

Desarrollo de una red neuronal artificial para la predicción de sobre corte en un proceso de manufactura no convencional

Gabriela Itzell Rangel Velázquez¹, José Arturo Pérez Martínez²,
Everardo Efrén Granda Gutiérrez¹, Carlos Eduardo Torres Reyes²

¹ Universidad Autónoma del Estado de México,
Centro Universitario UAEM Atlacomulco,
México

² Universidad Autónoma del Estado de México,
Unidad Académica Profesional Tianguistenco,
México

grangelv001@alumno.uaemex.mx,
{eegranda, japerezm, cetorresr}@uaemex.mx

Resumen. El presente trabajo tiene como objetivo el diseño y desarrollo de un modelo de red neuronal artificial de tipo perceptrón multicapa para la predicción del sobre corte en un proceso de maquinado electroquímico por pulsos. Como variables de entrada se consideran el voltaje de polarización, la frecuencia de maquinado y la concentración del electrolito. Se determina un diseño experimental factorial completo 2^3 para la construcción del conjunto de datos, los cuales se segmentan en 70% para entrenamiento y 30% para validación. Como métrica de evaluación de desempeño del modelo, se calcula el error porcentual absoluto medio y, de acuerdo con los resultados obtenidos, se comprueba que el modelo desarrollado es una alternativa factible para utilizar en la predicción de la variable de interés del fenómeno de estudio.

Palabras clave: Maquinado electroquímico por pulsos, perceptrón multicapa, predicción de sobre corte, red neuronal artificial.

Development of an Artificial Neural Network for the Prediction of Overcut in a Non-Conventional Manufacturing Process

Abstract. The present article aims to design and develop a multilayer perceptron-type artificial neural network model to predict the called “overcut” in a pulse electrochemical machining process. The involved input variables are bias voltage, machining frequency and electrolyte concentration. A full factorial experimental design 2^3 is determined for the construction of the data set, which is segmented into 70% for training and 30% for validation. The metric used to evaluate the performance of the model, the mean absolute percentage error is calculated and, according to the obtained results, it is verified that the developed model is a feasible alternative to use in the prediction of the variable of interest of the study phenomenon.

Palabras clave: Artificial neural network, multilayer perceptron, pulse electrochemical machining, overcut prediction.

1. Introducción

La manufactura no convencional de materiales metálicos engloba procesos que permiten trabajar con piezas de geometría compleja, tamaño reducido, alta dureza o con un acabado específico, caracterizándose por evitar la producción de virutas durante su realización. Entre los ejemplos de este tipo de procesos se encuentran el maquinado por chorro de agua, el maquinado por ultrasonido, la electroerosión y el maquinado electroquímico [1]. Este último, es un proceso que permite la remoción de material mediante la generación de un fenómeno denominado disolución anódica, producido por el flujo de electrones que existe desde el cátodo (herramienta de trabajo), hasta el ánodo (pieza de trabajo), a través de un electrolito que actúa como medio conductor de corriente eléctrica [2], con la finalidad de que la pieza de trabajo adquiera la forma del negativo de la figura de la herramienta de trabajo. De acuerdo con McGeough [3], algunos de los factores de importancia que se deben de tomar en consideración para la realización de un proceso de maquinado electroquímico, son la distancia inter-electrodos, el tipo de solución y concentración del electrolito, así como la fuente de alimentación, ya que esta última define si es un proceso de corriente continua o bien, si se trata de un proceso de maquinado electroquímico por pulsos. Además, dichos factores tienen influencia en las variables de salida del proceso, entre las que se encuentran la tasa de remoción de material y el sobre corte, es decir, cuánto material se remueve por unidad de tiempo y la diferencia existente entre el diámetro de la figura hecha en la pieza de trabajo menos el diámetro de la herramienta de trabajo utilizada [2].

Para aportar a la optimización del sector manufacturero, diversos investigadores como [4-8], han estudiado y considerado la implementación de soluciones inteligentes, dando prioridad al uso del *Soft Computing*, que tiene como objetivo obtener y representar información incierta, imprecisa o incompleta para la toma de decisiones de forma automática, reduciendo tiempo e inversión económica, el cual engloba diversas técnicas como la lógica difusa, algoritmos genéticos o las redes neuronales artificiales (RNA), entre otras [9].

