

Trabajo Fin de Grado
Grado en Ingeniería de Tecnologías Industriales

Optimización de la operación de convertidores de potencia DC/DC interleaved mediante el uso de redes neuronales

Autora: Carmen Casillas Rego

Tutor: Sergio Vázquez Pérez

Dpto. Ingeniería Electrónica
Escuela Técnica Superior de Ingeniería
Universidad de Sevilla

Sevilla, 2024



Trabajo Fin de Grado
Grado en Ingeniería de Tecnologías Industriales

Optimización de la operación de convertidores de potencia DC/DC interleaved mediante el uso de redes neuronales

Autora:

Carmen Casillas Rego

Tutor:

Sergio Vázquez Pérez

Profesor Titular

Dpto. Ingeniería Electrónica
Escuela Técnica Superior de Ingeniería
Universidad de Sevilla

Sevilla, 2024

Trabajo Fin de Grado: Optimización de la operación de convertidores de potencia DC/DC interleaved mediante el uso de redes neuronales

Autora: Carmen Casillas Rego

Tutor: Sergio Vázquez Pérez

El tribunal nombrado para juzgar el trabajo arriba indicado, compuesto por los siguientes profesores:

Presidente:

Vocal/es:

Secretario:

acuerdan otorgarle la calificación de:

El Secretario del Tribunal

Fecha:

Índice

1	Introducción	1
1.1	Ingeniería	2
2	Convertidores Interleaved	5
2.1	Modelo del convertidor	5
2.2	Operación <i>Interleaved</i>	6
2.2.1	Desfase óptimo	7
3	Algoritmo Metaheurístico	11
3.1	Compensación Simétrica	13
3.2	Compensación Asimétrica	15
4	Red Neuronal	19
4.1	Condiciones de Operación	19
4.2	Entrenamiento de modelos	20
4.3	Modelos	21
4.3.1	Primer modelo	21
	Pruebas: <i>epochs</i>	23
4.3.2	Segundo modelo	25
4.3.3	Tercer modelo	26
	Pruebas: número de neuronas y capas	28
4.3.4	Cuarto modelo	30
	Pruebas: función de activación	32
	Pruebas: <i>epochs</i>	33
	Pruebas: número de datos	33
4.3.5	Quinto Modelo	35
	Cambio a la aproximación de la Tangente Hiperbólica	36
	Pruebas: <i>epochs</i> , número de neuronas y capas.	40
4.3.6	Modelo Final	42
5	Sustitución del AMH por la ANN	45
5.1	Compensación Simétrica	45
5.2	Compensación Asimétrica	46

6 Conclusión y futuros proyectos	49
<i>Índice de Figuras</i>	51
<i>Índice de Tablas</i>	55
<i>Bibliografía</i>	57

1 Introducción

La movilidad sostenible es un objetivo común en muchos gobiernos actualmente. Esto se debe a que, según la UE, el 25 % de las emisiones de gases de efecto invernadero provienen del transporte, como se refleja en el gráfico de la Figura 1.1 [1]. A pesar de que en otros sectores hayan disminuido las emisiones considerablemente en los últimos años, en el transporte sin embargo han aumentado. Es por eso que en el paquete de medidas "Objetivo 55" de la UE, muchas de ellas tratan este problema. Este paquete de medidas, presentado por la Comisión Europea el 14 de Julio de 2021, es un conjunto de propuestas para revisar y actualizar las leyes de la UE. Su objetivo es reducir las emisiones de gases de efecto invernadero al menos en el 55 % para el 2030 (en comparación con los valores de 1990) y alcanzar la neutralidad climática en 2050 [1].

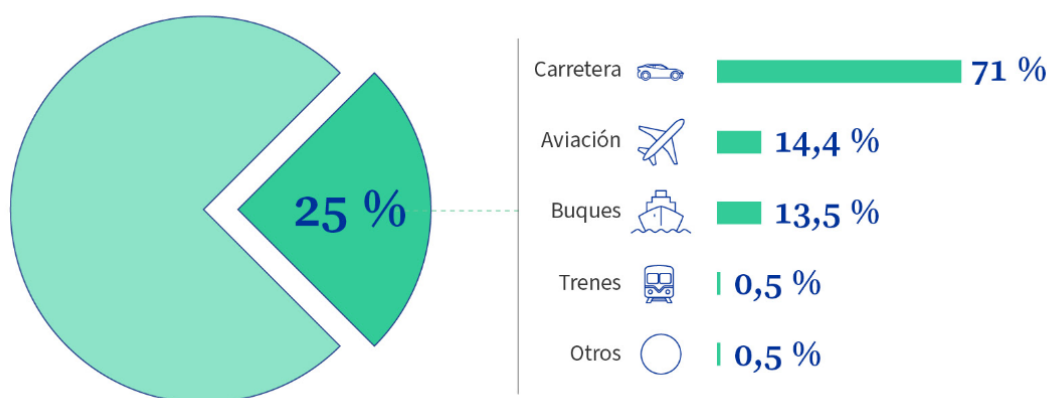


Figura 1.1 Emisiones de gases de efecto invernadero, según la UE.

Una de las propuestas impulsadas para reducir las emisiones de gases de efecto invernadero en el transporte es disminuir el consumo de combustibles fósiles, favoreciendo el uso de combustibles alternativos, como pueden ser el hidrógeno y el metano licuado; aunque la alternativa más extendida es el uso de vehículos eléctricos. El Reglamento sobre la Infraestructura para los Combustibles Alternativos, adoptado por el Consejo Europeo en julio de 2023, busca garantizar la existencia de una red de infraestructuras que permita la carga o repostaje de estos combustibles alternativos, así como la facilidad de su uso y la interoperabilidad en toda la UE. Esto es necesario para facilitar y fomentar el uso de vehículos y medios de transporte de emisión cero o baja emisión, evitando la falta de autonomía [2].

En el Reglamento se contemplan medidas para buques y aeronaves, pero principalmente para el transporte por carretera, ya que este tiene el mayor porcentaje de emisiones de gases de efecto

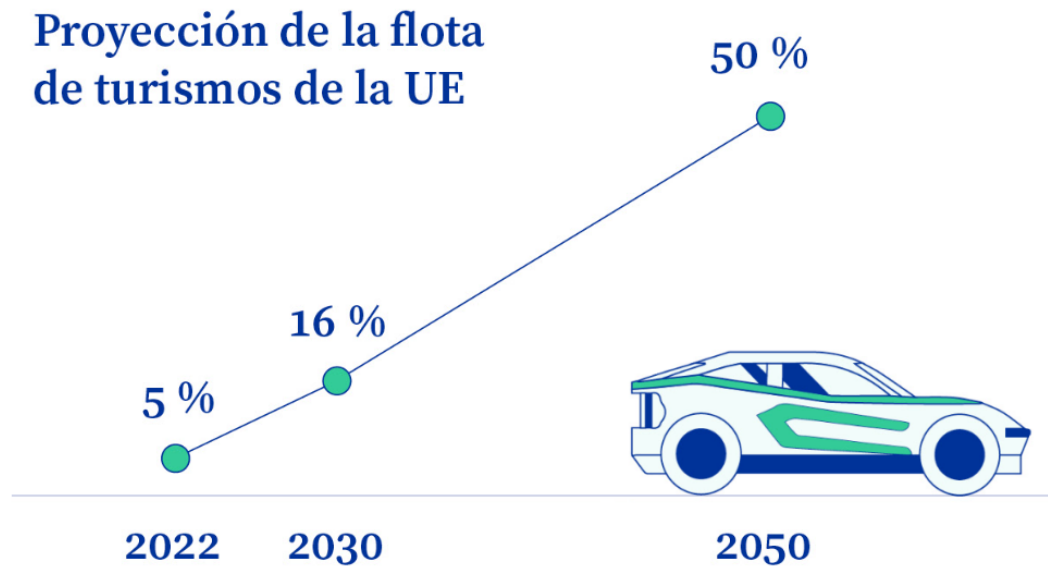


Figura 1.2 Proyección del crecimiento de la flota de vehículos eléctricos.

invernadero dentro del transporte. Solamente los turismos representan el 12% de todas las emisiones de dióxido de carbono de la UE. En 2022, más de 13.4 millones de turismos y furgonetas utilizan combustibles alternativos en la UE, lo que representaba un 5% de la flota de vehículos. Para el 2050 se prevé que este porcentaje se multiplique por 10, alcanzando el 50% de la flota, como refleja la Figura 1.2 [3]. El Reglamento busca facilitar el uso de estos nuevos vehículos de combustibles alternativos habilitando la capacidad pública de recarga en las calles y autopistas europeas, de forma que los ciudadanos puedan cargar sus coches eléctricos con la misma facilidad que se reposta en una gasolinera tradicional, según Raquel Sánchez Jiménez, ministra de Transportes, Movilidad y Agenda Urbana de España de 2021 a 2023 [4].

Para ello, el Reglamento fija una serie de normas y objetivos a cumplir para el 2025 o 2030, entre ellas habilitar una red de recarga con instalaciones en los que se pueda pagar fácilmente: a partir de 2025 se deben instalar estaciones de carga rápida de al menos 150kW para turismos y furgonetas cada 60km en los principales corredores de transporte de la UE, y de al menos 350kW para vehículos pesados cada 60km en la red básica de transporte y cada 100km en la red global. Para 2030 la red deberá tener cobertura completa [4].

1.1 Ingeniería

Todo esto presenta nuevos retos para la ingeniería, desde la disminución de los tiempos de carga a la compatibilidad de las estaciones de carga con los diversos modelos de vehículos eléctricos que existen actualmente.

Desde 2010, la tecnología en baterías ha avanzado de manera significativa, la mayoría de vehículos eléctricos actuales pueden recorrer al menos 320km con una batería de 44kWh. Pero la gran variedad de capacidades de las baterías implica variaciones en los tiempos de carga esperados, muchos vehículos no son capaces cargar a la velocidad esperada en estaciones convencionales de recarga de 50kW, porque sus capacidades son distintas a las previstas en el diseño de las estaciones. Por ejemplo, con esa potencia de carga, un Nissan Leaf de 40kWh es capaz de cargarse al 80% en 40 minutos, mientras que un Chevrolet Bolt de 62kWh tardaría en alcanzar ese porcentaje casi 20 minutos más.

Con enchufes convencionales en los hogares, esta diferencia aumenta significativamente: tardan en cargar una batería de 60kWh más de 32h. Esto implica que aunque haya grandes avances en la reducción de tiempos de carga, (hasta 20-30 minutos para 400km) estos resultados solo se presenten en algunos vehículos y sean peores para otros [5].

Las incompatibilidades entre vehículos eléctricos asociadas a la falta de estandarización de hardware, y su consecuente incompatibilidad de carga, ha ido desapareciendo desde 2011. En 2014 surgió un sistema de carga abierto (CCS), promovido por la organización CharIn que propone una solución universal para coches eléctricos monofásicos y trifásicos, de corriente alterna y continua de alta potencia; en Estados Unidos y Europa. Actualmente contempla potencias de hasta 400kW para vehículos medianos y rangos de hasta 1.5kV y 3KA para vehículos grandes. Sin embargo, no es el único estándar de carga: la compañía Tesla, por ejemplo, tiene el suyo propio dedicado a sus vehículos, aunque es compatible con otros [5].

Las regularizaciones no contemplan, sin embargo, el amplio rango de voltajes que presentan las baterías. Los primeros modelos usaban 200V, y este valor ha ido aumentando, actualmente el rango de voltajes va desde los 450V a los 920V. Las configuraciones de 800V, por ejemplo, permitirían teóricamente duplicar la potencia de carga manteniendo la misma sección de cable, lo que supone una reducción de peso significativa en el vehículo. Sin embargo, la gran mayoría de estaciones de carga están diseñadas para vehículos de 400V, lo que supone que vehículos de voltajes superiores no llegan a cargarse del todo o incluso no se carguen. Una de las soluciones propuestas es dividir la batería en dos subsecciones de 400V, que se carguen en paralelo o en interleaved [5].

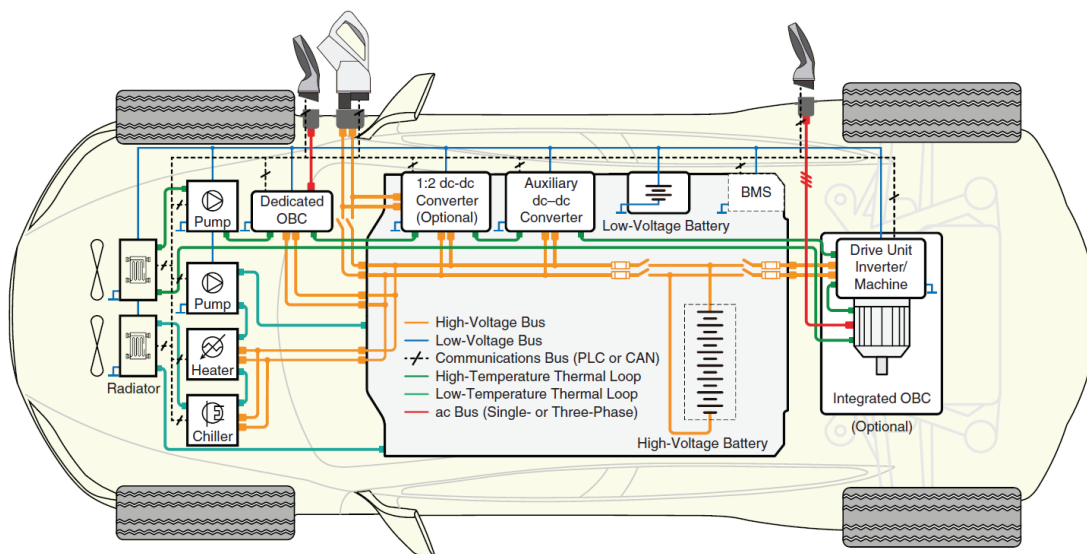


Figura 1.3 Tren de carga de un coche eléctrico.

La mayoría de coches enchufables tienen trenes de carga muy similares, como se refleja en la Figura 1.3, formados por: la batería, el sistema de gestión de la batería (BMS), el cargador de abordo (OBC), varios convertidores dc/dc para adaptar los niveles de tensión para unidades auxiliares, etc. Las topologías que presentan los OBCs son muy diversas, sin embargo tienen en común que la mayoría se puede dividir en dos etapas: en el lado de la red, un rectificador pasivo opera como corrector de factor de potencia, y alimenta a un dc-link que es suficientemente grande como para absorber fluctuaciones de potencia. También el dc-link actúa como desacoplador de las dos etapas. En la segunda etapa hay un convertidor dc-dc que alimenta a la batería, que suele estar aislado galvánicamente por seguridad [5].

Los cargadores están diseñados para poder comunicarse con toda esta estructura de carga de los

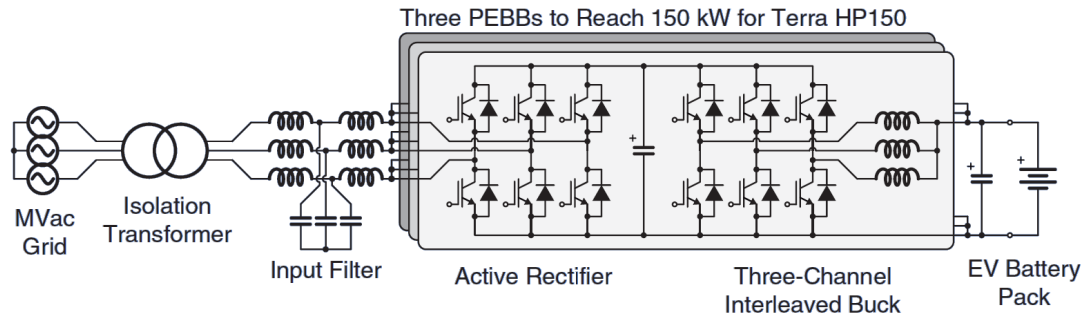


Figura 1.4 Topología del cargador ABB Terra HP 150kW de alta potencia.

coches eléctricos, a través del BMS, demandando el voltage y la corriente adecuados para cada coche. Es por eso que la flexibilidad en los cargadores es interesante. Un ejemplo de topología que puede presentar un cargador rápido externo para una estación de recarga es la presentada en la Figura 1.4, es el ABB Terra High Power Series. La particularidad de esta topología es el uso de módulos: cada cabina alcanza los 150kW, y está formada por tres módulos de 50kW. En cada uno de esos módulos se utiliza un rectificador activo y un convertidor *interleaved* buck. Este a su vez utiliza tres módulos y alimenta a la batería. Presenta aislamiento galvánico de baja frecuencia y su eficiencia alcanza el 94% a carga completa. Para alcanzar potencias de carga más altas, esta unidad de cargador se puede replicar, hasta conseguir los 600kW para autobuses o grandes vehículos [5].

