



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

**Control predictivo Modulado basado en redes neuronales para un
inversor de voltaje trifásico de tres niveles**

Andino Bustamante, Josue Adrian

Vicerrectorado de Investigación, Innovación y Transferencia de Tecnología

Centro de Posgrados

Maestría de Investigación en Electrónica

Trabajo de titulación, previo a la obtención del título de Magíster en

Investigación en Electrónica, mención Automática

Ing. Ayala Taco, Jaime Paúl, PhD

15 de Diciembre de 2021

15/12/21 7:27

Revisión tesis Josue Andino

Informe de originalidad

NOMBRE DEL CURSO

Revisión perfiles tesis

NOMBRE DEL ALUMNO

JOSUE ADRIAN ANDINO BUSTAMANTE

NOMBRE DEL ARCHIVO

JOSUE ADRIAN ANDINO BUSTAMANTE - Tesis Josue Andino

SE HA CREADO EL INFORME

15 dic 2021

Resumen

Fragmentos marcados	2	0,1 %
Fragmentos citados o entrecomillados	0	0 %

Coincidencias de la Web

walmart.com	1	0,1 %
udlap.mx	1	0,1 %

.....

Ayala Taco, Jaime Paúl

C.C.: 1709434243

DIRECTOR



ESPE

UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

VICERRECTORADO DE INVESTIGACIÓN, INNOVACIÓN Y TRANSFERENCIA
DE TECNOLOGÍA
CENTRO DE POSGRADOS

CERTIFICACIÓN

Certifico que el trabajo de titulación, “**Control predictivo modulado basado en redes neuronales para un inversor de voltaje trifásico de tres niveles**” fue realizado por el señor **Andino Bustamante, Josue Adrian** el mismo que ha sido revisado y analizado en su totalidad, por la herramienta de verificación de similitud de contenido; por lo tanto cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, razón por la cual me permito acreditar y autorizar para que lo sustente públicamente.

Sangolquí, 15 de Diciembre del 2021

.....
Ayala Taco, Jaime Paúl

C.C.: 1709434243

DIRECTOR



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

**VICERRECTORADO DE INVESTIGACIÓN, INNOVACIÓN Y TRANSFERENCIA
DE TECNOLOGÍA**

CENTRO DE POSGRADOS

RESPONSABILIDAD DE AUTORÍA

Yo **Andino Bustamante, Josue Adrian**, con cédula de ciudadanía n° 1725048506, declaro que el contenido, ideas y criterios del trabajo de titulación: **Control predictivo modulado basado en redes neuronales para un inversor de voltaje trifásico de tres niveles** es de mi autoría y responsabilidad, cumpliendo con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Sangolquí, 14 de Diciembre del 2021

Andino Bustamante, Josue Adrian

C.C.: 1725048506



ESPE

UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

VICERRECTORADO DE INVESTIGACIÓN, INNOVACIÓN Y TRANSFERENCIA
DE TECNOLOGÍA

CENTRO DE POSGRADOS

AUTORIZACIÓN DE PUBLICACIÓN

Yo **Andino Bustamante, Josue Adrian**, con cédula de ciudadanía n° 1725048506, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **Control predictivo modulado basado en redes neuronales para un inversor de voltaje trifásico de tres niveles** en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi/nuestra responsabilidad.

Sangolquí, 14 de Diciembre de 2021

Una firma manuscrita en tinta azul que dice "ANDINO" sobre una línea punteada.

Andino Bustamante, Josue Adrian

C.C.: 1725048506



ESPE

UNIVERSIDAD DE LAS FUERZAS ARMADAS

INNOVACIÓN PARA LA EXCELENCIA

**VICERRECTORADO DE INVESTIGACIÓN, INNOVACIÓN Y TRANSFERENCIA DE
TECNOLOGÍA
CENTRO DE POSGRADOS**

DEDICATORIA

El presente trabajo de investigación va dedicado a las personas más importantes en mi vida, las cuales aprecio mucho. A mi hermanita Nathaly, por confiar en mí en todo momento y porque la quiero mucho . A mi primo Jaime Andres, que siempre me ha dado la mano y ha estado ahí para mí como un hermano. A mi amada novia Gaby, por su afecto, consejos, paciencia, apoyo, y por decidir estar a mi lado cada día. A mis padres por haberme guiado por el camino correcto. A mis amigos y compañeros que han sido un soporte en este trayecto.

Sangolquí, 15 de Diciembre del 2021



**VICERRECTORADO DE INVESTIGACIÓN, INNOVACIÓN Y TRANSFERENCIA DE
TECNOLOGÍA
CENTRO DE POSGRADOS**

AGRADECIMIENTO

Quiero expresar mi más profundo agradecimiento a la Universidad de las Fuerzas Armadas ESPE por haberme proporcionado una beca para estudiar la presente maestría y ser parte de la primera promoción de la misma. Después, agradezco al proyecto "MIRA-ESTE", en colaboración con la universidad de KU Leuven y el apoyo de VLIR-UOS, que me han permitido viajar al extranjero y así poder desarrollar la idea que se plasma en el trabajo de titulación. También, valoro mucho el esfuerzo que mis maestros han realizado en el transcurso de estos dos años de estudios, destacando sobre todo la labor de mis tutores, Dr. Ayala, Dr. Arcos y Dra. Llanos, en la investigación que en conjunto hemos realizado. Por último pero no menos importante, quiero expresar mi aprecio hacia mi terapeuta Elizabeth Rivadeneira que ha sabido acompañarme y ayudarme a mejorar como persona.

Sangolquí, 15 de Diciembre del 2021

Tabla de Contenido

Introducción	18
Estado del Arte	19
Formulación del Problema y Justificación	21
Formulación del Problema	21
Justificación	21
Hipótesis de la Investigación	22
Objetivos de la Investigación	22
Objetivo General	22
Objetivos Específicos	22
Metodología de la Investigación	23
Marco Teórico	25
Transformada de Clarke	25
Convertidores DC/AC	26
Inversor de Voltaje Trifásico de Tres Niveles	27
Modelamiento Matemático	27
Modulación por Vector Espacial	30
Filtro LC	30
Redes Neuronales Artificiales	32
Redes Neuronales en Sistemas de Control.	33
Propuesta.	35
Estrategias de Control a Comparar	35
Ley de Control	35
Control Predictivo de Estados Finitos (FCS-MPC)	36
Compensación del Retardo de una Muestra	37
Control Predictivo Modulado (M ² PC)	37
Control Predictivo Modulado con Sobre Modulación Óptima (OM ² PC)	39

Control Predictivo Modulado con Restricciones	40
Función de Costo con Restricciones	41
Descripción del Algoritmo Propuesto	41
Algoritmo de Sobre Modulación Extendido	43
Sobre Modulación No Óptima	46
Sobre Modulación Óptima	47
Algoritmo de Sobre Modulación No Óptima	48
Validación del Algoritmo Propuesto	50
Control Predictivo Modulado Basado en Redes Neuronales	52
Controlador Neuronal	53
Generación de Patrones de Entrenamiento	54
Entrenamiento del Controlador Neuronal	55
Etapa de Pre-Modulación	56
Algoritmo de Pre-Modulación	56
Resultados	60
Simulación de las Estrategias de Control	60
Discusión	62
Simulación del Controlador Predictivo Modulado con Restricciones	66
Simulación del Algoritmo de Sobre Modulación No Óptima	74
Controlador Neuronal	76
Entrenamiento de la Red Neuronal	76
Desempeño del Controlador Neuronal	81
Análisis de Sensitividad	84
Tiempos de Ejecución	85
Conclusiones y Recomendaciones	89
Conclusiones	89
Recomendaciones	90
Trabajos Futuros	91

Referencias 93

Anexos

Índice de Tablas

Tabla 1:	Caso de estudio 1: Criterios de desempeño cuando no hay carga a la salida.	61
Tabla 2:	Caso de estudio 2: Criterios de desempeño al conectar una carga lineal RL .	61
Tabla 3:	Case de estudio 3: Criterios de desempeño al conectar una carga no lineal.	61

Índice de Figuras

Figura 1:	Estructura de inversor de voltaje trifásico de tres niveles con la topología tipo T-NPC.	28
Figura 2:	Espacio de voltajes de conmutación y sus respectivas regiones: voltajes nulos v_0 , voltajes pequeños (v_1-v_6), voltajes medios (v_7-v_{12}) y voltajes largos ($v_{13}-v_{18}$).	29
Figura 3:	Filtro LC trifásico.	31
Figura 4:	Ejemplo de la arquitectura de una red neuronal con dos neuronas en la capa de entrada, cuatro en la oculta y una a la salida.	32
Figura 5:	Representación gráfica de la adición de restricciones en la corriente de la bobina.	42
Figura 6:	Sobre modulación interna y externa generada por la estrategia OM ² PC con restricción en la corriente de la bobina.	44
Figura 7:	Interpretación de la sobre modulación óptima.	47
Figura 8:	Interpretación de la sobre modulación no óptima.	49
Figura 9:	Error calculado entre el algoritmo de sobre modulación óptima v_{opt} y la aproximación propuesta v_{nopt}	51
Figura 10:	Tiempo de ejecución promedio de los algoritmos de sobre modulación en un computador Intel Core i7-6700 a 3.40 GHz con 32 GB en RAM.	52
Figura 11:	Lazo de control propuesto.	53
Figura 12:	Rango de valores en los que $\tilde{v}_{i\alpha\beta,k} = z^{-1} \cdot \tilde{v}_{i\alpha\beta,k+1}$. Fuera del mismo $\tilde{v}_{i\alpha\beta,k+1}$ necesita ser sobre modulado.	57
Figura 13:	División de las regiones del espacio de conmutaciones.	58
Figura 14:	Lazo de control.	60

Figura 15:	THD resultante de los voltajes de salida de las dos estrategias de control bajo variaciones en índices de modulación y factores de potencia con cargas lineales RL .	62
Figura 16:	Comparación de los resultados de las simulaciones entre el controlador M^2PC y el OM^2PC .	63
Figura 17:	Acción de control de la estrategia M^2PC en el plano $\alpha\beta$.	64
Figura 18:	Acción de control de la estrategia OM^2PC en el plano $\alpha\beta$.	65
Figura 19:	Puente de diodos rectificadores usado como carga no lineal con $C_n = 1100\mu F$ y $R_n = 70\Omega$.	67
Figura 20:	Respuesta del inversor sin carga a la salida con la estrategia OM^2PC sin restricciones.	68
Figura 21:	Respuesta del inversor sin carga a la salida con la estrategia OM^2PC con restricción de $I_{f_{max}} = 15$ amperios en la bobina.	69
Figura 22:	Respuesta del inversor ante un perturbación con una carga resistiva a la salida con la estrategia OM^2PC sin restricciones.	70
Figura 23:	Respuesta del inversor ante un perturbación con una carga resistiva a la salida con la estrategia OM^2PC con restricción de $I_{f_{max}} = 15$ amperios en la bobina.	71
Figura 24:	Respuesta del inversor ante un perturbación con una carga no lineal a la salida con la estrategia OM^2PC sin restricciones.	72
Figura 25:	Respuesta del inversor ante un perturbación con una carga no lineal a la salida con la estrategia OM^2PC con restricción de $I_{f_{max}} = 15$ amperios en la bobina.	73
Figura 26:	Comparación del error del voltaje de salida del inversor con respecto a la referencia para el algoritmo de sobre modulación óptima y no óptima cuando no existe carga a la salida del inversor.	75
Figura 27:	Comparación del error del voltaje de salida del inversor con respecto a la referencia para el algoritmo de sobre modulación óptima y no óptima cuando se conecta una carga resistiva a la salida del inversor.	75

Figura 28: Comparación del error del voltaje de salida del inversor con respecto a la referencia para el algoritmo de sobre modulación óptima y no óptima cuando se conecta un carga no lineal a la salida del inversor.	76
Figura 29: Estructura de la red neuronal creada en MATLAB.	76
Figura 30: Criterios de desempeño de las cada una de las funciones de activación.	78
Figura 31: Criterios de desempeño para la selección del número de neuronas (N) de la capa oculta.	79
Figura 32: Resultados del coeficiente de regresión en el entrenamiento, validación y test de la red neuronal con diez neuronas en la capa oculta y función de activación <i>satlins</i>	80
Figura 33: Resultados del error cuadrático medio en el entrenamiento de la red neuronal con diez neuronas en la capa oculta y función de activación <i>satlins</i> durante diez mil épocas de entrenamiento.	81
Figura 34: Comparación de los voltajes del inversor con los controladores OM ² PC ($\bar{v}_{i\alpha\beta}$) y ANN-M ² PC ($\hat{v}_{i\alpha\beta}$) ante la conexión de una carga no lineal.	82
Figura 35: Comparación de los voltajes de salida y la referencia con los controladores OM ² PC ($v_{f\alpha\beta}$) y ANN-M ² PC ($\hat{v}_{f\alpha\beta}$) ante la conexión de una carga no lineal.	83
Figura 36: Comparación del error porcentual con respecto a la referencia de los voltajes del filtro con los controladores OM ² PC y ANN-M ² PC ante la conexión de una carga no lineal.	83
Figura 37: Comparación de la magnitud de las corrientes del filtro con los controladores OM ² PC ($i_{f\alpha\beta}$) y ANN-M ² PC ($\hat{i}_{f\alpha\beta}$) ante la conexión de una carga no lineal.	84
Figura 38: Análisis de sensibilidad de la distorsión armónica total (THD) del voltaje de salida respecto a la variación de elementos del filtro LC.	86
Figura 39: Tiempos de ejecución en un ordenador con procesador Intel Core i7-6700 a 3.40Ghz con 32 GB en RAM.	87

Figura 40: Tiempos de ejecución en un DSP F28335. 88

Resumen

El control predictivo modulado (M^2PC) ha sido ampliamente estudiado en electrónica de potencia gracias a su capacidad de mantener fija la frecuencia de conmutación de los convertidores de potencia, y por tanto, reducir nivel de distorsión armónica total (THD) comparado con el control predictivo de estados finitos (FCS-MPC). Una frecuencia de conmutación fija es útil para el diseño de inversores. Desafortunadamente, los controladores M^2PC requieren de un coste computacional más elevado que los FCS-MPC, ya a que, los M^2PC realizan más cálculos para determinar la acción de control. Esto limita su uso en inversores multinivel (MLIs), puesto que la cantidad de conmutaciones es mayor comparado con inversores de dos niveles. En la literatura se pueden encontrar propuestas para reducir el coste computacional de los controladores predictivos; entre las cuales se puede resaltar el aproximar a un FCS-MPC mediante el uso de redes neuronales artificiales (ANNs). No obstante, usar una aproximación mediante ANNs aumenta el THD resultante que ya de por sí tiene presente un FCS-MPC. El presente trabajo propone el uso de una ANN para aproximar el comportamiento de un control M^2PC , a fin de no solo reducir el coste computacional, sino que también de mermar el THD, y al aplicarlo a un inversor de voltaje trifásico de tres niveles (3φ -3L-VSI). La principal diferencia con previas propuestas similares, radica en que la propuesta de este trabajo se basa en realizar una regresión múltiple mediante una ANN, y con ello predecir el voltaje promedio óptimo que el inversor debe generar. Los resultados de la investigación muestran que, en efecto, el controlador neuronal propuesto (ANN- M^2PC) posee un coste computacional mucho menor que su contra parte M^2PC , y que al mismo tiempo conserva una frecuencia constante de conmutación, además de un bajo THD.

Palabras Claves:

- CONTROL PREDICTIVO MODULADO
- INVERSOR TRIFÁSICO
- INVERSOR MULTINIVEL
- REDES NEURONALES ARTIFICIALES

Abstract

Modulated model predictive control (M^2PC) has been widely studied in power electronics since it is able to keep fixed the switching frequency of power converters and to keep low the total harmonic distortion (THD) compared with Finite Control Set Model Predictive Control (FCS-MPC). Keeping switching frequency fixed is particularly useful when designing power inverters, for it allows to reduce the size of filter components (i.e., inductors and capacitors). Unfortunately, M^2PC controllers require a higher computational cost than FCS-MPC since that M^2PC is based on FCS-MPC, but it needs to perform more calculations at same time. This high computational cost limits the use of M^2PC in multilevel inverters (MLIs), for the amount of possible switching states is higher than two-level inverters. This issue is even worse if it is required to increase the switching frequency since the available time for performing calculation is much narrower. Literature shows several proposals for reducing the computational burden of predictive controllers. One interesting approach is to approximate an FCS-MPC controller by using an artificial neural network (ANN). However, this approximation comes with an increase of the resulting THD, which is already present in FCS-MPC controllers. The present study proposes to approximate the behavior of a M^2PC controller by using an ANN in order to not only reduce the computational burden but also to reduce the resulting THD when controlling a three-phase three-level voltage source inverter (3φ -3L-VSI). The main difference with previous proposals is that our proposal is to use the ANN as a multiple regression algorithm in order to determine the average voltage the inverter must supply in each time. Results show that, indeed, the proposed neural controller (ANN- M^2PC) does reduce the computational cost of implementing a M^2PC while keeps a low THD and a fixed switching frequency.

Keywords:

- MODULATED MODEL PREDICTIVE CONTROL
- THREE-PHASE INVERTER
- MULTILEVEL INVERTER
- ARTIFICIAL NEURAL NETWORKS

Introducción

Los inversores multinivel (MLIs) han ganado una gran popularidad en los campos investigativos, ya que presentan grandes ventajas en comparación a los inversores de dos niveles (2L-VSI). Entre dichos beneficios se puede destacar que los MLIs pueden trabajar con potencias más elevadas, producen ondas senoidales con una menor distorsión armónica total (THD), y sus elementos de conmutación sufren de una menor degradación, dado que se trabaja con voltajes menores. Por tales motivos, MLIs son frecuentemente usados en energías renovables como los son la solar y la eólica (Vijeh, Rezanejad, Samadaei, y Bertilsson, 2019).

Una estrategia común para el control de MLIs es el control predictivo de estados finitos, *Finite Control Set Model Predictive Control (FCS-MPC)*, mismo que ha sido ampliamente utilizado en inversores trifásicos en últimos años (Karamanakos, Liegmann, Geyer, y Kennel, 2020). FCS-MPC posee una rápida respuesta dinámica, fácil e intuitiva implementación, y control multiobjetivo (Garcia, Silva, Rodriguez, Zanchetta, y Odhano, 2019; Doi, Nguyen, y Nguyen, 2019). Sin embargo, FCS-MPC no mantiene fija la frecuencia de conmutación, lo que incrementa la distorsión armónica y la complejidad del cálculo de los elementos utilizados como filtro (inductancias y capacitancias).

Actualmente, existen estrategias que mantienen fija la frecuencia de conmutación del convertidor mediante el uso de controladores predictivos modulados (M^2PC) (Donoso y cols., 2018; Rivera, Morales, y cols., 2015; Wang, Rivera, Riveros, y Wheeler, 2019; Zheng, Dragičević, Majmunović, y Blaabjerg, 2020; Wang y cols., 2020). La estrategia básica de control de un M^2PC , que es una modificación del FCS-MPC, es aplicar un conjunto de voltajes en un solo tiempo de muestreo de manera que, en promedio, se pueda alcanzar un voltaje que no existe dentro del conjunto de un FCS-MPC. Para ello, cada uno de los voltajes es aplicado durante una fracción del tiempo de muestreo; dicha fracción del tiempo de muestreo se la conoce como ciclo de trabajo. La estrategia M^2PC permite conservar todos los beneficios que posee un FCS-MPC al tiempo que se mantiene fija la frecuencia de conmutación.

A pesar de los claros beneficios que tiene el uso de controladores predictivos en inver-

sores, estos presentan el inconveniente de tener un alto coste computacional (Karamanakos y cols., 2020). Dicho coste se produce principalmente, debido a la cantidad de posibles estados que puede tener un convertidor de potencia. Por lo que, mientras más niveles posea un convertidor de potencia, mayor será el coste computacional requerido para un controlador que utiliza una estrategia predictiva basada en FCS-MPC. En consecuencia y para lograr cumplir con estrictos márgenes de tiempo, se puede observar que cada vez se requiere de procesadores más potentes y veloces (Karamanakos y cols., 2020; Bandy y Stumpf, 2021).

Estado del Arte

En la literatura existen múltiples estrategias que logran reducir el tiempo de ejecución de controladores predictivos en MLIs. En (Doi y cols., 2019) se divide el espacio de conmutaciones en seis sectores, entre los cuales se selecciona únicamente el sector más cercano a la referencia deseada. Por lo que, al solo tener diez combinaciones por sector en lugar de 27, el proceso de optimización es más rápido. Es pertinente mencionar que al reducir la cantidad de estados disponibles dependiendo de la referencia, es posible que el subconjunto escogido no sea el más óptimo, sobre todo cuando se trata de rechazar perturbaciones. Además, al ser una estrategia netamente basada en FCS-MPC, presenta armónicos en un rango muy amplio del espectro de frecuencia. Un caso similar pero aplicado a M^2PC se muestra en (Yang y cols., 2020).

