



Ciencia Latina
Internacional

Ciencia Latina Revista Científica Multidisciplinar, Ciudad de México, México.
ISSN 2707-2207 / ISSN 2707-2215 (en línea), mayo-junio 2024,
Volumen 8, Número 3.

https://doi.org/10.37811/cl_rcm.v8i3

PROPUESTA DE UNA PLATAFORMA UTILIZANDO LAS TIC'S COMO SISTEMA DE CONTROL DE UNA RED NEURONAL EN MOTORES DE CORRIENTE CONTINÚA

**PROPOSAL FOR A PLATFORM USING ICT AS A
CONTROL SYSTEM FOR A NEURAL NETWORK IN
DIRECT CURRENT MOTORS**

Humberto Dorantes Benavidez

TecNM- TESOEM Área de Investigación y Posgrado, México

Aldo Miguel Zarate Santiago

TecNM- TESOEM Área de Investigación y Posgrado, México

Miguel Ángel Martínez Cruz

TecNM- TESOEM Área de Investigación y Posgrado, México

Felipe de Jesús Dorantes Benavidez

TecNM- TESOEM Área de Investigación y Posgrado, México

Marco Antonio Acosta Mendizábal

TecNM- TESOEM Área de Investigación y Posgrado, México

DOI: https://doi.org/10.37811/cl_rcm.v8i3.11314

Propuesta de una plataforma utilizando las TIC'S como sistema de control de una Red Neuronal en Motores de Corriente Continúa

Humberto Dorantes Benavidez¹

humberdorantes@gmail.com

<https://orcid.org/0000-0003-1490-1873>

TecNM- TESOEM

Área de Investigación y Posgrado

Los reyes la paz, Estado de México

Aldo Miguel Zarate Santiago

Aldomiguel.zarate@gmail.com

<https://orcid.org/0000-0002-4510-9363>

TecNM- TESOEM

Área de Investigación y Posgrado

Los reyes la paz, Estado de México

Miguel Ángel Martínez Cruz

mamartinezc@ipn.mx

<https://orcid.org/0000-0002-4431-9262>

TecNM- TESOEM

Área de Investigación y Posgrado

Los reyes la paz, Estado de México

Felipe de Jesús Dorantes Benavidez

Ing_fe_li_pe@hotmail.com

<https://orcid.org/0000-0001-6145-0038>

TecNM- TESOEM

Área de Investigación y Posgrado

Los reyes la paz, Estado de México

Marco Antonio Acosta Mendizábal

domila1631@gmail.com

<https://orcid.org/0000-0002-7408-9808>

TecNM- TESOEM

Área de Investigación y Posgrado

Los reyes la paz, Estado de México

RESUMEN

Una problemática de índole mundial es la falta de desarrollo de software, en la actualidad una ventaja competitiva dentro de cualquier proceso de fabricación o servicio, hacen que el desarrollo sobre el control automático ha desempeñado una función vital en el avance de la ingeniería. SCRUM es una metodología de fácil manejo y una de las más utilizadas en todo el mundo con una gran aceptación dentro de la comunidad y el mercado. La presente investigación propone una plataforma utilizando las TIC'S como sistema de control de una Red Neuronal en Motores de Corriente Continúa, con el objetivo de predecir y controlar su funcionamiento en tiempo real confirmando que las redes neuronales (RNA) pueden ser usadas para controlar sistemas de control con un alto grado de amortiguamiento. Los datos que se obtendrán de los resultados de las múltiples simulaciones experimentales del sistema conformado por el motor y su control, utilizando una red blackpropagation para emular bloques de los sistemas de control estabilizando el sistema. De manera que la red pueda evolucionar en un sistema de autoaprendizaje ya que en la actualidad se han constituido como una herramienta tecnológica importante debido a su contribución en el desarrollo de problemas relacionados con los aprendizajes de control y automatización, sin embargo, el control automático ha desempeñado una función vital en el avance de la ingeniería y la ciencia, ya que los sistemas mecánicos o eléctricos mantienen su equilibrio. El control automático ha sido de gran importancia en la transformación y evolución del ser humano debido a la constante necesidad de optimizar sus procesos o actividades con menor tiempo posible, de manera eficiente y segura. Además, el control automático se volvió parte importante e integral de los procesos modernos e industriales y de manufactura.

Palabras clave: motores, TIC'S, redes neuronales, scrum

¹ Autor principal

Correspondencia: humberdorantes@gmail.com

Proposal for a platform using ICT as a control system for a Neural Network in Direct Current Motors

ABSTRACT

A global problem is the lack of software development, currently a competitive advantage within any manufacturing process or service, which means that the development of automatic control has played a vital role in the advancement of engineering. SCRUM is an easy-to-use methodology and one of the most widely used around the world with great acceptance within the community and the market. The present research proposes a platform using ICT as a control system of a Neural Network in Direct Current Motors, with the aim of predicting and controlling its operation in real time, confirming that neural networks (ANN) can be used to control control systems with a high degree of damping. The data that will be obtained from the results of the multiple experimental simulations of the system made up of the engine and its control, using a blackpropagation network to emulate blocks of the control systems stabilizing the system. In such a way that the network can evolve into a self-learning system since they have currently become an important technological tool due to their contribution in the development of problems related to control and automation learning, however, automatic control has played a vital role in the advancement of engineering and science. as mechanical or electrical systems maintain their balance. Automatic control has been of great importance in the transformation and evolution of human beings due to the constant need to optimize their processes or activities in the shortest possible time, efficiently and safely. In addition, automatic control became an important and integral part of modern, industrial and manufacturing processes.

