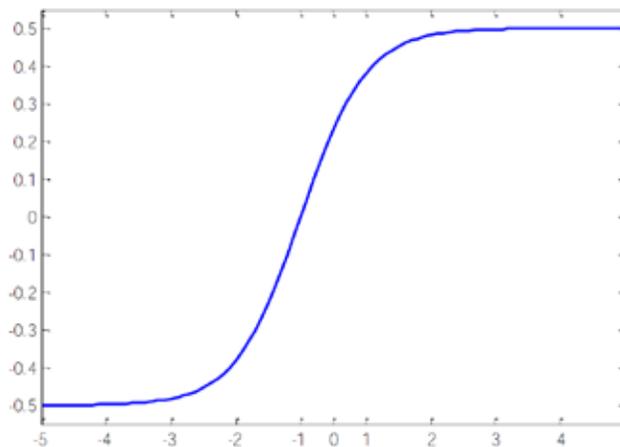


Figura 2. Gráfica típica de la forma sigmoideal logística

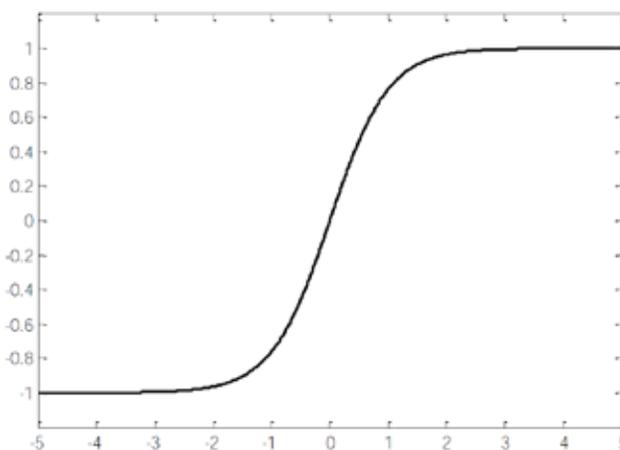


Figura 3. Gráfica típica de la forma sigmoideal tangencial hiperbólica

Materiales y métodos

En este trabajo se empleó la base de datos generada a partir de los resultados obtenidos en la experimentación realizada por Apinya Laohaprapanon (2011) para optimizar los parámetros proceso y obtener la predicción de la máxima densidad. Los datos utilizados en dicha investigación se obtuvieron de una máquina SLM desarrollada por el Centro Nacional de Tecnología de Metal y Materiales de Tailandia.

El acero inoxidable AISI 316L que se usó en la experimen-

tación estaba en forma de polvo con un 99% de pureza. Este polvo constó de una morfología esférica y un tamaño de partícula promedio de aproximadamente 36.6 μm [17]. La composición del material empleado se muestra en la Tabla 1.

Tabla 1. Composición del acero inoxidable AISI 316L (% masa) [17]

C	Cr	Cu	Mn	Mo	Ni	P	S	Si	Fe
≤ 0.03	18	≤ 0.05	≤ 2	2.25	13	≤ 0.025	≤ 0.01	≤ 0.75	Bal

Como se mencionó con anterioridad los parámetros tomados en cuenta para generar la base de datos fueron: la potencia de láser (PL), la estrategia de escaneo (SS), la velocidad de escaneo (VE) y el área de sombreado (HS), además se consideró el % de densidad.

