

Diseño y simulación de un control neuronal aplicado a un convertidor flyback para la regulación de tensión

Design and simulation of a neural control applied to a flyback converter for voltage regulation

Óscar Eduardo López-Manchola ^{1a}, Juan David Gómez-Buitrago ^{1b},
Andrés Eduardo Gaona-Barrera ^{1c}, Nelson Leonardo Díaz-Aldana ²

¹ Laboratorio de Automática e Inteligencia Computacional, Facultad de Ingeniería, Universidad Distrital Francisco José de Caldas, Colombia. Correos electrónicos: ^a oelopezm@correo.udistrital.edu.co, ^b judgomez@correo.udistrital.edu.co, ^c angaona@hotmail.com. Orcid: ^b 0000-0002-9136-7849.

² Laboratorio de Investigación de Fuentes Alternativas de Energía, Facultad de Ingeniería, Universidad Distrital Francisco José de Caldas, Colombia. Correo electrónico: nelson.diaza@gmail.com. Orcid: 0000-0003-0202-0489.

Recibido: 10 enero, 2021. Aceptado: 10 mayo, 2021. Versión final: 30 junio, 2021.

Resumen

Este artículo presenta el diseño y simulación de un controlador basado en redes neuronales para regular la tensión de salida de un convertidor flyback. Se usan redes neuronales, ya que estas no requieren de un modelo matemático del convertidor, y, por tanto, se obtiene un mayor rango de operación respecto a métodos de control tradicional. En el entrenamiento se realizan cambios en la base de datos y en la arquitectura para obtener el controlador más apropiado, que garantice la regulación de línea y carga del convertidor. La validación del controlador neuronal funcional se realiza en Simulink con el modelo circuital de un convertidor flyback, sometiéndolo a cambios en la tensión de entrada y en la carga resistiva. Los resultados obtenidos muestran la efectividad del control neuronal para la regulación de línea entre 20 V y 50 V, regulación de carga entre 8 Ω y 12 Ω , y cuya arquitectura está conformada por cuatro neuronas.

Palabras clave: aprendizaje de máquina; control inteligente; convertidor flyback; red neuronal; regulador de tensión; Simulink; efectividad del control neuronal; cuatro neuronas.

Abstract

This article explains the design and simulation of a controller based on neural networks to regulate the output voltage of a flyback converter. Neural networks are used since they do not require a mathematical model of the converter, with the advantage of a greater operating range than traditional control methods. In the training process, changes were made in the database and in the neural network architecture to get a more appropriate controller that the guaranteed line and load regulation of the converter. The functional neural controller validation was made on Simulink with the circuital model of a flyback converter, putting it to changes of output load and input voltage. The results obtained show the effectiveness of neuronal control with its ability to regulate lines in a range of 20V to 50V, load regulation between 8 Ω and 12 Ω , and whose architecture is made up of four neurons.

Keywords: intelligent control; flyback converter; machine learning; neural network; voltage regulator; Simulink; effectiveness of neuronal control; four neurons.

ISSN impreso: 1657 - 4583. ISSN en línea: 2145 - 8456, **CC BY-ND 4.0** 

Como citar: O. E. López-Manchola, J. D. Gómez-Buitrago, A. E. Gaona-Barrera, N. L. Díaz-Aldana, "Diseño y simulación de un control neuronal aplicado a un convertidor flyback para la regulación de tensión," *Rev. UIS Ing.*, vol. 20, no. 4, pp. 111-126, 2021, doi: [10.18273/revuin.v20n4-2021009](https://doi.org/10.18273/revuin.v20n4-2021009).

1. Introducción

El análisis de los sistemas de control requiere, en un inicio, establecer una representación matemática del modelo a estudiar, visto este modelo como una operación particular entre las variables de entrada y salida del problema, generalmente obtenido a través de un conjunto de ecuaciones diferenciales [1]. Los avances tecnológicos actuales han generado una gran variedad de nuevos problemas y aplicaciones de carácter no lineal. Por ejemplo, en ingeniería mecánica, múltiples aplicaciones involucran fenómenos de amortiguamiento y rigidez de carácter no lineal [2]. En las telecomunicaciones, los amplificadores de potencia son intencionalmente forzados a trabajar en un régimen de operación de tipo no lineal para obtener una mejora en la eficiencia de potencia [3]. Inclusive, en varios sistemas biológicos, por ejemplo, los ojos, los oídos y el sentido del tacto, primero se aplica una compresión no lineal, conocida como la ley de Weber-Fechner, para cubrir el gran rango dinámico de sus entradas [4].

Gracias a este gran campo de aplicación, la teoría de control no lineal ha experimentado en los últimos años una importante expansión, utilizando novedosas técnicas restringidas a sistemas con una estructura específica. En particular, es frecuente encontrar un método de análisis por medio de puntos de equilibrio [5]; a través de este se comienza a dar linealidad al sistema no lineal alrededor de algún punto o conjunto de puntos continuos para poder usar técnicas de control tradicional, utilizando, por ejemplo, el controlador PI o el PID [6], [7]. Sin embargo, esta técnica solo permite predecir el comportamiento local, no sirve para estudiar el comportamiento lejos del punto de operación, por lo cual limita el campo de trabajo de una implementación del control en una aplicación particular [8].

Como alternativa, a finales del siglo XX, surge la línea de investigación denominada control inteligente, con el fin de usar técnicas de inteligencia artificial, como las redes neuronales o la lógica difusa, aplicadas al control [9]. Las redes neuronales y los sistemas difusos presentan una gran versatilidad, y permiten la identificación y el control de sistemas dinámicos con características no lineales. El continuo avance en los algoritmos utilizados para su entrenamiento, principalmente en redes neuronales, ha sido posible gracias al cada vez más fácil acceso a herramientas computacionales más robustas, a precios relativamente accesibles [10].

En el campo de la electrónica de potencia se han hecho trabajos de identificación y control de convertidores DC/DC; por sus rangos de operación, dinámica no lineal y retos en su diseño e implementación, son usados como

filtros activos, sistemas de almacenamiento energéticos y fuentes de energía renovables [11]. En [1] y [12] se desarrolla un modelo dinámico de un convertidor flyback. Cuando en el modelo se consideren más características del convertidor, este se hará más complejo; aunque el propósito de los controles sea distinto, su complejidad hace que el proceso de implementación sea largo.

En [13] se presenta un control basado en redes neuronales, y en [14] se presenta otro que utiliza lógica difusa. En ambos trabajos el control ajusta la señal de conmutación por modulación de ancho de pulso (PWM) para regular la tensión de entrada o salida del convertidor, pero el entrenamiento de los controles necesita mayor trabajo y algoritmos más elaborados para garantizar la regulación de tensión. También, el uso de controladores en modo deslizante se destaca recientemente en la literatura, debido a su simplicidad de implementación. Sin embargo, este tipo de controles puede presentar problemas de alta variabilidad en la frecuencia de conmutación y, por ende, mayor rizado, además de un alto error de estado estacionario [15].

En este trabajo se presenta el desarrollo de un control inteligente, basado en redes neuronales, para un convertidor tipo flyback, que actúa como regulador de tensión. La particularidad de este desarrollo es que se caracteriza el sistema utilizando el convertidor en lazo abierto y capturando la información correspondiente a la respuesta natural del convertidor ante una entrada tipo escalón; adicionalmente, el control neuronal no requiere de algún algoritmo complejo de entrenamiento, puesto que se usa el algoritmo de backpropagation. Con este procedimiento se evita el problema del cero en el semiplano derecho abierto del sistema en lazo cerrado [12], y, al no requerir el uso de controles convencionales como el PI, no es necesario realizar el diseño ni mejorar su desempeño [14]. El diseño y la validación del control se realizan por medio de un modelo de simulación; se involucra la comparación de tres arquitecturas de redes neuronales: feedforward, fully connected cascade (FCC) y de base radial, donde la experimentación consiste en regular la tensión de salida ante cambios en la tensión de entrada y en la carga resistiva.

Este documento está organizado de la siguiente forma: en la sección 2 se explica el funcionamiento y las cualidades del convertidor flyback y de las redes neuronales, además, se mencionan aplicaciones de redes neuronales en el control de convertidores DC/DC; también se describe el proceso para desarrollar el control neuronal, desde la adquisición de la base de datos hasta el entrenamiento de la red neuronal; en la sección 3 se muestran los resultados de la validación del control

neuronal ante los cambios de los parámetros del convertidor; por último, en la sección 4 se establecen las conclusiones sobre el desempeño del control neuronal y el desarrollo de este para garantizar la regulación de tensión de salida.