Igualmente, existen también otras propuestas que como en (Bandy y Stumpf, 2021) que se basan en mejorar el algoritmo de optimización por medio de redes de ordenamiento, es decir, se busca mejorar el algoritmo que halla la opción más óptima mas no reducir la cantidad de estados a predecir. Cabe resaltar, que es requerido utilizar un procesador de dos núcleos, el primero, se encarga de realizar las evaluaciones de la función de costo, mientras que el segundo es utilizado para el proceso de optimización. Entonces se puede afirmar entonces que el elevado gasto computacional de dicho algoritmo es dividido entre los dos núcleos, y con ello lograr la ejecución del algoritmo lo suficientemente rápido.

Otras alternativas como en (Mohamed, Rovetta, Do, Dragicevic, y Diab, 2019; Novak y

Dragicevic, 2021) basan su funcionamiento en el uso de redes neuronales artificiales (ANNs) para emular el comportamiento de un FCS-MPC en inversores de dos niveles (2L-VSI). Al emular un FCS-MPC mediante una ANN, se pueden obtener frecuencias de conmutación mayores como en (Mohamed y cols., 2019), o incluso ser capaz de incrementar el horizonte de predicción con hasta tres muestras a futuro como en (Novak y Dragicevic, 2021). En ambos casos, el proceso de aprendizaje fue abordado como un problema de clasificación, esto es, la ANN únicamente. Es decir, la ANN clasifica o predice cuál de las siete posibles conmutaciones de un 2L-VSI se debe aplicar en el siguiente instante de tiempo. Si bien de esta forma se simplifica el problema de aprendizaje, asimismo presenta el inconveniente de si la ANN comete un error, el voltaje aplicado al inversor estará desfasado, al menos, 60° del voltaje que debería ser aplicado. Esto último incrementa la cantidad de armónicos en el voltaje de salida que ya de por sí están más presentes por ser un controlador basado en FCS-MPC en lugar de un M^2PC .

Es importante resaltar que existe una mayor cantidad de trabajos relacionados M^2PC para inversores de dos niveles como en (Garcia y cols., 2019), en el cual se aborda el tema de la sobre modulación y que permite una respuesta más rápida cuando el sistema sufre de perturbaciones y/o cambios de consigna. En (Santis, Sáez, Cárdenas, y Núñez, 2019) que se muestra una versión del M^2PC multiobjetivo. Si bien estas estrategias no han sido pensadas para MLIs, se las puede tomar en consideración, puesto que proporcionan excelentes resultados, y pueden servir para la generación del controlador a emular.

La contribución del presente trabajo es la de proponer una alternativa para la implementación de controladores predictivos para MLIs, misma que ofrezca un menor costo computacional comparada a la implementación directa del controlador M^2PC , y que al mismo tiempo reduzca el THD con respecto a otras alternativas previamente discutidas. Cabe destacar, que la acción de control de un M^2PC se la puede tratar como una variable escalar en el dominio de los números complejos, dado que la misma se compone, en promedio, de la combinación lineal de los vectores más cercanos al punto deseado y sus respectivos ciclos de trabajo (Garcia y cols., 2019; Wang y cols., 2020; Rivera, Perez, y cols., 2015).

Formulación del Problema y Justificación

Formulación del Problema

Tras la revisión del estado del arte, se ha podido evidenciar que si bien los controladores predictivos basados en FCS-MPC son excelentes al controlar inversores de dos niveles, su uso no es muy extendido con MLIs. Esto es debido a la cantidad de posibles conmutaciones que posee un MLI. Así por ejemplo, un 3Ph-2L-VSI posee ocho posibles conmutaciones (siete no redundantes), mientras que un 3 φ -3L-VSI posee 27 posibles conmutaciones (19 no redundantes). Dicho incremento en las posibles conmutaciones hace impráctico el uso de controladores predictivos (sean FCS-MPC o M²PC) dado a que los tiempos disponibles para el cómputo de la ley de control son muy reducidos. Dicho problema es abruptamente peor cuando se desea predecir múltiples muestras en el futuro, puesto que la cantidad de posibles conmutaciones aumenta de forma exponencial.

Justificación

Como se ha evidenciado en la revisión del estado del arte, existe una gran necesidad por reducir el coste computacional de los controladores predictivos, sobre todo en áreas en donde la ejecución en tiempo real es crucial, como lo es la electrónica de potencia, puesto que se suele operar con tiempos de muestreo y de procesamiento en el orden de las decenas de microsegundos (Karamanakos y cols., 2020), y por lo tanto, la cantidad de cálculos que se pueden realizar en dicha ventana de tiempo es también muy reducida. Así, resulta particularmente desafiante en MLIs, ya que como se mencionó anteriormente, éstos deben estimar un número mucho mayor de posibles combinaciones en un mismo tiempo. Si bien los estudios (Mohamed y cols., 2019; Novak y Dragicevic, 2021) ofrecen una posible alternativa para acelerar el cálculo de la acción de control para 2L-VSI, aún están basados en FCS-MPC, que inherentemente produce una mayor distorsión armónica comparado con M²PC. Por tales motivos, el presente trabajo de investigación procura aproximar el comportamiento entrada-salida de un M²PC mediante el uso de ANNs y aplicarlo a MLIs con el objetivo de no solo reducir el

costo computacional asociado a los controladores predictivos, sino que igualmente disminuir la distorsión armónica con respecto a las propuestas mostradas en (Mohamed y cols., 2019; Novak y Dragicevic, 2021).

Hipótesis de la Investigación

Al aproximar el comportamiento de un M²PC para un 3 φ -3L-VSI mediante el uso de ANNs, se reducirán los tiempos de cómputo necesarios para obtener la ley de control con respecto a la implementación directa de un M²PC. Por consiguiente, los requerimientos de hardware para la implementación del controlador también serán menores al tiempo que la distorsión armónica del voltaje de salida también será mermada con relación a otras implementaciones basadas en redes neuronales.

Objetivos de la Investigación

Objetivo General

Aproximar el comportamiento de un M²PC mediante el uso de ANNs con el fin de reducir la carga computacional asociada con la implementación de dicho controlador para un 3 φ -3L-VSI.

Objetivos Específicos

- Seleccionar una estructura del 3 φ -3L-VSI a controlar.
- Definir el algoritmo de control a emular, lo que incluye: función de costo, horizonte de predicción, estrategia de modulación, etc.
- Generar los patrones de entrenamiento de la red neuronal a partir del controlador previamente definido.
- Entrenar una red neuronal que emule la relación entrada-salida a partir de los patrones de entrenamiento generados previamente.

- Comparar el desempeño del controlador emulador frente a un M^2PC y un FCS-MPC, ambos implementados de forma tradicional.

Metodología de la Investigación

El presente proyecto de investigación utilizará fuentes de información bibliográfica provenientes de revistas indexadas de investigación en las áreas de: electrónica de potencia, sistemas de control, energías renovables, entre otros. Se considerarán únicamente las publicaciones con una antigüedad no mayor a cinco años exceptuando el caso que se tratase de artículos de muy alta relevancia que deban ser incluidos.

Para cumplir los objetivos previamente definidos, se pretende como primer paso seleccionar la estructura del inversor a utilizar. La estructura propuesta es la topología T-NPC, gracias a que únicamente requiere de doce transistores, mas no diodos para su funcionamiento, lo que la hace más eficiente en relación a otras topologías (Loncarski, Monopoli, Leuzzi, Ristic, y Cupertino, 2019). Con respecto a los parámetros del inversor, se plantea un inversor de 3kW a un voltaje de 110 voltios RMS y una frecuencia de 60 Hertz. El segundo paso del estudio es, definir el algoritmo de control predictivo a emular por la red neuronal, esto es: función de costo, restricciones, ponderaciones, horizonte de predicción, frecuencia de conmutación, etc. Entre los trabajos que se proponen usar como referencia para el algoritmo de control se encuentran (Garcia y cols., 2019; Doi y cols., 2019; Santis y cols., 2019; Wang y cols., 2020, 2019; Dragicevic, 2018; Donoso y cols., 2018), mismos que se han discutido con anterioridad, o que en su defecto se espera que presenten buenos resultados al ser generalizados a MLIs.

Una vez definido el controlador a emular y la planta a controlar, se procederá a la generación de los patrones de entrenamiento de la ANN. En (Novak y Dragicevic, 2021) se propone una metodología para extraer dichos patrones, la cual se basa en generar vectores de datos en las entradas del controlador a emular y registrar la salida respectiva, en vez de generalizar el comportamiento del controlador a emular mediante simulaciones de la planta y el controlador, como sugiere (Mohamed y cols., 2019). Dicha metodología se puede adaptar para la presente investigación con la diferencia que la salida del controlador es una variable

compleja en lugar de un número entero.

Con los patrones generados, se procede a realizar el entrenamiento de la ANN, cuya estructura debe tener en cuenta como entradas las medidas de corrientes y de voltajes previamente definidos, además de la referencia y de las posibles entradas pasadas que puedan o no ser necesarios para mejorar su rendimiento. En tanto que, la salida debe constar de dos neuronas, ya sea para estimar la componente real e imaginaria o en su lugar la magnitud y la fase de la acción de control. Es pertinente mencionar que, el proceso de generación de datos y de entrenamiento se realizará fuera de línea, y el controlador resultante será validado dentro de un equipo de simulación hardware-in-the-loop (HIL).

Para el análisis de los resultados obtenidos, se aspira utilizar técnicas de validación cruzada con el propósito de garantizar que los resultados del entrenamiento no dependan de la partición de los datos usados para el mismo. Por lo que, se propone el uso de la validación cruzada de K iteraciones o también conocida como K-fold cross-validation, donde K representa la cantidad de subconjuntos en los que los patrones de entrenamiento son divididos. Es necesario indicar que, si K es un número grande, el proceso de validación puede ser muy lento, mientras que si es muy bajo es posible que no sea muy preciso. Por tal motivo, el valor de K será determinado después de la generación de los patrones de entrenamiento.

Marco Teórico

Transformada de Clarke

La transformada *alfa-beta* ($\alpha\beta$), o también conocida como la transformada de Clarke, es una transformación empleada para simplificar el análisis de circuitos trifásicos. Suele ser ampliamente utilizada para el control de inversores trifásicos ya que permite convertir de un modelo matemático de tres fases en el dominio de los números reales a un modelo monofásico en el dominio de los números complejos, al tiempo que mantiene intacta la dinámica original del sistema (Dragicevic, 2018). En el presente trabajo se utiliza la versión tradicional, la cual preserva las magnitudes de los voltajes y corrientes mas no potencias. El vector fila \mathbf{T} mostrado en (1) permite realizar la transformación de Clarke al ser multiplicado por un vector columna correspondiente a la variable que se desea transformar.

$$\mathbf{T} = \frac{2}{3} \begin{bmatrix} 1 & e^{j\frac{2}{3}\pi} & e^{j\frac{4}{3}\pi} \end{bmatrix} \quad (1)$$

Por ejemplo, para hallar las componentes $\alpha\beta$ una variable trifásica \mathbf{z}_{abc} definido por $\mathbf{z}_{abc} = [z_a \ z_b \ z_c]^T$ se obtiene:

$$z_{\alpha\beta} = z_{\alpha} + jz_{\beta} = \mathbf{T} \cdot \mathbf{z}_{abc} \quad (2)$$

Al ser $z_{\alpha\beta}$ una variable en el dominio de los números complejos, se lo puede representar de forma polar de la siguiente forma:

$$z_{\alpha\beta} = |z_{\alpha\beta}| \cdot e^{j\theta_{z_{\alpha\beta}}} \quad (3)$$

En donde $|z_{\alpha\beta}|$ representa la magnitud del número complejo, mientras que $\theta_{z_{\alpha\beta}}$ el ángulo en radianes del mismo:

$$|z_{\alpha\beta}| = \sqrt{z_{\alpha}^2 + z_{\beta}^2} \quad (4)$$

$$\theta_{z_{\alpha\beta}} = \arctan \frac{z_{\beta}}{z_{\alpha}} \quad (5)$$

Convertidores DC/AC

Los convertidores DC/AC, o también conocidos como inversores de potencia, son elementos electrónicos que cambian o transforma la tensión de corriente directa (DC) a corriente alterna (AC). Una de las aplicaciones más comunes de los inversores es cambiar el voltaje de una batería a una tensión AC que la mayoría de dispositivos es capaz de usar al día de hoy. Otro uso muy común de los inversores es en los campos de energías renovables como lo es la energía solar. Dicha energía solar se produce en forma de corriente directa, mientras que se transporta de donde es generada a donde es consumida mediante corriente alterna.

Tradicionalmente, los inversores constan de un controlador para activar los transistores y generar una forma de onda rectangular. Esta onda rectangular pasa a través de un conjunto de elementos que actúan como un filtro, mismos que suavizan la forma de onda haciendo que la misma parezca un poco más senoidal. Para lograr convertir una voltaje DC en uno AC, se requieren de la utilización de alguna técnica de modulación. Entre las cuales se puede destacar: modulación de onda cuadrada, modulación por ancho de pulso (PWM), modulación por vector espacial (SVM), eliminación selectiva de armónicos, entre otros (Leon, Kouro, Franquelo, Rodriguez, y Wu, 2016).

Los inversores se pueden clasificar dependiendo del número de fases que estos son capaces de manejar. Entre los inversores más comunes se puede destacar los inversores monofásicos (o sea una sola fase) y los inversores trifásicos (tres fases). Los inversores monofásicos suelen ser utilizados para cargas cuya potencia suele llegar hasta 10kW. Cuando se requiere de energizar cargas con potencias superiores, usualmente se trabaja con alimentación trifásica.

Los inversores también se pueden clasificar por la cantidad de niveles que los elementos electrónicos son capaces de generar. Los inversores de voltaje más comunes suelen tener dos niveles (2L-VSI) ya que el costo de fabricación de los mismos es menor comparado

con los inversores multinivel (MLIs). No obstante, en los últimos años se ha visto un incremento significativo en el uso de MLIs gracias a todos los beneficios que los mismos poseen en comparación con los 2L-VSI. Así por ejemplo, dichos beneficios son una menor distorsión armónica, un menor estrés de los elementos de conmutación, y una menor interferencia electromagnética. Adviértase que, a pesar de todo los MLIs asimismo poseen desventajas tales como requerir de un mayor número de elementos de conmutación, el control suele ser más complejo mientras más niveles posea un MLI, la distribución de temperatura es desigual entre los elementos de conmutación, entre otros.

Inversor de Voltaje Trifásico de Tres Niveles


Si bien los MLIs pueden poseer cualquier cantidad de niveles, lo más usual es encontrar inversores de voltaje trifásicos de tres niveles 3φ -3L-VSI ya que la cantidad de elementos de conmutación no es tan elevada como los inversores de cuatro o más niveles. La arquitectura de un MLI se puede clasificar en tres categorías principales, entre las cuales se encuentran: capacitores flotantes (FC), punto neutro enclavado (NPC), e inversores tipo puente en cascada (CBH) (Rao, Kumar, y Babu, 2018; El-Hosainy, Hamed, Azazi, y El-Kholy, 2018). Para cada una de las configuraciones existen variaciones de las mismas. Por ejemplo en la figura 1 se muestra el esquema de un 3φ -3L-VSI con la topología tipo T-NPC, misma que requiere de una cantidad menor de elementos de conmutación al tiempo que presenta una eficiencia mayor (Loncarski y cols., 2019; Sajitha, Sandeep, y Ramchand, 2019) comparada con la topología tradicional de un NPC.

Modelamiento Matemático

El circuito de potencia del 3φ -3L-VSI, mostrado en la figura 1, consiste de cuatro transistores por cada pierna S_{1x} , S_{2x} , S_{3x} y S_{4x} donde $x \in \{a, b, c\}$ constituye una de las tres fases del sistema. A fin de evitar cortocircuitos, los transistores S_{1x} y S_{3x} deben operar de forma complementaria (lo mismo aplica para S_{4x} y S_{2x}). Adicionalmente, S_{1x} y S_{4x} no pueden estar encendidos al mismo tiempo, pero si pueden estar apagados simultáneamente. Tomando

Figura 1

Estructura de inversor de voltaje trifásico de tres niveles con la topología tipo T-NPC.



en cuenta las previas consideraciones, existen únicamente tres estados posibles para cada pierna, mismos que se pueden representar con la variable s_x (6).

$$s_x = \begin{cases} 1 & \text{si } S_{1x} \text{ \& } S_{2x} \text{ están encendidos} \\ 0 & \text{si } S_{2x} \text{ \& } S_{3x} \text{ están encendidos} \\ -1 & \text{si } S_{3x} \text{ \& } S_{4x} \text{ están encendidos} \end{cases} \quad (6)$$

Para representar las posibles conmutaciones de las tres piernas del 3φ -3L-VSI se utiliza un vector columna $s = [s_a \ s_b \ s_c]^T$ el cual puede generar las 27 posibles combinaciones en las que puede conmutar el inversor.

Es importante mencionar que el voltaje a la entrada del filtro $v_{i\alpha\beta}$ se puede obtener al hallar primeramente el voltaje trifásico \mathbf{v}_{iabc} con respecto al punto común n mostrado en la figura 3. Para ello, se debe obtener el voltaje trifásico con respecto al punto común N mostrado en la figura 1 y restar el promedio de dichos voltajes:

$$\mathbf{v}_{iabc} = \begin{bmatrix} v_{iaN} \\ v_{ibN} \\ v_{icN} \end{bmatrix} = \begin{bmatrix} v_{iaN} \\ v_{ibN} \\ v_{icN} \end{bmatrix} - \frac{v_{iaN} + v_{ibN} + v_{icN}}{3} \mathbf{1} = \frac{V_{DC}}{2} \cdot \left(\mathbf{I} - \frac{1}{3} \mathbf{1} \right) \cdot \mathbf{s} \quad (7)$$

En donde, V_{DC} es voltaje del DC-link, \mathbf{I} es la matriz identidad de 3×3 , y $\mathbf{1}$ es una matriz

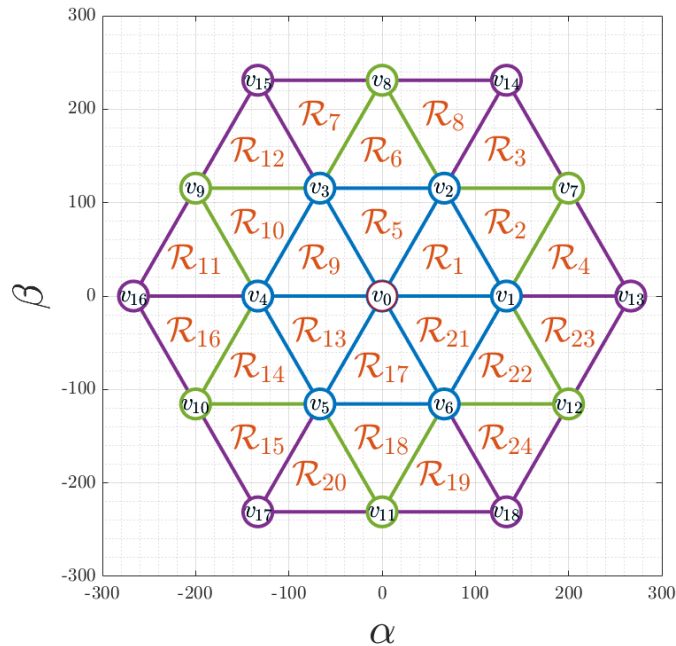
de unos de 3×3 . Se puede entonces hallar las componentes $\alpha\beta$ del voltaje a la entrada del filtro al aplicar la transformada de Clarke:

$$v_{i\alpha\beta} = v_{i\alpha} + jv_{i\beta} = \mathbf{T} \cdot \mathbf{v}_{iabc} = \frac{V_{DC}}{2} \cdot \mathbf{T} \cdot \left(\mathbf{I} - \frac{1}{3}\mathbf{1} \right) \cdot \mathbf{s} \quad (8)$$

Finalmente, al aplicar la expresión (8) a todas las posibles combinaciones, se obtiene el espacio de voltajes de conmutación mostrado en la figura 2. Es importante mencionar que si bien existen 27 posibles combinaciones, solamente 19 son no redundantes, y por tanto consideradas en el presente estudio por simplicidad. Dicho espacio de 19 conmutaciones se encuentra descrito en el Anexo ??, el mismo que como se muestra en la figura 2 se encuentra dividido en 24 regiones, mismas que se encuentran descritas en el Anexo ??.

Figura 2

Espacio de voltajes de conmutación y sus respectivas regiones: voltajes nulos v_0 , voltajes pequeños (v_1 - v_6), voltajes medios (v_7 - v_{12}) y voltajes largos (v_{13} - v_{18}).