La potencia del láser (PL) es dependiente de la máquina de SLM y en este caso trabaja a un máximo de 300 W. La velocidad de escaneo (VE) es la velocidad en que se mueve el láser sobre la superficie de trabajo. En las tecnologías comerciales, el movimiento del láser se realiza mediante unos espejos galvanométricos de gran precisión que son colocados en el centro de la plataforma de construcción. La estrategia de escaneo se utiliza para rellenar una sección transversal por la trayectoria de recorrido de escaneo. La estrategia de escaneo influye en la distribución de la temperatura en la pieza [17]. De acuerdo a investigaciones previas se determinó que las longitudes de escaneo láser deberían ser inferiores a 10 mm. Especialmente, en máquina sin sistema de precalentamiento [21]. En esta experimentación se utilizó un rango de 5-10 mm como estrategia de escaneo [17]. El área de sombreado (HS) es la distancia entre dos trayectorias de escaneo sucesivas, cuyo valor suele ser más bajo que el diámetro del rayo láser, como se muestra en la Figura 4. Un espacio de sombreado de 0 significa que las trayectorias de escaneo no se tocan. Una superposición de 1 significa escanear la misma trayectoria dos veces y, a partir de los experimentos, se observa que un valor del espacio de escaneo se define de la siguiente manera: $HS/d_x < 0.05$ [22].

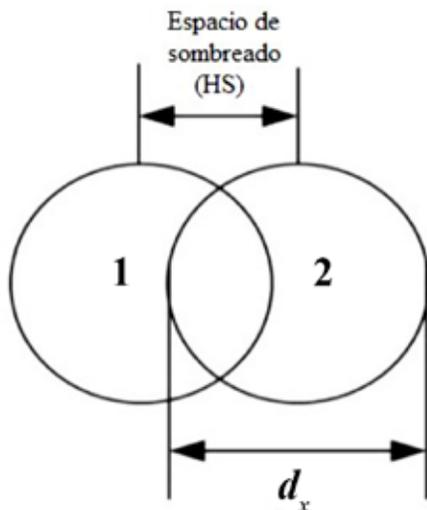


Figura 4. Porcentaje de superposición entre dos trayectorias sucesivas. HS es el espaciado de exploración y d_x el diámetro del haz

Para la medición de la densidad de las partes de SLM, se calcularon por el método de Arquímedes (ASTM B311-93) y las densidades relativas se obtuvieron en función de la densidad del material a granel [17].

La Tabla 2 muestra la base de datos normalizada con que se entrenaron las redes neuronales. La normalización es aplicada con el fin de eliminar redundancias e inconsistencias de dependencia en el diseño de la base de datos y para identificar cada grupo de datos relacionados con una clave primaria. En esta ocasión se utilizó la técnica de escala decimal.

Tabla 2. Normalización de base de datos empleada en el entrenamiento de las redes neuronales

No. de prueba	Entradas				Salida
	Potencia de láser (W)	Velocidad de escaneo (mm/s)	Espacio de sombreado (mm)	Estrategia de escaneo (mm)	Densidad (%)
Datos de entrenamiento					
1	0.075	0.200	0.04	0.10	0.8003
2	0.075	0.200	0.04	0.05	0.8277
3	0.175	0.200	0.04	0.10	0.9775
4	0.175	0.200	0.04	0.05	0.974
5	0.075	0.200	0.04	0.10	0.8609
6	0.075	0.200	0.04	0.05	0.8587
7	0.175	0.200	0.04	0.10	0.979
8	0.175	0.200	0.06	0.05	0.983
9	0.075	0.080	0.04	0.10	0.905
10	0.075	0.080	0.04	0.05	0.8809
11	0.175	0.080	0.04	0.10	0.9901
12	0.175	0.080	0.04	0.05	0.9731
13	0.075	0.080	0.04	0.10	0.9236
14	0.075	0.080	0.04	0.05	0.9223
Datos de validación					
15	0.175	0.080	0.04	0.10	0.9921
16	0.175	0.080	0.04	0.05	0.973
17	0.075	0.200	0.06	0.10	0.8004
18	0.075	0.200	0.06	0.05	0.8392
19	0.175	0.200	0.06	0.10	0.8893
20	0.175	0.200	0.06	0.05	0.8847

Neuroph Studio y Matlab fueron utilizados para construir las redes neuronales artificiales aplicadas para optimizar el proceso de SLM en este trabajo. En esta etapa, se seleccionaron los modelos feed-forward Multicapaca perceptrón y Adaline (Figura 6). La arquitectura de un modelo RNA feed-forward utilizado se muestra en la Figura 5. La primera capa está definida por las entradas, donde se asignaron los parámetros antes mencionados (PL, SS, VE, HS), seguida de las capas ocultas y por último la capa final, la cual es la capa de salida que define densidad predicha.