La modularización permite ofrecer diferentes valores de corriente y voltaje con una misma configuración, con lo que logra, por ejemplo que vehículos con sistemas anteriores, de 400V, y vehículos más nuevos, de 800V, se puedan cargar a alta potencia con una alta eficiencia, siendo ambos compatibles con un mismo sistema de carga. También se ha utilizado el trabajar con módulos para conseguir avances en la creación de cargadores de alta potencia rápidos, conocidos como *ultra* y *extremely fast chargers*. Estos cargadores están diseñados para poder proporcionar hasta 350kW a la batería, aunque actualmente los vehículos eléctricos no alcanzan esta potencia de carga [5]. La modularidad es una solución para solventar las diferencias de estándares de carga y permitir la compatibilidad para vehículos de diferentes capacidades y voltajes [5].

Como se ha visto en el ejemplo de topología de la Figura 1.4, los convertidores dc/dc *interleaved* son usados en los cargadores de coches eléctricos precisamente para conseguir la modularidad, y todos los avances que esta presenta.

2 Convertidores Interleaved

Los convertidores dc/dc *interleaved* están formados por la conexión en paralelo de varios módulos. En la Figura 2.1 se muestra un ejemplo de este tipo de convertidores, formado por 3 módulos. La principal ventaja que ofrece esta configuración de convertidor es la modularidad. Además, proporciona la misma forma de corriente de salida que un convertidor dc/dc, pero con menor rizado y distorsión armónica, [6–8]. Esto se consigue gracias a un controlador indirecto que genera la tensión de referencia, que posteriormente se sintetiza en una etapa moduladora. Este modulador se suele implementar mediante *phase-shifted pulse width modulation* (PS-PWM), que usa un desfase temporal en las portadoras de cada módulo del convertidor para minimizar el rizado y el contenido armónico de la corriente de salida. En general, este desfase se reparte entre las portadoras de los PWM de cada módulo. Sin embargo, esta solución es óptima solamente cuando todos los módulos del convertidor tienen las mismas condiciones de funcionamiento, es decir, cuando todos los módulos operan con la misma potencia, la misma corriente por las bobinas, misma frecuencia de conmutación, etc. Una solución generalizada implicaría que los desfases de cada portadora se calculasen de acuerdo a las condiciones de operación particulares del convertidor [9, 10].




Figura 2.1 Configuración de un convertidor de potencia dc/dc *interleaved*.

2.1 Modelo del convertidor

En este trabajo, el sistema de estudio es un convertidor de potencia dc/dc buck *interleaved* bidireccional, compuesto por tres módulos en paralelo, como se ilustra en la Figura 2.1. La tensión de régimen permanente del condensador de alta tensión, v_i , está fijada por una fuente externa de voltaje, por ejemplo, se asume que es la tensión regulada por la etapa de conexión a red del cargador ABB Terra 150 kW de la Figura 1.4. El ancho de banda del controlador de la fuente es limitado, lo que implica que en régimen permanente se espera conseguir una tensión estable, v_i , y corriente, i_i . Sin embargo, el condensador C_i es sensible a dinámicas de alta frecuencia o distorsiones debidas a la operación del convertidor dc/dc *interleaved* conectado a la salida.

La tensión v_o del condensador de baja tensión C_o , y las corrientes i_1 , i_2 y i_3 , que atraviesan las bobinas L_1 , L_2 y L_3 respectivamente; son las variables a controlar. Para modelar la carga se añade una resistencia R_o .

Para el modelo discreto del sistema, se usa una discretización Forward Euler [11], y se obtienen las siguientes ecuaciones:

$$i_{k,t+1} = i_{k,t} + (v_{i,t} S_{k,t} - v_{o,t}) \frac{\tau_s}{L_k} \quad (2.1a)$$

$$v_{i,t+1} = v_{i,t} + \left(i_i - \sum_k S_{k,t} i_{k,t} \right) \frac{\tau_s}{C_i} \quad (2.1b)$$

$$v_{o,t+1} = v_{o,t} + \left(\sum_x i_{k,t} - i_{o,t} \right) \frac{\tau_s}{C_o} \quad (2.1c)$$

donde los índices t y $k \in \{1,2,3\}$ son el instante de tiempo y el número del módulo, respectivamente; τ_s es el período de muestreo y $S_k \in \{0,1\}$ representa el estado del interruptor superior del módulo k .

2.2 Operación *Interleaved*

En los convertidores *interleaved* se suele usar una estrategia de operación tal que la potencia del sistema se reparta por igual entre todos los módulos. Esto se denomina operación equilibrada. En estas condiciones, la corriente de referencia i_k^* es la misma para los todos los módulos, y se puede calcular de la siguiente manera:

$$i_k^* = \frac{i_o^*}{N}, \quad (2.2)$$

donde i_o^* representa la referencia de la corriente total de salida, y N es el número de módulos de convertidores dc/dc conectados en paralelo. Como se ha comentado anteriormente, se trabajará con tres módulos, de forma que $N = 3$.

Si el convertidor usa PS-PWM [7, 8, 12], el ángulo de desfase óptimo de cada portadora para cada módulo durante la operación equilibrada es [13–18]:

$$\alpha = \frac{360^\circ}{N} \quad (2.3)$$

Esta variación de fase entre las portadoras minimiza el contenido armónico en la corriente de salida i_o y en las corrientes de los condensadores C_i y C_o . Esto aumenta la vida útil de los condensadores, como se explica en [9]. Además, la frecuencia efectiva de la corriente de salida i_o se multiplica, alcanzando N veces la frecuencia de conmutación de cada módulo f_{sw} , lo que reduce las necesidades de filtrado a la salida.

Las Figuras 2.2 y 2.3 reflejan el comportamiento de un convertidor de potencia *interleaved* con PS-PSW: la Figura 2.2(b) muestra la distribución de corrientes en cada módulo en régimen permanente, y su valor medio \bar{i}_k . En la Figura 2.2(c) se ilustran las corrientes por los condensadores de entrada i_{ci} y de salida i_{co} . En la Figura 2.3 se aprecia el efecto en el espectro de la corriente de los dos condensadores, de alta y baja tensión; y se compara con el espectro de las corrientes de las bobinas. El contraste del contenido armónico, demuestra la mejora que supone la operación *interleaved*. Particularmente, se observa que las corrientes de los condensadores no tienen contenido a bajas frecuencias.




Figura 2.2 Régimen permanente del convertidor *interleaved* con operación equilibrada, $f_{sw} = 2$ kHz: (a) Señales de switch (b) corrientes por las bobinas (c) corrientes de los condensadores de entrada i_{ci} y de salida i_{co} .




Figura 2.3 Espectro de la corriente para la operación equilibrada a frecuencia de conmutación de 2 kHz .

2.2.1 Desfase óptimo

Un desfase de las portadoras de $\frac{360^\circ}{N}$ consigue buenos resultados cuando todos los módulos en un convertidor *interleaved* funcionan con las mismas condiciones de operación. Sin embargo, hay situaciones donde cada módulo tiene una potencia distinta, como es el caso en la generación desigual en algunos sistemas de generación fotovoltaica (PV) [19], o cuando se detecta que uno de los módulos está defectuoso. En este caso, se requiere una distribución de las corrientes diferente, o en casos extremos, la desconexión del módulo defectuoso. Son en estas situaciones en las que se dice que el convertidor funciona en modo de operación desequilibrada.

Las Figuras 2.4 y 2.5 ilustran el comportamiento del convertidor *interleaved* en el modo de operación desequilibrado cuando se le aplica el desfase de portadoras convencional, $\frac{360^\circ}{N}$. Claramente, las ventajas que suponía el uso de PS-PWM se pierden, el desfase de portadoras convencional




Figura 2.4 Régimen permanente del convertidor *interleaved* en operación equilibrada (izquierda) y desequilibrada (derecha), con un desfase de portadoras de $\frac{360^\circ}{3}$ y $f_{sw} = 2$ kHz: (a) Corrientes por las bobinas y (b) corrientes por los condensadores.




Figura 2.5 Comparación de los espectros de las corrientes de C_i en el convertidor *interleaved* con modo de operación equilibrado y desequilibrado, con un desfase de portadoras de $\frac{360^\circ}{3}$ y $f_{sw} = 2$ kHz.

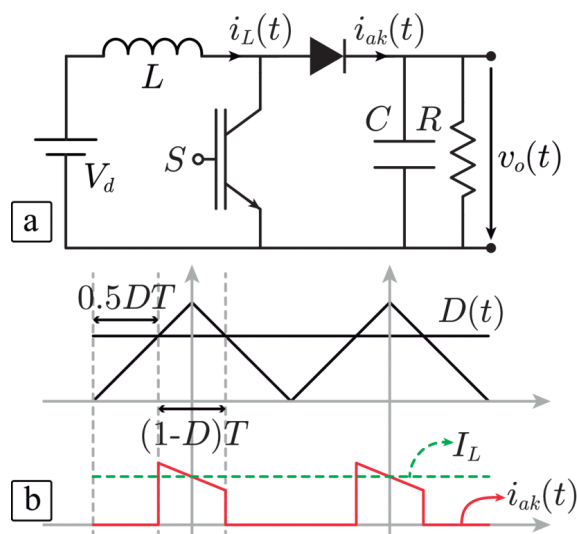


Figura 2.6 a) Topología de un convertidor dc/dc elevador, b) portadora, duty cycle y corriente por el diodo i_{ak} . También se representa el valor medio de la corriente de la bobina, I_L .

aplicado a la operación desequilibrada supone un aumento de los armónicos de baja frecuencia en la corriente del condensador C_i . Para solucionarlo, se varía el desfase de las portadoras de los módulos, para minimizar los componentes armónicos de baja frecuencia que se observan en la corriente del condensador [9].

En el artículo [9] se hace el análisis de armónico de un convertidor *interleaved* elevador. Sin embargo, es análogo al análisis de un convertidor *interleaved* reductor como el que se usa en este caso, por lo que se utiliza como referencia. La Figura 2.6 representa el módulo k del convertidor elevador. Analizando el circuito, se definen la corriente por el diodo $i_{ak}(t)$ en el período de la portadora T como:

$$i_{ak}(t) = \begin{cases} mt + I_L & \text{if } t_1 < t < t_2 \\ 0 & \text{if other case} \end{cases} \quad (2.4)$$

donde los parámetros m , t_1 y t_2 se definen como:

$$\begin{aligned} m &= \frac{V_d - v_o}{L} \\ t_1 &= -\frac{(1-D)T}{2} \\ t_2 &= \frac{(1-D)T}{2} \end{aligned} \quad (2.5)$$

Con esta información, se puede calcular el coeficiente n -ésimo del armónico de Fourier, $\|H_n\|$, de la corriente del condensador de entrada i_{ci} [9]:

$$\|H_n\| = \left[\left[\sum_{k=1}^3 \frac{a_{nk} - b_{nk} \tan(n\phi_k)}{\sqrt{1 + \tan(n\phi_k)^2}} \right]^2 + \left[\sum_{k=1}^3 \frac{b_{nk} + a_{nk} \tan(n\phi_k)}{\sqrt{1 + \tan(n\phi_k)^2}} \right]^2 \right]^{\frac{1}{2}} \quad (2.6)$$

donde los coeficientes a_{nk} y b_{nk} se definen como:

$$\begin{aligned} a_{nk} &= \frac{2}{T} \int_{t_1}^{t_2} i_{1,k}(t) \cos(n\omega t) dt = \frac{2\bar{i}_k}{n\pi} \sin(n\pi(1-D)) \\ b_{nk} &= \frac{2}{T} \int_{t_1}^{t_2} i_{1,k}(t) \sin(n\omega t) dt = \frac{mT}{n^2\pi^2} \left[\sin(n\pi(1-D)) + n\pi(1-D) \cos(n\pi(1-D)) \right] \end{aligned} \quad (2.7)$$

De acuerdo con (2.6), es posible usar ϕ_k , el desfase entre portadoras, para controlar la amplitud del armónico n -ésimo. Esto es interesante porque la amplitud de los armónicos de baja frecuencia disminuye la vida útil del condensador de entrada. Particularmente, se pretenden disminuir los dos primeros armónicos. Para ello, se define una función de coste a minimizar, que contiene información sobre la magnitud de los armónicos que se busca disminuir:

$$J = \sum_{n=1}^2 \|H_n\|. \quad (2.8)$$

Con un Algoritmo Metaheurístico, se pueden encontrar valores de los ángulos de desfase entre portadoras que minimicen el contenido de los primeros armónicos para diferentes situaciones de desequilibrio.

3 Algoritmo Metaheurístico

Los ángulos de desfase de las portadoras que minimizan la ecuación (2.8) se pueden calcular con un Algoritmo Metaheurístico (AMH), en función de los parámetros de operación del convertidor. Para el número de módulos fijo a $N = 3$, tiene 7 parámetros de entrada, y 3 de salida, como muestra la Figura 3.1.




Figura 3.1 Algoritmo Metaheurístico.

Tabla 3.1 Entradas y salidas del Algoritmo Metaheurístico.

Entradas	Salidas
Referencia de las corrientes por las bobinas, $\bar{i}_1^*, \bar{i}_2^*, \bar{i}_3^*$, [A]	Ángulos de desfase: ϕ_1, ϕ_2, ϕ_3 , [p.u.]
Rizados de corrientes, $\Delta i_1, \Delta i_2, \Delta i_3$, [A]	
Número de módulos, $N = 3$, [-]	

Las referencias de las corrientes son la salida de un bucle de control externo que controla la tensión de salida v_o del convertidor dc/dc *interleaved*, y el rizado de la corriente de cada módulo k se calcula de la siguiente manera:

$$\Delta i_k = \frac{1}{2} \frac{D(1-D)v_i}{f_{sw}} \frac{1}{L}$$

siendo $D = \frac{v_o}{v_i}$ el Duty Cycle, v_i la tensión de entrada y f_{sw} la frecuencia de conmutación del convertidor. Los ángulos de salida están en p.u., para interpretarlos se multiplican por 360° .

Los Algoritmos Metaheurísticos son algoritmos de propósito general que proporcionan soluciones suficientemente buenas a problemas de optimización en un tiempo de calculo limitado. No aseguran una solución óptima global, pero sí una solución óptima local, reduciendo el tiempo de búsqueda [20].

El Algoritmo de búsqueda de desfases óptimos que se ha usado está explicado brevemente en el Algoritmo 1.

Algoritmo 1 Búsqueda de desfases óptimos

Entradas: Referencias de las medias de las corrientes por las bobinas: \vec{i}_k^* [A], rizado de las corrientes Δi_k [A] y número de módulos, $N = 3$ [-].

Salidas: Ángulos óptimos de desfase, ϕ_k [p.u.].