2. Metodología

2.1. Convertidor flyback

Los convertidores DC/DC son conocidos como fuentes de alimentación conmutadas. Estos son dispositivos electrónicos capaces de tomar un valor tensión DC de entrada y aumentarlo o reducirlo a otro nivel DC, para brindar una tensión de salida regulada. El convertidor flyback es un elevador-reductor de tensión, está conformado por dos bobinas acopladas por el mismo núcleo como elemento almacenador de energía, un condensador para filtrar los componentes AC a la salida, un diodo y un transistor en conmutación constante que actúa como un interruptor [16], [17], [18]; el diagrama circuital se observa en la figura 1.

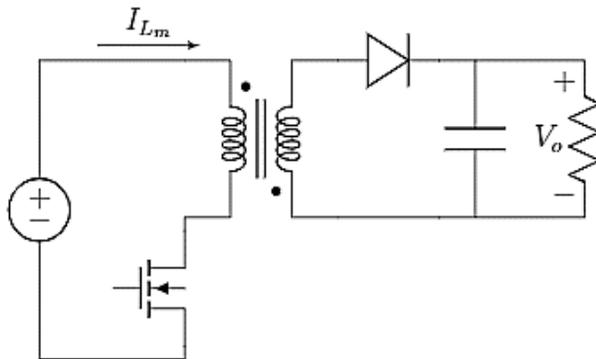


Figura 1. Convertidor flyback. Fuente: elaboración propia.

Las bobinas acopladas se comportan como un transformador de alta frecuencia [19], lo que brinda un aislamiento galvánico entre la entrada y la salida; además, el almacenamiento de energía se debe a la inductancia de magnetización del lado primario del transformador. Adicionalmente, el transformador brinda mayor eficiencia, gracias al control sobre la corriente o tensión del bobinado secundario.

Una forma de obtener la relación de conversión del convertidor es con el modelo simplificado del transformador, que no tiene en consideración las pérdidas ni las inductancias de fuga. En el análisis hay que considerar cuándo el interruptor está cerrado durante un tiempo $D.T$ y cuándo está abierto durante un tiempo

$T.(1-D)$, donde T es el periodo de conmutación y D es el ciclo útil. Gracias a la acción del interruptor, se obtiene una relación de conversión no lineal.

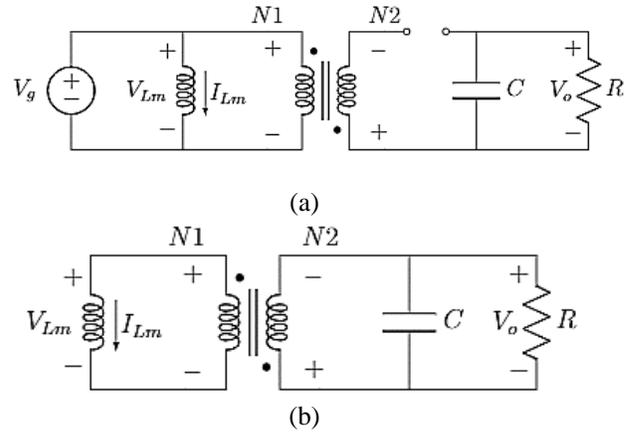


Figura 2. Circuitos equivalentes del convertidor flyback, (a) con interruptor cerrado, (b) con interruptor abierto. Fuente: elaboración propia.

Cuando el interruptor está cerrado, como se observa en la figura 2(a), la tensión de la inductancia de magnetización V_{Lm} es igual a la tensión de entrada V_g ; la corriente pasa a través de la inductancia de magnetización y no sobre el devanado primario, esto se debe a que la corriente del devanado secundario es cero a causa del diodo en inverso, de modo que la tensión en la inductancia de magnetización es:

$$V_{Lm} = V_g \quad (1)$$

Cuando el interruptor está abierto, como se observa en la figura 2(b), la corriente que se encuentra en la inductancia de magnetización se descarga a través del devanado primario del transformador; la corriente sale por el punto del segundo devanado y pone el diodo en directo. Puesto que la salida tiene la polaridad contraria al lado secundario, la tensión de salida V_o es negativa, por lo tanto, la tensión de la inductancia de magnetización es:

$$V_{Lm} = -V_o \cdot \frac{N_1}{N_2} \quad (2)$$

Con (1) y (2) se obtiene la relación de conversión del convertidor en términos de los parámetros del convertidor. Teniendo en cuenta que el valor medio de la tensión en el inductor en estado estacionario es cero [20], al sumar el valor de tensión de la bobina cuando el interruptor está abierto y cerrado, durante un periodo T , se obtiene la siguiente expresión:

$$0 = \frac{V_g \cdot D \cdot T - V_o \cdot \frac{N1}{N2} \cdot (1 - D) \cdot T}{T} \quad (3)$$

Al despejar la tensión de salida de (3), la relación de conversión se define así:

$$V_o = \frac{V_g \cdot D \cdot N2}{(1 - D) \cdot N1} \quad (4)$$

En este modelo se asume que la corriente en la inductancia de magnetización nunca es cero; esto se conoce como modo de conducción continua.

2.2. Redes neuronales artificiales

Son sistemas de aprendizaje inspirados en el funcionamiento del cerebro humano; emulan e imitan sistemas permitiendo establecer relaciones no lineales entre las variables de entrada y salida [21]. Las ventajas de las redes neuronales son la capacidad de aprender por medio de la experiencia, generalizar su comportamiento a nuevos estímulos, abstraer características esenciales de información de entrada, ser tolerante a fallos y procesamiento de información en paralelo en tiempo real. Gracias a estas propiedades, las redes neuronales son utilizadas en problemas de clasificación, regresión, predicción e identificación de sistemas [22].

Las neuronas que conforman una red neuronal artificial tienen la estructura que se observa en la figura 3; las señales de entradas son ponderadas mediante los pesos sinápticos; la salida depende de la función de activación y se calcula en función de la suma ponderada de las entradas y el umbral de activación o bias. El valor de la salida corresponde al estado de actividad de la neurona, donde el rango de la salida y suele estar en el intervalo $[0,1]$ o $[-1,1]$ [23].

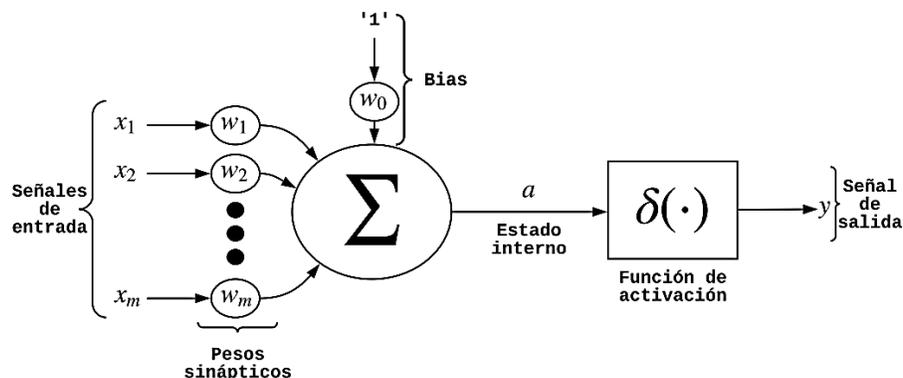


Figura 3. Estructura de una neurona artificial. Fuente: elaboración propia.

Dependiendo de cómo se organicen las capas y las neuronas, es posible obtener distintas arquitecturas. La más común es la feedforward [24]. En la figura 4 se muestra un ejemplo de esta arquitectura, la cual presenta las siguientes características:

- Capa de entrada: al igual que en el caso presentado para una neurona, la capa de entrada coincide con el vector de datos x_1, x_2, \dots, x_m .
- Capa oculta: conjunto de neuronas l_1, l_2, \dots, l_b que pertenecen al mismo nivel de jerarquía (capa oculta 1) dentro de toda la estructura de la red. Para este conjunto de neuronas no existen conexiones entre ellas. En general, la capa oculta k tiene como entradas las salidas de la capa k-1 o la capa de entrada, dependiendo si esta es la primera capa oculta de la red, donde cada una de estas puede tener una cantidad diferente de neuronas. De igual manera, todas las conexiones posibles de la red van de izquierda a derecha, ya que no está permitido que existan conexiones realimentadas. Es frecuente encontrar la misma función de activación para todas las neuronas pertenecientes a la misma capa, sin embargo, esta condición no es obligatoria; así mismo, la función de activación por cada capa puede no ser la misma.
- Capa de salida: última capa de la red, donde sus salidas y_1, y_2, \dots, y_i componen el conjunto de señales de salida de la red neuronal. La cantidad de salidas y_q depende de la cantidad de neuronas q presentes en esta capa.

