



**ESPE**  
UNIVERSIDAD DE LAS FUERZAS ARMADAS  
INNOVACIÓN PARA LA EXCELENCIA

**DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA  
Y TELECOMUNICACIONES**

**CARRERA DE INGENIERÍA EN ELECTRÓNICA,  
AUTOMATIZACIÓN Y CONTROL**

**TRABAJO DE TITULACIÓN, PREVIO A LA OBTENCIÓN DEL  
TÍTULO EN INGENIERO EN ELECTRÓNICA,  
AUTOMATIZACIÓN Y CONTROL**

**TEMA: ESTUDIO DE ESTRATEGIAS DE CONTROL:  
PREDICTIVO POR MATRIZ DINÁMICA Y REDES  
NEURONALES EN UN CONVERTIDOR ELEVADOR**

**AUTOR: CARRILLO HERRERA, NADIA CAROLINA**

**DIRECTOR: ING. AYALA TACO, JAIME PAÚL PhD.**

**SANGOLQUÍ**

**2018**



DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA  
CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y  
CONTROL

CERTIFICACIÓN

Certifico que el trabajo de titulación, “ESTUDIO DE ESTRATEGIAS DE CONTROL: PREDICTIVO POR MATRIZ DINÁMICA Y REDES NEURONALES EN UN CONVERTIDOR ELEVADOR” fue realizado por la señorita NADIA CAROLINA CARRILLO HERRERA, el mismo que ha sido revisado en su totalidad, analizado por la herramienta de verificación de similitud de contenido; por lo tanto cumple con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de Fuerzas Armadas ESPE, razón por la cual me permito acreditar y autorizar para que lo sustente públicamente.

Sangolquí, Julio del 2018

ING. PAÚL AYALA, PhD

C. C: 1709434243



DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA  
CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y  
CONTROL

**AUTORÍA DE RESPONSABILIDAD**

Yo, **NADIA CAROLINA CARRILLO HERRERA**, declaro que el contenido, ideas y criterios del trabajo de titulación: **“ESTUDIO DE ESTRATEGIAS DE CONTROL: PREDICTIVO POR MATRIZ DINÁMICA Y REDES NEURONALES EN UN CONVERTIDOR ELEVADOR”** es de mi autoría y responsabilidad, cumpliendo con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Consecuentemente el contenido de la investigación mencionada es veraz.

**Sangolquí, Julio del 2018**

*Nadia Carrillo*

---

Nadia Carolina Carrillo Herrera

C.C 1717915233



DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA  
CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y  
CONTROL

AUTORIZACIÓN

Yo, **NADIA CAROLINA CARRILLO HERRERA** autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **“ESTUDIO DE ESTRATEGIAS DE CONTROL: PREDICTIVO POR MATRIZ DINÁMICA Y REDES NEURONALES EN UN CONVERTIDOR ELEVADOR”** en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi responsabilidad.

Sangolquí, Julio del 2018

*Nadia Carrillo*

---

Nadia Carolina Carrillo Herrera

C.C 1717915233

## DEDICATORIA

Dedico este trabajo a mis padres, Marleni y Fernando, muchas gracias por todo su apoyo, por su aliento y sobretodo gracias por su amor. A mis hermanon Andrés y Xavier, quienes siempre han sido el mejor ejemplo a seguir.

Esto no seria posible sin todo su apoyo.

## AGRADECIMIENTO

Agredezco a Dios, por permitirme culminar esta etapa.

A la Universidad, en especial a mi director, Ing. Paúl Ayala, muchas gracias por su orientación, tiempo y paciencia a lo largo del trabajo de investigación.

A mis padres, Marleni y Fernando, por todo el esfuerzo que han realizado para que pueda culminar mi carrera universitaria, gracias por cada palabra de aliento y nunca haber dejado que me rinda. Este logro es nuestro pas, solo ustedes saben cuanto me ha costado cumplir con este objetivo.

A mi hermano Andrés y a mi cuñada Majo, gracias por apoyarme siempre y ser el mejor hermano que alguien pueda pedir.

A mi mejor amigo, mi pareja sentimental Andy, por su apoyo constante y por su cariño. Muchas gracias por el tiempo y conocimiento que siempre me ha brindado.

A toda mi familia, quienes siempre se han preocupado por mis estudios y bienestar.

A mis amigos, Dario y Belén, quienes han estado en los buenos y malos momentos. Gracias por cada experiencia, cada logro, cada proyecto, cada amanecida, serán momentos que siempre quedarán en mi memoria. Finalmente, a mis chiquis, por siempre sacarme una sonrisa.

*Nadia Carolina Carrillo Herrera.*

## ÍNDICE GENERAL

Certificación .....	i
Autoría de Responsabilidad .....	ii
Autorización .....	iii
Dedicatoria .....	iv
Agradecimiento .....	v
Indice de Tablas .....	ix
Indice de Figuras .....	xi
Resumen .....	xvii
Abstract .....	xviii
<b>1. INTRODUCCIÓN</b>	<b>1</b>
1.1. Antecedentes .....	1

1.2. Planteamiento del problema . . . . .	2
1.3. Justificación e Importancia . . . . .	3
1.4. Alcance del proyecto de fin de carrera . . . . .	5
1.5. Objetivos . . . . .	6
1.5.1. Objetivo general . . . . .	6
1.5.2. Objetivos específicos . . . . .	6
1.6. Organización del documento . . . . .	7
<b>2. ESTADO DEL ARTE</b>	<b>9</b>
2.1. Antecedentes . . . . .	9
2.2. Sistemas No Lineales . . . . .	12
2.3. Convertidor Boost . . . . .	13
2.3.1. Modelo Matemático del Convertidor <i>Boost</i> . . . . .	14
2.3.2. Modelo Promediado del Convertidor <i>Boost</i> en el Espacio de Estados	19
2.3.3. Función de Transferencia . . . . .	21
2.4. Estrategias de Control Avanzado . . . . .	24
2.5. Control Basado en Redes Neuronales . . . . .	25
2.5.1. Control Neuronal por Modelo Inverso . . . . .	29
2.5.2. Control PID con Redes Neuronales . . . . .	32
2.6. Control Predictivo basado en Modelo . . . . .	34
2.6.1. Control Predictivo por Matriz Dinámica . . . . .	37

<b>3. DISEÑO DEL CONVERTIDOR Y CONTROLADORES</b>	<b>45</b>
3.1. Diseño del Convertidor Elevador CD/CD . . . . .	45
3.1.1. Datos de partida para el diseño del convertidor . . . . .	45
3.1.2. Cálculo de la inductancia . . . . .	46
3.1.3. Cálculo del capacitor . . . . .	47
3.1.4. Simulación del convertidor . . . . .	48
3.2. Control Neuronal por Modelo Inverso . . . . .	51
3.2.1. Diseño del Controlador . . . . .	51
3.2.2. Simulación del Controlador . . . . .	55
3.3. Control PID con Redes Neuronales . . . . .	60
3.3.1. Diseño del Controlador . . . . .	61
3.3.2. Simulación del Controlador . . . . .	68
3.4. Control Predictivo por Matriz Dinámica . . . . .	71
3.4.1. Diseño del Controlador . . . . .	72
3.4.2. Simulación del Controlador . . . . .	75
<b>4. ESTUDIO COMPARATIVO DE CONTROLADORES</b>	<b>80</b>
4.1. Pruebas y Resultados . . . . .	80
4.1.1. Cambios en la tensión de referencia . . . . .	80
4.1.2. Perturbaciones en la tensión de entrada . . . . .	86
4.1.3. Perturbaciones en la carga . . . . .	91

4.2. Análisis de Desempeño de Controladores . . . . .	99
<b>CONCLUSIONES</b>	<b>107</b>
<b>REFERENCIAS</b>	<b>109</b>
<b>ANEXOS</b>	
Anexo A. Código para la identificación del convertidor <i>Boost</i> . . . . .	A.1
Anexo B. Código de entrenamiento de red. . . . .	B.2
Anexo C. Código para la generación del controlador neuronal inverso. . . . .	C.2
Anexo D. Código para importar los valores de entrada del controlador PID. . . . .	D.2
Anexo E. Código para importar los valores de salida del controlador PID. . . . .	E.2
Anexo F. Código para el controlador PID con redes neuronales. . . . .	F.2
Anexo G. Código para la simulación del controlador DMC. . . . .	G.2
Anexo H. Código de perturbaciones en la entrada en el controlador DMC . . . . .	H.3
Anexo I. Código de perturbaciones en la carga en el controlador DMC. . . . .	I.2

# Índice de tablas

<b>Tabla 1:</b>	<i>Especificaciones de diseño .....</i>	48
<b>Tabla 2:</b>	<i>Tiempos de respuesta del controlador neuronal por modelo inverso vs el controlador DMC .....</i>	99
<b>Tabla 3:</b>	<i>Tiempos de respuesta controlador PID con redes neuronales vs controlador DMC. ....</i>	99
<b>Tabla 4:</b>	<i>Tensión de salida controlador neuronal por modelo inverso vs controlador DMC. ....</i>	100
<b>Tabla 5:</b>	<i>Tensión de salida controlador PID con redes neuronales vs controlador DMC. ....</i>	100
<b>Tabla 6:</b>	<i>Tiempos de respuesta controlador neuronal inverso vs controlador DMC. ....</i>	101
<b>Tabla 7:</b>	<i>Tiempos de respuesta controlador PID con redes neuronales vs controlador DMC. ....</i>	101
<b>Tabla 8:</b>	<i>Tensión de salida controlador neuronal por modelo inverso vs controlador DMC. ....</i>	102

<b>Tabla 9:</b>	<i>Tensión de salida controlador PID con redes neuronales vs controlador DMC. ....</i>	102
<b>Tabla 10:</b>	<i>Tiempos de respuesta controlador neuronal inverso vs controlador DMC. ....</i>	103
<b>Tabla 11:</b>	<i>Tiempos de respuesta controlador PID con redes neuronales vs controlador DMC. ....</i>	103
<b>Tabla 12:</b>	<i>Tensión de salida controlador neuronal inverso vs controlador DMC. ...</i>	104
<b>Tabla 13:</b>	<i>Tensión de salida controlador PID con redes neuronales vs controlador DMC. ....</i>	104
<b>Tabla 14:</b>	<i>Especificaciones del procesador Intel® Core (TM) i7-7500U. ....</i>	105
<b>Tabla 15:</b>	<i>Tiempo de ejecución de las simulaciones. ....</i>	105

# Índice de figuras

<b>Figura 1:</b> <i>Señal de conmutación vs tiempo de conmutación</i> .....	13
<b>Figura 2:</b> <i>Esquema Convertidor Elevador CD/CD</i> .....	15
<b>Figura 3:</b> <i>Modo de conducción de un convertidor CD/CD, (Torres Pinzón, 2012).</i> .....	15
<b>Figura 4:</b> <i>Convertidor Elevador CD/CD</i> .....	16
<b>Figura 5:</b> <i>Convertidor Elevador en estado ON</i> .....	17
<b>Figura 6:</b> <i>Convertidor Elevador en estado OFF</i> .....	18
<b>Figura 7:</b> <i>Formulación Convertidor CD/CD en el Espacio de Estados</i> .....	19
<b>Figura 8:</b> <i>Estructura de una red neuronal artificial multicapa</i> .....	27
<b>Figura 9:</b> <i>Esquema del Controlador por Modelo Inverso</i> .....	29
<b>Figura 10:</b> <i>Diagrama esquemático del controlador PID</i> .....	32
<b>Figura 11:</b> <i>Estructura básica del MPC</i> .....	35
<b>Figura 12:</b> <i>Respuesta ante escalón de la planta</i> .....	38
<b>Figura 13:</b> <i>Trayectoria de referencia <math>w</math></i> .....	43
<b>Figura 14:</b> <i>Tensión en el capacitor</i> .....	49

<b>Figura 15:</b> <i>Señal ampliada de la tensión en el capacitor .....</i>	49
<b>Figura 16:</b> <i>Corriente en el inductor .....</i>	50
<b>Figura 17:</b> <i>Señal ampliada de la corriente en el inductor .....</i>	51
<b>Figura 18:</b> <i>Modelo promediado del convertidor Boost en Simulink .....</i>	52
<b>Figura 19:</b> <i>Variación de la tensión.....</i>	54
<b>Figura 20:</b> <i>Simulación de la red.....</i>	55
<b>Figura 21:</b> <i>Controlador neuronal inverso en lazo cerrado .....</i>	56
<b>Figura 22:</b> <i>Señal de referencia.....</i>	56
<b>Figura 23:</b> <i>Controlador neuronal inverso con 8 neuronas en la capa oculta .....</i>	57
<b>Figura 24:</b> <i>Controlador neuronal inverso con 10 neuronas en la capa oculta .....</i>	58
<b>Figura 25:</b> <i>Controlador neuronal inverso con 15 neuronas en la capa oculta .....</i>	58
<b>Figura 26:</b> <i>Controlador neuronal inverso con 20 neuronas en la capa oculta .....</i>	59
<b>Figura 27:</b> <i>Respuesta al impulso de la función de transferencia.....</i>	61
<b>Figura 28:</b> <i>Diagrama en lazo cerrado del controlador PID.....</i>	63
<b>Figura 29:</b> <i>Simulación del controlador PID en Simulink.....</i>	65
<b>Figura 30:</b> <i>Respuesta del controlador PID a una referencia de 70 V .....</i>	66
<b>Figura 31:</b> <i>Obtención del conjunto de entrenamiento .....</i>	67
<b>Figura 32:</b> <i>Esquema del controlador neuronal PID.....</i>	69
<b>Figura 33:</b> <i>Controlador neuronal PID con 10 neuronas en la capa oculta .....</i>	70
<b>Figura 34:</b> <i>Controlador neuronal PID con 15 neuronas en la capa oculta .....</i>	70
<b>Figura 35:</b> <i>Controlador neuronal PID con 20 neuronas en la capa oculta .....</i>	71

<b>Figura 36:</b> <i>Ley de control DMC</i> .....	72
<b>Figura 37:</b> <i>Respuesta ante escalón del convertidor Boost</i> .....	73
<b>Figura 38:</b> <i>Simulación del controlador DMC para Lambda 10</i> .....	76
<b>Figura 39:</b> <i>Simulación del controlador DMC para Lambda 100</i> .....	77
<b>Figura 40:</b> <i>Simulación del controlador DMC para Lambda 1000</i> .....	78
<b>Figura 41:</b> <i>Simulación del controlador DMC para Lambda 10000</i> .....	79
<b>Figura 42:</b> <i>Señal de referencia para pruebas</i> .....	81
<b>Figura 43:</b> <i>Controlador neuronal inverso</i> .....	82
<b>Figura 44:</b> <i>Señal de control del Controlador neuronal inverso</i> .....	82
<b>Figura 45:</b> <i>Controlador PID con Redes Neuronales</i> .....	83
<b>Figura 46:</b> <i>Señal de control del Controlador PID con Redes Neuronales</i> .....	84
<b>Figura 47:</b> <i>Controlador DMC</i> .....	85
<b>Figura 48:</b> <i>Señal de control del Controlador DMC</i> .....	85
<b>Figura 49:</b> <i>Perturbación en la tensión de entrada</i> .....	86
<b>Figura 50:</b> <i>Perturbación de entrada en el controlador neuronal inverso</i> .....	87
<b>Figura 51:</b> <i>Señal de control ante perturbaciones en la entrada</i> .....	88
<b>Figura 52:</b> <i>Perturbación de entrada en el controlador PID con redes neuronales</i> .....	89
<b>Figura 53:</b> <i>Señal de control ante perturbaciones en la entrada</i> .....	89
<b>Figura 54:</b> <i>Perturbación de entrada en el controlador DMC</i> .....	90
<b>Figura 55:</b> <i>Señal de control ante perturbaciones en la entrada</i> .....	91
<b>Figura 56:</b> <i>Perturbación en la carga</i> .....	92

<b>Figura 57:</b> <i>Perturbaciones de carga en el controlador neuronal inverso.....</i>	93
<b>Figura 58:</b> <i>Perturbación en la carga para cada referencia.....</i>	94
<b>Figura 59:</b> <i>Señal de control ante perturbaciones en la carga.....</i>	94
<b>Figura 60:</b> <i>Perturbaciones de carga en el controlador PID con redes neuronales .....</i>	95
<b>Figura 61:</b> <i>Perturbación en la carga para cada referencia.....</i>	96
<b>Figura 62:</b> <i>Señal de control ante perturbaciones en la carga.....</i>	96
<b>Figura 63:</b> <i>Perturbaciones de carga en el controlador DMC.....</i>	97
<b>Figura 64:</b> <i>Perturbación en la carga para cada referencia.....</i>	98
<b>Figura 65:</b> <i>Señal de control ante perturbaciones en la carga.....</i>	98

## RESUMEN

En el presente trabajo se realiza un estudio comparativo de tres estrategias de control avanzado aplicadas a un convertidor elevador CD/CD, dos de las cuales son basadas en redes neuronales y una en control predictivo por matriz dinámica (DMC). Se toma como punto de partida el diseño y simulación del convertidor elevador CD/CD que cumpla con las especificaciones de diseño. En la segunda etapa se realiza el diseño y simulación de los siguientes controladores: neuronal por modelo inverso, PID con redes neuronales y predictivo por matriz dinámica. Para finalmente realizar un estudio comparativo que permita elegir al controlador con mejores características de desempeño. Se ha evaluado cada controlador neuronal frente al controlador DMC, donde se toma como parámetros de evaluación a las respuestas de cada controlador ante perturbaciones en la carga, tensión de entrada y su consumo computacional.

### **PALABRAS CLAVE:**

- **CONTROL NEURONAL.**
- **CONTROLADOR PID CON REDES NEURONALES.**
- **CONTROL POR MATRIZ DINÁMICA.**
- **DMC.**

## ABSTRACT

This paper presents a comparative study of three advanced control strategies applied to a CD/CD Boost converter, two of which are based on neural networks and one on predictive control. The starting point is the design and simulation of the CD / CD riser that meets the design specifications. In the second stage, the design and simulation of the following controllers is carried out: neuronal by inverse model, PID with neural networks and predictive by dynamic matrix. To finally make a comparative study that allows choosing the driver with better performance characteristics. Each neuronal controller has been evaluated against the DMC controller, where the responses of each controller to perturbations in the load, input voltage and its computational consumption are taken as evaluation parameters.

### KEYWORDS:

- NEURONAL CONTROL.
- PID CONTROLLER WITH NEURAL NETWORKS.
- DYNAMIC MATRIX CONTROL.
- DMC.

# Capítulo 1

## INTRODUCCIÓN

### 1.1. Antecedentes

Los convertidores de corriente directa a corriente directa (CD/CD) son circuitos electrónicos de potencia que se usan como puentes de transferencia de energía entre la fuente y la carga, su principal propósito es convertir una tensión de entrada en niveles de corriente o tensión de salida que sean requeridos por la aplicación (Durango y otros., 2017). Entre los componentes que conforman el esquema de un convertidor están: los elementos conmutadores que consumen poca potencia y los elementos que almacenan energía (inductores y capacitores), que permiten suavizar el comportamiento pulsante causado por la conmutación y que idealmente no consumen energía (Torres Pinzón, 2012). En la actualidad existen varios tipos de convertidores diseñados para diferentes aplicaciones, entre los que se pueden mencionar *Buck*, *Boost*, *Buck-Boost*, *CUK*. Sin embargo, la realización de este trabajo se enfoca en el convertidor elevador de tensión “*boost*”.

Debido a la gran demanda en el desarrollo tecnológico y de aplicaciones industriales que buscan mejorar la calidad de energía, los convertidores deben ser capaces de responder ante ciertas exigencias, como son: disminución de tamaño de los elementos reactivos (inductores y capacitores), rapidez de respuesta y alto rendimiento. Es por ello, que el control de convertidores CD/CD se ha convertido en un campo muy activo de la investigación en la electrónica de potencia y la teoría de control.

Al hablar de convertidores CD/CD se debe tener en claro que son sistemas de naturaleza no lineal, y que aunque existan varias investigaciones de estrategias de control clásicas (Vázquez Gutiérrez, 2011; Rollón Rodríguez, 2014; Malo y Griño, 2005) y control avanzado (Ponce Palomino, 2013; Martínez Sarmiento y Castiblanco Ortiz, 2009; Torres Pinzón, 2012; Pinzón Trejos y Perdomo Borrero, 2016) aplicadas a este tipo de sistemas, es de gran aporte la realización de un estudio comparativo de estrategias de control avanzado: basado en redes neuronales y control predictivo por matriz dinámica (DMC) por sus siglas en inglés *Dynamic Matrix Control*, que pueda recomendar la estrategia que muestre las mejores prestaciones dinámicas del convertidor. Extendiendo de este modo trabajos previamente realizados.

## 1.2. Planteamiento del problema

En el campo de la electrónica y debido a la demanda de la tecnología actual, los convertidores de tensión CD/CD tienen gran importancia en múltiples aplicaciones, las mismas que están presentes tanto en objetos de uso cotidiano como a nivel industrial. Debido a su trascendencia se ha generado un campo específico dentro de la investigación en la electrónica

de potencia. Su objetivo principal es adecuar una señal eléctrica (corriente o/y tensión) y alimentar a una carga (Ponce Palomino, 2013).

Ante la presencia de problemas en la dinámica de este tipo de convertidores como son el comportamiento no lineal y su estructura variable; los diseñadores han optado por el uso de estrategias de control clásico, que aunque han mostrado eficiencia también han provocado fallas en la estabilidad del convertidor.

En los últimos años las investigaciones de estrategias de control que toman en consideración la no linealidad, aplicada a convertidores CD/CD han aumentado (Torres Pinzón, 2012), esto debido a que se busca solucionar problemas presentados en el uso de estrategias de control clásico como por ejemplo: desestabilización del sistema por causa de perturbaciones de gran señal, estabilidad únicamente en la región alrededor del punto de equilibrio, entre otras (Grasa y otros., 2000).

El uso de estrategias de control no lineal aplicadas a sistemas de estructura variable, permiten un control más preciso de la dinámica resultante (Salazar Calahorrano, 2013). Por ello, en el presente trabajo se plantea el uso de estrategias de control avanzado: control predictivo por matriz dinámica y control basado en redes neuronales; con las que se pretende mejorar las prestaciones dinámicas del convertidor y además se presenta un estudio comparativo de dichas estrategias utilizadas.

### **1.3. Justificación e Importancia**

El área de la electrónica de potencia ha demostrado tener un gran valor en la industria, debido a la necesidad de demasiados sistemas que procesen la energía eléctrica de mane-

ra adecuada. Los convertidores CD/CD son usados en varias aplicaciones donde se exige estabilidad frente a perturbaciones y alta eficiencia (Velarde Rueda, 2010). Sin embargo, estas características son difíciles de alcanzar debido a la naturaleza no lineal de este tipo de sistemas.

El convertidor elevador (*boost* en inglés) es un sistema altamente no lineal, utilizado para la conversión de potencia eléctrica CD/CD, regulación de voltaje y frecuentemente usado en la reducción de armónicos inherentes a los convertidores y corrección activa del factor de potencia en fuentes conmutadas de potencia (Martinez y Gómez, 2007). Su característica no lineal se debe a su funcionamiento, el cual requiere de la apertura y cierre continuo de un interruptor, lo que ocasiona que en estado estacionario la dinámica se comporte como la continua conmutación de dos circuitos lineales diferentes conocidos como sistemas de estructura variable (Martínez Sarmiento y Castiblanco Ortíz, 2009).

En los últimos años se han realizado investigaciones sobre la aplicación de estrategias de control avanzado a sistemas que se basan en modelos lineales (Martínez Sarmiento y Castiblanco Ortíz, 2009), sin embargo, es necesario aclarar la incertidumbre de su trabajo al considerar la no linealidad inherente del sistema. Además, se requiere un análisis de perturbaciones internas y externas, las mismas que permitirán concluir si los criterios seleccionados para el diseño fueron apropiados y representan un aporte en el desarrollo de aplicaciones de control de sistemas conmutados CD/CD. Para alcanzar un óptimo funcionamiento del convertidor es necesario cumplir con varios requerimientos de desempeño como son: comportamiento ante perturbaciones, tiempo de respuesta, etc. Los mismos que han motivado el desarrollo de esta investigación con el fin de obtener un controlador que mejore las prestacio-

nes dinámicas del convertidor. Si bien en la literatura científica y técnica se han encontrado varios análisis de estrategias de control aplicados a convertidores, no existe un análisis específico sobre el desempeño de un convertidor elevador *boost* al ser controlado por diferentes estrategias de control avanzadas. Es por ello que el aporte de esta investigación servirá para trabajos futuros e incluso para interés académico.

## 1.4. Alcance del proyecto de fin de carrera

En este proyecto se pretende diseñar un convertidor elevador de 100 W al que posteriormente se le aplica dos estrategias de control avanzadas, las mismas que serán estudiadas y analizadas en base a su desempeño, para finalmente realizar un estudio comparativo de ambos controladores.

Inicialmente, el trabajo consiste en el diseño y simulación del convertidor elevador *boost* bajo parámetros establecidos como tensión de salida de 100 voltios para una entrada de 20 voltios y una carga de 100 ohmios. La siguiente etapa se centra en la investigación, estudio y realización del estado del arte de los controladores.

Una vez que han sido estudiadas las estrategias de control se procede a su diseño y simulación, las que serán programadas por medio del software MatLab<sup>®</sup>. Además la forma por la que se excitará el semiconductor del convertidor es la modulación por ancho de pulso (PWM).

Finalmente, una vez que hayan sido simulados los dos controladores se procederá al análisis comparativo, donde se analizarán características como: consumo computacional, comportamiento ante perturbaciones, tiempo de respuesta, etc.

Por medio de este análisis comparativo de controladores se llegará a conclusiones que permitan recomendar la estrategia de control que muestre el mejor desempeño del convertidor elevador CD/CD en función de las dos estrategias de control simuladas.

## **1.5. Objetivos**

### **1.5.1. Objetivo general**

Evaluar el desempeño del controlador basado en redes neuronales y el controlador predictivo por matriz dinámica (DMC) en un convertidor elevador CD/CD de 100 W.

### **1.5.2. Objetivos específicos**

- Diseñar un convertidor elevador que cumpla requerimientos de funcionamiento establecido.
- Diseñar un control basado en redes neuronales y un controlador predictivo por matriz dinámica (DMC) para un convertidor elevador CD/CD.
- Simular cada uno de los controladores para validar las estrategias de control planteadas.
- Evaluar el comportamiento de las estrategias avanzadas de control aplicadas al convertidor elevador CD/CD.

## 1.6. Organización del documento

El trabajo de investigación se presenta en cuatro capítulos, que se describen de una manera resumida en esta sección para proporcionar al lector una visión general del mismo.

### Capítulo 1

En este capítulo se realiza una introducción al trabajo de investigación, donde se detallan los siguientes temas: antecedentes, planteamiento, justificación, importancia, alcance y objetivos del proyecto.

### Capítulo 2

En este capítulo se realiza la búsqueda de información necesaria para el desarrollo de la investigación, se toma como punto inicial la importancia de los convertidores elevadores a través de trabajos previamente realizados, a continuación se presenta la explicación del funcionamiento y modelo matemático del convertidor elevador CD/CD. Además, se recopila información sobre las estrategias de control avanzado que serán diseñadas y simuladas como son el control basado en redes neuronales y el control predictivo por matriz dinámica (DMC).

### Capítulo 3

En esta etapa se diseña el convertidor elevador CD/CD, se empieza con la selección adecuada de los semiconductores que lo conformarán, seguido de los cálculos necesarios como son: cálculo de la inductancia, capacitor y carga. Finalmente, se presenta el diseño y simulación de cada una de las estrategias de control aplicadas al convertidor y que han sido planteadas

para la presente investigación.

## **Capítulo 4**

En este capítulo se presentan los resultados de las pruebas aplicadas a los controladores, las que permitirán visualizar los requerimientos de desempeño exigidos como son: tiempo de respuesta, comportamiento ante perturbaciones, consumo computacional, etc. Finalmente, se presenta un estudio comparativo de los controladores aplicados al convertidor elevador CD/CD y las conclusiones finales de la investigación.

## Capítulo 2

### ESTADO DEL ARTE

#### 2.1. Antecedentes

Los convertidores conmutados de corriente directa a corriente directa (CD/CD) son circuitos electrónicos de potencia utilizados con el propósito de adaptar fuentes de energía continua no reguladas a determinados requerimientos de carga en diferentes aplicaciones (Erickson y Maksimovic, 2007). Durante los últimos 10 años las aplicaciones de estos convertidores han ido incrementándose debido a las necesidades de los sistemas eléctricos y de diferentes dispositivos electrónicos de disponer de reguladores de tensión eficientes (Torres Pinzón, 2012). Varias de estas aplicaciones van desde convertidores bidireccionales en autos híbridos, control de motores de tracción de autos eléctricos, tranvías, grúas marinas, montacargas y elevadores de mina, hasta equipos de fuente de energía renovable.

El control de convertidores de potencia conmutados CD/CD, es un área de investigación muy activa, tanto en la teoría de control automático como en la electrónica de potencia. Esto

debido esencialmente, a la actual demanda de este tipo de sistemas en diferentes aplicaciones industriales, donde se requiere convertir un voltaje fijo de una fuente de CD en un voltaje variable de suministro de CD (Velarde Rueda, 2010).

Cuando se hace referencia a “Control avanzado” se quiere indicar la aplicación de estrategias de control automático que trascienden a las que comúnmente se aplican en control de procesos, conocidos como control clásico. Existen diferentes formas de control automático que responden a este tipo de denominación de Control Avanzado. En general, el desarrollo de estos algoritmos de control avanzado implica una fuerte plataforma computacional debido a que no se los considera de “parámetros definidos” sino que responden a estrategias de “estructura optimizada”, ya que su estructura depende del sistema particular a controlar (Ortiz Guevara, 2011).

Los convertidores de potencia deben proporcionar un determinado nivel de tensión, bien sea en tareas de regulación o de seguimiento y deben ser capaces de rechazar alteraciones en la carga. Se ha estimado que el 90 % de la energía eléctrica se procesa a través de convertidores de potencia antes de su uso final (Banerjee y Verghese, 1999). Una de las cualidades más requeridas en estos dispositivos es su desempeño eficiente, el mismo que puede ser mejorado mediante el uso de dispositivos de conmutación, correctamente implementados, que permitan generar la salida deseada con un bajo consumo de potencia (Velasco y otros., 2010).

Existen varias técnicas para el control a frecuencia fija como son: control en modo corriente promediada, control por tensión, control en modo corriente pico, control por histéresis, etc. Estas difieren entre sí por el nivel de complejidad del diseño y el número de componentes que requieren para su implementación y que repercute en el costo (Vázquez Gutiérrez, 2011).

En la actualidad, existen diferentes investigaciones que reportan estructuras de control para convertidores de potencia donde utilizan normalmente controladores proporcionales integrales (PI) (Lin y otros., 2006; Qin y Kimball, 2014; Tsang y Chan, 2005; Zhang y otros., 2016). Estas propuestas de control convencionales están basadas en la aplicación de técnicas clásicas de realimentación lineal, tras una fase previa de linealización alrededor de un punto de operación de las ecuaciones dinámicas no lineales que modelan el comportamiento del convertidor. Esta aproximación restringe considerablemente las capacidades dinámicas de aquellos sistemas conmutados de conversión de potencia (Alarcón Cot, 2000).

La disminución de costos de plataformas digitales de alto desempeño ha acelerado el uso de algoritmos de control avanzado, lo que muestra la facilidad de programación en dispositivos digitales y las mejoras en especificaciones de estabilidad, robustez y frecuencia fija de conmutación. Esta última característica permite filtrar de mejor forma el ruido de alta frecuencia inherente a los convertidores de potencia (Liu y Sen, 2005).

El trabajar con sistemas altamente no lineales se ha convertido en todo un reto para los ingenieros de diseño, ya que las técnicas tradicionales parten del modelo idealizado del convertidor y fallan cuando se presentan variaciones en el circuito real. Es por ello que en los últimos años se ha recurrido a la inteligencia artificial como herramienta que permita controlar la planta frente a cambios tanto en el voltaje de entrada como en la carga, al entregar sobrepasos de voltaje pequeños, despreciable error de estado estacionario y un muy bajo tiempo de respuesta (Khoshooei y Moghani, 2004).