1: **Inicialización de los parámetros de búsqueda:**

- Ángulos iniciales, $x \leftarrow [x_1 = 0, x_2 = 1/3, x_3 = 2/3]$
- Paso inicial, $g \leftarrow g_o$
- Limite del paso, LIM_g
- Contenido Armónico Inicial $J \leftarrow J_o$

2: **Búsqueda:** Mientras que el paso g se mantenga mayor al límite LIM_g :

1. Busca en 4 direcciones (se mueve en los dos ángulos x_2 y x_3 , aumentando o disminuyéndolos el paso g , como muestra la Figura 3.2. El ángulo x_1 se mantiene constante a 0).
2. En cada posición de búsqueda, calcula el contenido armónico de la corriente i_{ci} , J .
3. Compara el contenido armónico de las cuatro posiciones nuevas y también la posición de inicio.
4. La nueva posición será aquella en la que el contenido armónico es mínimo. Si la mejor posición es en la que estaba, reduce el paso.
5. Vuelve a iniciar la búsqueda desde la posición nueva.

3: **Solución:** cuando el paso g es menor que el límite LIM_g , se considera que la solución hallada es suficientemente buena:

- Ángulos óptimos, $x^{OPT} \leftarrow [0, x_2^{OPT}, x_3^{OPT}]$

4: **Return:** $\phi_1, \phi_2, \phi_3 \leftarrow 0, x_2^{OPT}, x_3^{OPT}$.

El Algoritmo 1 intenta minimizar el contenido de los tres primeros armónicos, penalizando por igual el contenido de los tres. Sin embargo, por la naturaleza del sistema y cómo se distribuyen sus armónicos, tiende a reducir mucho más el contenido del primer armónico.

Para ilustrar la mejora que supone la implementación del Algoritmo 1 en el modo de operación desequilibrado de un convertidor dc/dc *interleaved*, se realizan una serie de simulaciones en *Simulink*. Los efectos de usar ángulos de desfase óptimos en vez de fijos se reflejan en el contenido armónico de la corriente del condensador de entrada i_{ci} , por lo que se realizan análisis espectrales de esta corriente para el caso en el que los ángulos de desfase de las portadoras son fijos, y para el caso en el que el Algoritmo 1 calcula los ángulos óptimos. Los parámetros de diseño del modelo de simulación se reflejan en la Tabla 3.2:




Figura 3.2 Las cinco posiciones de búsqueda en cada iteración del algoritmo: ángulos actuales, aumento y disminución de x_2 y x_3 .

Tabla 3.2 Parámetros del modelo de *Simulink*.

Parámetro	Valor	Parámetro	Valor
Frecuencia de conmutación, f_{sw}	1500 Hz	Potencia del convertidor, P	650 W
Número de módulos, N	3	Bobina de cada módulo, L	15 mH
Tensión de entrada, v_i	100 V	Tensión de salida, v_o	75 V
Condensador de entrada, C_i	940 μF	Condensador de salida, C_o	470 μF

En el modo de operación desequilibrado, las corrientes medias por las bobinas $\bar{i}_1, \bar{i}_2, \bar{i}_3$ dejan de ser iguales. El nuevo reparto de las corrientes se puede realizar de muchas maneras. Para simplificar, se limitan los casos a estudiar a dos: compensación simétrica y compensación asimétrica de la corriente.

3.1 Compensación Simétrica

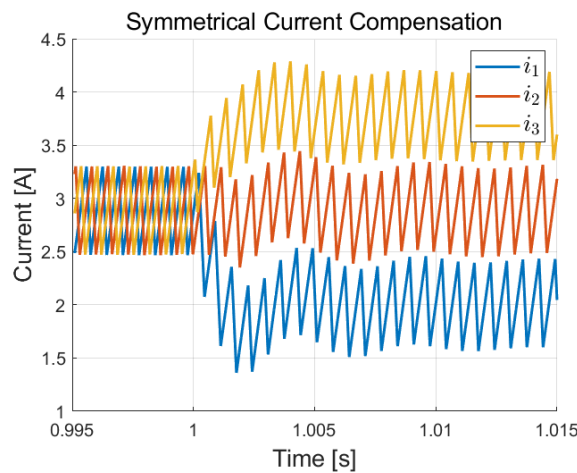


Figura 3.3 Compensación simétrica de las corrientes por las bobinas en operación desequilibrada.

La compensación es simétrica si, al disminuir la corriente de uno de los módulos, en otro aumenta

la misma cantidad, mientras que en el último se mantiene constante. Esto se ilustra en la Figura 3.3. Las corrientes varían proporcionalmente de forma que la potencia total del sistema se mantenga constante. Siendo \bar{i}_{ko} el valor medio de la corriente por la bobina en el módulo k en caso de operación equilibrada, y δ la variación de corriente en la bobina en el primer módulo; las corrientes por las bobinas en caso de compensación simétrica son las siguientes:

$$\begin{aligned}\bar{i}_1 &= \bar{i}_{1o} - \delta \\ \bar{i}_2 &= \bar{i}_{2o} \\ \bar{i}_3 &= \bar{i}_{3o} + \delta\end{aligned}\quad (3.1)$$

Las figuras 3.4 y 3.5 presentan los análisis de espectro de la corriente del condensador de entrada i_{ci} para dos casos de desequilibrio con compensación simétrica, del 10 % y del 23 % respectivamente. A la izquierda, se muestra el contenido armónico de la corriente cuando los ángulos de las portadoras son fijos, mientras que a la derecha, los ángulos de las portadoras han sido calculados por el Algoritmo Metaheurístico de manera que se el contenido de los primeros armónicos. En ambas Figuras se puede comprobar que los resultados son los esperados: el contenido del primer armónico se reduce significativamente, a costa de que el contenido del segundo crezca.

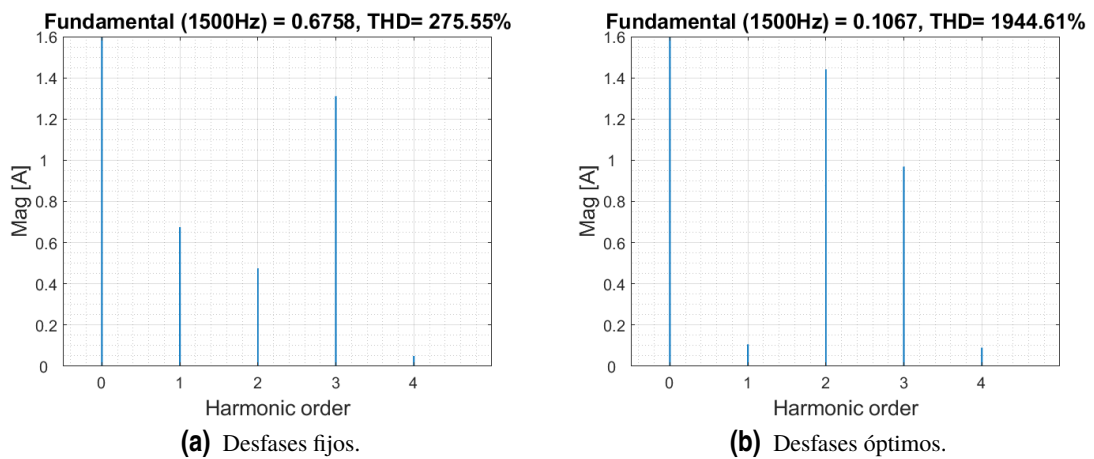


Figura 3.4 Compensación simétrica, del 10% de la corriente equilibrada.

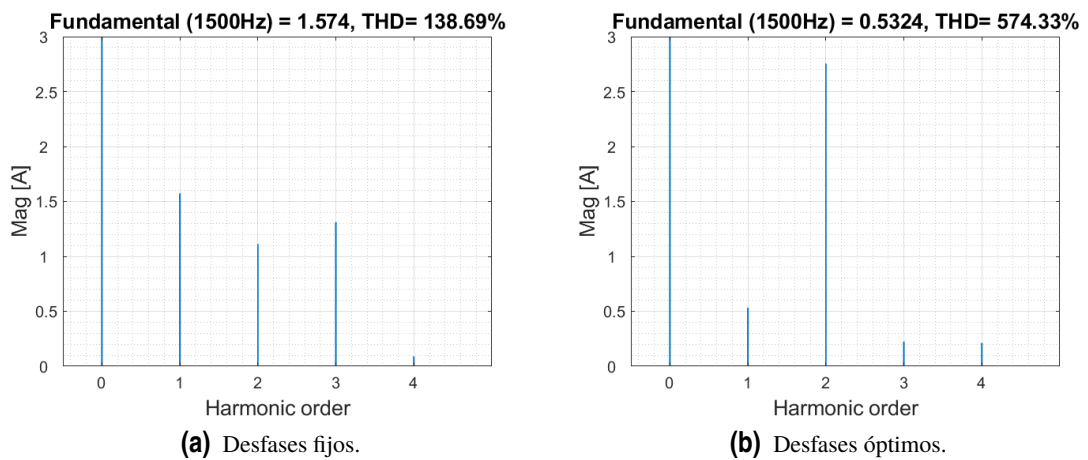


Figura 3.5 Compensación simétrica, del 23% de la corriente equilibrada.

En la Tabla 3.3 se reflejan los datos numéricos de las Figuras 3.4 y 3.5. Se puede ver cómo el contenido de los armónicos de baja frecuencia aumentan con el desequilibrio. El Algoritmo 1 es capaz de reducirlo, pero aun así son valores altos.

Tabla 3.3 Contenidos de los Armónicos, desequilibrio simétrico.

Desequilibrio	ϕ_1	ϕ_2	ϕ_3	1 ^{er} Arm [A]	2 ^{do} Arm [A]	3 ^{er} Arm [A]
10%	0	120	240	0.6758	0.4753	1.3106
	0	84.86	232.27	0.1067	1.4410	0.9693
23%	0	120	240	1.5740	1.1122	1.3116
	0	6.76	186.92	0.5324	2.7559	0.2250

3.2 Compensación Asimétrica

La compensación es asimétrica si, al disminuir la corriente de uno de los módulos, en los otros dos módulos crecen por igual, de tal forma que la potencia total del sistema se mantiene constante. Esto se ilustra en la Figura 3.6. Siendo \bar{i}_{ko} el valor medio de la corriente por la bobina en el módulo k en caso de operación equilibrada, y δ la variación de corriente en la bobina en el primer módulo; las corrientes por las bobinas en caso de compensación asimétrica son las siguientes:

$$\begin{aligned}
 \bar{i}_1 &= \bar{i}_{1o} - \delta \\
 \bar{i}_2 &= \bar{i}_{2o} + \frac{\delta}{2} \\
 \bar{i}_3 &= \bar{i}_{3o} + \frac{\delta}{2}
 \end{aligned}
 \tag{3.2}$$




Figura 3.6 Compensación asimétrica de las corrientes por las bobinas en operación desequilibrada.

Las figuras 3.7 y 3.8 presentan los análisis de espectro de la corriente del condensador de entrada i_{ci} para dos casos de desequilibrio con compensación asimétrica, del 6.6 % y del 16 % respectivamente. A la izquierda, se muestra el contenido armónico de la corriente cuando los ángulos de las portadoras son fijos, mientras que a la derecha, los ángulos de las portadoras han sido calculados por el Algoritmo Metaheurístico de manera que se minimice el primer armónico.

Al igual que en el caso de compensación simétrica, los resultados que se obtienen son los buscados: el contenido del primer armónico se reduce, aumentando el segundo.

La Tabla 3.4 refleja los resultados numéricos de las Figuras 3.7 y 3.8. Al igual que en el caso de compensación simétrica, a mayor desequilibrio, mayores son los contenidos de los armónicos primero y segundo.




Figura 3.7 Compensación asimétrica, del 6.6% de la corriente equilibrada.

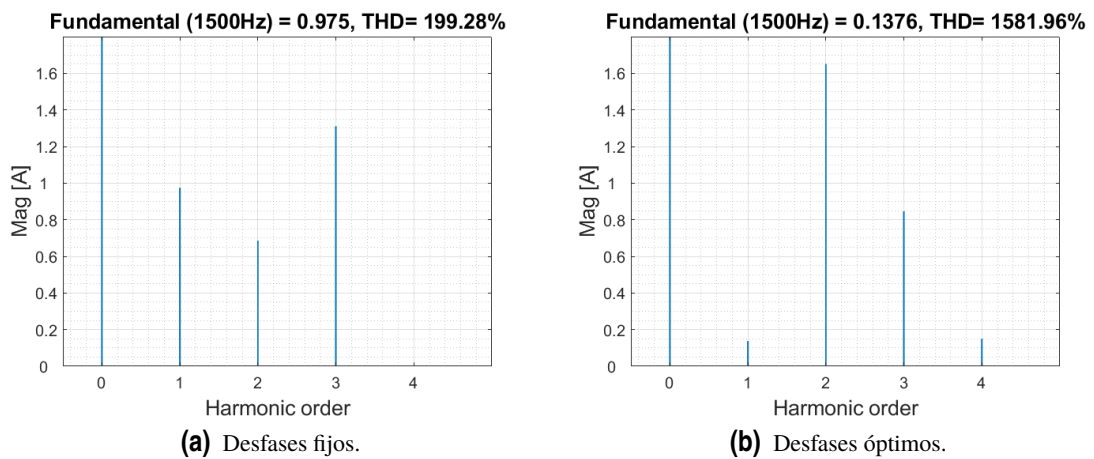


Figura 3.8 Compensación asimétrica, del 16% de la corriente equilibrada.

Tabla 3.4 Contenidos de los Armónicos, desequilibrio asimétrico.

Desequilibrio	ϕ_1	ϕ_2	ϕ_3	1 ^{er} Arm [A]	2 ^{do} Arm [A]	3 ^{er} Arm [A]
6.6%	0	120	240	0.3903	0.2731	1.3066
	0	111.99	249.14	0.0609	0.7484	1.2181
16%	0	120	240	0.9750	0.6857	1.3106
	0	103.44	260.20	0.1376	1.6513	0.8460

Los ejemplos presentados muestran los beneficios que presenta la implementación de desfases variables en las portadoras de los módulos de un convertidor dc/dc *interleaved*. El Algoritmo Metaheurístico es capaz de calcular los ángulos de desfase de las portadoras para reducir los armónicos de baja frecuencia, pero implica un peso computacional muy alto, lo que dificulta su implementación en tiempo real.

4 Red Neuronal

La red neuronal (ANN, por sus siglas en inglés, *Artificial Neural Network*) pretende sustituir al Algoritmo Metaheurístico, de forma que se consiga reducir los armónicos de la corriente del condensador de entrada i_{ci} aplicando desfases variables en las portadoras de los módulos de un convertidor dc/dc *interleaved*, pero sin la carga computacional que supone el cálculo de esos ángulos de desfase por el Algoritmo 1. La Red se entrenará con datos proporcionados por el propio Algoritmo 1, de forma que podrá predecir los ángulos de desfase. De esta forma, el Algoritmo 1 calcula una sola vez, para proporcionar los datos de entrenamiento a la Red, que tendrá los mismos parámetros de entrada y las mismas salidas que el Algoritmo, como refleja la Figura 4.1.




Figura 4.1 Red neuronal.