Modulación por Vector Espacial

Existen múltiples técnicas de modulación para inversores multinivel (Leon y cols., 2016), entre la cuales se pueden destacar la modulación por vector espacial (SVM) (Attique, 2017). La modulación SVM es básicamente una modificación de la modulación por ancho de pulso (PWM), pero diseñada para convertidores trifásicos. Esta técnica de modulación determina las señales de conmutación para cada uno de los interruptores del inversor al seleccionar el conjunto de vectores $[v_0, v_1, v_2]$ que se encuentra más próximo al punto deseado $\bar{v}_{i\alpha\beta}$. Además, cada uno de estos vectores es aplicado en una fracción del tiempo de muestreo de tal forma que:

$$\bar{v}_{i\alpha\beta} = \frac{1}{T_s} (\tau_1 \cdot v_{j1} + \tau_2 \cdot v_{j2} + \tau_3 \cdot v_{j3}) \quad (9)$$

$$\tau_1 + \tau_2 + \tau_3 = T_s$$

Cabe mencionar que la modulación SVM considera al sistema trifásico como un todo, al contrario que la modulación PWM en donde se considera cada fase de forma independiente.

Para la implementación de la modulación SVM se utiliza un patrón simétrico como describe (Donoso y cols., 2018). En el cual los tres vectores activos son aplicados en cinco tiempos diferentes de la siguiente forma:

$$\mathbf{S}_j = \left\{ \underbrace{v_{j1}}_{\frac{d_{j1}}{2}}, \underbrace{v_{j2}}_{\frac{d_{j2}}{2}}, \underbrace{v_{j3}}_{d_{j3}}, \underbrace{v_{j2}}_{\frac{d_{j2}}{2}}, \underbrace{v_{j1}}_{\frac{d_{j1}}{2}} \right\} \quad (10)$$


En donde d_{ji} es el ciclo de trabajo que se ha calculado para el elemento i -ésimo del vector v_j .

Filtro LC

A fin de suprimir las componentes armónicas provenientes de la conmutación, un filtro LC debe ser conectado en los terminales de salida del 3φ -3L-VSI. Cada pierna del filtro está constituido por una inductancia L_f , una resistencia en serie R_f , y un capacitor C_f . La dinámica del filtro puede ser representada mediante la ecuación de espacio de estados mostrada en

Figura 3

Filtro LC trifásico.



(11). Cabe notar que $i_{f\alpha\beta}$ y $v_{f\alpha\beta}$ son las variables del vector de estados $\mathbf{x}_{\alpha\beta}$, mientras que $v_{i\alpha\beta}$ y $i_{o\alpha\beta}$ son las entradas al sistema.

$$\dot{\mathbf{x}}_{\alpha\beta} = \frac{d}{dt} \begin{bmatrix} i_{f\alpha\beta} \\ v_{f\alpha\beta} \end{bmatrix} = \mathbf{A} \cdot \begin{bmatrix} i_{f\alpha\beta} \\ v_{f\alpha\beta} \end{bmatrix} + \mathbf{B} \cdot \begin{bmatrix} v_{i\alpha\beta} \\ i_{o\alpha\beta} \end{bmatrix} \quad (11)$$

En donde, $i_{f\alpha\beta}$ y $i_{o\alpha\beta}$ son las corrientes de la inductancia y la carga respectivamente, mientras que $v_{f\alpha\beta}$ y $v_{i\alpha\beta}$ son los voltajes del capacitor y del inversor respectivamente, y:

$$\mathbf{A} = \begin{bmatrix} -\frac{R_f}{L_f} & -\frac{1}{L_f} \\ \frac{1}{C_f} & 0 \end{bmatrix} \quad (12)$$

$$\mathbf{B} = \begin{bmatrix} -\frac{1}{L_f} & 0 \\ 0 & \frac{1}{C_f} \end{bmatrix} \quad (13)$$

Sin embargo, para poder hacer predicciones del futuro comportamiento del sistema, éste debe ser discretizado. En el presente estudio se utiliza el método *zero-order hold* (ZOH), con lo que el sistema se puede representar de la siguiente ecuación de estados discreta:

$$\mathbf{x}_{\alpha\beta, k+1} = \begin{bmatrix} i_{f\alpha\beta, k+1} \\ v_{f\alpha\beta, k+1} \end{bmatrix} = \mathbf{A}_d \cdot \begin{bmatrix} i_{f\alpha\beta, k} \\ v_{f\alpha\beta, k} \end{bmatrix} + \mathbf{B}_d \cdot \begin{bmatrix} v_{i\alpha\beta, k} \\ i_{o\alpha\beta, k} \end{bmatrix} \quad (14)$$

En donde:

$$\mathbf{A}_d = e^{AT_s} \quad (15)$$


$$\mathbf{B}_d = \int_0^{T_s} e^{A\tau} d\tau \quad (16)$$

Redes Neuronales Artificiales

Las redes neuronales artificiales (ANNs) son un conjunto de algoritmos que son capaces de reconocer relaciones entre datos, su funcionamiento se da de la misma manera que una red biológica de un animal. Las ANNs están agrupadas en capas, en las que cada capa posee un grupo de neuronas o nodos. Usualmente, una ANN contiene una capa de entrada, una o más capas ocultas, y una capa de salida. Al día de hoy, se pueden encontrar múltiples usos para las ANNs entre los cuales se puede destacar control de sistemas dinámicos, reconocimiento de patrones, electrónica de potencia, robótica, manufactura, arte, optimización, entre otros (Abiodun y cols., 2018).

Figura 4

Ejemplo de la arquitectura de una red neuronal con dos neuronas en la capa de entrada, cuatro en la oculta y una a la salida.



La red neuronal se puede concebir como un sistema que cuyas entradas y salidas están relacionadas por muchos elementos de procesamiento simple, conocidos como neuronas. Dichos elementos de procesamiento simple poseen parámetros internos propios, como lo son los pesos para cada una de las entradas además de un bias. Entonces, la respuesta de ca-

da neurona se puede calcular como la suma de los productos entre las entradas y los pesos respectivos y más el término de bias. A eso, se le aplica una función no lineal que es la que garantiza que el aprendizaje de la red neuronal.

$$s(\mathbf{x}) = \mathbf{x} \cdot \mathbf{w} + b = \sum_{i=0}^N w_i x_i + b \quad (17)$$

$$y = f(s(\mathbf{x})) \quad (18)$$

Existe muchas funciones no lineales, o también conocidas como funciones de activación, que se utilizan en redes neuronales, entre las más comunes se pueden destacar las funciones: *tansig*, *poslin*, *radbas*, *logsig* y *satlins*:

$$\text{tansig}(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (19)$$

$$\text{poslin}(x) = \begin{cases} x & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases} \quad (20)$$

$$\text{radbas}(x) = e^{-x^2} \quad (21)$$

$$\text{logsig}(x) = \frac{1}{1 + e^{-x}} \quad (22)$$

$$\text{satlins}(x) = \begin{cases} -1 & \text{si } x \leq -1 \\ x & \text{si } -1 \leq x \leq 1 \\ 1 & \text{si } x \geq 1 \end{cases} \quad (23)$$

Redes Neuronales en Sistemas de Control

Las redes neuronales en el ámbito de control son utilizadas para resolver problemas de control altamente no lineales, gracias a su capacidad para aprender la dinámica de este tipo

de sistemas, y acorde a dicho aprendizaje, genera una acción de control apropiada para los mismos. A efectos prácticos, en estado estacionario la respuesta de un sistema controlador por una ANN sería muy similar a la respuesta que se obtiene de una función de transferencia. La diferencia sería entonces más notable cuando el sistema a controlar cambie sus parámetros con el paso de tiempo, de perturbaciones, o incluso la propia dinámica del mismo sistema.

Una de las formas más conocidas de controladores neuronales es el control por modelo de referencia (Burns, 2001), cuyo proceso de aprendizaje iterativo es capaz de generar una acción de control que garantiza que la salida del sistema retroalimentado sea lo más próxima posible al modelo usado como referencia. En general, los modelos de referencia son funciones de transferencia de primer o de segundo orden.

Propuesta

Estrategias de Control a Comparar

Como se mencionó anteriormente, existen múltiples estrategias de control que se pueden aplicar a MLIs. El presente capítulo pretende analizar cuál de las estrategias de control es la más apta para ser emulada por una ANN. Entre las estrategias tomadas en consideración se encuentran la implementación clásica del control predictivo modulado mostrado en (Donoso y cols., 2018), de ahora en adelante simplemente llamada M²PC. Así mismo, la estrategia propuesta por (García y cols., 2019) en la cual se añade una etapa de sobre modulación, esta última estrategia se denominará de ahora en adelante como OM²PC. Cabe mencionar que ambas estrategias basan su algoritmo de control en el funcionamiento de un FCS-MPC clásico, por lo que esta última estrategia es desarrollada como fundamento para las otras dos. Otro punto a tener en cuenta es cómo actúa la acción de control en las estrategias moduladas. En la sección *Ley de Control* se muestra la propuesta del presente trabajo para analizar el comportamiento de la ley de control de las estrategias a estudiar.

Ley de Control

Cuando se trabaja con controlador del tipo FCS-MPC, la acción de control u_k para el instante k -ésimo es simplemente el vector de conmutación s_k aplicado durante todo el tiempo de muestreo T_s . No obstante y como se mencionó con anterioridad, los controladores predictivos modulados aplican un conjunto de voltajes o conmutaciones en un mismo instante de tiempo. Para el presente trabajo, se considera que el controlador genera tres conmutaciones dentro del tiempo de muestreo. Dichas conmutaciones se las puede interpretar como una matriz $\mathbf{S}_k = [s_{1k} s_{2k} s_{3k}]$, en la cual cada columna representa conmutación para todo el inversor. Dichas conmutaciones se deben aplicar en tres fracciones de tiempo dentro del tiempo de muestreo $T_s = \tau_{1k} + \tau_{2k} + \tau_{3k}$.

De igual forma, también se puede observar la ley de control como un vector fila de tres

voltajes óptimos aplicados al inversor $\mathbf{v}_{opt} = [v_{opt\alpha\beta,1} \ v_{opt\alpha\beta,2} \ v_{opt\alpha\beta,3}]$ con su respectivos ciclos de trabajo representados por un vector fila $\mathbf{d} = [d_1 \ d_2 \ d_3]^T$. Cabe aclarar que $d_1 + d_2 + d_3 = 1$ y $0 \leq d_1, d_2, d_3 \leq 1$.

El presente trabajo de investigación propone comprender la acción de control no como un conjunto de voltajes y ciclos de trabajo, sino como un voltaje complejo promedio entregado por el inversor hacia el filtro $\bar{v}_{i\alpha\beta,k}$ en el instante k . El mismo se puede obtener mediante el promedio durante un período de muestreo T_s (24) del voltaje instantáneo del inversor $v_{i\alpha\beta}$, que es capaz de representar cualquier punto en el espacio de conmutaciones mostrado en la figura 2.

$$\bar{v}_{i\alpha\beta,k} = \bar{v}_{i\alpha,k} + j\bar{v}_{i\beta,k} = \frac{1}{T_s} \int_{(k-1)T_s}^{kT_s} v_{i\alpha\beta}(t) dt = \mathbf{v}_{optk} \cdot \mathbf{d}_k = \frac{V_{DC}}{2} \cdot \mathbf{T} \cdot \left(\mathbf{I} - \frac{1}{3} \mathbf{1} \right) \cdot \mathbf{S}_k \cdot \mathbf{d}_k \quad (24)$$

Nota: La expresión (24) es para controladores modulados. En el caso de trabajar con controladores del tipo FCS-MPC, basta con utilizar la expresión (8) para hallar el voltaje complejo de la acción de control.

Control Predictivo de Estados Finitos (FCS-MPC)

Como se ha mencionado antes, los controladores modulados seleccionados para el presente trabajo de investigación basan su funcionamiento el control FCS-MPC. Dicha estrategia de control se obtiene al escoger la conmutación que minimiza una función de costo previamente definida. Una de las funciones de costo más comúnmente usadas es la mostrada en (25) que cuantifica el error entre la referencia y la predicción del estado del sistema.

$$g(v) = |v_{ref\alpha\beta,k+2} - v_{f\alpha\beta,k+2}(v)|^2 \quad (25)$$

En donde, $v_{f\alpha\beta,k+2}(v)$ es la predicción del voltaje del filtro en el instante $k + 2$ evaluada en el punto correspondiente al voltaje v , el cual es uno de los 19 voltajes no redundantes previamente mencionados, es decir, $v \in \{v_0, v_1, v_2, \dots, v_{18}\}$. Y $v_{ref\alpha\beta,k+2}$ es la predicción del voltaje de referencia en el instante $k + 2$, la cual se puede obtener mediante la expresión (26).

$$v_{ref\alpha\beta,k} = v_{ref\alpha,k} + jv_{ref\beta,k} = V_n \cdot e^{j2\pi f_n T_s k} \quad (26)$$

En donde, V_n y f_n representan el voltaje y frecuencia nominales del inversor. Finalmente, el voltaje óptimo a aplicar durante el siguiente período de muestreo se obtiene al minimizar la función de costo evaluada en los 19 posibles voltajes del espacio de conmutaciones:

$$v_{opt\alpha\beta,k+1} = \arg \min_v \{g(v)\} \quad (27)$$

Compensación del Retardo de una Muestra

En general, los algoritmos de control predictivos requieren un tiempo de cálculo para poder obtener la acción de control. Dichos cálculos ocurren en un tiempo usualmente menor que el tiempo de muestreo T_s . Es pertinente advertir que mientras el controlador se encuentra realizando los cálculos necesarios para hallar la siguiente acción de control $\bar{v}_{i\alpha\beta,k+1}$, que producirá un estado futuro del sistema en el instante $k + 2$, el sistema se encuentra excitado en el instante k con la acción de control presente $\bar{v}_{i\alpha\beta,k}$, el cual genera un estado futuro del sistema en el instante $k + 1$. En otras palabras, para obtener la acción de control para el instante $k + 1$ se debe realizar la predicción del sistema dos muestras al futuro. Entonces, la predicción en el instante $k + 1$ se la realiza con la expresión (14) evaluada en $\bar{v}_{i\alpha\beta,k}$, mientras que la predicción en el instante $k + 2$ con la expresión (28). Cabe decir, para tiempos de muestreo lo suficientemente cortos, la corriente en la carga presenta muy pocas variaciones entre dos muestras consecutivas, por lo que se puede asumir que $i_{o\alpha\beta,k} \approx i_{o\alpha\beta,k+1}$.

$$\mathbf{x}_{\alpha\beta,k+2}(v) = \begin{bmatrix} i_{f\alpha\beta,k+2}(v) \\ v_{f\alpha\beta,k+2}(v) \end{bmatrix} = \mathbf{A}_d \cdot \begin{bmatrix} i_{f\alpha\beta,k+1} \\ v_{f\alpha\beta,k+1} \end{bmatrix} + \mathbf{B}_d \cdot \begin{bmatrix} v \\ i_{o\alpha\beta,k} \end{bmatrix} \quad (28)$$

Control Predictivo Modulado (M^2PC)

La estrategia de control, previamente definida en (Donoso y cols., 2018), plantea calcular los ciclos de trabajo dependiendo de la evaluación de la función $g(v)$ de costo en los tres

voltajes presentes en una región \mathcal{R}_j (es decir $v \in \mathcal{R}_j$). Dichas evaluaciones en la región j -ésima se las representan en un vector fila \mathbf{g}_j . Así, el vector de los tres ciclos de trabajo \mathbf{d}_j para la j -ésima región se puede calcular como:

$$\mathbf{d}_j = \frac{Q_j}{\mathbf{g}_j} \quad (29)$$

En donde:

$$Q_j = \frac{1}{\sum 1/\mathbf{g}_j} \quad (30)$$

$$\mathbf{g}_j = g(\mathbf{v}_j) = \left[g(v_{j1}) \quad g(v_{j2}) \quad g(v_{j3}) \right] \quad (31)$$

Las expresiones previas permiten calcular los ciclos de trabajo para cada una de las 24 regiones, entre las cuales se debe escoger la región más óptima \mathcal{R}_{opt} . Dicha región se adquiere al minimizar una nueva función de costo G_j , a la cual, como menciona (Donoso y cols., 2018), se obtiene dependiendo de la función de costo de error $g(v)$ y los ciclos de trabajo como se muestra en (32).

$$G_j = \mathbf{g}_j \cdot \mathbf{d}_j^2 \quad (32)$$

Finalmente, la región más óptima, que contiene el vector de voltajes óptimos \mathbf{v}_{opt} con sus respectivos ciclos de trabajo \mathbf{d}_{opt} se consiguen al hallar el argumento que minimiza G_j . Esto es:

$$\mathcal{R}_{\text{opt}} = \arg \min_j \{G_j\} \quad (33)$$

La estrategia de control del M²PC se encuentra definido paso a paso en la figura del Anexo ??.

Control Predictivo Modulado con Sobre Modulación Óptima (OM²PC)

En contraste con la estrategia convencional, el OM²PC no calcula los ciclos de trabajo basados en la evaluación de la función de costo, sino que mediante la resolución de un sistema de ecuaciones lineales (34). Empero, OM²PC usa la función de costo $g(v)$ para seleccionar la región óptima \mathcal{R}_{opt} .

$$\mathbf{d}_{k+1} = \begin{bmatrix} v_{f\alpha,k+2}(v_{opt1}) & v_{f\alpha,k+2}(v_{opt2}) & v_{f\alpha,k+2}(v_{opt3}) \\ v_{f\beta,k+2}(v_{opt1}) & v_{f\beta,k+2}(v_{opt2}) & v_{f\beta,k+2}(v_{opt3}) \\ 1 & 1 & 1 \end{bmatrix}^{-1} \begin{bmatrix} v_{ref\alpha,k+2} \\ v_{ref\beta,k+2} \\ 1 \end{bmatrix} \quad (34)$$

Sin embargo, es posible conseguir ciclos de trabajo negativos, los cuales no son posibles de ser implementados físicamente, esto ocurre cuando el sistema no pueda alcanzar el voltaje de referencia en un solo tiempo de muestreo T_s . Para resolver dicho inconveniente, (Garcia y cols., 2019) expresa el cálculo de los ángulos θ y ϕ utilizando (35) & (36) para determinar los ciclos de trabajo \mathbf{d}_{k+1} usando (37) pero, solo si los ángulos θ & ϕ se encuentran en un ángulo entre cero y $\pi/2$.

$$\theta = \arccos \frac{\Re\{x_1 x_3^*\}}{|x_1||x_3|} \quad (35)$$

$$\phi = \arccos -\frac{\Re\{x_2 x_3^*\}}{|x_2||x_3|} \quad (36)$$

$$\mathbf{d}_{k+1} = \begin{bmatrix} 0 & \frac{|x_2|}{|x_3|} \cos \phi & \frac{|x_1|}{|x_3|} \cos \theta \end{bmatrix}^T \quad (37)$$

En donde, $\Re\{\cdot\}$ retorna la parte real de un número complejo, x^* representa el conjugado de un número complejo, y las variables x_1 , x_2 & x_3 se obtienen de la siguiente forma:

$$\begin{cases} x_1 = v_{ref\alpha\beta,k+2} - v_{f\alpha\beta,k+2}(v_{opt2}) \\ x_2 = v_{ref\alpha\beta,k+2} - v_{f\alpha\beta,k+2}(v_{opt3}) \\ x_3 = v_{f\alpha\beta,k+2}(v_{opt2}) - v_{f\alpha\beta,k+2}(v_{opt3}) \end{cases} \quad (38)$$

Cabe aclarar que las expresiones (35) y (36), inicialmente descritas en (García y cols., 2019), son adaptadas a las coordenadas $\alpha\beta$ en el presente trabajo. Adicionalmente, este estudio también define la función de costo para las regiones en la estrategia OM²PC como la suma de la función de costo evaluada en los tres voltajes de una región. El diagrama de flujo de la estrategia OM²PC se evidencia paso a paso en el anexo de la figura ??.

$$G_j = \sum_{v \in \mathcal{R}_j} g(v) \quad (39)$$

Control Predictivo Modulado con Restricciones

En la sección anterior se exploraron algunas alternativas, pero la que presenta mejores prestaciones la OM²PC. No obstante, a fin que el controlador neuronal resultante sea lo más robusto posible, se requiere hacer una serie de modificaciones al algoritmo original del OM²PC. Dichas mejoras son: añadir restricciones a la corriente del inductor para mantenerla por debajo de un umbral preestablecido, poder elevar el horizonte de predicción del controlador, y añadir una estrategia de sobre modulación de menor gasto computacional. Así, el presente apartado abordará el proceso para la adición de restricciones a la estrategia OM²PC.

Existen dos principales motivaciones para añadir restricciones a la estrategia de control OM²PC. La primera es para mantener la integridad del inversor, debido a que cuando se considera únicamente el voltaje a la salida del filtro $v_{f\alpha\beta}$ en el proceso de optimización, la corriente en la inductancia puede llegar a tener picos de corriente muy elevados, por ende, la inductancia podría llegar a saturarse, o en el peor de los casos podría corromperse físicamente. Dichos picos de corriente se originan cuando existen perturbaciones en el sistema como son los cambios de referencia o cambios en la carga del inversor, sobre todo si se trata de cargas no lineales. La segunda es para que la futura red neuronal pueda lidiar con valores de corriente en el rango en el que la misma fue entrenada y de tal manera mantener al sistema dentro de un rango conocido por el controlador neuronal.

