

Control Predictivo Modulado basado en Redes Neuronales para un Inversor de Voltaje Trifásico de Tres Niveles

Josue Andino¹

¹Maestría de Investigación en Electrónica mención Automática
Grupo de investigación en Propagación, Control Electrónico y Networking (PROCONET)
Departamento de Eléctrica, Electrónica y Telecomunicaciones
Universidad de las Fuerzas Armadas ESPE

Trabajo de Titulación, Diciembre 2021



KU LEUVEN



vliros
SHARING MINDS, CHANGING LIVES

MIRA-ESTE: Microgrids for isolated rural areas: environmental, social, technological and economic aspects



Belgium
partner in development

MIRA-ESTE: Specific, innovative microgrids solutions (accounting for environmental, social, technological and economic aspects) for isolated rural areas of Ecuador

Project number: **EC2020SIN322A101**

- 1 Introducción
- 2 Marco Teórico
- 3 Propuesta de Investigación
 - Controlador Neuronal
 - Estrategia de Control
 - Etapa de Pre-Modulación
- 4 Resultados
 - Entrenamiento
 - Simulaciones
 - Análisis de Sensitividad
 - Tiempos de Ejecución
- 5 Conclusiones y Trabajos Futuros

Tabla de Contenidos

- 1 Introducción
- 2 Marco Teórico
- 3 Propuesta de Investigación
 - Controlador Neuronal
 - Estrategia de Control
 - Etapa de Pre-Modulación
- 4 Resultados
 - Entrenamiento
 - Simulaciones
 - Análisis de Sensitividad
 - Tiempos de Ejecución
- 5 Conclusiones y Trabajos Futuros

Introducción



Inversores Multinivel (MLIs)

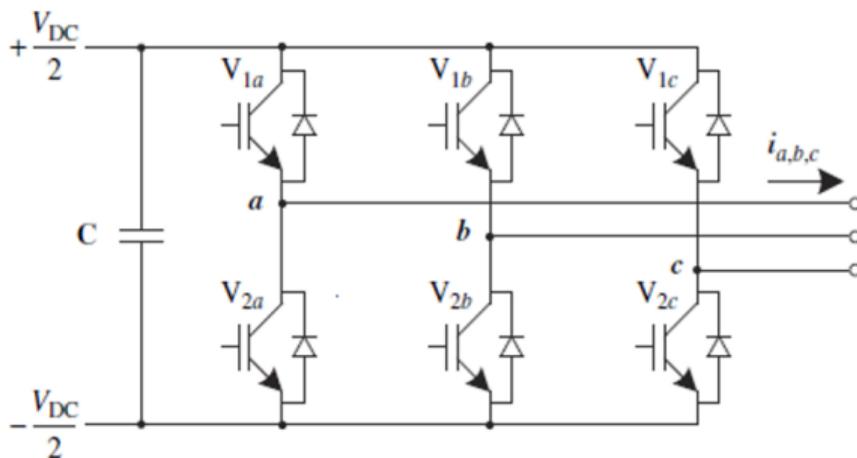
Ventajas

- Pueden alcanzar mayores voltajes.
- Reducen interferencia electromagnética (EMI).
- Menor distorsión armónica total (THD).
- Aminoran pérdidas de conmutación.
- Incrementan eficiencia.

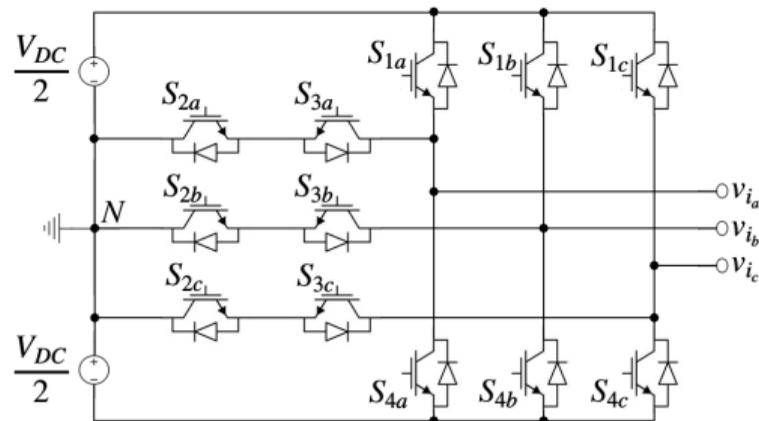
Desventajas

- Poseen una mayor cantidad de elementos de conmutación.
- Distribución desigual de temperatura.
- Requieren de múltiples fuentes DC.
- Mayor complejidad de los algoritmos de control.

¿Por qué los MLIs son más complejos de controlar?



(a) 3φ-2L-VSI



(b) 3φ-3L-VSI tipo T-NPC

Figura: Estructura de los inversores trifásicos de dos y tres niveles.

¿Qué tipos de control hay?

Estrategias de control para MLIs:

- Por modos deslizantes (SMC).
- Por lógica difusa (FLC).
- Proporcional integral derivativo (PID).
- Predictivo por modelo (MPC).

Controladores Predictivos:

- De conjunto continuo (CCS-MPC).
- De conjunto finito (FCS-MPC).
- **Modulado (M²PC).**

Control Predictivo Modulado (M^2PC)

Aplica un conjunto de tres voltajes \mathbf{v}_{opt} en un tiempo de muestreo (T_s) con sus respectivos ciclos de trabajo \mathbf{d} . De tal forma que, el voltaje del inversor \bar{v}_i , en promedio, puede tomar cualquier valor dentro del espacio de conmutaciones.

Ventajas:

- Frecuencia fija de conmutación, rápida respuesta dinámica, y baja distorsión armónica.

Desventajas:

- Muy alto coste computacional.

Nota:

Es tipo de control suele más comúnmente utilizado con la modulación por vector espacial (SVM).

Estado del Arte

Para reducir el coste computacional de controladores predictivos en inversores trifásicos, se han encontrado las siguientes propuestas:

- Algoritmos de ordenamiento [1].
- Reducción de estados de conmutación [2], [3].
- Soluciones analíticas [4], [5].
- Utilización FPGAs.
- Redes neuronales [6], [7].

Objetivos

Objetivo General:

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

Objetivos Específicos

- Seleccionar una estructura del inversor a controlar.
- Definir un algoritmo de control a emular.
- Generar los patrones de entrenamiento.
- Entrenar una red neuronal que imite la relación entrada-salida del controlador seleccionado.
- Comparar los resultados del controlador original y el emulado.

Tabla de Contenidos

- 1 Introducción
- 2 Marco Teórico**
- 3 Propuesta de Investigación
 - Controlador Neuronal
 - Estrategia de Control
 - Etapa de Pre-Modulación
- 4 Resultados
 - Entrenamiento
 - Simulaciones
 - Análisis de Sensitividad
 - Tiempos de Ejecución
- 5 Conclusiones y Trabajos Futuros

Transformada de Clarke ($\alpha\beta$)

Si el sistema trifásico es balanceado, se puede transformar de coordenadas naturales abc al plano complejo $\alpha\beta$ mediante la transformada de Clarke.

Es decir, si tenemos un voltaje trifásico $\mathbf{v}_{abc} = [v_a, v_b, v_c]^T$ o una corriente trifásica $\mathbf{i}_{abc} = [i_a, i_b, i_c]^T$, se las puede pasar al plano $\alpha\beta$ al multiplicarlas por el vector de transformación \mathbf{T} :

$$\begin{aligned} v_{\alpha\beta} &= v_\alpha + jv_\beta = \mathbf{T} \cdot \mathbf{v}_{abc} \\ i_{\alpha\beta} &= i_\alpha + ji_\beta = \mathbf{T} \cdot \mathbf{i}_{abc} \end{aligned} \quad (1)$$

En donde:

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

Modelo Matemático del Filtro LC

$$\frac{d}{dt} \begin{bmatrix} i_{f\alpha\beta} \\ v_{f\alpha\beta} \end{bmatrix} = \mathbf{A} \begin{bmatrix} i_{f\alpha\beta} \\ v_{f\alpha\beta} \end{bmatrix} + \mathbf{B} \begin{bmatrix} v_{i\alpha\beta} \\ i_{o\alpha\beta} \end{bmatrix}$$

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

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

(3)

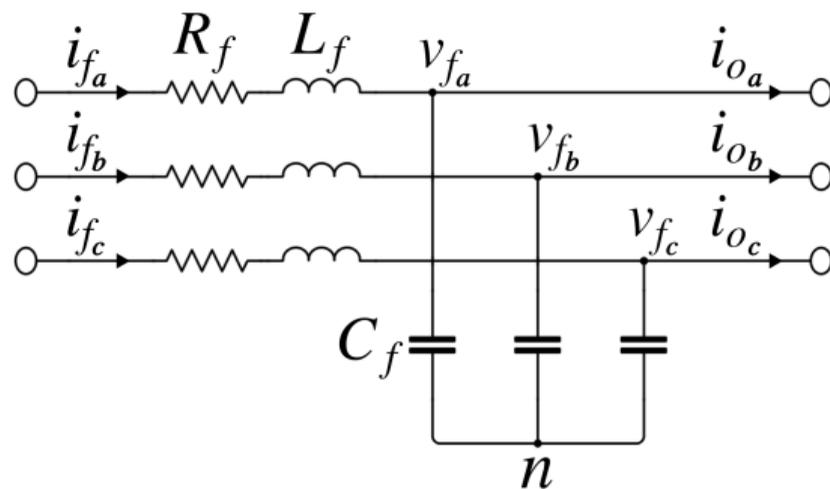


Figura: Filtro LC trifásico.

En donde:

- $i_{f\alpha\beta}$: Corriente del filtro.
- $v_{f\alpha\beta}$: Voltaje del filtro.
- $i_{o\alpha\beta}$: Corriente de la carga.

Conmutaciones del Inversor

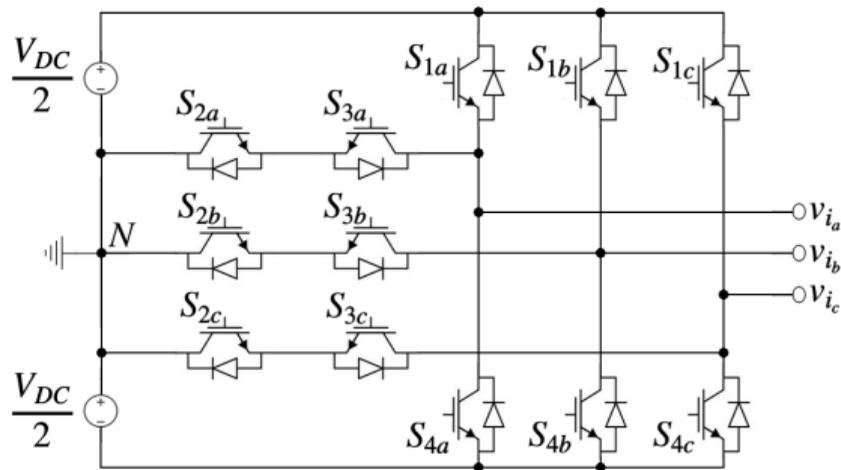


Figura: 3 φ -3L-VSI tipo T-NPC.