4.1 Condiciones de Operación

La red neuronal se aplicará para predecir los ángulos de desfase óptimos de las portadoras de los módulos de un convertidor dc/dc *interleaved* cuando opere de manera desequilibrada. El reparto de corrientes desequilibradas se puede dar de diversas maneras, siempre que la suma de las corrientes por los módulos sea la misma, de forma que la potencia total del sistema se mantenga constante. Para simplificar y concretizar, sólo se contemplarán los casos comentados en el capítulo anterior: la compensación simétrica y la compensación asimétrica de corrientes. Estos dos casos se ilustran en la Figura 4.2

También, para reducir el campo de posibilidades, se propone un convertidor concreto, de forma que se define el número de módulos, la potencia total, las tensiones de entrada y salida, y el resto de parámetros. Así, lo único que varía es el valor de las corrientes por las bobinas. Los valores elegidos para el convertidor se muestran en la Tabla 4.1

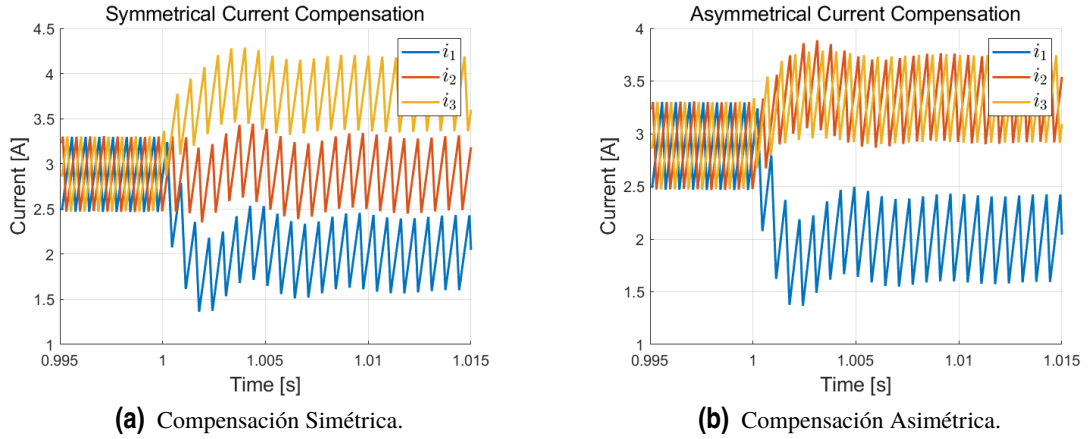


Figura 4.2 Casos de compensación contemplados.

Tabla 4.1 Parámetros del convertidor a estudiar.

Parámetro	Valor	Parámetro	Valor
Frecuencia de conmutación, f_{sw}	1500 Hz	Potencia del convertidor, P	650 W
Número de módulos, N	3	Bobina de cada módulo, L	15 mH
Tensión de entrada, v_i	100 V	Tensión de salida, v_o	75 V
Condensador de entrada, C_i	940 μF	Condensador de salida, C_o	470 μF

Algoritmo 2 Generación de datos y entrenamiento de la Red

Entradas: Referencias de las medias de las corrientes por las bobinas: \bar{i}_k [A], rizado de las corrientes Δi_k [A] y número de módulos, N [-].

Salidas: ANN entrenada.

- 1: **Set de datos:** el AMH proporciona los sets de datos, con las mismas entradas y salidas que tendrá la Red Neuronal. El AMH recibe sets de corrientes desequilibradas (con compensación simétrica y asimétrica), y calcula los ángulos óptimos de desfase para las portadoras.
- 2: **División de datos:** Los datos se dividen en dos grupos: los datos de entrenamiento y los datos para la comprobación, compuestos por el 80% y el 20% de los datos respectivamente.
- 3: **Entrenamiento:** ajustar la Red Neuronal con los datos de entrenamiento, minimizando error medio absoluto (MAE) o el error cuadrático medio (MSE) de las predicciones.

$$\text{MAE} = \frac{1}{|\mathcal{D}|} \sum_{i=1}^{|\mathcal{D}|} |\phi_i - \hat{\phi}_i| \text{ o } \text{MSE} = \frac{1}{|\mathcal{D}|} \sum_{i=1}^{|\mathcal{D}|} |\phi_i - \hat{\phi}_i|^2$$

- 4: **Return:** ANN entrenada.

4.2 Entrenamiento de modelos

Para el entrenamiento de los diferentes modelos se han utilizado sets de datos proporcionados por el AMH. Para cada uno se ha seguido el Algoritmo 2.

Para esta aplicación, se propone una Red Neuronal Secuencial, que es un modelo de *deep learning* muy simple. Se crean una serie de capas de neuronas secuenciales en las que se realizan transformaciones no lineales, como se ilustra en la Figura 4.3a: siempre existen una capa de entrada y otra de salida, y entre ellas, varias capas ocultas [21]. Este tipo de modelo funciona muy bien para problemas de regresión, en los que se busca predecir un valor numérico dada una entrada [21].

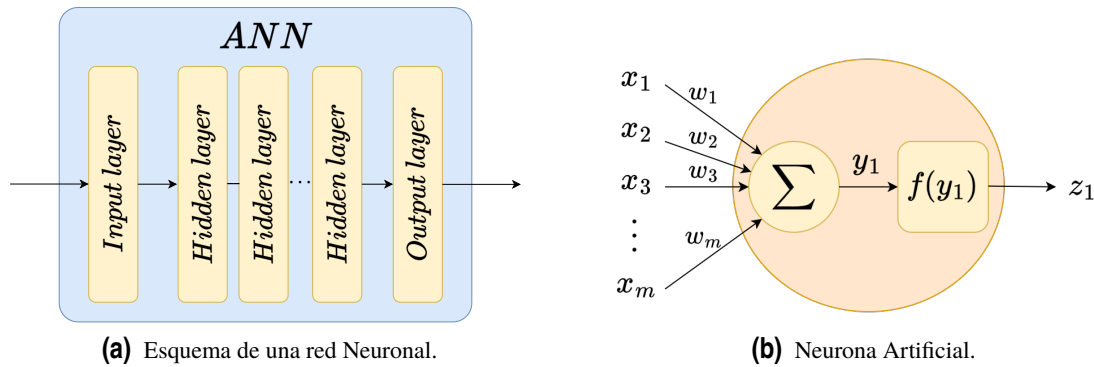


Figura 4.3 Estructura de la red neuronal.

En la Figura 4.3b se explica el funcionamiento de una neurona de la red. Cada capa de la red, formada por un número definido de neuronas, tiene unas entradas y unas salidas. Las entradas de las capas son las salidas de la capas anterior, excepto la capa de entrada que las recibe como dato.

En cada neurona de cada capa, se realiza una suma ponderada por pesos de todas las entradas que recibe esa capa. Entrenar una red supone aprender qué pesos son los adecuados para cada entrada de cada neurona. El resultado de esa suma entra a una función de activación no lineal, proporcionando la salida de esa neurona. Es esta función no lineal la que permite que la salida no sea meramente una función lineal de las entradas [21]. Cada capa se puede expresar como operaciones con matrices:

$$Y_{n \times 1} = W_{n \times m} X_{m \times 1} + A_{n \times 1}$$

$$Z_{n \times 1} = f(Y_{n \times 1}) \quad (4.1)$$

donde n es el número de neuronas de la siguiente capa, y m es el número de neuronas de la capa actual, $X_{m \times 1}$ es el vector de entradas de la capa, $W_{n \times m}$ es la matriz de pesos que multiplican, $A_{n \times 1}$ el vector de bias, $Y_{n \times 1}$ el vector resultado de la suma ponderada, $f(Y_{n \times 1})$ es la función de activación y $Z_{n \times 1}$ el vector de salidas de la capa.

4.3 Modelos

A continuación se presentan seis modelos de red neuronal, desde el primero intento hasta conseguir un modelo cuyas predicciones fuesen lo suficientemente precisas como para sustituir al Algoritmo 1. Para mejorar el comportamiento de los modelos, se ha probado a variar diferentes parámetros de diseño: número de capas, número de iteraciones de entrenamiento (*epochs*) [21], funciones de activación, etc.

4.3.1 Primer modelo

Al crear, entrenar y ajustar un modelo de red neuronal se debe especificar varios parámetros, como el tipo de red, el número de capas, etc. La función de pérdida es la función que se pretende minimizar o maximizar con un Optimizador elegido. En este primer modelo se ajustará la red minimizando el Error Medio Absoluto, usando el Gradient Descent Optimizer, que minimiza la derivada de la función de pérdida [21].

- Datos: 100 sets.
- Modelo: Secuencial.
- Capas:
 - 1 capa de entrada, 7 neuronas.
 - 1 capa de salida, 3 neuronas.
- Función de pérdida: Error Medio Absoluto (MAE).
- Optimizador: Gradient Descent Optimizer.
- *Epochs*: 100.

Tabla 4.2 Primer Modelo, resultados.

Resultado	ϕ_1	ϕ_2	ϕ_3
MAE	15.17	50.50	21.70
MSE	387.47	487.41	541.94

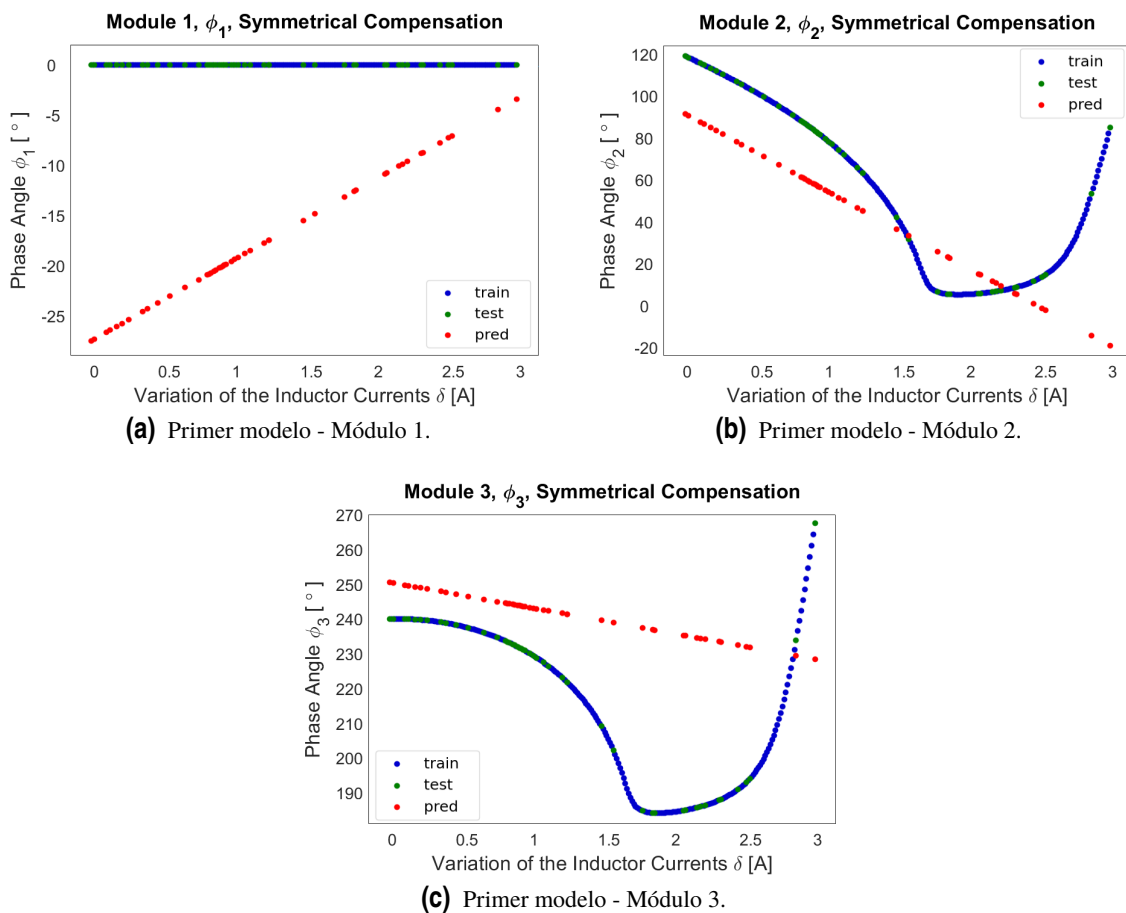


Figura 4.4 Primer modelo, compensación simétrica de las corrientes de la bobina.

Los resultados de este modelo se reflejan en la Tabla 4.2, como era de esperar, son muy malos. Para entrenar se ha usado el MAE, pero también se ha calculado el MSE para mostrar la precisión

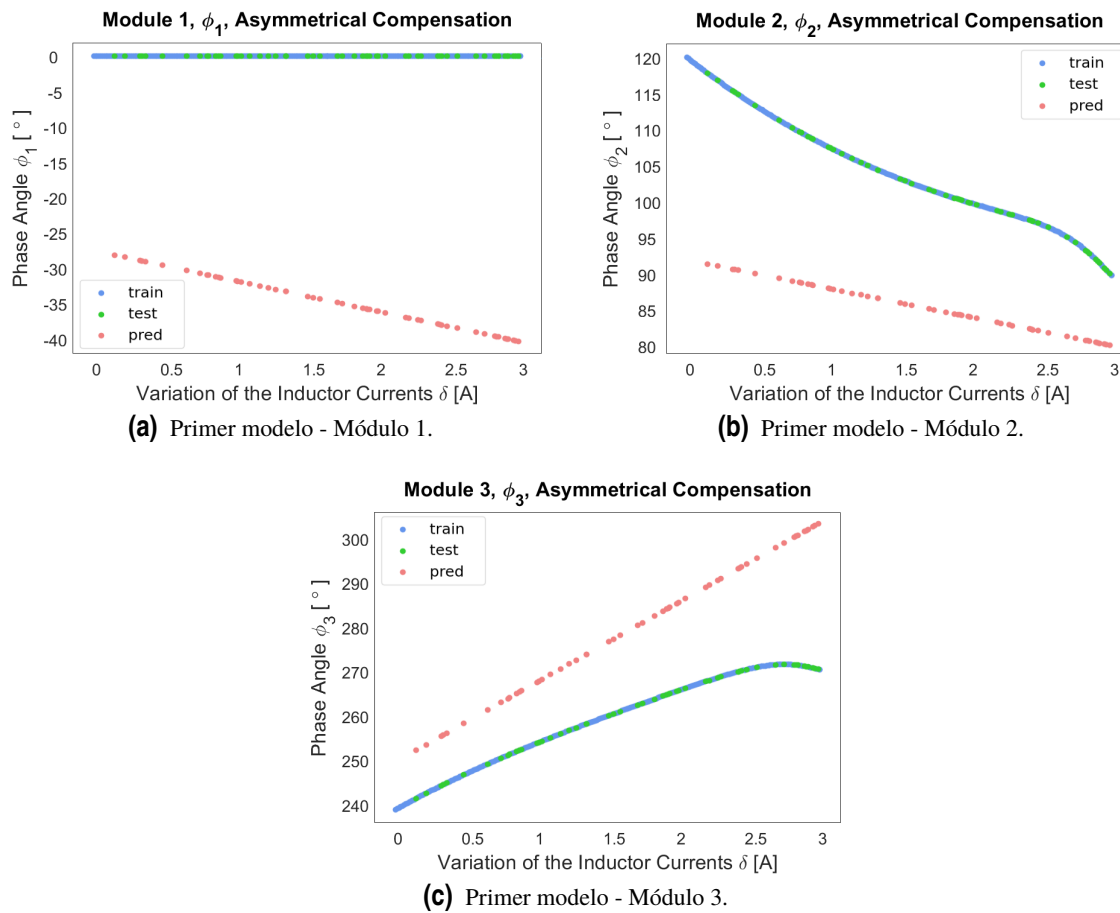


Figura 4.5 Primer modelo, compensación asimétrica de las corrientes de la bobina.

del modelo, y para comparar con modelos posteriores.

Las Figuras 4.4 y 4.5 también reflejan los resultados de este modelo, de forma que se ve la precisión de la predicción para cada dato. La Figura 4.4 muestra los ángulos para los tres módulos del convertidor, en el modo de operación desequilibrada con compensación simétrica. La Figura 4.5 muestra los ángulos para los tres módulos del convertidor, en el modo de operación desequilibrada con compensación asimétrica. Los datos se presentan de la siguiente forma: en azul aparecen aquellos datos que se han usado para entrenar a la red, suponen el 80 % del total de los datos. En verde se presentan los datos que se han reservado para comprobar, son el 20 % del total. Estos datos se introducen a la red, que predice unas salidas de acuerdo al entrenamiento realizado. Estas predicciones se muestran en las gráficas en rojo.

En las figura 4.4 y 4.5 se puede comprobar que el principal problema en este modelo es que busca con sus predicciones acercarse a una recta oblicua en cada módulo, mientras que los datos del algoritmo forman curvas en el segundo y tercer módulo, y una recta horizontal en el primer módulo. Por eso hay predicciones que aciertan más que otras. Aun así, está muy lejos de ser un modelo aceptable.