Keywords: engines, ICTs, neural networks, scrum

Artículo recibido 10 abril 2024

Aceptado para publicación: 20 mayo 2024



INTRODUCCIÓN

En la actualidad, las distintas técnicas de creación de software son cada vez más avanzadas. Es posible que la metodología SCRUM sea una de las más utilizadas. Dado que la competitividad dentro de las empresas hace que los procesos de fabricación cambien rápidamente, las tecnologías de la información (TIC) nos permiten compilar información en tiempo real. Sin embargo, el control automático ha desempeñado un papel importante en el avance de la ingeniería y la ciencia porque mantiene el equilibrio de los sistemas mecánicos o eléctricos. Debido a la constante necesidad de optimizar sus procesos o actividades con el menor tiempo posible, de manera segura. El control automático se ha convertido en una parte integral de los procesos industriales y de fabricación modernos. (Katsuhiko, 1998).

La importancia de la automatización en la industria de procesos ha aumentado significativamente en los últimos años y, de hecho, se ha convertido en una fuerza impulsora de todo industrial. La creación de una aplicación móvil que tenga en cuenta estos factores y que sea fácil de usar y descargar es una solución a esta problemática. Los procesos complejos están dirigidos por sistemas de instrumentación innovadores. (Suykens, 2022). La confiabilidad y la seguridad de los procesos son fundamentales para estrategias de mantenimiento avanzadas. En los últimos años, la automatización de procesos ha experimentado avances significativos que han impactado significativamente en nuestra nación. Por lo tanto, es necesario desarrollar procesos novedosos que modernicen nuestros sistemas de producción automática. En un principio, el control automático se desarrolló para cubrir ciertas necesidades humanas. Uno de los primeros ejemplos es el flotador mecánico, que se encuentra documentado en los años 200 aC y es un mecanismo automático que permite que un flujo de agua llegue a un límite específico.

Después, durante la revolución industrial en Europa, se introdujeron las primeras máquinas de vapor que se utilizaban en molinos de grano, hornos, entre otros, lo que facilitaba el trabajo diario de las personas. Con el tiempo, la tecnología se volvió más compleja, pasando de un sistema mecánico a sistemas con múltiples disciplinas de ingeniería, como los sistemas mecatrónicos. Por lo tanto, el control tuvo que adaptarse a ellos. Una de las aplicaciones industriales más importantes de las máquinas de corriente continua e ingeniería de control son los motores de corriente continua. Debido a su uso como

generadores o dinamos y porque representaron el primer procedimiento para producir, este tipo de máquina tiene una gran importancia histórica.

Por otro lado, los motores de corriente continua son uno de los dispositivos más versátiles del mercado. Se ha convertido en una de las mejores opciones para aplicaciones de control y automatización de procesos debido a su fácil control de posición, par y velocidad. Sin embargo, con la aparición de la electrónica, su utilización ha disminuido significativamente, ya que los motores de corriente alterna asíncronos pueden ser controlados de manera similar y a precios más económicos para los consumidores comunes de la industria. A pesar de esto, muchas aplicaciones de potencia de trenes o máquinas de precisión, micromotores, etc. todavía utilizan motores de corriente continua.

De todos los métodos existentes, las redes neuronales artificiales son las más adecuadas para el reconocimiento de patrones en tiempo real porque funcionan en paralelo actualizando todas sus instancias al mismo tiempo. Es importante tener en cuenta que esta característica solo se puede utilizar en redes que están equipadas con hardware especialmente diseñado para el procesamiento paralelo.

Los principios de las redes neuronales permiten resolver problemas difíciles, de los cuales se mencionan los cinco más importantes (Sastry, Santharam y Unnikrishnan, 1994). Estos se enumeran a continuación:

Aprendizaje que se adapta: Las redes neuronales pueden actuar como resultado de un entrenamiento, lo que es quizás su característica más importante. De esta manera, no se requiere la creación de un modelo previo ni la creación de funciones probabilísticas. Debido a su capacidad para adaptarse constantemente a los nuevos entornos de trabajo, una red neuronal artificial es adaptativa.