## 2.2. Sistemas No Lineales

En la actualidad la mayor parte de sistemas o fenómenos físicos poseen características no lineales. Sin embargo se debe tener en claro cuando un sistema puede o no considerarse lineal. Cuando las magnitudes de las señales dentro de un sistema de control están limitadas en intervalos en los cuales los componentes del sistema exhiben una característica lineal, es decir, se puede aplicar el principio de superposición; el sistema es esencialmente lineal. Sin embargo si las magnitudes de las señales se extienden más allá del intervalo lineal, el sistema no se debe considerar como lineal (Pérez y otros., 2008). Además, existen algunas aplicaciones de sistemas de control que han sido manipulados intencionalmente con características de no linealidad para mejorar el desempeño de sus sistemas, como por ejemplo: un controlador de tipo si-no que ha sido empleado en el control de naves espaciales para la mejora de motores de reacción para controlar la altitud del mismo (Pérez y otros., 2008).

Debido a su sencillez y que pueden representar el comportamiento de un sistema de manera más precisa, los modelos matemáticos lineales han sido usados durante mucho tiempo tanto en la teoría como en la práctica; sin embargo, actualmente la exigencia de trabajar con sistemas de características no lineales crea la oportunidad de continuar con investigaciones y aportar en el desarrollo de herramientas de sistemas no lineales.

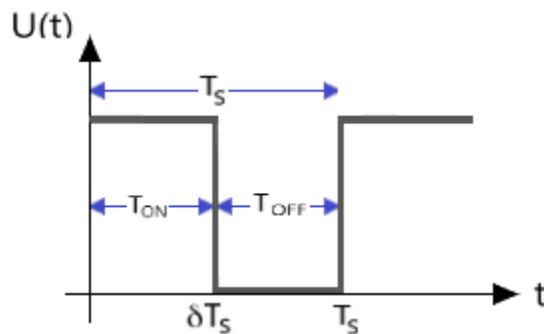
Un tipo de sistema no lineal son los sistemas de estructura variable, donde existe un cambio estructural de sistema, debido a un cambio en el conjunto de ecuaciones entre las variables dependientes del tiempo. Una de las causas que producen este cambio brusco, y que es la de interés para la presente investigación, es la activación automática de uno o más

conmutadores que conforman el sistema.

## 2.3. Convertidor Boost

El convertidor *boost* conocido como convertidor elevador de tensión hace uso de las propiedades del capacitor e inductor que conforman su circuito para elevar la corriente de la fuente de alimentación y usarla para la carga del condensador, obteniendo así un voltaje mayor en la carga con relación al de la fuente; esto gracias a la características de los elementos almacenadores de energía (Valderrama y otros., 2013).

El convertidor conmutado, como su nombre lo indica, se basa en la conmutación ON-OFF, a este periodo de conmutación se lo denomina  $T_S$ . Además, se conoce como relación de trabajo  $\delta$ , a la relación entre el tiempo  $T_{ON}$  y el periodo  $T_S$ , para su mejor comprensión véase la figura 1.



**Figura 1:** Señal de conmutación vs tiempo de conmutación

La figura 1 muestra el valor asignado a la acción de conmutación  $u$ , es decir, depende de la posición del conmutador. Donde  $u = 1$  en el tiempo  $T_{ON}$  y  $u = 0$  en el tiempo  $T_{OFF}$ .

El comportamiento dinámico del convertidor *boost* tanto para ON ( $u=1$ ) y OFF ( $u=0$ )

es descrito mediante las siguientes ecuaciones.

Para  $0 \leq t \leq T_{ON}$

$$\dot{x} = A_1 \times x + B_1 \cdot E \quad (2.1)$$

Para  $T_{ON} \leq t \leq T_S$

$$\dot{x} = A_2 \times x + B_2 \cdot E \quad (2.2)$$

Donde:

$x$ , representa el vector de  $n$  variables de estado.

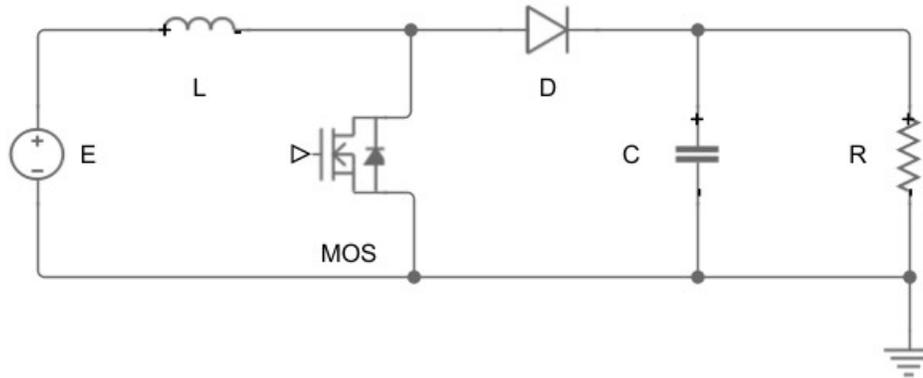
$A_1$ ,  $A_2$ ,  $B_1$  y  $B_2$  son las matrices descriptivas del circuito en cada topología.

$E$ , es la fuente de alimentación

Estos convertidores son utilizados para la regulación de tensión, conversión de potencia CD/CD y corrección activa del factor de potencia en fuentes conmutadas de potencia. Se distinguen dos estados: transitorio y estacionario (Martínez Sarmiento y Castiblanco Ortíz, 2009).

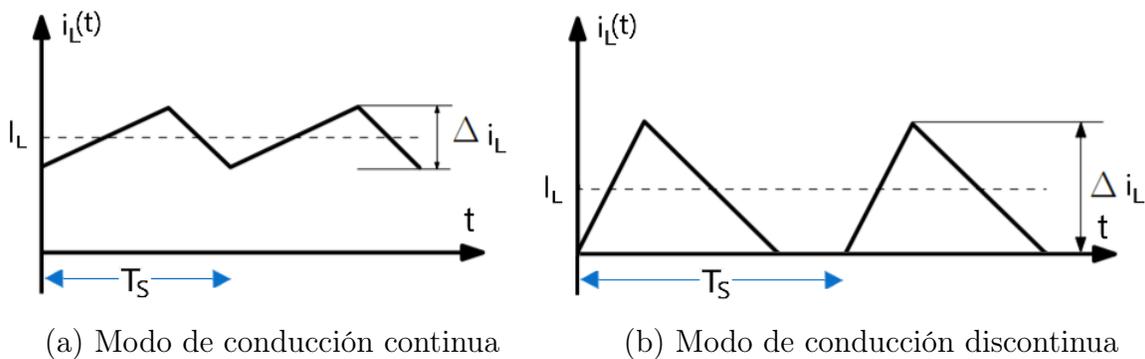
### 2.3.1. Modelo Matemático del Convertidor *Boost*

Para el análisis y obtención del modelo matemático del convertidor *boost* se hace uso de la topología general del convertidor que se presenta en la figura 2.



**Figura 2:** Esquema Convertidor Elevador CD/CD

Para los convertidores conmutados existen dos posibles modos de funcionamiento, los que dependen de la continuidad de la corriente a través del inductor, en el periodo  $T_S$ . El modo de conducción continua se presenta cuando dicha corriente en estado estable del convertidor es diferente de cero. Mientras el modo de conducción discontinua se presenta cuando la corriente en el inductor llega a cero (Erickson y Maksimovic, 2007). Ambos modos son presentados en la figura 3.

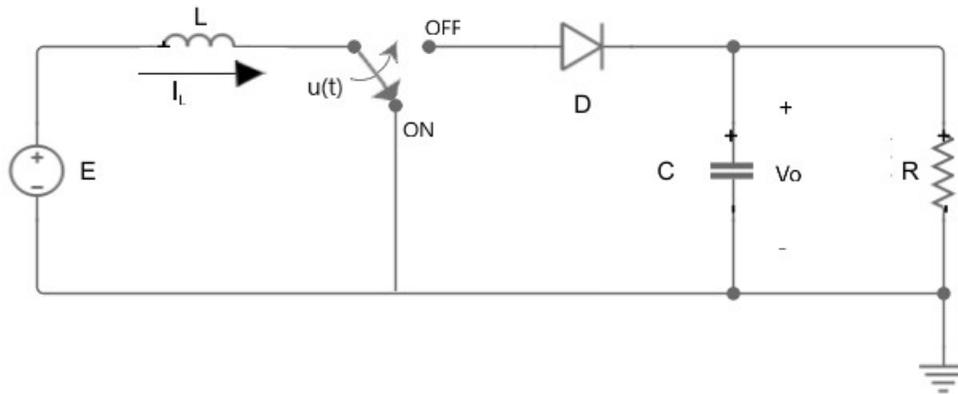


**Figura 3:** Modo de conducción de un convertidor CD/CD, (Torres Pinzón, 2012).

Para la presente investigación se trabajará en el modo de conducción continua, requiriendo toda la energía almacenada en la bobina. Por ello no se considera el modo de conducción

discontinua, sin embargo se toma en cuenta el mínimo valor de inductancia para no entrar en modo de conducción discontinua (Salazar Calahorrano, 2013).

Para el análisis se consideran a los elementos como ideales, es decir, sin pérdidas en los mismos. Además en los elementos de conmutación, que son el diodo y el transistor, se descartan los efectos inductivos y capacitivos, obteniendo así un análisis menos complejo.



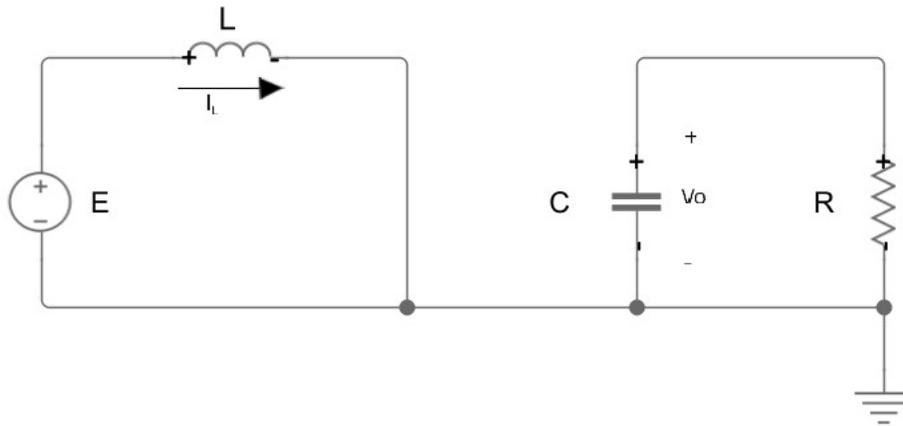
*Figura 4:* Convertidor Elevador CD/CD

En modo de conducción continua existen dos posibles estados de funcionamiento, como se observa en la figura 4, esto debido a la posición del conmutador que opera de acuerdo a un ciclo de trabajo  $\delta$ . A continuación se presenta el análisis de los estados ON y OFF.

#### ■ ESTADO ON ( $u=1$ )

En este estado el transistor conduce y el diodo se encuentra en estado de no conducción. Lo cual permite que la fuente  $E$  alimente únicamente al inductor  $L$ , mientras que el voltaje en el capacitor es el mismo que en la carga. Véase en la figura 5.

Se establecen las ecuaciones de Kirchoff para cada una de las mallas formadas. Al expresar las ecuaciones en función del voltaje en el inductor y la corriente en el capacitor, entonces se



*Figura 5:* Convertidor Elevador en estado ON

obtiene:

$$L \frac{d}{dt} i_L = E \quad (2.3)$$

$$C \frac{d}{dt} v_o = -\frac{v_o}{R} \quad (2.4)$$

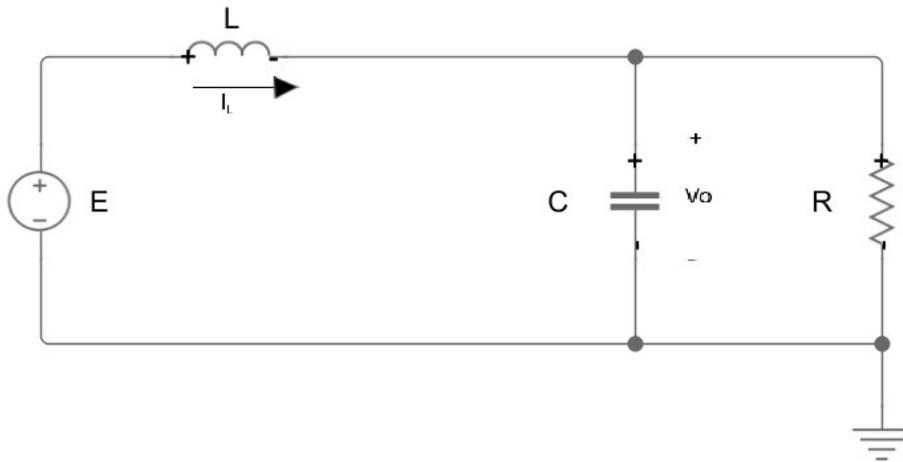
#### ■ ESTADO OFF ( $u=0$ )

En este estado el transistor no conduce y la energía almacenada en el inductor fuerza la conducción en el diodo. Lo que permite que el inductor se cargue con la tensión  $E - v_o$ .

Véase en la figura 6.

Se establecen las ecuaciones de Kirchoff para cada malla y se expresan las ecuaciones en función del voltaje en el inductor y la corriente en el capacitor, entonces se obtiene:

$$L \frac{d}{dt} i_L = E - v_o \quad (2.5)$$



**Figura 6:** Convertidor Elevador en estado OFF

$$C \frac{d}{dt} v_o = i_L - \frac{v_o}{R} \quad (2.6)$$

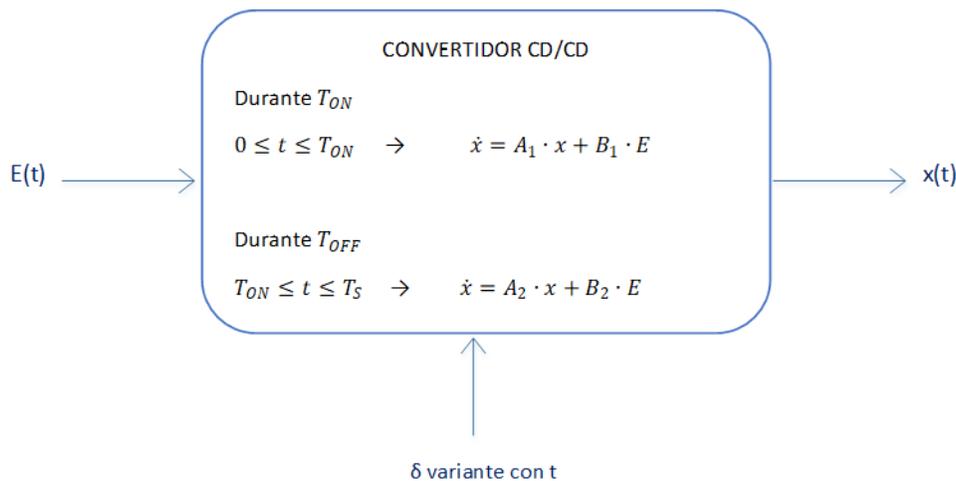
Como se ha explicado previamente el trabajar con este tipo de sistemas, que poseen uno o varios conmutadores, se habla de un sistema de estructura variable. Por lo que se pueden plantear las siguientes ecuaciones que describen al convertidor en los dos posibles estados de funcionamiento.

$$\frac{d}{dt} i_L = -(1 - u) \cdot \frac{v_o}{L} + \frac{E}{L} \quad (2.7)$$

$$\frac{d}{dt} v_o = -(1 - u) \cdot \frac{v_o}{R \cdot C} + \frac{i_L}{C} \quad (2.8)$$

### 2.3.2. Modelo Promediado del Convertidor *Boost* en el Espacio de Estados

El modelo promediado permite aproximar la evolución de las variables en cada intervalo de conmutación. El convertidor *boost* es un convertidor conmutado, es por ello que mediante el modelado promediado se puede aproximar el comportamiento real del convertidor en el espacio de estados (Velarde Rueda, 2010).



**Figura 7:** Formulación Convertidor CD/CD en el Espacio de Estados

Para la dinámica del convertidor descrita por las ecuaciones 2.1 y 2.2, cuando el conmutador se encuentra abierto durante el tiempo  $\delta T_S$  y cerrado durante el tiempo  $(1 - \delta)T_S$ ; la dinámica promediada del convertido será descrita por la siguiente ecuación:

$$\dot{x} = [A_1 \delta + A_2(1 - \delta)] \cdot x + [B_1 \delta + B_2(1 - \delta)] \cdot E \quad (2.9)$$

Se aproxima por un sistema cuya dinámica equivalente es:

$$\dot{x} = [A_e] \times x + [B_e] \cdot E \quad (2.10)$$

Donde

$$A_e = A_1 \delta + A_2 (1 - \delta)$$

$$B_e = B_1 \delta + B_2 (1 - \delta)$$

De acuerdo al análisis que se ha realizado en el enunciado anterior. Las matrices  $A_1$ ,  $A_2$ ,  $B_1$  y  $B_2$  quedan formadas de la siguiente manera:

$$A_1 = \begin{bmatrix} 0 & 0 \\ 0 & -\frac{1}{RC} \end{bmatrix}, A_2 = \begin{bmatrix} 0 & -\frac{1}{L} \\ \frac{1}{C} & -\frac{1}{RC} \end{bmatrix}, B_1 = B_2 = \begin{bmatrix} \frac{E}{L} \\ 0 \end{bmatrix}, x = \begin{bmatrix} i_L \\ v_o \end{bmatrix}$$

$$A_e = A_1 \delta + A_2 (1 - \delta) = \begin{bmatrix} 0 & -\frac{(1-\delta)}{L} \\ \frac{(1-\delta)}{C} & -\frac{1}{RC} \end{bmatrix}$$

$$B_e = B_1 \delta + B_2 (1 - \delta) = \begin{bmatrix} \frac{1}{L} \\ 0 \end{bmatrix}$$

El modelo promediado equivalente para el convertidor *boost* queda planteado de la siguiente manera:

$$\begin{bmatrix} \frac{d}{dt} i_L \\ \frac{d}{dt} v_o \end{bmatrix} = \begin{bmatrix} 0 & -\frac{(1-\delta)}{L} \\ \frac{(1-\delta)}{C} & -\frac{1}{RC} \end{bmatrix} \times \begin{bmatrix} i_L \\ v_o \end{bmatrix} + \begin{bmatrix} \frac{1}{L} \\ 0 \end{bmatrix} \cdot E \quad (2.11)$$

### 2.3.3. Función de Transferencia

La función de transferencia del convertidor *Boost* se obtiene mediante el modelo del convertidor en régimen estacionario.

Para representar de manera indicada el comportamiento dinámico del convertidor, las variables del modelo deben ser lo más exactas posibles a las variables reales (Cevallos Espinoza y Rojas Quishpe, 2018).

Entonces, la formulación incremental de las variables promedio se obtienen a partir de las variables en régimen estacionario y el incremento de la perturbación. A continuación se expresa dicha formulación:

$$\langle x \rangle = X + \hat{x} \quad (2.12)$$

$$\langle E \rangle = E + \hat{E} \quad (2.13)$$

$$\langle \delta \rangle = \delta + \hat{\delta} \quad (2.14)$$

Donde:  $\hat{x}$ ,  $\hat{E}$ , y  $\hat{\delta}$  representan el incremento de la perturbación de las variables de estado, tensión de entrada y señal de control respectivamente.

Para el modelo en régimen estacionario no deben existir perturbaciones, de forma que la ecuación queda planteada de la siguiente manera:

$$\hat{x} = \hat{E} = \hat{d} = 0 \quad (2.15)$$

$$A_e \triangleq A_e^o; \quad B_e \triangleq B_e^o \quad x \triangleq X \quad (2.16)$$

A partir de la ecuación 2.10 el sistema equivalente en régimen estacionario queda expresado:

$$\dot{x} + \hat{x} = \left\{ (D + \hat{d}) \cdot A_1 + (D + \hat{d}) \cdot A_2 \right\} \cdot (x + \hat{x}) + \left\{ (D + \hat{d}) \cdot B_1 + (D + \hat{d}) \cdot B_2 \right\} \cdot (E + \hat{E}) \quad (2.17)$$

Donde:

$$(D + \hat{d}) \cdot A_1 + (D + \hat{d}) \cdot A_2 \triangleq A_e^o \quad (2.18)$$

$$(D + \hat{d}) \cdot B_1 + (D + \hat{d}) \cdot B_2 \triangleq B_e^o \quad (2.19)$$

Al despejar  $X$  y reemplazar las condiciones de régimen estacionario de la ecuación 2.16 se encuentra el modelo del convertidor elevador *Boost*, dada por:

$$X = -(A_e^o)^{-1} \times B_e^o \cdot E \quad (2.20)$$

De acuerdo a la ecuación 2.11 se puede expresa  $A_e^o$  y  $B_e^o$  . Las mismas que son reemplazadas en la ecuación 2.20.

$$(A_e^o) = \begin{bmatrix} -\frac{L}{(1-\delta)^2 R} & -\frac{C}{(1-\delta)} \\ -\frac{L}{(1-\delta)} & 0 \end{bmatrix} \quad B_e^o = \begin{bmatrix} \frac{D}{L} \\ 0 \end{bmatrix} \quad (2.21)$$

$$X = \begin{bmatrix} i_L \\ v_o \end{bmatrix} = - \begin{bmatrix} -\frac{L}{(1-\delta)^2 R} & -\frac{C}{(1-\delta)} \\ -\frac{L}{(1-\delta)} & 0 \end{bmatrix} \times \begin{bmatrix} \frac{D}{L} \\ 0 \end{bmatrix} \cdot E$$

$$X = \begin{bmatrix} \frac{E}{(1-\delta)^2 \cdot R} \\ \frac{E}{(1-\delta)} \end{bmatrix} \quad (2.22)$$

Para encontrar la función de transferencia del convertidor se transforma las variables de estado al dominio de la frecuencia y se despeja  $\hat{x}(s)$  (Erickson y Maksimovic, 2007).

$$\hat{x} = \hat{X}(s); \quad \hat{E} = \hat{E}(s); \quad \hat{\delta} = \hat{\delta}(s) \quad (2.23)$$

$$\hat{x}(s) = [s^1 - A_e^o]^{-1} \cdot [B_e^o \cdot \hat{E}(s) + \{(A_1 - A_2) \cdot X + (B_1 - B_2) \cdot E\} \cdot \hat{\delta}(s)] \quad (2.24)$$

En el presente trabajo se desea controlar la tensión del capacitor, es por ello que a continuación se obtiene la función de transferencia de la tensión de salida en función a la tensión de entrada.

$$\frac{\hat{x}(s)}{\hat{E}(s)} \Big|_{\hat{\delta}(s)=0} = [s^1 - A_e^o]^{-1} \cdot B_e^o \quad (2.25)$$

$$[s^1 - A_e^o]^{-1} = \frac{1}{s^2 + \frac{s}{RC} + \frac{(1-\delta)^2}{LC}} \begin{bmatrix} s + \frac{1}{RC} & -\frac{(1-\delta)}{L} \\ \frac{(1-\delta)}{C} & s \end{bmatrix}$$

$$\begin{bmatrix} \hat{i}_L(s) \\ \hat{v}_o(s) \end{bmatrix} = \frac{1}{s^2 + \frac{s}{RC} + \frac{(1-\delta)^2}{LC}} \begin{bmatrix} s + \frac{1}{RC} & -\frac{(1-\delta)}{L} \\ \frac{(1-\delta)}{C} & s \end{bmatrix} \begin{bmatrix} \frac{1}{L} \\ 0 \end{bmatrix} \hat{E}(s)$$

Función de transferencia del convertidor *Boost*:

$$\frac{\hat{v}_o(s)}{\hat{E}(s)} = \frac{(1-\delta)}{LC} \cdot \frac{1}{s^2 + \frac{s}{RC} + \frac{(1-\delta)^2}{LC}} \quad (2.26)$$

## 2.4. Estrategias de Control Avanzado

Dentro de las industrias y en varios procesos se ha optado por el uso de estrategias de control clásicas basadas en controladores PID (Proporciona, integral y derivativo); esto debido a su gran desempeño y mejoras en el tiempo de respuesta, costo de implementación, estabilidad, etc.

Sin embargo, existen varios procesos con dinámicas más complejas que requieren el uso de técnicas de control avanzado para alcanzar las prestaciones de funcionamiento deseadas, es por ello que existen diferentes estrategias de control automático que ofrecen solución a estas dificultades.

El control avanzado es la integración de varios elementos de ingeniería de control, inge-

nería de procesos, ingeniería en instrumentación e ingeniería de sistemas. Esta unión permite la implementación de diferentes técnicas de control que mejoran el desempeño de los procesos en ámbitos como: flexibilidad en la producción, aspectos económicos para elegir el mejor sistema de control, mayor exigencia de control y calidad de control en procesos (Barrionuevo Grijalva y otros., 2013).

Las estrategias de control avanzado mas relevantes son:

- Control basado en redes neuronales.
- Control de lógica difusa *fuzzy*.
- Control adaptativo.
- Control predictivo
- Control robusto
- Control por lazo en cascada, entre otros.

En las siguientes secciones se explica a detalle las estrategias de control que serán utilizadas en el presente trabajo, como son: el control basado en redes neuronales y el control predictivo por matriz dinámica.

## 2.5. Control Basado en Redes Neuronales

Se conoce que los sistemas biológicos pueden llegar a realizar procesos complejos sin la necesidad de usar operaciones complicadas, estos sistemas son capaces de aprender gradual-

mente con el tiempo y esta capacidad de aprendizaje es propia de las neuronas, las mismas que aprenden a través de estímulos externos (Nguyen y otros., 2002). Es por ello que dentro de la ingeniería se ha echo uso de esta propiedad para ser implementada en diferentes aplicaciones como por ejemplo: control de sistema de generación eólica (Martínez, 2015), control de una máquina procesadora de papel (Vásquez Choquehuanca, 2009), control de motores (Nevot Cercós, 2000), etc .

Las redes neuronales artificiales (RNA) se componen de elementos que se comportan de manera similar a sistemas neuronales biológicos por medio de modelos matemáticos recreados mediante mecanimos artificiales (Martínez, 2015). Se componen de neuronas, consideradas como componentes elementales de la red y además están conectadas entre sí. Su principal propiedad es la de ser un aproximador universal de funciones.

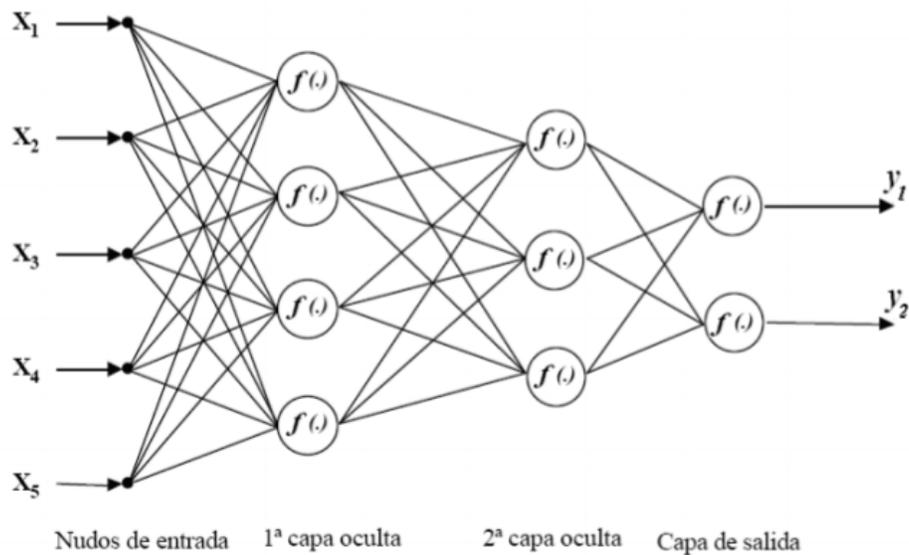
Su funcionamiento es similar al de un cerebro humano en los siguientes aspectos (Liang y otros., 2006):

- La información de la red es adquirida a través de un proceso denominado aprendizaje.
- La información es almacenada mediante la modificación del peso sináptico de las distintas uniones entre neuronas.
- Presenta características propias como la generalización y abstracción.

Las RNA al igual que los sistemas biológicos no son perfectos, puede ocurrir el caso en el que las neuronas mueran o se deterioren llegando a afectar al sistema de manera cuantitativa, más no cualitativa. Por esta razón las redes neuronales son consideradas muy adecuadas para

su uso en sistemas de control, identificación y reconocimiento de patrones (Nevot Cercós, 2000).

El funcionamiento de las RNA es simple, debido a que consisten en recibir en las entradas las salidas de las neuronas vecinas y calcular el valor de la salida (Hilera González y Martínez Hernando, 2000). Su estructura puede ser multicapa (figura 8), es decir, consiste de 3 tipos de capas: capa de entrada, capa oculta y capa de salida. Donde cada una de ellas puede estar conformada por una o mas neuronas.



**Figura 8:** Estructura de una red neuronal artificial multicapa  
Fuente: (Vásquez Choquehuanca, 2009).

- **Capa de entrada:** En esta capa se encuentran las neuronas de entrada, que a su vez son las entradas a la red. Las mismas que reciben las señales desde el entorno y provienen generalmente de una serie de tiempo con datos anteriores al que se quiere predecir.

- **Capa oculta:** Las neuronas que componen esta capa son aquellas cuyas entradas y salidas se encuentran dentro del sistema, es decir, no tienen contacto con el exterior. Para la elección del número de neuronas que la conforman no existe una regla definida, se deben realizar pruebas y elegir el número que tenga el mejor comportamiento (Rocha y Escorcia, 2010).
- **Capa de salida:** En esta capa las neuronas son la salida de la red. Son las encargadas de enviar una señal correspondiente al valor futuro o estimado fuera de la red.

Las RNA pueden llegar a aprender de experiencias que son provistas como entradas o salidas, las mismas que pueden generalizar la experiencia aprendida y obtener la salida correcta cuando existen situaciones nuevas (Ouyang y Yeh, 2001).

Controlar un sistema siempre depende de la dinámica, es decir, los componentes que conforman al sistema. Sin embargo, llegar a expresar el comportamiento de todos los componentes en expresiones matemáticas puede llegar a ser muy complicado. Es por ello que varios de los controladores basados en redes neuronales no necesitan tener el modelo matemático del sistema a controlar (Vásquez Choquehuanca, 2009).

Existen dos formas de controlar un sistema:

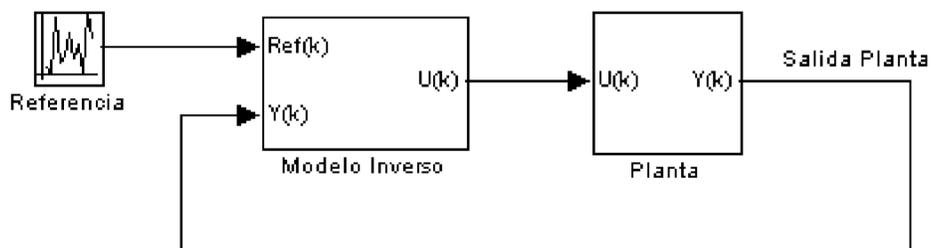
- **Sistema de control directo:** Este sistema de control lleva como controlador una red neuronal. Su implementación es sencilla mientras que el diseño y calibración son complicados. Entre los tipos de control directo se tiene: control por modelo interno, control directo inverso, linealización de retroalimentación, control óptimo y feedward con modelo inverso (Vásquez Choquehuanca, 2009).

- **Sistema de control indirecto:** Este diseño se basa en un modelo que usualmente es entrenado anticipadamente. La red neuronal es usada para modelar el sistema a ser controlado. Entre los tipos de control indirecto se puede mencionar los siguientes: control predictivo, control predictivo no lineal, varianza mínima y colocación de polos aproximado (Vásquez Choquehuanca, 2009).

### 2.5.1. Control Neuronal por Modelo Inverso

La técnica del control neuronal por modelo inverso busca cancelar la dinámica de la planta al colocar una red en cascada con ella, siendo esta red una aproximación matemática del inverso de la planta. Es así como se busca que la salida sea lo más parecida a la referencia (Norgaard y otros., 2000).

En (Rodríguez-Toro y otros., 2011) se muestran dos maneras de realizar un controlador neuronal por modelo inverso. En primera instancia se puede realizar un entrenamiento general, donde a partir de datos conocidos se encuentra el modelo inverso de la planta. En la figura 9 se puede observar como la red entrenada cancela la dinámica de la planta.



**Figura 9:** Esquema del Controlador por Modelo Inverso  
Fuente: (Vásquez Choquehuanca, 2009).

O a su vez se puede realizar un entrenamiento especializado, conocido como control adap-

tativo, donde el objetivo es minimizar el error entre la salida de la planta y la salida del modelo de referencia (Norgaard y otros., 2000).