Pruebas: *epochs*

Modificando el número de iteraciones de aprendizaje (*epochs*) del modelo, se consigue disminuir el MAE, pero no la disposición lineal de las predicciones. Se hacen pruebas con 100, 200 y 500 *epochs*.

La Figura 4.6 muestra como varía el parámetro Loss frente al número de *epochs*. Este parámetro hace referencia a la función de pérdida durante el entrenamiento, en el caso de este primer modelo indica el valor del MAE minimizado durante el entrenamiento. Es un buen indicador del comportamiento de la red en el entrenamiento, sin embargo no da una visión completa pues no refleja su comportamiento al predecir. La figura 4.7 muestra como varían el MAE y MSE con el número de *epochs*, siendo estos calculados con los datos de comprobación. Estos parámetros son útiles para comprender el comportamiento de la red al predecir, completan el análisis del modelo.

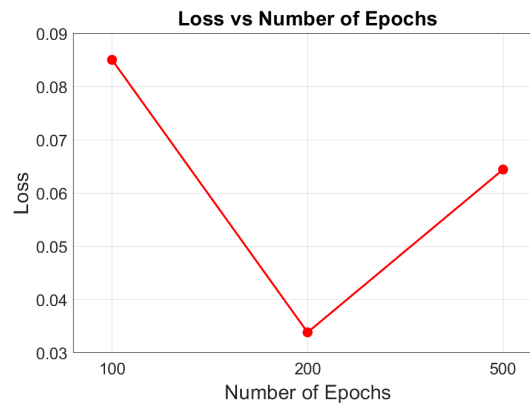
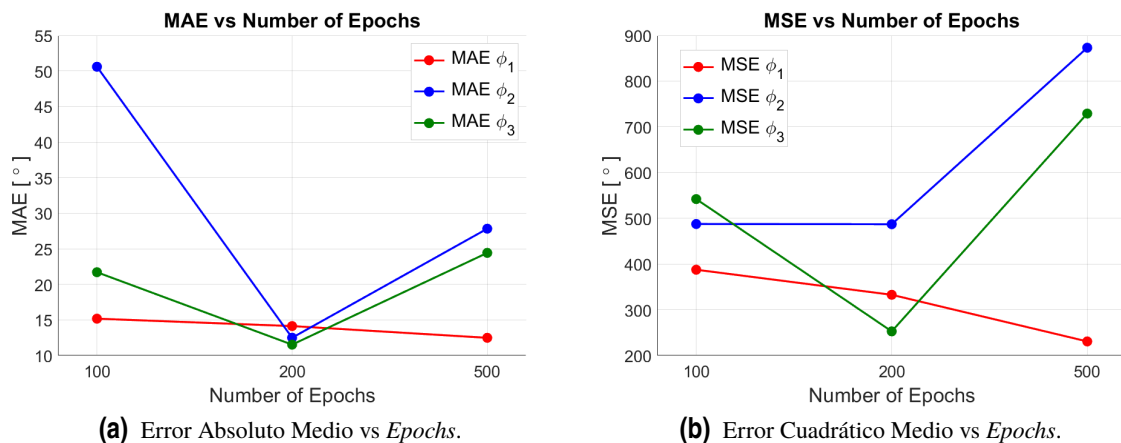


Figura 4.6 Primer modelo, comparación Loss vs *Epochs*.



(a) Error Absoluto Medio vs *Epochs*.

(b) Error Cuadrático Medio vs *Epochs*.

Figura 4.7 Primer modelo, comparación MAE y MSE vs *Epochs*.

En general, se espera que aumentar el número de *epochs* mejore el comportamiento del modelo. Sin embargo, se puede observar que, los resultados del modelo entrenado con 200 *epochs* son mejores que los de 100 y los de 500. Esto sucede por un fenómeno denominado *overfitting*, en el que el modelo memoriza el set de entrenamiento, aprendiendo propiedades muy específicas que no le permiten generalizar, como se ilustra en la Figura 4.8. Esto hace que aunque el error de entrenamiento sea bajo, el error de comprobación sea alto, al no ser capaz de predecir los datos de comprobación [21].




Figura 4.8 Fenómeno de *overfitting*. A la izquierda, un modelo ajustado a los datos correctamente, siguiendo a los datos. A la derecha, un modelo que presenta *overfitting* [21].

4.3.2 Segundo modelo

- Datos: 500 sets.
- Modelo: Secuencial.
- Capas:
 - 1 capa de entrada, 7 neuronas.
 - 2 capas ocultas, 100 neuronas, función de activación tanh e inicializador de kernel uniforme.
 - 1 capa de salida, 3 neuronas, función de activación lineal e inicializador de kernel uniforme.
- Función de pérdida: Error Cuadrático Medio (MSE).
- Optimizador: Adam.
- *Epochs*: 200.

En este segundo modelo se hacen cambios para mejorar el anterior, principalmente se busca que las predicciones se adapten a la curva que siguen los datos.

Tabla 4.3 Segundo Modelo, resultados.

MAE	ϕ_1	ϕ_2	ϕ_3
Primer Modelo	15.17	50.58	21.70
Segundo Modelo	0.12	2.89	2.46
MSE	ϕ_1	ϕ_2	ϕ_3
Primer Modelo	387.47	4887.41	541.94
Segundo Modelo	0.02	13.77	12.89

En la Tabla 4.3 se reflejan los resultados de este segundo modelo, y también del primer modelo: se puede comprobar que los cambios realizados implican una gran mejora.

Esta mejora también se refleja en las Figuras 4.9 y 4.10: en este modelo, las predicciones siguen curvas en vez de rectas, y son parecidas a las de los datos, aunque todavía la precisión no es muy buena.

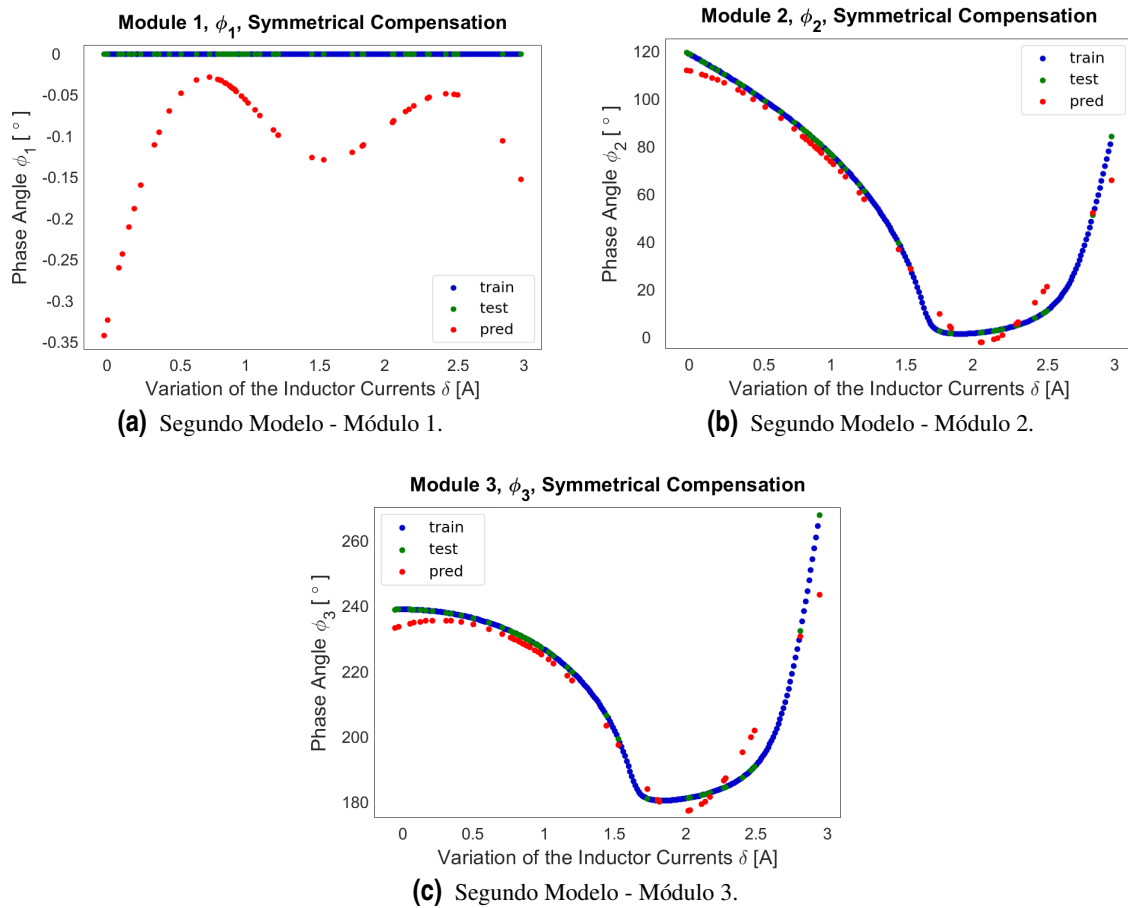


Figura 4.9 Segundo modelo, compensación simétrica de las corrientes de la bobina.

4.3.3 Tercer modelo

- Datos: 500 sets.
- Modelo: Secuencial.
- Capas:
 - 1 capa de entrada, 3 neuronas.
 - 2 capas ocultas, 50 neuronas, función de activación *tanh* e regularizadores de kernel ($L_1=1e-5$, $L_2=1e-6$).
 - 1 capa de salida, 2 neuronas.
- Función de pérdida: Error Cuadrático Medio (MSE).
- Optimizador: Adam.
- Epochs: 1000.

La modificación principal de este modelo es la reducción de entradas y salidas: en este caso particular en el que algunos parámetros son fijos (el número de módulos, la potencia, etc), es posible reducir el número de entradas a 3, y el número de salidas a 2; tanto en el AMH como en la Red Neuronal. Esto se refleja en la Figura 4.11. De las 7 entradas que se contemplaban antes, N tiene un valor fijo, porque se trabaja con 3 módulos; y los rizados de corriente también son constantes, al

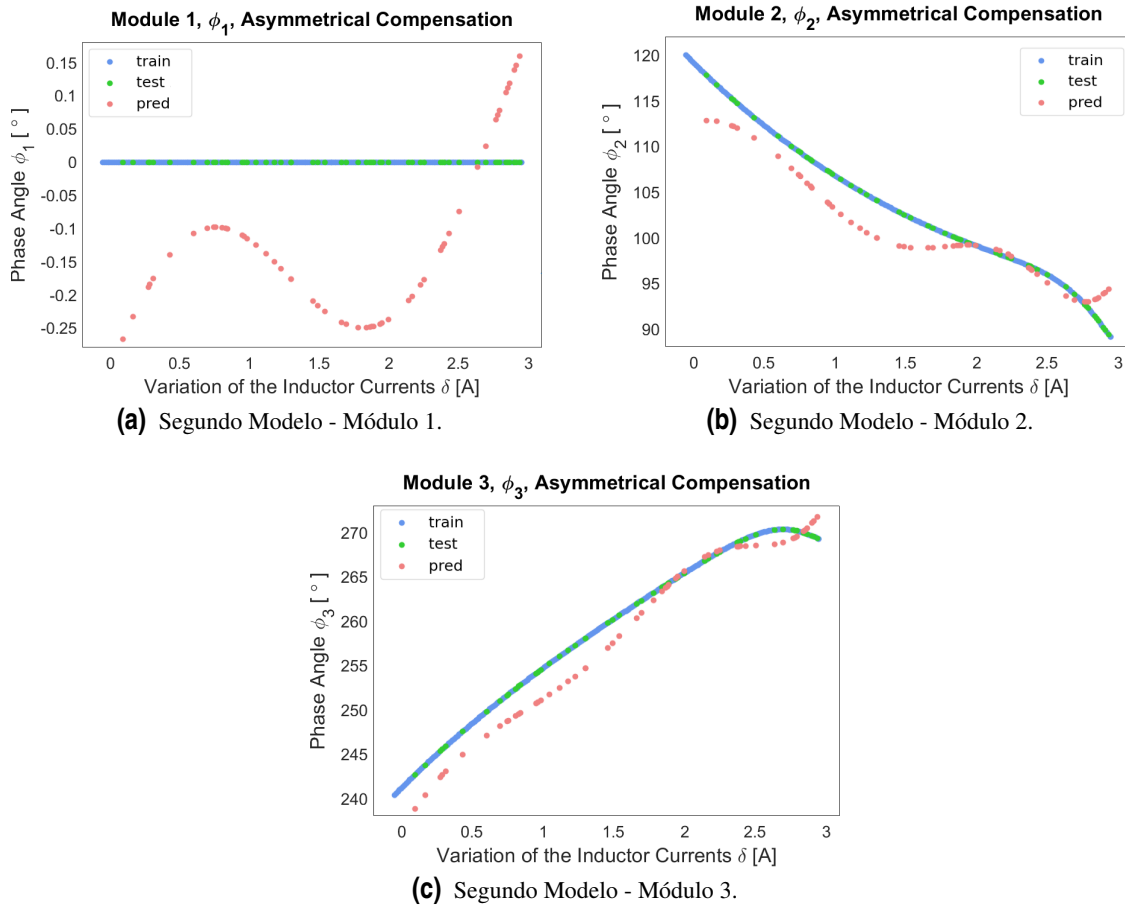


Figura 4.10 Segundo modelo, compensación asimétrica de las corrientes de la bobina.




Figura 4.11 Red neuronal, entradas y salidas simplificadas.

tener definidos los parámetros de los que dependen. A partir de ahora, las únicas entradas serán las tres referencias de las corrientes por las bobinas en cada módulo, \bar{i}_1^* , \bar{i}_2^* , \bar{i}_3^* . Las salidas serán los ángulos de desfase del segundo y tercer módulos, ϕ_2 y ϕ_3 . El ángulo de desfase del primero módulo ϕ_1 es el que se toma como referencia, por lo que su valor es constante, 0° , y no es necesario su predicción.

Otras modificaciones que mejorarán el rendimiento de la red son la definición de regularizadores de kernel en las capas ocultas, y un aumento considerable en las *epochs*.

Los resultados de este modelo se reflejan en la Tabla 4.4, donde se puede apreciar una pequeña mejora.

En las Figuras 4.12 y 4.13 se puede apreciar también una ligera mejora, pero las predicciones

Tabla 4.4 Tercer Modelo, resultados.

MAE	ϕ_2	ϕ_3
Segundo Modelo	2.89	2.46
Tercer Modelo	2.03	1.76
MSE	ϕ_2	ϕ_3
Segundo Modelo	13.77	12.89
Tercer Modelo	9.50	9.66

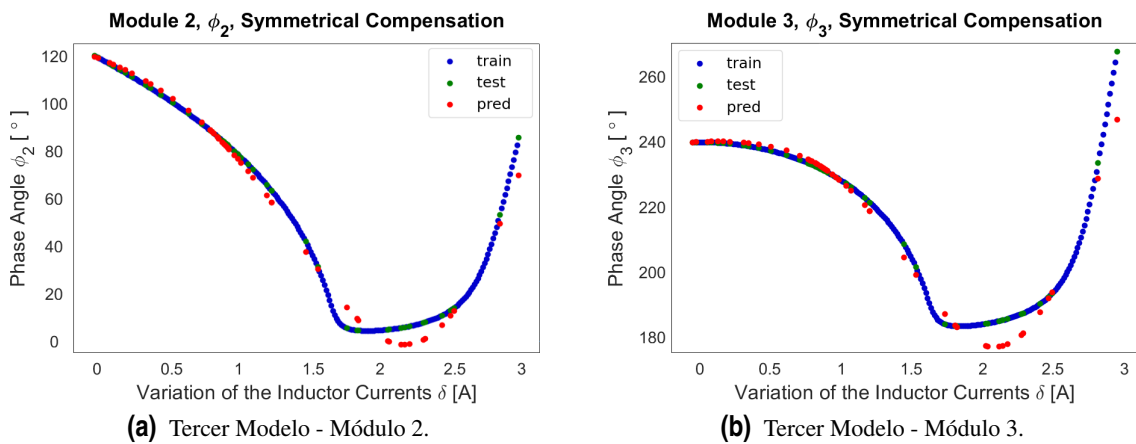


Figura 4.12 Tercer modelo, compensación simétrica de las corrientes de la bobina.