Cabe indicar que la adición de restricciones al proceso de optimización de un controlador predictivo afecta negativamente al tiempo de establecimiento del sistema controlado.

En este caso, se planea restringir el valor máximo que la corriente en la inductancia puede alcanzar $I_{f_{max}}$, por lo tanto, es esperable que al controlador le tome más tiempo hacer que el voltaje del filtro alcance la referencia deseada, puesto que, mientras mayor sea la corriente que la inductancia pueda manejar, más rápidamente será rechazada una perturbación.

Función de Costo con Restricciones

La función utilizada para cuantificar las restricciones h_{lim} , propuesta por (Dragicevic, 2018), presenta un valor nulo cuando el módulo de la corriente en la bobina es menor que su límite $I_{f_{max}}$. Caso contrario, esta función retorna un valor infinito. lo que permite descartar aquellas predicciones que ocasionen una corriente mayor a la deseada. Es importante mencionar que el valor máximo de la corriente $I_{f_{max}}$, es un valor arbitrario que debe ser dimensionado dependiendo de las limitantes físicas de la propia inductancia. Igualmente, dicha restricción sobre la corriente de la bobina representa un círculo de radio $I_{f_{max}}$ y con centro en origen del plano complejo $\alpha\beta$.

$$h_{lim}(i_{f_{\alpha\beta}}) = \begin{cases} 0 & \text{si } |i_{f_{\alpha\beta}}| < I_{f_{max}} \\ \infty & \text{si } |i_{f_{\alpha\beta}}| \geq I_{f_{max}} \end{cases} \quad (40)$$

Entonces, se puede definir una nueva función de costo $g_c(v)$ tomando en cuenta la restricción en corriente. Dicha función de coste se comporta exactamente igual que la anterior $g(v)$ si la corriente se encuentra dentro del rango admisible.

$$g_c(v) = |v_{ref_{\alpha\beta,k+2}} - v_{f_{\alpha\beta,k+2}}(v)|^2 + h_{lim}(i_{f_{\alpha\beta,k+2}}(v)) \quad (41)$$


Descripción del Algoritmo Propuesto

Supóngase que el inversor se encuentra actualmente en un estado $\mathbf{x}_{\alpha\beta,k}$ y que se encuentra también sometido por la acción de control $\bar{v}_{i_{\alpha\beta,k}}$. Se desea entonces hallar la siguiente acción de control $\bar{v}_{i_{\alpha\beta,k+1}}$, la cual debe llevar a la predicción del voltaje de salida $v_{f_{\alpha\beta,k+2}}$ lo más cerca posible de la predicción de la referencia $v_{ref_{\alpha\beta,k+2}}$ como sea posible. A este punto ya se sabe como el sistema evolucionará en el instante $k + 1$, gracias a la compensación del

retardo de una muestra $\mathbf{x}_{\alpha\beta, k+1}$. Así por ejemplo, se sabe que la región óptima para este caso es la región número 8, es decir $\mathcal{R}_{\text{opt}} = \mathcal{R}_8$, y que por tanto $\mathbf{v}_{\text{opt}} = \mathbf{v}_8 = [v_2, v_{14}, v_8]$, así como se puede apreciar en la figura 5.

Figura 5

Representación gráfica de la adicción de restricciones en la corriente de la bobina.



Asúmase también que, el círculo que representa las restricciones (línea a trozos color roja) desafortunadamente pasa por el medio de la región óptima dividiéndola en dos áreas (verde y roja) como se puede observar en la figura 5. Entonces, se afirma que si la predicción de la corriente en la bobina cae en el área verde (como muestra la flecha azul), esta será entonces una acción de control válida. Caso contrario, si cae en el área roja, está acción de control debe ser descartada, y por consiguiente la región \mathcal{R}_8 ya no debería ser tomada en cuenta en el proceso de optimización actual. Así, una de las regiones aledañas debería ser considerada como la nueva región óptima.

Como se aprecia en la figura 5, si se aplican los voltajes óptimos descritos por \mathcal{R}_8 con sus respectivos ciclos de trabajo, se generaría una corriente $i_{f_{\alpha\beta, k+2}}$ como la mostrada por la flecha azul, la cual se encuentra dentro de la región permitida. Por ende, la región \mathcal{R}_8 debe ser considerada como una región válida. Empero, si aplicamos el proceso de optimización, la región sería considerada como no válida. Esto se debe a que el algoritmo del OM²PC cuantifica a las regiones como la suma de función de costo evaluada en los tres voltajes que conforman una región. Así pues, al usar $g_c(\mathbf{v})$ como función de costo y, si uno de los voltajes de la región

se encuentra fuera del área permitida, dicha región quedará descartada inmediatamente.

Para el ejemplo mostrado en la figura 5 se puede deducir que la función de costo de la región posee un valor infinito ($G_8 = \infty$) a cause de que la función de costo de v_{14} es infinito ($g_c(v_{14}) = \infty$). Dicho de otro modo:

$$G_8 = \sum_{v \in \mathcal{R}_8} g_c(v) = g_c(v_2) + \cancel{g_c(v_{14})}^{\infty} + g_c(v_8) = \infty \quad (42)$$

Así pues, para poder incluir a la región \mathcal{R}_8 como una región válida, se requiere de una modificación al algoritmo mostrado previamente. El presente trabajo plantea evaluar la función de costo ya no con los voltajes que conforman una región, sino con el voltaje promedio ponderado que generan los tres voltajes con sus respectivos ciclos de trabajo. Para ello, se puede definir una nueva función de costo para regiones \tilde{G}_j como:

$$\tilde{G}_j = g_c(\bar{v}_j) = g_c(\mathbf{v}_j \cdot \mathbf{d}_j) \quad (43)$$

En donde, $\bar{v}_j = \mathbf{v}_j \cdot \mathbf{d}_j$ es el promedio ponderado de los tres voltajes de la región j -ésima. Recordando que \mathbf{d}_j debe obtenerse siguiendo el proceso definido para la sobre modulación óptima. Entonces, la región óptima \mathcal{R}_{opt} que contiene el conjunto vectores óptimos \mathbf{v}_{opt} y ciclos de trabajo óptimos \mathbf{d}_{opt} se obtiene al hallar la región que minimiza \tilde{G}_j :

$$\mathcal{R}_{\text{opt}} = \arg \min_j \{\tilde{G}_j\} \quad (44)$$


Algoritmo de Sobre Modulación Extendido

Usualmente cuando se habla de sobre modulación, se refiere a cuando el valor de la referencia a alcanzar se encuentra fuera del hexágono que delimita el espacio de conmutaciones como se demuestra en la figura (18). Dicha sobre modulación se la ha denominado como *Sobre Modulación Externa*, dado a que ocurre fuera del espacio de conmutaciones. Sin embargo, al añadir restricciones a la función de costo (41), se genera un fenómeno que se lo ha nombrado *Sobre Modulación Interna* debido a que ocurre dentro del espacio de conmutaciones.

nes, específicamente en los bordes de las regiones que conforman dicho espacio. En la figura 6 se puede apreciar los tipos de sobre modulación previamente descritos.

Figura 6

Sobre modulación interna y externa generada por la estrategia OM²PC con restricción en la corriente de la bobina.



Recordando el algoritmo del OM²PC, cuando existe sobre modulación externa y si los voltajes se encuentran ordenados como se muestra en la Tabla ??, únicamente el primer elemento del vector de ciclos de trabajo \mathbf{d}_j puede conseguir un valor menor que cero al resolver el sistema de ecuaciones en (34), esto es, $d_{j1} \leq 0$ y $d_{j2}, d_{j3} \geq 0$. Cabe explicar que esto surge ya que la primera posición del vector de voltajes de cada región está ocupada por los voltajes pequeños o nulos ($v_0 - v_6$). Así, d_{j1} debe ser reemplazado por cero cada vez que existe sobre modulación externa, mientras que d_{j2} y d_{j3} deben ser calculados como se explica en el algoritmo del OM²PC.

En contraste, cuando existe sobre modulación interna, cualquiera de los términos del vector de ciclos de trabajo \mathbf{d}_j puede ser menor que cero, ya que el orden no importa. Por consiguiente, se debe detectar cuál de los tres ciclos de trabajo es menor o igual que cero e igualarla a cero. Posteriormente, las otras dos posiciones se calculan de manera similar que en secciones anteriores, pero con las siguientes diferencias dependiendo de cuál de los términos

de \mathbf{d}_j es menor o igual que cero y resolver el sistema de ecuaciones con los tres voltajes de cada región:

$$\mathbf{d}_j = \begin{bmatrix} v_{f\alpha,k+2}(v_{j1}) & v_{f\alpha,k+2}(v_{j2}) & v_{f\alpha,k+2}(v_{j3}) \\ v_{f\beta,k+2}(v_{j1}) & v_{f\beta,k+2}(v_{j2}) & v_{f\beta,k+2}(v_{j3}) \\ 1 & 1 & 1 \end{bmatrix}^{-1} \begin{bmatrix} v_{ref\alpha,k+2} \\ v_{ref\beta,k+2} \\ 1 \end{bmatrix} \quad (45)$$

$$\begin{cases} x_1 = v_{ref\alpha\beta,k+2} - v_{f\alpha\beta,k+2}(u_j) \\ x_2 = v_{ref\alpha\beta,k+2} - v_{f\alpha\beta,k+2}(w_j) \\ x_3 = v_{f\alpha\beta,k+2}(w_j) - v_{f\alpha\beta,k+2}(u_j) \end{cases} \quad (46)$$

En donde:

$$u_j = \begin{cases} v_{j2} & \text{si } d_{j1} \leq 0 \\ v_{j1} & \text{si } d_{j2} \leq 0 \\ v_{j1} & \text{si } d_{j3} \leq 0 \end{cases} \quad (47)$$

$$w_j = \begin{cases} v_{j3} & \text{si } d_{j1} \leq 0 \\ v_{j3} & \text{si } d_{j2} \leq 0 \\ v_{j2} & \text{si } d_{j3} \leq 0 \end{cases} \quad (48)$$

Las expresiones (46), (47) & (48) permiten calcular los ángulos θ y ϕ con las mismas expresiones (35) y (36) definidas previamente. No obstante, para calcular los ciclos de trabajo, se propone definir dos nuevas variables d_ϕ y d_θ , mismas que representan los ciclos de trabajo los dos voltajes no nulos a aplicar, los cuales se calculan a partir del algoritmo original mostrado en (Garcia y cols., 2019):

$$d_\phi = \begin{cases} \frac{|x_2|}{|x_3|} \cos \phi & \text{si } \theta, \phi \leq \pi/2 \\ 1 & \text{si } \theta \geq \pi/2 \\ 0 & \text{caso contrario} \end{cases} \quad (49)$$

$$d_{\theta} = \begin{cases} \frac{|x_1|}{|x_3|} \cos \theta & \text{si } \theta, \phi \leq \pi/2 \\ 1 & \text{si } \phi \geq \pi/2 \\ 0 & \text{caso contrario} \end{cases} \quad (50)$$

Por último, el vector de ciclos de trabajo \mathbf{d}_j se define asimismo en función de dónde se encuentre el término que es menor o igual a cero. De la siguiente forma:

$$\mathbf{d}_j = \begin{cases} [0, d_{\phi}, d_{\theta}]^T & \text{si } d_{j1} \leq 0 \\ [d_{\phi}, 0, d_{\theta}]^T & \text{si } d_{j2} \leq 0 \\ [d_{\phi}, d_{\theta}, 0]^T & \text{si } d_{j3} \leq 0 \end{cases} \quad (51)$$

El diagrama de flujo del algoritmo del OM²PC con restricciones se encuentra detallado en la figuras de los Anexos ?? y ??, en las cuales se una diferencia con el algoritmo original, la propuesta requiere evaluar los ciclos de trabajo para cada una de las 24 regiones, esto conlleva un gasto computacional más elevado, puesto que se debe invertir 24 matrices de 3×3 y además aplicar funciones trigonométricas para la etapa de sobre modulación. Lo que puede significar que la implementación del OM²PC con restricciones sea muy complicada de realizar directamente dado que los tiempos disponibles de cálculo son muy reducidos. Una posible solución que ofrece el presente trabajo es la utilizar un algoritmo de *sobre modulación no óptima* para reducir el gasto computacional de la etapa de sobre modulación, mismo que se discute con mayor detalle en la sección de sobre modulación no óptima.

Nota: Las expresiones desde (46) hasta (51) son una generalización de las expresiones originales definidas en (Garcia y cols., 2019). Las mismas son capaces de producir tanto sobre modulaciones externas como internas.

Sobre Modulación No Óptima

Como se ha mencionado en apartados anteriores, la sobre modulación ocurre cuando el sistema no es capaz de alcanzar la referencia en un instante de tiempo. Como resultado, el vector de ciclos de trabajo \mathbf{d} presenta términos negativos, los cuales son imposibles de im-

plementar en la vida real, ya que carecen de interpretación física. Por ende, un algoritmo de sobre modulación debe remover dichos ciclos de trabajo negativos, al tiempo que modifica los positivos que quedan con el objetivo de que la suma sea igual a uno. Igualmente, en dichas secciones se menciona utilizar dichos algoritmos de sobre modulación requiere un tiempo de computo elevado, el cual muchas veces no se dispone. La presente sección propone un algoritmo de sobre modulación no óptima que exige de un gasto computacional considerablemente más bajo al tiempo que posee un desempeño similar a los otros previamente mencionados.


Sobre Modulación Óptima

Para entender el funcionamiento de la propuesta, es lícito comprender cómo funciona el algoritmo de sobre modulación óptima. Así pues, se conoce que el sistema evolucionará al estado $\mathbf{x}_{\alpha\beta, k+1}$ en el siguiente instante de tiempo. Entonces, se desea calcular entonces la siguiente acción de control $\bar{v}_{i\alpha\beta, k+1}$ que lleve a la predicción del voltaje de salida $v_{f\alpha\beta, k+2}$ lo más cerca posible de la predicción del voltaje de referencia $v_{ref\alpha\beta, k+2}$.

$v_{ref\alpha\beta, k+2}$.

Figura 7

Interpretación de la sobre modulación óptima.



Ejemplificando con la figura 7, la región más óptima sería la \mathcal{R}_8 . Empero, se observa que no se puede alcanzar a la referencia en un solo instante de tiempo k , ya que la referencia se encuentra fuera del espacio de conmutación. En consecuencia, el algoritmo de sobre modulación óptima escoge el punto más cercado del hexágono exterior del espacio de conmutación como nuevo objetivo a alcanzar. Entonces, los voltajes v_8 y v_{14} forman una línea recta, se sabe además que la distancia más corta entre un punto a una recta es la recta perpendicular a la primera recta (representada por la línea negra) y que pasa por el punto $v_{ref\alpha\beta,k+2}$. Así, el propósito del control es ahora llegar, en el instante $k + 2$, al punto de intersección entre las dos rectas previamente mencionadas. Dicho punto se lo representa con el vector color rojo. Para calcular dicho punto el controlador aplica los pasos descritos en secciones anteriores.

Cabe expresar que el algoritmo descrito previamente es válido si el punto más cercano a la referencia se encuentra en una de las rectas del hexágono como se muestra en las áreas de color verde de la figura 7. Si, por el contrario el punto más cercano a la referencia se ubica en los vértices del hexágono (área amarilla), entonces el punto más cercano es el mismo vértice del hexágono que para el ejemplo sería v_{14} .

Algoritmo de Sobre Modulación No Óptima

El voltaje de referencia $v_{ref\alpha\beta,k+2}$ puede ser expresado, cuando no existe sobre modulación, como la combinación lineal entre las predicciones del voltaje del filtro $v_{f\alpha\beta,k+2}$ evaluado en los voltajes de una región \mathbf{v}_j y sus respectivos ciclos de trabajo \mathbf{d}_j :

$$\underbrace{\begin{bmatrix} v_{f\alpha,k+2}(v_{j1}) & v_{f\alpha,k+2}(v_{j2}) & v_{f\alpha,k+2}(v_{j3}) \\ v_{f\beta,k+2}(v_{j1}) & v_{f\beta,k+2}(v_{j2}) & v_{f\beta,k+2}(v_{j3}) \\ 1 & 1 & 1 \end{bmatrix}}_{\mathbf{v}_f(\mathbf{v}_j)} \cdot \underbrace{\begin{bmatrix} d_{j1} \\ d_{j2} \\ d_{j2} \end{bmatrix}}_{\mathbf{d}_j} = \underbrace{\begin{bmatrix} v_{ref\alpha,k+2} \\ v_{ref\beta,k+2} \\ 1 \end{bmatrix}}_{\mathbf{v}_{ref}} \quad (52)$$


La misma expresión puede ser representada, en el plano $\alpha\beta$, mediante el error entre la referencia y las predicciones de los voltajes del filtro, así pues $E_{ji} = v_{ref\alpha\beta,k+2} - v_{f\alpha\beta,k+2}(v_{ji})$. En la figura 8 se muestra la interpretación gráfica de dichos errores.

$$d_{j1}E_{j1} + d_{j2}E_{j2} + d_{j3}E_{j3} = 0 \quad (53)$$

La expresión (53) demuestra que a mayor distancia entre un voltaje v_{ji} y la referencia $v_{ref\alpha\beta,k+2}$ menor será su aporte a la acción de control. Tomando el ejemplo de la figura 8, los vectores v_{j2} y v_{j3} tendrán un mayor aporte a la acción de control total que v_{j1} dado a que este último se encuentra más lejos. Es decir, ya que $|E_{j1}| > |E_{j2}|, |E_{j3}|$ entonces $|d_{j1}| < |d_{j2}|, |d_{j3}|$.

Figura 8

Interpretación de la sobre modulación no óptima.



Ahora bien, cuando existe sobre modulación (como en la figura 8), se debe seleccionar una nueva referencia $v'_{ref\alpha\beta,k+2}$ que se encuentre en el borde externo del espacio de conmutaciones (en este caso sobre la recta ℓ). Por tanto, el sistema de ecuaciones puede reescribirse de la siguiente forma:

$$\begin{bmatrix} v_{f\alpha,k+2}(v_{j1}) & v_{f\alpha,k+2}(v_{j2}) & v_{f\alpha,k+2}(v_{j3}) \\ v_{f\beta,k+2}(v_{j1}) & v_{f\beta,k+2}(v_{j2}) & v_{f\beta,k+2}(v_{j3}) \\ 1 & 1 & 1 \end{bmatrix} \cdot \begin{bmatrix} 0 \\ d \\ 1-d \end{bmatrix} = \begin{bmatrix} v'_{ref\alpha,k+2} \\ v'_{ref\beta,k+2} \\ 1 \end{bmatrix} \quad (54)$$

En donde $0 \leq d \leq 1$. Reescribiendo la expresión (54) en el plano $\alpha\beta$, se obtiene la ecuación de la recta que pasa por v_{j2} y v_{j3} :

$$\ell : dv_{f_{\alpha\beta,k+2}}(v_{j2}) + (1-d)v_{f_{\alpha\beta,k+2}}(v_{j3}) = v'_{ref_{\alpha\beta,k+2}} \quad (55)$$

Cabe explicar que tanto el algoritmo de sobre modulación óptima como no óptima deben satisfacer la ecuación de la recta ℓ . La diferencia entre ellos radica en donde se ubica la nueva referencia $v'_{ref_{\alpha\beta,k+2}}$. En el caso de la sobre modulación óptima, este punto se lo ubica en el punto que reduce la distancia entre la referencia y la recta ℓ . Es decir, $v'_{ref_{\alpha\beta,k+2}} = v_{opt}$ en la figura 8. En contraste, el algoritmo de sobre modulación no óptima, propone en aproximar el cálculo del punto óptimo bajo la consideración de que la contribución de v_{j1} es siempre menor que la de los otros dos voltajes, esto dado que se encuentra más lejos. Por tanto, esta contribución se puede obviar. Desafortunadamente, al descartar la contribución del primer voltaje, la suma de los otros dos ciclos de trabajo es diferente de uno, es decir $d_{j2} + d_{j3} \neq 1$. Entonces, para hacer que dicha suma sea igual a uno, se propone el normalizar ambos elementos con respecto a la suma de los dos. Es decir:

$$d = \frac{d_{j2}}{d_{j2} + d_{j3}} \quad \text{y} \quad 1 - d = \frac{d_{j3}}{d_{j2} + d_{j3}} \quad (56)$$

Con lo que el vector de ciclos de trabajo queda definido como:

$$\mathbf{d}_j = \begin{bmatrix} 0 \\ d \\ 1 - d \end{bmatrix} \quad (57)$$

Validación del Algoritmo Propuesto


Para validar la aproximación propuesta en el presente apartado, se propone calcular el error porcentual (58) entre la acción de control generada por el algoritmo de sobre modulación óptima (v_{opt}) y la aproximación propuesta (v_{nopt}). Para ello, se calcula únicamente la acción de control que cada algoritmo genera para un voltaje de referencia que se encuentra fuera

del espacio de conmutaciones. La figura 9 manifiesta la diferencia que existe entre los dos algoritmos propuestos. Cabe señalar que el algoritmo usado para el test es el descrito por el diagrama de flujo mostrado en la figura ??.

$$e = 100 \% \frac{|v_{opt} - v_{nopt}|}{|v_{opt}|} \quad (58)$$

Figura 9

Error calculado entre el algoritmo se sobre modulación óptima v_{opt} y la aproximación propuesta v_{nopt} .