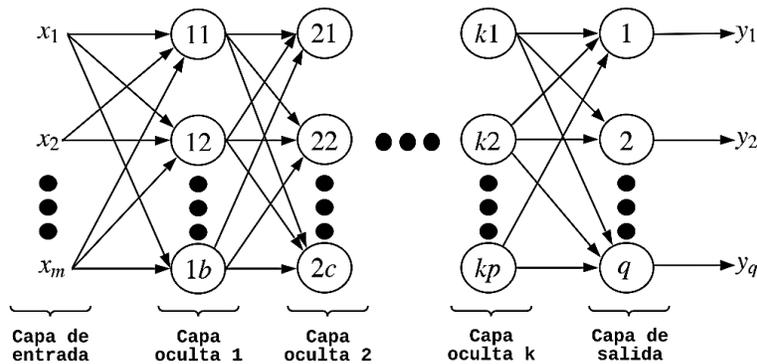


Figura 4. Red neuronal feedforward. Fuente: elaboración propia.

Otra arquitectura de red neuronal es la FCC (fully connected cascade [25]), que se caracteriza por reducir el número de neuronas por capa a una sola. La arquitectura de la FCC se constituye de la siguiente forma: las conexiones de la capa de entrada están conectadas a todas las capas de la red, además, cada capa oculta está conectada a la entrada de las capas ocultas posteriores hasta la capa de salida; un ejemplo de esta arquitectura se observa en la figura 5.

La red neuronal de base radial es una arquitectura distinta que combina aprendizaje supervisado y no supervisado, en donde la función de activación de las neuronas de la capa oculta es una distribución gaussiana normalizada, como se aprecia en la figura 6, mientras que la capa oculta contiene neuronas como las presentadas en la figura 3.

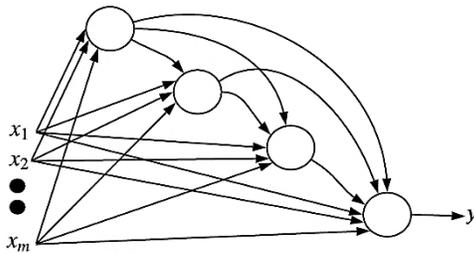


Figura 5. Red neuronal FCC. Fuente: elaboración propia.

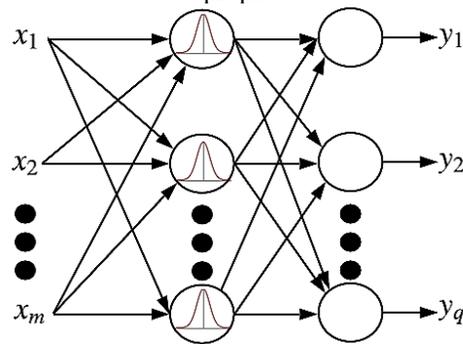


Figura 6. Red neuronal de base radial. Fuente: elaboración propia.

2.3. Control neuronal

Para la etapa de control de convertidores DC/DC pueden utilizarse redes neuronales tipo feedforward [13], [26], [27], [28], [29], donde a su entrada se tiene un conjunto de señales encargadas de entregar una muestra de corriente o tensión asociada directamente con el circuito [13] o como señales de error, siendo estas la resta entre la señal de referencia y la señal medida, también de tensión o de corriente [26], [27], [28], [29]. La elección de una u otra depende de la aplicación particular y de la facilidad que esté presente al momento de su evaluación y posible implementación. Así mismo, la salida de la red se encarga de modificar el valor del ciclo útil del circuito de conmutación del convertidor, bien sea entregando directamente el valor del ciclo útil [26], [27], [28], [29] o teniendo una salida binaria que se encarga de definir si se debe incrementar o disminuir este parámetro [13].

Para completar la arquitectura de la red, es necesario establecer el número de capas ocultas y la respectiva cantidad de neuronas presentes en cada una de ellas, junto con el conjunto de funciones de activación, que generalmente se establece por capa. En [29] se tiene una red 1-3-1, con funciones de activación unitaria y tangente hiperbólica. En [28] se utiliza una red 2-3-1 con las mismas funciones de activación ya mencionadas para la capa oculta y la de salida; en este caso difiere la capa de entrada, gracias a que se toma la muestra de la señal de error de tensión y de corriente. En ninguno de estos dos casos se justifica el porqué de la cantidad elegida de capas ocultas y su cantidad de neuronas.

En contraparte, en [26] se utiliza un algoritmo genético para la obtención de una arquitectura óptima y otro para realizar el entrenamiento de la red. Estos algoritmos se caracterizan por utilizar el concepto de evolución natural, soportado en los mecanismos de herencia, mutación y selección. Como alternativa de entrenamiento, en [29] utilizan el algoritmo de backpropagation, el cual, al ser

de tipo supervisado, requiere un conjunto de datos de entrenamiento apropiados para su ejecución, para lograr obtener el menor error de generalización asociado al error cuadrático medio.

En [30] utilizan identificación paralela, cuyo diagrama esquemático se muestra en la figura 7, argumentando su utilidad cuando se dispone de una planta o sistema sin memoria, es decir, cuando el valor actual de salida del sistema no depende de valores de la entrada o salida en instantes anteriores. El entrenamiento de la red neuronal busca gradualmente reducir el error asociado a la salida esperada del sistema respecto a la calculada por la red neuronal. Con este error se ajustan los parámetros de la red neuronal por medio de un algoritmo de entrenamiento como el backpropagation, el cual es el algoritmo más utilizado gracias a sus bajos requisitos computacionales. Una de las implementaciones comunes de este algoritmo en *software* es el método de Levenberg-Marquardt, que se caracteriza por su rápida velocidad de convergencia [31], [32].

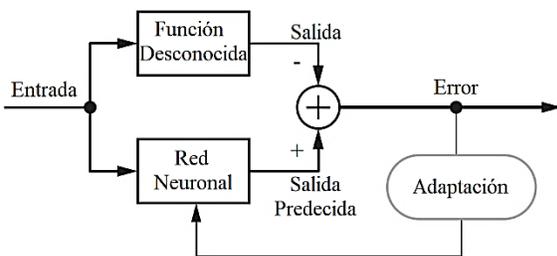


Figura 7. Identificación paralela para sistemas de control. Fuente: [30].

Respecto a la implementación del control, existen trabajos previos [33], [34] que realizan aproximaciones de redes neuronales en microcontroladores o en FPGA, por medio de multiplicadores y sumadores que permiten realizar operaciones en paralelo, donde, en particular, las funciones de activación se obtienen mediante aproximaciones numéricas.

2.4. Desarrollo de este control basado en redes neuronales

El desarrollo de este control basado en redes neuronales se divide en cuatro etapas. En la (i) adquisición de datos se obtiene la base de datos para el entrenamiento y validación de la red; en la (ii) regulación de línea se entrena la red para asegurar una tensión objetivo de 15 V a la salida ante cambios de tensión en la entrada entre 20 V y 40 V; la (iii) variación de arquitectura para obtener la red con mejor desempeño, y, por último, la (iv) regulación de carga busca asegurar la tensión objetivo ante cambios de la carga resistiva de 8Ω a 12Ω.

2.4.1. Adquisición de datos

En la figura 8 se presenta el esquema de simulación utilizado en Simulink. En este, el convertidor opera como un reductor de tensión; además, se consideran los componentes resistivos de sus elementos. El convertidor trabaja en lazo abierto, es decir, se ajusta manualmente el valor del ciclo útil para cada una de las variaciones de la tensión de entrada para obtener una tensión de salida fija de 15 V.