Conmutaciones válidas:

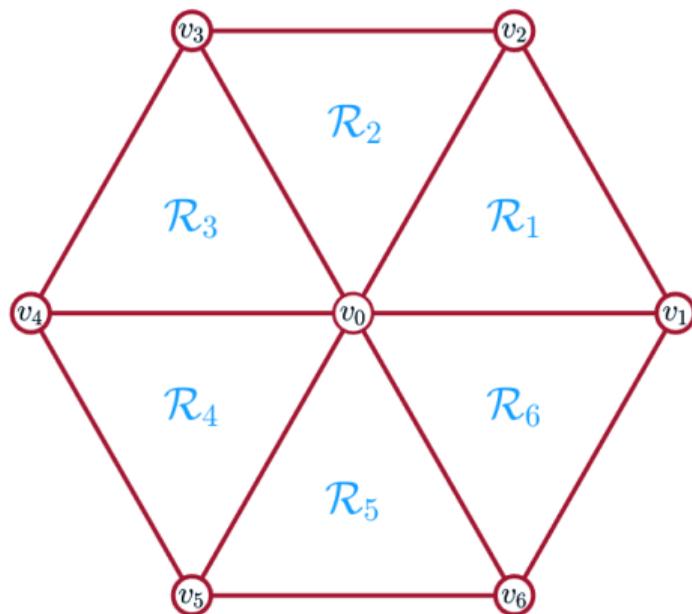
$$s_x = \begin{cases} 1 & \text{sí } S_{1x} \text{ y } S_{2x} : \text{ ON} \\ 0 & \text{sí } S_{2x} \text{ y } S_{3x} : \text{ ON} \\ -1 & \text{sí } S_{3x} \text{ y } S_{4x} : \text{ ON} \end{cases} \quad (4)$$

en donde: $x \in \{a, b, c\}$

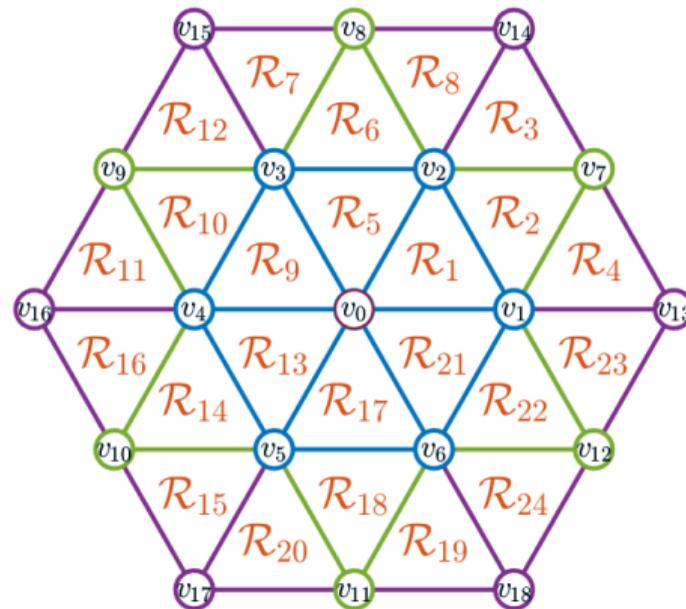
Voltaje Instantáneo del Inversor:

$$v_{i\alpha\beta} = \frac{V_{DC}}{2} \cdot \mathbf{T} \cdot \left(\mathbf{I} - \frac{1}{3} \mathbf{1} \right) \cdot \begin{bmatrix} s_a \\ s_b \\ s_c \end{bmatrix} \quad (5)$$

Espacio de Conmutaciones



(a) 2L-VSI: 7 voltajes en 6 regiones.



(b) 3L-VSI: 19 voltajes en 24 regiones.

Figura: Espacio de conmutaciones para inversores trifásicos.

Acción de Control

La acción de control en un inversor trifásico suele estar representada como:

- Conmutaciones $\mathbf{s} = [s_a, s_b, s_c]^T$ y tiempos de aplicación $T_s = \tau_1 + \tau_2 + \tau_3$.
- Voltajes óptimos $\mathbf{v}_{opt} = [v_{opt1}, v_{opt2}, v_{opt3}]$ y ciclos de trabajo $\mathbf{d} = [d_1, d_2, d_3]^T$.
- Región óptima \mathcal{R}_{opt} y ciclos de trabajo \mathbf{d} .
- *Voltaje promedio del inversor*: $\bar{v}_{i\alpha\beta, k+1}$.

En donde:

$$\bar{v}_{i\alpha\beta, k+1} = \mathbf{v}_{opt} \cdot \mathbf{d} = d_1 v_{opt1} + d_2 v_{opt2} + d_3 v_{opt3} \quad (6)$$

Redes Neuronales Artificiales (ANN)

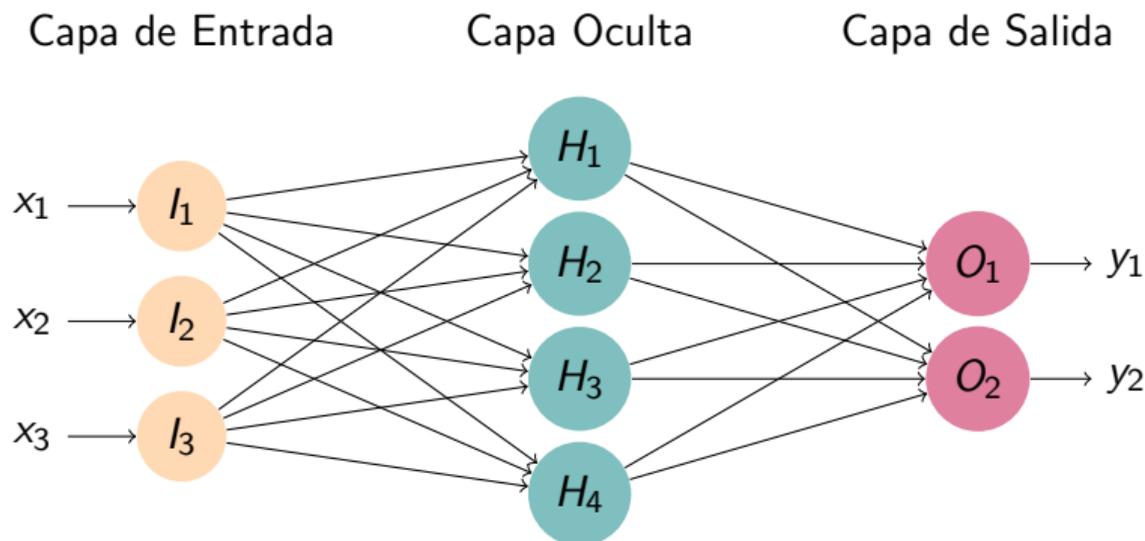


Figura: Estructura de una red neuronal con tres entradas, dos salidas, y cuatro neuronas en la capa oculta.

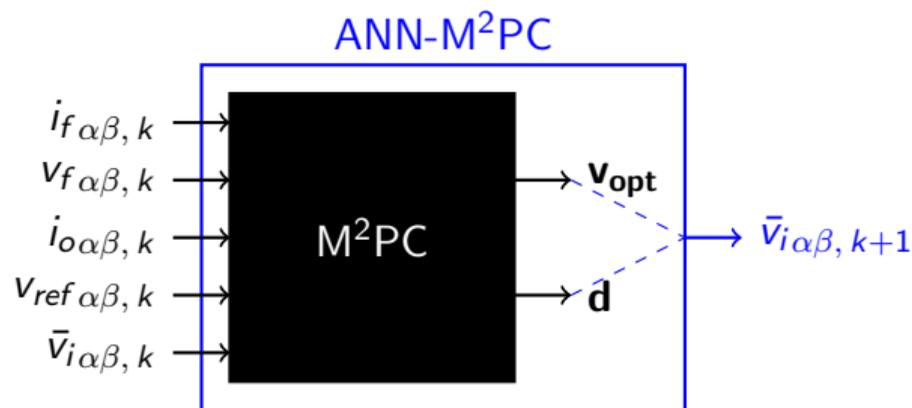
Tabla de Contenidos

- 1 Introducción
- 2 Marco Teórico
- 3 Propuesta de Investigación
 - Controlador Neuronal
 - Estrategia de Control
 - Etapa de Pre-Modulación
- 4 Resultados
 - Entrenamiento
 - Simulaciones
 - Análisis de Sensitividad
 - Tiempos de Ejecución
- 5 Conclusiones y Trabajos Futuros

Tabla de Contenidos

- 1 Introducción
- 2 Marco Teórico
- 3 Propuesta de Investigación**
 - **Controlador Neuronal**
 - Estrategia de Control
 - Etapa de Pre-Modulación
- 4 Resultados
 - Entrenamiento
 - Simulaciones
 - Análisis de Sensitividad
 - Tiempos de Ejecución
- 5 Conclusiones y Trabajos Futuros

Controlador Neuronal



El algoritmo de control se lo puede ver como:

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

Nota:

$$v_{ref\alpha\beta, k} = V_n \exp(j2\pi f_n T_s k)$$

Regresión Múltiple utilizando una Red Neuronal

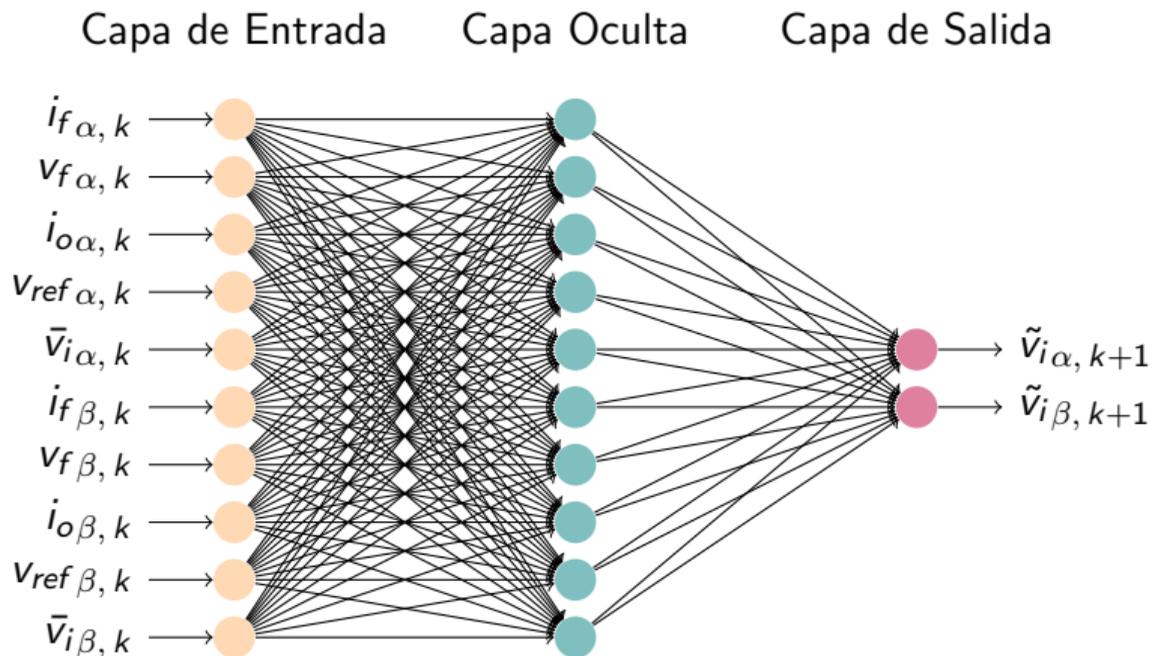


Figura: Estructura del controlador neuronal ANN-M²PC.