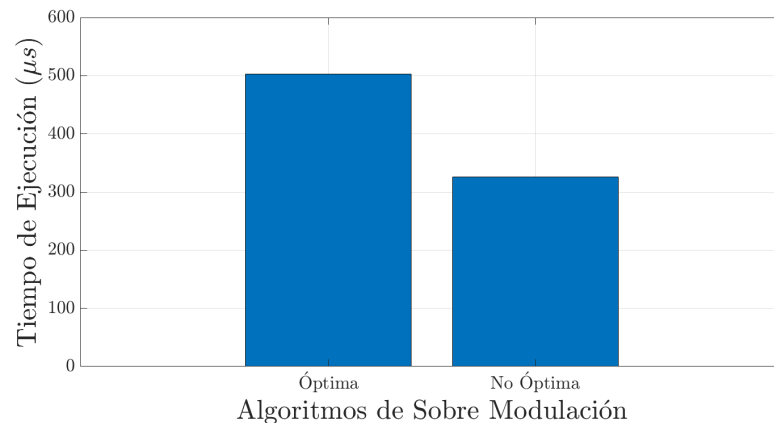


Como se puede apreciar en la figura 9, no existe diferencia entre los dos algoritmos dentro del espacio de conmutaciones, lo cual se espera, puesto que ambos únicamente ocurren fuera del mismo. De igual manera, se observa que la diferencia es nula en los vértices, así como en medio de cada una de las rectas que forman las regiones. Otro punto a contemplar es que el error entre los algoritmos aumenta mientras más lejos se encuentre la referencia. Dicho error se incrementa hasta un valor máximo de aproximadamente 28.7% cuando la referencia posee una magnitud que tiende al infinito, dicho de otro modo, si $|v_{ref_{\alpha\beta}}| \rightarrow \infty$, entonces $e \rightarrow 28,7 \%$. En suma, se infiere que la diferencia entre los dos algoritmos no crece indefinidamente, sino

que posee una cota máxima.

Figura 10

Tiempo de ejecución promedio de los algoritmos de sobre modulación en un computador Intel Core i7-6700 a 3.40 GHz con 32 GB en RAM.



La figura 10 demuestra la diferencia que existe en términos de tiempo de ejecución para ambos algoritmos. La sobre modulación no óptima reduce el tiempo de cómputo en un 35 % en promedio respecto a la sobre modulación óptima. Para medir los tiempos de ejecución de los algoritmos, se generaron 1×10^5 muestras para cada variable de forma aleatoria. Para los voltajes $v_{ref\alpha\beta,k}$, $v_{f\alpha\beta,k}$ y $\bar{v}_{i\alpha\beta,k}$ de entre $\pm\sqrt{2}V_n$, y para las corrientes $i_{f\alpha\beta,k}$ y $i_{o\alpha\beta,k}$ entre $\pm I_{fmax}$ tanto para componente real α como para componente imaginaria β . Dichas variables son introducidas en los dos algoritmos con el objetivo de medir el tiempo de cómputo que cada algoritmo al calcular la acción de control futura $\bar{v}_{i\alpha\beta,k+1}$.


Control Predictivo Modulado Basado en Redes Neuronales

La presente sección describe el proceso que se ha realizado para aproximar el controlador modulado predictivo mediante redes neuronales. En la figura 11 se aprecia el lazo de control propuesto. Así, se puede notar que el bloque del controlador, mostrado en la figura 14, es reemplazado por un controlador neuronal en conjunto con un bloque de pre-modulación. En pocas palabras, el controlador neuronal se encarga de predecir una aproximación de la acción de control futura $\bar{v}_{i\alpha\beta,k+1}$, al tiempo que el bloque de pre-modulación transforma dicha acción

de control en el vector de voltajes óptimos \mathbf{v}_{opt} y sus respectivos ciclos de trabajo \mathbf{d} .

Figura 11

Lazo de control propuesto.



Controlador Neuronal

Para aproximar el comportamiento del controlador predictivo modulado, descrito en secciones anteriores, se lo puede considerar como una caja negra que aplica una función $f(\cdot)$ a un conjunto de variables, y que a su salida retorna el voltaje complejo promedio del inversor, de tal forma que:

$$\bar{v}_{i\alpha\beta, k+1} = f(i_{f\alpha\beta, k}, v_{f\alpha\beta, k}, i_{o\alpha\beta, k}, v_{ref\alpha\beta, k}, \bar{v}_{i\alpha\beta, k}) \quad (59)$$

Se comprende con certeza que la siguiente acción de control $\bar{v}_{i\alpha\beta, k+1}$ depende del estado actual del sistema (definido por: $i_{f\alpha\beta, k}$, $v_{f\alpha\beta, k}$ & $i_{o\alpha\beta, k}$), la referencia a alcanzar $v_{ref\alpha\beta, k}$ y la acción de control actual $\bar{v}_{i\alpha\beta, k}$. Desafortunadamente se desconoce si existe una expresión matemática que relacione directamente la entrada y la salida de la función $f(\cdot)$ a causa que la salida se calcula, mediante un conjunto de pasos descritos en secciones anteriores. Lamentablemente el algoritmo del OM²PC requiere de un proceso de optimización, lo que incrementa aún más la complejidad para obtener una expresión analítica de $f(\cdot)$.

El presente trabajo investigativo, aborda el uso de redes neuronales para aproximar el comportamiento de $f(\cdot)$, esto es, mediante la ANN se puede obtener una función $\tilde{f}(\cdot)$ que aproxima a $f(\cdot)$ y por lo tanto, la salida es una aproximación de la acción de control futura definida por:

$$\tilde{v}_{i\alpha\beta, k+1} = \tilde{v}_{i\alpha, k+1} + j\tilde{v}_{i\beta, k+1} = \tilde{f}(i_{f\alpha\beta, k}, v_{f\alpha\beta, k}, i_{o\alpha\beta, k}, v_{ref\alpha\beta, k}, \tilde{v}_{i\alpha\beta, k}) \quad (60)$$

Entonces, para representar la función $\tilde{f}(\cdot)$ se ha optado por una red neuronal conformada por tres capas. La primera, denominada capa de entrada, está conformada por diez neuronas, considerando que la red únicamente trabaja con números reales mas no con números complejos; así pues se requiere dos neuronas para cada variable que se conecte a la entrada de la red. La segunda, nombrada capa oculta, es un conjunto de N neuronas, dicho número se ajusta dependiendo de la precisión con la que la red es capaz de predecir. Y finalmente, la capa de salida, está conformada por dos neuronas a fin de representar las componentes $\alpha\beta$ de la acción de control futura $\tilde{v}_{i\alpha\beta, k+1}$. La configuración de la red neuronal se la puede apreciar en la figura del Anexo ?? con más detalle.

Generación de Patrones de Entrenamiento

Para poder aproximar el comportamiento del OM²PC mediante una red neuronal, se debe generar patrones de entrenamiento que sean capaces de representar la relación que existe entre entrada y salida de la función $f(\cdot)$. Dichos patrones se han generado mediante simulaciones en el software de Matlab®-Simulink. Para asegurar que los datos generados de cada simulación sean diferentes, se ha considerado los siguientes escenarios:

- Se asigna una carga a la salida del inversor en cada simulación; estas pueden ser: cargas resistivas (R), cargas no lineales (RC), e incluso sin carga a la salida.
- También, al fijar una carga, el valor de la misma es diferente para cada simulación, e incluso las mismas son conectadas a diferentes tiempos dentro de la simulación. El rango de variación de la componente resistiva para cada carga varía entre 25Ω hasta 110Ω .
- El sistema está pensado para funcionar a una tensión nominal de $110V_{RMS}$ a $60Hz$, éstos se mantienen constantes durante las simulaciones. Sin embargo, se ha optado por cambiar el ángulo de fase inicial en cada simulación, de manera de que cada simulación recibe un voltaje diferente al anterior pese a que la magnitud y la frecuencia son

constantes.

- Las variables de interés son muestreadas a una frecuencia de $f_s = 10kHz$ y cada simulación es ejecutada por un tiempo de 0.166 segundos lo, que equivale a 10 ciclos del voltaje de referencia a $60Hz$.
- El controlador utilizado es el OM²PC con restricción de 15 amperios en la corriente de la bobina.

Entrenamiento del Controlador Neuronal

Con los patrones de entrenamiento generados, se procede a entrenar y validar la red neuronal. Hay que tomar en cuenta que la acción de control $\bar{v}_{i\alpha\beta, k+1}$ está definida en el plano complejo $\alpha\beta$, y en consecuencia, posee dos términos que la red neuronal debe ser capaz de predecir: $\bar{v}_{i\alpha, k+1}$ y $\bar{v}_{i\beta, k+1}$. Dichos términos son variables continuas en el espacio de conmutación que se encuentran dentro de los siguientes rangos, mismos que se pueden obtener de la Tabla ??:

$$-\frac{2}{3}V_{DC} \leq \bar{v}_{i\alpha, k+1} \leq \frac{2}{3}V_{DC} \tag{61}$$

$$-\frac{\sqrt{3}}{3}V_{DC} \leq \bar{v}_{i\beta, k+1} \leq \frac{\sqrt{3}}{3}V_{DC}$$

Así, para que la red neuronal sea capaz de predecir ambos términos, se propone el uso de una regresión múltiple. A diferencia de (Mohamed y cols., 2019) y (Novak y Dragicevic, 2021), los cuales utilizan clasificadores para predecir la combinación de conmutación a aplicar en el siguiente intervalo de tiempo.

Otro punto importante a tomar en cuenta, es la función de activación de las neuronas en cada capa, así como también la cantidad de neuronas presentes en la capa oculta (N). Por un lado, al ser un problema de regresión, la capa de salida posee una función de activación lineal. Por otro lado, la función de activación de la capa escondida debe ser escogida de acuerdo al rendimiento que éstas presentan. Entre las que se han utilizado para el estudio se encuentran las funciones (en el lenguaje de MATLAB): *tansig*, *poslin*, *radbas*, *logsig* y *satlins*. Finalmente,

para el entrenamiento se ha considerado un 70% de los datos generados, un 15% para la validación y el restante 15% para el test de la misma red.

Etapa de Pre-Modulación

Existen tres motivaciones para utilizar una etapa de pre-modulación en el lazo de control mostrado en la figura 11. La primera motivación, radica en que tal y como se ha mencionado anteriormente, la red neuronal es únicamente capaz de aproximar la acción de control futura representada por la variable compleja $\tilde{v}_{i\alpha\beta,k+1}$. No obstante, para controlar el 3φ -3L-VSI, se requiere conocer el vector de voltajes óptimos \mathbf{v}_{opt} y los respectivos ciclos de trabajo \mathbf{d}_{opt} que juntos generen la acción de control, es decir $\tilde{v}_{i\alpha\beta,k+1} = \mathbf{v}_{opt} \cdot \mathbf{d}_{opt}$. La segunda motivación, es por el hecho que el controlador neuronal puede generar acciones de control que se encuentren fuera del espacio de conmutaciones. Por tanto, estas acciones de control deben ser sobre moduladas a fin de llevarlas a un punto en los bordes del espacio de conmutaciones. La tercera motivación, el controlador neuronal necesita saber la acción de control actual $\tilde{v}_{i\alpha\beta,k}$ ante la cual el sistema está siendo sometido. Si bien, se puede pensar que $\tilde{v}_{i\alpha\beta,k}$ se obtiene desplazando temporalmente una unidad de tiempo a $\tilde{v}_{i\alpha\beta,k+1}$, la realidad es que esto es verdad únicamente si no existe sobre modulación de la acción de control generada por la red neuronal. Dicho fenómeno se muestra con mayor claridad en la figura 12.

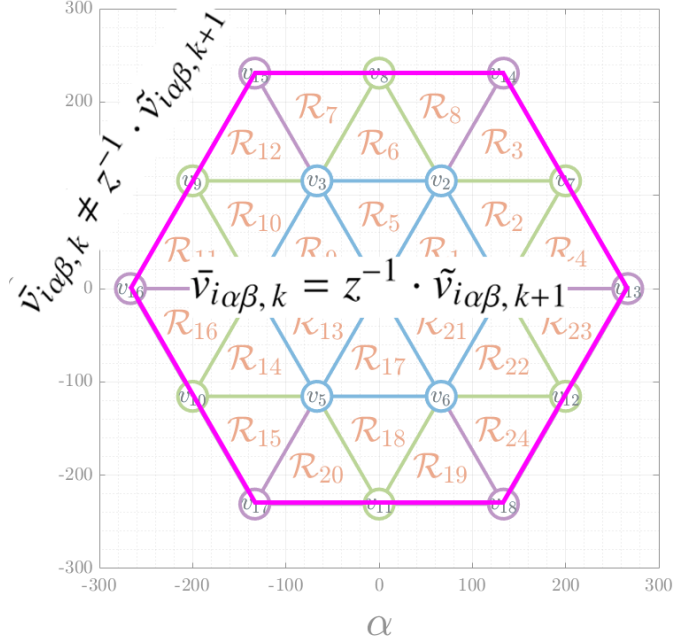
Algoritmo de Pre-Modulación

La acción de control aproximada tiene que ser igual al producto de sus voltajes óptimos y los respectivos ciclos de trabajo, esto es $\tilde{v}_{i\alpha\beta,k+1} = \mathbf{v}_{opt} \cdot \mathbf{d}_{opt}$. Empero, al tratarse de operaciones vectoriales, este producto no puede ser invertido fácilmente, por lo que se requiere de otra estrategia para hallar dichos vectores. Una posible alternativa puede ser el calcular la distancia entre el punto $\tilde{v}_{i\alpha\beta,k+1}$ y el centro de todas las regiones, para posteriormente hallar la región óptima al minimizar dichas distancias. Es decir:

$$\mathcal{R}_{opt} = \arg \min_j \left| \tilde{v}_{i\alpha\beta,k+1} - \frac{1}{3} \sum_{i=1}^3 v_{ji} \right|^2 \quad (62)$$

Figura 12

Rango de valores en los que $\bar{v}_{i\alpha\beta,k} = z^{-1} \cdot \tilde{v}_{i\alpha\beta,k+1}$. Fuera del mismo $\tilde{v}_{i\alpha\beta,k+1}$ necesita ser sobre modulado.



Desafortunadamente, esto puede incrementar mucho el coste computacional ya que requiere evaluar todas y cada una de las 24 regiones disponibles. La alternativa propuesta en el presente trabajo es deducir la región óptima directamente. Para ello, se considera que en este caso se trata de buscar la región óptima en el espacio de conmutaciones de $v_{i\alpha\beta}$ en lugar de $v_{f\alpha\beta}$ como en los escenarios pasados. Tomando esto en cuenta, se puede dividir el espacio de conmutaciones en las componentes α y β de cada uno de los vértices de dicho espacio, tal y como se expresa en la figura 13. Con dichas divisiones, se puede hallar la posición \mathbf{p} en donde se encuentra la acción de control $\tilde{v}_{i\alpha\beta,k+1}$:


$$\mathbf{p} = \begin{bmatrix} p_\alpha \\ p_\beta \end{bmatrix} = \begin{bmatrix} \lceil \tilde{v}_{i\alpha,k+1}/\Delta v_\alpha \rceil + 5 \\ \lceil \tilde{v}_{i\beta,k+1}/\Delta v_\beta \rceil + 3 \end{bmatrix} \quad (63)$$

En donde $\lceil \cdot \rceil$ retorna el número entero más grande y que sea menor o igual que su argumento, y:

$$\begin{aligned}\Delta v_\alpha &= V_{DC}/6 \\ \Delta v_\beta &= \sqrt{3}/6 \cdot V_{DC}\end{aligned}\quad (64)$$

Figura 13

División de las regiones del espacio de conmutaciones.



Conociendo la posición \mathbf{p} en donde se encuentra $\tilde{v}_{i\alpha\beta, k+1}$, se puede deducir que existen dos posibles regiones en las que se encuentra la acción de control, la región de la izquierda $\mathcal{R}_{\text{left},\mathbf{p}}$ y la región de la derecha $\mathcal{R}_{\text{right},\mathbf{p}}$. De la misma forma, se puede determinar que en la esquina inferior izquierda de cada rectángulo existe siempre un voltaje que lo podemos llamar $v_{s\alpha\beta, \mathbf{p}} \in \{v_0, v_1, \dots, v_{18}\}$. Además, cada rectángulo está atravesado por una diagonal que puede tener una pendiente positiva o negativa de $m_{\mathbf{p}} = \pm \tan 60^\circ$ dependiendo de la posición \mathbf{p} . Entonces, la región óptima \mathcal{R}_{opt} se puede hallar fácilmente de la siguiente forma:

$$\mathcal{R}_{\text{opt}} = \begin{cases} \mathcal{R}_{\text{right},\mathbf{p}} & \text{si } m_{v_x} \leq m_{\mathbf{p}} \\ \mathcal{R}_{\text{left},\mathbf{p}} & \text{si } m_{v_x} > m_{\mathbf{p}} \end{cases}\quad (65)$$

En donde:

$$m_{v_x} = \frac{v_{x\beta}}{v_{x\alpha}} \quad \& \quad v_{x\alpha\beta} = \tilde{v}_{i\alpha\beta, k+1} - v_{s\alpha\beta, \mathbf{p}} \quad (66)$$

Con la región óptima obtenida \mathcal{R}_{opt} , se obtiene también el vector de voltajes óptimo \mathbf{v}_{opt} , por lo que resta únicamente hallar los ciclos de trabajo \mathbf{d}_{opt} . Recordando que los ciclos de trabajo se pueden calcular de manera similar que con la expresión (34):

$$\mathbf{d}_{\text{opt}} = \underbrace{\begin{bmatrix} v_{\text{opt}1, \alpha} & v_{\text{opt}2, \alpha} & v_{\text{opt}3, \alpha} \\ v_{\text{opt}1, \beta} & v_{\text{opt}2, \beta} & v_{\text{opt}3, \beta} \\ 1 & 1 & 1 \end{bmatrix}^{-1}}_{\mathbf{V}_{\text{opt}}^{-1}} \cdot \underbrace{\begin{bmatrix} \tilde{v}_{i\alpha, k+1} \\ \tilde{v}_{i\beta, k+1} \\ 1 \end{bmatrix}}_{\tilde{\mathbf{v}}_i} \quad (67)$$

Es importante notar que $\mathbf{V}_{\text{opt}}^{-1}$ es una matriz que se puede invertir de antemano, puesto que todos los elementos de la matriz son conocidos y constantes. En efecto, existen 24 matrices \mathbf{V} , una por cada una de las regiones; esto permite que el cálculo de los ciclos de trabajo pase de ser una inversión de una matriz de 3×3 a una simple multiplicación de una matriz por un vector como se aprecia en (67).

Como se explica en la sección de la sobre modulación óptima, basta con comparar el primer elemento del vector de ciclos de trabajo $d_{\text{opt}1}$ para detectar si se debe realizar la sobre modulación tal y como describe la expresión (57). Esto sucede ya que en este escenario no existe sobre modulación interna y, por tanto solo $d_{\text{opt}1}$ puede ser menor que cero. Para finalizar, la acción de control que se aplica al inversor es $\bar{v}_{i\alpha\beta, k+1} = \mathbf{v}_{\text{opt}} \cdot \mathbf{d}_{\text{opt}}$, misma que se debe retroalimentar al controlador neuronal al siguiente instante de tiempo para así obtener $\bar{v}_{i\alpha\beta, k}$.


Nota: Aquellos rectángulos ubicados en las esquinas del espacio de conmutaciones, figura 13, se les asigna la región más cercana a los mismos, con el objetivo que el algoritmo tenga una región para operar. Aunque, es pertinente mencionar que en las esquinas siempre habrá sobre modulación.

Resultados

Simulación de las Estrategias de Control

Figura 14

Lazo de control.



La presente sección se realiza la simulación del lazo de control mostrado en la figura 14 mediante el software Matlab®-Simulink con los parámetros presentados en la tabla ?? en la sección de anexos. Ambas estrategias de control son testeadas bajo tres circunstancias diferentes: la primera, es sin carga a la salida del inversor, la segunda, es con una carga lineal RL , y finalmente, es con una carga no lineal basada en un puente de diodos rectificadores trifásico en paralelo a una resistencia y un capacitor. Para analizar el desempeño de las dos estrategias de control, cuatro criterios han sido escogidos, entre los cuales se encuentra: distorsión armónica total (THD), tiempo de establecimiento (t_s), variación total de la señal de control (TV_{vi}), y máximo sobre impulso (M_p). Es importante mencionar que la frecuencia escogida para el PWM es el inverso del tiempo de muestreo con el propósito de que los ciclos de trabajo se actualicen en cada tiempo de muestreo.

$$M_p = 100 \% \times \left(1 - \frac{\max |v_{f\alpha\beta,k}|}{V_n} \right) \quad (68)$$

La variación total de la acción de control (69), también conocida como esfuerzo de

Tabla 1

Caso de estudio 1: Criterios de desempeño cuando no hay carga a la salida.