Autoorganización: mientras que el aprendizaje es un proceso donde se modifica la información interna de una red neuronal artificial, la autoorganización implica modificar toda la red para lograr un objetivo específico. La autoorganización significa generalización, por lo que una red puede responder a datos o situaciones que no ha visto antes pero que puede inferir a partir de su entrenamiento. Cuando la información de entrada es ambigua o incompleta, esta característica es especialmente útil. Desde McCulloch-Pitts (1943), se ha realizado una gran cantidad de investigación sobre modelos matemáticos de redes neuronales. Hopfield, Hinton, Rumelhart, Sejnowski y otros han demostrado recientemente que el uso de estos modelos para aclarar el mecanismo de procesamiento de la información humana es posible. En particular, el algoritmo de retropropagación (también conocido como regla delta

generalizada) propone una regla de aprendizaje para redes multicapa. Este algoritmo tiene muchas aplicaciones. han aparecido recientemente. Sin embargo, la investigación teórica sobre la capacidad de una red multicapa es limitada. Rumelhart, Hinton y Williams. Lippmann (1987) afirma que la toma de decisiones complejas arbitrarias Se pueden formar áreas, como áreas cóncavas. (Ken-Ichi, 1989). La tolerancia a errores en la informática tradicional. La inutilización del sistema ocurre con frecuencia cuando se pierde un pequeño fragmento de información. Las redes neuronales artificiales son altamente resistentes a los errores. Por lo tanto, las redes pueden reconocer patrones de información con ruido, distorsión o incompletos, pero también pueden continuar funcionando, aunque se destruya parte de la red. Las redes neuronales almacenan la información de manera distribuida y con un alto grado de redundancia, mientras que la computación tradicional lo hace en espacios únicos, localizados y direccionales (Ken-Ichi, 1989). La operación se lleva a cabo en tiempo real: De todos los métodos existentes, las redes neuronales artificiales son las más adecuadas para el reconocimiento de patrones en tiempo real porque funcionan en paralelo actualizando todas sus instancias al mismo tiempo. Es importante tener en cuenta que esta característica solo se puede utilizar en redes que están equipadas con hardware especialmente diseñado para el procesamiento paralelo.

Y su fácil incorporación en la tecnología actual, ya que es relativamente sencillo adquirir chips especializados para redes neuronales que mejoran su capacidad en tareas específicas. Esto facilita la integración modular en los sistemas que ya están en funcionamiento.

La investigación actual describe cómo se pueden utilizar las redes neuronales artificiales en sistemas de control vectorial y control directo de motores de corriente continua. Esta tecnología relativamente nueva permite reemplazar equipos que ya no funcionan correctamente debido a los avances tecnológicos modernos, lo cual es fundamental para un país en desarrollo como el nuestro. Los resultados de las simulaciones del sistema formado por el motor y su control y los resultados de los experimentos proporcionarán los datos necesarios para entrenar las redes neuronales artificiales. Para lograr esto, se utilizó un modelo de motor de corriente continua que se probó con varios valores nominales y se controló con varios sistemas de control.

Modelos de ARN El interprete los maneja como tipos primitivos de datos, de la misma manera que maneja enteros, símbolos o cadenas de caracteres, pero no como abstracciones codificadas directamente

en el esquema. Los modelos de RNA pueden almacenar objetos de primer nivel en variables, pasarlos dentro de los argumentos de las funciones e incluso ser devueltos como resultado de ellas.

Debido a la importancia de la velocidad de ejecución de estas funciones en el desempeño de la aplicación, las funciones para la creación y manipulación de modelos de RNA también se codifican como primitivas directamente en el lenguaje C, lo que permite tener código ejecutable altamente optimizado. (Velasquez, 2005)

METODOLOGÍA

La metodología SCRUM

El término proviene de Francia y se utiliza en el rugby para describir una jugada en la que, por decisión del árbitro, los dos equipos forman una fila de jugadores una en frente de la otra y forcejean contra el otro equipo. En la mitad de la jugada, el balón queda detrás del equipo ganador, que se queda con el balón y la jugada.

Por lo tanto, en 1993, Jeff Sutherland, John Scumni Tales y Jeff McKenna idearon, implementaron y registraron el primer Scrum para desarrollo ágil de software conocido, que se basó en el estudio de gestión de equipos de Takeuchi y Nonaka. En 1995, Ken Schwaber formalizó el proceso para la industria de desarrollo de software, y desde entonces, miles de proyectos en todo el mundo han utilizado Scrum para el desarrollo de software. (Higuera, Camelo, & Cediél, 2014)

Se utilizará un motor de 24 voltios con una corriente máxima de aproximadamente 8 amperios. Una tarjeta de adquisición de datos controlará el amplificador de potencia que conectará al motor. Matlab-Simulink es un entorno de programación.

En los experimentos de control, se asignará una referencia a la posición y velocidad del motor. Debido a que la información de retroalimentación es la posición del motor en las cuentas de un codificador óptico, se utiliza un filtro para estimar la velocidad.

Un amplificador de potencia, conectado a una tarjeta electrónica de adquisición de datos, impulsa el motor de corriente continua. Las dos computadoras programan y supervisan el sistema.

El plan de control tendrá tres entradas a la red. El objetivo de una de ellas era simular el modelo contrario del sistema, utilizando el error generado por la discrepancia entre la señal de referencia y la respuesta del motor.

$$e_c = r(k) - y(k) \quad (1)$$

La siguiente es un identificador del motor, que mostrara la diferencia entre la respuesta del motor y su salida.

$$e_i = y_{n2}(k) - y(k) \quad (2)$$

Los estados de la red de identificación se utilizan para crear una retroalimentación, que se transmite a la tercera red que se entrena con el error de control.