Las RNA también conocidas como neuro-redes, son modelos computacionales que tienen el propósito de emular el funcionamiento del cerebro humano, con la finalidad de que un sistema informático sea capaz de tomar decisiones basadas en conocimiento empírico [10]. Estas se conforman por neuronas, las cuales están interconectadas jerárquicamente formando capas para la transmisión de información; además, las RNA son usadas para la resolución de problemas de clasificación mediante clases y etiquetado de metadatos, o para problemas de predicción de valores, también conocidos como problemas de aproximación de funciones, entre los que se encuentran los problemas de regresión y las series temporales [11]. Dentro de las capas que conforman la RNA, se encuentran la capa de entrada, que es aquella que interactúa con el exterior recibiendo la información necesaria para la definición de las variables independientes; la capa oculta, que puede ser desde una hasta las que se consideren necesarias para el entrenamiento de la red y las cuales permiten obtener el aprendizaje deseado;

finalmente, la capa de salida, que contiene la resultante de las variables dependientes del proceso de estudio [10]. Las RNA se han utilizado para contribuir al estudio y mejora de procesos de maquinado electroquímico, tal es el caso de [12], en donde se presenta un modelo para predecir los valores de la tasa de remoción y estudiar el efecto que ejercen sobre ella las variables de entrada, considerando la corriente (50, 100 y 200 A), la concentración del electrolito (10, 25 y 50 g/l) y el gap (0.5, 1 y 1.5 mm).

Emplean un conjunto de 12 datos, de los cuales 9 fueron para entrenamiento y 3 para validación, realizando una comparativa de los valores predichos y los valores reales, de los cuales se obtiene que la predicción correcta es mayor al 70%. Así mismo en [13], proponen un modelo de predicción de la tasa de remoción mediante una RNA perceptrón multicapa con un algoritmo de retropropagación elaborado en MATLAB; consideran el voltaje de polarización (6 y 10 V), la velocidad de avance de la herramienta (0.16 y 0.23 mm/min), la concentración del electrolito (200 y 300 g/l) y el material de la herramienta de trabajo (cobre y latón).

Se emplea un conjunto de datos construido a partir de un factorial completo 2^4 , segmentado en 70% de los datos para entrenamiento y el 30% restante para validación; obtienen que el menor Error Porcentual Absoluto Medio (MAPE, por sus siglas en inglés) resultante fue del 0.0018% correspondiente a 6 V de polarización, 0.23 mm/min de velocidad de avance, 200 g/l de concentración y como material, latón. Por otro lado, en [14] plantean que es necesario mejorar el sistema de control del proceso de maquinado electroquímico para que se puedan aprovechar los beneficios que el uso de este tipo de procesos brinda en la manufactura de metales.

Proponen un modelo de diagnóstico basado en RNA perceptrón multicapa para reducir imprecisiones derivadas de los modelos matemáticos utilizados con fines de control, o posibles fallas provocadas por un diseño incorrecto del proceso, esto con el propósito de determinar ciertas características sobre el maquinado con respecto al equipo de polarización. Realizan pruebas con la variación de la topología de RNA, donde utilizan 4 neuronas en la capa de entrada, 3, 4, 5, 6 y 10 neuronas en la capa oculta y 2 neuronas en la capa de salida; emplean como función de activación la tangente hiperbólica para la capa oculta y función logística para la capa de salida. Obtienen como resultado que el menor error de entrenamiento es del 0.257446% con una topología 4 - 4 - 2; y el menor error de validación es del 0.263862% con una topología 4 - 6 - 2.

El presente artículo tiene como objetivo describir el proceso de diseño y desarrollo de un modelo de RNA perceptrón multicapa para predecir el sobre corte producido en la pieza de trabajo al término de un proceso de maquinado electroquímico por pulsos, con la finalidad de poder ajustar las condiciones de trabajo correspondientes previo a la realización de un experimento real.

Se consideran como variables de entrada la magnitud del voltaje de polarización, la frecuencia de trabajo de los pulsos aplicados durante el proceso y la concentración del electrolito. Además, se construye un conjunto de datos mediante un factorial completo 2^3 , del cual se realiza una segmentación del 70% de datos para entrenamiento y el 30% para validación; finalmente, se evalúa el desempeño del modelo usando como métrica el cálculo del MAPE para determinar si es factible la solución propuesta.