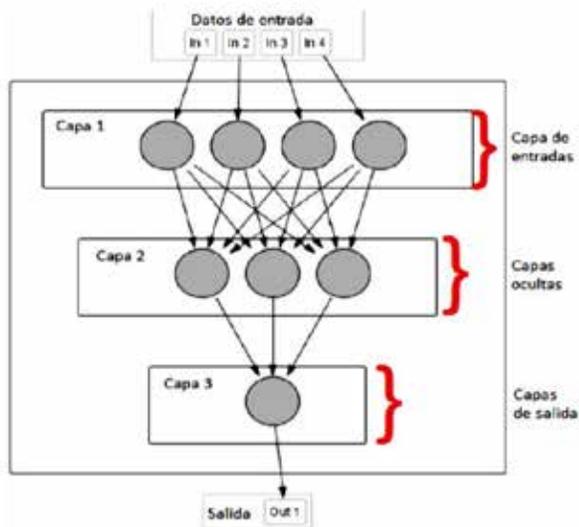


Figura 5. Arquitectura del modelo de RNA feed-forward

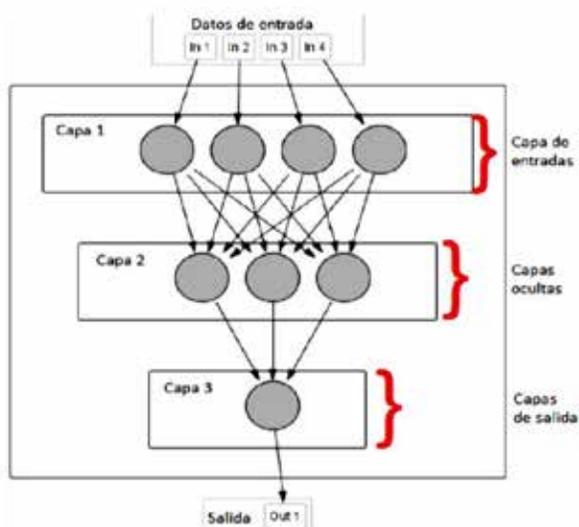


Figura 6. Arquitectura del modelo de ADALINE

Para poder determinar la estructura apropiada que debería tener la RN se realizó el entrenamiento de un conjunto de redes con diferentes configuraciones. El orden en que se ha escogido la variación de las configuraciones de las Redes Neuronales ha sido de tal forma de ir de la red más simple a la red más compleja. De la base de datos se consideraron 70 % para el entrenamiento y el 30% para la validación.

La Tabla 3 muestra un resumen de las distintas configuraciones probadas en las redes neuronales, mientras que en la Tabla 4 se observa la arquitectura y las características de las redes que tuvieron mejor desempeño.

Resultados y discusión

A continuación se muestran las gráficas de la evolución los errores de entrenamiento que se obtuvieron con cada una de las redes neuronales empleadas. Debido a que la red inicia en forma aleatoria, el error puede tener variaciones, pero el comportamiento y la tendencia suele ser muy similar.

En la Figura 7 se aprecia el descenso del error de entrenamiento de una red multicapa perceptrón con una arquitectura de tres capas ocultas y sin bias, el error disminuye con gran rapidez en las primeras 40 iteraciones y la tendencia indica que se mantendrá así.