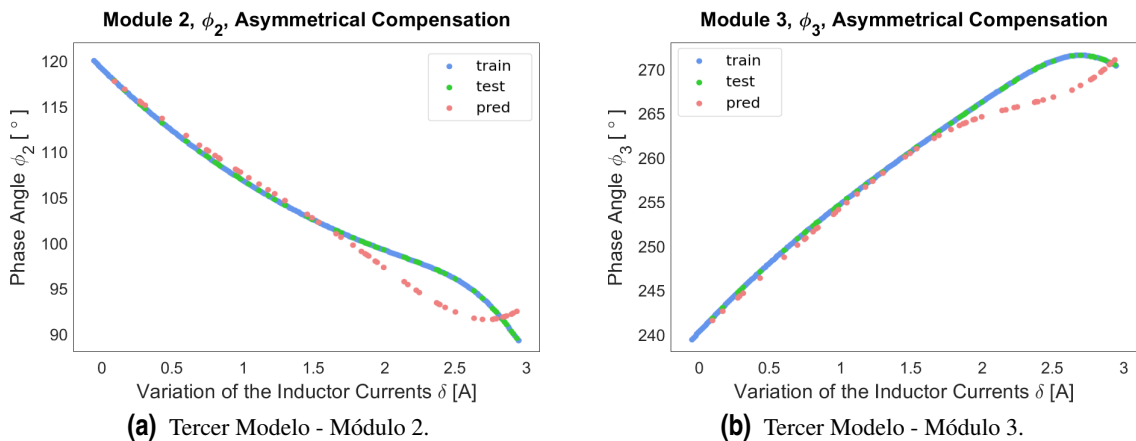


Figura 4.13 Tercer modelo, compensación asimétrica de las corrientes de la bobina.

aun no siguen la misma curva que los datos, teniendo peor precisión en algunas zonas concretas, como en cambios de curvatura, o en los valores más altos de desequilibrio; en las gráficas, en los valores más altos de δ .

Pruebas: número de neuronas y capas

Partiendo del tercer modelo, se realizan pruebas variando el número de capas y el número de neuronas en cada capa (manteniendo el número de neuronas de las capas del mismo modelo iguales):

se probará con 1, 2 o 3 capas de 20, 50 o 100 neuronas cada una. Aunque aumentar estos parámetros puede implicar mejorar la capacidad de predicción del modelo, también aumenta el cálculo necesario, que no interesa que sea demasiado alto.






Figura 4.14 Tercer modelo, comparación Loss vs Número de capas y neuronas.




(a) MAE - Módulo 2.




(b) MAE - Módulo 3.

Figura 4.15 Tercer modelo, comparación Error Absoluto Medio vs Número de capas y neuronas.



(a) MSE - Módulo 2.



(b) MSE - Módulo 3.

Figura 4.16 Tercer modelo, comparación Error Cuadrático Medio vs Número de capas y neuronas.

Los resultados obtenidos se reflejan en las Figuras 4.14, 4.15 y 4.16. La Figura 4.14 representa cómo varía la pérdida del modelo en las distintas pruebas. Las Figuras 4.15 y 4.16 representan la variación de MAE y MSE respectivamente de cada ángulo. Se puede comprobar que el modelo que mejor comportamiento expone es el que tiene 2 capas de 20 neuronas. Este modelo además tiene un costo computacional mucho menor que otros modelos propuestos en esta prueba, al tener menos neuronas, lo que facilitaría en un futuro implementar la Red Neuronal en el hardware de control en tiempo real.

4.3.4 Cuarto modelo

- Datos: 500 sets, estandarizados.
- Modelo: Secuencial.
- Capas:
 - 1 capa de entrada, 3 neuronas.
 - 2 capas ocultas, 20 neuronas, función de activación tanh e regularizadores de kernel ($L_1=1e-5$, $L_2=1e-6$).
 - 1 capa de salida, 2 neuronas.
- Función de pérdida: Error Cuadrático Medio (MSE).
- Optimizador: Adam.
- *Epochs*: 1000.

Partiendo de las mejoras obtenidas hasta ahora, en este modelo se experimenta con los datos que recibe la red. Hasta ahora, los datos se pasaban a la red tal cual los recibía el AMH: las corrientes de entrada medidas en Amperios y los ángulos de desfase de salida medidos en tanto por uno. Los rangos de valores de las entradas y de las salidas eran por lo tanto bastante dispares. Las redes neuronales se benefician de que estos rangos sean parecidos, concretamente que se mantengan en el intervalo (0,1), por eso se estandarizan los datos de entrada y de salida:

$$\bar{x} = \frac{x - \mu}{\sigma}$$

con la media y la desviación típica definidas como

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad \text{y} \quad \sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N |x_i - \mu|^2} \quad (4.2)$$

La estandarización se realiza por separado para los datos de entrada y para los de salida, es decir, para los datos de entrada, μ es la media de los datos de entrenamiento de entrada, mientras que para los datos de salida será la media de los datos de entrenamiento de salida. Es importante recalcar que la media y la desviación típica de los datos de entrenamiento es la que se usará también para estandarizar durante el funcionamiento de la red, por lo que es un parámetro que hay que conservar.

Usar datos estandarizados para el entrenamiento de la red implica que al usarse, los datos de entrada se estandarizan antes de entrar en la red, y que las salidas se desestandarizan antes de ser interpretadas como ángulos. Esto se ilustra en la Figura 4.17

Los resultados de este modelo se reflejan en la Tabla 4.5. Sin hacer cambios en el modelo, simplemente en la forma de meter los datos, se obtiene mucho mejor resultado.

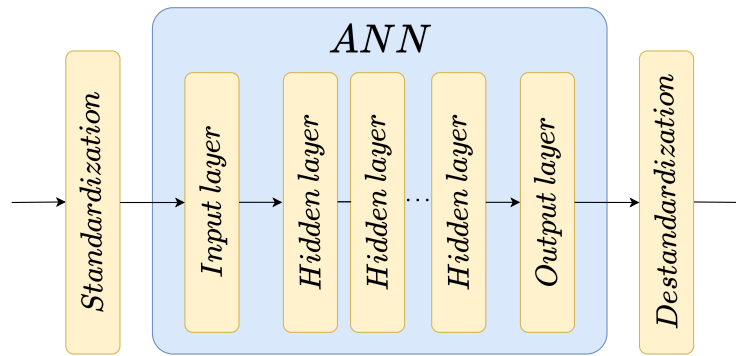


Figura 4.17 Esquema de la red neuronal con datos estandarizados.

Tabla 4.5 Cuarto Modelo, resultados.

MAE	ϕ_2	ϕ_3
Tercer Modelo	2.03	1.76
Cuarto Modelo	0.35	0.36
MSE	ϕ_2	ϕ_3
Tercer Modelo	9.50	9.66
Cuarto Modelo	0.29	0.23

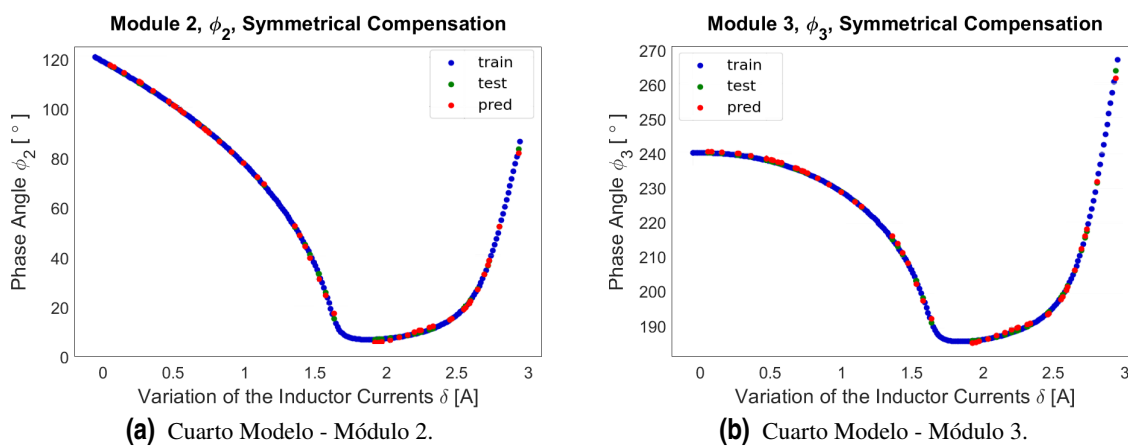


Figura 4.18 Cuarto modelo, compensación simétrica de las corrientes de la bobina.

Observando las Figuras 4.18 y 4.19 se aprecia como ahora los datos se adaptan muy bien a las curvas de los datos, aunque siguen teniendo más problemas en las zonas mencionadas anteriormente.

A partir de este modelo, se realizan varias pruebas para obtener la combinación óptima de los parámetros de la red que proporcionen las predicciones más precisas.

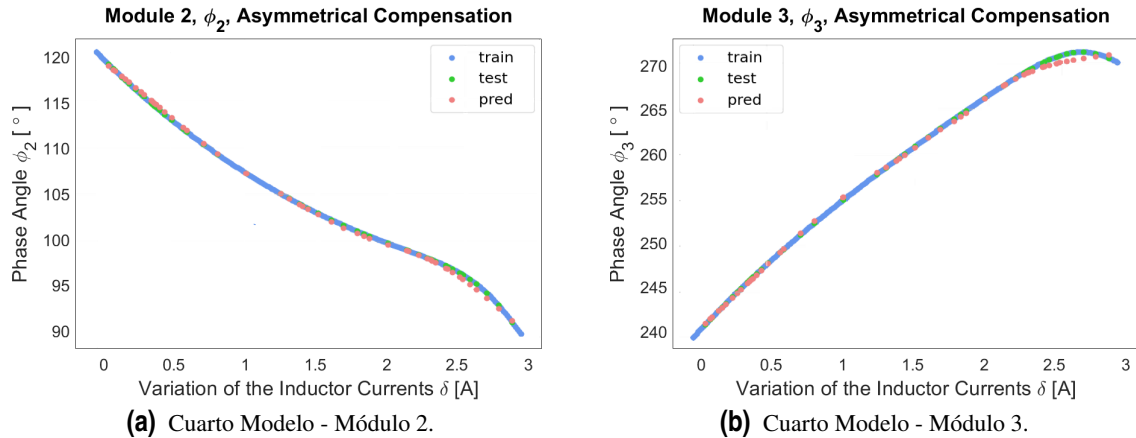


Figura 4.19 Cuarto modelo, compensación asimétrica de las corrientes de la bobina.

Pruebas: función de activación

La función de activación es una función no lineal que se aplica en cada neurona al sumatorio ponderado de las entradas, como se ha comentado anteriormente y se explica en la Figura 4.3b. Hasta ahora se han utilizado dos funciones de activación, Lineal o Tangente Hiperbólica; y se ha comprobado que la segunda tiene mejores resultados. Sin embargo hay muchas más, que dependiendo del tipo de red, pueden mejorar las predicciones de la red. Se prueban tres de ellas que funcionan bien con los modelos secuenciales, comparando sus resultados con los obtenidos con la Tangente Hiperbólica, (tanh):

- **Softplus:**

$$f(y) = \log(e^y + 1)$$

- **Gelu:** Unidad Exponencial Lineal Gaussiana

$$f(y) = y \cdot P(y)$$

- **Elu:** Unidad Exponencial Lineal

$$f(y) = \begin{cases} y & \text{si } y > 0 \\ \alpha \cdot \log(e^y + 1) & \text{si } y < 0 \end{cases}$$

Como se ve en las Figuras 4.20 y 4.21, la función de activación que peores resultados da en este caso es la Softplus. Las otras tres funciones de activación dan resultados muy parecidos, aunque la Tangente Hiperbólica es ligeramente mejor. Esto confirma que es la adecuada para esta red. El mayor inconveniente de esta función de activación es que su peso computacional es alto. Se podría elegir una de las otras funciones con menos calculo, o bien emplear una aproximación de la Tangente Hiperbólica. Esta solución es la elegida, y se implementará más adelante.


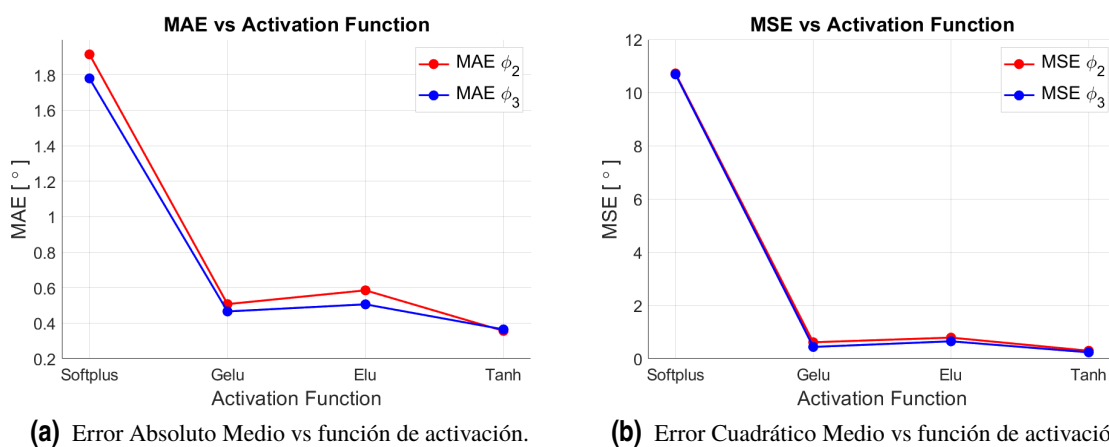


Figura 4.20 Cuarto modelo, comparación Loss vs la función de activación.



(a) Error Absoluto Medio vs función de activación.

(b) Error Cuadrático Medio vs función de activación.

Figura 4.21 Cuarto modelo, comparación MAE y MSE vs la función de activación.

Pruebas: *epochs*

Como se vió en el Primer Modelo, aumentando las *epochs* se puede conseguir mejor resultado hasta cierto punto, ya que por *overfitting* la red puede empeorar la capacidad de predecir resultados fuera del conjunto de datos con los que se ha entrenado. Se hacen pruebas con 1000, 2000, 5000 y 10000 *epochs*.

Los resultados se reflejan en las Figuras 4.22 y 4.23. Esta vez no se detecta *overfitting*, al aumentar las *epochs* los resultados siempre mejoran. Sin embargo, esa mejora a partir de los 2000 es pequeña comparándola con el aumento de cálculo que suponen tantos *epochs*. Es por ello que se puede seleccionar 2000 *epochs* como la mejor opción.

Pruebas: número de datos

También se prueba variar el número de datos. En los primeros modelos se vio que hay una mejora al aumentar los sets de datos que se le pasan a la ANN, pero al igual que con los *epochs*, si se aprende demasiado bien los datos no es capaz de predecir datos nuevos. Se entrena el cuarto modelo con sets de 100, 200, 500 y 1000 datos.