Uno de los esquemas básicos es que la red neuronal aprende la relación inversa entre las variables de entrada y salida del sistema a controlar, ya que las redes tienen la capacidad de generar modelos que se ajustan a las relaciones entre las variables de entrada y salida. Y usar esta red como un precompensador del sistema después. Al hacer esto, se obtiene una ganancia unitaria en la relación referencia-salida. Esto significa que la salida del sistema nos brindará un control total del sistema.

Después de probar varias veces el modelo con los datos obtenidos, se realizará un diseño de experimentos en el que se creará una matriz de experimentos factorial completa de 2^k . En estos experimentos, cada factor se examinará a solo dos niveles del motor, con y sin retroalimentación de velocidad, y sus experimentos contemplarán todas las combinaciones de cada nivel de un factor con todos los niveles de los factores.

Los algoritmos de tipo competitivo, la ley Hebbiana y la corrección por error son los principales algoritmos de aprendizaje de redes neuronales.

Dado que este algoritmo de aprendizaje está basado en el modelo supervisado y existe una señal deseada para las salidas de la red, se ha seleccionado el aprendizaje de Corrección por Error para el entrenamiento. La función del error se describe de la siguiente manera:

$$e_i(k) = y_i^d(k) - y_i(k) \quad (3)$$

En el instante k , $e_i(k)$ es la señal de error, $y_i^d(k)$ es la señal deseada y $y_i(k)$ es la señal de salida de la red neuronal. El algoritmo se basa en la función de costo mínimo utilizando el método del gradiente descendente. El valor instantáneo de la suma de los cuadrados de errores se utiliza como criterio o función de costo en aplicaciones que requieren que se realice el ajuste de pesos en cada iteración.

$$E(k) = \frac{1}{2} \sum_r e_r^2(k) \quad (4)$$

Los pesos sinápticos de la red neuronal deben reducir la función de costo. Para lograr esto, se emplea la siguiente regla.

$$\Delta w_{ij}(k) = w_{ij}(k + 1) - w_{ij}(k) = \mu e_i(k) x_j(k) \quad (5)$$

En donde el índice de aprendizaje es μ .

La regla de corrección por error y el índice de aprendizaje garantizan la estabilidad del algoritmo. La superficie del error es una función cuadrática de los pesos con un mínimo global si la red neuronal está compuesta por nodos lineales.

Sin embargo, la superficie del error tiene un mínimo global y posiblemente varios mínimos locales si la red neuronal está compuesta por unidades de procesamiento no lineales. La regla delta puede caer en un mínimo local y nunca alcanzar el mínimo porque el algoritmo de aprendizaje comienza en un punto arbitrario de la superficie y avanza paso a paso en busca de un mínimo.

Este es uno de los problemas con la actualización de pesos mediante ecuaciones; Sin embargo, su popularidad y facilidad de uso lo hacen adecuado para el propósito del método. Retropropagación del error es un algoritmo de aprendizaje por corrección del error para redes con conexiones hacia adelante. Este tiene la característica de transferir el error de salida a las capas internas de la red neuronal, lo que lo hace muy útil para realizar procedimientos de codificación y clasificación.

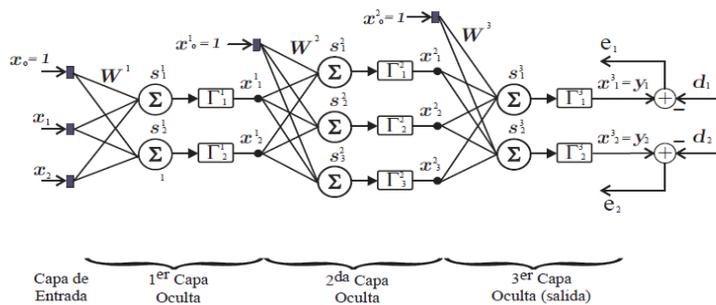
Las redes neuronales del tipo de conexión hacia adelante (FeedForward), que es una red estática, se ajustan utilizando este algoritmo. Este algoritmo se puede presentar de dos maneras: por lote (Batch) o iterativo. El ajuste de los pesos de la red se realiza al final de cada época, es decir, una vez que se ha comparado la respuesta actual de la red para todo el conjunto de datos de entrenamiento, en el algoritmo por lote que se utilizaría. Para este caso, la expresión describe el índice de desempeño.

$$\varepsilon = \frac{1}{2} \sum_{n=1}^N (\sum_{i=1}^P e_i^2(n)) \quad (6)$$

Donde N es un entero que representa la cantidad de épocas. Una época es el conjunto completo de patrones o datos de entrenamiento. La cantidad de patrones de entrenamiento se indica con P y el error de salida i de la red neuronal con e_i . Al final de cada época, se ajustan los pesos.

En el caso iterativo, los pesos de la red se ajustan para cada elemento del conjunto de entrenamiento. Nos interesa este tipo de algoritmo porque permite su uso en aplicaciones que requieren un ajuste continuo de los parámetros de la red neuronal.