Durante la etapa de entrenamiento, la salida de la planta es empleada como entrada de la RNA. La señal de control es comparada con la salida de la red neuronal y mediante este error se realiza el ajuste de los pesos a través del algoritmo de aprendizaje.

Según (Villaseñor-Aguilar y otros., 2011) el aprendizaje de la red depende de los datos de entrenamiento, entre mayor sean los datos, la red tendrá una mejor respuesta.

### ***Algoritmo de aprendizaje Levenberg-Marquardt (LM)***

Este método de aprendizaje muestra una modificación al método tradicional de *Newton*, fue sugerido por *Marquardt* en 1963 y posterior a ello por *Levenberg* en 1994. Surgue debido a las dificultades que presentó el método de *Newton*, cuando a lo largo del proceso iterativo en algún punto la matriz Jacobiana no tiene rango completo (Vivas, 2014).

Se aproxima la matriz Hessiana mediante la ecuación:

$$\nabla^2 E(w_k) \approx J(w_k)^T J(w_k) + \lambda_k I \quad (2.27)$$

Donde:

$\nabla^2 E(w_k)$ , es la gradiente del error.

$J(w_k)$ , es la matriz Jacobiana.

$\lambda_k$ , es el factor de amortiguamiento que asegura la positividad de la matriz Hessiana.

$I$ , es la matriz identidad.

Por lo tanto una iteración básica del método de *Gauss-Newton*, se expresa:

$$x_{k+1} = x_k - [J(x_k)^T J(x_k) + \lambda_k I]^{-1} J(x_k)^T R(x_k) \quad (2.28)$$

Cuando  $\lambda_k = 0$  la dirección de búsqueda es la de *Gauss-Newton* y cuando  $\lambda_k$  toma un valor grande, la dirección de descenso es paralela a la del máximo descenso. Es por ello que se puede decir que este método combina los métodos de descenso de gradiente y *Gauss-Newton* en una sola ecuación para estimar la actualización de los pesos en la RNA (*Rodriguez-Toro y otros., 2011*).

Se basa en el modelo de *Gauss-Newton* mostrado en la ecuación 2.29, donde se usa la estrategia de región de confianza para encontrar el punto  $x_{k+1}$  y resolver el problema de mínimos cuadrados lineales con restricciones.

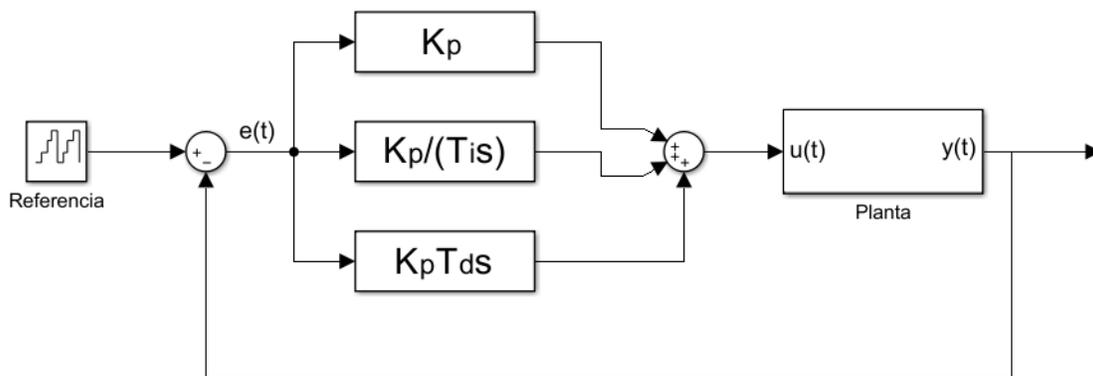
$$x_{k+1} = x_k - [J(x_k)^T J(x_k) + \lambda_k I]^{-1} J(x_k)^T R(x_k) \quad (2.29)$$

Se minimiza  $\frac{1}{2} \| R(x_k) + J(x_k)(x - x_k) \|_2^2$ ; sujeto a  $\| x - x_k \| \leq \delta_k$ .

Las propiedades de convergencia del método de *Levenberg-Marquardt* son similares a las del método de *Gauss-Newton* (*Vivas, 2014*). Entre las ventajas de este método es que está bien definido aún cuando la matriz  $J(x_k)$  no sea de rango completo, además suele ser más eficiente que el método clásico aunque requiere más memoria.

### 2.5.2. Control PID con Redes Neuronales

El controlador PID es usado generalmente en la industria, debido a la mejora que presenta en la respuesta dinámica de la planta y su reducción en el error en estado estacionario. Como se observa en la figura 10 el controlador PID se compone de la suma del controlador proporcional, controlador derivativo que mejora la respuesta transitoria y del controlador integral que reduce el error en estado estacionario (Subramanian y Kayalvizhi, 2015).



*Figura 10:* Diagrama esquemático del controlador PID

Su función de transferencia viene dada por:

$$K_p + \frac{K_i}{s} + K_d s = \frac{K_d s^2 + K_p s + K_i}{s} \quad (2.30)$$

El controlador PID funciona en un sistema de lazo cerrado, donde la señal de control  $u(t)$  queda expresada de la siguiente forma:

$$K_p e + K_i \int e dt + K_d \frac{de}{dt} \quad (2.31)$$

De este modo la señal de control  $u(t)$  proporcionará la nueva salida de la planta  $y(t)$ . El sensor captura la nueva salida para obtener la nueva señal de error  $e(t)$  y así el controlador toma este valor como señal de entrada para calcular las ganancias  $K_p$ ,  $K_i$  y  $K_d$  (Subramanian y Kayalvizhi, 2015).

El controlador PID es el algoritmo más común, puede ser implementado de varias maneras y su estudio puede ser abordado de diferentes puntos de vista (Millán y otros., 2012).

Cuando se busca mejorar el controlador PID una opción a ser considerada es usar un controlador neuronal PID.

En (Quintero y otros., 2013) se muestra la comparación de cuatro controladores basados en PID para el control de velocidad en motores de corriente alterna. Entre las diferentes estrategias de control se presenta: controlador PI, controlador PID, controlador neuronal PID y controlador neuronal predictivo. Donde el que tiene la mejor respuesta es el controlador neuronal PID, no se presenta error y alcanza una respuesta mínima al punto de referencia.

En (Millán y otros., 2012) se demuestra que una red neuronal es capaz de emular el comportamiento de un controlador PID para el control de motores de corriente continua en robots móviles diferenciales. Se demostró que la red neuronal funciona muy bien en seguimiento de trayectorias rectilíneas como en curvilíneas.

El controlador neuronal PID busca reemplazar el bloque PID por una red neuronal, donde se busca una aproximación de la respuesta del regulador. Para su diseño es necesario que se establezca el conjunto de entrenamiento, es decir, los datos representativos del entorno en el que funciona (Quintero y otros., 2013).

## 2.6. Control Predictivo basado en Modelo

El control predictivo basado en modelo (MPC) por sus siglas en inglés *Model Predictive Control* se considera un controlador óptimo, debido a que sus actuaciones responden de acuerdo a la optimización de un criterio o función objetivo, la misma que se relaciona con el comportamiento futuro del sistema (Marruedo, 2002).

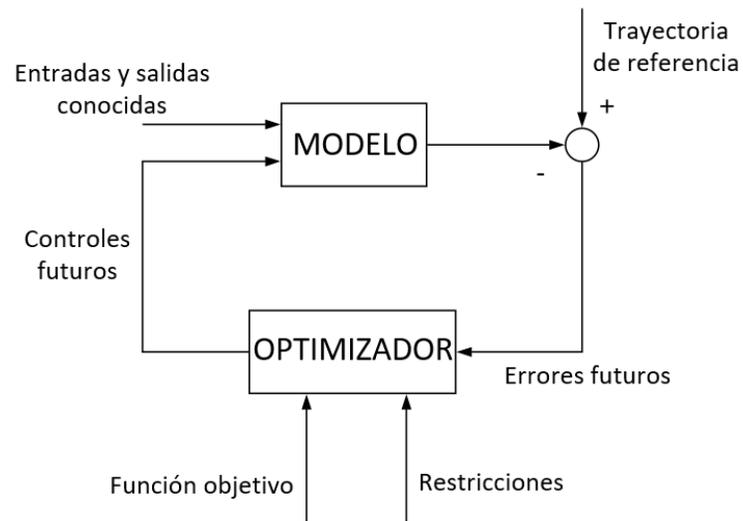
El MPC es un tipo de control de naturaleza abierta, que ha sido considerado como una herramienta poderosa para el control de procesos tecnológicos industriales, pues su estructura interna permite predecir el desempeño futuro de las variaciones del sistema y sus señales de control (Rodríguez y Téllez, 2002).

La estructura básica del MPC se presenta en la figura 11, donde se puede establecer que el modelo predice la evolución de la salida del proceso a partir de las entradas y salidas conocidas, además la acción de control futura se obtiene con el optimizador, que considera la función objetivo y las restricciones (Camacho y Bordons, 2004).

Entre las ventajas más representativas de esta estrategia de control es su formulación abierta, ya que permite incorporar diferentes modelos de predicción: lineales, no lineales, multivariables y monovariables (Marruedo, 2002). La formulación del control predictivo consta de los siguientes elementos: el uso explícito de un modelo de predicción, optimización de una función objetivo y la obtención de la ley de control (estrategia de horizonte deslizante) (Cueli, 2005).

El MPC se fundamenta en los siguientes criterios:

- Se hace uso del modelo matemático del sistema para predecir el futuro de las variables



**Figura 11:** Estructura básica del MPC  
Fuente: (Camacho y Alba, 2013).

a ser controladas, esto sobre el horizonte de predicción.

- Imposición de una estrategia de control para el cálculo de las variables manipuladas, donde se optimiza la función objetivo.
- Establecer la trayectoria actual o futura para las variables controladas del proceso.
- En la obtención del control se aplica a la primera señal de control en cada instante y se desecha las demás, se repiten los cálculos en cada instante de muestreo (Salcedo y Correa, 2008).

De acuerdo a lo explicado anteriormente el MPC requiere de un modelo matemático cercano del sistema, sin embargo esto llega a ser un inconveniente ya que no en todas las plantas es sencillo obtener su modelo. Otra de las desventajas es el requerimiento de un elevado grado de computación para la solución de ciertos algoritmos. La eficiencia del MPC depende del

grado de diferencia entre la planta real y el nivel de precisión utilizado en la predicción que es dependiente del modelo (Salcedo y Correa, 2008).

El control predictivo ha tenido una gran evolución en el campo industrial más que en la comunidad investigadora. La necesidad de las industrias de controlar procesos en puntos de operación límites, las llevó a la creación de controladores predictivos basados en modelos sencillos. A continuación se presentan algunas formulaciones destacadas:

- ***MPHC (Model Predictive Heuristic Control)***: Utiliza como modelo de predicción la respuesta impulsional, función objetivo cuadrática, algoritmo de optimización heurístico y restricciones en las entradas y salidas. Fue propuesto por (Richalet y otros., 1978).
- ***DMC (Dynamic Matrix Control)***: Utiliza como modelo de predicción la respuesta ante escalón, función objetivo cuadrática penalizando el esfuerzo de control y no considera restricciones en las entradas y salidas. Este controlador se limita a plantas estables. Fue propuesto por (Cutler y Ramaker, 1980).
- ***QDMC (Quadratic Dynamic Matrix Control)***: Es el resultado de la extensión del DMC con restricciones de dos tipos: duras y blandas, las mismas que llegan a ser vulnerables en un periodo de tiempo. Fue propuesto por (Garcia y Morshedi, 1986).
- ***SMOC (Shell Multivariable Optimizing Control)***: Este controlador permite utilizar modelos en espacios de estados, incorpora observadores y modelos de perturbaciones. También tienen restricciones duras y blandas con niveles de prioridad. Fue propuesto por (Marquis y Broustail, 1988).

- **GPC (*Generalized Predictive Control*):** Este controlador utiliza como modelo de predicción la formulación CARIMA, que incorpora una perturbación modelada como ruido blanco. Tiene restricciones y resultados asociados a la estabilidad. Fue propuesto por (Clarke y otros., 1987).

Para la presente investigación se realiza el diseño y simulación del control predictivo por matriz dinámica DMC.

### 2.6.1. Control Predictivo por Matriz Dinámica

En la presente subsección se presenta la formulación del control predictivo por matriz dinámica, es decir, se expone el modelo de predicción, función objetivo y la obtención de la ley de control.

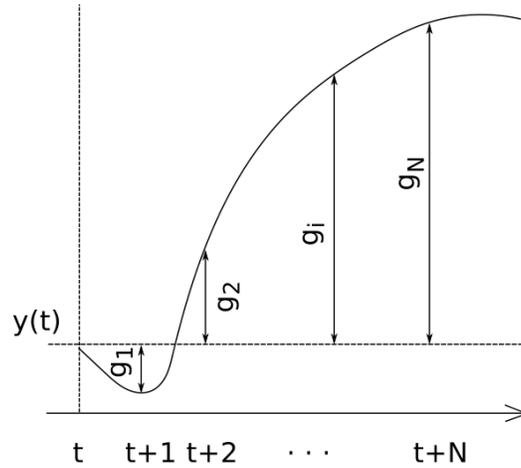
#### Modelo de predicción

El DMC utiliza como modelo de predicción la respuesta ante escalón de la planta véase figura 12, la misma que puede ser expresada en la ecuación 2.32. Además se debe mencionar que las perturbaciones son consideradas constantes a lo largo del horizonte de predicción (Camacho y Alba, 2013).

$$y(t) = \sum_{i=1}^{\infty} g_i \Delta u(t - i) \quad (2.32)$$

Donde:

$g_i$ , representa los valores muestreados ante la entrada escalón.



**Figura 12:** Respuesta ante escalón de la planta  
Fuente:(Camacho y Alba, 2013).

Por medio de la ecuación 2.32 los valores que se predicen a lo largo del horizonte de predicción se expresan como:

$$\hat{y}(t+k | t) = \sum_{i=1}^{\infty} g_i \Delta u(t+k-i) + \hat{n}(t+k | t) \quad (2.33)$$

Donde:

$\hat{n}$ , representa las perturbaciones futuras.

La ecuación 2.33 puede escribirse de la siguiente manera:

$$\hat{y}(t+k | t) = \sum_{i=1}^k g_i \Delta u(t+k-i) + \sum_{i=k+1}^{\infty} g_i \Delta u(t+k-i) + \hat{n}(t+k | t)$$

Se establece que las perturbaciones son constantes en el futuro, por ello:

$$\hat{n}(t+k | t) = y_m(t) - \hat{y}(t | t)$$

$$\hat{y}(t+k | t) = \sum_{i=1}^k g_i \Delta u(t+k-i) + \sum_{i=k+1}^{\infty} g_i \Delta u(t+k-i) + y_m(t) - \hat{y}(t | t)$$

Donde,  $\hat{y}(t | t)$  es igual a la ecuación 2.32. Por lo tanto la ecuación se puede expresar como la suma de la respuesta forzada y la respuesta libre:

$$\hat{y}(t+k | t) = \sum_{i=1}^k g_i \Delta u(t+k-i) + f(t+k) \quad (2.34)$$

Donde, la respuesta forzada es calculada con el modelo en respuesta al escalón y la respuesta libre  $f(t+k)$  detalla el comportamiento del estado actual y las acciones pasadas del proceso, es decir, no depende de los valores que tome la señal de control futura. Se expresa como:

$$f(t+k) = y_m(t) + \sum_{i=1}^{\infty} (g_{k+i} - g_i) \Delta u(t-i)$$

Cuando el proceso se establece despues de N periodos los valores de la respuesta escalonada  $g_i$  tienden a ser constantes, entonces se considera:

$$g_{k+i} - g_i \approx 0$$

Entonces la respuesta libre puede ser expresada como:

$$f(t+k) = y_m(t) + \sum_{i=1}^N (g_{k+i} - g_i) \Delta u(t-i) \quad (2.35)$$

Las predicciones serán calculadas a lo largo del horizonte de predicción ( $k = 1, 2, \dots, p$ ) y se consideran  $m$  como las acciones de control.

$$\begin{aligned}\hat{y}(t+1 | t) &= g_1 \Delta u(t) + f(t+1) \\ \hat{y}(t+2 | t) &= g_2 \Delta u(t) + g_1 \Delta u(t+1) + f(t+2) \\ \hat{y}(t+3 | t) &= g_3 \Delta u(t) + g_2 \Delta u(t+1) + g_1 \Delta u(t+2) + f(t+3) \\ &\vdots\end{aligned}$$

$$\hat{y}(t+p | t) = \sum_{i=p-m+1}^p g_i \Delta u(t+p-i) + f(t+p)$$

Se define la matriz dinámica  $G$  formada por los coeficientes de  $g_i$ .

$$G = \begin{bmatrix} g_1 & 0 & \cdots & 0 \\ g_2 & g_1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ g_m & g_{m-1} & \cdots & g_1 \\ \vdots & \vdots & \ddots & \vdots \\ g_p & g_{p-1} & \cdots & g_{p-m+1} \end{bmatrix} \quad (2.36)$$

Entonces la ecuación de predicción 2.34, puede ser expresada matricialmente como:

$$\hat{y} = Gu + f$$

Se observa que la matriz  $G$  se compone de  $m$  columnas y  $p$  filas. Además es claro identificar

que los coeficientes de la respuesta al escalón del sistema se desplazan en orden hacia abajo.

Donde:

$\hat{y}$ , es el vector de dimensión  $p$  que contiene las predicciones a lo largo del horizonte de predicción.

$u$ , es el vector de dimensión  $m$  que contiene los incrementos de control.

$f$ , es el vector de la respuesta libre.

Esta expresión relaciona las salidas futuras con los incrementos de control, por lo que será usada para el cálculo de la acción de control necesaria para lograr un comportamiento específico del sistema (Camacho y Alba, 2013).

La respuesta libre depende del vector de estados  $x(t)$  expresado como:

$$x(t)^T = [y_m(t) u(t-1) u(t-2) \dots u(t-N-1)]$$

y puede ser expresada como  $F x(t)$ . Entonces la salida predicha puede ser expresada como:

$$\hat{y} = Gu + Fx(t) \tag{2.37}$$

## Función objetivo

La función objetivo tiene como meta indicar el criterio a optimizar. La variable manipulada es seleccionada para minimizar los errores cuadráticos en el horizonte de predicción y se expresa como:

$$J = \sum_{j=1}^p [\hat{y}(t+j|t) - w(t+j|t)]^2 + \sum_{j=1}^m \lambda [\Delta u(t+j-1)] \quad (2.38)$$

Donde:

$\lambda$ , se considera un parámetro de sintonización que representa el esfuerzo de control y puede ser constante.

Si el controlador DMC conoce los valores futuros de referencia, se puede obtener una trayectoria de referencia  $w$ , que no es necesariamente conocida con el valor real de referencia  $r$  (Rodríguez, 2018).

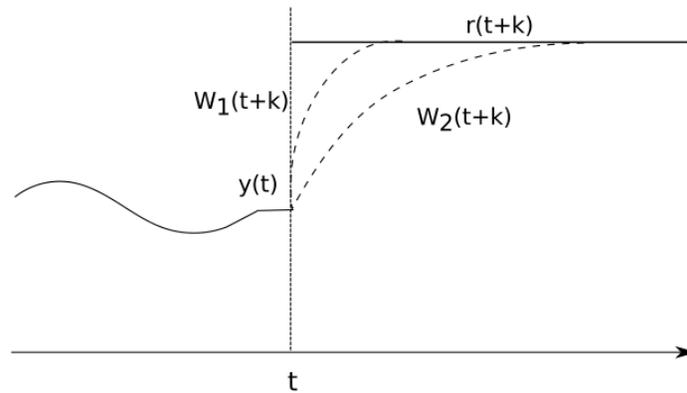
A través de un sistema de primer orden se puede aproximar el valor actual de la salida  $y(t)$  hacia la referencia conocida, como se muestra en la siguiente ecuación:

$$w(t+k) = \alpha w(t+k-1) + (1-\alpha)r(t+k), \quad k = 1 \dots p \quad (2.39)$$

La trayectoria  $w$  de la figura 13 muestra cuando la referencia  $r(t+k)$  es constante y para dos valores diferentes de  $\alpha$ . Los valores pequeños de este parámetro proporcionan un seguimiento rápido  $w_1$ , si se aumenta, la trayectoria de referencia se convierte en  $w_2$ , dando lugar a una respuesta más suave (Camacho y Alba, 2013).

Cuando no existen perturbaciones, la minimización de la función objetivo  $J$  queda expresada como:

$$J = ee^T + \lambda uu^T \quad (2.40)$$



**Figura 13:** Trayectoria de referencia  $w$   
Fuente:(Camacho y Alba, 2013).

Donde:

$e$ , representa el vector de errores futuros.

$u$ , representa el vector compuesto por los incrementos de control futuros.

### Obtención de la ley de control

La ley de control consiste en encontrar las variaciones de control que minimicen la función objetivo. Entonces, al derivar e igualar a cero la ecuación 2.38, queda expresada como:

$$u = (G^T G + \lambda I)^{-1} G^T (w - f)$$

Se toma solo el primer valor de control  $u$  en cada instante de tiempo de muestreo. Por lo tanto:

$$u = K (w - f)$$

Donde:

$K$ , es la primera fila de la matriz  $(G^T G + \lambda I)^{-1} G^T$ . Esto debido a que si no hay errores en el futuro, no existe variación en la señal de control. Sin embargo, si existen errores entonces existirá un incremento de la acción de control proporcional ( $K$ ) al error futuro (Camacho y Alba, 2013).

## Capítulo 3

# DISEÑO DEL CONVERTIDOR Y CONTROLADORES

### 3.1. Diseño del Convertidor Elevador CD/CD

Para el diseño del convertidor elevador se determinan los componentes principales que lo conforman. El dimensionamiento de los elementos pasivos como son el capacitor e inductor son de gran importancia, ya que su comportamiento es ideal. A continuación se plantean los datos de partida para el diseño del convertidor.

#### 3.1.1. Datos de partida para el diseño del convertidor

Los parámetros de partida para el convertidor elevador cuya potencia es igual a 100 W, son:

- Tensión de entrada,  $E = 20\text{V}$ .
- Tensión de salida,  $v_o = 100\text{ V}$ .

- Frecuencia de conmutación,  $f = 30\text{kHz}$ .
- Corriente en la carga,  $i_o = 1\text{ A}$ .
- Carga resistiva,  $R = 100\Omega$ .
- Rizado de tensión de salida,  $\Delta v_o \leq 1\%$ .

La relación entre la tensión de entrada y salida en el régimen de conducción continua se expresa en la siguiente ecuación:

$$v_o = E \cdot \frac{1}{(1 - \delta)} \quad (3.1)$$

Entonces, el ciclo de trabajo  $\delta$  queda expresado:

$$\delta = 1 - \frac{E}{v_o} \quad (3.2)$$

$$\delta = 0,8 \quad (3.3)$$

### 3.1.2. Cálculo de la inductancia

Para calcular el valor de la inductancia se debe considerar que opere justo entre el límite de conducción continua y discontinua. Se aplica la ecuación 3.4, que permite calcular el valor de inductancia mínima:

$$L_{min} = \frac{\delta \cdot R \cdot (1 - \delta)^2}{2 \cdot f} \quad (3.4)$$

Se obtiene:  $L_{min} = 53\mu H$ .

Para evitar que el régimen de operación entre en modo de conducción discontinua es necesario que el valor de la inductancia sea superior al  $L_{min}$  calculado en condiciones críticas. Entonces, se establece como valor de inductor  $L = 66,25\mu H$ , donde se añade 25 % del valor previamente calculado.

En el convertidor elevador, la corriente a través de la inductancia resulta ser igual a la corriente de entrada y esta representada por la ecuación 3.5. Además, se puede calcular la corriente mínima y máxima con las ecuaciones 3.6 y 3.7 respectivamente:

$$i_L = \frac{E}{(1 - \delta)^2 \cdot R} \quad (3.5)$$

$$i_{L,min} = \frac{E}{(1 - \delta)^2 \cdot R} + \frac{\delta \cdot E}{2 \cdot L \cdot f} \quad (3.6)$$

$$i_{L,max} = \frac{E}{(1 - \delta)^2 \cdot R} - \frac{\delta \cdot E}{2 \cdot L \cdot f} \quad (3.7)$$

Se obtiene  $i_{L,min} = 0,97 A$  y  $i_{L,max} = 9,02 A$ .

### 3.1.3. Cálculo del capacitor

La tensión de salida del convertidor elevador está expuesta a variaciones de energía a la frecuencia de conmutación. La siguiente ecuación permite el cálculo del capacitor.

$$C = \frac{\delta \cdot v_o}{R \cdot f \cdot \Delta v_o} \quad (3.8)$$

Se ha utilizado el criterio de diseño que permite una tensión de rizado de hasta el 1 % de la tensión nominal de salida (D'Alessio y otros., 2014). Donde se obtiene  $C = 27\mu F$

### 3.1.4. Simulación del convertidor

Para la simulación del convertidor elevador *boost* se ha considerado el modelo matemático obtenido en la subsección 2.3.1. El mismo que ha sido realizado en el programa MatLab<sup>®</sup> a través de su entorno de programación visual *Simulink*.

Los parámetros para la simulación del convertidor se presentan en la tabla 1:

**Tabla 1**

*Especificaciones de diseño*

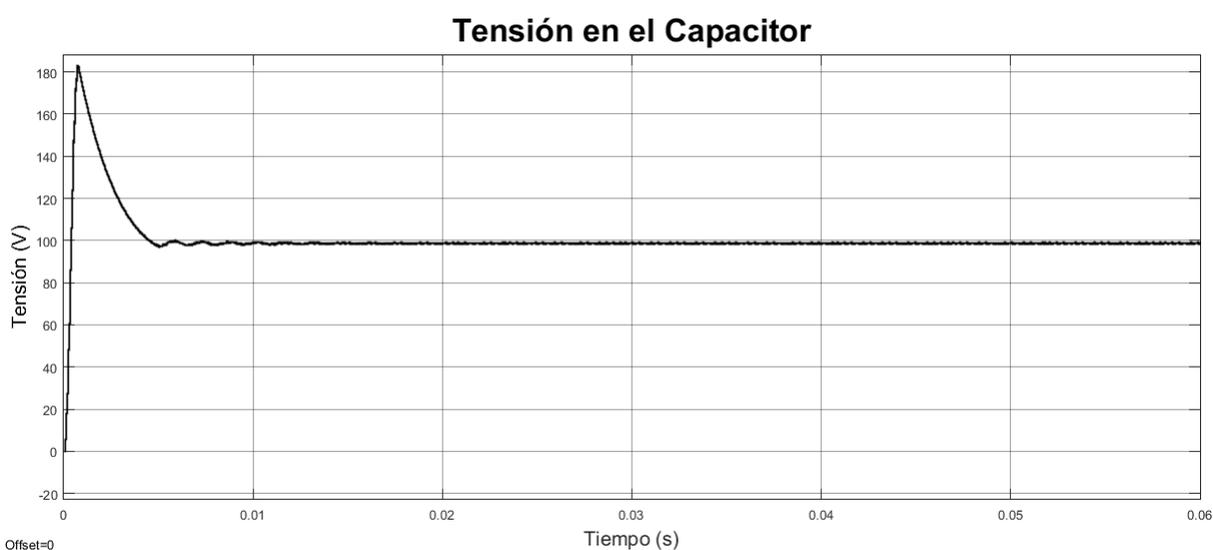
Parámetro	Valor
Tensión de entrada	20 V
Inductor	66,25 $\mu H$
Capacitor	27 $\mu F$
Carga	100 $\Omega$
Frecuencia de conmutación	30 KHz
Ciclo de trabajo	0.8
Tensión de salida	100 V

A continuación se muestra la respuesta del controlador *boost* sin control.

#### ▪ TENSIÓN EN EL CAPACITOR

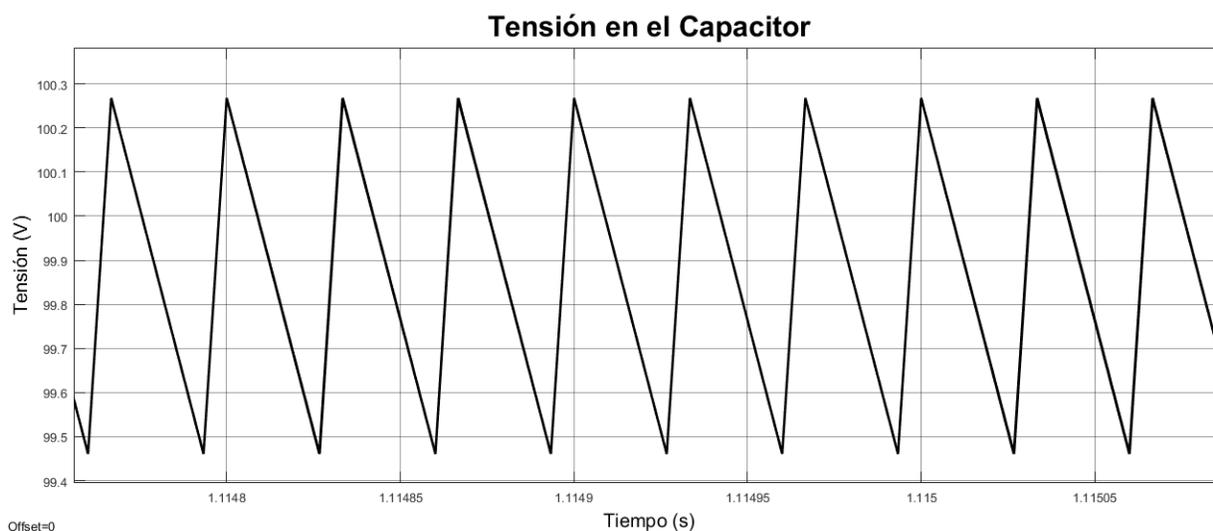
En la figura 14 se muestra la tensión en el capacitor, donde se puede observar que 100 V se

establecen aproximadamente en 0,015 s. Además, existe un sobreimpulso que sobrepasa la tensión de entrada llegando a casi 190 V.



*Figura 14:* Tensión en el capacitor

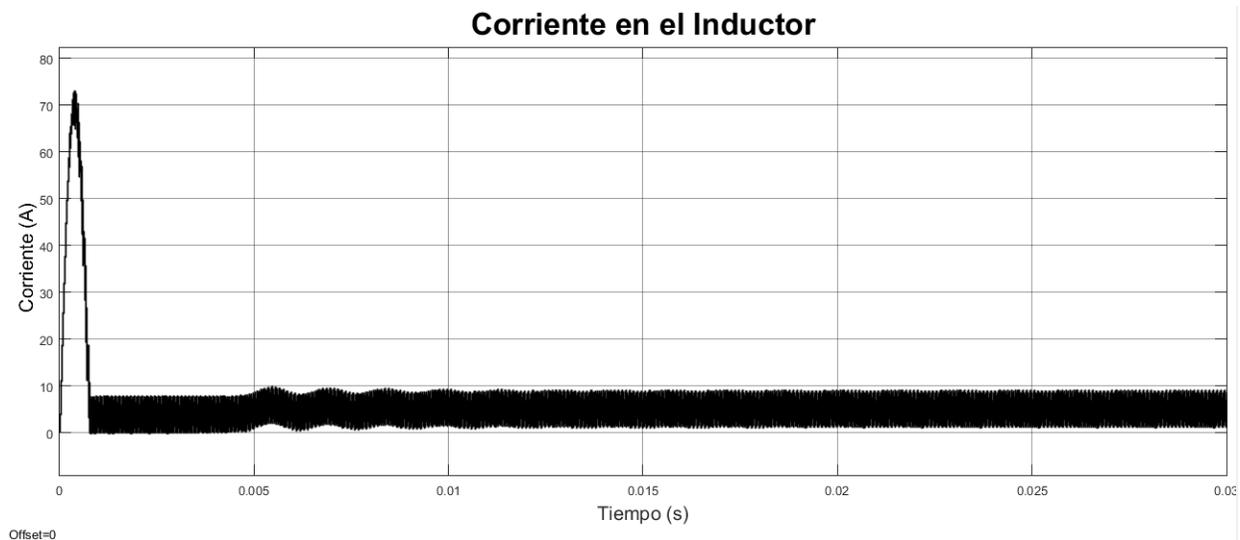
En la figura 15 se muestra una señal ampliada de la tensión del capacitor, donde se observa que el rizado obtenido es de 0,8%.