2. Metodología

2.1. Condiciones para la obtención del conjunto de datos

El diseño del experimento (DOE, por sus siglas en inglés) que se determinó para la construcción del conjunto de datos para el entrenamiento y validación del modelo, fue un factorial completo 2^k [15], debido a que el proceso de maquinado electroquímico por pulsos es un fenómeno multivariable. El valor de k es igual a 3, esto significa que se consideran 3 factores: el voltaje de polarización, la frecuencia de maquinado y la concentración del electrolito, con dos niveles determinados para cada uno (nivel alto y nivel bajo). En la Tabla 1 se muestran los niveles de cada factor para la realización de los experimentos correspondientes a la matriz de combinaciones del DOE factorial 2^3 . Los valores de cada nivel sirvieron para poder establecer los parámetros iniciales de cada maquinado y así, obtener un valor del sobre corte por cada barreno realizado.

Una vez definidos los factores de estudio y los niveles de cada factor, se construye la matriz de combinaciones DOE factorial 2^3 , la cual se presenta en la Tabla 2, en donde se pueden observar todas las combinaciones de los factores y sus niveles por cada uno de los experimentos que se deben realizar.

Así mismo, para observar el comportamiento del fenómeno bajo las condiciones de entrada establecidas en la matriz construida, se determinan dos repeticiones por experimento; es decir, se realiza 3 veces cada una de las combinaciones de la variables de entrada, obteniendo un total de 24 respuestas, donde cada tercia de respuestas se promedia para tener un conjunto de datos promedio del valor del sobre corte resultante.

2.2. Prototipo del sistema para el proceso de maquinado electroquímico

Para la experimentación se empleó un prototipo de sistema mecánico de tres ejes coordenados (X, Y, Z) controlado por una Raspberry Pi 3B, el cual se conforma por una bomba que permite el flujo del electrolito, una fuente de alimentación pulsada con una frecuencia de conmutación ajustable entre 20 kHz y 100 kHz, así como un regulador de voltaje de polarización ajustable de 2.5 V a 10 V.

Además, como pieza de trabajo se empleó acero al carbón AISI-1018; como herramienta de trabajo se utilizó una aguja de acero inoxidable de 603 μm de diámetro externo y, como electrolito, se usó una solución de cloruro de sodio ($\text{H}_2\text{O} + \text{NaCl}$). El tiempo de maquinado establecido por cada experimento fue de 60 segundos a lazo abierto con una distancia inicial entre los electrodos (*gap*) de 240 μm . La representación gráfica del esquema general del funcionamiento del prototipo se puede ver en la Figura 1, en donde se muestra cómo fluye el electrolito durante el proceso, así como la corriente real producida en donde se ven involucradas, principalmente, la herramienta y pieza de trabajo.

Por otra parte, el cálculo del sobre corte se realizó considerando la diferencia entre el diámetro del barreno maquinado y el diámetro del electrodo, tal como se muestra en la ecuación (1).

Tabla 1. Niveles alto y bajo de cada factor para experimentos de la matriz factorial 2^3 .

	Voltaje de polarización	Frecuencia	Concentración del electrolito
	[V]	[kHz]	[M]
Nivel bajo	5	60	2.5
Nivel alto	7	80	3

Tabla 2. Matriz de combinaciones del DOE para la obtención del data set.

No. Experimento	Voltaje de polarización [V]	Frecuencia [kHz]	Concentración del electrolito [M]
1	bajo	bajo	bajo
2	alto	bajo	bajo
3	bajo	alto	bajo
4	alto	alto	bajo
5	bajo	bajo	alto
6	alto	bajo	alto
7	bajo	alto	alto
8	alto	alto	alto




Fig. 1. Representación gráfica del esquema general del prototipo del sistema de maquinado electroquímico utilizado.

$$\text{Sobre Corte} = dP - dH, \quad (1)$$

donde:

dP = diámetro de la pieza de trabajo,

dH = diámetro de la herramienta de trabajo.

De manera ilustrativa, en la Figura 2 se muestra el proceso de generación de sobre corte en un proceso de maquinado electroquímico, donde a) representa el inicio del corte en la pieza, la corriente principal generada a través del flujo del electrolito, la cual sale a través de la herramienta, se coloca en color rojo; posteriormente en b) se muestra




Fig. 2. Generación de sobre corte en un proceso de maquinado electroquímico. a) Inicio del proceso. b) Adición de la corriente de las caras laterales de la herramienta. c) Aumento de la corriente por el descenso de la herramienta. d) Barreno con efecto de sobre corte.

la remoción de material en la pieza de trabajo, el aumento del *gap* y, de color verde, la corriente producida por las caras laterales de la herramienta de trabajo; en c) se representa el descenso de la herramienta con el *gap* reestablecido y la corriente de las caras laterales aumentada. Finalmente, en d) se muestra el maquinado realizado en la pieza de trabajo, el cual es un barreno producido por la corriente principal que tiene el borde en color rojo y, a su vez, un corte adicional producido por la corriente de las caras laterales de la herramienta, el cual tiene el borde en color verde y es conocido como efecto de sobre corte.