Para crear el algoritmo de retropropagación del error, se utilizará un caso específico de una red neuronal que tiene una configuración de dos entradas, dos nodos ocultos en la primera capa oculta, tres nodos ocultos en la segunda capa oculta y dos nodos de salida, o En resumen, una configuración de {2, 2, 3, 2}.



Este algoritmo de retropropagación de errores reduce el valor medio de la suma de los errores de salida al cuadrado.

$$E(k) = \sum_{i=1}^{nL} [y_i^d(k) - y_i(k)]^2 = \sum_{i=1}^{nL} [e_i(k)]^2 \quad (7)$$

En el instante k , $E(k)$ es el índice de desempeño y $y_d i (k)$ es el valor deseado en la salida i de la red neuronal. La expresión se utiliza para actualizar los pesos de la red.

$$\Delta w_{ij}^l(k) = -\mu \frac{\partial E(k)}{\partial w_{ij}^l(k)} \quad (8)$$

En la situación en la que μ es el índice de aprendizaje y w_{ij}^l es el peso de la capa l que conecta la salida de la neurona j de la capa $l - 1$ con la entrada de la neurona i en la capa l , la cual tendremos al desarrollarse.

$$\Delta w_{ij}(k) = w_{ij}(k + 1) - w_{ij}(k) \quad (9)$$

que indica que la función de costo debe ser minimizada, lo que indica que el algoritmo de retropropagación del error minimizará el valor medio de la suma de los errores de salida al cuadrado.

El proceso ahora se divide en dos partes. La primera parte ocurre cuando el peso a ajustar se encuentra en la capa de salida de la red, mientras que la segunda parte ocurre cuando el peso a ajustar se encuentra en una de las capas ocultas de la red. Esta separación se debe a que los pesos de la capa de salida son la

función directa del error, $e_i(k)$ se almacenará en la base de datos de la red como un nuevo vector para lograr el objetivo de aprendizaje supervisado en la red.

RESULTADOS Y DISCUSIÓN

Debido a sus principios simples y formales de control y seguimiento, la metodología SCRUM es sin duda la más popular entre las empresas. Aunque esta metodología tiene muchas ventajas, también pueden surgir algunos problemas, como la participación de los miembros del equipo, la ubicación geográfica o la diversidad cultural. La idea de un grupo centralizado requiere situaciones que no todos pueden cumplir, lo que obstaculiza su desarrollo, por lo que estas dificultades no solo surgen en situaciones extremas.

Los resultados son talentosos porque se simularon y entrenaron redes neuronales utilizando la herramienta de programación MATLAB en su versión R2013a. Esto simula una red neuronal para que los motores de corriente continúen funcionando en tiempo real. Para lograr esto, se implementó un modelo de motor que se probó con una variedad de valores nominales y se controló con una variedad de sistemas de control. Se utilizó una distribución de negro rojo para emular bloques de sistemas de control.

Primero, se emplearon métodos matemáticos físicos convencionales para ingresar los datos en forma de matriz a Matlab. Las entradas de esta matriz se llaman INPUT. Luego se agregaron los datos utilizados en el método anterior, así como las variables de control y las salidas esperadas. TARGET y una matriz de prueba adicional, que muestran las variables de salida del diseño estadístico. En el Workspace de Matlab se crean las Tablas 1,2 y 3.

Los resultados son talentosos porque se simularon y entrenaron redes neuronales utilizando la herramienta de programación MATLAB en su versión R2013a. Esto simula una red neuronal para que los motores de corriente continúen funcionando en tiempo real. Para lograr esto, se implementó un modelo de motor que se probó con una variedad de valores nominales y se controló con una variedad de sistemas de control. Se utilizó una distribución de negro rojo para emular bloques de sistemas de control.

Primero, se emplearon métodos matemáticos físicos convencionales para ingresar los datos en forma de matriz a Matlab. Las entradas de esta matriz se llaman INPUT. Luego se agregaron los datos

utilizados en el método anterior, así como las variables de control y las salidas esperadas. TARGET y una matriz de prueba adicional, que muestran las variables de salida del diseño estadístico. En el Workspace de Matlab se crean las Tablas 1,2 y 3.

Tabla 1. Entradas a RNA para reproducir el modelo inverso del sistema.

>> input						
input =						
Posición	1	1	1	0	1	0
Velocidad	30	30	30	1	30	1

Tabla 2. Entradas de RNA para mostrar la diferencia entre la respuesta del motor y su salida.

>>Simple	
Sample=	
1	9
6	12

Tabla 3. Salidas esperadas

>> target						
target =						
Velocidad de salida final	6	3.0001	9	294.893	93.86	89.76

Posteriormente, se creó la red neuronal artificial mediante el uso del toolbox NNTool por la cual, a través de diversos editores, nos permitió importar grandes cantidades de datos y también nos permitió clasificar y codificar las diferentes características de las variables controlables que determinaron el buen comportamiento al entrenar la red. En el editor se seleccionó una red del tipo feed-forward backprop, se indicó que el rango de las entradas en la cual se eligieron 2 capas con 10 neuronas cada una y con la función de activación tansig Figuras 1 y 2.