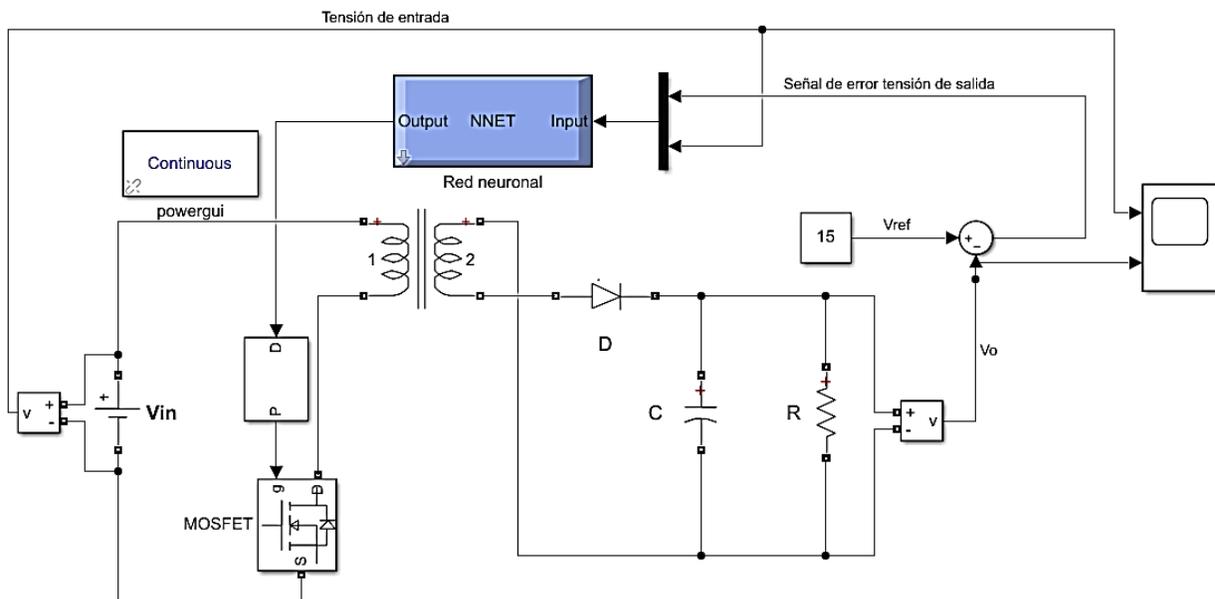


Figura 8. Esquema de simulación del control neuronal aplicado al convertidor flyback. Fuente: elaboración propia.

La información correspondiente al comportamiento del convertidor se exporta a MATLAB para poder entrenar la red neuronal. Una vez entrenada, la red neuronal, bloque azul, se acopla al convertidor, conectando a sus entradas la tensión de entrada y la señal de error de la tensión de salida, y en donde su salida corresponde al valor de ciclo útil que el convertidor debe adoptar.

El cálculo del ciclo útil necesario se realiza utilizando la expresión (4). Al realizar las simulaciones para diferentes valores de la tensión de entrada, se encuentra que el modelo matemático no permite obtener un error en estado estacionario nulo ($15\text{ V} - V_o$), debido a que la simulación incluye pérdidas para cada uno de los componentes del convertidor, las cuales no están contempladas en el análisis analítico del mismo, esto con el objetivo de que el control sea capaz de manejar las variaciones asociadas a las pérdidas del convertidor. Es necesario entonces ajustar los valores de ciclo útil que sí permiten obtener una tensión de salida cercana a 15 V .

Los diferentes valores de la tensión de entrada V_{in} , utilizados para la adquisición de datos, junto con el valor de ciclo útil teórico D_t , calculado con (4), y el ciclo útil ajustado por simulación D_s se muestran en la tabla 1.

Se realizan dos pruebas para determinar cuáles estímulos de entrada permiten cumplir con el objetivo de regulación de tensión. El primer conjunto de entrenamiento se

obtiene al aplicar escalones independientes, dando prioridad al estado transitorio. Las curvas obtenidas para la señal de error se muestran en la figura 9.

Tabla 1. Valores de ciclo útil calculados y simulados

V_{in}/V	D_t	D_s
20	0,8446	0,8444
22,5	0,8285	0,8173
25	0,8130	0,7929
27,5	0,7981	0,7705
30	0,7837	0,7500
32,5	0,7698	0,7306
35	0,7564	0,7126
37,5	0,7435	0,6956
40	0,7310	0,6795

Fuente: elaboración propia.

En complemento, el segundo conjunto de entrenamiento es definido a través de la aplicación de escalones de distinta magnitud en intervalos que permiten que el sistema se estabilice. Cada variación de los escalones se ajusta de forma consecutiva. Al pasar al siguiente escalón, se ajusta inmediatamente el valor del ciclo útil correspondiente. En este caso el comportamiento de las variaciones de la señal de error se observa en la figura 10.

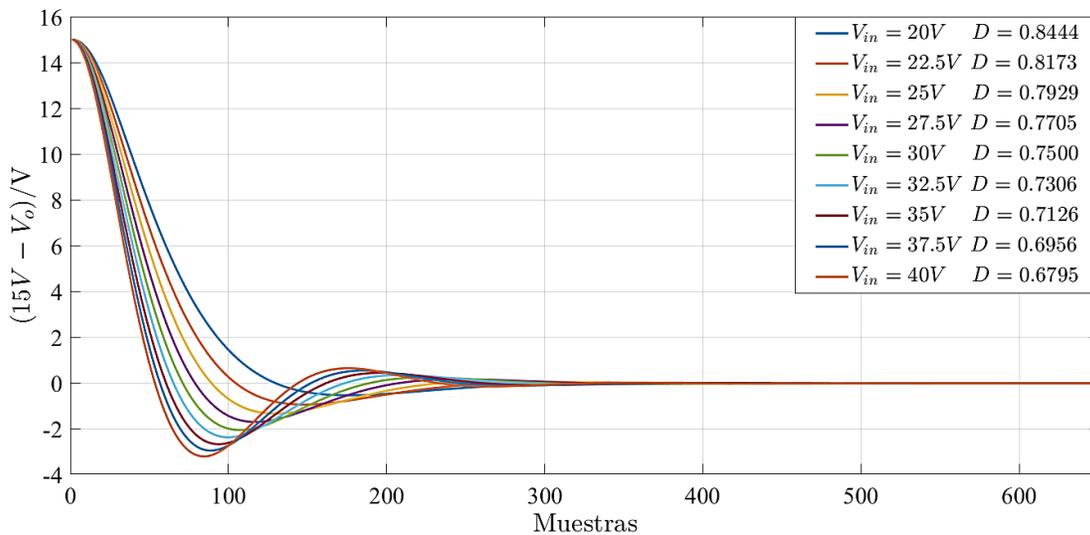


Figura 9. Conjunto de curvas de señal de error para escalones independientes. Fuente: elaboración propia.

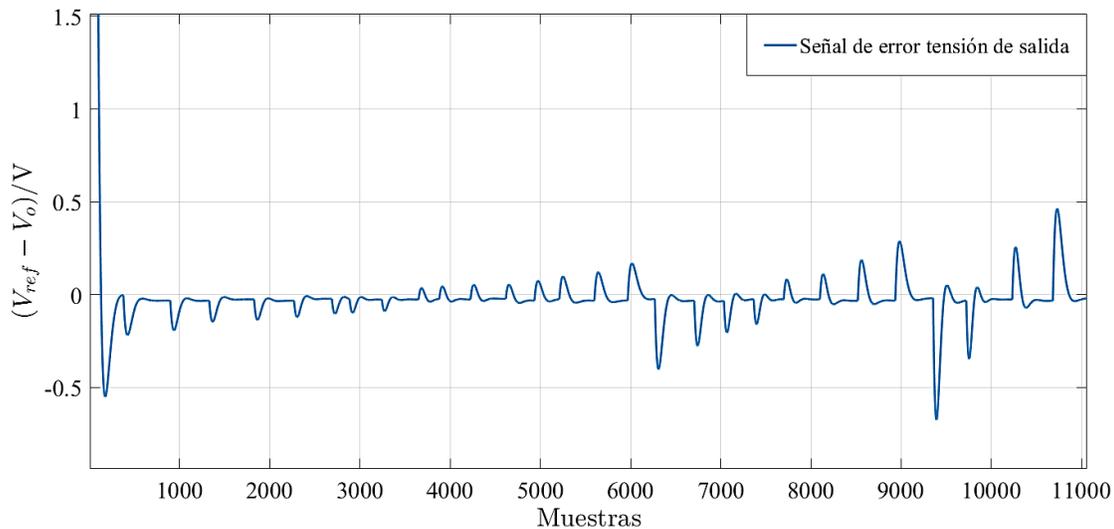


Figura 10. Señal de error para escalones de diferentes magnitudes aplicados consecutivamente. Fuente: elaboración propia.