*Figura 15:* Señal ampliada de la tensión en el capacitor

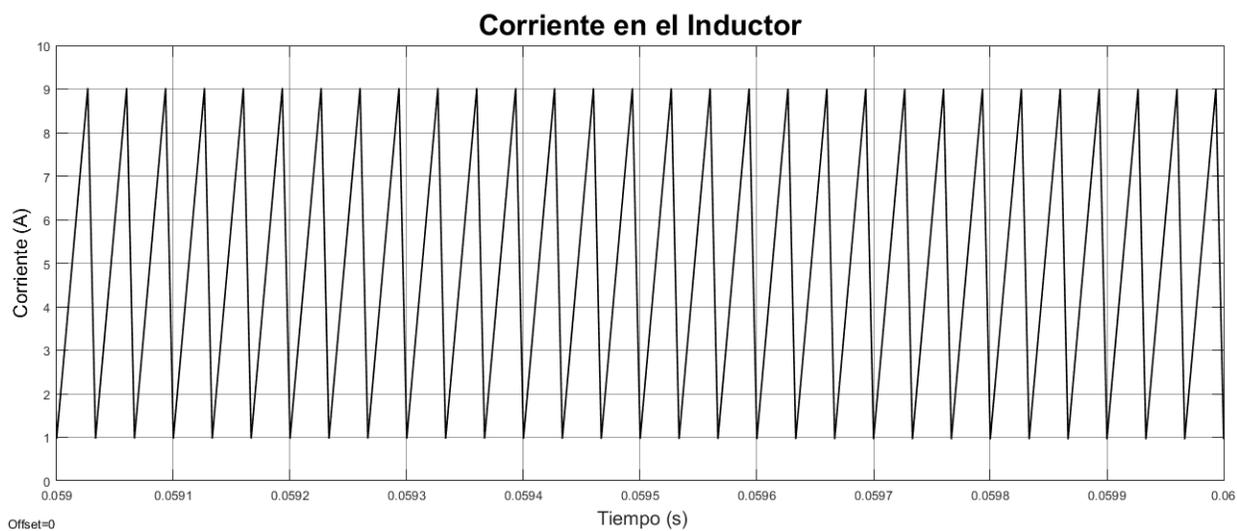
## ■ CORRIENTE EN EL INDUCTOR

En la figura 16 se muestra la gráfica de la corriente en el inductor, donde se observa que existe un pico positivo de casi 75 A.



*Figura 16:* Corriente en el inductor

En la figura 17 se observa que la corriente mínima y máxima en el inductor corresponden a los valores previamente obtenidos en el diseño 0,97 A y 9,01 A respectivamente. Además, se obtiene un valor medio aproximado de corriente de 5 A.



*Figura 17:* Señal ampliada de la corriente en el inductor

## 3.2. Control Neuronal por Modelo Inverso

Como se ha explicado en la sección anterior las RNA buscan ser un aproximador universal de funciones. Por su parte el control neuronal por modelo inverso es considerado la estrategia básica del control neuronal, busca controlar la planta interactuando con ella, sin necesidad de conocer de manera detallada las características de la misma.

### 3.2.1. Diseño del Controlador

Para el correcto diseño del controlador se han seguido los siguientes pasos:

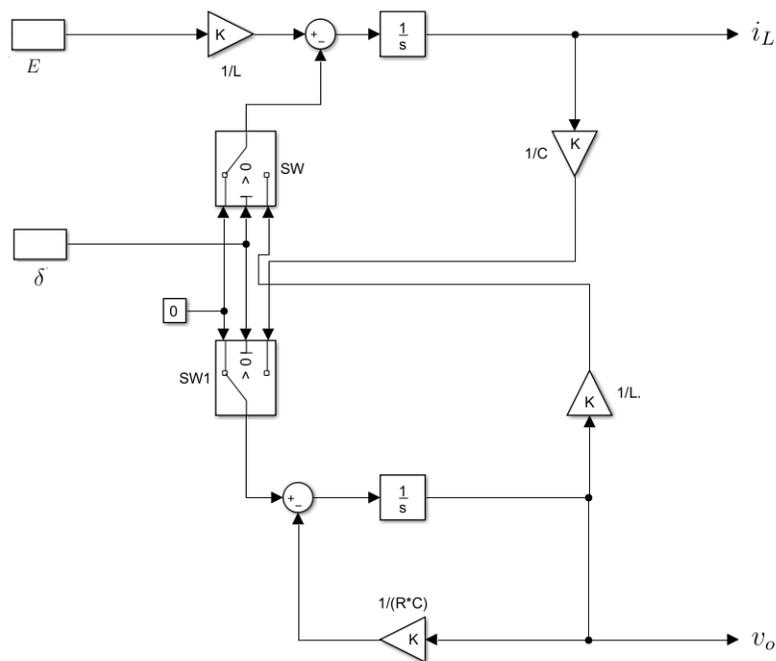
#### Modelación de la planta

El convertidor elevador *boost* como ha sido explicado anteriormente es un convertidor conmutado, cuenta con componentes como el capacitor e inductor. Para su análisis y diseño

se emplea el modelo promediado del convertidor *boost* en el espacio de estados como se puede revisar en la subsección 2.3.2.

### Identificación de la planta

Por medio de la ecuación 2.11 se ha establecido el modelo de la planta, realizado en el programa MatLab<sup>®</sup> a través de su entorno de programación visual *Simulink*, véase figura 18.



**Figura 18:** Modelo promediado del convertidor *Boost* en *Simulink*

Mediante el modelo se implementa en *Simulink* y con los siguientes parámetros:  $E = 20V$ ;  $\delta=0.8$ ;  $L = 66,25\mu H$ ;  $C = 27\mu F$ , se logra obtener el modelo de la planta.

## Diseño del controlador neuronal inverso

Para el diseño del controlador neuronal se han realizado tres scripts en MatLab<sup>®</sup>, los mismos que pueden ser revisados en los Anexos A, B y C.

En el primer programa llamado “Identificación\_Boost” se hace uso del modelo de la planta. Se ha inducido valores a la planta de lazo abierto, de esta manera se logra identificar el funcionamiento de la salida.

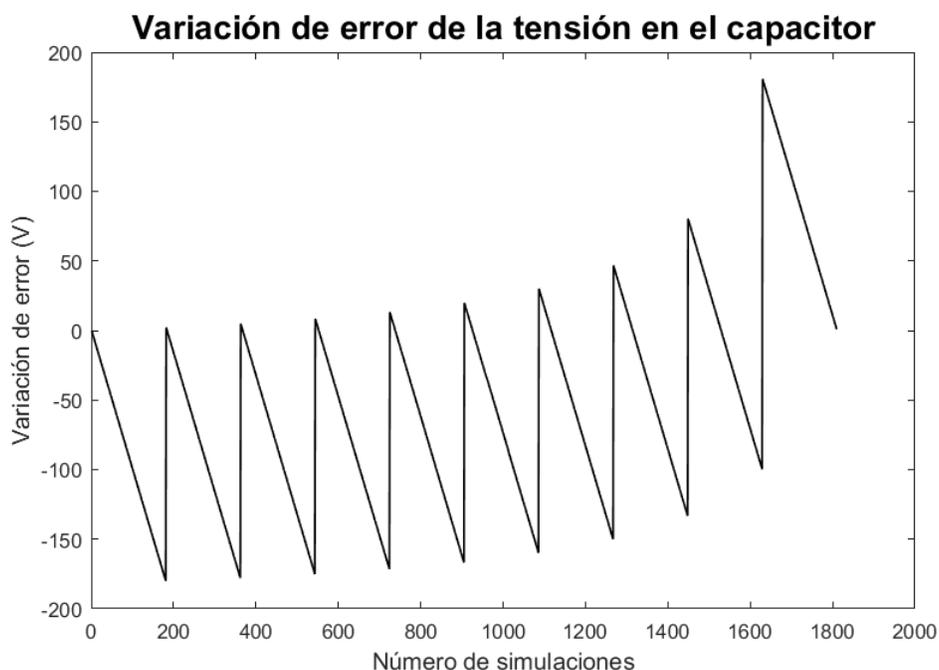
Se establecen los valores de entrada y condiciones iniciales de la planta, a continuación se guarda en un vector las posibles combinaciones de ambos.

Los valores de entrada son los valores de la tensión de referencia, que van desde los 20V hasta los 200V. Las condiciones iniciales son establecidas como los valores del ciclo de trabajo, es decir, desde 0% hasta 100%.

Finalmente se almacena como meta de entrenamiento las variaciones de error obtenidas a través de la simulación. El resultado de la variación de la tensión se observa en la siguiente figura:

El segundo programa llamado “Entrenamiento\_Red” se encarga de comprobar el funcionamiento del sistema. A través del entrenamiento de una red y mediante la variación de error de la tensión se verifica la funcionalidad de la planta.

En esta etapa se prueban diferentes arquitecturas de redes bajo la estrategia de prueba y error. Se entrenan tres redes que poseen tres capas. Tales redes consisten en una primera capa con función de transferencia “tansig”, la capa oculta y finalmente la capa de salida que posee una neurona con la función de transferencia “purelin”. Cabe mencionar que las pruebas



**Figura 19:** Variación de la tensión

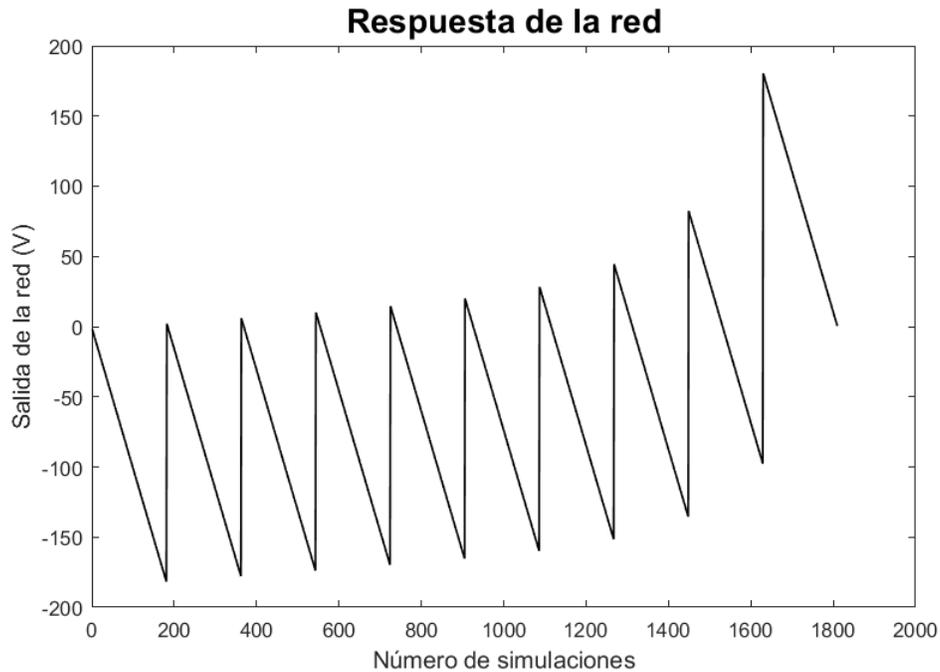
fueron efectuadas en base al número de neuronas pertenecientes a la capa oculta y se utilizan 10000 épocas para el entrenamiento.

Se realizaron pruebas para seis, 10 y 15 neuronas en la capa oculta. Donde se obtiene que la red con diez neuronas en la capa oculta es la de mejor respuesta. A continuación se puede observar la gráfica de la simulación de la red.

Como se ha observado las figuras 19 y 20 son similiares. Por esta razón el controlador neuronal inverso puede ser diseñado en base a dichos valores.

Finalmente, el tercer programa llamado “Controlador\_Neuronal\_Inverso” contiene el establecimiento de los parámetros de entrada, salida y meta de la red neuronal inversa. Seguida de la creación de la RNA, simulación y generación del bloque neuronal en *Simulink*.

De igual manera en esta etapa se realizan varios entrenamientos a diferentes redes, donde



*Figura 20:* Simulación de la red

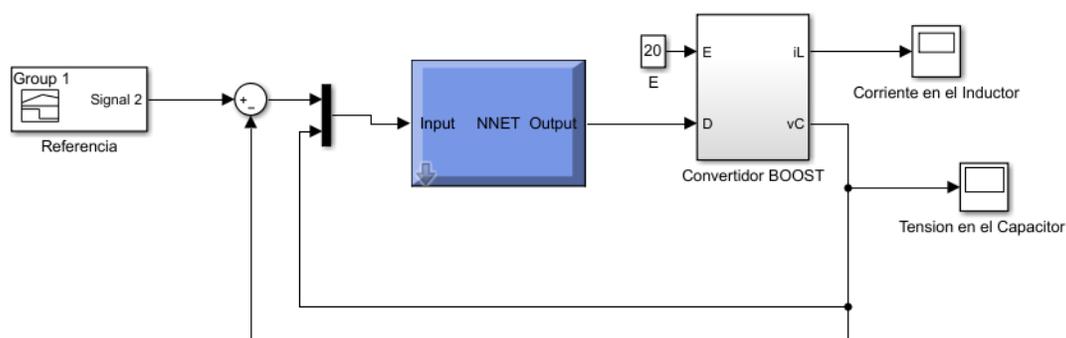
se ha tomado la arquitectura de tres capas y se han echo pruebas en base al número de neuronas en la capa oculta.

Se realizan pruebas para ocho, 10, 15 y 20 neuronas en la capa oculta, además se usa 30000 épocas para el entrenamiento.

En este caso la entrada a la red serán los datos de las condiciones iniciales y la variación de error obtenida en el programa "Identificación\_Boost. El *target* es la señal de control, es decir, el ciclo de trabajo.

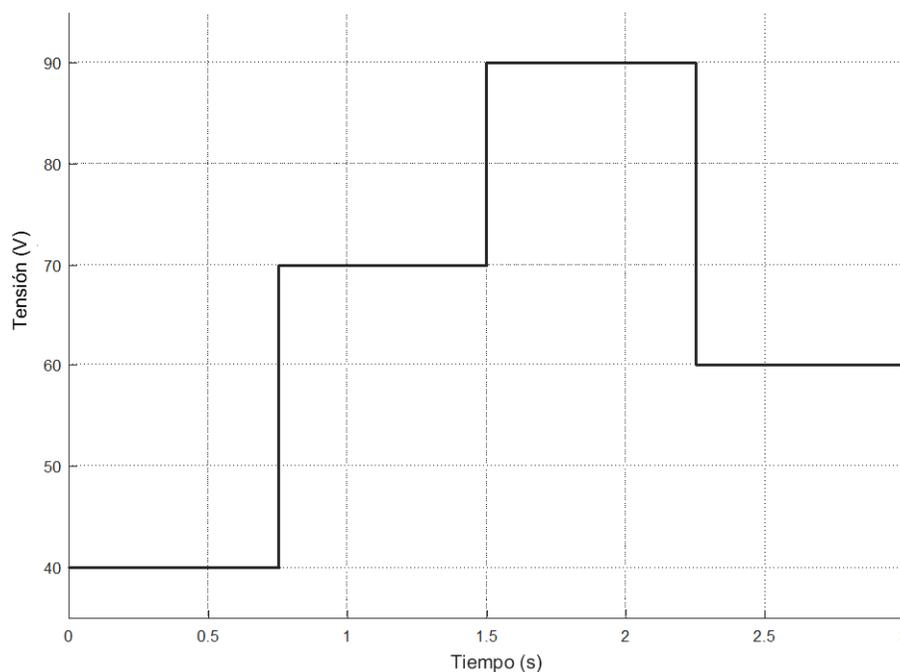
### 3.2.2. Simulación del Controlador

Para la simulación del controlador se ha usado el esquema presentado en la figura 9.



**Figura 21:** Controlador neuronal inverso en lazo cerrado

Como se puede observar en la figura 21, este esquema nos permite probar cada una de las redes neuronales que han sido entrenadas. Como señal de referencia se ha usado la señal mostrada en la figura 22.

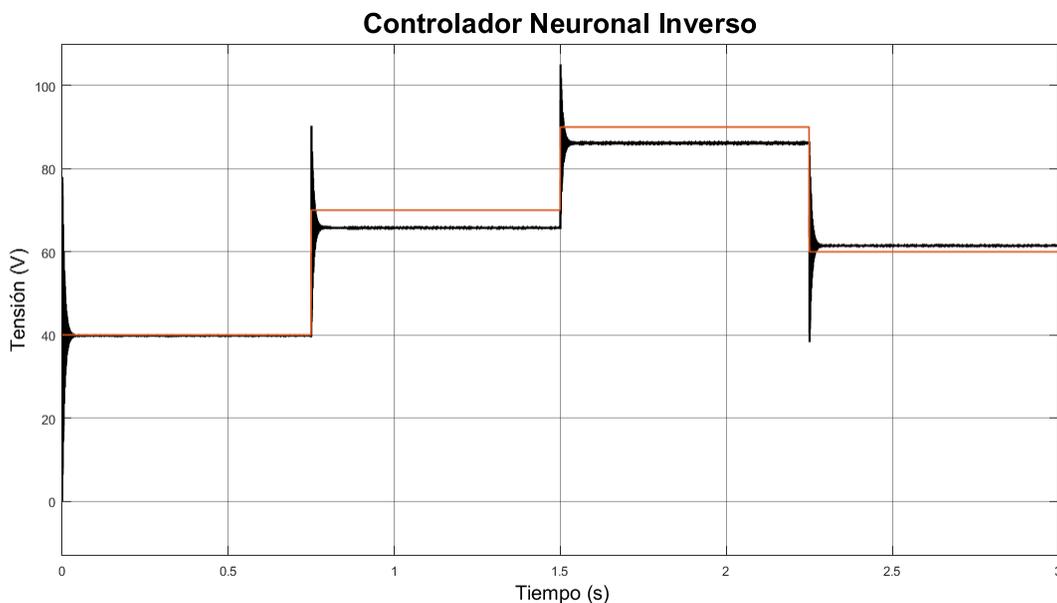


**Figura 22:** Señal de referencia

Se han realizado pruebas con ocho, 10, 15 y 20 neuronas en la capa oculta. A continuación

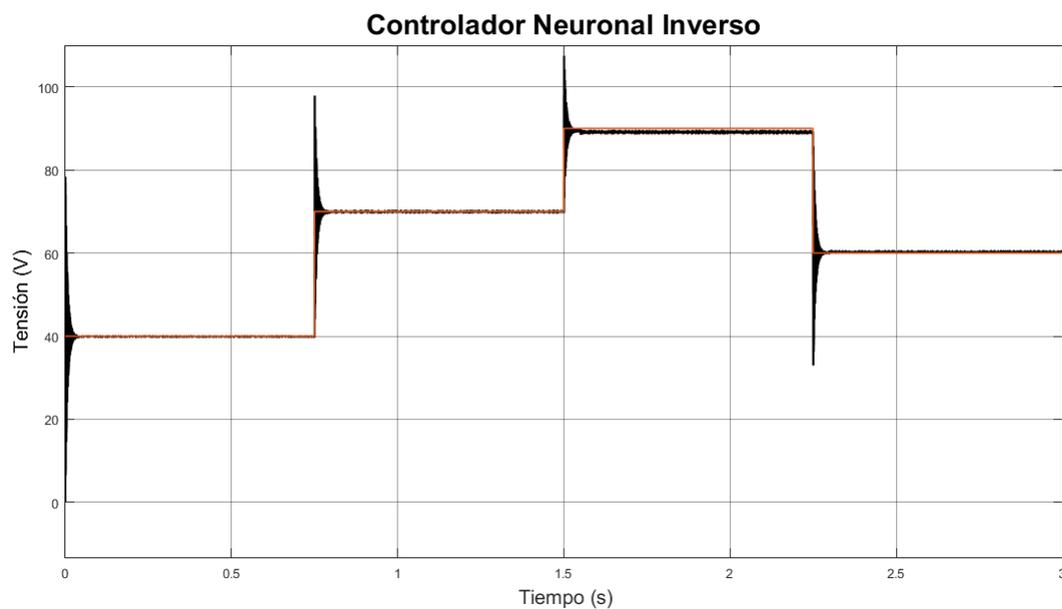
se presenta la respuesta de cada una de las redes entrenadas.

- En la figura 23 se muestra la simulación de la red neuronal con ocho neuronas en la capa oculta. Se puede observar que el controlador en un principio sigue la trayectoria satisfactoriamente, sin embargo para los valores de referencia de  $70V$ ,  $90V$  y  $60V$  el error es demasiado evidente.

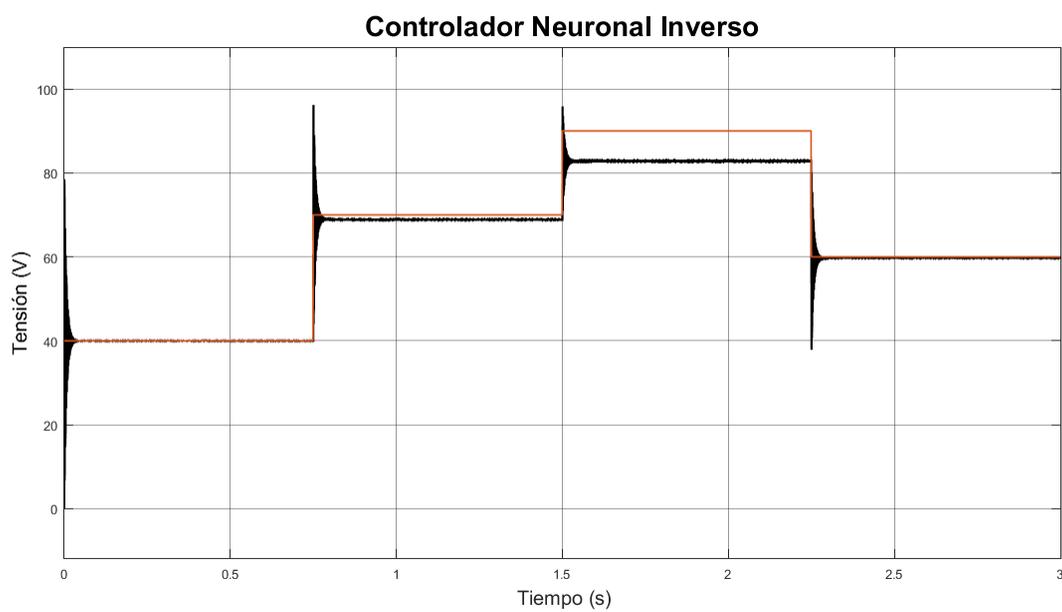


**Figura 23:** Controlador neuronal inverso con 8 neuronas en la capa oculta

- En la figura 24 se muestra la simulación de la red neuronal con diez neuronas en la capa oculta. Se puede observar que el controlador sigue de mejor manera la señal de referencia a comparación de la prueba anterior, se muestra un error menor a los presentados en las demás pruebas.
- En la figura 25 se muestra la simulación de la red neuronal con quince neuronas en la capa oculta. Se puede observar que el controlador sigue la trayectoria en los valores

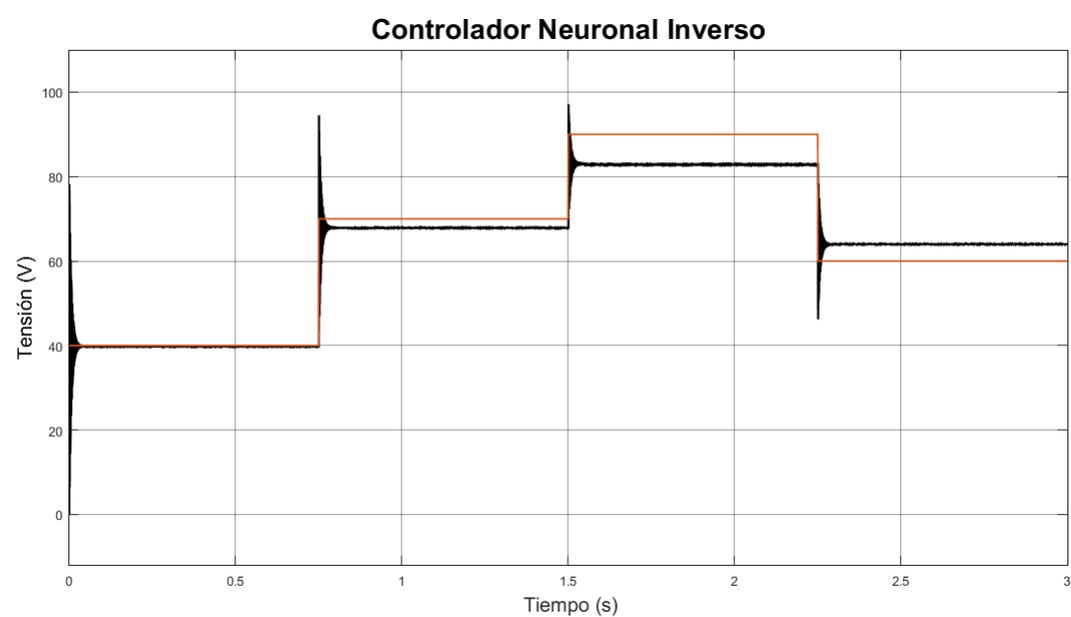


*Figura 24:* Controlador neuronal inverso con 10 neuronas en la capa oculta de 40V, 70V y 60V. Sin embargo para 90V la señal de control no llega a seguir a la referencia.



*Figura 25:* Controlador neuronal inverso con 15 neuronas en la capa oculta

- En la figura 26 se muestra la simulación de la red neuronal con veinte neuronas en la capa oculta. Se puede observar que el controlador sigue a la referencia en los 40V. Sin embargo para los valores de 70V, 90V y 50V la señal de control muestra error elevado.



*Figura 26:* Controlador neuronal inverso con 20 neuronas en la capa oculta

Como se ha podido observar la RNA que ha sido elegida, debido a la respuesta que ha presentado, es la red con diez neuronas en la capa oculta. Debido a que presenta el menor error en el seguimiento de la señal de referencia en comparación con las demás pruebas, además cabe mencionar que esta red ha sido entrenada en 1151 épocas.

Si bien el objetivo del presente estudio es la comparación de un controlador basado en redes neuronales con un controlador predictivo, se ha considerado necesario diseñar otra estrategia de control basada en redes neuronales, debido a que las pruebas mostradas anteriormente no cumplen con los requerimientos en cuanto al sobreimpulso elevado que presentan. Es por esto que a continuación se presenta el diseño y simulación del controlador PID con redes

neuronales.

### 3.3. Control PID con Redes Neuronales

Previo el diseño del controlador PID mediante redes neuronales se debe diseñar el controlador de estrategia básica proporcional, integral y derivativa.

La función de transferencia del controlador PID viene dada por:

$$Gc(s) = K_p \left( 1 + \frac{1}{T_i} + T_d s \right) = K_p + \frac{K_i}{s} + K_d s \quad (3.9)$$

$$Gc(s) = k \frac{(s + a)^2}{s} \quad (3.10)$$

Donde:

$T_i$ , es la constante de tiempo integral.

$T_d$ , es la constante de tiempo derivativa.

$K_p$ , es la ganancia proporcional.

$K_i$ , es la ganancia integral.

$K_d$ , es la ganancia derivativa.

$k$ , es la constante proporcional.

$a$ , son los ceros de la función.

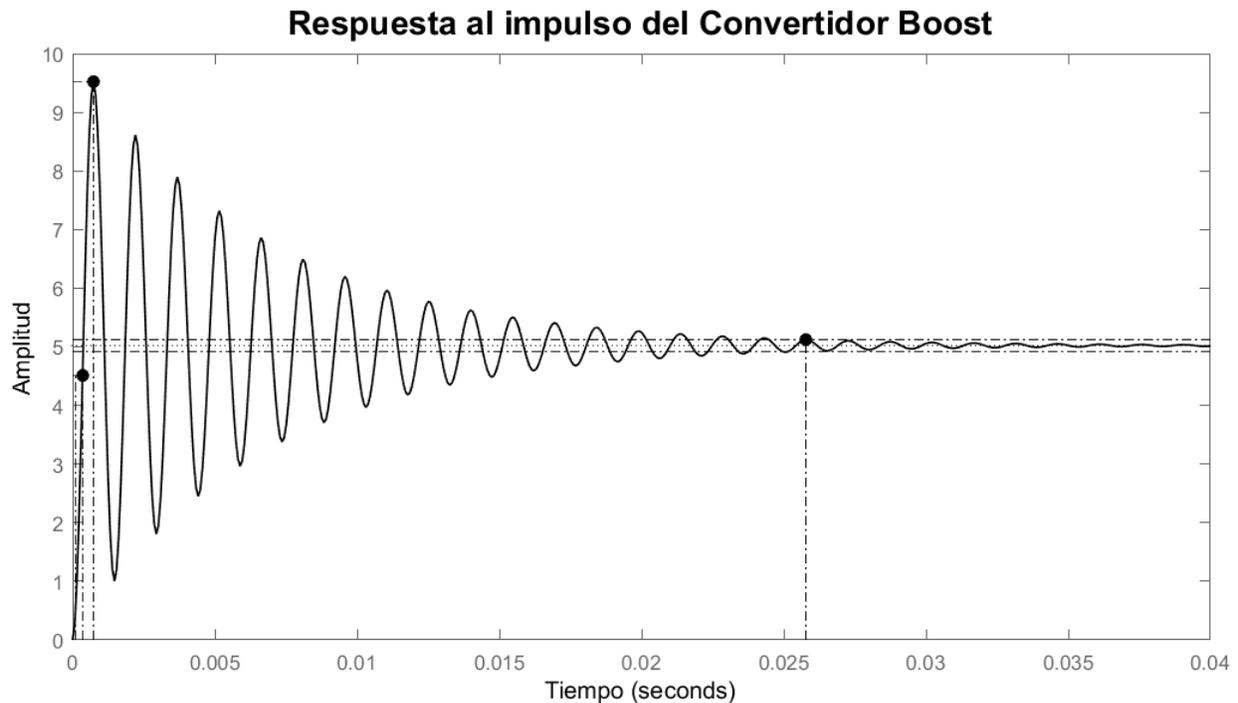
### 3.3.1. Diseño del Controlador

#### Diseño del Controlador PID

Para el diseño del controlador PID es necesario conocer la función de transferencia del convertidor, la misma que ha sido expresada en la ecuación 2.26. Al reemplazar los valores obtenidos en el diseño del convertidor *Boost* , se obtiene la siguiente función de transferencia:

$$\frac{\hat{v}_o(s)}{\hat{E}(s)} = \frac{91,4M}{s^2 + 303,03s + 18,2M} \quad (3.11)$$

A continuación se presenta la respuesta al impulso de la función de transferencia.



**Figura 27:** Respuesta al impulso de la función de transferencia

Mediante la figura 27 se pueden establecer los siguientes valores:

- Tiempo se subida;  $t_r = 0,25ms$
- Tiempo se establecimiento  $t_s = 0,0258s$
- Máximo sobreimpulso  $Mp = 89,4\%$

Para obtener el valor de la frecuencia natural no amortiguada ( $\omega_n$ ) y el coeficiente de amortiguamiento ( $\zeta$ ) se compara la ecuación general de una función de transferencia de segundo grado (ecuación 3.12) con la función de transferencia del convertidor (Katsuhiko, 1998).

$$\frac{C(s)}{R(s)} = Ke \cdot \frac{\omega_n^2}{s^2 + 2 \cdot \zeta \cdot \omega_n \cdot s + \omega_n^2} \quad (3.12)$$

De donde se obtiene:

$$\omega_n = 9560,33$$

$$\zeta = \frac{303,03}{2 \cdot 9560,33} = 0,016$$

Debido a que el valor de  $\zeta$  se encuentra en el rango de  $0 < \zeta < 1$ , se establece que el sistema es subamortiguado. A continuación se obtienen los valores del tiempo de establecimiento, máximo sobreimpulso y los polos conjugados del sistema. Ya que estos valores demuestran el comportamiento del convertidor *Boost* en lazo cerrado (Katsuhiko, 1998).

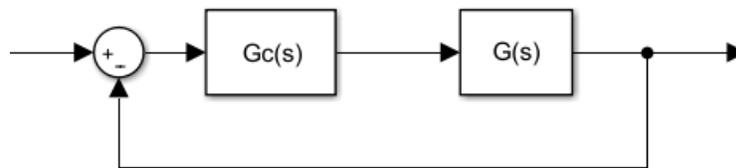
$$t_s = \frac{4}{\zeta \cdot \omega_n} = 0,025 \quad (3.13)$$

$$Mp = e^{-\frac{\zeta \cdot \pi}{\sqrt{1-\zeta^2}}} = 0,9 \quad (3.14)$$

$$s = -\zeta \cdot \omega_n \pm \omega_n \sqrt{\zeta^2 - 1} \quad (3.15)$$

$$s = 9407,36 \pm 0,99i$$

Para el diseño del PID se usa el método del lugar de las raíces. En este método (figura 28) la respuesta del sistema depende de la ubicación que tengan los polos del sistema en lazo cerrado.