Figura 1. Creación de la Red Neuronal.

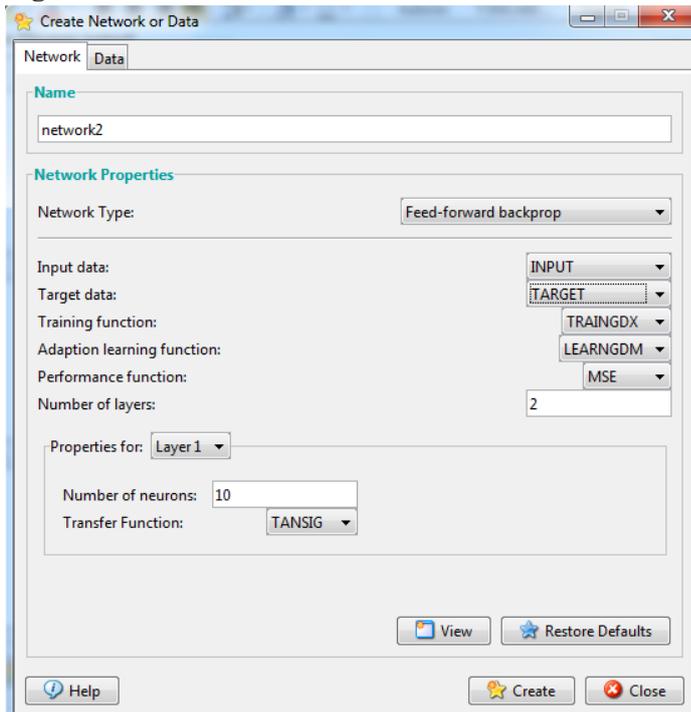
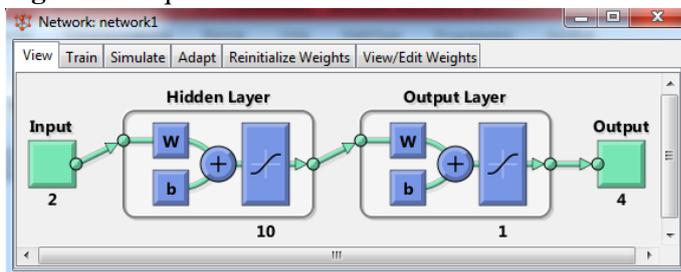


Figura 2. Esquema de la Red Neuronal.



A continuación, se entrenó la red para lo cual se seleccionaron los parámetros con los cuales se deseaba entrenar y luego se indicaron las entradas y los objetivos (input y target respectivamente) previamente guardados Figuras 3,4 y 5.

Figura 3. Parámetros para Entrenar la Red

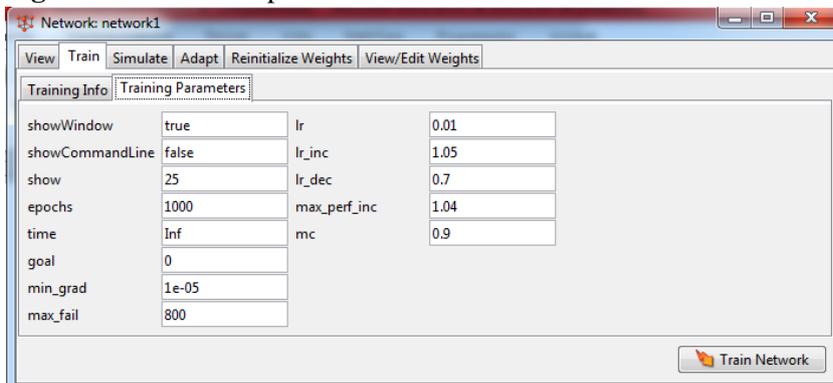
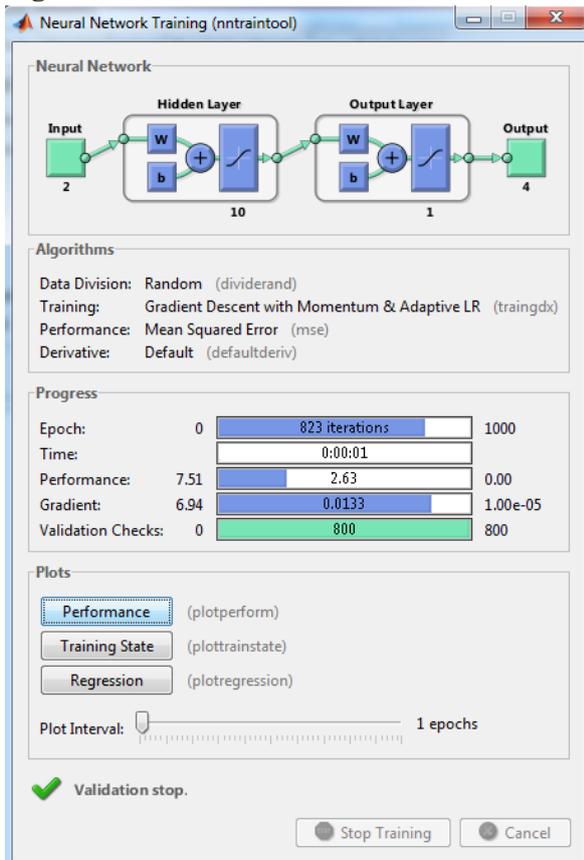


Figura 4. Entrenamiento de la Red.