En la Figura 3, se muestra un ejemplar de barreno realizado con una concentración de 2.5 M, 5 V de polarización y 80 kHz de frecuencia de maquinado. Se puede observar que el diámetro del barreno es de 836 μm (representado con el borde en color rojo), por lo que, al utilizar la ecuación (1) y restar los 603 μm del diámetro de la herramienta de trabajo (representados con el borde color blanco), se obtiene un sobre corte de 233 μm . Este proceso de obtención de sobre corte se repite en cada una de las pruebas hechas con base en la matriz del DOE factorial completo 2^3 .




Fig. 3. Barreno realizado a 60 segundos, con una concentración de 2.5 M, 5 V de polarización y 80 kHz de frecuencia de maquinado.

2.3. Modelo de red neuronal para la predicción de sobre corte

El modelo de RNA propuesto para la predicción de sobre corte, es un perceptrón multicapa con una topología definida en la ecuación (2) [16]:

$$F: I^3 \rightarrow \mathbb{R}^1, \quad (2)$$

donde:

F = función continua del modelo de RNA,
 I^3 = matriz de entradas,
 $\mathbb{R}^1$ = matriz de salidas.

La representación gráfica de la topología del modelo propuesto se puede visualizar en la Figura 4, en donde se encuentra la matriz de entradas, que son 3: el voltaje de polarización (v), la frecuencia de maquinado (f) y la concentración del electrolito (ce); también se observa una capa oculta de cuatro neuronas y la matriz de salidas, que en este caso es solo una: el sobre corte (oc).

Cada conexión entre las neuronas que conforman la topología tiene asociado un coeficiente w , conocido como peso sináptico [10]. De modo que, el modelo de RNA propuesto, tiene dos matrices de coeficientes: W^1 , que es una matriz de 4×3 , conformada por las conexiones de las neuronas de la capa de entrada a las neuronas de la capa oculta; y W^2 , que es una matriz de 4×1 , conformada por las conexiones de las neuronas de la capa oculta hacia la neurona de la capa de salida.

Considerando la ecuación (3) como la ecuación general para el cálculo de las salidas, y la ecuación (4) para el cálculo de la función de activación rectificada lineal ($relu$) [17], se procede al recorrido del perceptrón de forma unidireccional hacia delante, para obtener el valor de la variable dependiente:

$$Y = wx + u, \quad (3)$$

$$\phi(Y) = \max\{0, Y\}, \text{ siendo } Y \geq 0, \quad (4)$$




Fig. 4. Topología del modelo de RNA propuesto.

donde:

Y = la salida que se desea obtener,
 w = peso sináptico de la conexión,
 x = valor de entrada,
 u = valor del umbral,
 ϕ = función de activación.

De acuerdo con la estructura de la topología, considerando la ecuación (3) y las matrices de coeficientes W^1 y W^2 , primero se calcula el resultado de la capa de entrada hacia la capa oculta (Y^1) y este se utiliza para calcular el valor de la capa de salida (Y^2), para posteriormente aplicar la función de activación y obtener el valor del sobre corte. Sustituyendo los valores, el recorrido unidireccional hacia delante del perceptrón multicapa, se representa por las ecuaciones (5 - 7), considerando a U^1 y U^2 como las matrices del umbral por cada capa recorrida:

$$Y^1 = \begin{bmatrix} W_{1,1}^1 & W_{1,2}^1 & W_{1,3}^1 \\ W_{2,1}^1 & W_{2,2}^1 & W_{2,3}^1 \\ W_{3,1}^1 & W_{3,2}^1 & W_{3,3}^1 \\ W_{4,1}^1 & W_{4,2}^1 & W_{4,3}^1 \end{bmatrix} * \begin{bmatrix} v \\ f \\ ce \end{bmatrix} + \begin{bmatrix} U_{1,1}^1 \\ U_{2,1}^1 \\ U_{3,1}^1 \\ U_{4,1}^1 \end{bmatrix}, \quad (5)$$