Patrones de Entrenamiento

El lazo de control es simulado en en MATLAB-Simulink ante diferentes valores en la carga (lineales, no lineales, sin carga). Se utiliza el 70% para entrenamiento, el 15% para validación y el restante 15% para test.

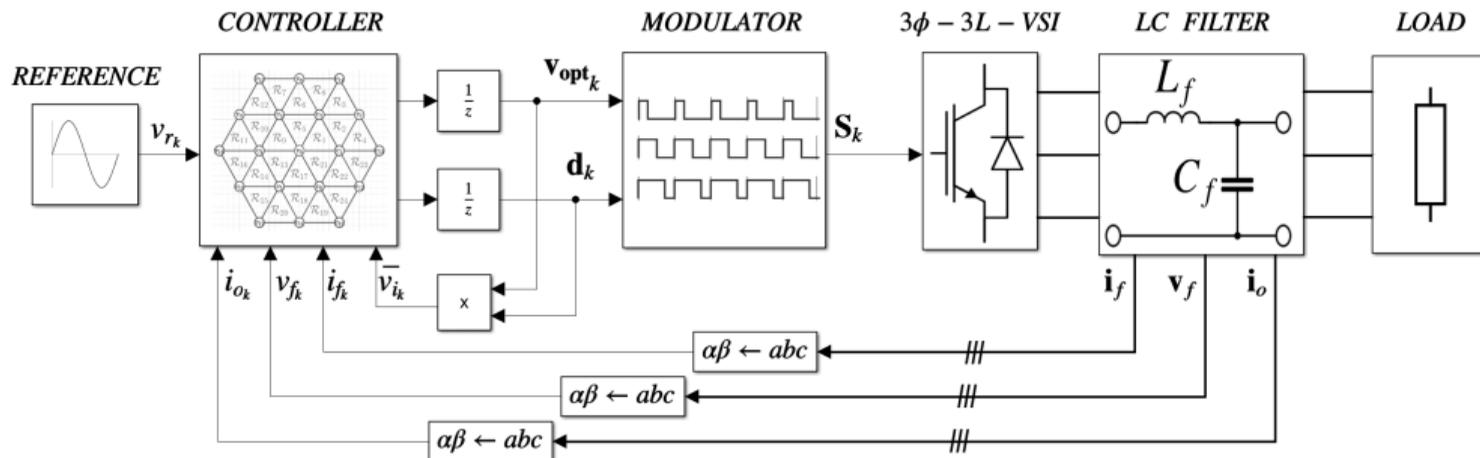


Figura: Lazo de control.

Tabla de Contenidos

- 1 Introducción
- 2 Marco Teórico
- 3 **Propuesta de Investigación**
 - Controlador Neuronal
 - **Estrategia de Control**
 - Etapa de Pre-Modulación
- 4 Resultados
 - Entrenamiento
 - Simulaciones
 - Análisis de Sensitividad
 - Tiempos de Ejecución
- 5 Conclusiones y Trabajos Futuros

Características del Controlador a Emular

La estrategia de control a emular debe poseer las siguientes características:

- Estar basado en M^2PC .
- Generar una baja distorsión armónica (THD) en el voltaje resultante.
- Producir un bajo error en estado estacionario (ESS).
- Utilizar todo el espacio de conmutaciones.
- Limitar la corriente del inductor.

Selección de la estrategia de control

Existen dos principales alternativas para calcular los ciclos de trabajo en un M²PC [8]:

- 1 Asumir que los ciclos de trabajo tienen son inversamente proporcionales a la función de costo [8]–[12]:

$$d_i \propto \frac{1}{g_i} \quad (7)$$

- 2 Asumir una que existe una relación lineal entre los ciclos de trabajo, la referencia, y el voltaje del filtro [13], [14] (OM²PC):

$$\mathbf{V}_f(\mathbf{v}_{\text{opt}}) \cdot \mathbf{d} = \mathbf{v}_{\text{ref}} \quad (8)$$

M²PC vs OM²PC

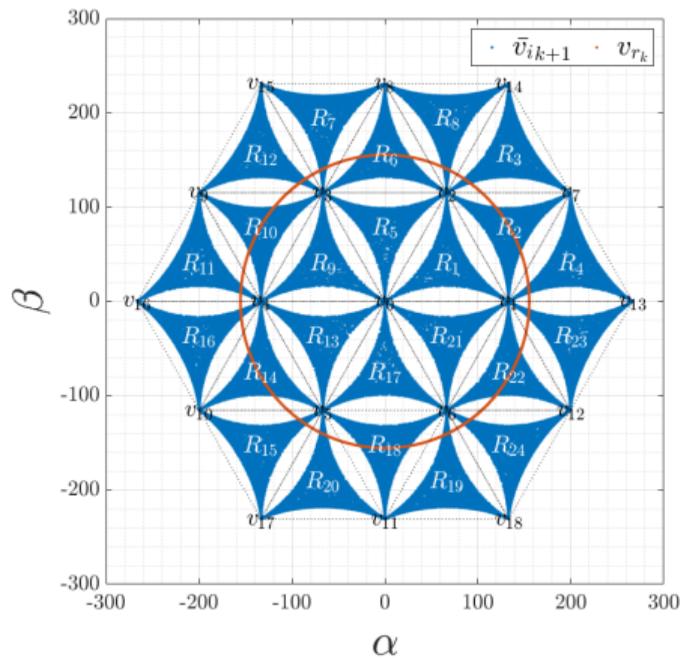


Figura: M²PC

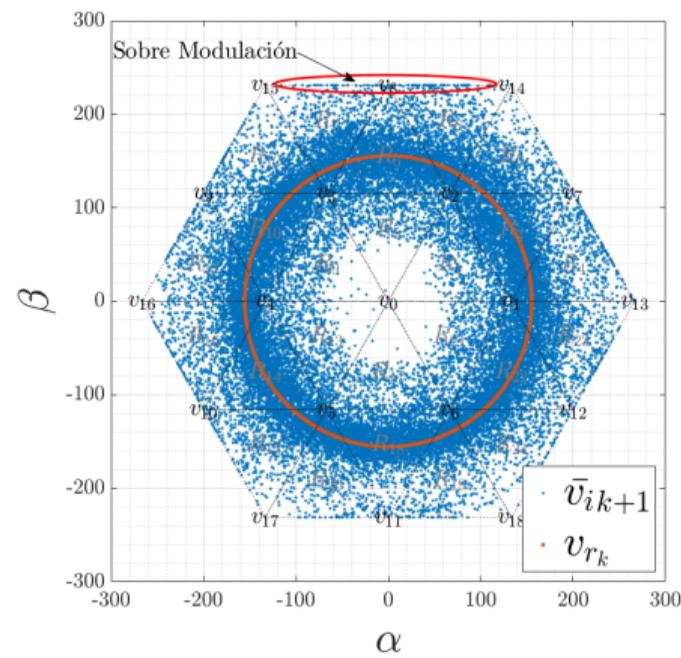
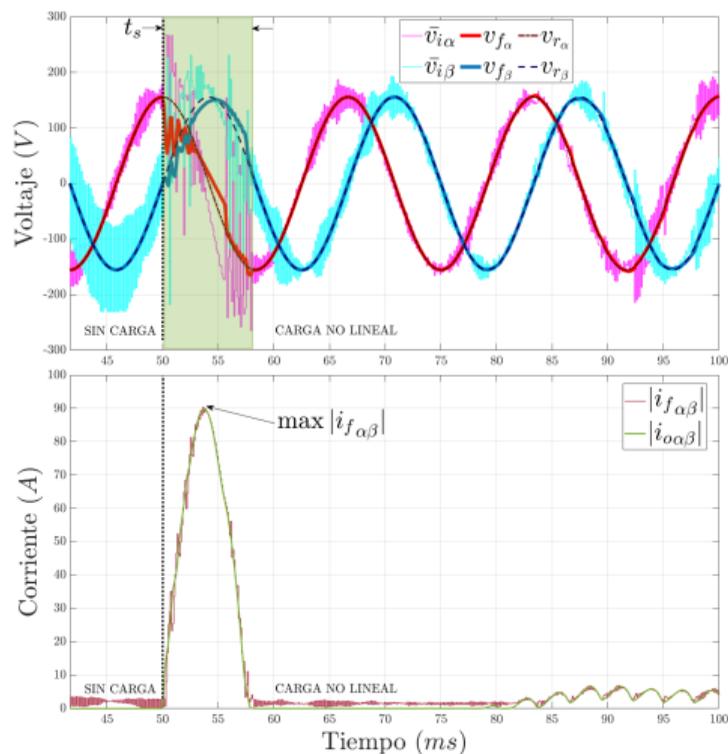


Figura: OM²PC

Efecto de Acoplamiento Cruzado en el Filtro LC



OM²PC sin Restricciones

Función de costo de error de voltaje:

$$g(v) = |v_{ref\alpha\beta, k+2} - v_{f\alpha\beta, k+2}(v)|^2 \quad (9)$$

Función de costo para regiones:

$$G_j = \sum_{i=1}^3 g(v_{ji}) = g(v_{j1}) + g(v_{j2}) + g(v_{j3}) \quad (10)$$

Región Óptima

$$\mathcal{R}_{opt} = \arg \min_j G_j \quad (11)$$

OM²PC sin Restricciones

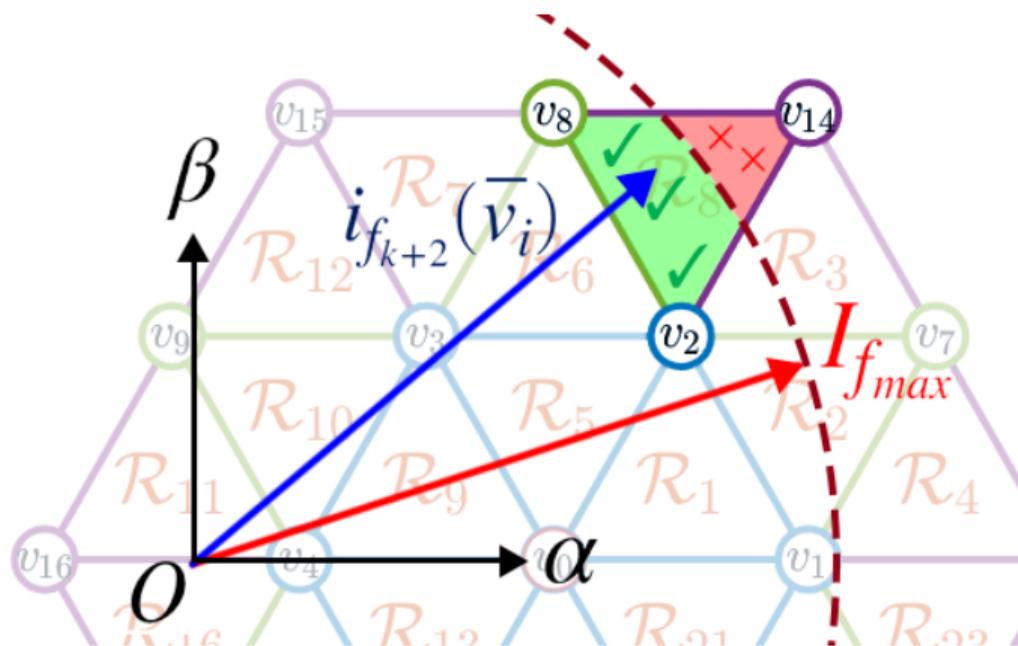


Figura: Ilustración de las múltiples evaluaciones de la función de costo.