**Figura 28:** Diagrama en lazo cerrado del controlador PID

La función de transferencia de retroalimentación negativa expresada en la ecuación 3.16, permite establecer los criterios fundamentales de diseño del control PID a partir de las raíces (Katsuhiko, 1998).

$$\frac{C(s)}{R(s)} = \frac{G(s)}{1 + G(s) \cdot G_c(s)} \quad (3.16)$$

$$|G(s) \cdot G_c(s)| = 1 \quad (3.17)$$

$$\angle(G(s) \cdot G_c(s)) = \angle G_c(s) + \angle G(s) = \pm 180 \cdot (2n \pm 1) \quad (3.18)$$

## Criterios de diseño para el controlador PID

El diseño de un controlador PID se realiza en base a los siguientes criterios: el tiempo de establecimiento y el máximo sobreimpulso. Al tratarse de un convertidor *Boost* se debe tener en claro que su respuesta es rápida, es por ello que para el presente diseño se plantean los siguientes parámetros:

- $Mp = 10\%$
- $t_s = 0,005s$

Se necesitan calcular los nuevos valores del coeficiente de amortiguamiento ( $\zeta$ ) y la frecuencia natural no amortiguada ( $\omega_n$ ). Para ello se usa las ecuaciones 3.14 y 3.13 respectivamente.

$$Mp = e^{-\frac{\zeta \cdot \Pi}{\sqrt{1-\zeta^2}}} = 10\%$$

$$\zeta = 0,591$$

$$t_s = \frac{4}{\zeta \cdot \omega_n} = 0,005$$

$$\omega_n = 1355,93$$

Los nuevos polos del sistema son:

$$s_1 = -799505 \pm 1094,78i$$

El ángulo de la función de transferencia del convertidor se calcula mediante las ecuaciones 3.11 y 3.18:

$$G(s_1) = \frac{91,4M}{s_1^2 + 303,03s_1 + 18,2M}$$

$$\angle G(s_1) = 0,15^\circ$$

$$\angle G_c(s_1) = 179,85^\circ$$

Para obtener el valor de  $a$  y  $k$  se usan las ecuaciones 3.10 y 3.17. Posterior a ello se encuentran los parámetros  $K_p$ ,  $K_i$  y  $K_d$ .

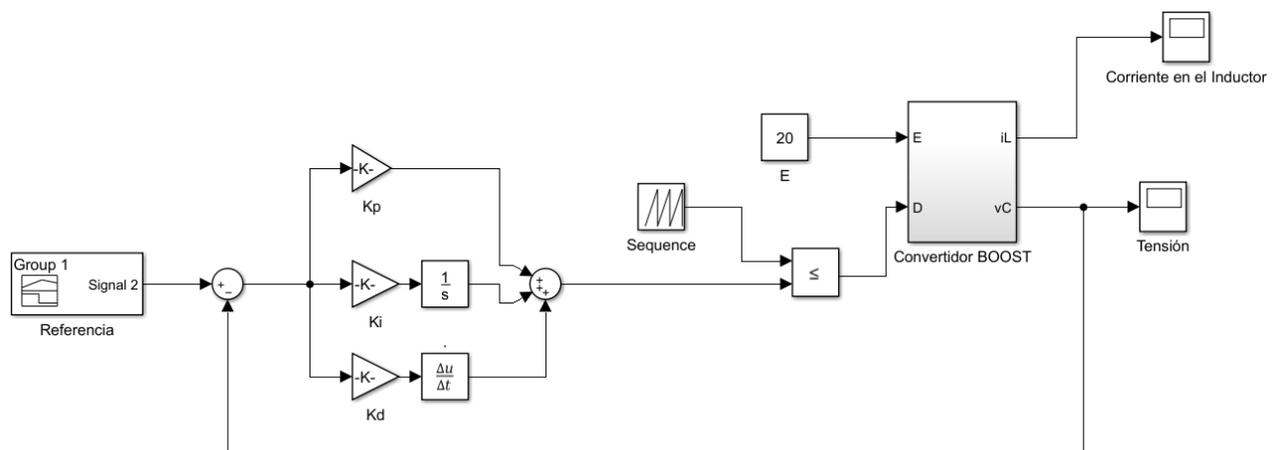
$$G_c(s) = k \cdot \frac{(s+a)^2}{s} = \frac{K_d \cdot s^2 + K_p \cdot s + K_i}{s}$$

$$K_p = 0,601$$

$$K_i = 1900$$

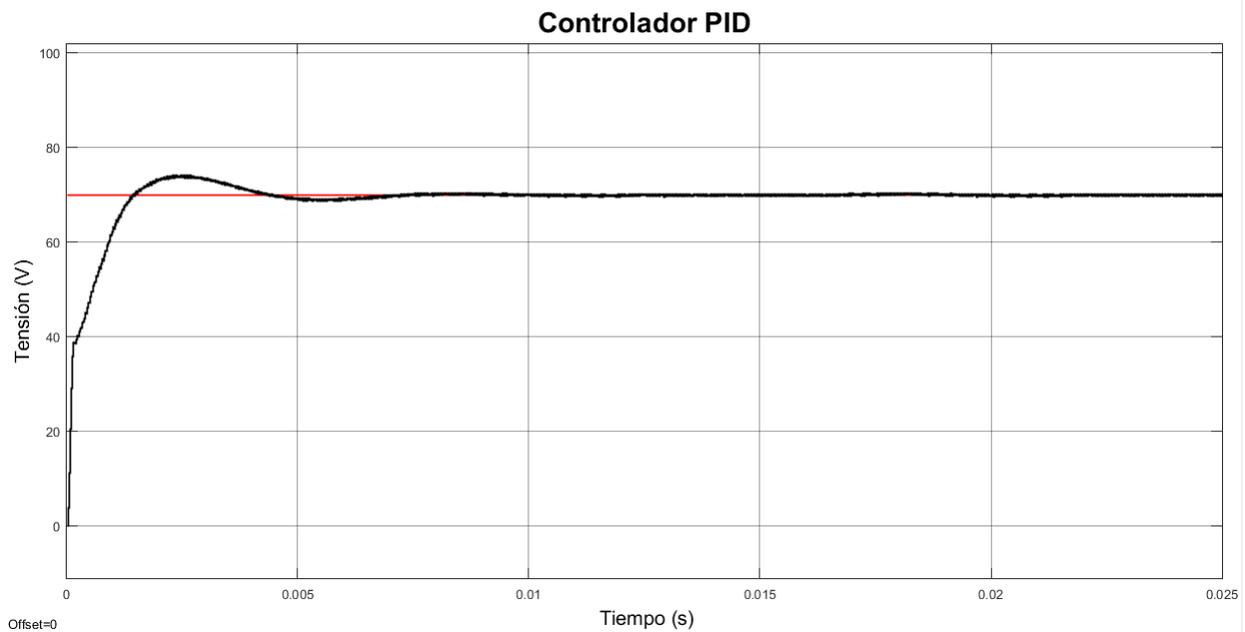
$$K_d = 0,0011$$

Una vez han sido obtenidas las ganancias del controlador PID. Se procede a su verificación mediante el uso del siguiente diagrama realizado en *Simulink*.



**Figura 29:** Simulación del controlador PID en Simulink

Se ha probado el funcionamiento del controlador PID para una referencia de tensión de 70V. Donde se obtiene la siguiente respuesta.

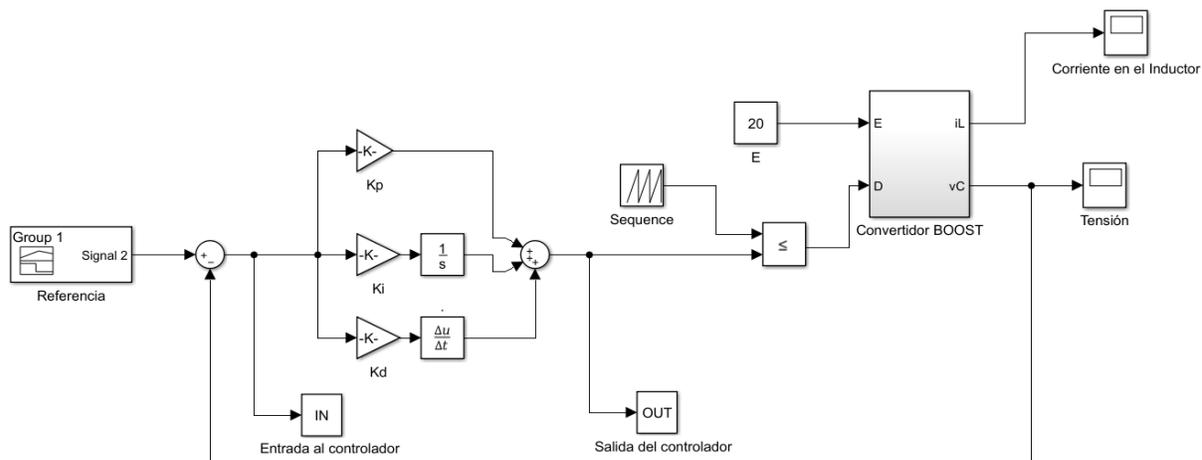


**Figura 30:** Respuesta del controlador PID a una referencia de 70 V

Como se observa en la figura 30 se cumplen las condiciones de diseño y además la señal controlada sigue a la referencia de 70V.

### Diseño del controlador PID mediante Redes Neuronales

Una vez se ha obtenido el controlador PID que genera la señal de control a emular, se selecciona el conjunto de datos de entrenamiento para la RNA. Se ha usado el esquema de la figura 29 con una pequeña modificación. Con ayuda de los bloques IN y OUT se obtiene el conjunto de entrenamiento para la RNA.



**Figura 31:** Obtención del conjunto de entrenamiento

Para la generación de datos del conjunto de entrenamiento se emplea el programa “IMPORTAR\_IN” (Anexo D), donde se envía la señal de referencia desde 20V hasta 200V en pasos de 2V y mediante el bloque de *Simulink* “IMPORTAR\_IN\_OUT” se obtienen los valores del vector “IN” y del estado anterior de la salida.

Como se ha mencionado anteriormente la respuesta de una red neuronal puede llegar a mejorar dependiendo del número de elementos que conformen el conjunto de entrenamiento. Además las entradas a la red generalmente provienen de una serie de tiempo con datos anteriores al que se quiere predecir.

Para el entrenamiento de la RNA es necesario realizar la combinación de las entradas a la misma. Es por ello que mediante el programa “IMPORTAR\_OUT” (Anexo E) se combinan las entradas y posterior a ello son guardadas en el vector “p”. A continuación se generan los valores del vector “OUT” mediante el mismo bloque de *Simulink* “IMPORTAR\_IN\_OUT” y son guardados en el vector “duty”.

La creación y aprendizaje de la RNA se ha realizado mediante el programa “Neuronal\_PID” (Anexo F).

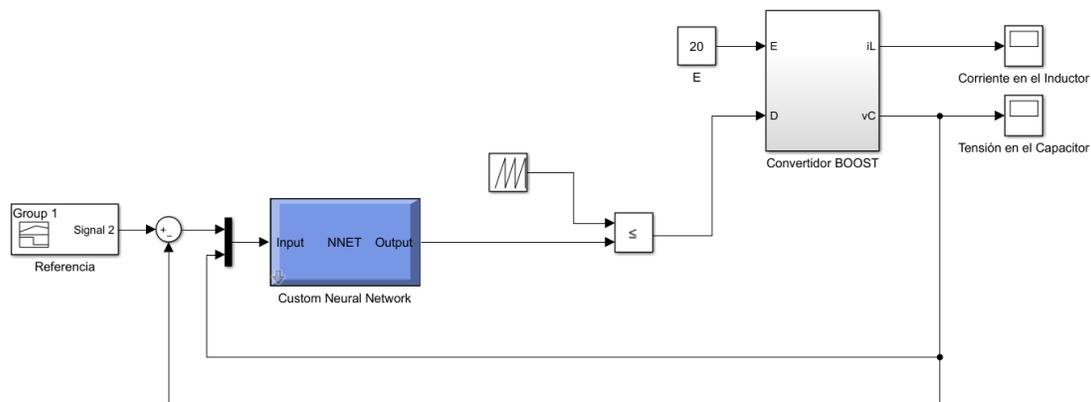
### 3.3.2. Simulación del Controlador

En la etapa de simulación se han realizado pruebas con tres redes neuronales de diferentes arquitecturas. Las mismas que consisten de tres capas: capa de entrada con dos neuronas, capa de salida con una neurona y la capa oculta que fue la modificada con diez, quince y veinte neuronas para cada prueba.

La función de transferencia para la capa de entrada fue “tansig” y la función de activación para la capa de salida fue “purelin”.

Dentro de los posibles métodos de aprendizaje de descenso de gradiente se ha elegido el método de *Levenberg-Marquardt*, debido a la eficiencia en tiempo computacional en comparación a otros métodos y además por su robustez (Bouami, 2005).

El esquema que ha sido utilizado para las pruebas es el que se muestra en la siguiente figura:

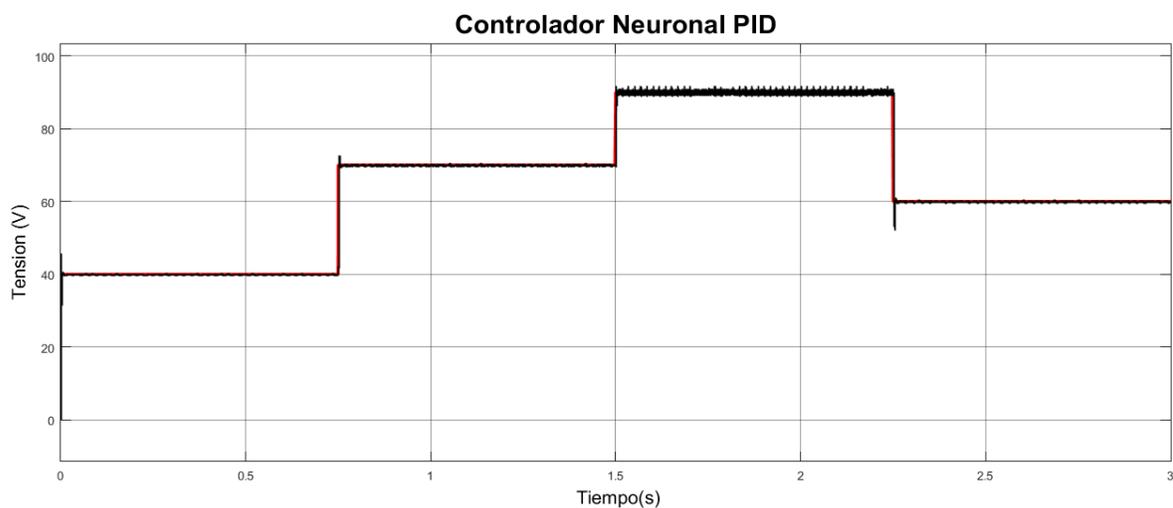


*Figura 32:* Esquema del controlador neuronal PID

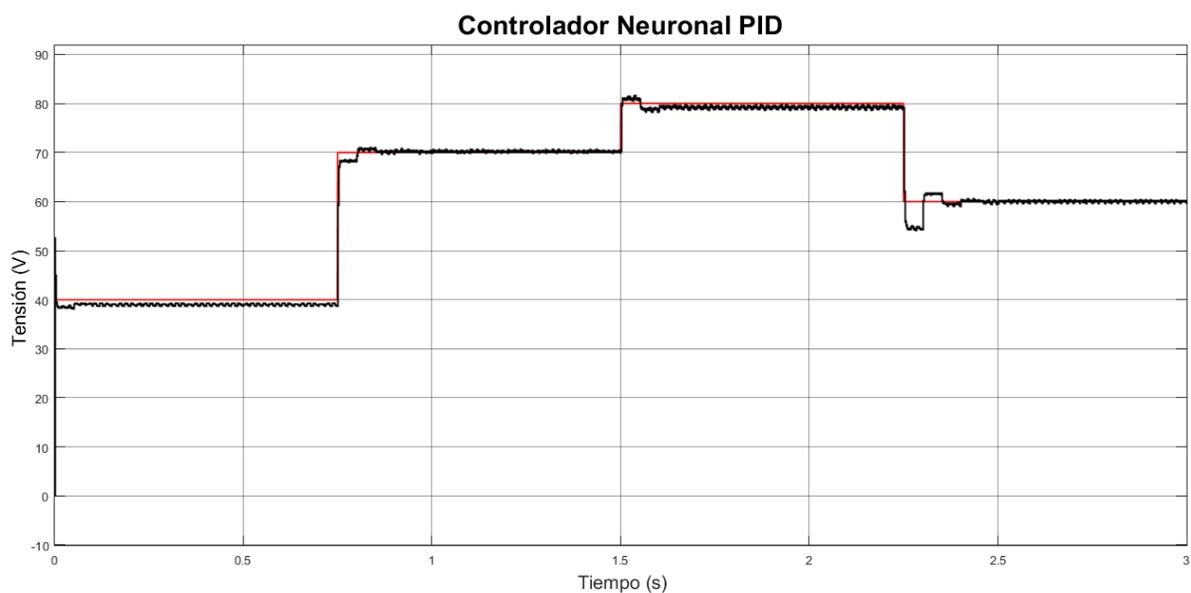
Para las diferentes pruebas se ha utilizado la misma señal de referencia usada en el controlador neuronal inverso, véase figura 22.

A continuación se presentan las respuestas de cada una de las redes neuronales creadas.

- A partir de la figura 33 se observa que la respuesta de la red es satisfactoria, debido a que la señal controlada sigue a la referencia. Además el máximo sobreimpulso ha sido notoriamente disminuido.
- A partir de la figura 34 se observa que el controlador funciona de manera indicada, sin embargo no existe un tiempo de establecimiento aceptado, es decir, el tiempo de establecimiento es mayor que 0,005s.

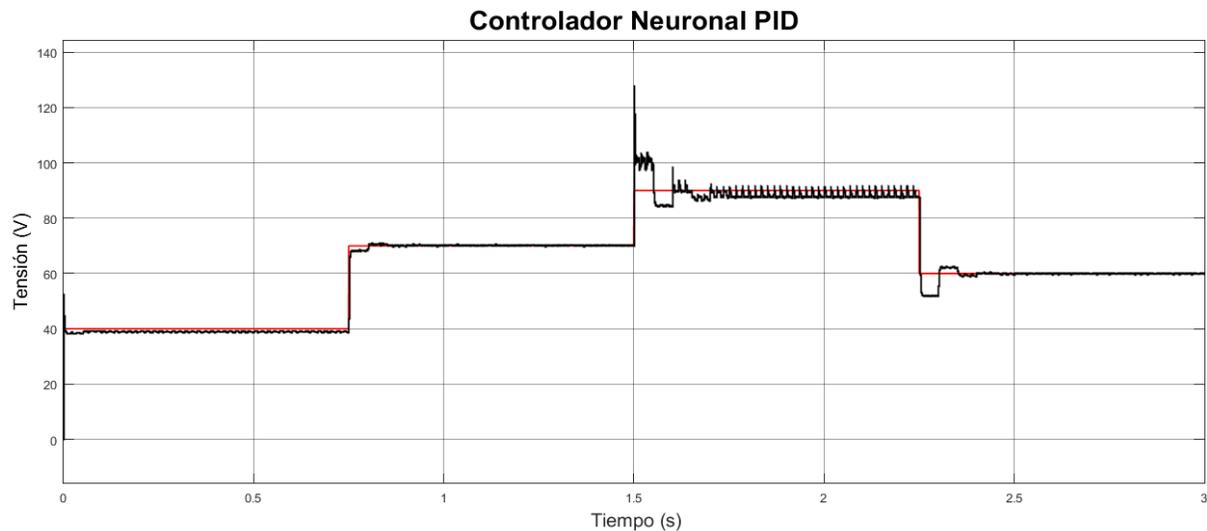


*Figura 33:* Controlador neuronal PID con 10 neuronas en la capa oculta



*Figura 34:* Controlador neuronal PID con 15 neuronas en la capa oculta

- A partir de la figura 35 se observa que el controlador funciona satisfactoriamente con las referencias de 40V y 70V. Sin embargo para los 90V la señal no logra estabilizarse.



**Figura 35:** Controlador neuronal PID con 20 neuronas en la capa oculta

De acuerdo a las figuras que han sido mostradas, se ha elegido al controlador neuronal PID con estructura de diez neuronas en la capa oculta, el mismo que ha sido entrenado en 16222 de un total de 40000 épocas.

### 3.4. Control Predictivo por Matriz Dinámica

Previo al diseño del controlador por matriz dinámica se debe conocer la función de transferencia del convertidor, la misma que ha sido obtenida en la ecuación 3.11.

Para discretizar la función de transferencia se ha usado el método de aproximación Bilinear o Tustin. Donde se obtiene la siguiente función, la misma que será usada para la variación en las perturbaciones que afectarán al convertidor:

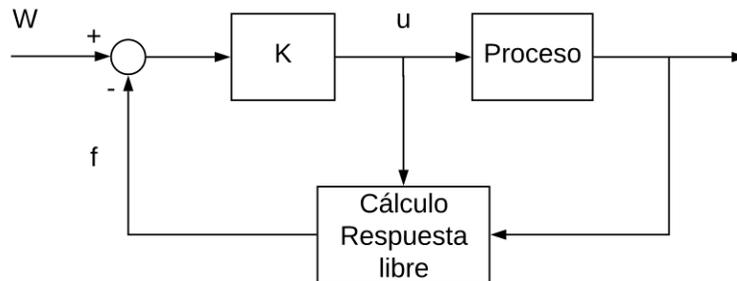
$$G(z^{-1}) = \frac{((1-\delta)^2 \cdot R \cdot T^2) + (2 \cdot (1-\delta)^2 \cdot R \cdot T^2)z^{-1} + ((1-\delta)^2 \cdot R \cdot T^2)z^{-2}}{(4 \cdot R \cdot L \cdot C + 2 \cdot T \cdot L + T^2 \cdot R \cdot (1-\delta)^2) + (-8 \cdot R \cdot L \cdot C + 2 \cdot T^2 \cdot R \cdot (1-\delta)^2)z^{-1} + (4 \cdot R \cdot L \cdot C - 2 \cdot T \cdot L + T^2 \cdot R \cdot (1-\delta)^2)z^{-2}}$$

Al reemplazar cada uno de los datos y con tiempo de muestreo igual a  $33 \mu s$ , la función de transferencia que se obtiene es:

$$G(z^{-1}) = \frac{0,0246 + 0,0495z^{-1} + 0,0246z^{-2}}{1 - 1,97z^{-1} + 0,9901z^{-2}} \quad (3.19)$$

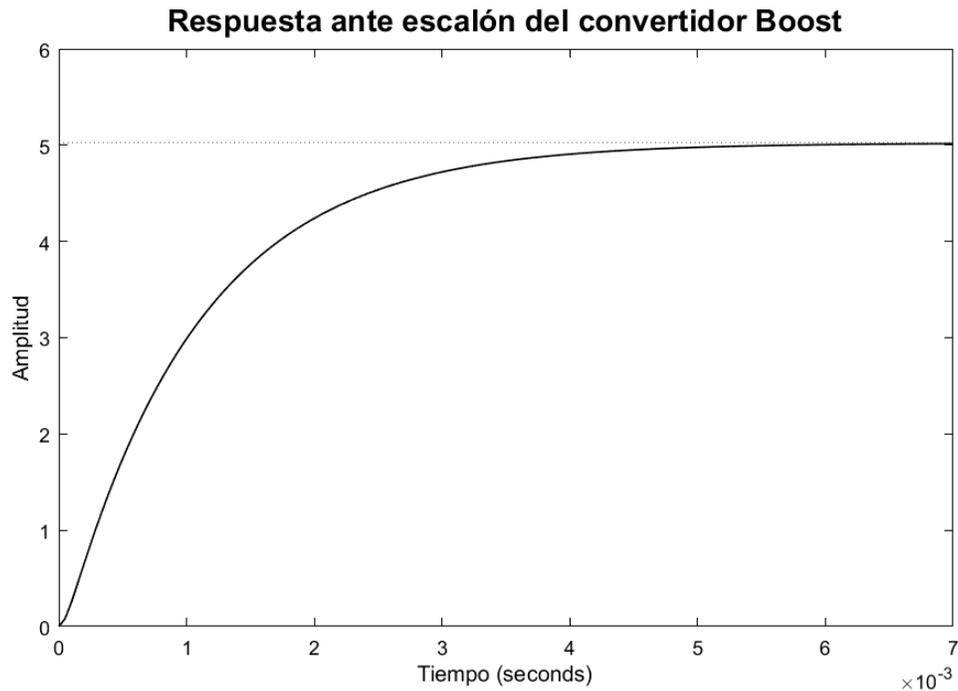
### 3.4.1. Diseño del Controlador

La ley de control que será aplicada al convertidor elevador es representada en el siguiente esquema:



**Figura 36:** Ley de control DMC  
Fuente:(Camacho y Bordons, 2004).

Como se ha explicado en la subsección 2.6.1 y a través del esquema anteriormente presentado es necesario conocer el valor de los coeficientes de la matriz dinámica  $G$ , los mismos que son obtenidos a través de la respuesta ante escalón. Por ello, a continuación, se muestra la respuesta del convertidor elevador *Boost*.



**Figura 37:** Respuesta ante escalón del convertidor *Boost*

Posterior a ello a través de la señal de referencia mostrada en la figura 22 y la respuesta libre del sistema se calculan las variaciones de la salida de la variable manipulada, es decir, del ciclo de trabajo.

Como ha sido explicado, con anterioridad, solo se envía al proceso la primera variación de control y la respuesta libre  $f$  se calcula en cada instante de tiempo con los valores de control  $u$ , el valor actual del proceso y los coeficientes de la matriz  $G$ .

### Matriz Dinámica $G$

La matriz dinámica  $G$  contiene los coeficiente de  $g_i$  obtenidos de la respuesta ante escalón con un tiempo de muestreo 40 veces menor que el tiempo subida ( $t_s=33\text{ us}$ ). Se ha establecido como horizonte de predicción  $p = 15$  y como horizonte control  $m = 7$ . A continuación se

presenta la matriz dinámica  $G$ .

$$G = \begin{bmatrix} 0,0186 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0,0837 & 0,0186 & 0 & 0 & 0 & 0 & 0 \\ 0,1899 & 0,0837 & 0,0186 & 0 & 0 & 0 & 0 \\ 0,3154 & 0,1899 & 0,0837 & 0,0186 & 0 & 0 & 0 \\ 0,4487 & 0,3154 & 0,1899 & 0,0837 & 0,0186 & 0 & 0 \\ 0,5840 & 0,4487 & 0,3154 & 0,1899 & 0,0837 & 0,0186 & 0 \\ 0,7183 & 0,5840 & 0,4487 & 0,3154 & 0,1899 & 0,0837 & 0,0186 \\ 0,8501 & 0,7183 & 0,5840 & 0,4487 & 0,3154 & 0,1899 & 0,0837 \\ 0,9786 & 0,8501 & 0,7183 & 0,5840 & 0,4487 & 0,3154 & 0,1899 \\ 1,1037 & 0,9786 & 0,8501 & 0,7183 & 0,5840 & 0,4487 & 0,3154 \\ 1,2251 & 1,1037 & 0,9786 & 0,8501 & 0,7183 & 0,5840 & 0,4487 \\ 1,3428 & 1,2251 & 1,1037 & 0,9786 & 0,8501 & 0,7183 & 0,5840 \\ 1,4570 & 1,3428 & 1,2251 & 1,1037 & 0,9786 & 0,8501 & 0,7183 \\ 1,5676 & 1,4570 & 1,3428 & 1,2251 & 1,1037 & 0,9786 & 0,8501 \\ 1,6749 & 1,5676 & 1,4570 & 1,3428 & 1,2251 & 1,1037 & 0,9786 \end{bmatrix}$$

Como se observa en el esquema de la figura 36, se necesita conocer el valor de  $K$ . Entonces, a través de la matriz dinámica  $G$  se obtiene la matriz  $(G^T G + \lambda I)^{-1} G^T$ , donde  $K$  representa la primera fila de dicha matriz.

### Algoritmo del controlador DMC

El algoritmo del controlador predictivo DMC se encarga de calcular la acción de control para el convertidor elevador *Boost*, el mismo que ha sido realizado en el programa “DMC\_Boost” (Anexo G). En este programa se establece el tiempo de muestreo ( $t_s$ ), tiempo de simulación ( $t_{sim}$ ), muestras ( $N$ ), función de transferencia del convertidor ( $H$ ). Seguido de la obtención de los coeficientes de la respuesta ante escalón ( $g_i$ ), además se establecen los

parámetros de sintonización ( $\lambda$ ), horizontes de control ( $m$ ) y predicción ( $p$ ).

Para obtener el valor de  $K$  se debe calcular la respuesta libre en cada instante de tiempo y la variable de control ( $u$ ) para la señal de referencia ( $R$ ). Finalmente se almacenan los vectores de salida ( $Y$ ) y control ( $U$ ).

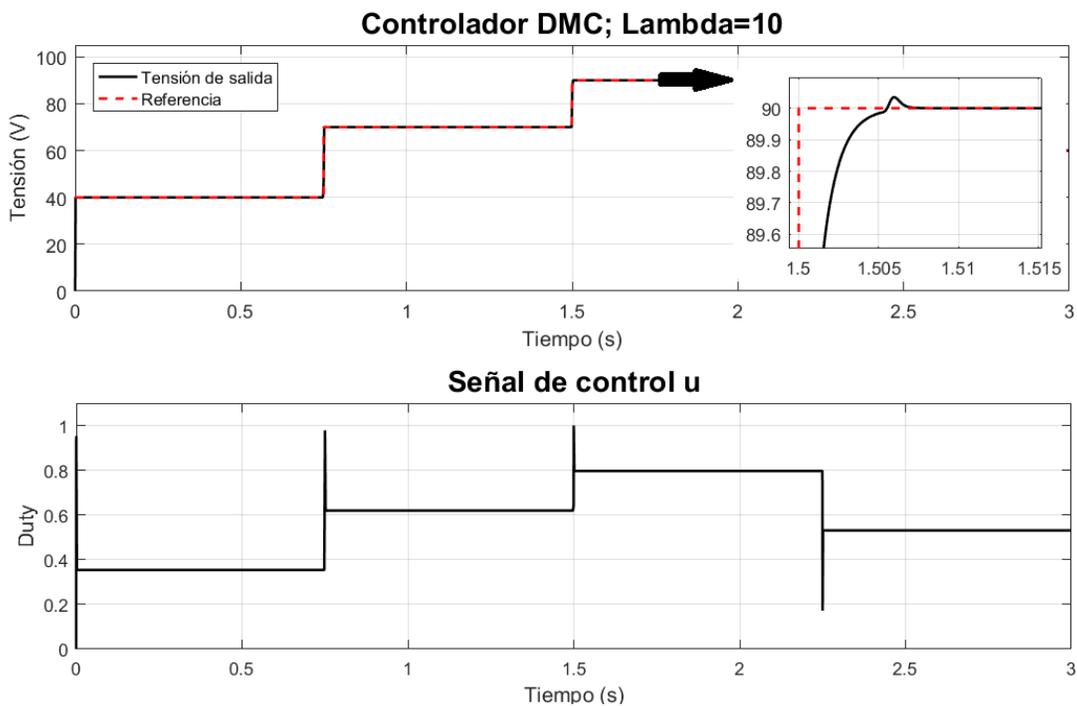
Las restricciones limitan los valores en los cuales debe discurrir la evolución del sistema. La evolución de las señales de control de un sistema no deben exceder determinadas restricciones que, ya sea por límites físicos o bien por motivos de seguridad, se imponen al sistema (Marruedo, 2002). Si bien es cierto el controlador DMC no considera restricciones en la entrada o salida. Sin embargo para el convertidor *Boost* y su señal de control se considera la limitación de la amplitud. Por ello el rango limitado del ciclo de trabajo es entre:  $0 \leq u(t) \leq 1$ .

### 3.4.2. Simulación del Controlador

Dentro de la literatura existen varios métodos experimentales, técnicas heurísticas y formulaciones para calcular el valor apropiado del esfuerzo de control, tal es el ejemplo de las ecuaciones planteadas por (Iglesias y otros., 2006) para sistemas SISO y (Kember y otros., 2005) para sistemas MIMO. Sin embargo en la actualidad la sintonización de estos parámetros se considera un campo de estudio abierto.

Para la etapa de simulación se han realizado cuatro pruebas diferentes en base al esfuerzo de control ( $\lambda$ ) bajo la estrategia de prueba y error. Se realizaron pruebas del controlador DMC para:  $\lambda = 10$ ,  $\lambda = 100$ ,  $\lambda = 1000$  y  $\lambda = 10000$ . Además se ha realizado un acercamiento en el tiempo  $1,5 s$  y en la tensión de salida  $90 V$ .