Controlador	THD (%)	t_s (ms)	TV_{v_i} (V)	M_p (%)
M ² PC	1.21	2.1	2.38E+05	27.49
OM ² PC	0.15	1.3	1.36E+05	18.18

Tabla 2

Caso de estudio 2: Criterios de desempeño al conectar una carga lineal RL.

Controlador	THD (%)	t_s (ms)	TV_{v_i} (V)	M_p (%)
M ² PC	1.24	1.0	1.69E+05	0.79
OM ² PC	0.16	0.9	4.86E+04	0.06

control, es una medida acumulativa de la suavidad de la señal de control entre dos muestras consecutivas (Vilanova, Alfaro, y Vilanova, 2016). Por ende, si una estrategia de control posee una variación total mayor, la misma tendrá una mayor distorsión armónica a su voltaje de salida.

$$TV_{v_i} = \sum_{k=1}^{\infty} |\bar{v}_{i\alpha\beta, k+1} - \bar{v}_{i\alpha\beta, k}| \quad (69)$$

Los resultados de las simulaciones se encuentran resumidos en las tablas 1, 2, & 3. Una estrategia de control resulta ser mejor si la misma posee un menor THD, un menor tiempo de establecimiento. menor variación total y menor máximo sobre impulso.

Adicionalmente, para obtener un análisis detallado del rendimiento de ambas estrategias, estas son testeadas con diferentes cargas lineales conectadas a la salida. Dichas cargas lineales poseen diferentes factores de potencia (PF). Asimismo, los controladores son puestos a prueba bajo diferentes índices de modulación (m). Dichos resultados se pueden apreciar en la figura 15.

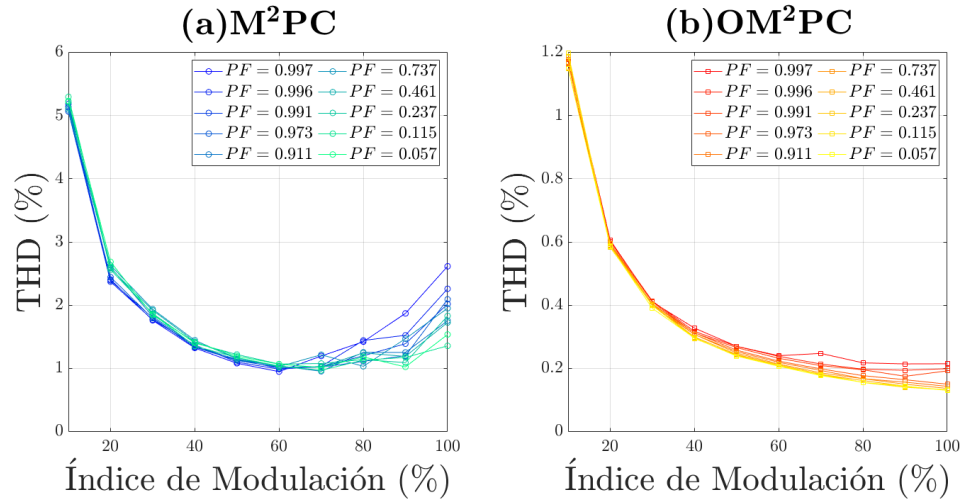
Tabla 3

Case de estudio 3: Criterios de desempeño al conectar una carga no lineal.

Controlador	THD (%)	t_s (ms)	TV_{v_i} (V)	M_p (%)
M ² PC	2.69	4.0	1.77E+05	12.99
OM ² PC	2.19	3.6	1.17E+05	15.10

Figura 15

THD resultante de los voltajes de salida de las dos estrategias de control bajo variaciones en índices de modulación y factores de potencia con cargas lineales RL.



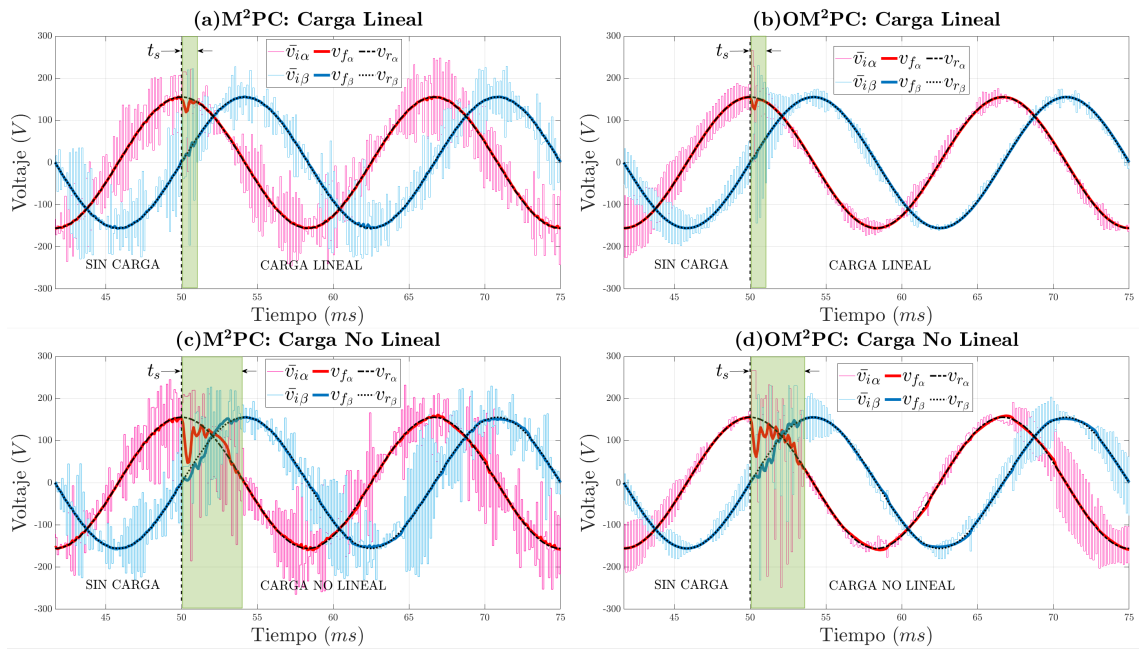
Discusión

La principal desventaja de la estrategia M²PC es el cómo se calculan los ciclos de trabajo, ya que al estar basado en evaluar la función de costo, deviene dos problemas. El primero, es que los ciclos de trabajo no pueden alcanzar un valor de cero o uno, debido a que la función de costo $g(v)$ tampoco puede alcanzar el valor de cero. Siendo así, que la estrategia M²PC no es capaz de tocar los bordes de los triángulos internos del espacio de conmutación (figura2). Como resultado, espacios vacíos son creados en dichos bordes (mismos que son mostrados en la figura 17). El segundo, se produce a causa que los ciclos de trabajo son calculados usando funciones no lineales (29), lo que distorsiona el espacio de conmutación y aumenta el tiempo requerido para alcanzar la referencia con respecto al OM²PC.

Los espacios vacíos generados por la estrategia M²PC son directamente responsables de incrementar el THD resultante a la salida del voltaje, debido a que dichos espacios hacen que las transiciones entre regiones sea más bruscas, lo que termina por aumentar la variación de control y, por consiguiente el THD. Por ejemplo, las figuras 16(a) y (c) demuestran que la acción de control del M²PC parece ser mas ruidosa que la del OM²PC en ambos escenarios.

Figura 16

Comparación de los resultados de las simulaciones entre el controlador M^2PC y el OM^2PC .




Nota. Voltaje de salida $v_{f_{\alpha\beta}}$ (líneas roja y azul), ley de control $\bar{v}_{i_{\alpha\beta}}$ (líneas magenta y cyan), y voltaje de referencia $v_{ref_{\alpha\beta}}$ (líneas negras punteadas) de las dos estrategias de control. Figuras (a) y (b) representan los resultados con perturbaciones con cargas lineales. (c) y (d) muestran los resultados con perturbaciones con cargas no lineales. Las cajas verdes simbolizan el intervalo de tiempo en el cual dichas perturbaciones aún no son rechazadas.

Cabe resaltar que los espacios vacíos ocupan un 57.68 % del espacio de conmutación disponible, lo que significa que existe más espacio vacío que áreas útiles. Este porcentaje es obtenido al calcular el área de A_s , que se muestra a la derecha de la figura 17, y dividiéndola para la tercera parte del área total de una de las regiones.

Figura 17

Acción de control de la estrategia M²PC en el plano $\alpha\beta$.




Nota. El gráfico representa la distribución de la acción de control $\bar{v}_{i\alpha\beta,k+1}$ y el voltaje de referencia $v_{ref\alpha\beta,k}$ en el plano complejo $\alpha\beta$ generada por la estrategia M²PC.

En contraste, la figura 18 no muestra dichos espacios vacíos en la acción de control generada por la estrategia OM²PC. Igualmente se observa que la tendencia de dicha acción de control sigue a la referencia gracias a que el espacio es continuo y puede ser utilizado en su totalidad. Además, gracias a la etapa de sobre modulación, la acción de control del OM²PC puede entregar voltajes más elevados cuando hay perturbaciones, rechazándolas más rápidamente en comparación con M²PC. Dichos voltajes se encuentran ubicados sobre los bordes del hexágono exterior, como se representa en la elipse de color rojo en la figura 18. De la misma forma, dichos voltajes resaltados dentro de las cajas verdes en las figuras 16(d), los cuales son considerablemente mayores que los de la figura 16(c).

Al trabajar con cargas lineales, la diferencia entre el desempeño de las dos estrategias es más notable, como se muestra en la figure 15. OM²PC presenta THDs menores en todos los

Figura 18

Acción de control de la estrategia OM²PC en el plano $\alpha\beta$.



Nota. El gráfico representa la distribución de la acción de control $\bar{v}_{i\alpha\beta, k+1}$ y el voltaje de referencia $v_{ref\alpha\beta, k}$ en el plano complejo $\alpha\beta$ generada por la estrategia OM²PC. La sobre modulación ocurre en los bordes del hexágono exterior (mostrado por el elipse de color rojo).

escenarios tomados a consideración. Si bien, ambas estrategias poseen poca dependencia del factor de potencia, la estrategia M²PC es más susceptible a dicho factor, especialmente cuando el índice de modulación es cercano a uno.

Finalmente, pese que el THD resultante de la estrategia OM²PC es menor que la obtenida por M²PC cuando se trabaja con cargas no lineales, su diferencia no es tan grande comparada con otros escenarios. Esto se debe a que las dos estrategias deben realizar más transiciones entre regiones por defecto cuando lidian con cargas no lineales, lo que termina por enmascarar los espacios vacíos que la estrategia M²PC posee.

Simulación del Controlador Predictivo Modulado con Restricciones

La presente sección pretende realizar una comparación entre las estrategias de control OM²PC con y sin restricciones en la corriente del inductor. Los parámetros utilizados para las simulaciones en la presente sección son los mismos que los descritos en previas simulaciones con la excepción de las estrategias de control utilizadas. Al igual que en dicho apartado, las estrategias de control propuestas son sometidas a tres escenarios diferentes, lo cuales son: sin carga a la salida, carga resistiva y carga no lineal. Es pertinente mencionar que se ha seleccionado una corriente límite de corriente de $I_{f_{max}} = 15A$.


La presente comparación no se tomará en cuenta el THD, debido a que el cambio en los algoritmos ocurren únicamente en la etapa de sobre modulación, misma que no afecta al sistema en estado estable. Lo que si se toma en cuenta es el tiempo de establecimiento con y sin restricciones y el máximo pico de corriente alcanzado por ambas estrategias de control. Las figuras 22 - 25 exponen la evolución del voltaje de salida del inversor y la magnitud alcanzada por la corriente en cada uno de los escenarios propuestos.

Cuando el inversor no posee una carga conectada a la salida, éste genera un pico de corriente de aproximadamente 21 amperios en la bobina, misma que se puede observar en la parte inferior de la figura 20. Asimismo, el tiempo de establecimiento con el controlador sin restricciones es de 1.3 ms. En contraste, en la figura 21 se aprecia cómo la adición de restricción en $i_{f_{\alpha\beta}}$ incrementa el tiempo de establecimiento a 2 ms, pero con el beneficio que el

máximo pico de corriente es apenas superior (momentáneamente) al límite establecido para la misma. Algo similar sucede cuando una carga resistiva de 14 amperios es conectada a la salida del inversor. La figura 22 evidencia la existencia de un pico de 18 amperios en la corriente cuando no hay restricciones, mientras que la figura 23 la corriente nunca llega al límite de 15 amperios. Es importante conocer que en este caso, el controlador con restricciones presenta un menor tiempo de estabilización, posiblemente gracias a que la corriente de la bobina se estabiliza más rápido al no poseer grandes fluctuaciones, y por tanto el voltaje tampoco presenta mayores oscilaciones en el momento de la perturbación en la carga.

Figura 19


Puente de diodos rectificadores usado como carga no lineal con $C_n = 1100\mu F$ y $R_n = 70\Omega$.



Por último, el caso más evidente se produce cuando se conecta una carga no lineal a la salida del inversor. Al estar constituida de un puente rectificador trifásico en paralelo a un capacitor y una resistencia; siendo así que se requiere cargar completamente el capacitor con el objetivo de alcanzar un régimen de estado estacionario. Para la presente prueba se utilizó un condensador de $C_n = 1100\mu F$ y una resistencia de $R_n = 70\Omega$ en la configuración mostrada en la figura 19. Para el caso en que el controlador no posee restricciones se puede ver, en la figura 24, que la corriente adquiere un pico máximo de aproximadamente 90 amperios hasta cargar el capacitor C_n . Dicha corriente puede fácilmente saturar la inductancia o incluso llegar a comprometerla por el exceso de corriente. En cambio, en la figura 25 se puede apreciar como la adición de la restricción limita la cantidad de corriente que puede almacenar la inductancia, la cual en este caso se mantiene en valores menores que el límite definido, exceptuando las veces en que alcanza un pico máximo de 15.65 amperios. Asimismo y como era de esperarse, el tiempo de establecimiento se encuentra dramáticamente afectado, dado que el mismo se incrementa de 8 ms a 27.1 ms , a causa de que la carga del capacitor C_n toma más tiempo.

Figura 20

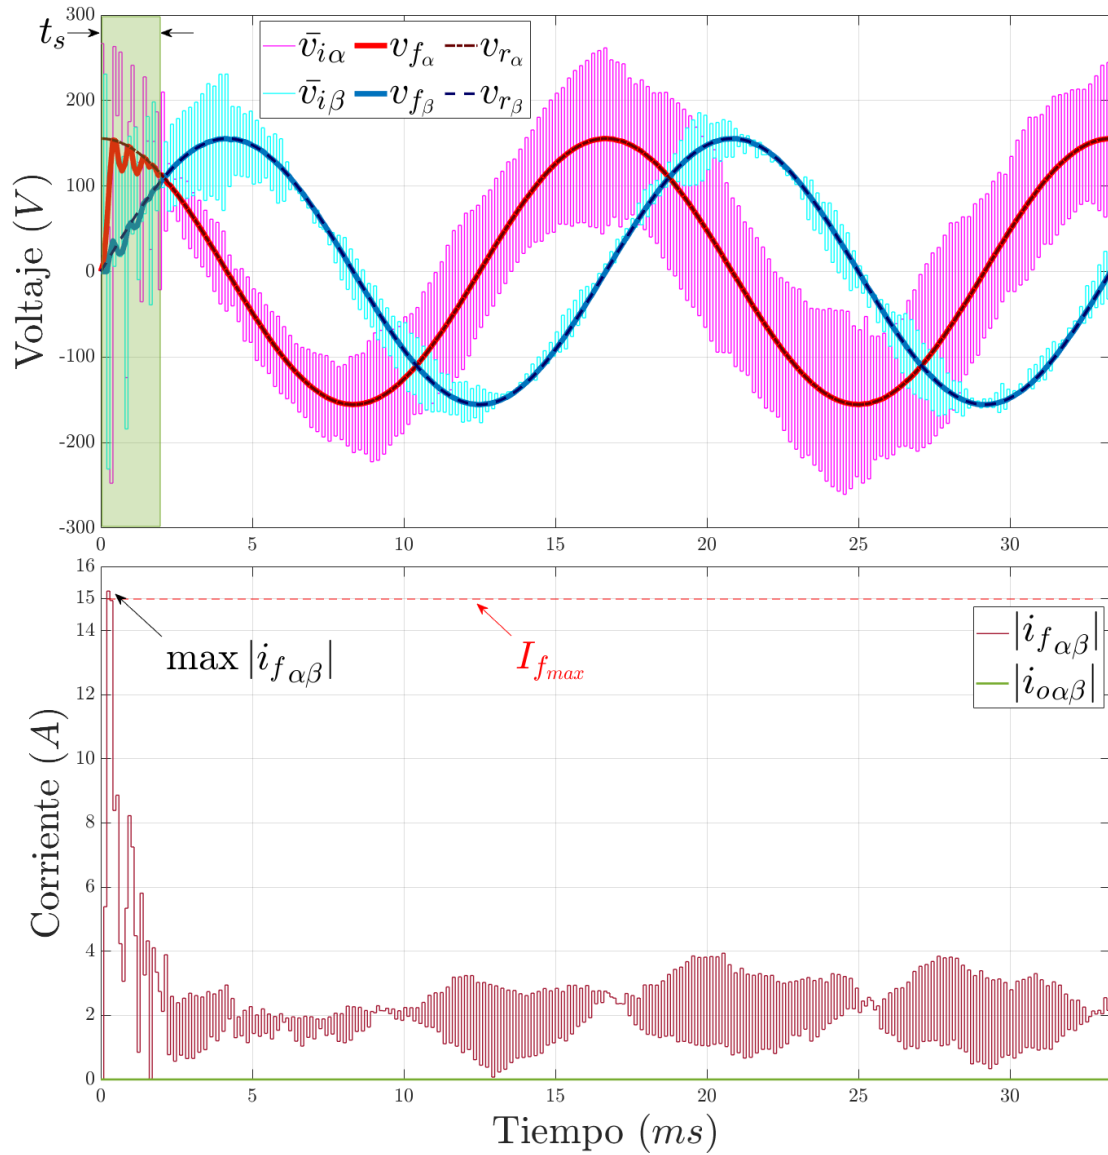
Respuesta del inversor sin carga a la salida con la estrategia OM^2PC sin restricciones.



Nota. (Gráfico superior) Voltaje del inversor $\bar{v}_{i\alpha\beta}$, voltaje del filtro $v_{f\alpha\beta}$ y voltaje de referencia $v_{ref\alpha\beta}$. (Gráfico inferior) Módulo de la corriente de la inductancia $|i_{f\alpha\beta}|$ y de la carga $|i_{o\alpha\beta}|$.

Figura 21


Respuesta del inversor sin carga a la salida con la estrategia OM^2PC con restricción de $I_{fmax} = 15$ amperios en la bobina.



Nota. (Gráfico superior) Voltaje del inversor $\bar{v}_{i\alpha\beta}$, voltaje del filtro $v_{f\alpha\beta}$ y voltaje de referencia $v_{ref\alpha\beta}$. (Gráfico inferior) Módulo de la corriente de la inductancia $|i_{f\alpha\beta}|$ y de la carga $|i_{o\alpha\beta}|$.

Figura 22


Respuesta del inversor ante un perturbación con una carga resistiva a la salida con la estrategia OM^2PC sin restricciones.



Nota. (Gráfico superior) Voltaje del inversor $\bar{v}_{i\alpha\beta}$, voltaje del filtro $v_{f\alpha\beta}$ y voltaje de referencia $v_{ref\alpha\beta}$.
(Gráfico inferior) Módulo de la corriente de la inductancia $|i_{f\alpha\beta}|$ y de la carga $|i_{o\alpha\beta}|$.

Figura 23


Respuesta del inversor ante un perturbación con una carga resistiva a la salida con la estrategia OM^2PC con restricción de $I_{fmax} = 15$ amperios en la bobina.



Nota. (Gráfico superior) Voltaje del inversor $\bar{v}_{i\alpha\beta}$, voltaje del filtro $v_{f\alpha\beta}$ y voltaje de referencia $v_{ref\alpha\beta}$.
 (Gráfico inferior) Módulo de la corriente de la inductancia $|i_{f\alpha\beta}|$ y de la carga $|i_{o\alpha\beta}|$.

Figura 24


Respuesta del inversor ante un perturbación con una carga no lineal a la salida con la estrategia OM^2PC sin restricciones.