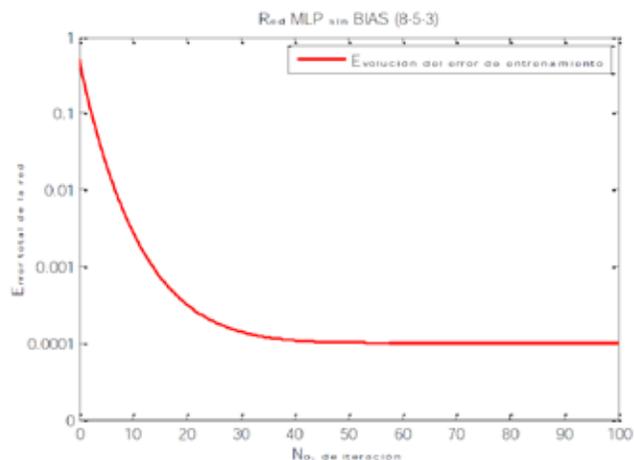
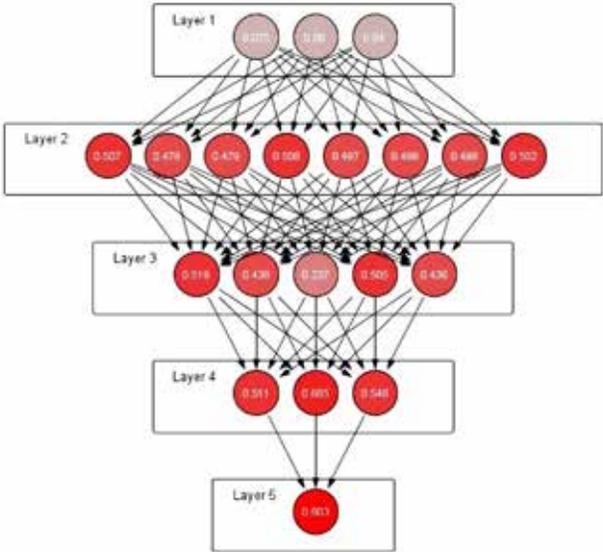
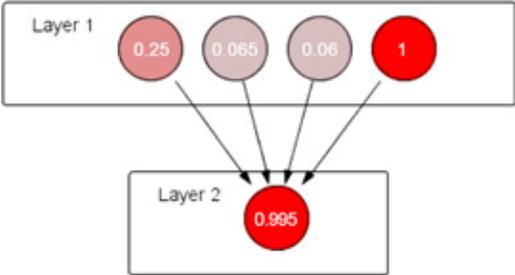
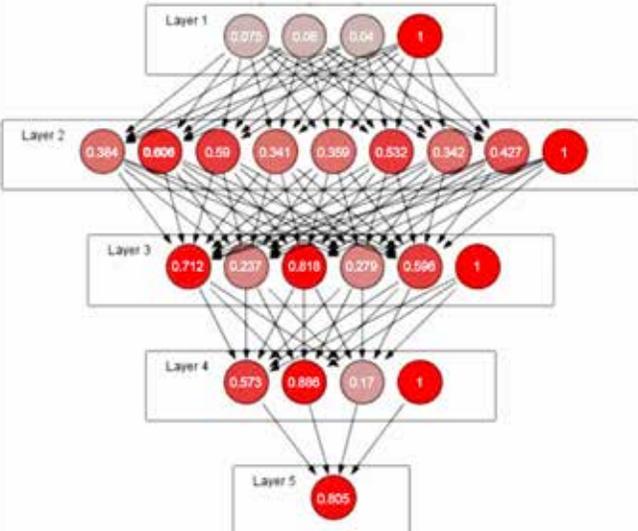