OM²PC con Restricciones

Función de costo con restricciones:

$$g_c(v) = g(v) + h_{lim}(i_{f_{\alpha\beta, k+2}}(v)) \quad (12)$$

En donde:

$$h_{lim}(i_{f_{\alpha\beta}}) = \begin{cases} 0 & \text{if } |i_{f_{\alpha\beta}}| < I_{f_{max}} \\ \infty & \text{if } |i_{f_{\alpha\beta}}| \geq I_{f_{max}} \end{cases} \quad (13)$$

Función de costo para regiones:

$$\bar{G}_j = g_c(\bar{v}_j) = g_c(\mathbf{v}_j \cdot \mathbf{d}) = g_c(d_1 v_{j1} + d_2 v_{j2} + d_3 v_{j3}) \quad (14)$$

Región Óptima

$$\mathcal{R}_{opt} = \arg \min_j \bar{G}_j \quad (15)$$

OM²PC con Restricciones

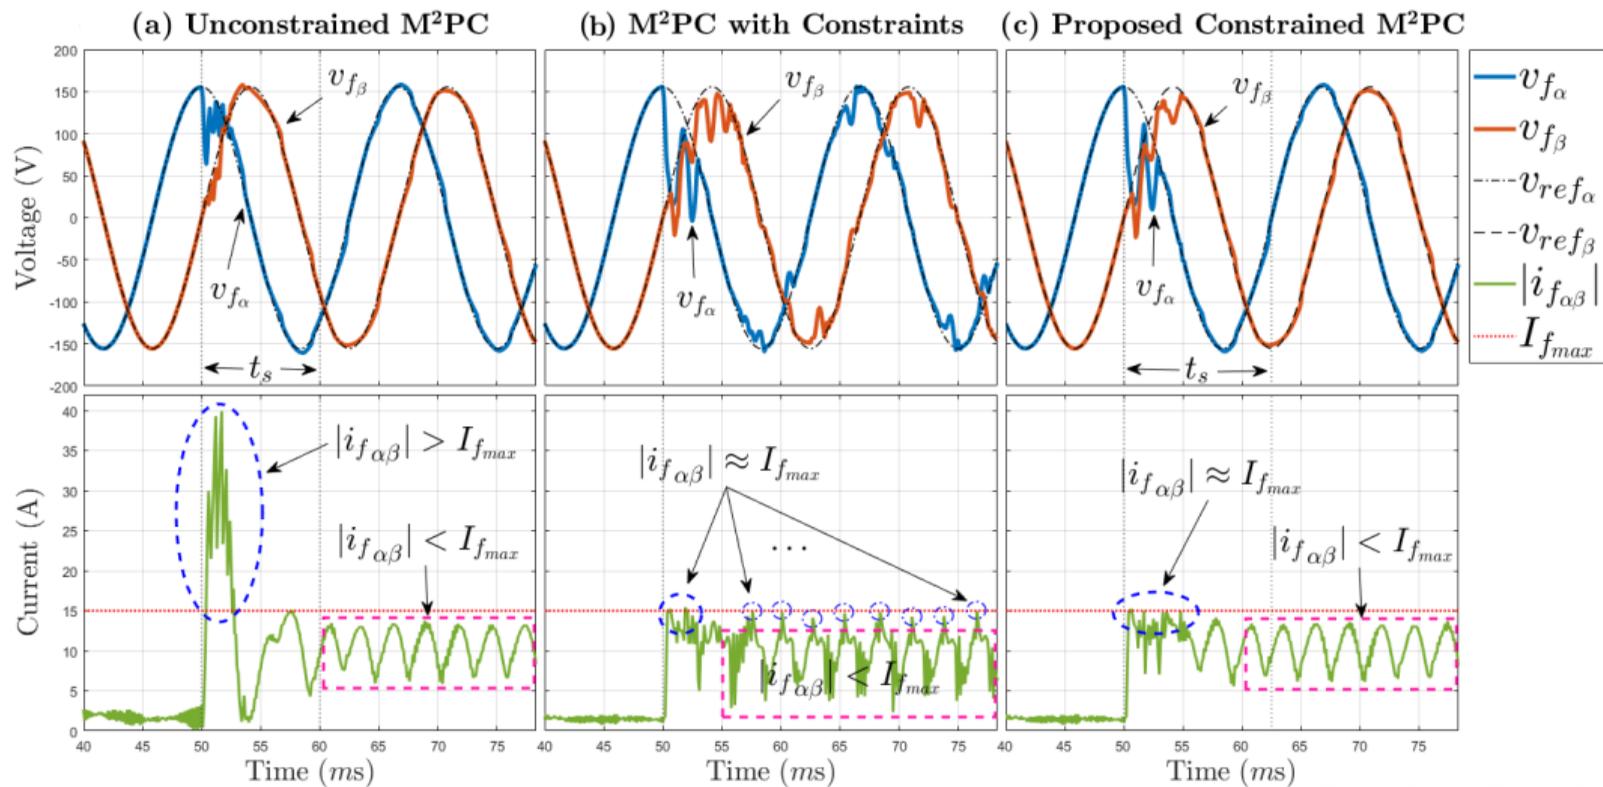
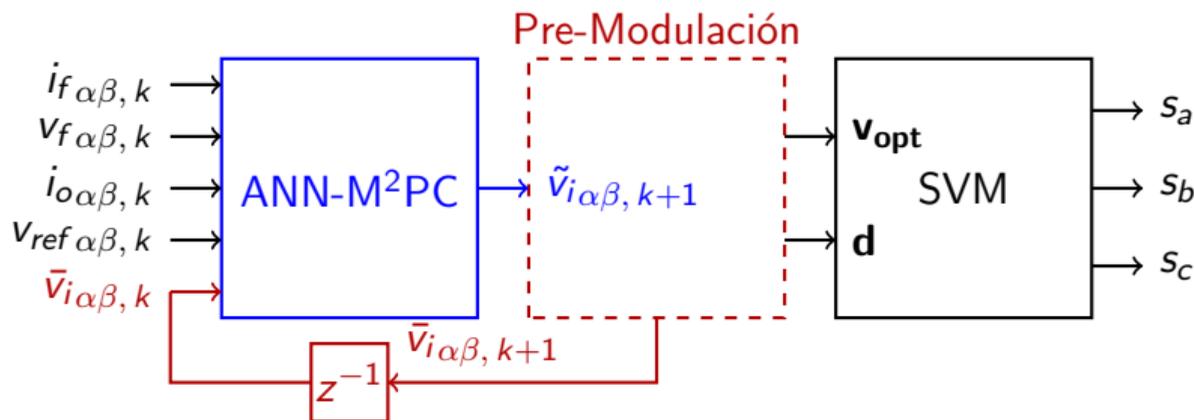


Tabla de Contenidos

- 1 Introducción
- 2 Marco Teórico
- 3 Propuesta de Investigación**
 - Controlador Neuronal
 - Estrategia de Control
 - Etapa de Pre-Modulación**
- 4 Resultados
 - Entrenamiento
 - Simulaciones
 - Análisis de Sensitividad
 - Tiempos de Ejecución
- 5 Conclusiones y Trabajos Futuros

Motivación



Sabemos que:

Si tenemos v_{opt} y d , podemos obtener fácilmente $\bar{v}_{i\alpha\beta,k+1}$.

Entonces:

¿Si tenemos $\tilde{v}_{i\alpha\beta,k+1}$, podemos obtener v_{opt} y d ?

Ciclos de Trabajo

Sabiendo la región óptima \mathcal{R}_{opt} , se puede calcular los ciclos de trabajo de la siguiente forma:

$$\underbrace{\begin{bmatrix} v_{\text{opt}1,\alpha} & v_{\text{opt}2,\alpha} & v_{\text{opt}3,\alpha} \\ v_{\text{opt}1,\beta} & v_{\text{opt}2,\beta} & v_{\text{opt}3,\beta} \\ 1 & 1 & 1 \end{bmatrix}}_{\mathbf{V}_{\text{opt}}} \cdot \underbrace{\begin{bmatrix} d_1 \\ d_2 \\ d_3 \end{bmatrix}}_{\mathbf{d}} = \underbrace{\begin{bmatrix} \tilde{v}_{i\alpha,k+1} \\ \tilde{v}_{i\beta,k+1} \\ 1 \end{bmatrix}}_{\tilde{\mathbf{v}}_i} \quad (16)$$

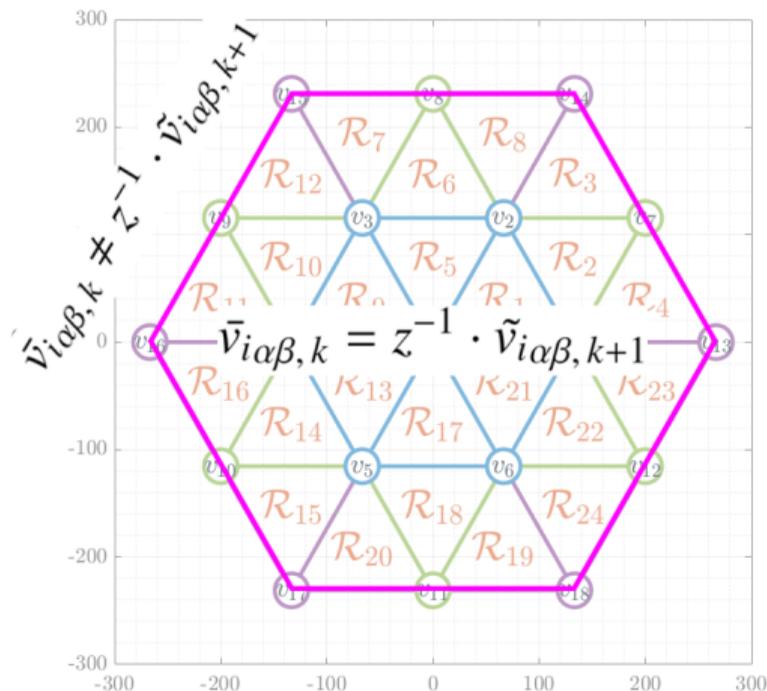
$$\mathbf{d} = \mathbf{V}_{\text{opt}}^{-1} \cdot \tilde{\mathbf{v}}_i \quad (17)$$

Nota:

- \mathbf{V}_{opt} es una de las 24 matrices constantes que pueden existir. Una por cada región ($\mathcal{R}_j \rightarrow \mathbf{V}_j$ donde $j \in \{1, 2, \dots, 24\}$).
- Al ser \mathbf{V}_j una matriz constante, se puede invertir fuera de línea, lo que reduce el coste computacional.