$$Y^2 = \begin{bmatrix} W_{1,1}^2 \\ W_{2,1}^2 \\ W_{3,1}^2 \\ W_{4,1}^2 \end{bmatrix} * \begin{bmatrix} \phi(Y_{1,1}^1) \\ \phi(Y_{2,1}^1) \\ \phi(Y_{3,1}^1) \\ \phi(Y_{4,1}^1) \end{bmatrix} + \begin{bmatrix} U_{1,1}^2 \\ U_{2,1}^2 \\ U_{3,1}^2 \\ U_{4,1}^2 \end{bmatrix}, \quad (6)$$

$$oc = \phi(Y^2). \quad (7)$$

Para llevar a cabo la codificación del modelo se utilizó Python como lenguaje de programación y Google Collaboratory [18] como entorno de desarrollo, fue necesario implementar una normalización de datos para que se establecieran dentro del mismo rango debido a la diferencia existente entre los valores de las entradas y los de la variable dependiente. Dicha normalización se realizó previo al entrenamiento del modelo y para ello se utilizó *preprocessing* de la librería *sklearn* [19]. La función de normalización utilizada fue *QuantileTransformer* [20], que aplica una transformación

no lineal de modo que se hace un mapeo de los datos en una distribución uniforme o gaussiana dentro del rango (0, 1).

Una vez normalizado el conjunto de datos, se procedió al entrenamiento del modelo utilizando una segmentación del 70% de los datos del conjunto. Como métrica para la evaluación del desempeño del modelo se utilizó el MAPE, el cual es el promedio de la diferencia absoluta entre el valor observado y los valores predichos [21], la ecuación que lo define es la ec. (8):

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|p_t - \hat{p}_t|}{|p_t|} * 100, \quad (8)$$

donde:

p_t = valor predicho,

$\hat{p}_t$ = valor real o esperado,

n = número de datos.

3. Resultados y discusión

Los valores de sobre corte obtenidos mediante la aplicación de la matriz del DOE factorial 2^3 , se muestran dentro de la Tabla 3. Los datos observados son el valor promedio de cada terna de pruebas de las 24 en total realizadas, y el cual se consideró como conjunto de datos de entrenamiento (mostrados en color verde) y validación (mostrados en color naranja) del modelo.

Correspondiente a la relación existente entre el sobre corte obtenido y las variables de entrada utilizadas por la combinación de la matriz factorial (ver Figura 5), se puede observar que el menor sobre corte es de 124 μm , el cual se presenta con una concentración de 2.5 M, 60 kHz de frecuencia de maquinado y 5 V de voltaje de polarización; por otro lado, el mayor sobre corte es de 296 μm , obtenido de igual forma con una concentración de 2.5 M y 5 V de voltaje de polarización, pero con una frecuencia de maquinado de 80 kHz. Así mismo, se visualiza que, con una concentración de 3 M, los valores de sobre corte no tienen un cambio significativo entre sí, es decir, los valores de sobre corte obtenidos con esta concentración no varían demasiado entre sí, a pesar de que la frecuencia de maquinado y el voltaje de polarización se alternen en los niveles determinados.

Al realizar la normalización de los datos del conjunto construido con el DOE establecido, se obtuvieron dos matrices: 1) la matriz de datos de entrada normalizados y 2) la matriz de datos de salida normalizados. Para la primera matriz, se tomaron en cuenta los valores del voltaje de polarización, frecuencia de maquinado y concentración del electrolito definidos en las combinaciones del DOE; en el caso de la segunda matriz, se consideraron los valores de la columna de sobre corte mostrados en la Tabla 3, de esta forma, todos los datos utilizados para el entrenamiento estuvieron dentro del rango (0,1). Esto se puede observar en las Figuras 6 y 7.

Tabla 3. Valor promedio de sobre corte obtenido con la matriz de DOE factorial 2³.

No. Experimento	Voltaje de polarización [V]	Frecuencia [kHz]	Concentración del electrolito [M]	Sobre corte [μm]
1	5	60	2.5	124
2	7	60	2.5	248
3	5	80	2.5	296
4	7	80	2.5	217
5	5	60	3	284
6	7	60	3	244
7	5	80	3	269
8	7	80	3	251





Fig. 5. Relación entre las variables de entrada y la variable de salida para la visualización del comportamiento del fenómeno. a) Concentración de 2.5 M. b) Concentración de 3 M.