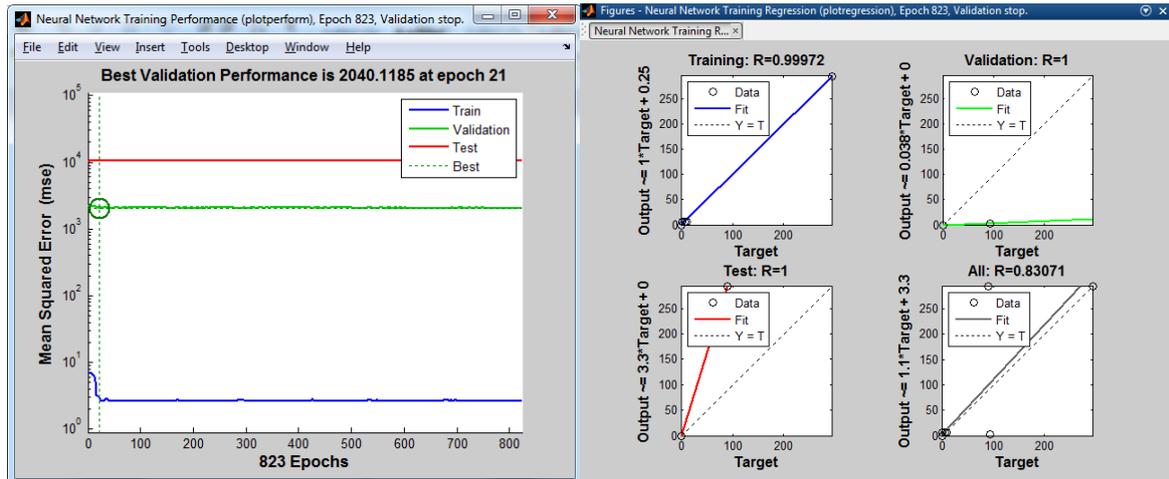


CONCLUSIONES

Nuestro objetivo ha sido alcanzado después de 823 épocas. La red simple ha sido instrumentada. Esta estructura almacena toda la información de la red. Existe una relación lineal precisa entre los resultados deseados para la clasificación y la codificación, según los índices de puntos de datos utilizados en los conjuntos de entrenamiento, validación y prueba $tr.trainInd$, $tr.valInd$ y $tr.testInd$, respectivamente. Los datos de entrenamiento, validación y prueba se muestran en la Figura 5. La línea de trazos representa el resultado perfecto - salidas = objetivos en cada gráfico. La línea continua es la mejor línea de regresión de ajuste lineal entre los objetivos y los resultados.

El valor R es una indicación de la relación entre las salidas y las metas. Si $R = 1$, esto indica que existe una relación lineal exacta entre los resultados y objetivos. Si R es cercano a cero, entonces no existe una relación lineal entre resultados y metas.

Figura 5. Validación de la red



Los datos de entrenamiento indican un buen ajuste. Los validación y resultados de pruebas también muestran que los valores de R mayor que 0,9. El diagrama de dispersión es útil para mostrar en este caso que todos los datos forman una misma línea que ciertos puntos de datos tienen pobre ajuste. Hay un punto de datos en el conjunto de Validación cuya salida está cerca de la red de 100, pero no afecta a los demás datos ya que con tantas iteraciones realizadas este valor no es significativo, puesto que en todo proceso existe una variabilidad en los datos. Se anexa gráfica de tornado mostrando el peso de influencia (en %) de las variables de impacto con respecto a la variable de salida fig. 6.