Los resultados se reflejan en las Figuras 4.24 y 4.25. Como se esperaba, la red mejora al aumentar los datos hasta cierto punto, pues para 1000 datos se los aprende y pierde capacidad de predicción. Esto es un claro ejemplo de *overfitting*: se observa que en la Figura 4.24, el Loss de la red con 1000 datos menor que el resto, porque al entrenar se aprende los datos de entrenamiento muy bien. Sin embargo, en la Figura 4.25 se observa como al intentar predecir con los datos de comprobación,


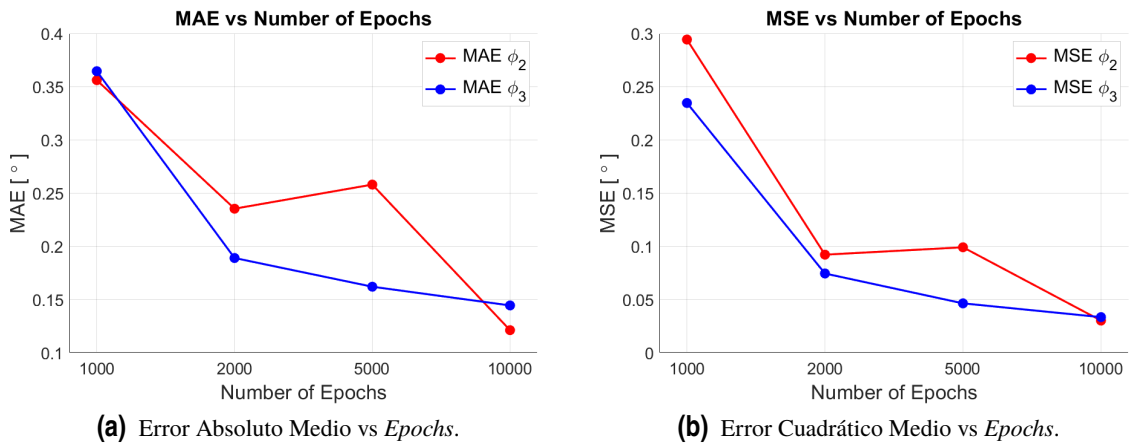


Figura 4.22 Cuarto modelo, comparación Loss vs Epochs.



(a) Error Absoluto Medio vs Epochs.

(b) Error Cuadrático Medio vs Epochs.

Figura 4.23 Cuarto modelo, comparación MAE y MSE vs Epochs.



Figura 4.24 Cuarto modelo, comparación Loss vs Número de Datos.

que son datos que no ha visto al entrenar, no tiene tan buenos resultados como se esperaría con el Loss tan bajo.

Por lo tanto, los mejores resultados se obtienen con 500 sets de datos, siendo el 80% de los datos para entrenamiento (400 datos) y el 20% restante, para comprobar (100 datos).

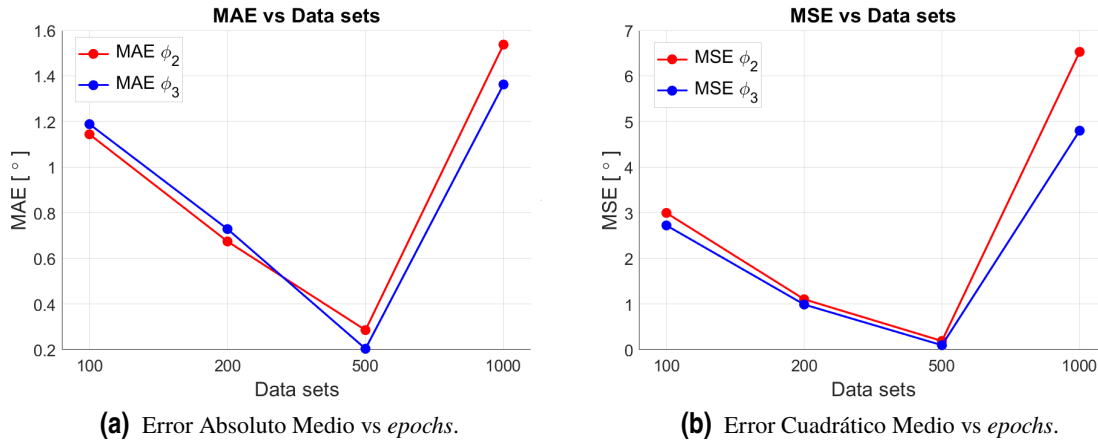


Figura 4.25 Cuarto modelo, comparación MAE y MSE vs Número de Datos.

4.3.5 Quinto Modelo

- Datos: 500 sets, estandarizados.
- Modelo: Secuencial.
- Capas:
 - 1 capa de entrada, 3 neuronas.
 - 2 capas ocultas, 20 neuronas, función de activación tanh y regularizadores de kernel ($L_1=1e-5$, $L_2=1e-6$).
 - 1 capa de salida, 2 neuronas.
- Función de pérdida: Error Cuadrático Medio (MSE).
- Optimizador: Adam.
- Epochs: 2000.

Este modelo recoge todas las mejoras resultado de las pruebas realizadas, es el que mejores predicciones obtiene.

Tabla 4.6 Quinto Modelo, resultados.

MAE	ϕ_2	ϕ_3
Cuarto Modelo	0.35	0.36
Quinto Modelo	0.15	0.12
MSE	ϕ_2	ϕ_3
Cuarto Modelo	0.29	0.23
Quinto Modelo	0.05	0.02

Sus resultados se reflejan en la Tabla 4.6. También en las Figuras 4.26 y 4.27, se observa que las predicciones son muy precisas en todo el rango de δ , la variación de las corrientes; incluso en las zonas que antes eran más problemáticas, como los cambios de curvatura.

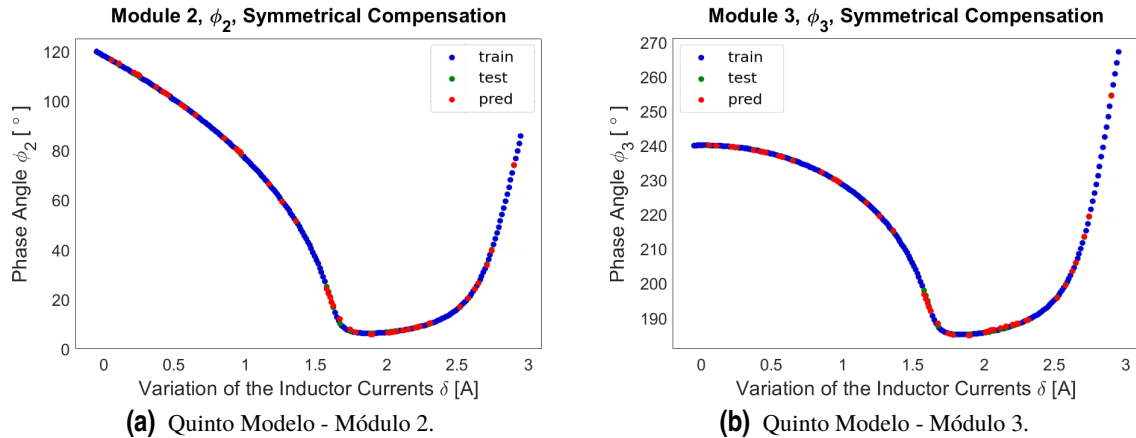


Figura 4.26 Quinto modelo, compensación simétrica de las corrientes de la bobina.

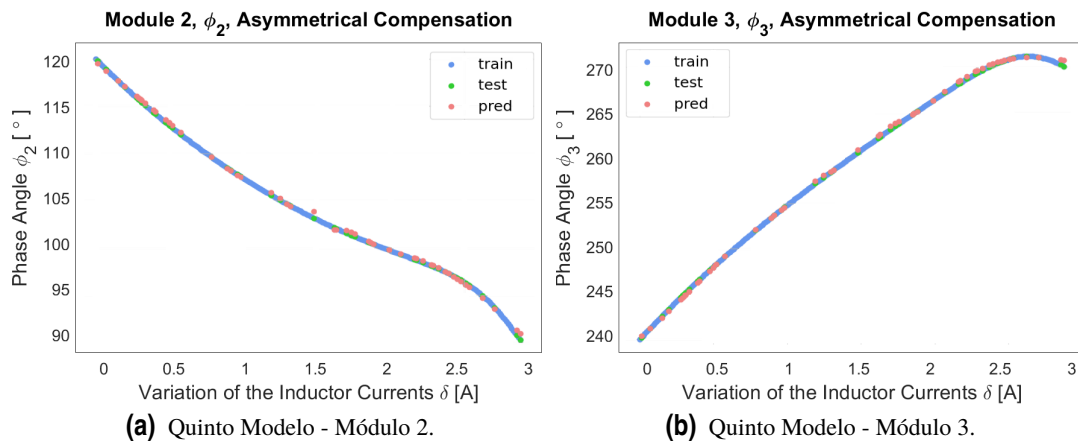


Figura 4.27 Quinto modelo, compensación asimétrica de las corrientes de la bobina.

Este modelo podría sustituir al AMH, obteniendo buenos resultados. Sin embargo, su función de activación, la Tangente Hiperbólica, tiene un coste computacional alto, como se comentó anteriormente. La solución que se adopta es sustituirla por una aproximación.

Cambio a la aproximación de la Tangente Hiperbólica

Para sustituir la función de activación de Tangente Hiperbólica, se propone la siguiente aproximación, ilustrada en la Figura 4.28:

$$f(y) = \begin{cases} -1 & \text{si } y < -1 \\ y & \text{si } -1 < y < 1 \\ 1 & \text{si } y > 1 \end{cases}$$

Esta aproximación se podría usar de dos formas: solamente para la predicción de nuevos datos, habiendo usado la tangente hiperbólica para el entrenamiento, o para el entrenamiento y la predicción.

Para esta Red Neuronal, el entrenamiento con \tanh y la predicción con la aproximación da muy malos resultados, como se puede observar en las Figuras 4.29 y 4.30. Se pierde totalmente los avances conseguidos hasta ahora, las predicciones siguen curvas muy distintas a las de los datos. En la Tabla 4.7, se puede apreciar que los resultados son mucho peores que los conseguidos en modelos anteriores.




Figura 4.28 Comparación de la Tangente Hiperbólica con la aproximación utilizada.




Figura 4.29 Modelo entrenado con Tangente Hiperbólica, prediciendo con la Aproximación, compensación simétrica de las corrientes de la bobina.

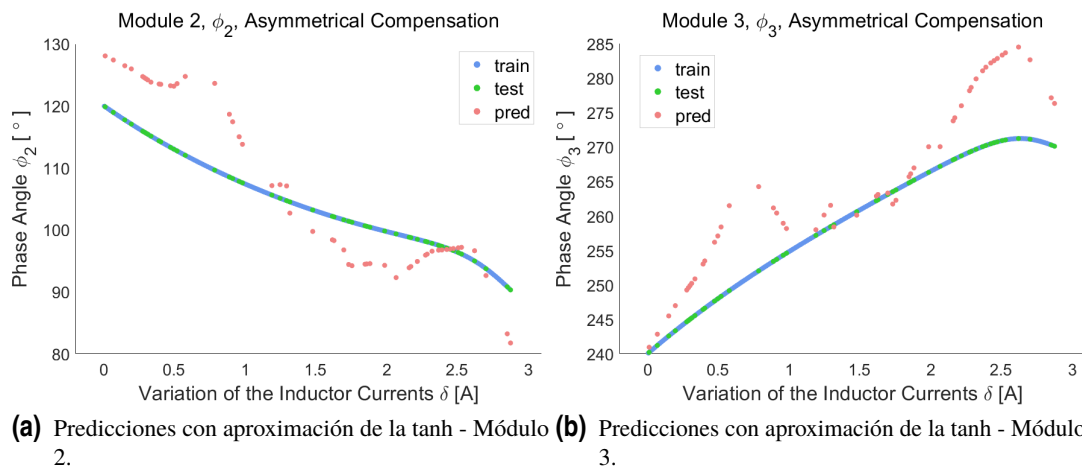


Figura 4.30 Modelo entrenado con Tangente Hiperbólica, prediciendo con la Aproximación, compensación asimétrica de las corrientes de la bobina.

Tabla 4.7 Aproximación de la Tangente Hiperbólica, resultados.

MAE		ϕ_2	ϕ_3
Entrenamiento y predicciones con tanh		0.15	0.12
Entrenamiento con tanh, predicciones con la aproximación		7.45	4.75
Entrenamiento y predicciones con la aproximación		0.31	0.23
MSE		ϕ_2	ϕ_3
Entrenamiento y predicciones con tanh		0.05	0.02
Entrenamiento con tanh, predicciones con la aproximación		78.54	35.55
Entrenamiento y predicciones con la aproximación		0.23	0.11

Al ser candidata para sustituir el AMH, interesa visualizar también los errores cometidos, en las Figuras 4.31 y 4.32 se distinguen errores de -25° , que son inaceptables para este caso.

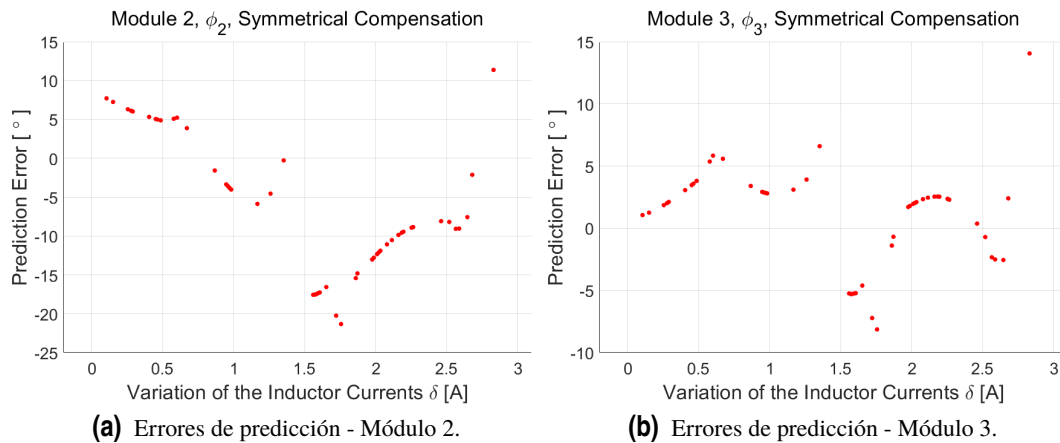


Figura 4.31 Errores del modelo entrenado con Tangente Hiperbólica, prediciendo con la Aproximación, compensación simétrica de las corrientes de la bobina.

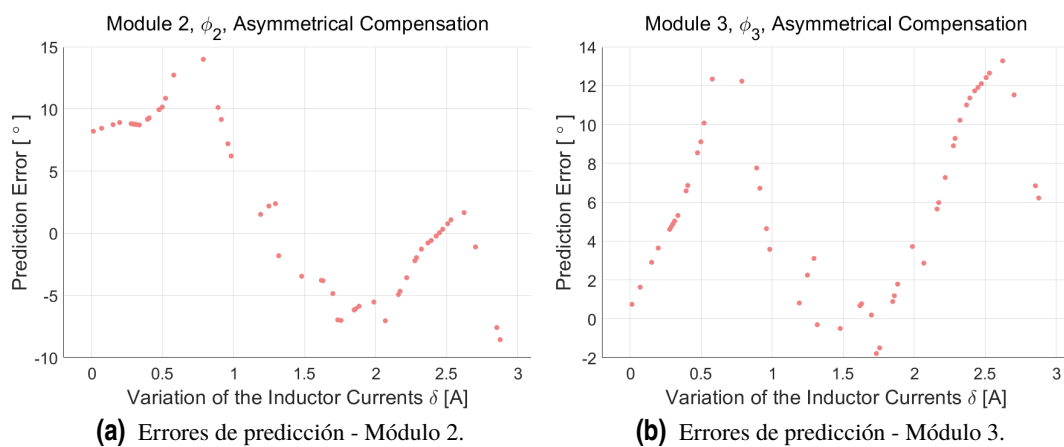


Figura 4.32 Errores del modelo entrenado con Tangente Hiperbólica, prediciendo con la Aproximación, compensación asimétrica de las corrientes de la bobina.

Sin embargo, si se usa la aproximación en el entrenamiento y la predicción, se obtienen resultados más adecuados, como se refleja en las Figuras 4.33 y 4.34. Volviendo a la Tabla 4.7, las predicciones de este modelo son mucho mejores que el anteriormente comentado, aunque por supuesto son un poco peores que si se usase la Tangente Hiperbólica.