Sobre Modulación

La red neuronal puede producir valores fuera del espacio de conmutaciones. En cuyo caso, se debe aplicar un algoritmo de sobre modulación.



Lazo de control

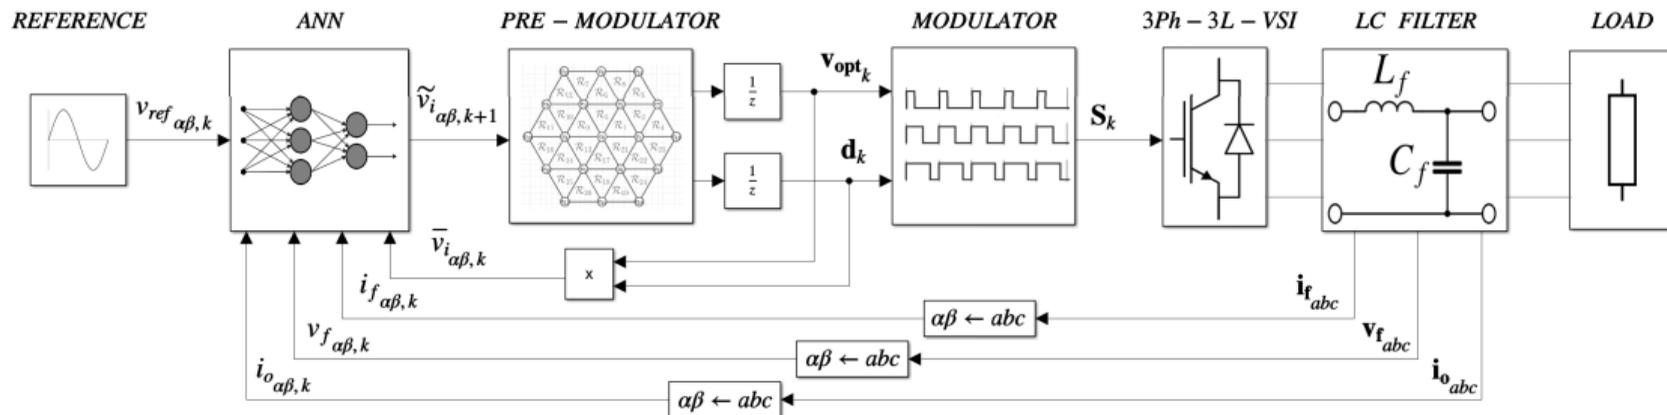


Figura: Lazo de control propuesto.

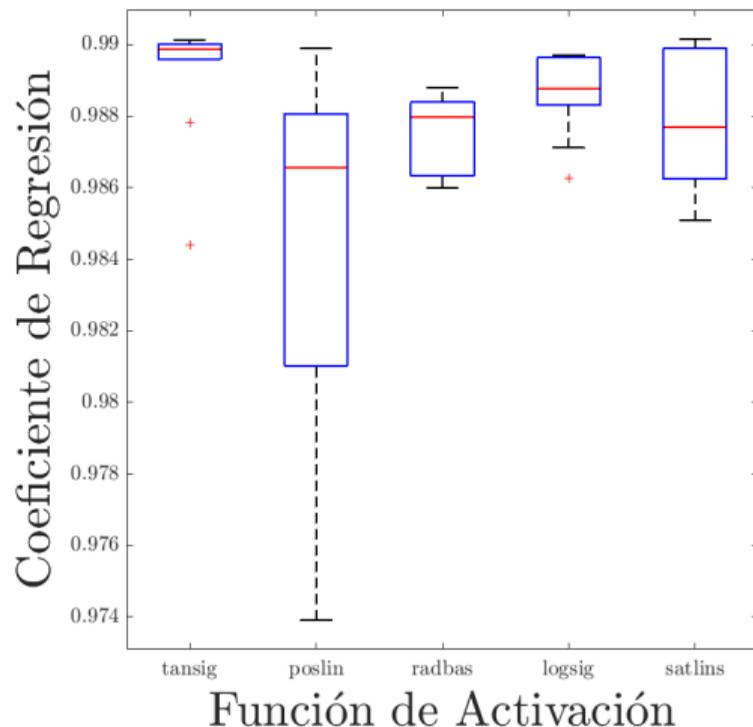
Tabla de Contenidos

- 1 Introducción
- 2 Marco Teórico
- 3 Propuesta de Investigación
 - Controlador Neuronal
 - Estrategia de Control
 - Etapa de Pre-Modulación
- 4 Resultados**
 - Entrenamiento
 - Simulaciones
 - Análisis de Sensitividad
 - Tiempos de Ejecución
- 5 Conclusiones y Trabajos Futuros

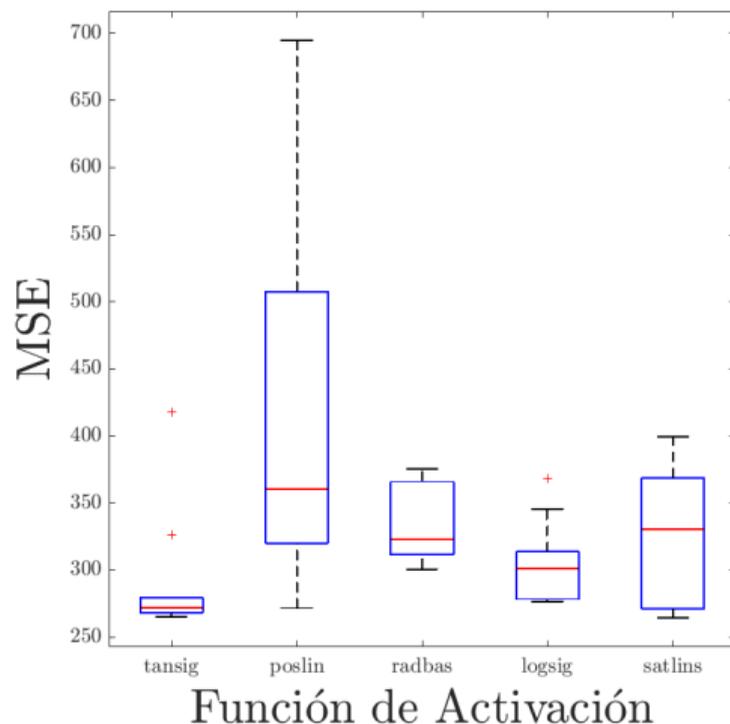
Tabla de Contenidos

- 1 Introducción
- 2 Marco Teórico
- 3 Propuesta de Investigación
 - Controlador Neuronal
 - Estrategia de Control
 - Etapa de Pre-Modulación
- 4 **Resultados**
 - **Entrenamiento**
 - Simulaciones
 - Análisis de Sensitividad
 - Tiempos de Ejecución
- 5 Conclusiones y Trabajos Futuros