Figura 6. Ajuste de Red

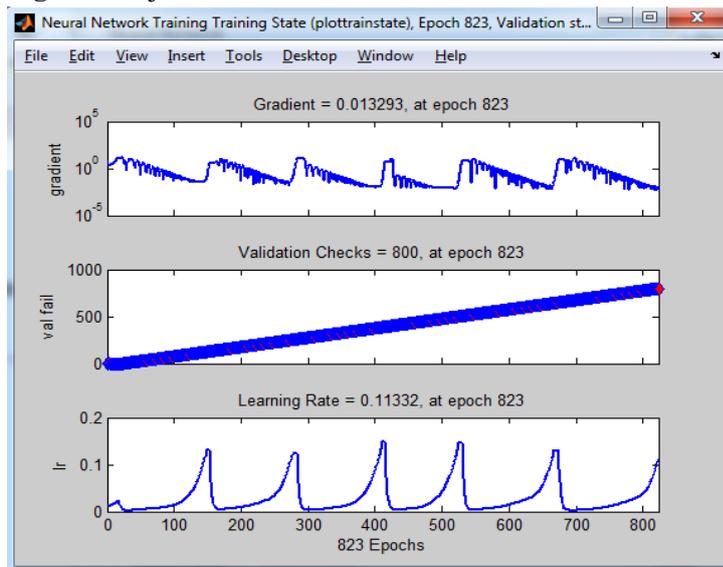
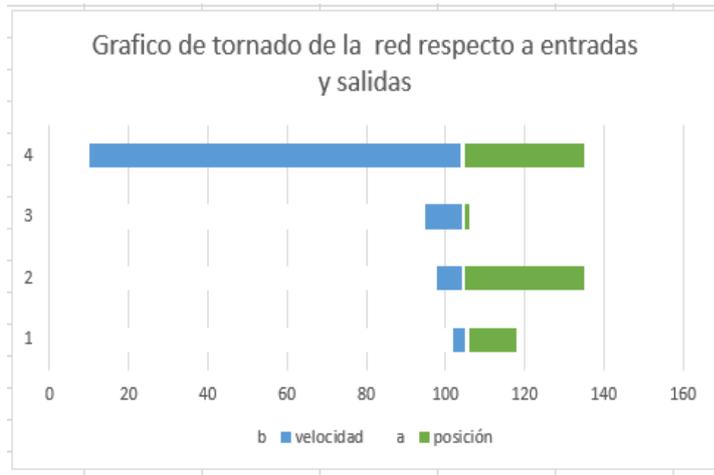


Figura 6. Gráfica de tornado



Como se vio la aplicación de las redes neuronales artificiales en los sistemas de control de motores de corriente continua, es una tecnología nueva sirve para poder reemplazar eficientemente equipos que ya no tiene un funcionamiento óptimo de acuerdo a los adelantos tecnológicos modernos. El método se validó con ensayos experimentales en el entrenamiento de la red neuronal y simulaciones del sistema formado por el motor y su control probando que el método es factible para aplicación en sistemas de control de motores de corriente continua.

REFERENCIAS BIBLIOGRAFICAS

- Higuera, A. J., Camelo, D. M., & Cediell, T. O. (2014). SCRUM: A TRAVÉS DE UNA APLICACIÓN MÓVIL. *TIA*, 182-192.
- Katsuhiko, O. (1998). *Ingeniería de Control moderna*. México : Pearson.
- Ken-Ichi, F. (1989). On the Approximate Realization of Continuous Mappings by Neural Networks. *Neural Network*, 183-192.
- Sastry, P., Santharam, G., & Unnikrishnan, K. (1994). Memory neuron networks for identification and control of dynamical systems. *IEEE Transactions on Neural Networks*, 306-319.
- Suykens, J. &. (28 de 11 de 2022). *Neural control theory : an overview*. Obtenido de Semantic scholar: <https://www.semanticscholar.org/paper/Neural-control-theory-%3A-an-overview-Suykens-Bersini/8918f4bb531650f425a0c419f5854bf7167e616d?sort=relevance>
- Velasquez, H. J. (2005). NEUROSCHHEME: A MODELING LANGUAGE FOR ARTIFICIAL NEURAL NETWORKS . *Dyna*, 75-83.

- Ah Chung Tsoi, S. Andrew D. Back. Locally Recurrent Globally Feedforward Networks: A Critical Review of Architectures. *IEEE Trans. on Neural Networks*, Vol. 5, No. 2, pp . 229-239 March, 2004
- Chiu, H.N. (2005): “The integrated logistics management system: A framework and case study”, *International Journal of Physical Distribution and Logistics Management*, vol. 25, núm. 6, p. 4-22.
- De Pablos Heredero (2004): “Innovative automation technology in corporate warehousing logistics”, *Journal of Business Logistics*, vol. 12, núm. 1, p. 63-82.
- Denis, J.E. y Czellar, S. (1997): “Les nouvelles directions de recherche en marketing: une étude comparative France-États Unis 1989-1994”, *Revue Française du Marketing*, vol. 2, núm. 16, p. 7-29.
- Dresner, M. y Xu, K. (1995): “Customer service, customer satisfaction, and corporate performance”, *Journal of Business Logistics*, vol. 16, núm. 1, p. 23-41.
- Ellram, L.M.; La Londe, B.J. y Weber, M.M. (1999): “Retail logistics”, *International Journal of Physical Distribution & Logistics Management*, vol. 29, núm. 7/8, p. 477-494.
- Gil, I. Cervera, A. y Frasquet, M. (2007). “Empleo de TIC y efectos relacionales en la cadena logística”. *Boletín Económico de ICE*, núm. 2914, p. 31-48.
- Jones, P.; Clarke-Hill, C.; Hillier, D. y Comfort, D. (2005b): “The benefits, challenges and impacts of radio frequency identification technology (RFID) for retailers in the UK”, *Marketing Intelligence & Planning*, vol. 23, núm. 4, p. 395-402
- Evans, P.; Wurster S. (2000). *Blown to bits: how the new economics of information transforms strategy*. USA: Harvard Business.
- Fletcher R., Bell J. y McNaughton R. (2004). *International E- Business Marketing*. Gran Bretaña: Thomson.