Al obtener los datos de la normalización se procedió al entrenamiento del modelo, destacando la importancia de la normalización para la disminución del error en la predicción de los datos. Con la segmentación del 70% de los datos utilizados para el entrenamiento, se obtuvo un MAPE del 7.3%. Se observa que la mayor diferencia de predicción se encuentra en el segundo experimento, con una cantidad de 43.83 μm y la diferencia de predicción más baja, es de la posición cuatro con una cantidad de 2.11 μm (ver Tabla 4). La distribución de los datos predichos por el modelo, en comparación

Tabla 4. Valor del MAPE obtenido en el entrenamiento, considerando los valores reales y los valores predichos por el modelo correspondientes al sobre corte.

No. Experimento	Datos Reales [μm]	Datos Predichos [μm]	MAPE
1	124	146.39	18.05 %
2	296	248.17	16.15 %
3	217	221.62	2.12 %
4	244	241.89	0.86 %
5	269	260.94	2.99 %
6	251	241.89	3.62 %
Total MAPE entrenamiento			7.3 %

**Fig. 6.** Distribución de la matriz de datos de entrada normalizados en un rango de 0 a 1.

con los datos reales del sobre corte promedio obtenido por cada experimento se puede observar en la Figura 8.

De igual forma, con los datos de predicción obtenidos durante el entrenamiento, se pudo observar la relación existente entre las variables de entradas del proceso y el sobre corte obtenido, los cuales se muestran en la Figura 9. Se observa que la predicción de sobre corte más cercana, corresponde a las condiciones de 7 V de polarización, 60 kHz de frecuencia de maquinado y 3 M de concentración del electrolito.

Por otro lado, se realizó una validación con el 30% de los datos no usados para entrenamiento, en donde se obtuvo un MAPE del 16.3%. Los datos predichos en la validación se pueden observar en la Tabla 5, en donde se visualiza que la diferencia más grande de los datos predichos es de 61.11 unidades.

Al obtener los datos de validación, se puede observar que, con relación a las variables de entrada, el valor de predicción más cercano es con 60 kHz de frecuencia de maquinado 5 V de polarización y una concentración del electrolito de 3 M, tal como se muestra en la Figura 10.

Tabla 5. Valor del MAPE obtenido en la validación, considerando los valores reales y los valores predichos por el modelo.

No. Experimento	Datos Reales [μm]	Datos Predichos [μm]	MAPE
1	248	186.89	24.64 %
2	284	260.94	8.11 %
Total MAPE validación			16.3 %




Fig. 9. Relación de las variables de entrada con los valores reales y los valores predichos en el entrenamiento del modelo. a) Concentración de 2.5 M. b) Concentración de 3 M.




Fig. 10. Relación de las variables de entrada con los valores reales y los valores predichos en la validación del modelo. a) Concentración de 2.5 M. b) Concentración de 3 M.

4. Conclusiones

De acuerdo con los resultados obtenidos del entrenamiento y validación del modelo, se concluye que las redes neuronales artificiales, son una técnica de aprendizaje

supervisado factible para la predicción correcta del sobre corte producido al término de un proceso de maquinado electroquímico por pulsos, coincidiendo con lo expuesto en [12 - 14]. Esto se puede observar con el resultado de la métrica utilizada para la evaluación del desempeño, en donde, con el 70% de datos empleados para el entrenamiento, se obtiene un MAPE del 7.3% y, con el 30% de los datos empleados para la validación, se obtiene un MAPE del 16.3%.

Con respecto al comportamiento del fenómeno, se observa que, al emplear una concentración del electrolito de 3 M, no existe un cambio significativo en el valor del sobre corte, lo cual hace que, como trabajo a futuro, se pueda considerar realizar las pruebas con un tiempo indeterminado para estudiar con mayor profundidad cómo influye el cambio de concentración en el proceso y en el sobre corte.

Así mismo, se propone la construcción de un conjunto con una matriz factorial completo 3^3 , la cual permitirá definir tres valores por factor y ampliar el rango de combinaciones de los experimentos para que, de esta manera, se pueda tener un conjunto de datos de entrenamiento y validación más grande.

Además, se contempla la optimización del algoritmo para la reducción del error obtenido, implementando técnicas de optimización tradicionales tales como un algoritmo de retropropagación o bien, con técnicas híbridas como Algoritmos Genéticos o Lógica Difusa. Finalmente, se propone la variación de los parámetros de la topología propuesta, es decir, se propone la aleatoriedad de las características de la red, tales como el número de capas, el número de épocas o el número de neuronas por capa, continuando con la línea de entrenamiento de una red poco profunda, con el objetivo de verificar el comportamiento y desempeño del modelo bajo estas condiciones.