Nota. (Gráfico superior) Voltaje del inversor $\bar{v}_{i\alpha\beta}$, voltaje del filtro $v_{f\alpha\beta}$ y voltaje de referencia $v_{ref\alpha\beta}$. (Gráfico inferior) Módulo de la corriente de la inductancia $|i_{f\alpha\beta}|$ y de la carga $|i_{o\alpha\beta}|$.

Figura 25

Respuesta del inversor ante un perturbación con una carga no lineal a la salida con la estrategia OM^2PC con restricción de $I_{f_{max}} = 15$ amperios en la bobina.



Nota. (Gráfico superior) Voltaje del inversor $\bar{v}_{i\alpha\beta}$, voltaje del filtro $v_{f\alpha\beta}$ y voltaje de referencia $v_{ref\alpha\beta}$.
 (Gráfico inferior) Módulo de la corriente de la inductancia $|i_{f\alpha\beta}|$ y de la carga $|i_{o\alpha\beta}|$.

Simulación del Algoritmo de Sobre Modulación No Óptima

A fin de comparar objetivamente cómo los dos algoritmos de sobre modulación evolucionan, se propone analizar el error porcentual del voltaje a la salida del filtro $v_{f_{\alpha\beta}}$ con respecto a la referencia $v_{ref_{\alpha\beta}}$ tal y como se muestra en la expresión (70). Para ello, se propone utilizar los mismos tres escenarios discutidos en capítulos anteriores, los cuales son: sin carga a la salida, carga resistiva, y carga no lineal.


$$e_k = 100 \% \cdot \frac{|v_{ref_{\alpha\beta,k}} - v_{f_{\alpha\beta,k}}|}{|v_{ref_{\alpha\beta,k}}|} \quad (70)$$

Las figuras 26, 27 y 28 denotan la evolución del error de voltaje ante los tres escenarios descritos. Cabe mencionar que únicamente se muestra el error en tanto que el sistema no ha entrado en estado estacionario, debido a que ambos algoritmos no presentan diferencia alguna.

En la figura 26 se puede apreciar que la sobre modulación no óptima es ligeramente más veloz que la óptima cuando no existe una carga a la salida del inversor. En contraste, lo ocurre cuando se conecta una carga resistiva como se muestra en la figura 27. No obstante, cuando se trata de cargas no lineales, la diferencia entre los dos algoritmos es despreciable, a causa de que el tiempo de establecimiento ante cargas no lineales y restricciones es mucho mayor con respecto a otros escenarios.

Figura 26

Comparación del error del voltaje de salida del inversor con respecto a la referencia para el algoritmo de sobre modulación óptima y no óptima cuando no existe carga a la salida del inversor.

**Figura 27**

Comparación del error del voltaje de salida del inversor con respecto a la referencia para el algoritmo de sobre modulación óptima y no óptima cuando se conecta una carga resistiva a la salida del inversor.

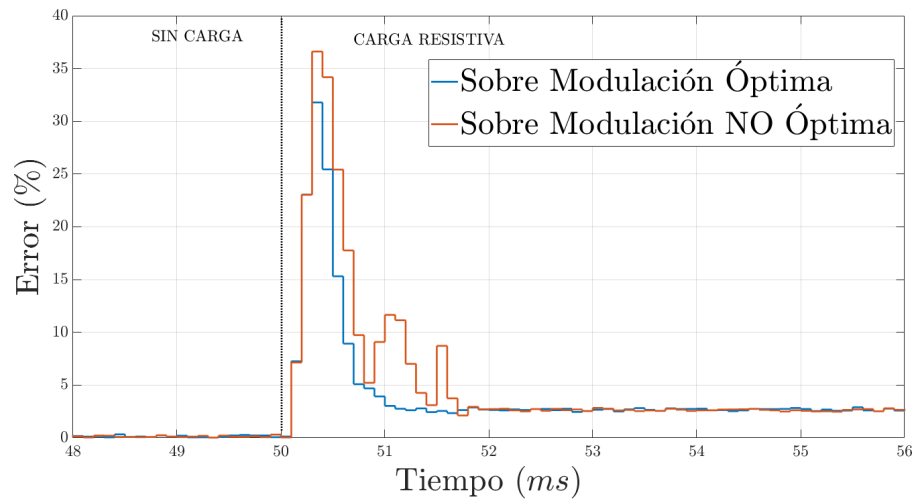
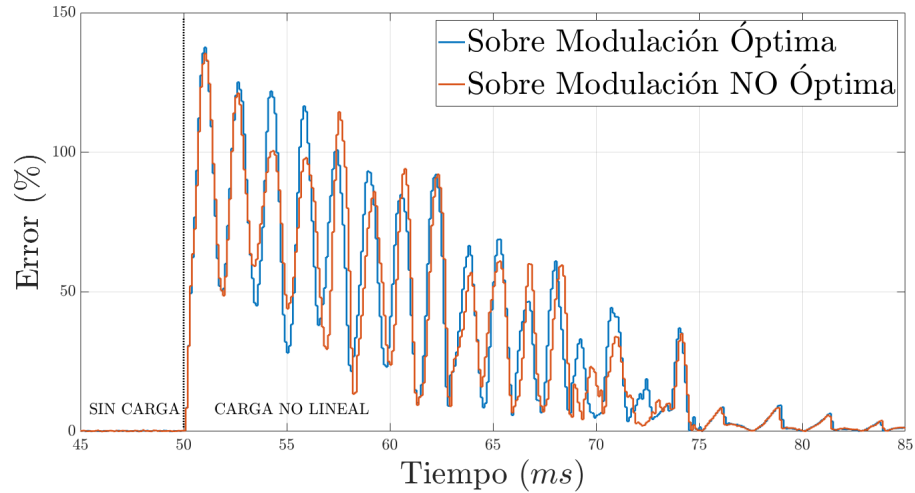


Figura 28

Comparación del error del voltaje de salida del inversor con respecto a la referencia para el algoritmo de sobre modulación óptima y no óptima cuando se conecta un carga no lineal a la salida del inversor.




Controlador Neuronal

La presente sección desea analizar el controlador neuronal propuesto desde cuatro puntos que se han considerado los más relevantes, y son: los resultados de entrenamiento, el análisis de sensibilidad, el desempeño del controlador neuronal, y el tiempo de ejecución del mismo controlador.

Figura 29

Estructura de la red neuronal creada en MATLAB.



Entrenamiento de la Red Neuronal

El presente apartado se manifiesta los resultados de entrenamiento de la red neuronal propuesta. Como primer punto se plantea la selección de la función de activación para


la capa oculta. Como se indicó en la sección correspondiente al entrenamiento del controlador, las funciones de activación consideradas son: *tansig*, *poslin*, *radbas*, *logsig* y *satlins*. Por consiguiente, para determinar la función de activación más adecuada, se realizaron diez entrenamientos con cada una de las funciones de activaciones mencionadas. Posteriormente, se ejecuta la red neuronal resultante en el entorno de Simulink para conocer su desempeño ante cargas lineales y no lineales. Así pues, se han escogido cuatro criterios de desempeño para evaluar cada una de dichas funciones: dos provenientes del proceso de entrenamiento y los otros dos de las simulaciones. El primero es el coeficiente de regresión (R), el cual mientras más cercano a 1 sea, mejor es la regresión. El segundo se utiliza el error cuadrático medio (MSE), el cual mientras menor sea mejor serán las predicciones de la ANN. Finalmente, se utiliza también el THD del inversor controlador con la red neuronal ante las cargas previamente mencionadas. Los resultados de dichos criterios de desempeño se pueden observar en los diagramas de caja de la figura 29; así con excepción de la función *poslim*, las otras cuatro funciones usadas poseen desempeños similares con respecto al resto de criterios de evaluación. Es importante mencionar que el proceso de entrenamiento de la red neuronal se lo realiza mediante la función *feedforwardnet* del toolbox *neural net fitting tool* de MATLAB.

El proceso para determinar la cantidad más óptima de neuronas en la capa oculta ocurre de igual manera que con la selección de la función de activación. Para ello, se establece una cantidad de neuronas que van desde dos hasta quince, igualmente realiza diez iteraciones de entrenamientos y extracción de criterios de desempeño, los cuales se reflejan en la figura 30. Como se puede observar en dicha figura, todos los criterios de desempeño mejoran cuantas más neuronas tenga la capa oculta, adviértase que, a pesar de todo el incremento desmedido de neuronas puede influir negativamente en el coste computacional de la red, sobre todo en dispositivos embebidos que poseen recursos limitados. Se debe agregar que, el desempeño de la red neuronal no mejora significativamente si la cantidad de neuronas supera las diez en la mayoría de criterios seleccionados, esto se muestra experimentalmente en la figura 31.

Tomando en cuenta los resultados de las figuras 29 y 31, se propone el uso de la función de activación *satlins* gracias a que presenta un mejor coste computacional con respecto a las otras dado que se basa en una función lineal. De igual manera, se plantea el uso de diez

Figura 30

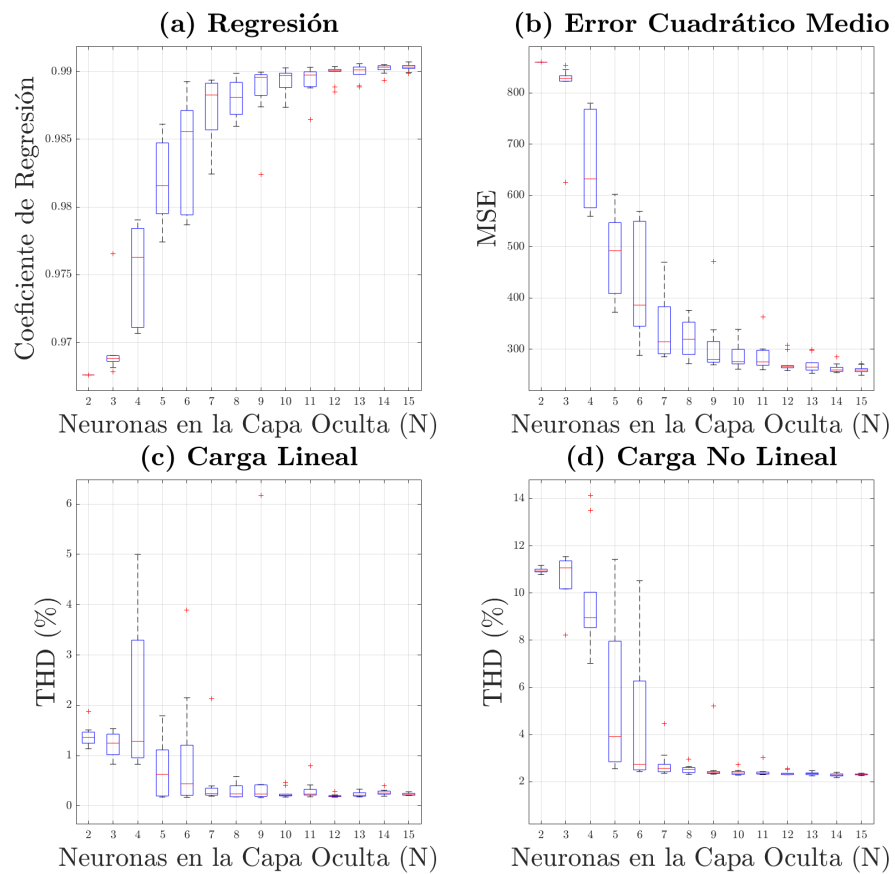
Criterios de desempeño de las cada una de las funciones de activación.



Nota. (a) Coeficiente de regresión. (b) Error cuadrático medio (c) THD ante cargas lineales. (d) THD ante cargas no lineales.

Figura 31

Criterios de desempeño para la selección del número de neuronas (N) de la capa oculta.



Nota. (a) Coeficiente de regresión. (b) Error cuadrático medio (c) THD ante cargas lineales. (d) THD ante cargas no lineales.

neuronas en la capa oculta ($N = 10$). En la figura 32 se aprecia cómo es el resultado del entrenamiento de la red propuesta ante diez mil épocas de entrenamiento mostrados en la figura 33.

Figura 32

Resultados del coeficiente de regresión en el entrenamiento, validación y test de la red neuronal con diez neuronas en la capa oculta y función de activación satlins.





Figura 33

Resultados del error cuadrático medio en el entrenamiento de la red neuronal con diez neuronas en la capa oculta y función de activación satlins durante diez mil épocas de entrenamiento.



Desempeño del Controlador Neuronal

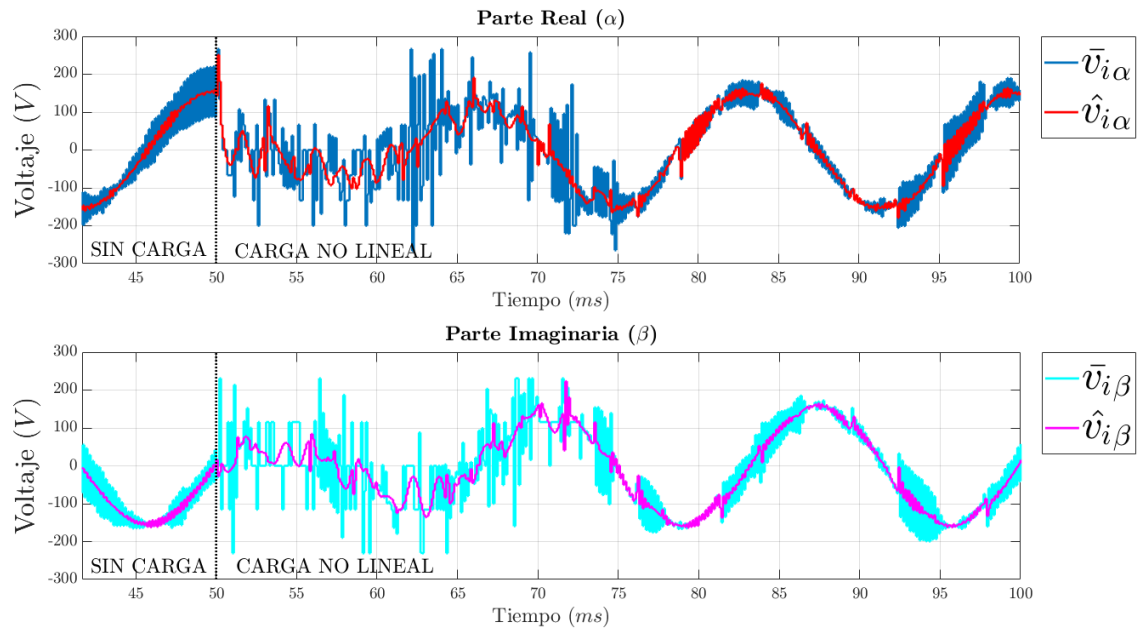
Una vez entrenado el controlador neuronal, se procede a ejecutarlo en conjunto con el inversor 3φ -3L-VSI dentro del entorno de simulación de MATLAB®-Simulink. El presente acápite plantea comparar la evolución del controlador neuronal en relación al algoritmo OM²PC con restricciones desarrollado. Dicha comparación se realiza tomando en cuenta el peor de los escenarios, el cual consiste en conectar una carga no lineal a la salida del inversor ya que exige al controlador un mayor tiempo de estabilización, corrientes de la inductancia más elevadas y mayores distorsiones armónicas en el voltaje de salida.

Como primer punto de comparación se tiene la acción de control $\bar{v}_{i\alpha\beta, k+1}$, mismas que se muestran en la figura 34. Como se puede observar, el controlador ANN-M²PC presenta una ley de control muy similar a la generada por OM²PC, razón por la cual el inversor es correctamente controlado. También, se contempla que la red neuronal genera menores variaciones en la acción de control, sobre todo cuando ocurre una perturbación. Esto se debe a que la red neuronal no ha sido capaz de aprender todas las variaciones que el controlador original realiza mas únicamente la tendencia de la misma acción de control.

A pesar que la red neuronal no replica a la perfección el algoritmo original OM²PC, se

Figura 34

Comparación de los voltajes del inversor con los controladores OM^2PC ($\bar{v}_{i\alpha\beta}$) y $ANN-M^2PC$ ($\hat{v}_{i\alpha\beta}$) ante la conexión de una carga no lineal.

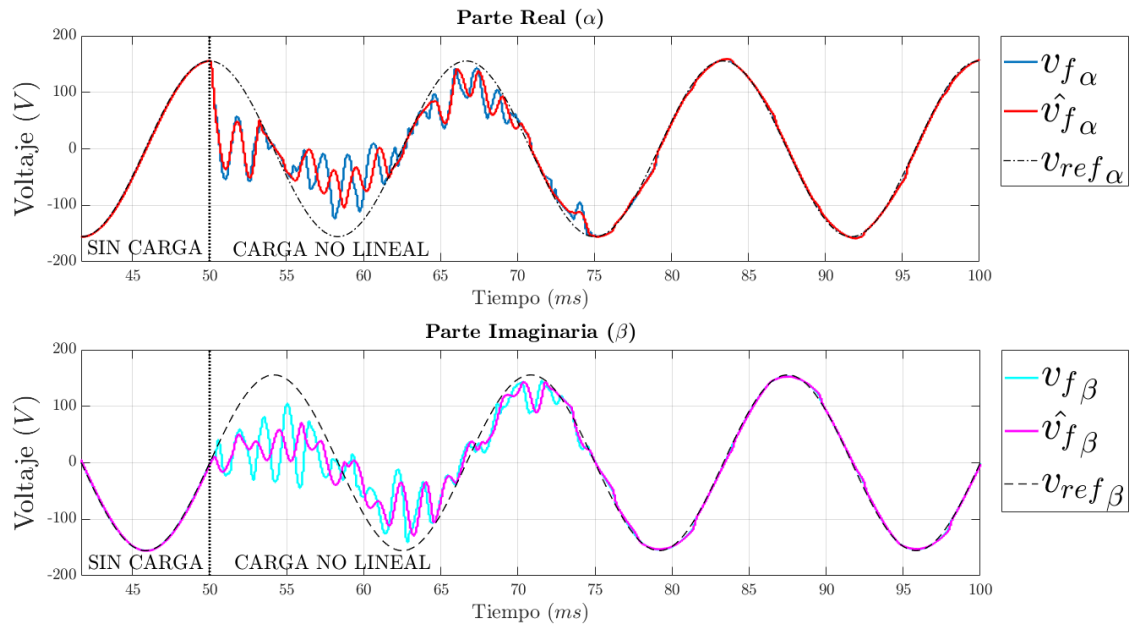


puede notar en la figura 35 que los voltajes resultantes de ambos controladores son bastante parecidos cuando estos llegan a un estado estacionario, mas difieren únicamente cuando existe una perturbación. Empero, pese a existir dichas diferencias, ambos controladores rechazan las perturbaciones en un tiempo idéntico, como se puede observar en la evolución del error de ambos controladores en la figura 36. Esto lleva a pensar que la red neuronal ha logrado extraer la información necesaria de los patrones de entrenamiento a fin de lograr controlar el inversor 3φ -3L-VSI, gracias a que su acción de control es considerablemente más suave y carente variaciones demasiado bruscas.

El efecto de dichas variaciones bruscas en la acción de control se puede apreciar de mejor manera en la magnitud de la corriente en bobina representadas en la figura 37. Se puede observar como la corriente generada por el controlador OM^2PC posee variaciones mucho más bruscas, tanto así que en ciertas ocasiones la misma logra superar, por breves instantes, el límite máximo permitido para la misma corriente. A diferencia, el algoritmo $ANN-M^2PC$ genera una corriente más suave y únicamente supera el límite establecido una única vez de forma muy breve. Esto último también confirma que la red neuronal ha aprendido a

Figura 35

Comparación de los voltajes de salida y la referencia con los controladores OM^2PC ($v_{f\alpha\beta}$) y $ANN-M^2PC$ ($\hat{v}_{f\alpha\beta}$) ante la conexión de una carga no lineal.

**Figura 36**

Comparación del error porcentual con respecto a la referencia de los voltajes del filtro con los controladores OM^2PC y $ANN-M^2PC$ ante la conexión de una carga no lineal.