Selección de función de activación

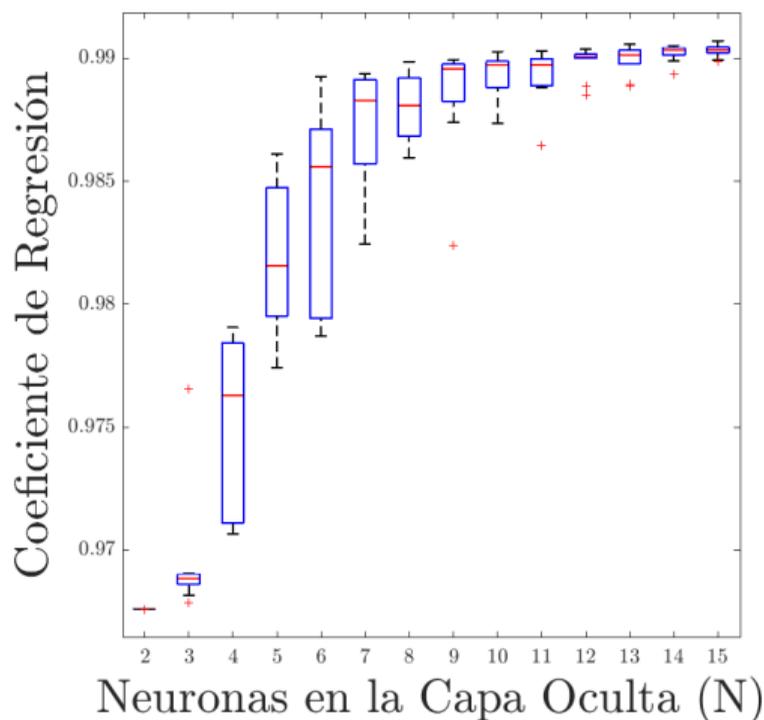


(a) Coeficiente de Regresión

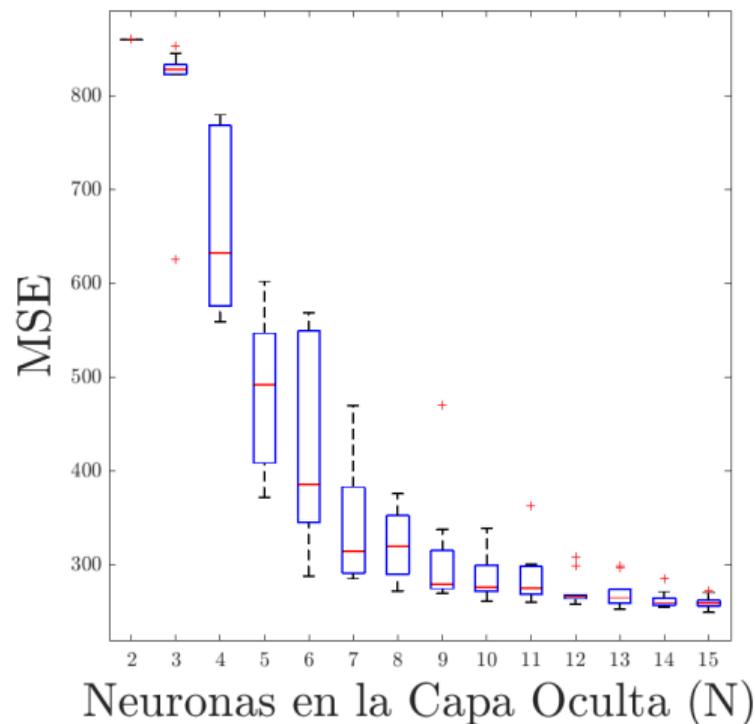


(b) Error Cuadrático Medio

Número de neuronas en la capa oculta



(a) Coeficiente de Regresión



(b) Error Cuadrático Medio

Entrenamiento

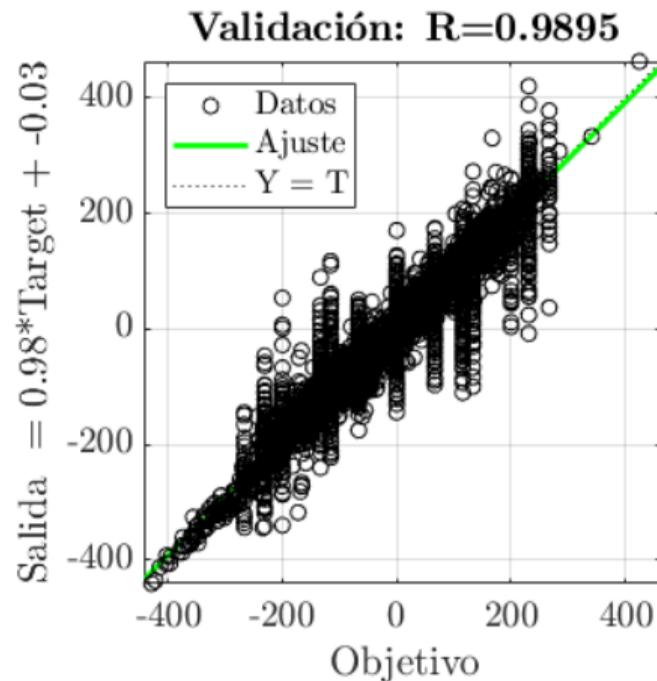


Figura: Coeficiente de regresión en la etapa de validación.

Tabla de Contenidos

- 1 Introducción
- 2 Marco Teórico
- 3 Propuesta de Investigación
 - Controlador Neuronal
 - Estrategia de Control
 - Etapa de Pre-Modulación
- 4 Resultados**
 - Entrenamiento
 - Simulaciones**
 - Análisis de Sensitividad
 - Tiempos de Ejecución
- 5 Conclusiones y Trabajos Futuros

Voltaje Promedio del Inversor

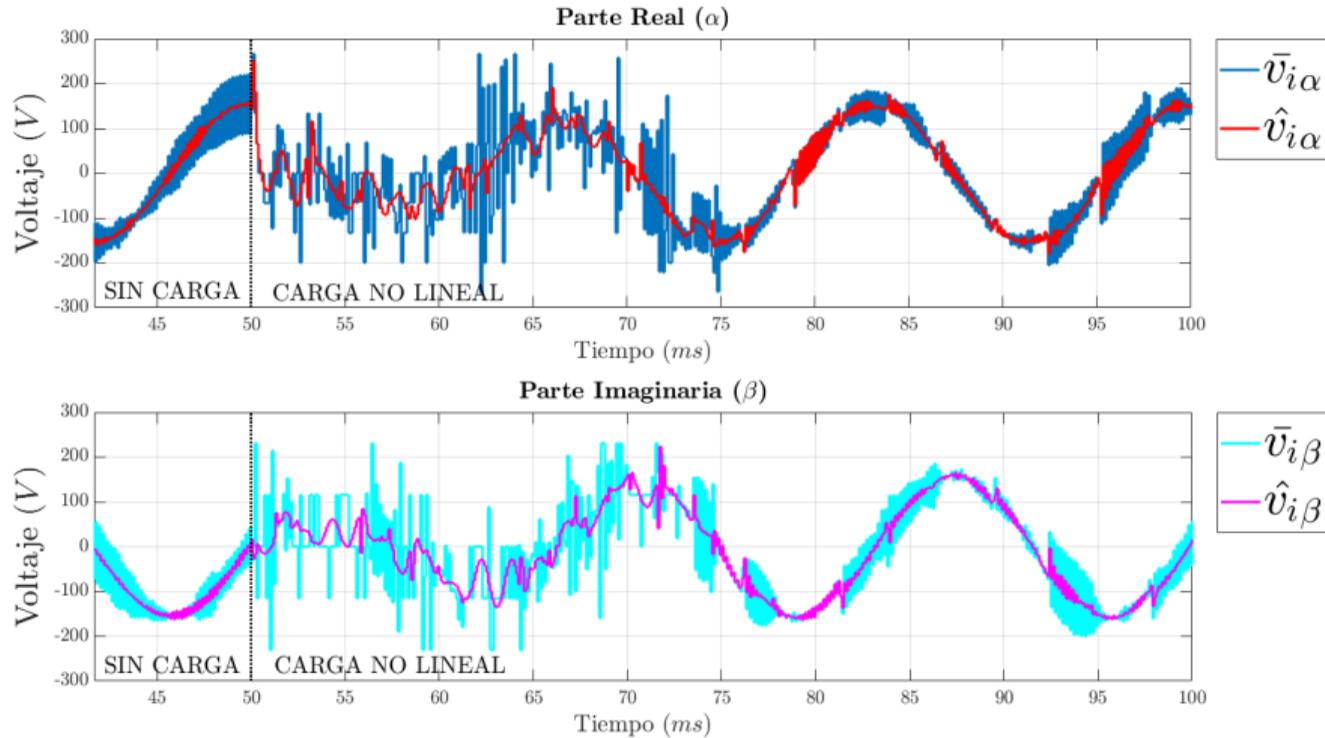


Figura: Comparación del voltaje del inversor: OM²PC ($\bar{v}_{i\alpha\beta}$) y ANN-M²PC ($\hat{v}_{i\alpha\beta}$)

Voltaje del Filtro

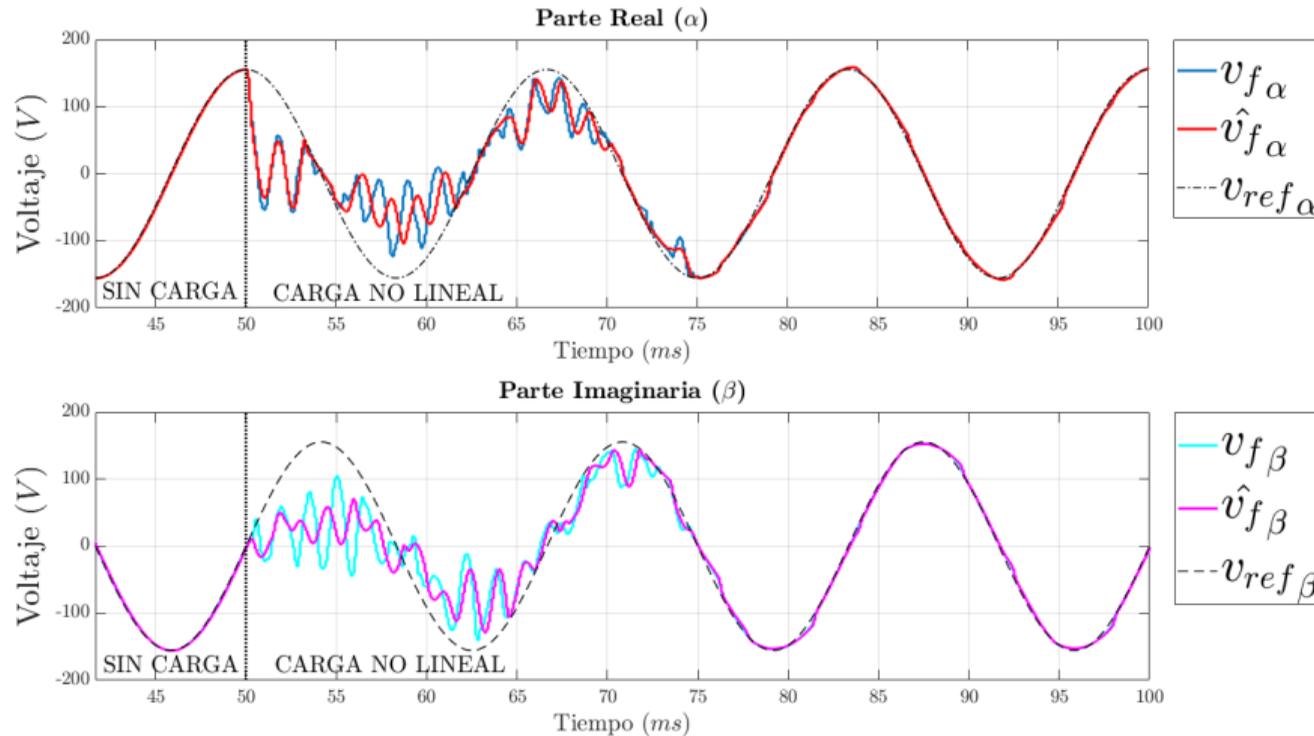


Figura: Comparación del voltaje del filtro: OM²PC ($v_{f\alpha\beta}$) y ANN-M²PC ($\hat{v}_{f\alpha\beta}$)

Magnitud de la Corriente del Filtro

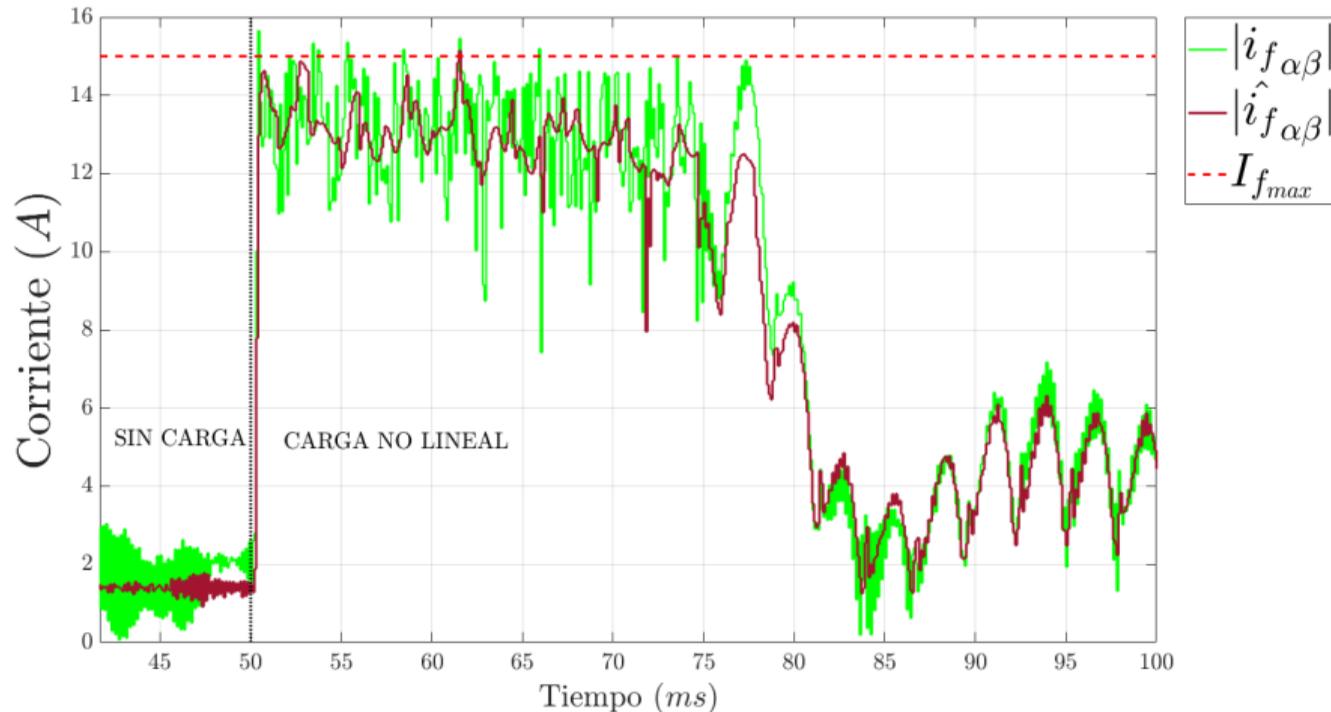


Figura: Comparación de la corriente del filtro: OM²PC ($i_{f\alpha\beta}$) y ANN-M²PC ($\hat{i}_{f\alpha\beta}$)