Referencias

1. Universidad del País Vasco: Métodos no convencionales de mecanizado. Dpto. de Ingeniería Mecánica, Euskadi, España (2015)
2. Schneider, M., Lohrengel, M.: Electrochemical Machining. Springer Hand Book, pp. 941–971 (2017) doi: 10.1007/978-3-662-46657-5_28.
3. Baswaraju, S., Harshvardhan T.: Principles of Electrochemical Machining. Encyclopedia of Chemical Technology, Londres, Inglaterra (2016)
4. Jena, R., Acharjya, D.P., Das, R.: A Fuzzy Graph Recurrent Neural Network Approach for the Prediction of Radial Overcut in Electro Discharge Machining. Advances in Distributed Computing and Machine Learning, 127, pp. 257–270 (2021) doi: 10.1007/978-981-15-4218-3_26.
5. Rouniyar, A.K., Shandilya, P.: Semi-Empirical Modeling and Optimization of Process Parameters on Overcut During MFAPM-EDM of Al6061 Alloy. Part E: Journal of Process Mechanical Engineering, 235, pp. 1784–1796 (2021) doi: 10.1177/09544089211015890.
6. Mirad, M.M., Das, B.: A Critical Review of the State-of-the-Art Literature in the Monitoring of Ultrasonic Machining Process and Tool Failure Prediction. Engineering Failure Analysis, 130 (2021) doi: 10.1016/j.engfailanal.2021.105769.
7. Das, R., Pradhan, M.K.: Artificial Neural Network Training Algorithms in Modeling of Radial Overcut in EDM: A Comparative Study. Research Anthology on Artificial Neural Network Applications, pp. 140–150 (2018) doi: 10.4018/978-1-5225-3035-0.ch006.
8. Sossa, H., Reyes, F.: Inteligencia artificial aplicada a la robótica y automatización. Marcombo-AlfaOmega (2021)

9. Swathi, B., Tiwari, H.: Test Automation Framework using Soft Computing Techniques. International Conference on Advances in Electrical, Computing, Communication and Sustainable Technologies (2021) doi: 10.1109/ICAECT49130.2021. 9392602.
10. Basogain Olabe, X.: Redes neuronales artificiales y sus aplicaciones. Escuela Superior de Ingeniería de Bilbao (1998)
11. Palacios González F.: Redes neuronales artificiales y métodos de estimación de funciones. Universidad de Granada (2000)
12. Hassan, A., Aghdeab, S.H., Ibrahim, A.F.: Optimization of Electrochemical Machining Process Based on Artificial Neural Network Technique. Eng. & Tech. Journal, 34, pp. 2960–2970 (2016) doi: 10.30684/etj.34.15A.16.
13. Kasdekar, D.K., Parashar, V., Chandan, A.: Artificial Neural Network Models for the Prediction of MRR in Electro-Chemical Machining. Department of Mechanical Engineering, Madhav Institute of Technology & Science, 5, pp. 772–779 (2018) doi: 10.1016/j.matpr.2017.11.146.
14. Masalimov, K.A., Munasyrov, R.A.: Neural-Network Diagnostics of Electrochemical Machining. Russian Engineering Research, 7, pp. 817–820 (2017) doi: 10.3103/S1068798X17090179.
15. Gutiérrez Pulido, H., De la Vara Salazar, R.: Análisis y diseño de experimentos. McGraw-Hill (2008)
16. Katsuura, A., Sprecher, D.: Computational Aspects of Kolmogorov Superposition Theorem. Neural Networks, 7, pp. 451– 461 (1994)
17. Vilagran Solsona, A.: Facial Expression Detection using Convolutional Neural Networks. Universidad Politécnica de Cataluña (2018)
18. Google Colab: <https://colab.research.google.com> (2021)
19. Sklearn Preprocessing Data: <https://scikit-learn.org/stable/modules/preprocessing.html> (2021)
20. Sklearn QuantileTransformer: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.QuantileTransformer.html#sklearn.preprocessing.QuantileTransformer> (2021)
21. Faryx: Selección de métricas para aprendizaje automático. https://faryx.com/machine-learning-metrics_es (2021)