Figura 7. Gráfica del error total de entrenamiento de la red MLP sin Bias

Tabla 3. Resumen de configuraciones probadas

Nº de prueba	Características	No. de capas	No. de neuronas por capa oculta	Tipo de aprendizaje	Función de transferencia	Software
1	MLP con bias	5	8-5-3	Retropropagación	Sigmoide	Neuroph Studio
2	MLP sin bias	5	8-5-3	Retropropagación	Sigmoide	Neuroph Studio
3	Adaline	2	N/A	Mínimo error cuadrático	Tangencial hiperbólica	Neuroph Studio
4	MLP con bias	5	4-4-4	Retropropagación	Sigmoide	Matlab Toolbox
5	MLP con bias	5	10-8-5	Retropropagación	Sigmoide	Matlab Toolbox
6	MLP con bias	6	10-10-10-10	Retropropagación dinámica	Sigmoide	Neuroph Studio
7	MLP con bias	10	5-5-5-5-5-5-5-5	Retropropagación con momento	Tangencial hiperbólica	Neuroph Studio
8	MLP con bias	5	15-10-5	Retropropagación	Tangencial hiperbólica	Matlab Toolbox
9	MLP con bias	3	10	Retropropagación	Tangencial hiperbólica	Matlab Toolbox
10	MLP con bias	4	10-5	Retropropagación	Tangencial hiperbólica	Matlab Toolbox

Tabla 4. Arquitectura y características de las redes neuronales empleadas

Arquitectura	Descripción								
	<table border="1" data-bbox="886 495 1422 642"> <tr> <td>Tipo de RNA</td> <td>MLP sin Bias</td> </tr> <tr> <td>No. De Capas</td> <td>5</td> </tr> <tr> <td>No. De capa ocultas</td> <td>3</td> </tr> <tr> <td>No. De neuronas por capa oculta</td> <td>8-5-3</td> </tr> </table>	Tipo de RNA	MLP sin Bias	No. De Capas	5	No. De capa ocultas	3	No. De neuronas por capa oculta	8-5-3
Tipo de RNA	MLP sin Bias								
No. De Capas	5								
No. De capa ocultas	3								
No. De neuronas por capa oculta	8-5-3								
	<table border="1" data-bbox="886 1020 1422 1094"> <tr> <td>Tipo de RNA</td> <td>ADALINE</td> </tr> <tr> <td>No. De Capas</td> <td>2</td> </tr> </table>	Tipo de RNA	ADALINE	No. De Capas	2				
Tipo de RNA	ADALINE								
No. De Capas	2								
	<table border="1" data-bbox="886 1461 1422 1608"> <tr> <td>Tipo de RNA</td> <td>MLP con Bias</td> </tr> <tr> <td>No. De Capas</td> <td>5</td> </tr> <tr> <td>No. De capa ocultas</td> <td>3</td> </tr> <tr> <td>No. De neuronas por capa oculta</td> <td>8-5-3</td> </tr> </table>	Tipo de RNA	MLP con Bias	No. De Capas	5	No. De capa ocultas	3	No. De neuronas por capa oculta	8-5-3
Tipo de RNA	MLP con Bias								
No. De Capas	5								
No. De capa ocultas	3								
No. De neuronas por capa oculta	8-5-3								

La evolución de error mostrado en la Figura 8 pertenece a una MLP con BIAS activas, el número de iteraciones aumentó de forma considerable en comparación a la MLP sin BIAS, sin embargo el error disminuyó y la tendencia indica que seguiría en descenso.

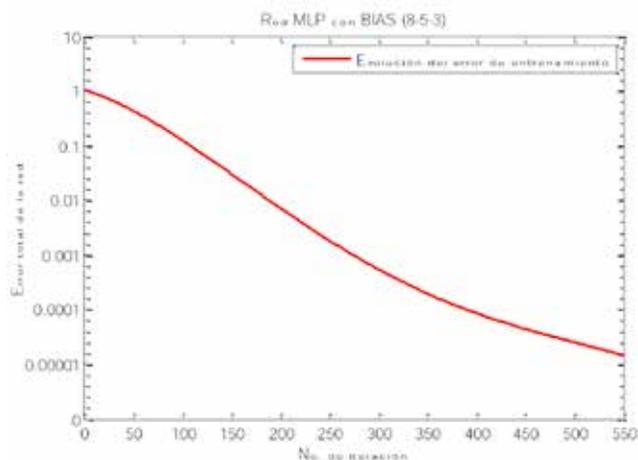


Figura 8. Gráfica del error total de entrenamiento de la red MLP con Bias

La Gráfica del error de entrenamiento de la red Adaline mostrada en la Figura 9 es la que presenta mayor inconsistencia ya que el error parece converger a un valor muy alto en comparación con las redes anteriores.