2.4.2. Regulación de línea

La red neuronal posee dos entradas: la tensión de entrada V_{in} y la señal de error de la tensión de salida $15\text{ V} - V_o$. La salida de la red neuronal corresponde al ciclo útil que debe tener la señal PWM del convertidor. Para comparar el desempeño de las dos bases de datos, se entrena una red neuronal con cada una de estas bases usando el esquema de identificación de la figura 7. Las características del entrenamiento y el criterio de parada en ambos casos son:

- División de los datos: aleatoria.
- Algoritmo de entrenamiento: Levenberg-Marquardt.
- Porcentaje de datos para entrenamiento: 70 %
- Porcentaje de datos para prueba: 20 %
- Porcentaje de datos para validación: 10 %
- Máxima cantidad de iteraciones: 10.000.
- Gradiente mínimo: 10^{-13}

Una vez entrenadas, las redes se conectan a dos convertidores iguales, con el fin de evaluar su comportamiento ante los mismos cambios de la señal de entrada realizados simultáneamente en ambos sistemas.

2.4.3. Variación de arquitectura

Después de elegir la base de datos apropiada y garantizar la regulación de línea, se realizan pruebas con diferentes arquitecturas de redes neuronales para realizar el control. Inicialmente, las redes tienen pocas neuronas y capas, estas van aumentando hasta encontrar la arquitectura más apropiada, es decir, encontrar la red de menor tamaño que

cumpla satisfactoriamente con el requisito de regulación de línea. Las arquitecturas propuestas son: red feedforward, red neuronal FCC y la red neuronal de base radial.

2.4.4. Regulación de carga

Al adicionar la regulación de carga, el control es más robusto ante cualquier cambio de tensión; esto implica agregar más muestras a la base de datos. En este caso, la tensión de entrada es constante y la resistencia de carga varía entre $8\ \Omega$ y $12\ \Omega$; después se ajusta el valor de D para obtener la tensión objetivo de 15 V . Los valores obtenidos se muestran en la tabla 2.

Tabla 2. Valores de ciclo útil ante cambios de carga

V_{in}/V	R_l/Ω	D
20	0,8446	0,8444
20	0,8285	0,8173
30	0,8130	0,7929
30	0,7981	0,7705
40	0,7837	0,7500
40	0,7698	0,7306

Fuente: elaboración propia.

3. Resultados

3.1. Regulación de línea

Como se observa en la figura 11, con ambas bases de datos se cumple el objetivo de regular la tensión de salida del convertidor. Al ajustar el tamaño de las curvas, se

observa cómo se superponen, esto muestra que el comportamiento en ambos casos es el mismo. Sin embargo, resulta conveniente continuar la experimentación únicamente con la base de datos correspondiente a los escalones independientes, ya que, una menor cantidad de muestras permite que el entrenamiento sea computacionalmente más eficiente, sin que afecte el desempeño del control. Por consiguiente, es importante destacar que basta con obtener la respuesta natural del sistema al escalón para entrenar la red neuronal.

Teniendo una única base de datos, se decide ahora reducir la cantidad de muestras de esta, pasando únicamente a considerar los escalones desde 20 V hasta 40 V, ahora en pasos de 5 V y aumentando el periodo de muestreo para reducir la cantidad de datos de cada curva. La base de

datos inicial cuenta con un total de 5859 muestras, mientras su reducción alcanza un máximo de 330 muestras.

En la figura 12, el resultado con el control 1 (curva azul) corresponde a la red entrenada con la base de datos inicial de 5859 muestras, mientras que el control 2 (curva roja) corresponde a la red entrenada con la base simplificada. Ambos controles operan correctamente dentro del rango establecido (20 V – 40 V), pero cuando se aumenta el valor de la tensión de entrada, el control 1 no logra regular la tensión de salida, de hecho, es el control 2 quien responde apropiadamente. Lo anterior indica que la primera base de datos está disminuyendo la capacidad de generalización del control neuronal, al impedir que funcione correctamente para tensiones superiores a 40 V, en cambio, la segunda base regula hasta 50 V.

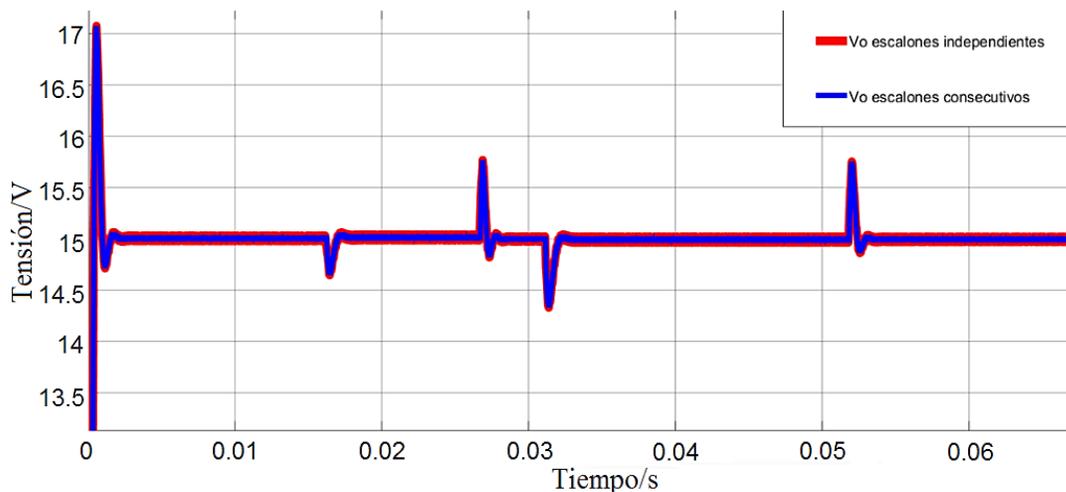


Figura 11. Comparación de desempeño base de datos escalones independientes y consecutivos. Fuente: elaboración propia.

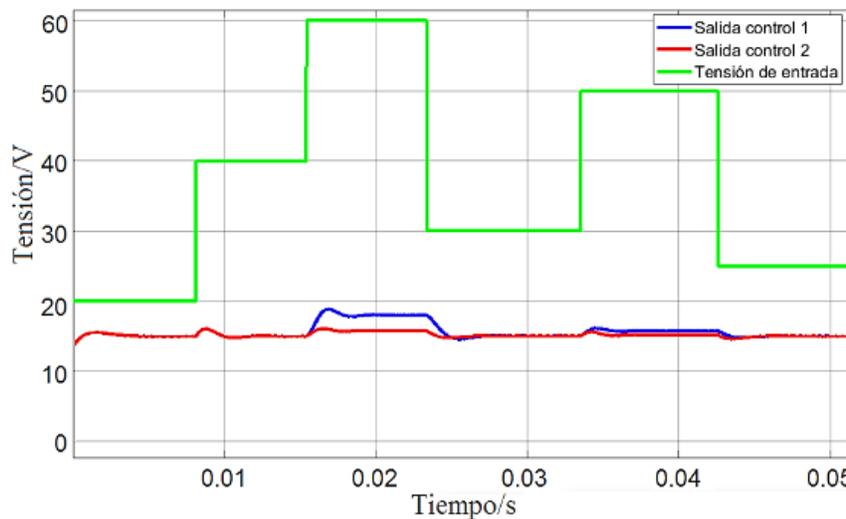


Figura 12. Comparación de desempeño base de datos inicial y simplificada. Fuente: elaboración propia.

3.2. Variación de arquitectura

Con la base de datos simplificada se prueban diferentes arquitecturas de redes neuronales para la etapa de control. Las pruebas con la red feedforward consisten en variaciones de la cantidad de capas ocultas y de neuronas por capa, todas las neuronas de las capas ocultas usan la función tangente sigmoidea. La capa de salida es una única neurona con función de activación sigmoidea. El desempeño se evalúa con el error en la tensión de salida. La tensión de entrada varía entre 40 V y 80 V , ya que en el rango de 20 V a 40 V no es posible apreciar alguna diferencia significativa. Los errores de la tensión de salida obtenidos para las diferentes arquitecturas establecidas se resumen en la [tabla 3](#); se observa que la quinta arquitectura es la que presenta mejor desempeño, con un error del $13,79\%$.

Tabla 3. Error tensión de salida con distintas arquitecturas

	Arquitectura	Error (%)
1	1 capa, 3 neuronas	23,88
2	1 capa, 4 neuronas	19,78
3	1 capa, 5 neuronas	19,2
4	2 capa, 3 neuronas	18,43
5	2 capa, 4 neuronas	13,79
6	2 capa, 5 neuronas	20,35

Fuente: elaboración propia.