Tabla de Contenidos

- 1 Introducción
- 2 Marco Teórico
- 3 Propuesta de Investigación
 - Controlador Neuronal
 - Estrategia de Control
 - Etapa de Pre-Modulación
- 4 **Resultados**
 - Entrenamiento
 - Simulaciones
 - **Análisis de Sensitividad**
 - Tiempos de Ejecución
- 5 Conclusiones y Trabajos Futuros

Inductancia

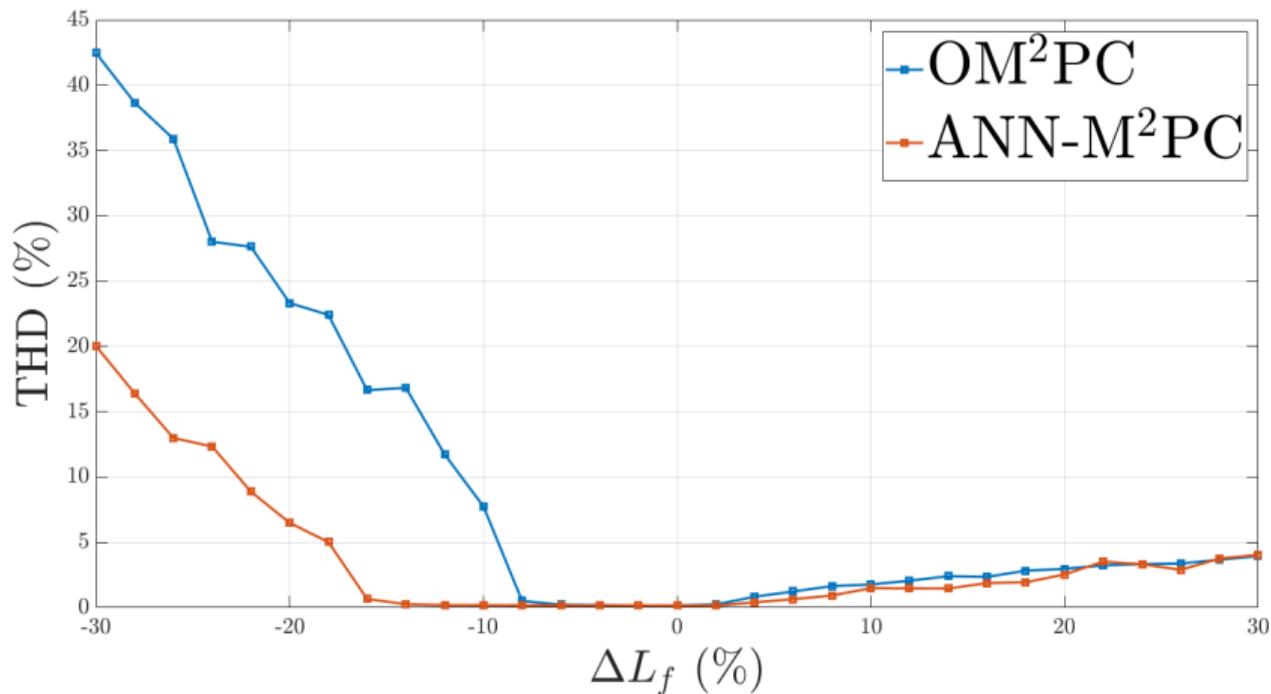


Figura: Sensitividad del THD del voltaje resultante con respecto a variaciones en la inductancia.

Capacitancia

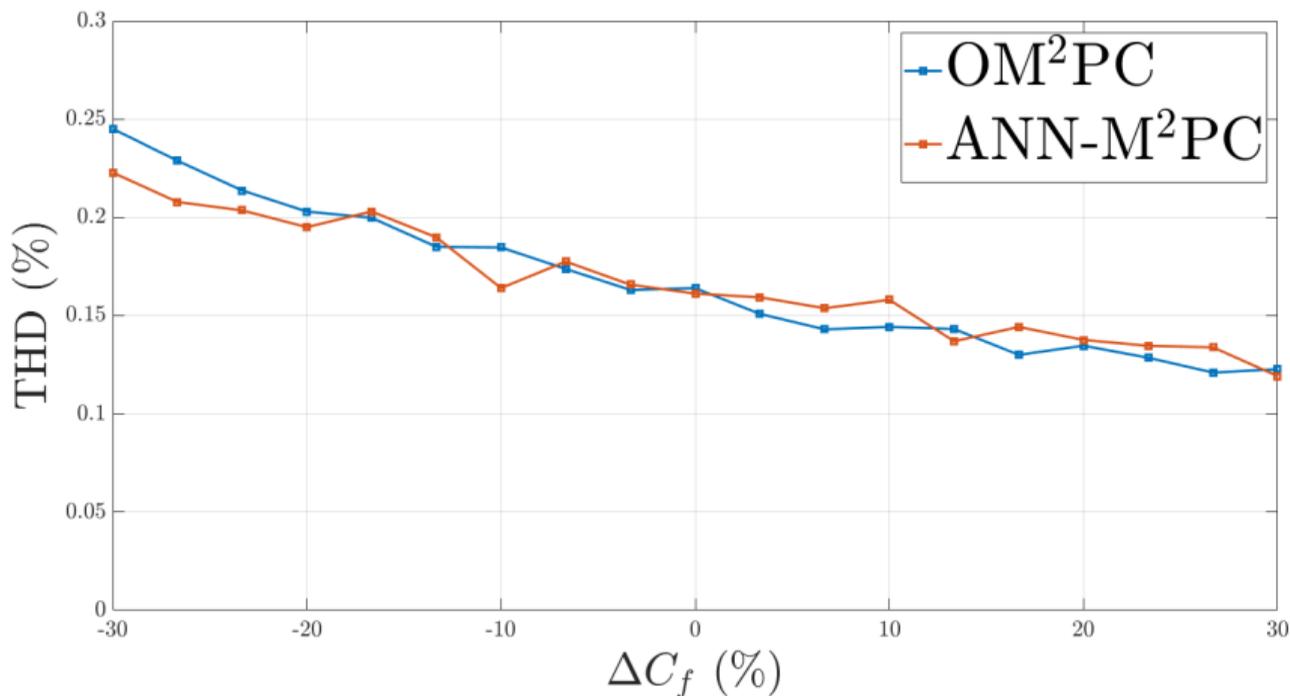


Figura: Sensitividad del THD del voltaje resultante con respecto a variaciones en la capacitancia.

Tabla de Contenidos

- 1 Introducción
- 2 Marco Teórico
- 3 Propuesta de Investigación
 - Controlador Neuronal
 - Estrategia de Control
 - Etapa de Pre-Modulación
- 4 Resultados**
 - Entrenamiento
 - Simulaciones
 - Análisis de Sensitividad
 - Tiempos de Ejecución**
- 5 Conclusiones y Trabajos Futuros

Ordenador

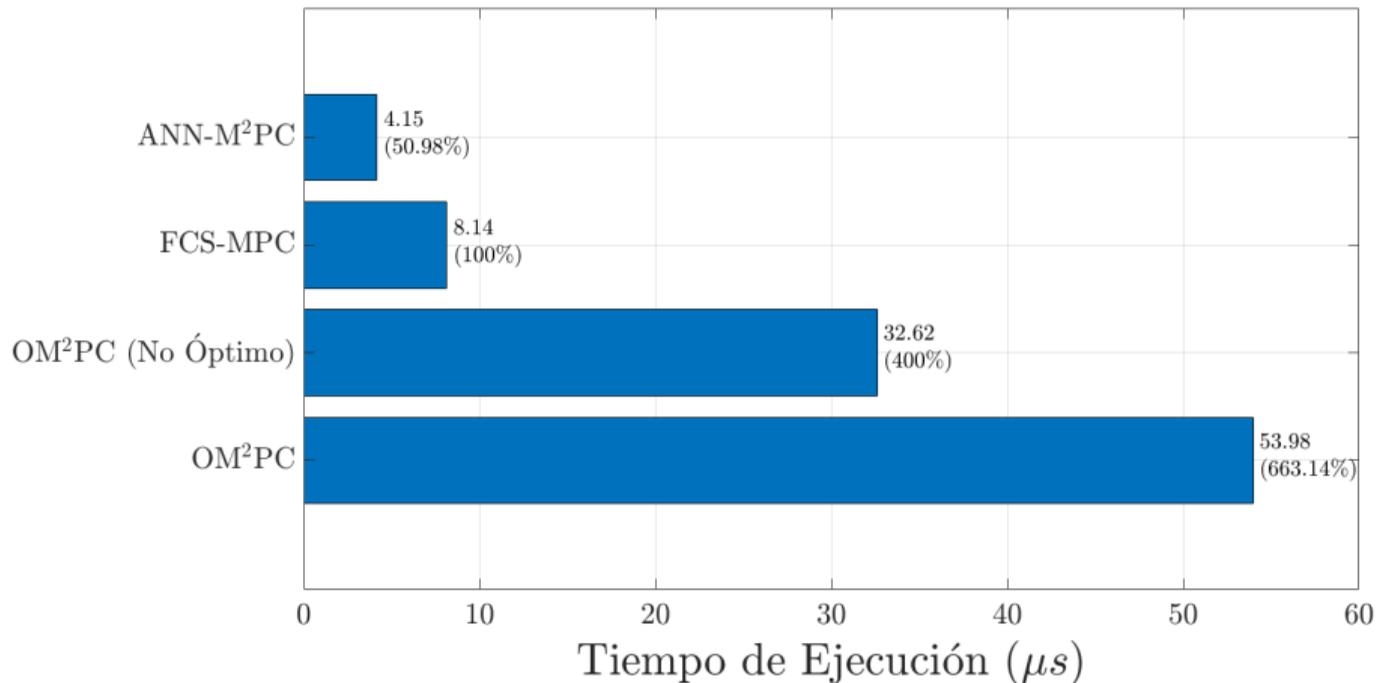


Figura: Tiempos de ejecución en un procesador Intel Core i7-6700 a 3.40Ghz con 32GB en RAM. ↻ 🔍