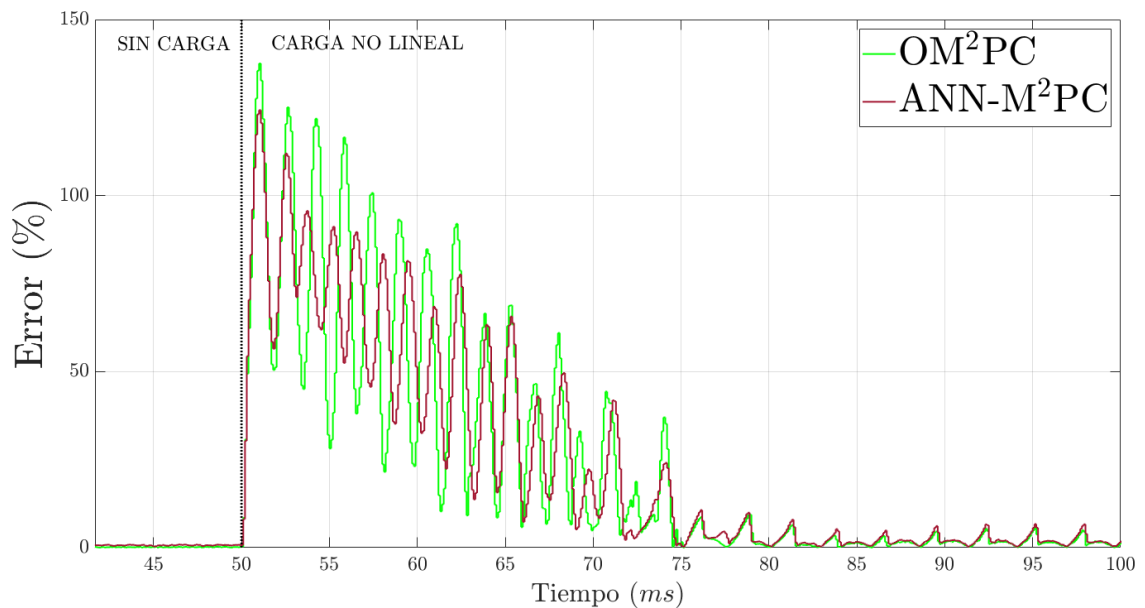



Figura 37

Comparación de la magnitud de las corrientes del filtro con los controladores OM^2PC ($i_{f\alpha\beta}$) y $ANN-M^2PC$ ($\hat{i}_{f\alpha\beta}$) ante la conexión de una carga no lineal.



cumplir las restricciones impuestas al algoritmo original al mismo tiempo que controla y rechaza perturbaciones en el sistema.

Análisis de Sensitividad

La sección anterior evaluó cómo el controlador neuronal se comporta en un escenario ideal, en otras palabras, los valores de la inductancia L_f y la capacitancia C_f que conforman el filtro LC son conocidos. Ahora bien, los valores nominales de dichos parámetros pueden variar dependiendo de múltiples factores como son: el desgaste, la temperatura, etcétera, lo cual significa que se debe probar cómo el controlador propuesto es capaz de lidiar con la incertidumbre de estos dos parámetros. Para ello, se realizaron simulaciones del sistema, en las cuales se modifica el valor de tanto la capacitancia como inductancia por separado, con el fin de simplificar el análisis. Al respecto conviene decir que dichos parámetros se han modificado en un rango de $\pm 30\%$ del valor nominal que éstos poseen.

En la figura 38 se puede apreciar cómo la distorsión armónica varía en función de las variaciones previamente mencionadas. Así pues, tanto el controlador propuesto como el origi-

nal OM²PC se ven severamente afectados cuando se sobre estima el valor de la inductancia. Es necesario recalcar que el controlador OM²PC se encuentra mucho más afectado que el propuesto ANN-M²PC. Con relación a la capacitancia, se puede notar que el THD apenas es alterado por dicha incertidumbre, con lo cual el valor de la inductancia es mucho más crítico que el de la capacitancia, y que es relevante tener un valor lo más próximo al real.

Una posible explicación del motivo por el cual la incertidumbre en la inductancia es mucho más crítica que la de la capacitancia, radica en que las dinámicas presentes en la corriente de la inductancia $i_{f\alpha\beta}$ son mucho más veloces que las presentes en el voltaje de la capacitancia $v_{f\alpha\beta}$. Además, la corriente $i_{f\alpha\beta}$ se ve afectada directamente por la acción de control $\bar{v}_{i\alpha\beta, k+1}$. Entonces, si el controlador subestima el valor de la inductancia, se producirán rizados de corriente de mayor amplitud, mismos que serán propagados hacia el voltaje de salida aumentando el THD de forma abrupta. En el otro escenario, cuando el controlador sobrestima el valor de la inductancia, las dinámicas son más lentas de lo esperado, lo que se traduce en un mayor esfuerzo del controlador para alcanzar la referencia, y por tanto el THD se incrementa pero de forma gradual. En contraste, dado a que el voltaje $v_{f\alpha\beta}$ posee una dinámica lenta, el controlador tiene tiempo más que suficiente para compensar desviaciones en el voltaje de salida, así pues el THD casi no se ve afectado ante variaciones en la capacitancia.


Tiempos de Ejecución

El último punto a analizar es el tiempo de ejecución del controlador propuesto, para el cual se han considerado dos escenarios. El primero, es el tiempo de ejecución dentro de un ordenador, y el segundo, en un microcontrolador de la serie F28335 de Texas Instruments. En las figuras 39 y 40 se puede examinar como el coste computacional afecta al tiempo de ejecución de cada uno de los algoritmos de control bajo estudio. Como referencia se ha decidido incluir el algoritmo FCS-MPC ya que, en teoría, debería ser el más rápido de todos gracias a su relativamente bajo coste computacional.

La figura 39 minifiesta que el algoritmo propuesto ANN-M²PC es capaz de ser ejecutado cerca de trece veces en el mismo tiempo que el algoritmo OM²PC se ejecuta una única vez en un ordenador, y cerca de ocho veces si se considera al OM²PC con sobre modulación

Figura 38


Análisis de sensibilidad de la distorsión armónica total (THD) del voltaje de salida respecto a la variación de elementos del filtro LC.



Nota. (a) THD en función de la variación de la inductancia (ΔL_f) respecto del valor nominal de $L_f = 2,4mH$. (b) THD en función de la variación de la capacitancia (ΔC_f) respecto del valor nominal de $C_f = 24\mu F$.

Figura 39

Tiempos de ejecución en un ordenador con procesador Intel Core i7-6700 a 3.40Ghz con 32 GB en RAM.




no óptima. Además, en un controlador embebido, en el cual los recursos computacionales son mucho más limitados, el ANN-M²PC puede ser ejecutado cerca de 32 veces en el tiempo que se ejecuta una vez el OM²PC (figura 40). Así pues, se confirma que la función de activación *satlins* es la más rápida y, por tanto la más adecuada para ser usada dentro del controlador neuronal. Hay que mencionar que el controlador propuesto es incluso cinco veces más veloz que el FCS-MPC al tiempo que obtiene resultados similares al OM²PC. Además, el controlador OM²PC no podría ser ejecutado en tiempo real (en el microcontrolador seleccionado) debido a que su tiempo de ejecución es 16 veces superior al tiempo de muestreo requerido, únicamente el ANN-M²PC es capaz de cumplir el estricto margen de tiempo que se tiene.

En suma, se puede decir que la propuesta de un controlador neuronal no solo logra reducir el coste computacional de implementar un algoritmo predictivo modulado, sino que también mantiene el desempeño del algoritmo a imitar.

Figura 40

Tiempos de ejecución en un DSP F28335.



Conclusiones y Recomendaciones

Conclusiones

El presente trabajo de investigación propone una estrategia para reducir el coste computacional de controladores predictivos y aplicarlo a inversores de tres niveles. La estrategia basa su funcionamiento en aproximar el comportamiento de la acción de control generada por un controlador predictivo tradicional, en este caso el OM²PC, mediante el uso de redes neuronales. Se ha demostrado que el controlador neuronal propuesto (ANN-M²PC) en efecto reduce notablemente el coste computacional de un controlador predictivo tradicional al lograr una velocidad de cálculo 32 veces superior a la del algoritmo OM²PC en un microcontrolador, al tiempo que mantiene una dinámica bastante rápida (con 5 mili segundos de tiempo de establecimiento similar al del OM²PC) y baja distorsión armónica, con un THD de 2.28 % que es ligeramente superior al 1.91 % obtenido por el OM²PC (con una carga no lineal de $R_n = 70\Omega$ y $C_n = 1100\mu F$). Es posible afirmar que el controlador neuronal ANN-M²PC posee los beneficios del OM²PC al tiempo que reduce drásticamente el coste computacional del mismo, y todas estas ventajas hacen que el controlador neuronal propuesto sea muy deseable para implementar en sistemas embebidos, los cuales usualmente poseen bajos recursos computacionales y que presentan restricciones muy estrictas en tiempos disponibles para realizar cálculos.

A fin de replicar lo mejor posible la estrategia de control del OM²PC a través de redes neuronales, se han realizado múltiples simulaciones de dicho controlador en conjunto con el inversor 3 φ -3L-VSI en diferentes configuraciones. De esta forma, se han podido generar los patrones de entrenamiento necesarios para el aprendizaje de la red neuronal. Adicionalmente, se ha replicado el comportamiento de la estrategia OM²PC con restricciones, gracias a que dicho algoritmo garantiza que las variables del sistema se encuentren dentro de un rango seguro de operación para los elementos del inversor, y que al mismo tiempo es un rango conocido para la red neuronal. Adicionalmente, se ha seleccionado la cantidad óptima de neuronas de la capa oculta ($N = 10$) y la función de activación más adecuada para la misma capa (*satlins*). Con todo

esto, se ha logrado obtener un coeficiente de regresión (R) cercano al 99 %, lo que implica que la red neuronal es capaz de replicar muy bien el comportamiento del controlador OM²PC en un tiempo mucho menor.

Durante el proceso de generación de la red neuronal se ha visto la necesidad de una etapa de pre-modulación, a causa de que la red neuronal retorna la acción de control futura, misma que es representada por el voltaje complejo promedio del inversor. No cabe duda que dicho voltaje no puede ser interpretado directamente por la etapa de modulación, debido a que la misma requiere de un conjunto de voltajes y ciclos de trabajo a aplicar. En consecuencia, la etapa de pre-modulación es la responsable de transformar dicha acción de control en los vectores que el bloque de modulación requiere.

Por último pero no menos importante, se ha decidido aproximar la estrategia de control, nombrada aquí como OM²PC, gracias a que la misma hace uso del todo el espacio de conmutaciones disponible. A diferencia de la estrategia M²PC que presenta vacíos entre regiones, y dichos vacíos ocupan más de la mitad del espacio de conmutaciones. Lo dicho hasta aquí supone que, la acción de control (a ser aproximada por la red neuronal) debe ser lo más continua posible dentro del espacio de conmutaciones, y además, la misma debe poseer una estrategia de sobre modulación con el propósito de mapear puntos fuera del espacio de conmutaciones en los bordes del mismo. Todas estas consideraciones garantizan un mejor aprendizaje de la red neuronal y las discontinuidades presentes en la acción de control se reducen, por lo tanto el proceso de regresión de la red neuronal es mejor.

Recomendaciones

- Para poder implementar el algoritmo en un micro controlador, es recomendable que este sea capaz de realizar las secuencias de conmutaciones. En general estas pueden ser realizadas mediante un bloque de combinación lógica o CLB.
- El proceso de entrenamiento del controlador neuronal ha tomado en cuenta una modulación SVM, no obstante, es posible adaptarlo para que pueda ser utilizado con una modulación más sencilla de generar por hardware como lo es la modulación PWM.

- Actualmente se ha considerado únicamente al inversor como una fuente de voltaje con un filtro LC . Por lo que, es recomendable utilizar otro tipo de estructura, en otras palabras, utilizarlo como una fuente de corriente, o también utilizar otro tipo de topología en el filtro.
- El controlador neuronal ha sido puesto a prueba con inversores de tres niveles, por lo que se aconseja utilizarlo con inversores con número de niveles superior a tres, o incluso con inversores de dos niveles.
- El controlador neuronal ANN-M²PC propuesto ha sido validado únicamente en forma de simulaciones dentro del entorno de MATLAB®-Simulink. Por lo que se es necesario realizar una validación experimental del mismo controlador en un ambiente real.

Trabajos Futuros

Basado en la experiencia obtenida en el presente trabajo de investigación, se plantean los siguiente tópicos a ser tratados en un futuro:

- La estrategia propuesta en el caso de microcontroladores (μC) presenta una reducción notable en el tiempo de computo de la ley de control. Empero, en sistemas basados en FPGAs, se observarían mejoras no solamente en tiempos de computo sino también en la cantidad de bloques lógicos requeridos para implementar el controlador.
- Para la generación de los patrones de entrenamiento en el presente trabajo, se ha considerado únicamente los valores nominales de L_f y C_f . Esto último es responsable de análisis de sensibilidad antes expuesto. En cambio, al generar patrones de entrenamiento con diferentes valores en los elementos del filtro se podría mejorar la incertidumbre del controlador neuronal.
- El presente trabajo asume que el DC-link está conformado por dos fuentes de voltaje DC ideales, mismas que son raramente utilizadas en ambientes reales. Usualmente se utiliza un DC-link constituido por dos capacitores en serie, mismos que se pueden descargar y cargar dependiendo de los patrones de conmutación utilizados. Por tanto, es necesario

añadir esta consideración al controlador ya propuesto. Dicha extensión puede añadirse sea: a la propia red neuronal, a la etapa de pre-modulación, o incluso como un bloque diferente a los ya mencionados.

- De momento se ha considerado que el algoritmo OM^2PC es el más adecuado para ser imitado por la red neuronal, pero se pueden generar nuevas alternativas. Entre las cuales se propone ya no utilizar el proceso de optimización basado un conjunto finito, como lo es el FCS-MPC, sino más bien tratar al proceso de optimización de forma continua como el controlador predictivo por conjunto continuo (CCS-MPC).
- La red neuronal enunciada en el presente trabajo sugiere que existe una relación directa entre las variables que describen el sistema y la acción de control para el mismo. Si bien se desconoce dicha relación, se podría descubrir al aplicar algún método de inteligencia artificial que permita la interpretación del mismo.

Referencias

- Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A. E., y Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11), e00938. Descargado de <https://doi.org/10.1016/j.heliyon.2018.e00938> doi: 10.1016/j.heliyon.2018.e00938
- Attique, Q. M. (2017). A Survey on Space-Vector Pulse Width Modulation for Multilevel Inverters. *CPSS Transactions on Power Electronics and Applications*, 2(3), 226–236. doi: 10.24295/cpsstpea.2017.00021
- Bandy, K., y Stumpf, P. (2021). Model Predictive Torque Control for Multilevel Inverter fed Induction Machines Using Sorting Networks. *IEEE Access*, 9, 13800–13813. doi: 10.1109/ACCESS.2021.3052129
- Burns, R. S. (2001). *Advanced Control Engineering*. doi: 10.1016/b978-0-7506-5100-4.x5000-1
- Doi, M. V., Nguyen, B. X., y Nguyen, N. V. (2019). A Finite Set Model Predictive Current Control for Three-Level NPC Inverter with Reducing Switching State Combination. *2019 IEEE 4th International Future Energy Electronics Conference, IFEEEC 2019*, 1–9. doi: 10.1109/IFEEEC47410.2019.9015021
- Donoso, F., Mora, A., Cardenas, R., Angulo, A., Saez, D., y Rivera, M. (2018). Finite-Set Model-Predictive Control Strategies for a 3L-NPC Inverter Operating with Fixed Switching Frequency. *IEEE Transactions on Industrial Electronics*, 65(5), 3954–3965. doi: 10.1109/TIE.2017.2760840
- Dragicevic, T. (2018). Model Predictive Control of Power Converters for Robust and Fast Operation of AC Microgrids. *IEEE Transactions on Power Electronics*, 33(7), 6304–6317. doi: 10.1109/TPEL.2017.2744986
- EI-Hosainy, A., Hamed, H. A., Azazi, H. Z., y El-Kholy, E. E. (2018). A review of multilevel inverter topologies, control techniques, and applications. *2017 19th International Middle-East Power Systems Conference, MEPCON 2017 - Proceedings, 2018-February(December)*,

1265–1275. doi: 10.1109/MEPCON.2017.8301344

- Garcia, C. F., Silva, C. A., Rodriguez, J. R., Zanchetta, P., y Odhano, S. A. (2019). Modulated Model-Predictive Control with Optimized Overmodulation. *IEEE Journal of Emerging and Selected Topics in Power Electronics*, 7(1), 404–413. doi: 10.1109/JESTPE.2018.2828198
- Karamanakos, P., Liegmann, E., Geyer, T., y Kennel, R. (2020). Model Predictive Control of Power Electronic Systems: Methods, Results, and Challenges. *IEEE Open Journal of Industry Applications*, 1, 95–114. Descargado de <https://ieeexplore.ieee.org/document/9180048/> doi: 10.1109/OJIA.2020.3020184
- Leon, J. I., Kouro, S., Franquelo, L. G., Rodriguez, J., y Wu, B. (2016). The Essential Role and the Continuous Evolution of Modulation Techniques for Voltage-Source Inverters in the Past, Present, and Future Power Electronics. *IEEE Transactions on Industrial Electronics*, 63(5), 2688–2701. doi: 10.1109/TIE.2016.2519321
- Loncarski, J., Monopoli, V. G., Leuzzi, R., Ristic, L., y Cupertino, F. (2019). Analytical and simulation fair comparison of three level Si IGBT based NPC topologies and two level SiC MOSFET based topology for high speed drives. *Energies*, 12(23), 1–16. doi: 10.3390/en12234571
- Mohamed, I. S., Rovetta, S., Do, T. D., Dragicevic, T., y Diab, A. A. (2019). A neural-network-based model predictive control of three-phase inverter with an output LC Filter. *IEEE Access*, 7, 124737–124749. doi: 10.1109/ACCESS.2019.2938220
- Novak, M., y Dragicevic, T. (2021). Supervised Imitation Learning of Finite-Set Model Predictive Control Systems for Power Electronics. *IEEE Transactions on Industrial Electronics*, 68(2), 1717–1723. doi: 10.1109/TIE.2020.2969116
- Rao, S. N., Kumar, D. V. A., y Babu, C. S. (2018). Implementation of Cascaded based Reversing Voltage Multilevel Inverter using Multi Carrier Modulation Strategies. *International Journal of Power Electronics and Drive Systems (IJPEDS)*, 9(1), 220. doi: 10.11591/ijpeds.v9.i1.pp220-230
- Rivera, M., Morales, F., Baier, C., Muñoz, J., Tarisciotti, L., Zanchetta, P., y Wheeler, P. (2015). A modulated model predictive control scheme for a two-level voltage source

- inverter. *Proceedings of the IEEE International Conference on Industrial Technology, 2015-June*(June), 2224–2229. doi: 10.1109/ICIT.2015.7125425
- Rivera, M., Perez, M., Baier, C., Munoz, J., Yaramasu, V., Wu, B., ... Wheeler, P. (2015). Predictive Current Control with fixed switching frequency for an NPC converter. *IEEE International Symposium on Industrial Electronics, 2015-Septe*, 1034–1039. doi: 10.1109/ISIE.2015.7281614
- Sajitha, M., Sandeep, J., y Ramchand, R. (2019). Comparative Analysis of Different Modulation Techniques for Three Level Three Phase T-type NPC Inverter. *IEEE Region 10 Annual International Conference, Proceedings/TENCON, 2019-October*, 1529–1534. doi: 10.1109/TENCON.2019.8929574
- Santis, P., Sáez, D., Cárdenas, R., y Núñez, A. (2019). Pareto-based modulated model predictive control strategy for power converter applications. *Electric Power Systems Research*, 171(September 2017), 158–174. Descargado de <https://doi.org/10.1016/j.epsr.2019.02.016> doi: 10.1016/j.epsr.2019.02.016
- Vijeh, M., Rezanejad, M., Samadaei, E., y Bertilsson, K. (2019). A General Review of Multilevel Inverters Based on Main Submodules: Structural Point of View. *IEEE Transactions on Power Electronics*, 34(10), 9479–9502. doi: 10.1109/TPEL.2018.2890649
- Vilanova, A. R., Alfaro, V. M., y Vilanova, R. (2016). Model-Reference Robust Tuning of PID Controllers. , 7–20. Descargado de <http://link.springer.com/10.1007/978-3-319-28213-8> doi: 10.1007/978-3-319-28213-8
- Wang, Q., Rivera, M., Riveros, J. A., y Wheeler, P. (2019). Modulated Model Predictive Current Control for PMSM Operating with Three-level NPC Inverter. *2019 IEEE 15th Brazilian Power Electronics Conference and 5th IEEE Southern Power Electronics Conference, COBEP/SPEC 2019*. doi: 10.1109/COBEP/SPEC44138.2019.9065401
- Wang, Q., Yu, H., Li, C., Lang, X., Yeoh, S. S., Yang, T., ... Wheeler, P. (2020). A Low-Complexity Optimal Switching Time-Modulated Model-Predictive Control for PMSM with Three-Level NPC Converter. *IEEE Transactions on Transportation Electrification*, 6(3), 1188–1198. doi: 10.1109/TTE.2020.3012352
- Yang, Y., Wen, H., Fan, M., He, L., Xie, M., Chen, R., ... Rodriguez, J. (2020). Multiple-Voltage-

Vector Model Predictive Control with Reduced Complexity for Multilevel Inverters. *IEEE Transactions on Transportation Electrification*, 6(1), 105–117. doi: 10.1109/TTE.2020.2973045

Zheng, C., Dragičević, T., Majmunović, B., y Blaabjerg, F. (2020). Constrained Modulated Model-Predictive Control of an LC-Filtered Voltage-Source Converter. *IEEE Transactions on Power Electronics*, 35(2), 1967–1977. doi: 10.1109/TPEL.2019.2917634

Anexos