La arquitectura de la FCC es similar a la feedforward, así que en lugar de variar el número de capas de la red FCC, se hace contraste entre ambos tipos de arquitecturas, comparando el funcionamiento de una arquitectura FCC

contra una feedforward. En la primera prueba se evalúa el desempeño de las dos arquitecturas con una capa oculta y una neurona por capa. En la [figura 13](#) se observa cómo la red FCC con una capa oculta es capaz de funcionar correctamente dentro del rango de trabajo establecido ($20\text{ V} - 40\text{ V}$), caso contrario a la red feedforward que no logra mantener la tensión de salida en el valor objetivo de 15 V ante las variaciones de la tensión de entrada.

Debido a que la arquitectura FCC más simple presenta buenos resultados, se realiza otra comparación respecto a una red feedforward de dos capas ocultas y una neurona por capa. En la [figura 14](#) se observa el resultado de esta comparación.

Con el aumento a dos capas ocultas, la red neuronal feedforward presenta un comportamiento más cercano al esperado, logrando alcanzar la tensión objetivo ante estímulos de la entrada que se encuentran dentro del rango de trabajo contemplado. Así mismo, la red FCC presenta una mayor capacidad de generalización al ser capaz de mantener la tensión regulada, aun cuando se presentan tensiones por debajo y por encima del rango, capacidad que no tienen las redes feedforward de una y dos capas propuestas. La red FCC deja de responder correctamente a 10 V por encima del valor máximo del rango planteado.

La tercera arquitectura, la red de base radial, inicia con 15 neuronas y se somete a los mismos cambios de tensión de entrada. Sin embargo, la red no es capaz de regular la tensión de salida dentro ni fuera del rango de operación establecido, como se observa en la [figura 15](#).

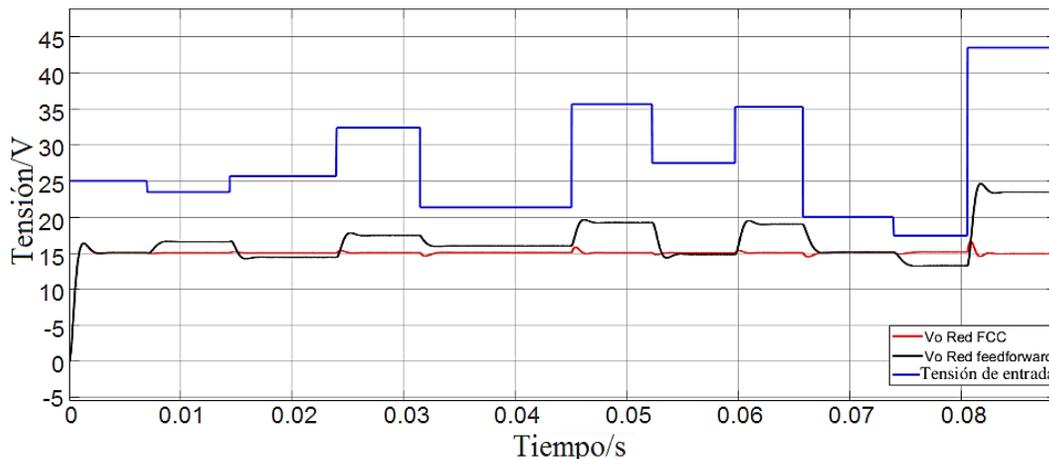


Figura 13. Desempeño de las arquitecturas tipo feedforward y FCC con una capa oculta. Fuente: elaboración propia.

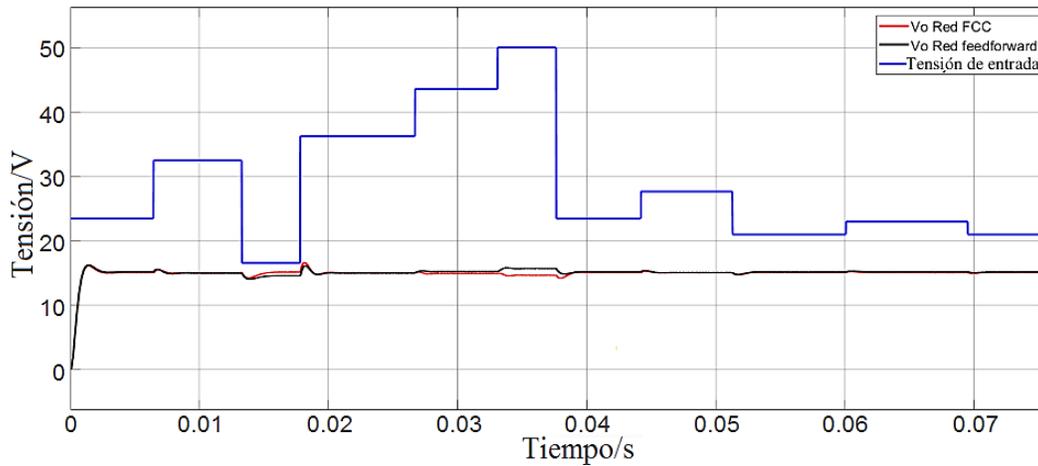


Figura 14. Arquitectura más simple para una red FCC vs. red neuronal feedforward de dos capas ocultas. Fuente: elaboración propia.

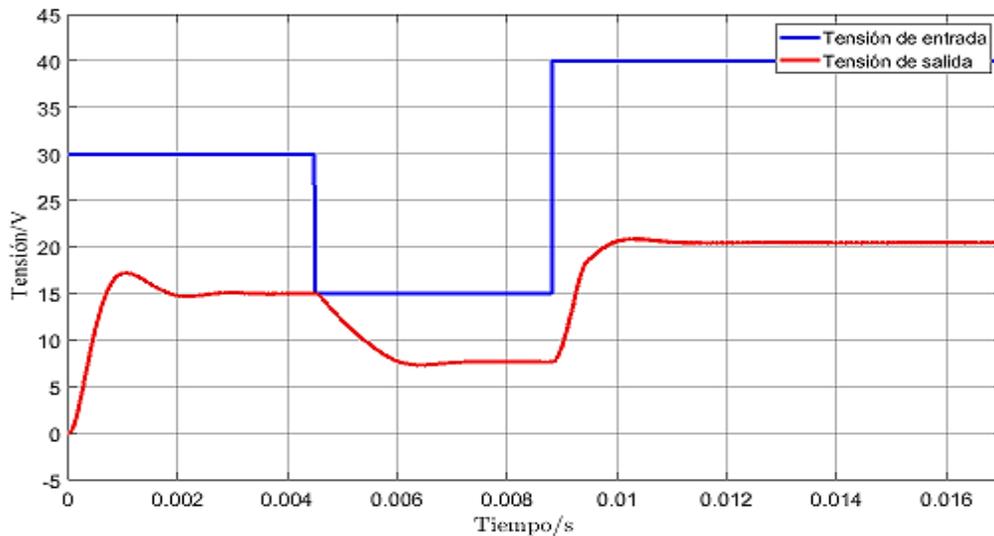


Figura 15. Resultados regulación de línea usando red neurona de base radial. Fuente: elaboración propia.

Al realizar más experimentos, variando los parámetros de entrenamiento y número de neuronas, se obtiene un mejor resultado; sin embargo, la red de base radial no logra regular la tensión de salida del valor objetivo, puesto que no es capaz de encontrar el patrón del comportamiento del convertidor.

3.3. Regulación de carga

A partir de los resultados de la experimentación anterior, las arquitecturas feedforward y la FCC son las más apropiadas para el control; la FCC es la mejor para la regulación de línea. Ahora, para estas arquitecturas se realizan cambios en la carga con el fin de evaluar su comportamiento. El comparativo es entre una red feedforward de dos capas ocultas con cuatro neuronas y una red FCC de cuatro capas.

Los resultados del comportamiento de los controles se observan en la [figura 16](#).

Calculando el error promedio entre las salidas con respecto a la tensión objetivo, el error para la red neuronal FCC es de $0,476 V$, mientras que en la red feedforward es de $0,4096 V$. En la [figura 16](#) se observa que la red feedforward se comporta mejor en el rango de operación, pero fuera de este responde mejor la FCC.

En una segunda prueba se reduce una capa en la red FCC y se repite la comparación. Como se observa en la [figura 17](#), en esta prueba los resultados son contrarios al de la prueba anterior; el error en red la FCC es $0,525 V$ y el error de la red feedforward es $0,5766 V$. En la [tabla 4](#) se encuentran resumidos los resultados de la experimentación.