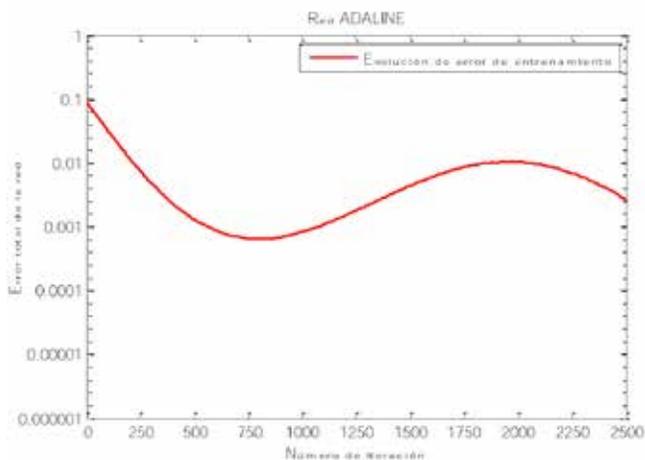


Figura 9. Gráfica del error total de entrenamiento de la red Adaline

Como se mencionó anteriormente, debido a las variaciones de error de entrenamiento que pueden presentar las redes neuronales, se hicieron 50 pruebas para cada una de las redes empleadas, la Figura 10 muestra el gráfico de caja de la variabilidad de los resultados de las RNA utilizadas.

De forma evidente, la varianza del error es mayor en la red ADALINE y también es la que presenta más resultados atípicos (marcados con una cruz), la MLP con BIAS es la que entrega el error más bajo y es la más constante en las pruebas realizadas. Si bien la RNA MLP sin BIAS activas arroja un error aceptable, existe un alto nivel de inconsistencia a lo largo de las muestras tomadas, ya que se observa un gran número de resultados atípicos.

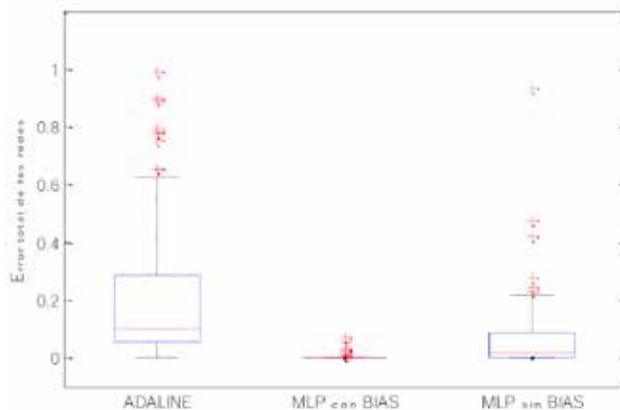


Figura 10. Gráfico de cajas de los errores obtenidos en la red

La Tabla 5 presenta un resumen de los resultados obtenidos con las redes neuronales que se emplearon en esta investigación. Destacando el tiempo de entrenamiento, que es muy bajo aún en las redes más robustas. El porcentaje de error mostrado es de acuerdo a los datos de entrenamiento.

La red neuronal multicapa perceptrón con Bias activas fue la que presentó mejor desempeño durante el entrenamiento, por ese motivo se utilizó para realizar la predicción de los parámetros de fabricación. La Tabla 6 muestra la validación de los parámetros predichos por la red empleada.