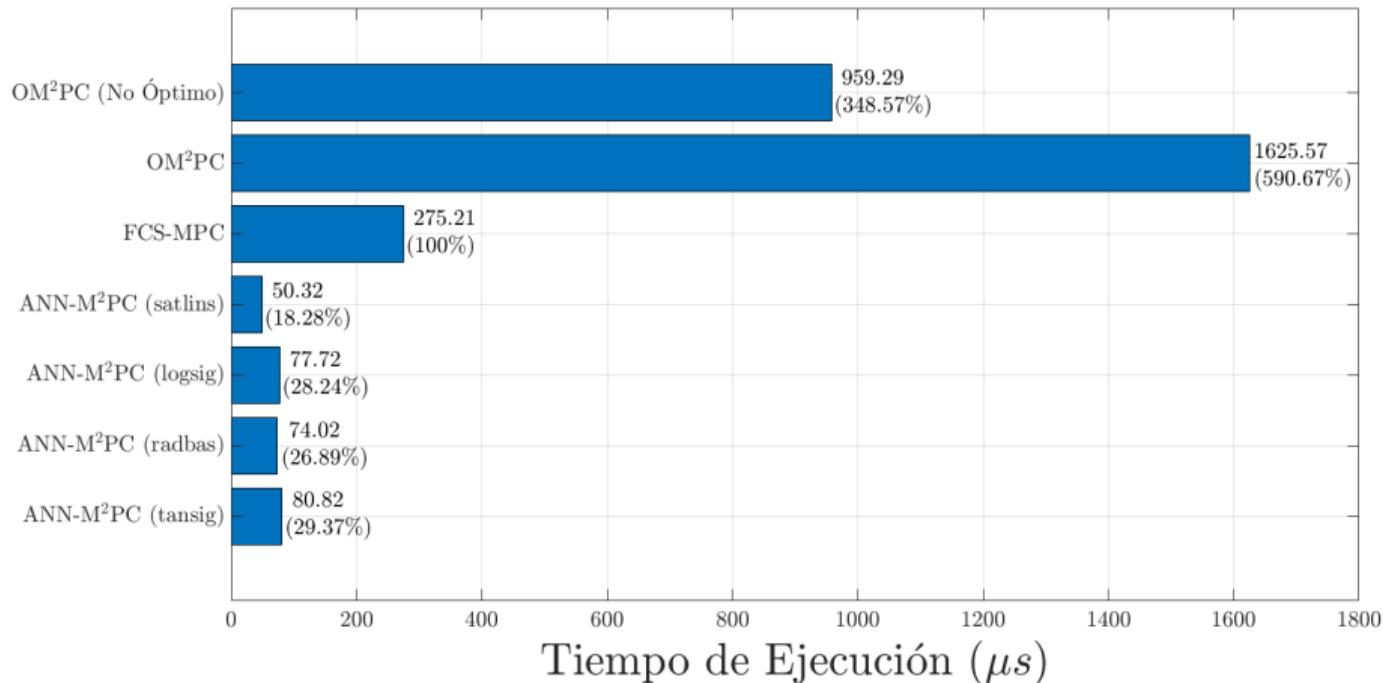


Figura: Tiempos de ejecución en un DSP F28335.

Tabla de Contenidos

- 1 Introducción
- 2 Marco Teórico
- 3 Propuesta de Investigación
 - Controlador Neuronal
 - Estrategia de Control
 - Etapa de Pre-Modulación
- 4 Resultados
 - Entrenamiento
 - Simulaciones
 - Análisis de Sensitividad
 - Tiempos de Ejecución
- 5 Conclusiones y Trabajos Futuros**

Conclusiones

- Mediante redes neuronales se ha logrado incrementar la velocidad de ejecución de estrategias de control predictivo cerca de treinta veces.
- La estrategia propuesta permite la implementación de algoritmos de control que antes eran solo viables en mediante simulaciones.
- Se ha determinado que diez neuronas en la capa oculta del controlador ANN-M²PC es suficiente para imitar cerca del 99% de la relación entrada-salida del controlador emulado (OM²PC).

Conclusiones

- Es importante que la red neuronal evalúe únicamente valores que se encuentren dentro de su rango de entrenamiento. De otra forma, la respuesta de la red no se puede garantizar, lo que puede llevar a desempeños pobres e incluso a inestabilidades.
- La corriente en la inductancia en un inversor trifásico con filtro LC puede presentar picos, los cuales pueden llegar a dañar equipos, saturar el núcleo de la misma inductancia, e incluso salirse del rango de entrenamiento de la red. Por tales motivos, es importante mantener dicha corriente limitada.

Conclusiones

- El controlador neuronal propuesto estima la acción de control como el voltaje promedio que el inversor debe aplicar en el siguiente instante de tiempo. Sin embargo, se necesita convertir dicho voltaje en los patrones de conmutación que el inversor sea capaz ejecutar. Para lo cual, se recurre a una etapa de pre-modulación, misma que debe hacer la conversión con el menor gasto computacional posible.
- La etapa de pre-modulación garantiza que la acción de control generada por la red neuronal sea factible de aplicar. Es decir, se encuentre dentro del espacio de conmutaciones.
- Es importante que la acción de control a imitar no posea discontinuidades a fin de garantizar un mejor entrenamiento.

Trabajos Futuros

- Analizar otras estrategias para la generación de los patrones de entrenamiento que no estén basadas en simulaciones del sistema en lazo cerrado.
- En el presente trabajo se asume un bus DC constante. Sin embargo, en la práctica este puede variar, por lo que es necesario considerar el balance del bus DC dentro de la red neuronal.
- De momento se ha considerado únicamente un controlador basado en M^2PC para ser emulado, pero existen otras estrategias basadas en CCS-MPC que podrían ofrecer un mejor rendimiento.
- Utilizar algoritmos de inteligencia artificial interpretables con el objeto de descubrir la relación entre las variables del sistema y la acción de control óptima.

Referencias I

- [1] K. Bandy and P. Stumpf, "Model Predictive Torque Control for Multilevel Inverter fed Induction Machines Using Sorting Networks," *IEEE Access*, vol. 9, pp. 13800–13813, 2021, ISSN: 21693536. DOI: 10.1109/ACCESS.2021.3052129.
- [2] Q. Wang, H. Yu, C. Li, *et al.*, "A Low-Complexity Optimal Switching Time-Modulated Model-Predictive Control for PMSM with Three-Level NPC Converter," *IEEE Transactions on Transportation Electrification*, vol. 6, no. 3, pp. 1188–1198, 2020, ISSN: 23327782. DOI: 10.1109/TTE.2020.3012352.
- [3] Y. Yang, H. Wen, M. Fan, *et al.*, "Multiple-Voltage-Vector Model Predictive Control with Reduced Complexity for Multilevel Inverters," *IEEE Transactions on Transportation Electrification*, vol. 6, no. 1, pp. 105–117, 2020, ISSN: 23327782. DOI: 10.1109/TTE.2020.2973045.
- [4] H. T. Nguyen and J. W. Jung, "Disturbance-Rejection-Based Model Predictive Control: Flexible-Mode Design with a Modulator for Three-Phase Inverters," *IEEE Transactions on Industrial Electronics*, vol. 65, no. 4, pp. 2893–2903, 2018, ISSN: 02780046. DOI: 10.1109/TIE.2017.2758723.
- [5] C. Zheng, T. Dragičević, B. Majmunović, and F. Blaabjerg, "Constrained Modulated Model-Predictive Control of an LC-Filtered Voltage-Source Converter," *IEEE Transactions on Power Electronics*, vol. 35, no. 2, pp. 1967–1977, 2020, ISSN: 19410107. DOI: 10.1109/TPEL.2019.2917634.
- [6] M. Novak and T. Dragicevic, "Supervised Imitation Learning of Finite-Set Model Predictive Control Systems for Power Electronics," *IEEE Transactions on Industrial Electronics*, vol. 68, no. 2, pp. 1717–1723, 2021, ISSN: 15579948. DOI: 10.1109/TIE.2020.2969116.
- [7] I. S. Mohamed, S. Rovetta, T. D. Do, T. Dragicevic, and A. A. Diab, "A neural-network-based model predictive control of three-phase inverter with an output LC Filter," *IEEE Access*, vol. 7, pp. 124737–124749, 2019, ISSN: 21693536. DOI: 10.1109/ACCESS.2019.2938220. arXiv: 1902.09964.
- [8] L. Cao, Y. Li, X. Li, L. Guo, N. Jin, and H. Cao, "A dual-vector modulated model predictive control method for voltage source inverters with a new duty cycle calculation method," *Energies*, vol. 13, no. 6, 2020, ISSN: 19961073. DOI: 10.3390/en13164200.
- [9] Y. Yang, H. Wen, M. Fan, M. Xie, R. Chen, and Y. Wang, "A Constant Switching Frequency Model Predictive Control Without Weighting Factors for T-Type Single-Phase Three-Level Inverters," *IEEE Transactions on Industrial Electronics*, vol. 66, no. 7, pp. 5153–5164, 2019, ISSN: 02780046. DOI: 10.1109/TIE.2018.2868290.

Referencias II

- [10] P. Santis, D. Sáez, R. Cárdenas, and A. Núñez, "Pareto-based modulated model predictive control strategy for power converter applications," *Electric Power Systems Research*, vol. 171, no. September 2017, pp. 158–174, 2019, ISSN: 03787796. DOI: 10.1016/j.epsr.2019.02.016. [Online]. Available: <https://doi.org/10.1016/j.epsr.2019.02.016>.
- [11] L. Tarisciotti, J. Lei, A. Formentini, *et al.*, "Modulated Predictive Control for Indirect Matrix Converter," *IEEE Transactions on Industry Applications*, vol. 53, no. 5, pp. 4644–4654, 2017, ISSN: 00939994. DOI: 10.1109/TIA.2017.2699666.
- [12] F. Donoso, A. Mora, R. Cardenas, A. Angulo, D. Saez, and M. Rivera, "Finite-Set Model-Predictive Control Strategies for a 3L-NPC Inverter Operating with Fixed Switching Frequency," *IEEE Transactions on Industrial Electronics*, vol. 65, no. 5, pp. 3954–3965, 2018, ISSN: 02780046. DOI: 10.1109/TIE.2017.2760840.
- [13] C. F. Garcia, C. A. Silva, J. R. Rodriguez, P. Zanchetta, and S. A. Odhano, "Modulated Model-Predictive Control with Optimized Overmodulation," *IEEE Journal of Emerging and Selected Topics in Power Electronics*, vol. 7, no. 1, pp. 404–413, 2019, ISSN: 21686785. DOI: 10.1109/JESTPE.2018.2828198.
- [14] A. Sarajian, C. F. Garcia, Q. Guan, *et al.*, "Overmodulation Methods for Modulated Model Predictive Control and Space Vector Modulation," *IEEE Transactions on Power Electronics*, vol. 36, no. 4, pp. 4549–4559, 2021, ISSN: 19410107. DOI: 10.1109/TPEL.2020.3023927.