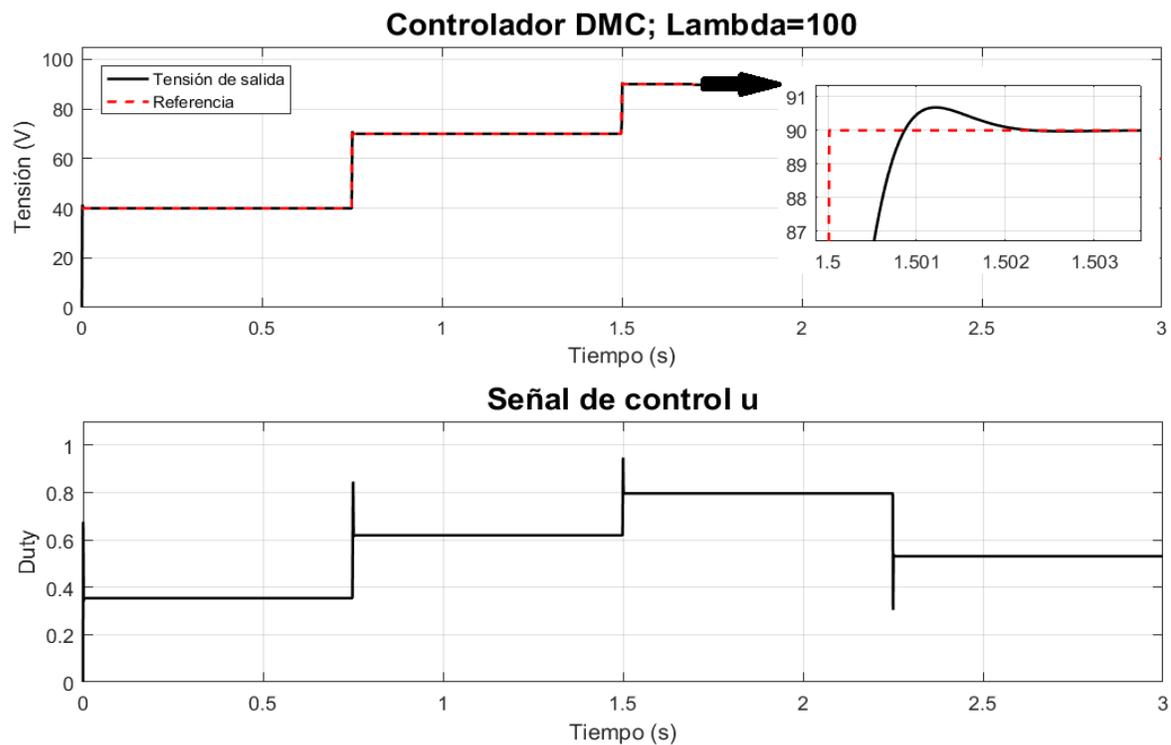
- En la figura 38 se muestra la simulación para  $\lambda = 10$ , se observa que la respuesta del controlador sigue satisfactoriamente a la referencia. Sin embargo en el acercamiento a los  $90\text{ V}$  se observa que la señal de salida presenta un sobreimpulso menor al  $1\%$  del valor de referencia, además se logra estabilizar en  $t = 1,507\text{ s}$ . La señal de control  $u$  es limitada por la restricción de su módulo y existe un control brusco en el cambio de referencia.



**Figura 38:** Simulación del controlador DMC para Lambda 10

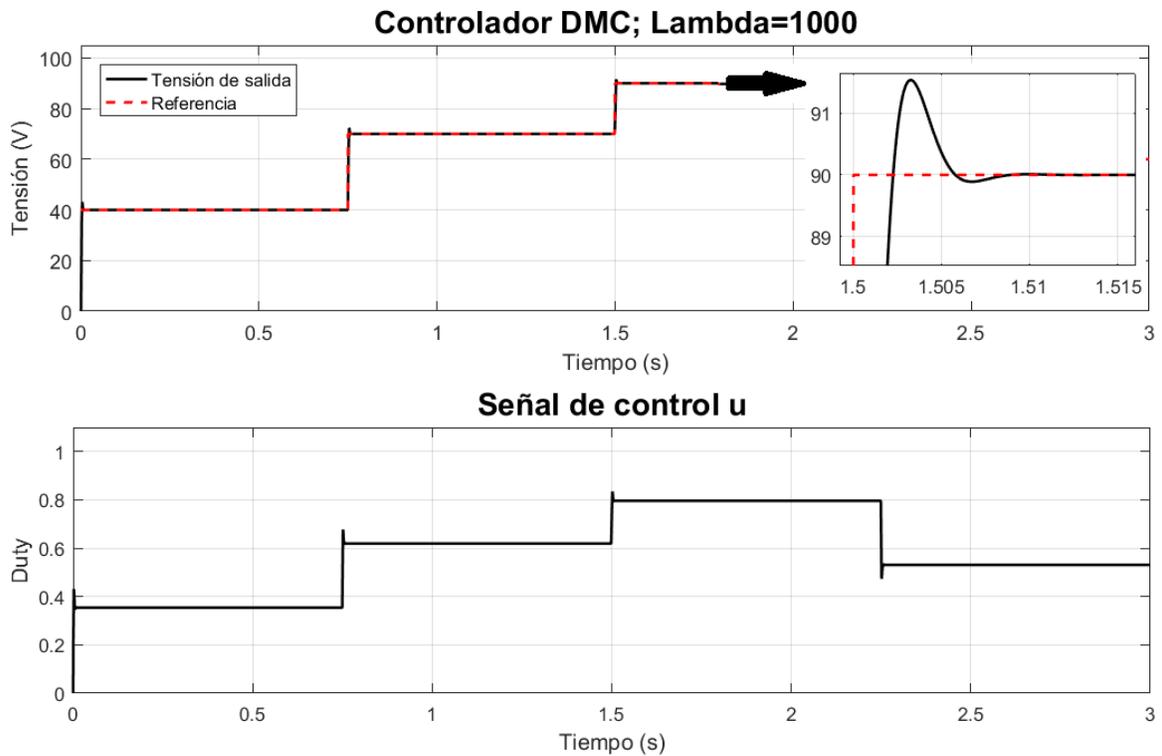
- En la figura 39 se muestra la simulación para  $\lambda = 100$ , se observa que la respuesta del controlador sigue satisfactoriamente a la referencia. Sin embargo en este caso en el acercamiento a los  $90\text{ V}$  se observa que la señal de salida presenta un sobreimpulso

de 1% del valor de referencia, además se logra estabilizar en  $t = 1,502$  s. La señal de control  $u$  no se limita por la restricción de su módulo y es menos brusca que el controlador anterior.



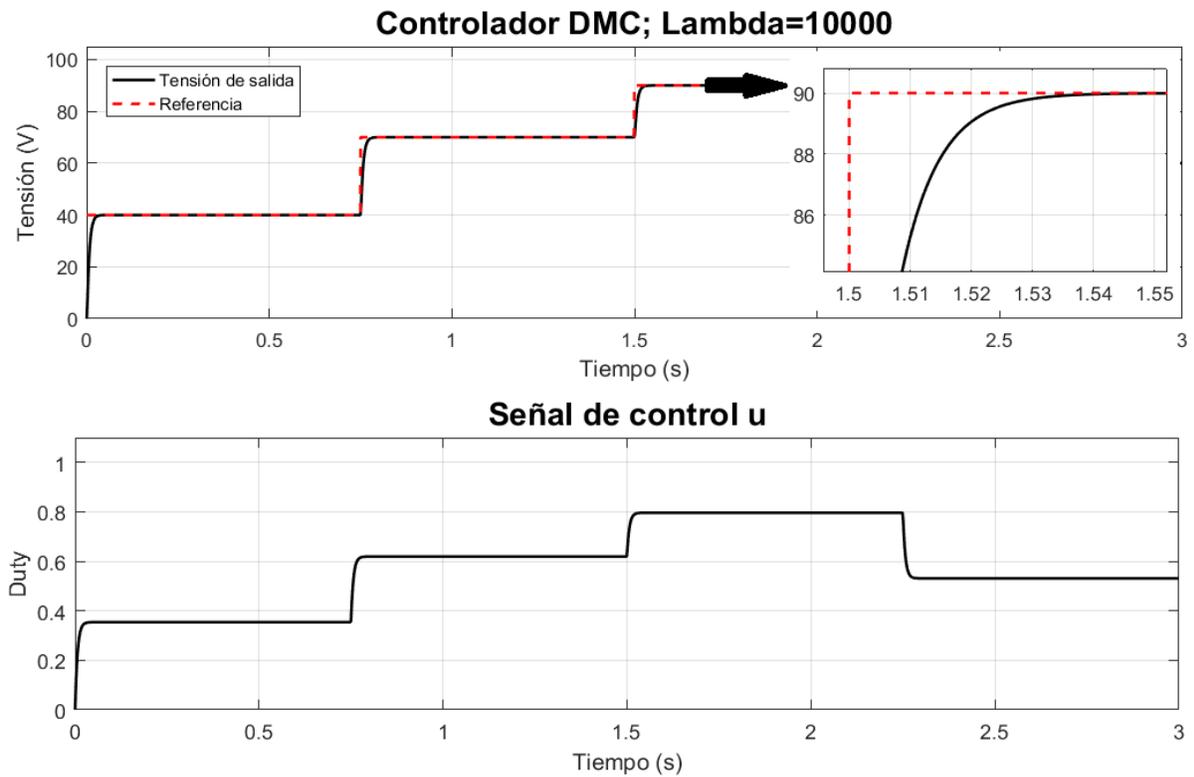
**Figura 39:** Simulación del controlador DMC para Lambda 100

- En la figura 40 se muestra la simulación para  $\lambda = 1000$ , se observa que la respuesta del controlador sigue satisfactoriamente a la referencia. Sin embargo en el acercamiento a los 90 V se observa que la señal de salida presenta un sobreimpulso de 1,5% del valor de referencia, además se logra estabilizar en  $t = 1,508$  s. La señal de control  $u$  no se limita por su restricción.



*Figura 40:* Simulación del controlador DMC para Lambda 1000

- En la figura 41 se muestra la simulación para  $\lambda = 10000$ , se observa que la respuesta del controlador sigue satisfactoriamente a la referencia. Sin embargo en el acercamiento a los 90 V se observa que la señal de salida no presenta sobreimpulso. Sin embargo, se logra estabilizar en  $t = 1,528$  s. La señal de control  $u$  no se limita por su restricción, y es suave.



**Figura 41:** Simulación del controlador DMC para Lambda 10000

De acuerdo a las figuras y a las comparaciones que han sido mostradas, se ha elegido como esfuerzo de control  $\lambda = 100$ , debido a que el sobreimpulso que presenta cumple con los requerimientos para el convertidor, su estabilización es la de menor tiempo (1,502 s). Además es importante considerar la señal de control que no ha sido saturada por su restricción en el módulo.

## Capítulo 4

# ESTUDIO COMPARATIVO DE CONTROLADORES

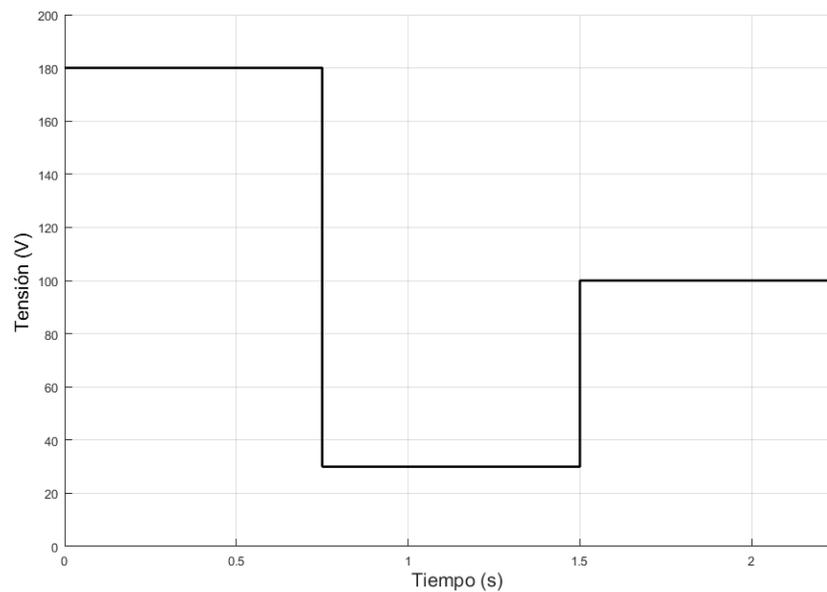
En este capítulo se presentan las diferentes pruebas que han sido simuladas para cada una de las estrategias de control diseñadas. Cada una de estas pruebas son las posibles perturbaciones que el convertidor *Boost* puede enfrentar. Se considera el cambio de referencia, cambio en la tensión de entrada y el cambio del valor de la carga.

### 4.1. Pruebas y Resultados

#### 4.1.1. Cambios en la tensión de referencia

En las siguientes pruebas se evalúa el desempeño del convertidor *Boost* al enfrentarse a cambios en la tensión de referencia. Si bien es cierto las pruebas presentadas en las diferentes simulaciones del capítulo 3 muestran al convertidor trabajando en diferentes tensiones de referencia, se considera necesario que para el estudio comparativo de las estrategias de control esta prueba sea detallada.

Se va a evaluar el desempeño del convertidor cuando la tensión de referencia cambia de un valor superior hasta un valor inferior como se muestra en la figura 42. Donde la tensión de referencia empieza en  $180\text{ V}$ , cambia a  $30\text{ V}$  en  $t = 0,75\text{ s}$  y finalmente en  $t = 1,5\text{ s}$  la referencia cambia a  $100\text{ V}$ .



**Figura 42:** Señal de referencia para pruebas

### Controlador Neuronal por Modelo Inverso

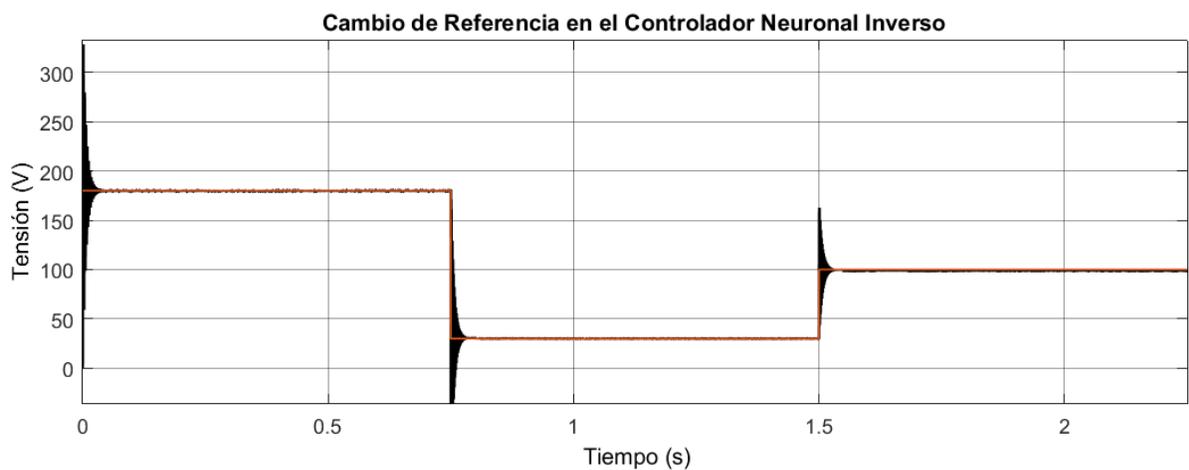
En la figura 43 se muestra la respuesta del controlador neuronal inverso con el cambio de referencia establecida. En esta figura se puede observar que si bien el controlador sigue a la referencia, los valores de sobreimpulso superan en más del 50 % del valor nominal. En los  $180\text{ V}$  el sobreimpulso es casi de 82,2 % y en los  $100\text{ V}$  es de 62,6 %.

Con respecto al tiempo de establecimiento y la tensión en la carga se determina que:

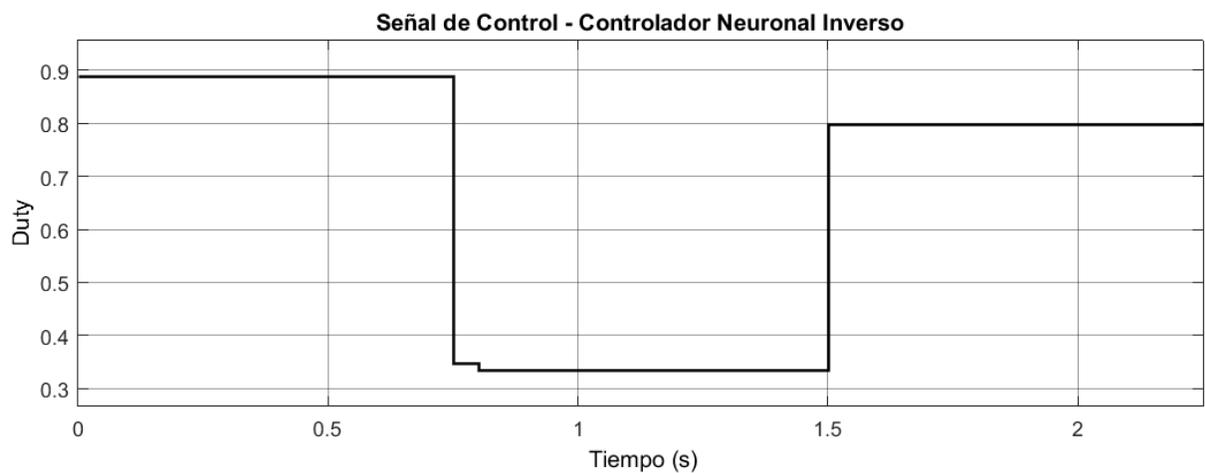
- Para  $180\text{ V}$ ,  $t_s = 0,04\text{ s}$ ,  $v_o = 179,80\text{ V}$ .

- Para  $30\text{ V}$ ,  $t_s = 0,80\text{ s}$ ,  $v_o = 29,90\text{ V}$ .
- Para  $100\text{ V}$ ,  $t_s = 1,58\text{ s}$ ,  $v_o = 98,70\text{ V}$ .

Además se presenta la señal de control (figura 44) que ha sido aplicada al controlador neuronal inverso para cumplir con la referencia requerida.



*Figura 43:* Controlador neuronal inverso



*Figura 44:* Señal de control del Controlador neuronal inverso

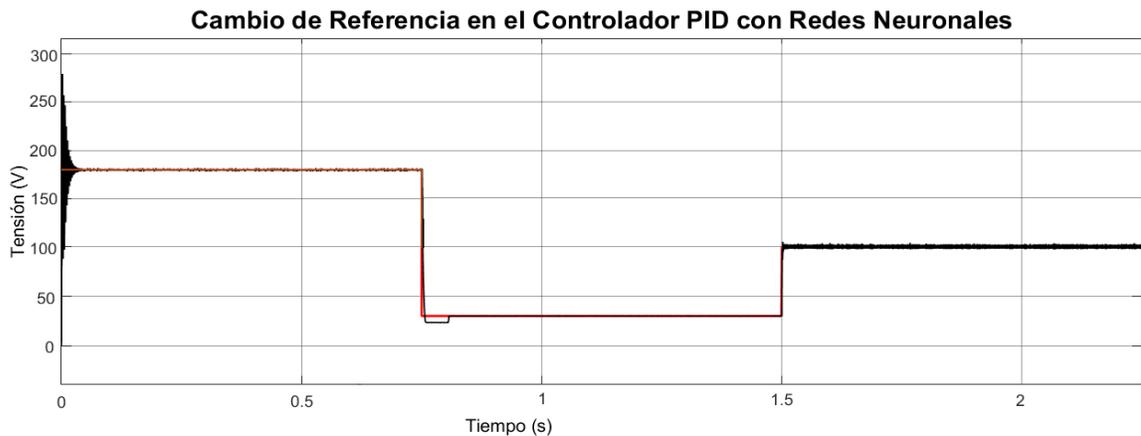
## Controlador PID con Redes Neuronales

En la figura 45 se muestra la respuesta del controlador PID con redes neuronales. Donde se determina que: para 180 V el sobreimpulso a dismuido siendo el 52,7% y para 100 V es de 5%.

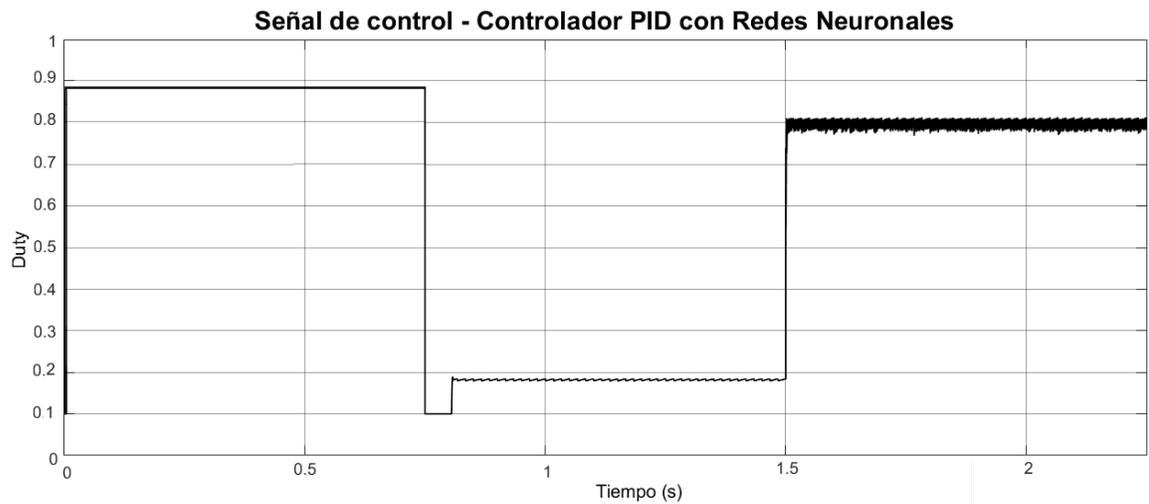
Con respecto al tiempo de establecimiento y la tensión en la carga se determina que:

- Para 180 V,  $t_s = 0,045 s$ ,  $v_o = 179,90 V$ .
- Para 30 V,  $t_s = 0,81 s$ ,  $v_o = 29,97 V$ .
- Para 100 V,  $t_s = 1,503 s$ ,  $v_o = 100,75 V$ .

Además se presenta la señal de control (figura 46) que ha sido aplicada al controlador PID con redes neuronales para cumplir con la referencia requerida.



*Figura 45:* Controlador PID con Redes Neuronales



**Figura 46:** Señal de control del Controlador PID con Redes Neuronales

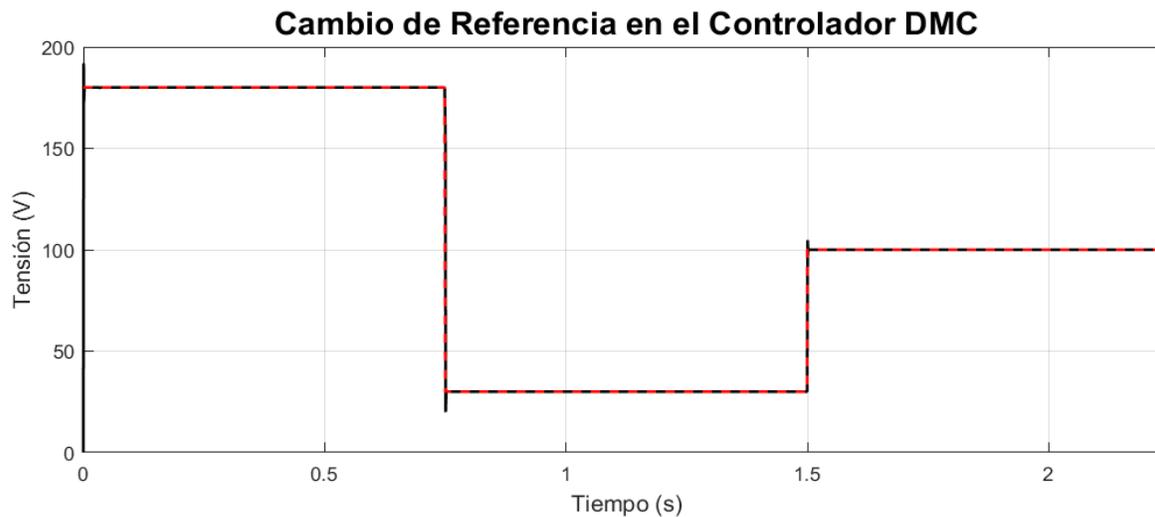
### Controlador Predictivo por Matriz Dinámica

En la figura 47 se muestra la respuesta del controlador predictivo por matriz dinámica. Donde se determina que: para 180 V el sobreimpulso es 6,66 % y para 100 V es de 4,7 %.

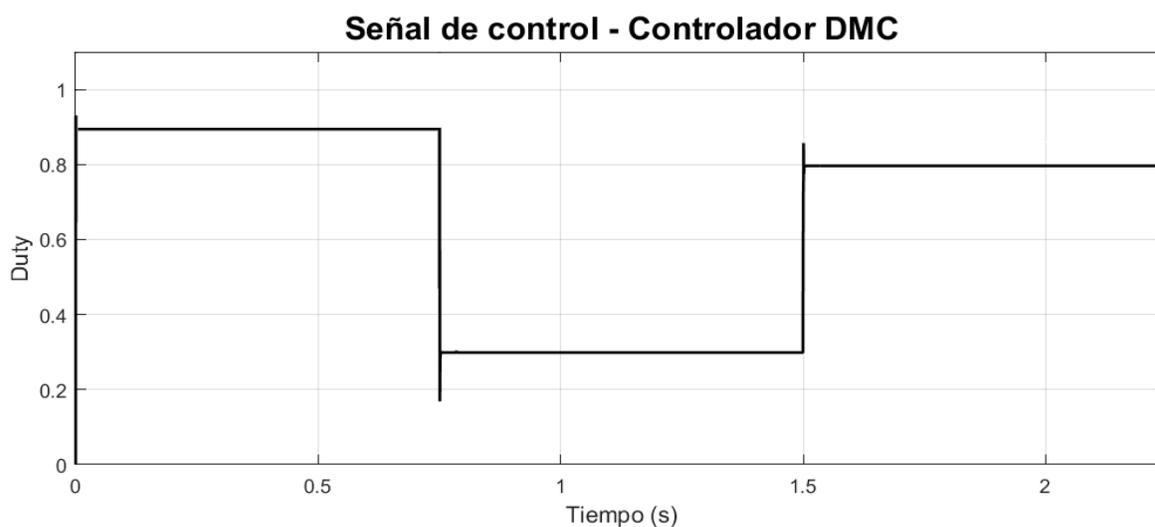
Con respecto al tiempo de establecimiento y la tensión en la carga se determina que:

- Para 180 V,  $t_s = 0,02 s$ ,  $v_o = 180 V$ .
- Para 30 V,  $t_s = 0,754 s$ ,  $v_o = 30 V$ .
- Para 100 V,  $t_s = 1,502 s$ ,  $v_o = 100 V$ .

Además se presenta la señal de control (figura 48) que ha sido aplicada al controlador DMC para cumplir con la referencia requerida.



*Figura 47:* Controlador DMC



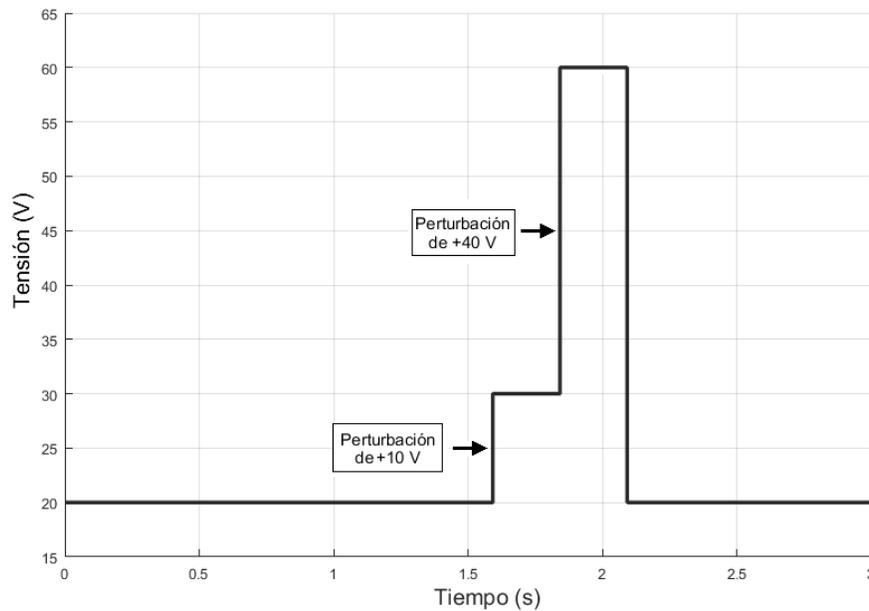
*Figura 48:* Señal de control del Controlador DMC

Se puede apreciar, con la comparación entre las figuras 43, 45 y 47, que el desempeño de los controladores es satisfactorio. Sin embargo, la estrategia que posee mejores características es el controlador DMC, ya que presenta el menor sobreimpulso, los tiempos de establecimiento en cada uno de los cambios son los más rápidos y cumplen con los requerimientos del convertidor.

Además el valor que alcanza la señal de salida sigue exitosamente a la tensión de referencia.

#### 4.1.2. Perturbaciones en la tensión de entrada

En las siguientes pruebas se evalúa el comportamiento del convertidor *Boost* ante perturbaciones en la tensión de entrada con la señal de referencia de la figura 22. Las perturbaciones han sido realizadas cuando la tensión de salida logra estabilizarse en los  $90\text{ V}$ . Entonces, las variaciones de la tensión de entrada están en el rango de  $20\text{ V}$  a  $75\text{ V}$ , por ello se establece que:  $E = 30\text{ V}$  en el intervalo de  $1,65 \leq t < 1,90$  y  $E = 60\text{ V}$  en el intervalo de  $1,90 < t \leq 2,15$ , como se muestra en la figura 49.



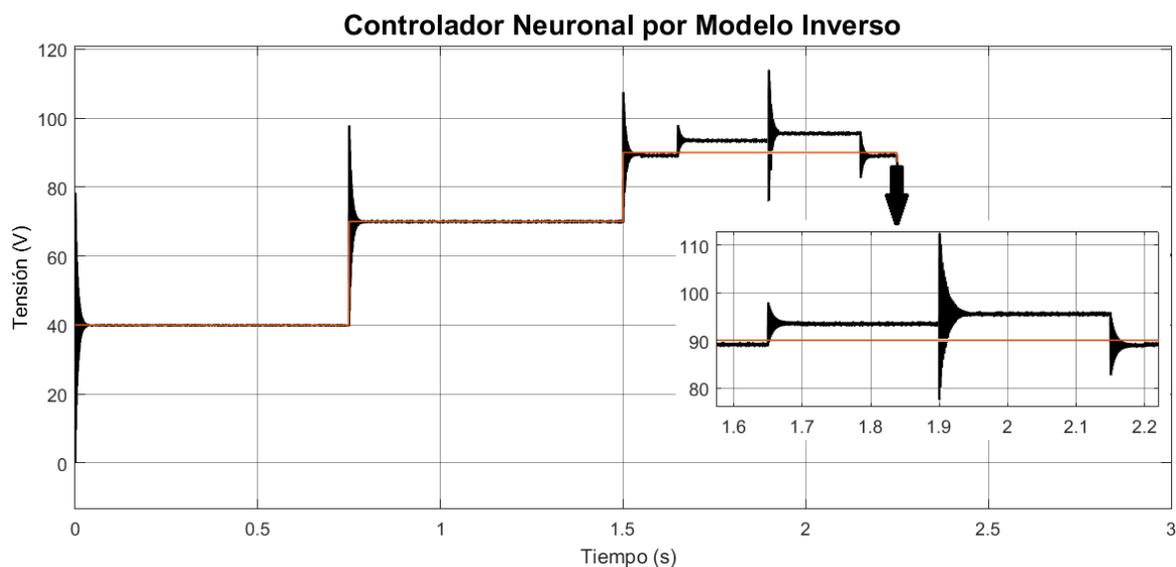
**Figura 49:** Perturbación en la tensión de entrada

Para la introducción de las perturbaciones en la tensión de entrada es necesario especificar que tanto para el controlador neuronal por modelo inverso y el controlador PID con redes neuronales se ha utilizado el bloque de construcción de señales de *Simulink*. En cambio para

el controlador DMC se ha utilizado la función de transferencia discreta en función de  $E$  para lograr sus variaciones, su código puede ser revisado en el Anexo H.