La metodología empleada por nosotros nos permitió evaluar con mayor exactitud la importancia o efecto de las variables de entrada de una red MLP. Con ello, se ha pretendido mostrar que una red neuronal no es una “caja negra”, sino más bien un instrumento complementario capaz de proporcionar claves acerca de las variables que están determinando la estimación realizada por el modelo propuesto. Las herramientas empleadas en este trabajo (Neuroph Studio y el Toolbox de Matlab) han supuesto un avance importante en el sentido de que ahora el usuario cuenta con programas que incorporan un conjunto de procedimientos numéricos y gráficos que han demostrado empíricamente ser de amplia utilidad en el análisis del efecto de las variables de entrada de una RNA. Pese a estos importantes logros alcanzados, uno de los principales objetivos de contribución de este trabajo es incentivar a los lectores en la aplicación de nuevas tecnologías, como las redes neuronales, en el ámbito de la estadística y el análisis de datos.

Conclusiones

Una vez presentados en detalle los resultados obtenidos con las distintas configuraciones de las RNA empleadas, nos disponemos a enunciar una serie de conclusiones acerca de las contribuciones realizadas en este trabajo.

1. Las RNA son capaces de predecir los parámetros más adecuados para fabricar piezas de AISI 316L con máxima densidad cuando se manufacturan de forma aditiva.
2. Los modelos de redes MLP y ADALINE permiten el

Tabla 5. Resumen de resultados con las redes neuronales empleadas

No. de prueba	Características	No. de capas	No. de neuronas por capa oculta	Menor error total obtenido	Tiempo de entrenamiento (s)	Número de iteraciones
1	MLP con Bias	5	8-5-3	0.00001%	60	600
2	MLP sin Bias	5	8-5-3	0.0001%	10	100
3	ADALINE	2	N/A	0.01%	250	2500
4	MLP con Bias	5	4-4-4	0.01%	30	300
5	MLP con Bias	5	10-8-5	0.001%	50	500

manejo de datos de supervivencia superando en algunos aspectos el rendimiento de los modelos que tradicionalmente han sido utilizados hasta el momento. A diferencia de los modelos tradicionales, las RNA no se ven afectadas por el cumplimiento del supuesto de proporcionalidad, tampoco es necesario introducir de forma explícita términos de interacción entre predictores ni funciones concretas entre predictores y variable de respuesta, debido a que son aprendidos de forma automática en el proceso de entrenamiento del modelo.

- Consideramos que emplear redes neuronales artificiales como una herramienta complementaria de optimización, es eficiente en los modelos de predicción del proceso de SLM y es esencial definir el número de capas ocultas utilizado en las MLP para reducir el error medio absoluto durante el entrenamiento.
- Con respecto a las pruebas hechas por la red neuronal MLP utilizada en este experimento, se predice que la mayor densidad obtenida mediante una combinaciones de los parámetros establecidos sería de 99.3%, correspondiendo a una potencia de láser de 185 W, una velocidad de escaneo de 80 mm/s, un espacio de sombreado de 0.04 mm y una estrategia de escaneo de 5 mm.

Referencias

- [1] M. Cotteleer, «*The 3D opportunity primer: The basics of additive manufacturing*,» Delolte University Press, 2013.
- [2] Kopel, A. (2015). *Neural Networks Performance and Structure Optimization using Genetic Algorithms*.
- [3] Louvis, E., Fox, P., Sutcliffe, C.J., *Selective laser melting of aluminium components*, Journal of Materials Processing Technology.
- [4] Roberts, I. A., 2012, "Investigation of Residual Stresses in the Laser Melting of Metal Powders in Additive Layer Manufacturing".
- [5] Rubiolo, M. (2014). *Desarrollo de nuevos modelos y algoritmos basados en redes neuronales para tareas de minera de datos*.
- [6] Laakso, P., Riipinen, T., Laukkanen, A., Andersson, T., Jokinen, A., Revuelta, A., & Ruusuvoori, K. (2016). *Optimization and simulation of SLM process for high density H13 tool steel parts*. Physics Procedia, 83, 26-35.
- [7] Verhaeghe, F., Craeghs, T., Heulens, J., & Pandelaers, L. (2009). *A pragmatic model for selective laser melting with evaporation*. Acta Materialia, 57(20), 6006-6012.
- [8] Hussein, A., Hao, L., Yan, C., & Everson, R. (2013). *Finite element simulate on of the temperature and stress fields in single layers built without-support in selective laser melting*. Materials & Design (1980-2015), 52, 638-647.
- [9] Grau, I., Nápoles, G., Bonet, I., & García, M. M. (2013). *Backpropagation through time algorithm for training recurrent neural networks using variable length instances*. Computación y Sistemas, 17(1), 15-24.