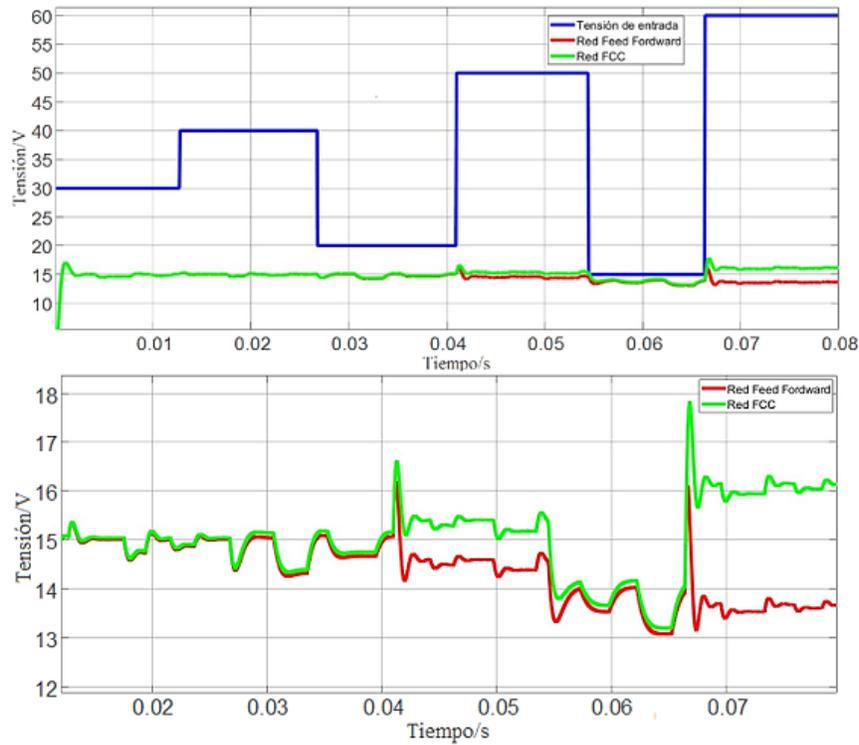


Figura 16. Resultados regulación de línea y carga red neuronal FCC 4 de neuronas vs. red feedforward de 2 capas ocultas. Fuente: elaboración propia.

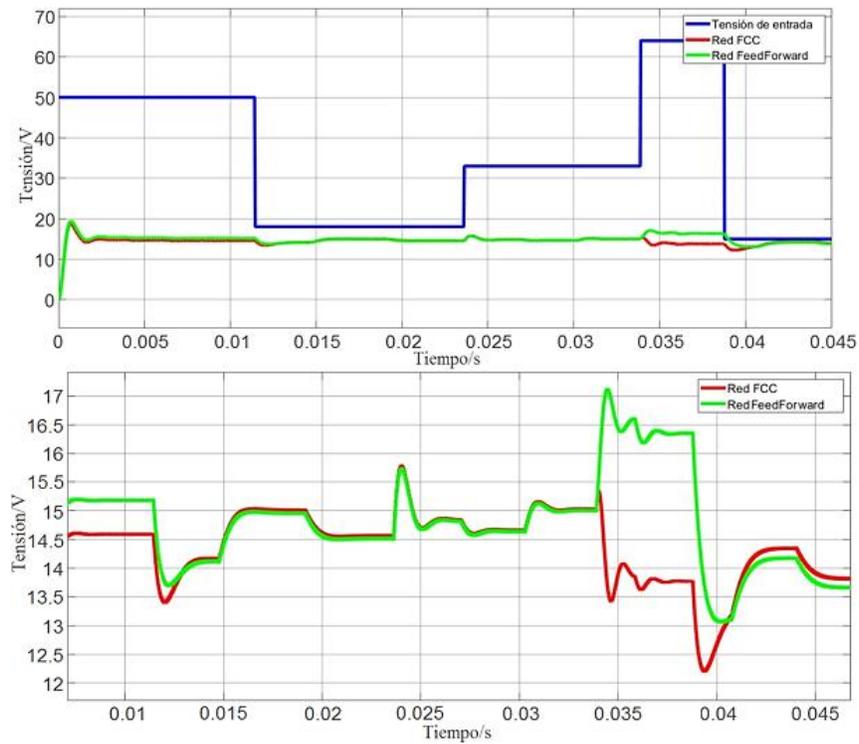


Figura 17. Resultados regulación de línea y carga red neuronal FCC 3 de neuronas vs. red feedforward de 2 capas ocultas. Fuente: elaboración propia.

Tabla 4. Resultados generales

Arquitectura	Regula línea	Regula carga	Neuronas requeridas
1	Sí	Sí	8
2	Sí	Sí	4
3	No	No	15

Fuente: elaboración propia.

A pesar de no haber una clara diferencia en qué red tiene mejor desempeño, la mejor opción es la FCC. Ambas redes tienen una capacidad de generalización similar, pero la FCC hace que cada neurona sea más relevante al aumentar el número de conexiones que posee. Comparando la cantidad de neuronas por arquitectura, la FCC tiene menos de la mitad de las neuronas que la feedforward y presenta resultados semejantes: en términos de costo computacional, es más sencillo implementar la red FCC para cumplir el objetivo de regulación de línea y carga.

4. Conclusiones

La metodología utilizada permite obtener un control a partir del comportamiento real del convertidor flyback en lazo abierto, tomando su relación entrada-salida. Esto evita caracterizar matemáticamente tanto la planta como el convertidor y sus pérdidas.

La elección correcta del conjunto de datos utilizados para el entrenamiento de la red neuronal tuvo una gran influencia al momento de evaluar su desempeño, puesto que al usar una menor cantidad de muestras, el rango de trabajo alcanzado de 20 V a 50 V es mayor respecto al inicialmente contemplado de 20 V a 40 V, resaltando así la capacidad de generalización del control neuronal.

Para cumplir la tarea de regulación de carga, entre 8 Ω y 12 Ω , y de línea del convertidor es necesario entrenar la red neuronal con la respuesta dinámica del convertidor, ya que el estado transitorio permite detectar si la variación es un incremento o disminución de la tensión de entrada o de la carga.

La exploración de las diferentes arquitecturas (feedforward, FCC y base radial) demuestra que la mejor es la red FCC, al presentar el mejor desempeño y menor costo computacional, utilizando cuatro neuronas; estas condiciones son importantes al momento de implementar este control en un sistema embebido o una FPGA, debido a la poca cantidad de neuronas requeridas.

Los resultados demuestran la capacidad de regulación de línea y carga del control neuronal; aunque este trabajo está limitado a diseño y simulación, es viable realizar una implementación en *hardware* del control neuronal. A futuro se pueden evaluar aspectos que no se tuvieron en cuenta, como el tipo de entrenamiento de la red neuronal. En cuanto a la operación del control, es posible aumentar el rango de operación del convertidor y además reducir parámetros de la respuesta dinámica como el overshoot y el tiempo de establecimiento.

Agradecimientos

Los autores quieren agradecer a la Universidad Distrital Francisco José de Caldas y a los grupos de investigación LAMIC y LIFAE por su apoyo económico y académico para el desarrollo de esta investigación.

Referencias

- [1] C. L. T. Rodríguez, N. L. D. Aldana, J. A. H. Mora, "Controller design for a flyback converter, in operating interconnected to grid mode, for photovoltaic applications", *Revista. Facultad de Ingeniería.*, no. 65, pp. 16-32, 2012.
- [2] C. M. Pappalardo, D. Guida, "Use of the adjoint method for controlling the mechanical vibrations of nonlinear systems", *Machines*, vol. 6, no. 2, pp. 19, 2018, doi: [10.3390/machines6020019](https://doi.org/10.3390/machines6020019).
- [3] J. S. Gill, D. K. Owen, M. Braylovskiy, "Apparatus, system, and method for improving the power efficiency of telecommunications devices", U.S. Patent No 10,063,049, 28-Ago-2018.
- [4] J. Schoukens, L. Ljung, "Nonlinear system identification: A user-oriented road map", *IEEE Control Syst. Mag.*, vol. 39, no. 6, pp. 28-99, 2019, doi: [10.1109/MCS.2019.2938121](https://doi.org/10.1109/MCS.2019.2938121).
- [5] X. Yue, B. Su, "Predictive Functional Control of Nonlinear Systems Based on Multiple LPV Models", en *2019 Chinese Automation Congress (CAC)*, 2019, pp. 5210-5214, doi: [10.1109/CAC48633.2019.8997055](https://doi.org/10.1109/CAC48633.2019.8997055).
- [6] K. M. Tsang, W. L. Chan, y X. L. Wei, "Robust DC/DC buck converter using conditional integrator compensator", *Electron. Letters*, vol. 44, no. 2, pp. 152-154, 2008.