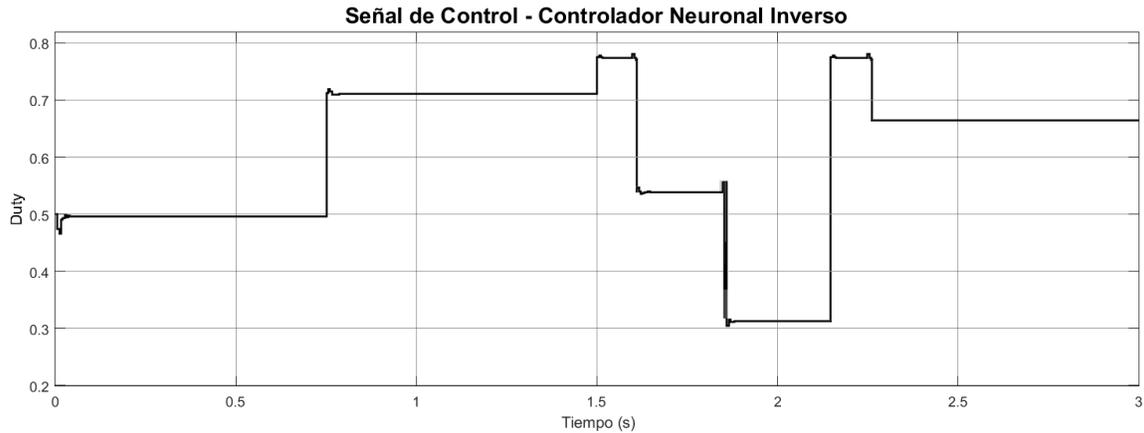
### Controlador Neuronal por Modelo Inverso

En la figura 50 se muestra el comportamiento del controlador neuronal por modelo inverso ante perturbaciones en la tensión de entrada. Como se observa en la figura 50 se han realizado cambios en la tensión cuando se estabilizan los 90 V. Se ha echo un acercamiento y es claro notar que existen alteraciones momentáneas en la respuesta del controlador en  $t = 1,65 s$ ,  $t = 1,9 s$  y  $t = 2,15 s$ , sin embargo, la tensión de salida logra estabilizarse en 93 V.



**Figura 50:** Perturbación de entrada en el controlador neuronal inverso

Además, se puede observar mediante la figura 51 la respuesta obtenida de la acción de control aplicada al controlador neuronal por modelo inverso ante las perturbaciones ocasionadas por la tensión de entrada.

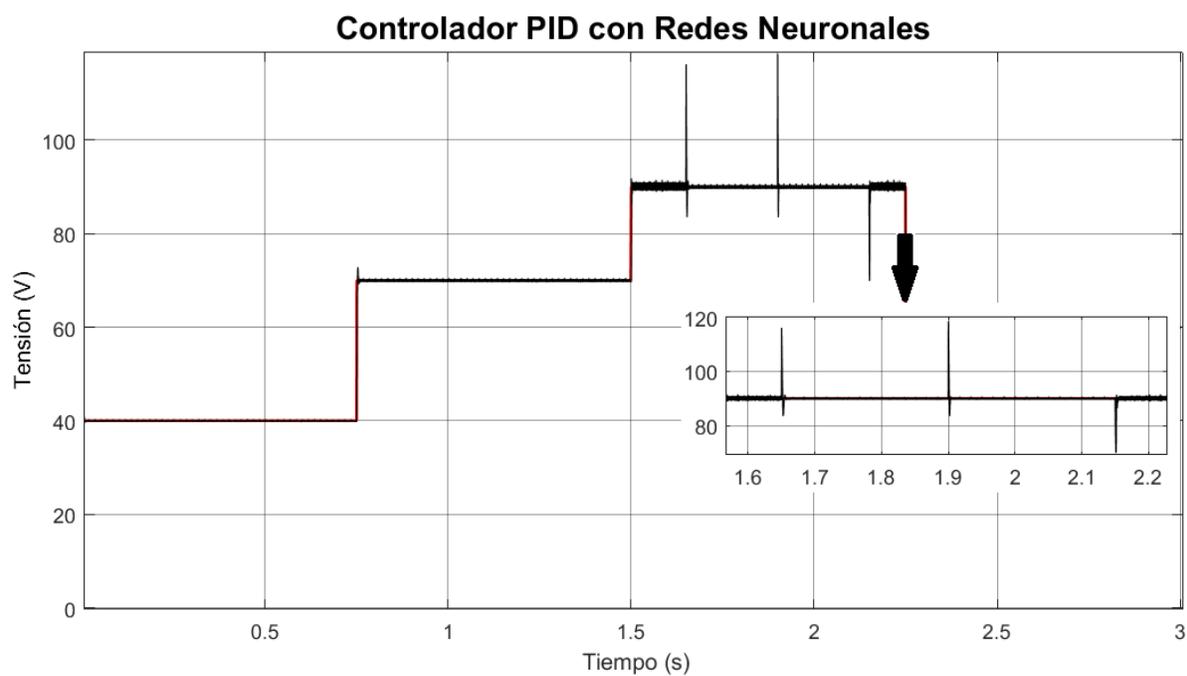


**Figura 51:** Señal de control ante perturbaciones en la entrada

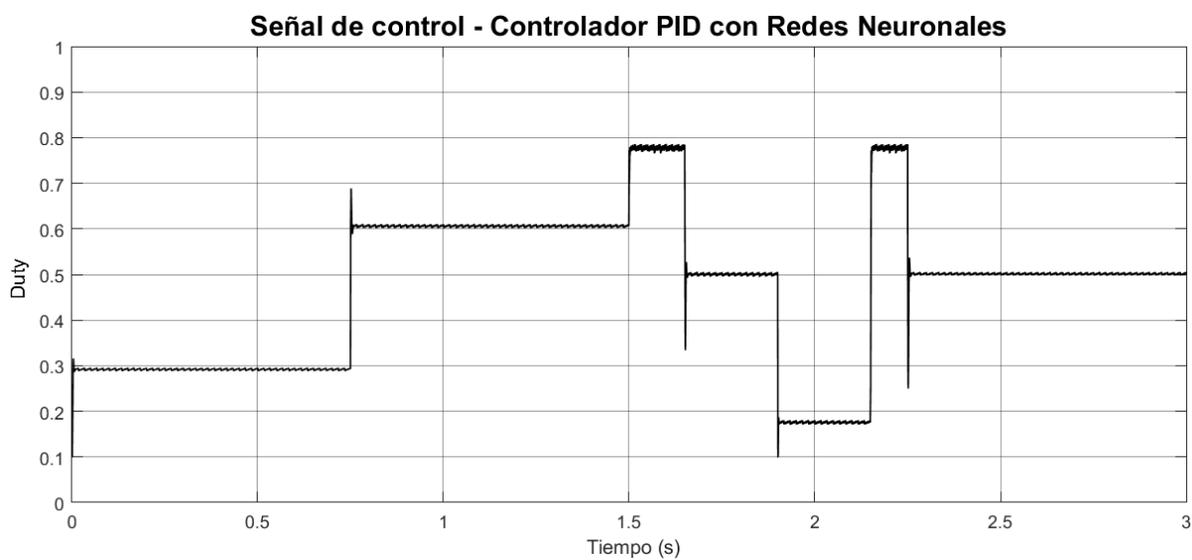
### Controlador PID con Redes Neuronales

En la figura 52 se muestra el comportamiento del controlador PID con redes neuronales ante perturbaciones en la tensión de entrada. Se ha echo un acercamiento y es claro notar que aunque aumenta la amplitud de la respuesta del controlador en  $t = 1,65 s$ ,  $t = 1,9 s$  y  $t = 2,15 s$  la tensión de salida logra estabilizarse en  $90 V$ .

Además, se puede observar mediante la figura 53 la respuesta obtenida de la acción de control aplicada al controlador PID con redes neuronales ante las perturbaciones ocasionadas por la tensión de entrada.



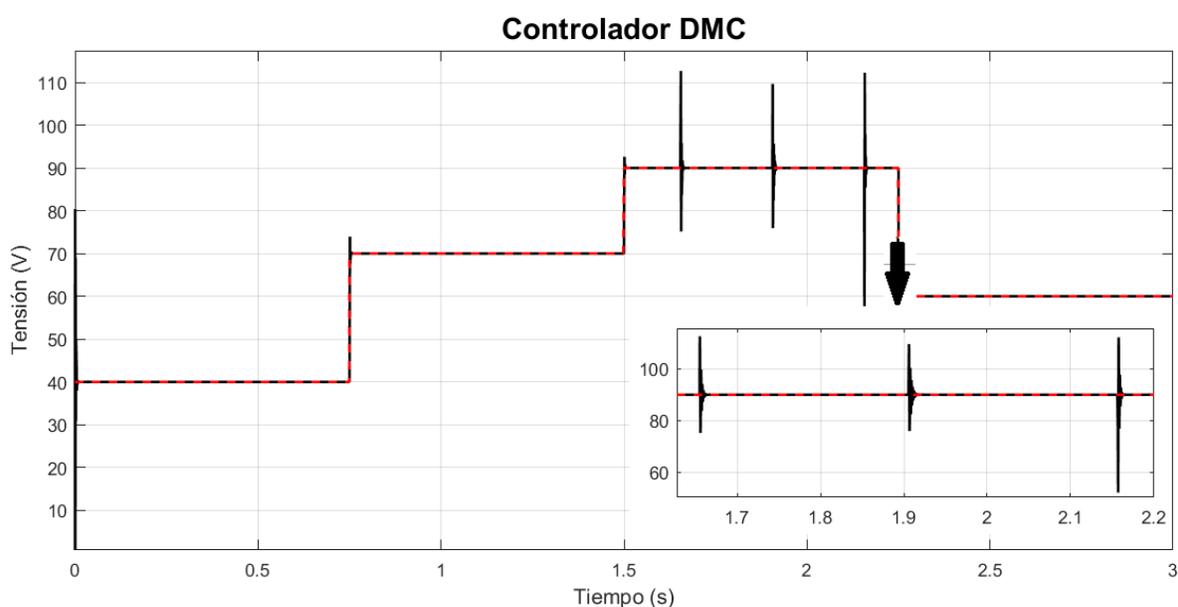
*Figura 52:* Perturbación de entrada en el controlador PID con redes neuronales



*Figura 53:* Señal de control ante perturbaciones en la entrada

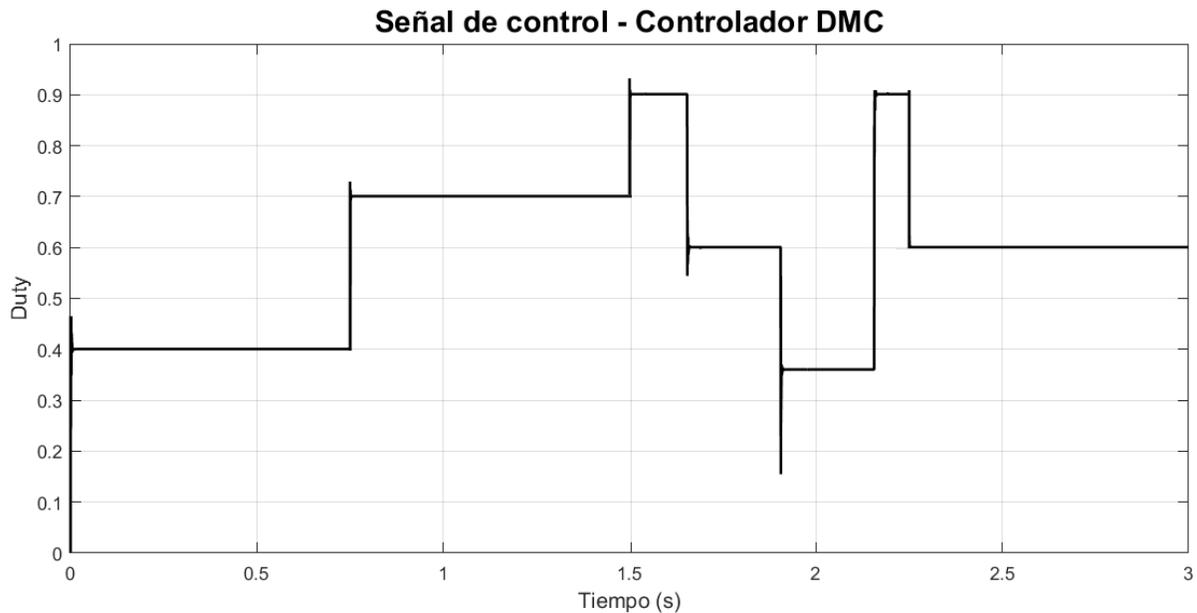
## Controlador Predictivo por Matriz Dinámica

Mediante la figura 54 se muestra el comportamiento del controlador predictivo por matriz dinámica ante perturbaciones en la tensión de entrada. Se ha echo un acercamiento y es claro notar que aunque aumenta la amplitud de la respuesta del controlador en  $t = 1,65 s$ ,  $t = 1,9 s$  y  $t = 2,15 s$  la tensión de salida logra estabilizarse en  $90 V$ .



*Figura 54:* Perturbación de entrada en el controlador DMC

Además, se puede observar mediante la figura 55 la respuesta obtenida de la acción de control aplicada al controlador DMC ante las perturbaciones ocasionadas por la tensión de entrada.



**Figura 55:** Señal de control ante perturbaciones en la entrada

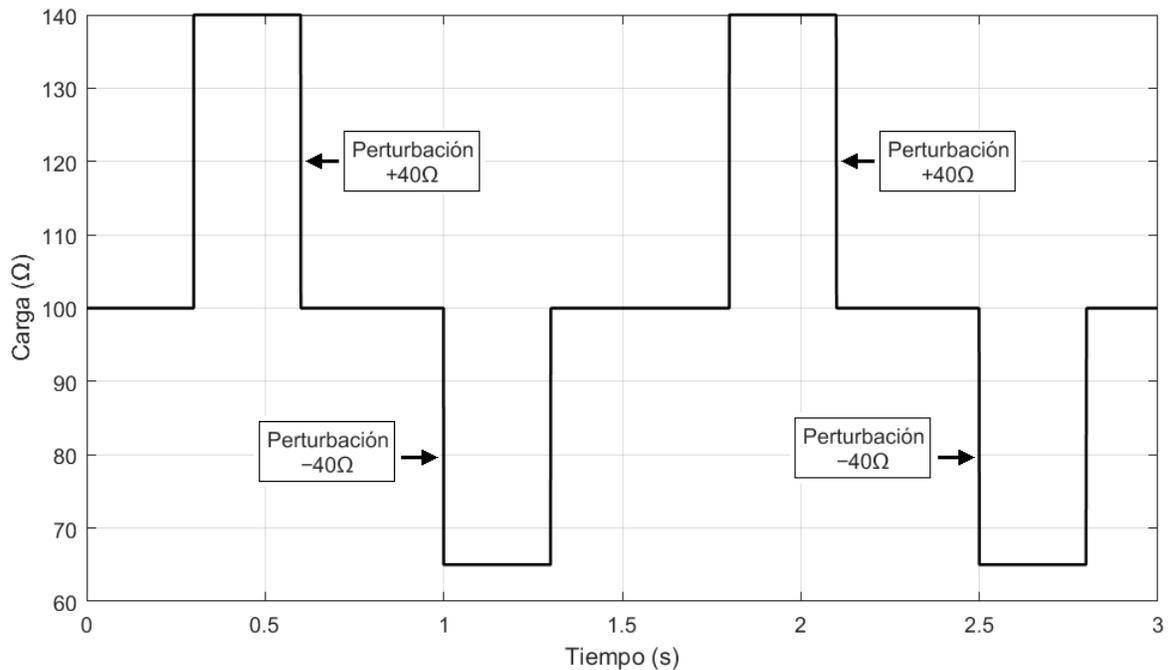
### 4.1.3. Perturbaciones en la carga

En las siguientes pruebas se evalúa el comportamiento del convertidor *Boost* ante perturbaciones en la carga. Se han considerado cambios del 40% tanto por encima como por debajo del valor nominal ( $R = 100\ \Omega$ ), como lo sugieren (Ochoa Arredondo y Rodríguez Campiño, 2017) y (D'Alessio y otros., 2014). Se podrá visualizar los incrementos y disminuciones máximos a los que el convertidor estará expuesto por dichas perturbaciones. La señal de referencia que será utilizada es la mostrada en la figura 22.

Las perturbaciones han sido aplicadas al convertidor *Boost* cuando la tensión de salida es estable. Para los 40 V y 90 V se ha cambiado el valor de la carga a  $R = 140\ \Omega$  en el intervalo de  $0,3 \leq t \leq 0,6$  y  $1,8 \leq t \leq 2,1$  respectivamente.

Para los 70 V y 60 V se ha cambiado el valor de la carga a  $R = 65\ \Omega$  en el intervalo de

$1 \leq t \leq 1,3$  y  $2,5 \leq t \leq 2,8$  respectivamente. Durante los tiempos no mencionados, la carga tiene su valor nominal. Como se muestra en la figura 56.

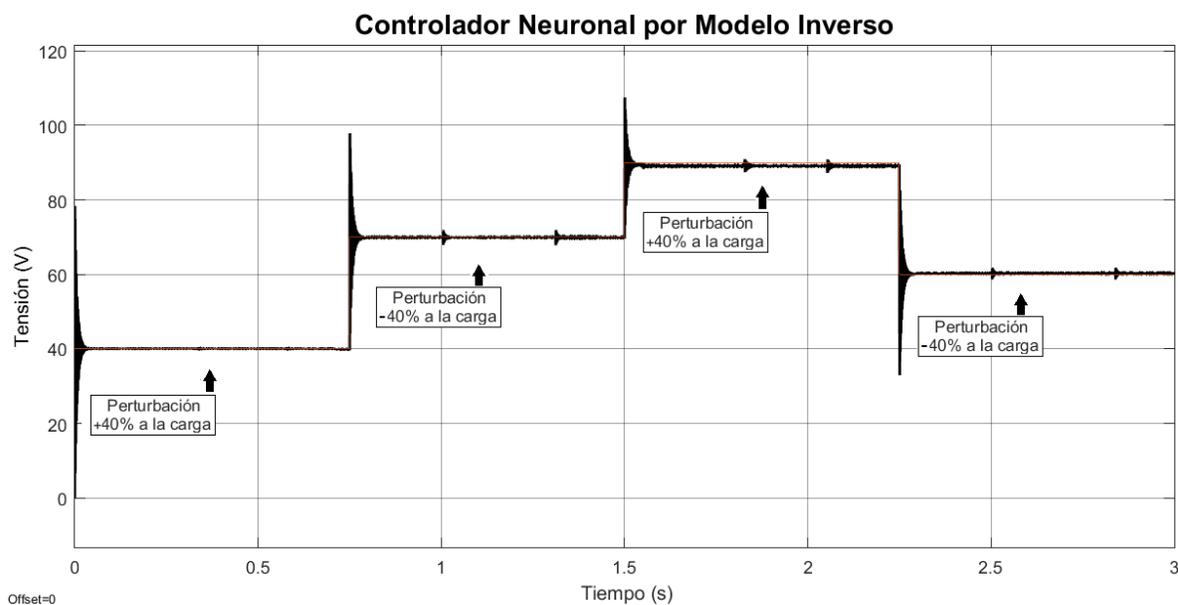


**Figura 56:** Perturbación en la carga

Para la introducción de las perturbaciones en la carga es necesario especificar que tanto para el controlador neuronal por modelo inverso y para el controlador PID con redes neuronales se han utilizado cargas externas conectadas en paralelo mediante un dispositivo de conmutación que logra la conexión y desconexión de las cargas en los tiempos de simulación establecidos. En cambio para el controlador DMC se ha utilizado la función de transferencia discreta en función de  $R$  para lograr sus variaciones, su código puede ser revisado en el Anexo I.

## Controlador Neuronal por Modelo Inverso

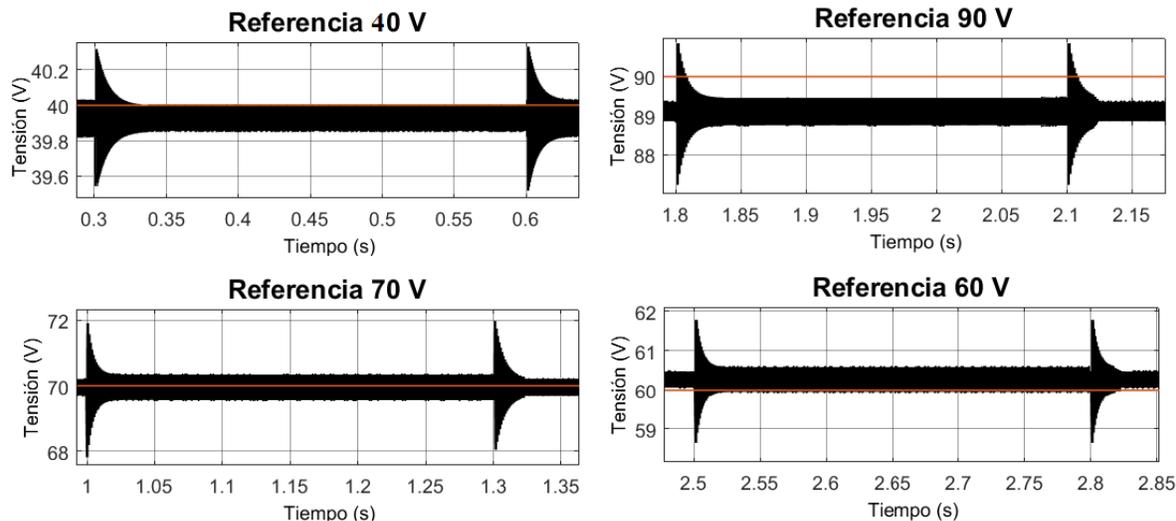
En la figura 57 se muestra el comportamiento del controlador neuronal por modelo inverso ante perturbaciones en la carga en diferentes valores de referencia.



**Figura 57:** Perturbaciones de carga en el controlador neuronal inverso

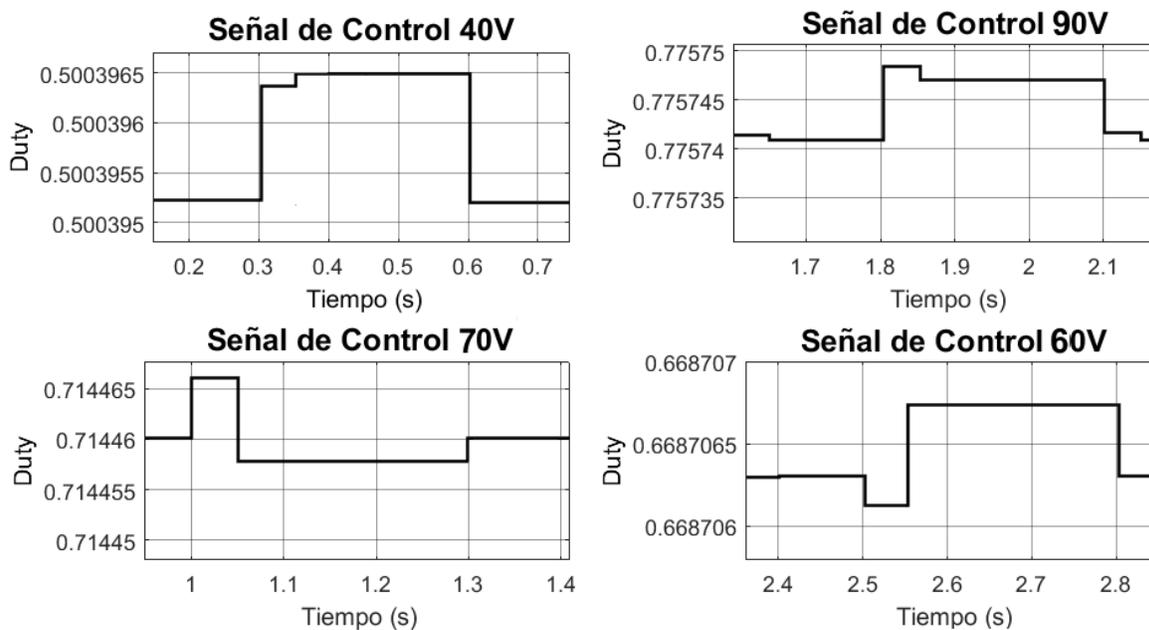
A continuación se muestra un acercamiento para cada una de las perturbaciones realizadas en cada referencia. Como se observa en la figura 58, en los 40 V existe una variación de  $\pm 0,4 V$ , en los 90 V una de  $\pm 1,8 V$  tanto cuando inicia y finaliza la perturbación de  $140 \Omega$ . Además, cuando la referencia es de 70 V y 60 V hay una variación de  $\pm 2 V$  y  $\pm 1,7 V$  respectivamente ante la perturbación de  $65 \Omega$ .

Mediante el acercamiento es claro notar que los valores de tensión de salida obtenidos no son los valores de referencia requeridos. Por ejemplo para la referencia de 90 V se observa que la tensión llega a ser 89 V, en cambio para 40 V, 70 V y 60 V la variación es menor a 1 V.



*Figura 58:* Perturbación en la carga para cada referencia

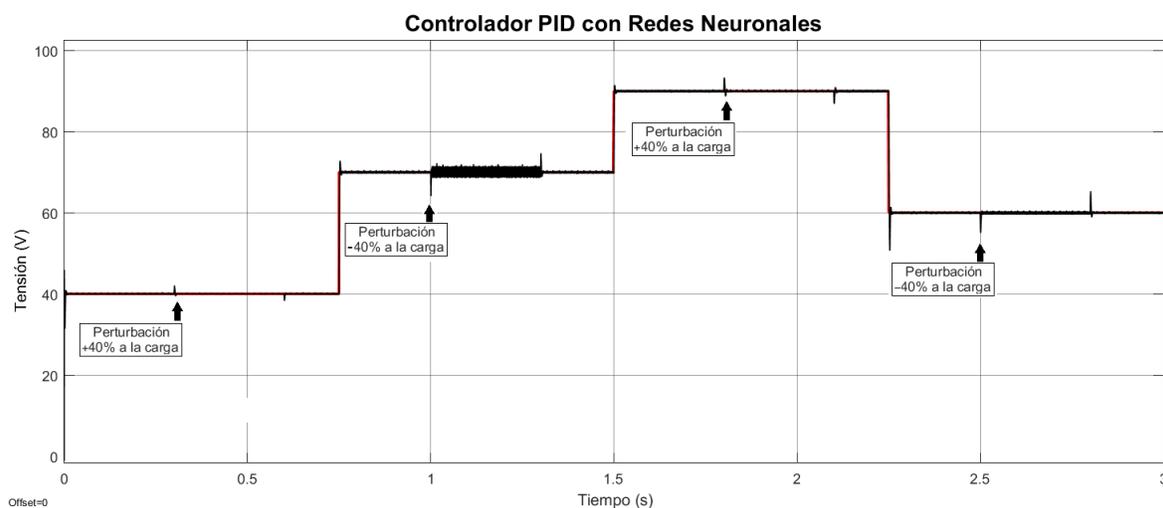
En cuanto a la señal de control, se observa mediante la figura 59 que la acción de control aplicada al convertidor se comporta de acuerdo a lo requerido por las diferentes referencias, la variación del ciclo de trabajo es mínima.



*Figura 59:* Señal de control ante perturbaciones en la carga

## Controlador PID con Redes Neuronales

En la figura 60 se muestra el comportamiento del controlador PID con redes neuronales ante perturbaciones en la carga en diferentes tensiones de salida.

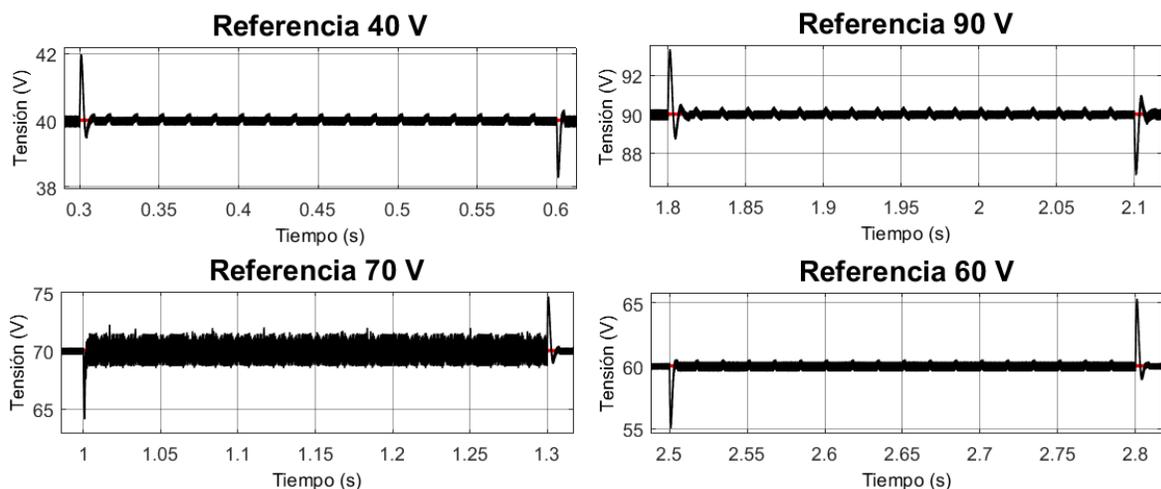


**Figura 60:** Perturbaciones de carga en el controlador PID con redes neuronales

A continuación se muestra un acercamiento para cada una de las perturbaciones realizadas en cada referencia. Como se observa, en la figura 61, en los 40 V existe una variación de  $\pm 1,8 V$ , en los 90 V una de  $\pm 3,5 V$  tanto cuando inicia y finaliza la perturbación de 140  $\Omega$ . Además, cuando la referencia es de 70 V y 60 V hay una variación de  $\pm 5 V$  ante la perturbación de 65  $\Omega$ .

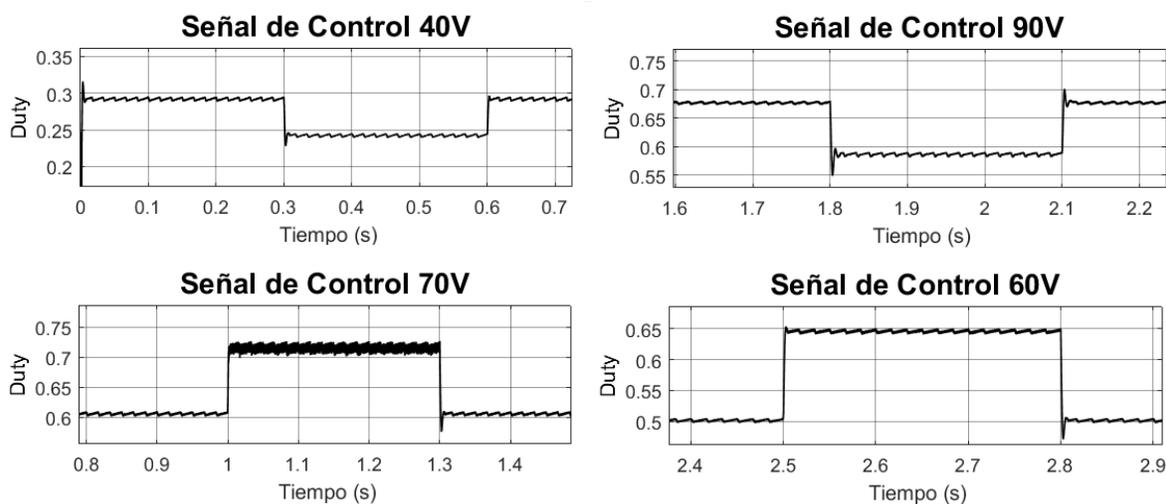
En base a la figura 61 se puede observar que aunque existen transitorios grandes en el momento en que se realiza el cambio del valor de la carga, los valores de referencia requeridos se estabilizan bastante rápido.