Tabla 6. Validación de los parámetros predichos por la RNA MLP

Parámetro	Valores predichos			Valores de validación			Promedio de porcentajes de error de validación
Potencia de láser (W)	173.27	75.75	174.28	175	75	175	
Velocidad de escaneo (mm/s)	79.21	80.800	199.17	80	80	200	
Espacio de sombreado (mm)	0.0396	0.0404	0.0597	0.04	0.04	0.06	0.7997
Estrategia de escaneo (mm)	9.90	10	4.979	10	10	5	
Densidad (%)	96.33	91.40	88.106	97.3	90.5	88.47	

- [10] Quesada, F. J. G., Graciani, M. A. F., Bonal, M. T. L., & Díaz-Mata, M. A. (1994). *Aprendizaje con redes neuronales artificiales*. Ensayos: Revista de la Facultad de Educación de Albacete, (9), 169-180.
- [11] Schmidhuber, J. (2015). *Deep learning in neural networks: An overview*. Neural networks, 61, 85-117.
- [12] Ghanou, Y., & Bencheikh, G. (2016). *Architecture optimization and training for the multilayer perceptron using ant system*. International journal of computer science, 43(1).
- [13] Águila Martínez, J. (2015). *Aprendizaje supervisado en conjuntos de datos no balanceados con redes neuronales artificiales*.
- [14] Widrow, B., & Lehr, M. A. (1990). *30 years of adaptive neural networks: perceptron, madaline, and backpropagation*. Proceedings of the IEEE, 78(9), 1415-1442.
- [15] Al-kaf, H. A. G., Chia, K. S., & Alduais, N. A. M. (2018). *A comparison between single layer and multi-layer artificial neural networks in predicting diesel fuel properties using near infrared spectrum*. Petroleum Science and Technology, 36(6), 411-418.
- [16] Cybenko, G. (1989). *Approximation by superpositions of a sigmoidal function*. Mathematics of control, signals and systems, 2(4), 303-314.
- [17] Laohaprapanon, A., Jeamwathanachai, P., Wongcumchang, M., Chantarapanich, N., Chantaweroad, S., Sitthiseriratip, K., & Wisutmethangoon, S. (2012). *Optimal scanning condition of selective laser melting processing with stainless steel 316L powder*. In Advanced Materials Research (Vol. 341, pp. 816-820). Trans Tech Publications.
- [18] Laakso, P., Riipinen, T., Laukkanen, A., Andersson, T., Jokinen, A., Revuelta, A., & Ruusuvoori, K. (2016). *Optimization and simulation of SLM process for high density H13 tool steel parts*. Physics Procedia, 83, 26-35.
- [19] Wang, Z., Xiao, Z., Tse, Y., Huang, C., & Zhang, W. (2019). *Optimization of processing parameters and establishment of a relationship between microstructure and mechanical properties of SLM titanium alloy*. Optics & Laser Technology, 112, 159-167.
- [20] Clijsters, S., Craeghs, T., & Kruth, J. P. (2012). *A priori process parameter adjustment for SLM process optimization*. Innovative developments on virtual and physical prototyping, 553-560.
- [21] Childs, T. H. C., C. Hauser, and M. Badrossamay. 2004. *Mapping and Modelling Single Scan Track Formation in Direct Metal Selective Laser Melting*. CIRP Annals-Manufacturing Technology 53 (1):191-194.
- [22] Van Elsen, M. 2007. *Complexity of selective laser melting: a new optimisation approach*, Mechanical engineering, Katholieke Universiteit Leuven.