- [7] Z. Yu, J. Zeng, J. Liu, F. Luo, "Terminal sliding mode control for dual active bridge DC-DC converter with structure of voltage and current double closed loop", en *2018 Australian & New Zealand Control Conference (ANZCC)*, 2018, pp. 11-15, doi: [10.1109/ANZCC.2018.8606608](https://doi.org/10.1109/ANZCC.2018.8606608).
- [8] M. M. Seron, J. H. Braslavsky, *Sistemas no lineales*. Bogotá, Colombia: Universidad Nacional del Rosario, 2000.
- [9] M. Santos, "Un enfoque aplicado del control inteligente", *Rev. Iberoamericana de Automática e Informática Industrial RIAI*, vol. 8, no. 4, pp. 283-296, 2011, doi: [10.1016/j.riai.2011.09.016](https://doi.org/10.1016/j.riai.2011.09.016).
- [10] J. J. Montaña Moreno *et. al.*, "Redes neuronales artificiales aplicadas al análisis de datos", tesis doctoral, Universitat de les Illes Balears, 2017.
- [11] P. Cossutta, M. P. Aguirre, A. Cao, M. A. Engelhardt, M. I. Valla, "Implementación de un algoritmo DSOGI-PLL en una FPGA para sincronización con la red de convertidores de potencia", en *2014 IEEE Biennial. Congress of. Argentina, ARGENCON 2014*, 2014, pp. 651-656, doi: [10.1109/ARGENCON.2014.6868566](https://doi.org/10.1109/ARGENCON.2014.6868566).
- [12] M. Salimi, M. Hamed, "Adaptive nonlinear control of the flyback switch mode power supplies", en *2017 Int. Conf. Mech. Syst. Control Eng. ICMSC 2017*, 2017, pp. 392-396, doi: [10.1109/ICMSC.2017.7959508](https://doi.org/10.1109/ICMSC.2017.7959508).
- [13] S. Messalti, A. Harrag, A. Loukriz, "A new variable step size neural networks MPPT controller: Review, simulation and hardware implementation", *Renew. Sustain. Energy Rev.*, vol. 68, no. 1, pp. 221-233, 2017, doi: [10.1016/j.rser.2016.09.131](https://doi.org/10.1016/j.rser.2016.09.131).
- [14] A. Pagni, R. Poluzzi, G. Rizzotto, M. Lo Presti, "DC/DC converters fuzzy control", *IFIS 1993 - 3rd International Conference on Industrial Fuzzy Control Intelligent Systems*, 1993, pp. 14-17, doi: [10.1109/IFIS.1993.324222](https://doi.org/10.1109/IFIS.1993.324222).
- [15] M. Salimi, J. Soltani, A. Zakipour, V. Hajbani, "Sliding mode control of the DC-DC flyback converter with zero steady-state error", en *4th Annual International Power Electronics, Drive Systems and Technologies Conference*, 2013, pp. 158-163, doi: [10.1109/PEDSTC.2013.6506695](https://doi.org/10.1109/PEDSTC.2013.6506695).
- [16] R. W. Erickson, "Fundamentals of Power Eletronics", en *Fundamentals of Power Eletronics*, Second., KluwerAcademic Publishers, 2001, pp. 146-168.
- [17] I. Javier, A. Guacaneme, "Análisis y diseño de los conversores DC / DC básicos: el reductor, el elevador y el reductor-elevador. Consideraciones de tensión, corriente y potencia de cada elemento que compone el circuito", tesis de grado, Universidad Distrital Francisco José de Caldas, 2018.
- [18] D. Hart, *Electrónica de Potencia*. Madrid, España: Prentice Hall, 2001.
- [19] F. Semiconductor *et al.*, "The Flyback Converter," *Appl. Mech. Mater.*, vol. 734, no. September, p. 11, 2013.
- [20] M. H. Rashid, "Electronica de Potencia Rashid", en *Electrónica de potencia*, Pretince Hall, 1995, pp. 478-481.
- [21] F. Villada, N. Muñoz, E. García, "Redes neuronales artificiales aplicadas a la predicción del precio del oro", *Información Tecnológica.*, vol. 27, no. 5, pp. 143-150, 2016, doi: [10.4067/S0718-07642016000500016](https://doi.org/10.4067/S0718-07642016000500016).
- [22] D. J. Matich, *Redes Neuronales: Conceptos básicos y aplicaciones vol. 41*. México: Universidad Tecnológica Nacional de México, 2001.
- [23] S. D. Hernández, F. T. Córdova, "Simulación de una red neuronal con mapas auto-organizados (som) de kohonen", *Jóvenes en la Ciencia.*, vol. 3, no. 2, pp. 2650-2653, 2017.
- [24] R. Salas, *Redes neuronales artificiales vol. 1*. Chile: Univ. Valparaíso, 2004.
- [25] G. Deshpande, P. Wang, D. Rangaprakash, B. Wilamowski, "Fully connected cascade artificial neural network architecture for attention deficit hyperactivity disorder classification from functional magnetic resonance imaging data", *IEEE Transactions on Cybernetic.*, vol. 45, no. 12, pp. 2668-2679, 2015, doi: [10.1109/TCYB.2014.2379621](https://doi.org/10.1109/TCYB.2014.2379621).
- [26] F. H. Martínez, D. Gómez, M. Castiblanco, "Evaluation of a neural control with optimal architecture for a dc/dc converter", en *The iee 2010 international power electronics conference-ecce asia-ipecc-sapporo*, 2010, pp. 53-57.

[27] Y. M. Buswig, A. K. B. H. Othman, N. Bin Julai, S. S. Yi, W. M. Utomo, A. J. L. M. Siang, "Voltage tracking of a multi-input interleaved buck-boost DC-DC converter using artificial neural network control", *J. Telecommunications Electron. Computer Engineering*, vol. 10, no. 1-12, pp. 29-32, 2018.

[28] W. M. Utomo, A. Bakar, M. Ahmad, T. Taufik, R. Heriansyah, "Online learning neural network control of buck-boost converter", en *Proc. - 2011 8th International Conference on Information Technology: New Generations. ITNG 2011*, pp. 485-489, doi: [10.1109/ITNG.2011.216](https://doi.org/10.1109/ITNG.2011.216).

[29] W. M. Utomo, S. S. Yi, Y. M. Y. Buswig, Z. A. Haron, A. A. Bakar, M. Z. Ahmad, "Voltage Tracking of a DC-DC Flyback Converter Using Neural Network Control", *Int. J. Power Electron. Drive Syst.*, vol. 2, no. 1, pp. 35-42, 2012.

[30] M. T. Hagan, H. B. Demuth, O. D. E. Jesús, "An introduction to the use of neural networks in control systems", *International Journal of Robust and Nonlinear Control: IFAC-Affiliated Journal*, vol. 12, no. 11, pp. 959-985, 2002, doi: [10.1002/rnc.727](https://doi.org/10.1002/rnc.727).

[31] J. Amrutha, A. S. Remya Ajai, "Performance analysis of Backpropagation Algorithm of Artificial Neural Networks in Verilog", en *2018 3rd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)*, 2018, pp. 1547-1550, doi: [10.1109/RTEICT42901.2018.9012614](https://doi.org/10.1109/RTEICT42901.2018.9012614).

[32] S. Basterrech, S. Mohammed, G. Rubino, M. Soliman, "Levenberg—Marquardt Training Algorithms for Random Neural Networks", *The Computer Journal*, vol. 54, no. 1, pp. 125-135, 2011, doi: [10.1093/comjnl/bxp101](https://doi.org/10.1093/comjnl/bxp101).

[33] Z. Dlugosz, R. Dlugosz, "Nonlinear Activation Functions for Artificial Neural Networks Realized in Hardware", en *2018 25th International Conference "Mixed Design of Integrated Circuits and System" (MIXDES)*, 2018, pp. 381-384, doi: [10.23919/MIXDES.2018.8436869](https://doi.org/10.23919/MIXDES.2018.8436869).

[34] K. Khalil, O. Eldash, B. Dey, A. Kumar, M. Bayoumi, "A Novel Reconfigurable Hardware Architecture of Neural Network", en *2019 IEEE 62nd International Midwest Symposium on Circuits and Systems (MWSCAS)*, 2019, pp. 618-621, doi: [10.1109/MWSCAS.2019.8884809](https://doi.org/10.1109/MWSCAS.2019.8884809).