Para un completo análisis del comportamiento del controlador PID con redes neuronales ante perturbaciones en la carga es necesario presentar la señal de control que ha sido aplicada



*Figura 61:* Perturbación en la carga para cada referencia

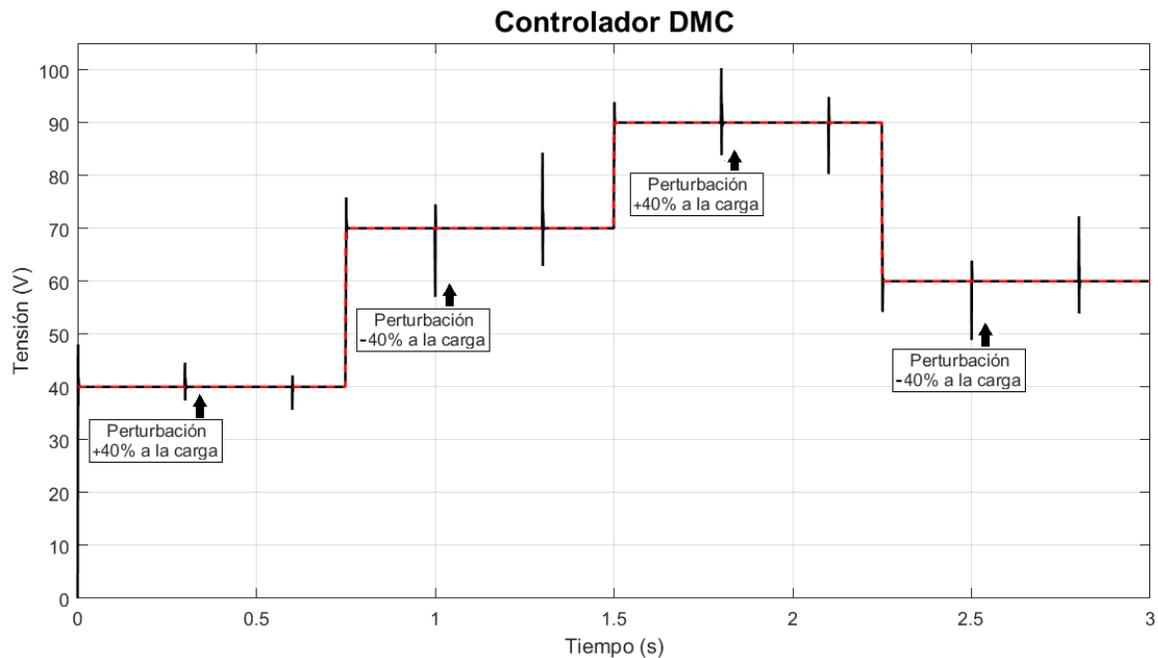
para cada una de las referencias requeridas. A través de la figura 62 se observa que el cambio realizado por el ciclo de trabajo es relativamente pequeño para los valores de la carga.



*Figura 62:* Señal de control ante perturbaciones en la carga

## Controlador Predictivo por Matriz Dinámica

En la figura 63 se muestra el comportamiento del controlador predictivo por matriz dinámica ante perturbaciones en la carga en diferentes tensiones de salida.

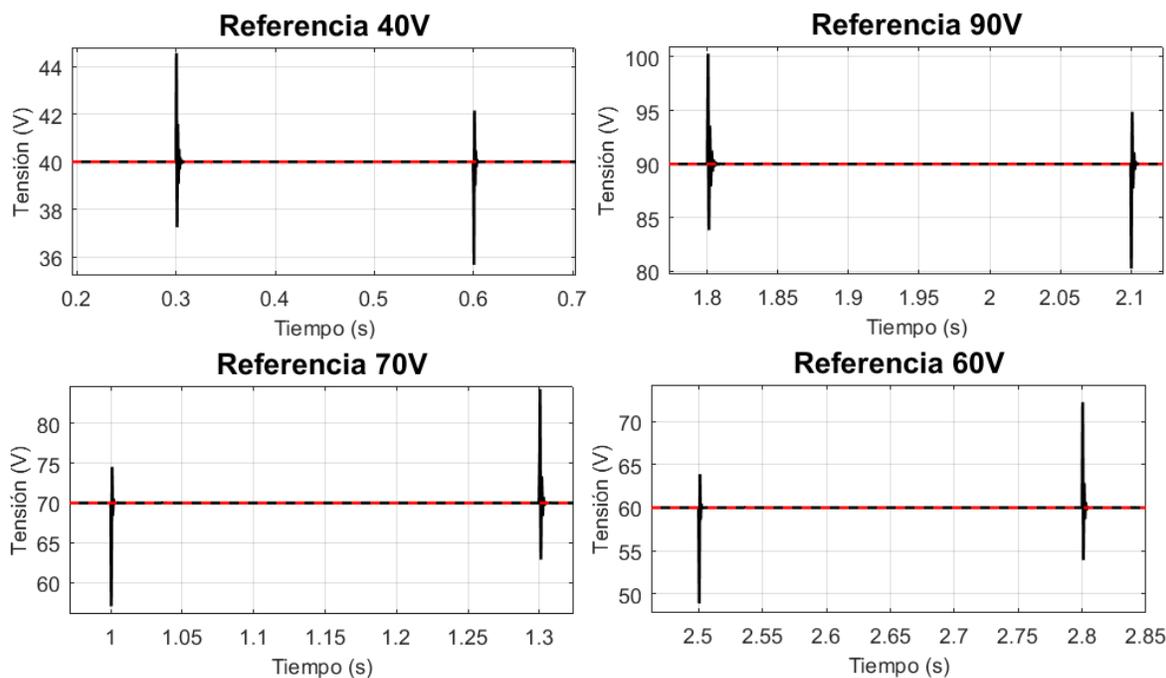


*Figura 63:* Perturbaciones de carga en el controlador DMC

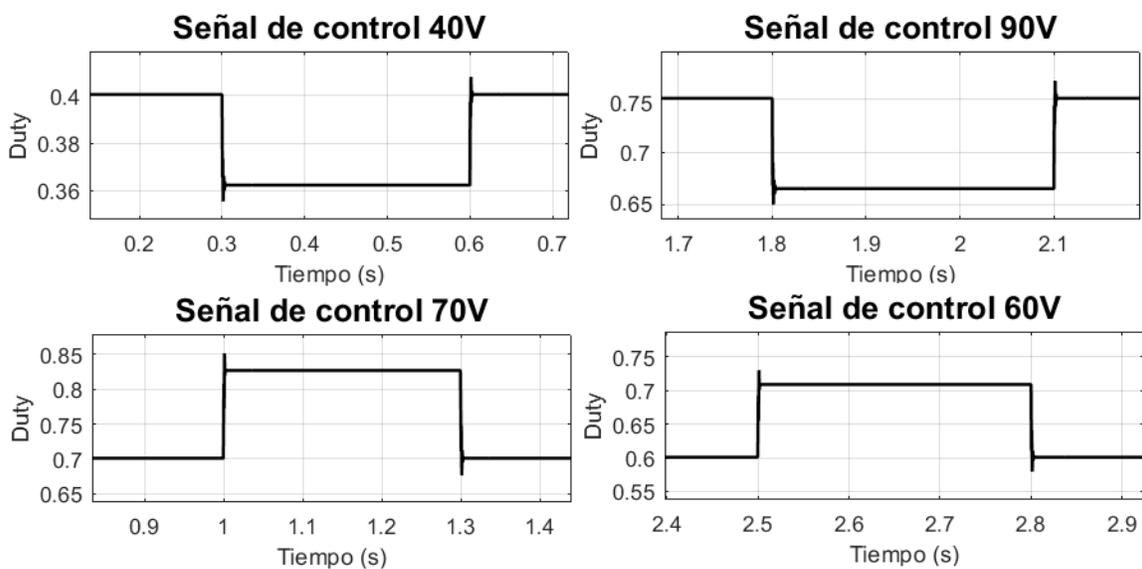
A continuación se muestra un acercamiento para cada una de las perturbaciones realizadas en cada referencia. Como se observa, en la figura 64, en los 40 V existe una variación de  $\pm 4,5 V$ , en los 90 V una de  $\pm 9,5 V$  tanto cuando inicia y finaliza la perturbación de  $140 \Omega$ . Además, cuando la referencia es de 70 V y 60 V hay una variación de  $\pm 14 V$  y  $\pm 12 V$  respectivamente ante la perturbación de  $65 \Omega$ .

Mediante la figura 64 es claro notar que este controlador pese a tener los transitorios más elevados en el momento de las perturbaciones logra estabilizarse en la tensión requerida sin oscilaciones y es bastante rápido.

Para el completo análisis, a continuación, se presenta un acercamiento a la señal de control aplicada al controlador DMC.



*Figura 64:* Perturbación en la carga para cada referencia



*Figura 65:* Señal de control ante perturbaciones en la carga

Como se observa en la figura 65 las acciones de control aplicadas al convertidor *Boost* responden adecuadamente para cada una de las tensiones de referencia.

## 4.2. Análisis de Desempeño de Controladores

En esta subsección se presentan tablas comparativas de tiempos de respuesta y tensiones de salida para cada una de las perturbaciones que han sido aplicadas al convertidor. Estas comparaciones son realizadas entre los controladores basados en redes neuronales y el controlador DMC. Además se presenta un análisis del consumo computacional de cada uno de los controladores simulados.

### Cambios en la tensión de referencia

En primera instancia se realizan tablas comparativas de los tiempos de respuesta obtenidos en cada controlador al enfrentarse a cambios bruscos en la tensión de referencia.

- Controlador neuronal por modelo inverso frente al controlador DMC.

**Tabla 2**

*Tiempos de respuesta del controlador neuronal por modelo inverso vs el controlador DMC*

Referencia	Neuronal por Modelo Inverso ( $t_s$ )	DMC ( $t_s$ )
180 V	0,041 s	0,020 s
30 V	0,051 s	0,004 s
100 V	0,082 s	0,003 s

- Controlador PID con redes neuronales frente al controlador DMC.

**Tabla 3**

*Tiempos de respuesta controlador PID con redes neuronales vs controlador DMC.*

Referencia	PID con Redes Neuronales ( $t_s$ )	DMC ( $t_s$ )
180 V	0,045 s	0,020 s
30 V	0,060 s	0,004 s
100 V	0,003 s	0,003 s

Según los resultados presentados en las tablas 2 y 3 es claro notar que el tiempo de respuesta del controlador DMC es mucho más rápido que los presentados por los controladores neuronales. Sin embargo, es importante recalcar que el controlador con mayor tiempo de respuesta es el PID con redes neuronales.

A continuación se presentan las tablas comparativas de las tensiones de salida obtenidas en cada controlador al enfrentarse a cambios bruscos en la referencia.

- Controlador neuronal por modelo inverso frente al controlador DMC.

**Tabla 4**

*Tensión de salida controlador neuronal por modelo inverso vs controlador DMC.*

Referencia	Neuronal por Modelo Inverso ( $v_o$ )	DMC ( $v_o$ )
180 V	179,80 V	180 V
30 V	29,90 V	30 V
100 V	98,70 V	100 V

- Controlador PID con redes neuronales frente al controlador DMC.

**Tabla 5**

*Tensión de salida controlador PID con redes neuronales vs controlador DMC.*

Referencia	PID con Redes Neuronales ( $v_o$ )	DMC ( $v_o$ )
180 V	179,92 V	180 V
30 V	29,97 V	30 V
100 V	100,75 V	100 V

Según los resultados presentados en las tablas 4 y 5 el valor de tensión de salida con respecto a la referencia es exacto para el controlador DMC. En cambio en los controladores neuronales los valores de tensión no presenta un error mayor al 1,5%.

Para este primer análisis se ha observado que el controlador DMC presenta los menores tiempos de respuesta y sigue a la referencia con exactitud.

### Perturbaciones en la tensión de entrada

Se realizan tablas comparativas de los tiempos de respuesta de cada uno de los controladores ante perturbaciones en la tensión de entrada ( $E$ ).

- Controlador neuronal por modelo inverso frente al controlador DMC.

**Tabla 6**

*Tiempos de respuesta controlador neuronal inverso vs controlador DMC.*

Referencia	Tensión de entrada ( $E$ )	Neuronal por Modelo Inverso ( $t_s$ )	DMC ( $t_s$ )
90 V	30 V	0,050 s	0,010 s
90 V	60 V	0,065 s	0,014 s

- Controlador PID con redes neuronales frente al controlador DMC.

**Tabla 7**

*Tiempos de respuesta controlador PID con redes neuronales vs controlador DMC.*

Referencia	Tensión de entrada ( $E$ )	PID con Redes Neuronales ( $t_s$ )	DMC ( $t_s$ )
90 V	30 V	0,017 s	0,010 s
90 V	60 V	0,031 s	0,014 s

Según los resultados presentados en las tablas 6 y 7 el controlador que presenta los menores tiempos de respuesta ante perturbaciones en la tensión de entrada es el controlador DMC. En cambio el controlador neuronal por modelo inverso es el que tiene los mayores tiempos de respuesta.

A continuación se presentan las comparaciones de las tensiones de salida obtenidas en cada controlador frente a perturbaciones en la tensión de entrada.

- Controlador neuronal por modelo inverso frente al controlador DMC.

**Tabla 8**

*Tensión de salida controlador neuronal por modelo inverso vs controlador DMC.*

Referencia	Tensión de entrada ( $E$ )	Neuronal por Modelo Inverso ( $v_o$ )	DMC ( $v_o$ )
90 V	30 V	94 V	90 V
90 V	60 V	94 V	90 V

- Controlador PID con redes neuronales frente al controlador DMC.

**Tabla 9**

*Tensión de salida controlador PID con redes neuronales vs controlador DMC.*

Referencia	Tensión de entrada ( $E$ )	PID con Redes Neuronales ( $v_o$ )	DMC ( $v_o$ )
90 V	30 V	90,5 V	90 V
90 V	60 V	90,5 V	90 V

Según los resultados presentados en las tablas 8 y 9 el controlador DMC nuevamente sigue con exactitud al valor de referencia. Sin embargo, en los controladores neuronales se puede decir que el controlador por modelo inverso presenta un error de 4 %, llegando a ser el más lejano al valor de referencia.

Para este análisis se observa que el controlador DMC tiene el menor tiempo de respuesta y es el más cercano al valor de referencia cuando se enfrenta a perturbaciones en la tensión de entrada.

## Perturbaciones en la carga

Se realizan tablas comparativas de los tiempos de respuesta obtenidos en cada controlador al enfrentarse a perturbaciones en la carga.

- Controlador neuronal por modelo inverso frente al controlador DMC.

**Tabla 10**

*Tiempos de respuesta controlador neuronal inverso vs controlador DMC.*

Referencia	Carga ( $R$ )	Neuronal por Modelo Inverso ( $t_s$ )	DMC ( $t_s$ )
40 V	140 $\Omega$	0,040 s	0,003 s
70 V	65 $\Omega$	0,021 s	0,002 s
90 V	140 $\Omega$	0,035 s	0,005 s
60 V	65 $\Omega$	0,021 s	0,003 s

- Controlador PID con redes neuronales frente al controlador DMC.

**Tabla 11**

*Tiempos de respuesta controlador PID con redes neuronales vs controlador DMC.*

Referencia	Carga ( $R$ )	PID con Redes Neuronales ( $t_s$ )	DMC ( $t_s$ )
40 V	140 $\Omega$	0,005 s	0,003 s
70 V	65 $\Omega$	0,008 s	0,002 s
90 V	140 $\Omega$	0,007 s	0,005 s
60 V	65 $\Omega$	0,006 s	0,003 s

Según los resultados presentados en las tablas 10 y 11 el controlador DMC presenta los menores tiempos de respuesta ante perturbaciones en la carga. Sin embargo, en cuanto a los controladores neuronales, se observa que el tiempo de respuesta del PID con redes neuronales es mucho más rápido que el de modelo inverso.

A continuación se presentan las comparaciones de las tensiones de salida obtenidas en cada controlador frente a perturbaciones en la carga.

- Controlador neuronal por modelo inverso frente al controlador DMC.

**Tabla 12**

*Tensión de salida controlador neuronal inverso vs controlador DMC.*

Referencia	Carga ( $R$ )	Neuronal por Modelo Inverso ( $v_o$ )	DMC ( $v_o$ )
40 V	140 $\Omega$	39,95 V	40 V
70 V	65 $\Omega$	70 V	70 V
90 V	140 $\Omega$	89 V	90 V
60 V	65 $\Omega$	60,5 V	60 V

- Controlador PID con redes neuronales frente al controlador DMC.

**Tabla 13**

*Tensión de salida controlador PID con redes neuronales vs controlador DMC.*

Referencia	Carga ( $R$ )	PID con Redes Neuronales( $v_o$ )	DMC ( $v_o$ )
40 V	140 $\Omega$	40 V	40 V
70 V	65 $\Omega$	70,5 V	70 V
90 V	140 $\Omega$	89,8 V	90 V
60 V	65 $\Omega$	60 V	60 V

Finalmente, según los resultados presentados en las tablas 12 y 13 el controlador DMC nuevamente sigue con exactitud al valor de referencia. Sin embargo, en cuanto a los controladores neuronales se puede decir que ambos muestran un comportamiento adecuado, presentando un error menor al 1 %.

Para este análisis se observa que el controlador con menor tiempo de respuesta y que sigue con exactitud a la tensión de referencia es el controlador DMC.

## Consumo computacional

Otro factor de gran importancia en este estudio comparativo es la evaluación del tiempo de ejecución de cada uno de los controladores aplicados al convertidor *Boost*. Para ello es necesario especificar las características del computador y herramientas de software que han sido utilizadas.

Para todas las simulaciones se ha utilizado un computador Dell con procesador Intel® Core (TM) i7-7500U, sus características se describen en la tabla 14. Además se ha utilizado el software MatLab® en la versión R2016b.

**Tabla 14**

*Especificaciones del procesador Intel® Core (TM) i7-7500U.*

<b>Performance</b>	
# de núcleos	2
# de subprocesos	4
Frecuencia básica del procesador	2,70 GHz
Frecuencia turbo máxima	3,50 GHz
Caché	4 MB SmartCache

A continuación se presentan los diferentes tiempos de ejecución que han sido obtenidos de cada controlador. Se han usado los comandos “tic” y “toc”, ya que permiten medir el tiempo que le toma a MatLab® para finalizar las simulaciones. Cabe mencionar que a se ha tomado cinco muestras las que han sido promediadas para así obtener el tiempo de ejecución.

**Tabla 15**

*Tiempo de ejecución de las simulaciones.*

<b>CONTROLADOR</b>	<b>Muestras</b>					<b>Promedio</b>
Neuronal por Modelo Inverso	25,91 s	26,16 s	27,08 s	25,89 s	26,60 s	26,33 s
PID con Redes Neuronales	78,96 s	84,10 s	77,41 s	78,78 s	78,84 s	44,1 s
DMC	75,81 s	84,43 s	78,02 s	77,20 s	92,22 s	81,54 s

Los resultados presentados en la tabla 15 permiten elegir al controlador con menor tiempo de ejecución. Para este caso el controlador neuronal por modelo inverso es el que presenta menor tiempo con 26,33 s y el controlador DMC es el que tiene mayor tiempo con 81,54 s.

## CONCLUSIONES

Se han diseñado y simulado tres estrategias de control avanzado aplicadas al convertidor elevador Boost, dos de las cuáles se basan en redes neuronales y una en control predictivo. Se comprueba que cada controlador presentado es capaz de regular la tensión de salida que requiere la referencia y sus respuestas de control son fiables.

Como primera estrategia de control basada en redes neuronales se optó por el controlador neuronal por modelo inverso ya que es la estrategia básica del control neuronal. Si bien su respuesta es satisfactoria, su alto sobreimpulso no la hace apta para un convertidor Boost. Es por ello que fue necesario optar por una estrategia con mejores prestaciones como lo es el controlador PID basado en redes neuronales.

Al evaluar que tan complejo puede llegar a ser el diseño de cada controlador. Se puede concluir que sino se cuenta con un modelo matemático que se ajuste bastante bien a la planta no se puede llegar a diseñar ni el controlador DMC ni el controlador PID con redes neuronales. Sin embargo una de las ventajas del controlador neuronal por modelo inverso es que no

necesita del modelo matemático para su diseño.

Se comprobó que al realizar cambios bruscos en la tensión de referencia todos los controladores son capaces de regular la tensión de salida. Sin embargo el controlador predictivo DMC es la mejor opción, ya que logra regular exactamente la tensión de salida y su tiempo de establecimiento es el menor.

Al provocar perturbaciones en la tensión de entrada el controlador neuronal por modelo inverso es la opción mas débil, esto se debe a su que su tiempo de respuesta es el más elevado y logra seguir a la tensión de referencia con un error del 4%. A diferencia del controlador DMC que sigue satisfactoriamente a la referencia y responde de manera inmediata ante las perturbaciones.

Al realizarse cambios en la carga, el controlador DMC se impone sobre los controladores neuronales. Esto debido a que su tiempo de establecimiento es mucho menor que el de ambos. Y la tensión de salida no presenta variación como las de los neuronales. Además debido a la robustez que posee se puede exigir un mayor desempeño frente a las perturbaciones en la carga, donde puede ser variada 180% por encima como 80% por debajo del valor nominal.

Al analizar el comportamiento del controlador DMC se comprueba su superioridad frente a las otras estrategias. Debido a su bajo tiempo de establecimiento y mejor respuesta ante perturbaciones. Sin embargo una de las desventajas que ha sido puesta en evidencia en el

presente estudio es su alto requerimiento de cálculo. Se demostró que este controlador es el que más tiempo de ejecución toma para su simulación.

Al término de la evaluación del comportamiento de cada controlador se elige como mejor opción al controlador DMC, debido a que es el que presenta mejor respuesta ante perturbaciones y responde de manera de inmediata a cambios bruscos en la referencia y la carga. Además presenta menor oscilación en su respuesta, contrario a los controladores neuronales que presenta un rizado de tensión de salida de 1,5 %.

Se demostró que el controlador DMC requiere de mayor consumo computacional, esto se debe a la gran cantidad de operaciones matemáticas que requiere para obtener la señal de control. Esta es una gran desventaja, sin embargo es el precio que debe pagarse para obtener la robustez del mismo.

## Referencias

- Alarcón Cot, E. J. (2000), *Diseño microelectrónico de controladores para convertidores conmutados continua-continua*, Universitat Politècnica de Catalunya.
- Banerjee, S. y Verghese, G. C. (1999), *Nonlinear phenomena in power electronics*, IEEE.
- Barrionuevo Grijalva, C. P., y otros. (2013), *Control adaptativo de una lámpara HID de 250 W*.
- Bouami, M. F. (2005), *Desarrollo y optimización de nuevos modelos de redes neuronales basadas en funciones de base radial*.
- Camacho, E. F. y Alba, C. B. (2013), *Model predictive control*, Springer Science & Business Media.
- Camacho, E. F. y Bordons, C. (2004), *Control Predictivo: pasado, presente y futuro*, en Revista Iberoamericana de Automática e Informática Industrial, Bd. 1, 3.
- Cevallos Espinoza, C. M. y Rojas Quishpe, D. J. (2018), *Diseño e implementación de un convertidor reductor CD/CD gobernado con diferentes estrategias de control, para el análisis comparativo de desempeño*.

- Clarke, D. W., y otros. (1987), *Generalized predictive control Part I. The basic algorithm*, en *Automatica*, Bd. 23, 2: 137–148.
- Cueli, J. R. (2005), *Control predictivo para procesos repetitivos*.
- Cutler, C. R. y Ramaker, B. L. (1980), *Dynamic matrix control?? A computer control algorithm*, en *joint automatic control conference*, 17, S. 72.
- D'Alessio, L. A., y otros. (2014), *Diseño y Construcción de un Convertidor Boost de Pequeña Potencia, con Propósitos Educativos y de Investigación*, en *ACI Avances en Ciencias e Ingenierías*, Bd. 6, 2.
- Durango, J. J. M., y otros. (2017), *Diseño y construcción de un convertidor dc/dc tipo Boost con PWM ajustable*, en *Scientia et technica*, Bd. 22, 1: 9–14.
- Erickson, R. W. y Maksimovic, D. (2007), *Fundamentals of power electronics*, Springer Science & Business Media.
- Garcia, C. E. y Morshedi, A. M. (1986), *Quadratic programming solution of dynamic matrix control (QDMC)*, en *Chemical Engineering Communications*, Bd. 46, 1-3: 73–87.
- Grasa, R. L., y otros. (2000), *Control de convertidores conmutados mediante técnicas no lineales: pasividad, linealización, entrada-salida y redes neuronales*.
- Hilera González, J. R. y Martínez Hernando, V. J. (2000), *Redes neuronales artificiales: fundamentos, modelos y aplicaciones*.

- Iglesias, E. J., y otros. (2006), *Tuning equation for dynamic matrix control in SISO loops*, en *Ingeniería y desarrollo*, , 19.
- Katsuhiko, O. (1998), *Ingeniería de control moderna*, en Minnesota, PEARSON EDUCATION, S. 669–843.
- Kember, G. C., y otros. (2005), *Continuous analysis of move suppressed and shifted DMC*, en *ISA transactions*, Bd. 44, 1: 69–80.
- Khoshooei, A. y Moghani, J. S. (2004), *Implementation of a single input fuzzy controller for a high power factor boost converter*, en *TENCON 2004. 2004 IEEE Region 10 Conference*, Bd. 500, S. 69–72, IEEE.
- Liang, Y., y otros. (2006), *Bluegene/l failure analysis and prediction models*, en *Dependable Systems and Networks, 2006. DSN 2006. International Conference on*, S. 425–434, IEEE.
- Lin, J.-L., y otros. (2006), *Analysis and design for a novel single-stage high power factor correction diagonal half-bridge forward AC/DC converter*, en *IEEE Transactions on Circuits and Systems I: Regular Papers*, Bd. 53, 10: 2274–2286.
- Liu, Y.-F. y Sen, P. C. (2005), *Digital control of switching power converters*, en *Control Applications, 2005. CCA 2005. Proceedings of 2005 IEEE Conference on*, S. 635–640, IEEE.
- Malo, S. y Griñó, R. (2005), *Análisis y diseño de controladores lineales para el convertidor elevador (“Boost”) bidireccional en corriente*.
- Marquis, P. y Broustail, J. P. (1988), *SMOC, a bridge between state space and model predictive*

- controllers: application to the automation of a hydrotreating unit*, en IFAC Proceedings Volumes, Bd. 21, 4: 37–45.
- Marruedo, D. L. (2002), *Control predictivo de sistemas no lineales con restricciones: estabilidad y robustez*.
- Martinez, F. H. y Gómez, D. F. (2007), *Fuzzy logic controller for boost converter with active power factor correction*, en *7th International Conference on Power Electronics ICPE*, Bd. 7, S. 936–940.
- Martínez, J. A. R. (2015), *Diseño de un controlador óptimo usando redes neuronales dinámicas para un sistema de generación Eólica*.
- Martínez Sarmiento, F. H. y Castiblanco Ortiz, M. (2009), *Evaluación de control neuronal con arquitectura óptima para convertidor DC/DC*, en *Ingeniería e Investigación*; Vol. 29, núm. 3 (2009); 134-138 *Ingeniería e Investigación*; Vol. 29, núm. 3 (2009); 134-138 2248-8723 0120-5609.
- Millán, G. A. H., y otros. (2012), *Implementación de un Controlador PID Mediante RNA para el Control de Motores DC de Robots Mviles Diferenciales*, en *Scientia et technica*, Bd. 2, 50: 8–14.
- Nevot Cercós, J. (2000), *Diseño de un controlador avanzado basado en redes neuronales para la gestión de la mezcla aire-gasolina en un motor alternativo*, Universitat Politècnica de Catalunya.

- Nguyen, H. T., y otros. (2002), *A first course in fuzzy and neural control*, Chapman and Hall/CRC.
- Norgaard, M., y otros. (2000), *Neural networks for modelling and control of dynamic systems: a practitioner's handbook. Advanced textbooks in control and signal processing*, Springer, Berlin.
- Ochoa Arredondo, A. T. y Rodríguez Campiño, S. (2017), *Control en lazo cerrado de un convertidor CC/CC tipo Buck utilizando lógica difusa mediante la implementación de Arduino*.
- Ortiz Guevara, M. J. (2011), *Diseño y construcción de un conversor DC/DC reductor elevador con control predictivo controlado por una tarjeta FPGA*.
- Ouyang, Y.-C. y Yeh, L.-B. (2001), *Predictive bandwidth control for MPEG video: a wavelet approach for self-similar parameters estimation*, en *Communications, 2001. ICC 2001. IEEE International Conference on*, Bd. 5, S. 1551–1555, IEEE.
- Pérez, M., y otros. (2008), *Introducción a los sistemas de control y modelo matemático para sistemas lineales invariantes en el tiempo*, en Facultad de Ingeniería, Departamento de Electrónica y Automática, Universidad Nacional de San Juan.
- Pinzón Trejos, J. A. y Perdomo Borrero, Y. S. (2016), *Implementar un control predictivo por medio de redes neuronales en los convertidores Boost y VSC en un generador eólico*.
- Ponce Palomino, J. P. (2013), *Control ponderado por replicator dynamics para un convertidor de potencia dc-dc tipo boost*.

- Qin, H. y Kimball, J. W. (2014), *Closed-loop control of DC/DC dual-active-bridge converters driving single-phase inverters*, en IEEE Transactions on Power Electronics, Bd. 29, 2: 1006–1017.
- Quintero, C. M., y otros. (2013), *APLICACIÓN DE REDES NEURONALES AL CONTROL DE VELOCIDAD EN MOTORES DE CORRIENTE ALTERNA*, en REVISTA COLOMBIANA DE TECNOLOGIAS DE AVANZADA (RCTA), Bd. 2, 20.
- Richalet, J., y otros. (1978), *Model predictive heuristic control*, en Automatica (Journal of IFAC), Bd. 14, 5: 413–428.
- Rocha, C. y Escorcía, J. (2010), *Sistema de Visión Artificial para la Detección y el Reconocimiento de Señales de Tráfico basado en Redes Neuronales*, en 8th LACCEI Latin American and Caribbean Conference for Engineering and Technology (LACCER'2010).
- Rodríguez, A. R. (2018), *Diseño de un controlador predictivo para matriz dinámica (DMC) de temperatura para una central termosolar de generación eléctrica*.
- Rodríguez, M. Á. y Téllez, J. L. (2002), *Control predictivo basado en el modelo de un horno industrial*, en Revista Colombiana de Física, Bd. 34, 1: 245.
- Rodríguez-Toro, V. A., y otros. (2011), *Control neuronal por modelo inverso de un servosistema usando algoritmos de aprendizaje Levenberg-marquardt y Bayesiano*, en arXiv preprint arXiv:1111.4267.
- Rollón Rodríguez, J. (2014), *Convertidor DC/DC elevador Boost con control de corriente y de tensión*, en .

- Salazar Calahorrano, P. A. (2013), *Diseño e implementación de un Control por Modo deslizante para un Convertidor Buck Boost DC/DC*.
- Salcedo, R. y Correa, R. (2008), *Sicompc: Simulador para control predictivo basado en modelos*, en *Dyna*, Bd. 75, 156: 89–98.
- Subramanian, P. S. y Kayalvizhi, R. (2015), *An optimum setting of pid controller for boost converter using bacterial foraging optimization technique*, en *Systems Thinking Approach for Social Problems*, S. 13–23, Springer.
- Torres Pinzón, C. A. (2012), *Control robusto de convertidores conmutados de cc/cc mediante desigualdades matriciales lineales*.
- Tsang, K. M. y Chan, W. L. (2005), *Adaptive control of power factor correction converter using nonlinear system identification*, en *IEE Proceedings-Electric Power Applications*, Bd. 152, 3: 627–633.
- Valderrama, F. F., y otros. (2013), *Análisis, simulación y control de un convertidor de potencia DC-DC tipo boost*, en *Ingenium Revista de la facultad de ingeniería*, Bd. 12, 24: 44–55.
- Vásquez Choquehuanca, F. (2009), *Diseño e implementación de sistema de control de tensión y alineamiento para una máquina procesadora de papel basado en redes neuronales artificiales y control PID*, en .
- Vázquez Gutiérrez, Y. (2011), *Modelado y diseño del control de un convertidor elevador con control en modo corriente de pico*.

- Velarde Rueda, P. A. (2010), *Diseño e implementación de un control no lineal de convertidores conmutados DC/DC, utilizando técnicas de deslizamiento; y la viabilidad del uso de la pasividad y linealización entrada-salida por realimentación.*
- Velasco, H., y otros. (2010), *Implementación de una nueva técnica de control digital para convertidores dc-dc y dc-ac*, en *Dyna*, Bd. 77, 164: 189–199.
- Villaseñor-Aguilar, M., y otros. (2011), *Control de estabilidad de un manipulador planar paralelo 3RRR utilizando redes neuronales*, en *Científica*, Bd. 15, 3.
- Vivas, H. (2014), *Optimización en entrenamiento del perceptrón multicapa.*
- Zhang, Z., y otros. (2016), *FPGA-based experimental investigation of a quasi-centralized model of predictive control for back-to-back converters*, en *IEEE Transactions on Power Electronics*, Bd. 31, 1: 662–674.