En las Figuras 4.35 y 4.36 se visualizan los errores. En algunos rangos de δ , en las compensaciones simétricas en ambos módulos, los errores son próximos a los 3° . Aunque es una mejora, errores de más de 1° suponen variaciones significantes en los armónicos que se intentan disminuir, por lo que no son aceptables.

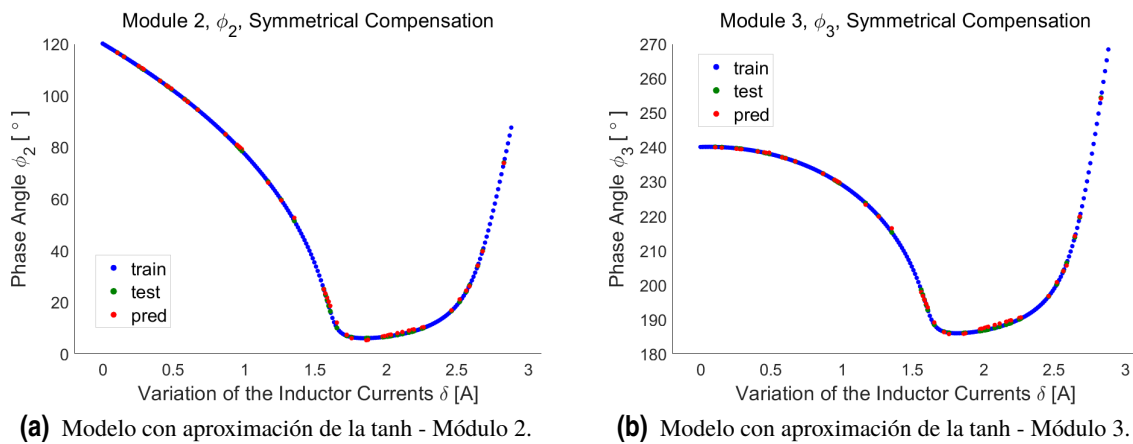


Figura 4.33 Modelo entrenado con la Aproximación de la Tangente Hiperbólica, compensación simétrica de las corrientes de la bobina.

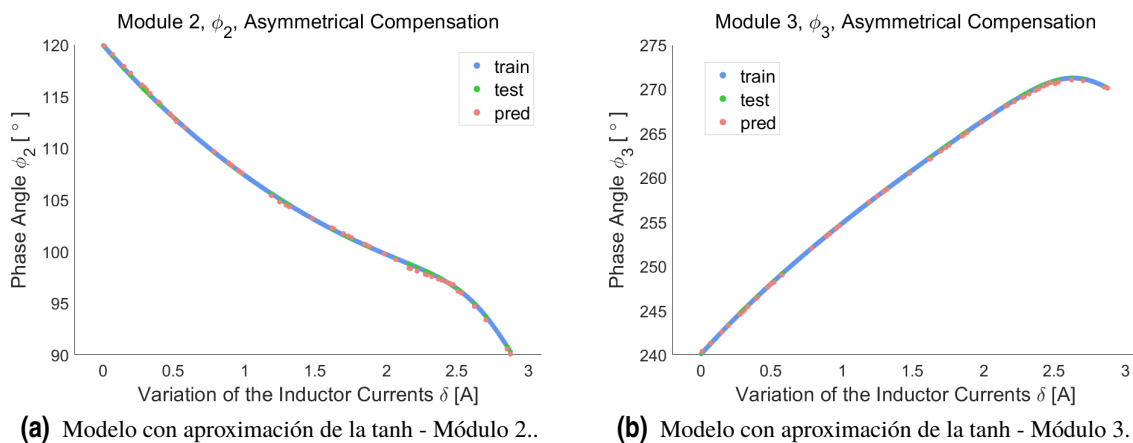


Figura 4.34 Modelo entrenado con la Aproximación de la Tangente Hiperbólica, compensación asimétrica de las corrientes de la bobina.

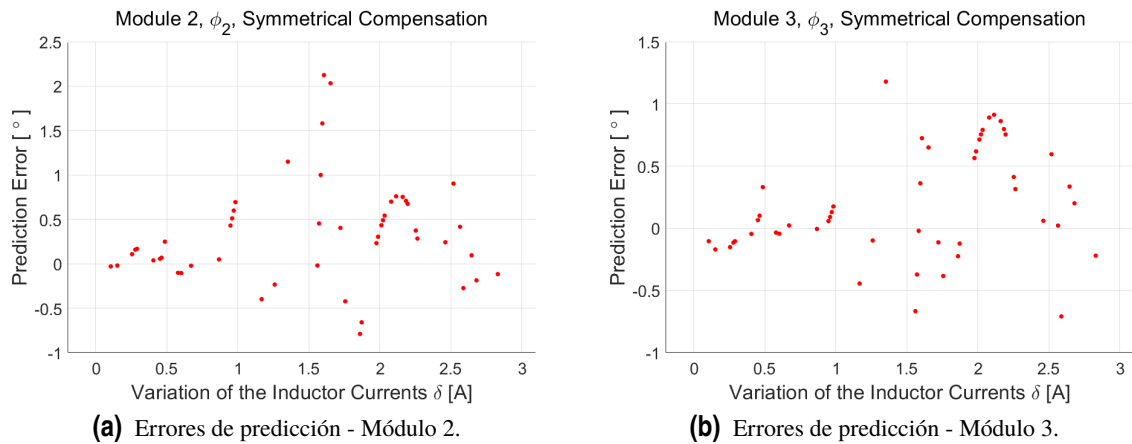


Figura 4.35 Errores del modelo entrenado con la Aproximación de la Tangente Hiperbólica, compensación simétrica de las corrientes de la bobina.

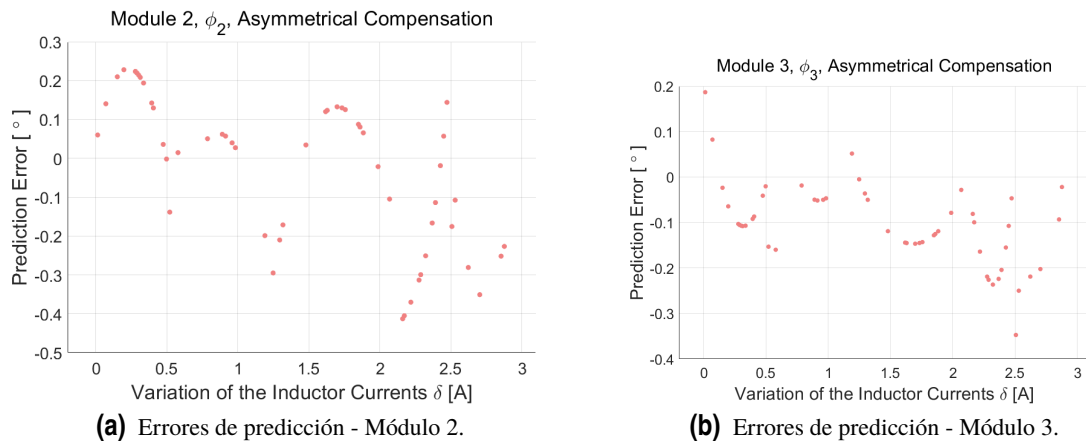


Figura 4.36 Errores del modelo entrenado con la Aproximación de la Tangente Hiperbólica, compensación asimétrica de las corrientes de la bobina.

Pruebas: *epochs*, número de neuronas y capas.

Partiendo del quinto modelo entrenado con la Aproximación de la la Tangente Hiperbólica como función de activación, se realizan una serie de pruebas para mejorar los resultados obtenidos hasta ahora, variando las *epochs*, el número de capas y el número de neuronas por capa. Los modelos con resultados más prometedores tienen los siguientes parámetros: las *epochs* varían entre las 2000, 2300 y 2600; todos tienen dos capas, y el número de neuronas varía entre los 15, 20 y 50.

Los resultados se muestran en las Figuras 4.37, 4.38 y 4.39. Se incluye también la Figura 4.40, que muestra el error máximo absoluto que se comete en cada una. Este dato es relevante, puesto que se está eligiendo el modelo de Red que sustituya finalmente al AMH, como se ha comentado anteriormente no interesa que sea mucho mayor a 1° , o al menos que no se cometa errores mayores a 1° con mucha frecuencia. Se observa que el mejor modelo es aquel que tiene 2600 *epochs*, y 15 neuronas por capa. Consigue errores de menos de 1° , por lo que es ideal para la finalidad que se requiere. Además, teniendo solamente 15 neuronas, requiere menos cálculo que los otros modelos, lo que ya se ha visto que es una ventaja.






Figura 4.37 Quinto modelo, comparación Loss vs *Epochs* y Neuronas..




(a) MAE - Módulo 2.




(b) MAE - Módulo 3.

Figura 4.38 Quinto modelo, comparación Error Absoluto Medio vs *Epochs* y Neuronas.



(a) MSE - Módulo 2.



(b) MSE - Módulo 3.

Figura 4.39 Quinto modelo, comparación Error Cuadrático Medio vs *Epochs* y Neuronas.

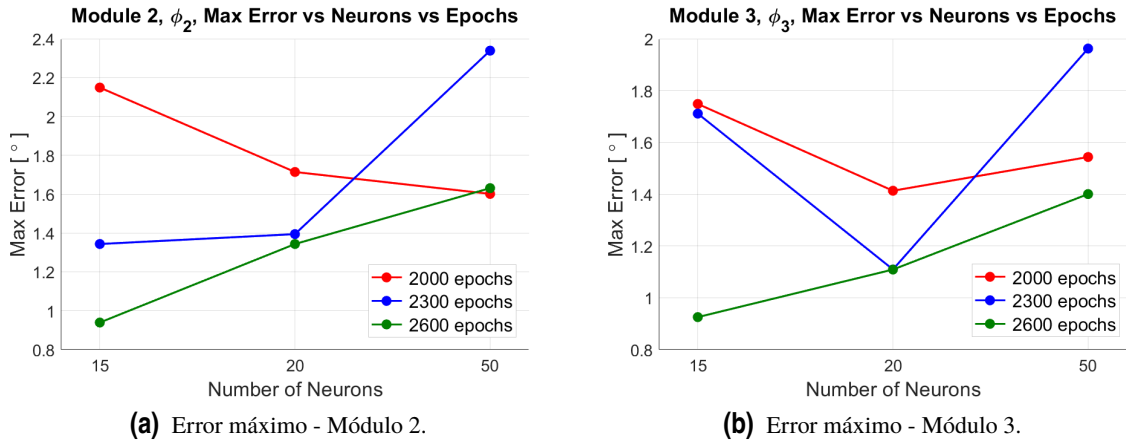


Figura 4.40 Quinto modelo, comparación Error Máximo vs *Epochs* y Neuronas.

4.3.6 Modelo Final

- Datos: 500 sets, estandarizados.
- Modelo: Secuencial.
- Capas:
 - 1 capa de entrada, 3 neuronas.
 - 2 capas ocultas, 15 neuronas, función de activación aproximación de tanh y regularizadores de kernel ($L_1=1e-5$, $L_2=1e-6$).
 - 1 capa de salida, 2 neuronas.
- Función de pérdida: Error Cuadrático Medio (MSE).
- Optimizador: Adam.
- *Epochs*: 2600.

Este modelo es el resultado de muchas pruebas en las que se pretendía mejorar las predicciones conseguidas por la Red Neuronal, de forma que esta pudiese reproducir el comportamiento del AMH fielmente.

Tabla 4.8 Modelo Final, resultados.

MAE	ϕ_2	ϕ_3
Quinto Modelo	0.15	0.12
Modelo Final	0.20	0.17
MSE	ϕ_2	ϕ_3
Quinto Modelo	0.05	0.02
Modelo Final	0.08	0.06

Comparándolo con el Quinto Modelo, en la Tabla 4.8, se observa que los resultados son ligeramente peores. Sin embargo, esto era de esperar, puesto que este último modelo tiene como función de activación una Aproximación de la Tangente Hiperbólica. Considerando que el Modelo Final tiene un coste computacional mucho menor que el Quinto Modelo gracias a esa Aproximación, y que las predicciones, aun peores, son muy buenas; este Modelo es el mejor candidato para sustituir al AMH en el hardware de control en tiempo real.

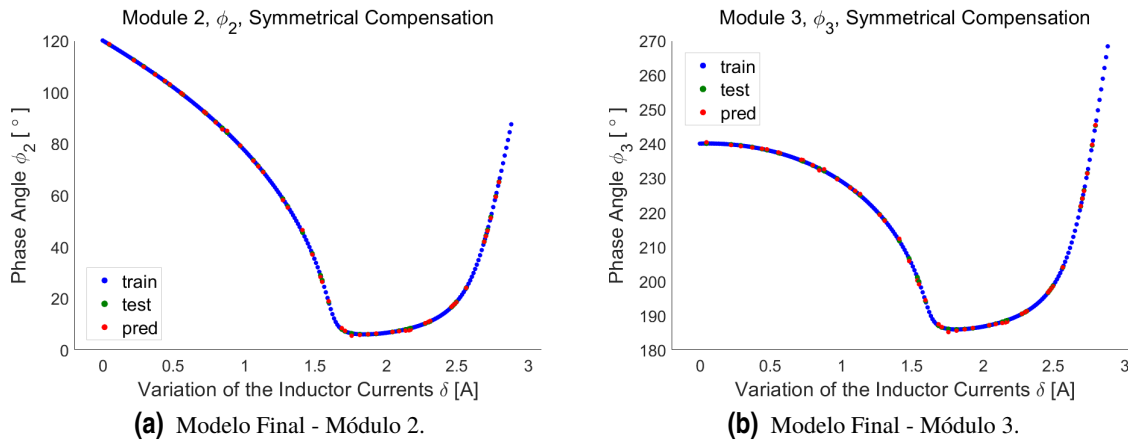


Figura 4.41 Modelo Final, compensación simétrica de las corrientes de la bobina.

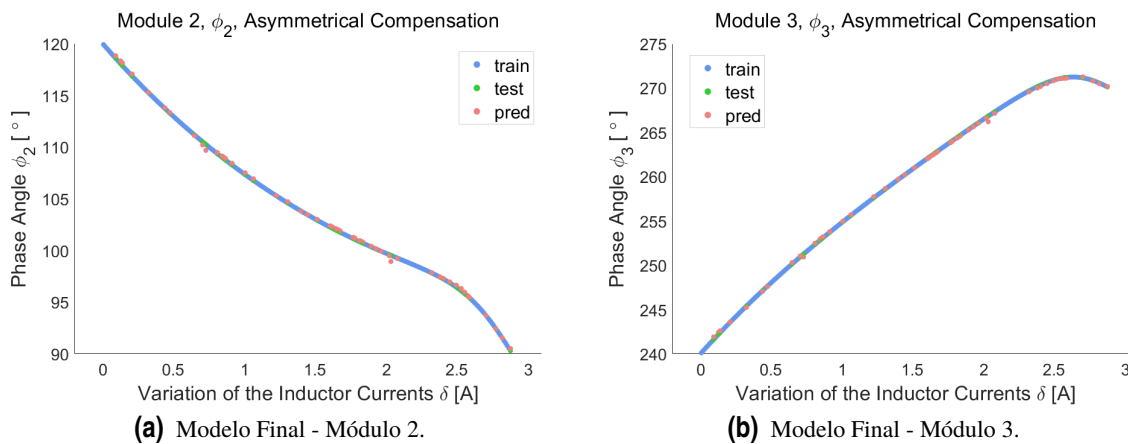


Figura 4.42 Modelo Final, compensación asimétrica de las corrientes de la bobina.

En las Figuras 4.41 y 4.42 se puede comprobar que las predicciones de este modelo son muy buenas, se ajustan muy bien a los datos.

Las Figuras 4.43 y 4.44 muestran los errores cometidos por este modelo de red, se puede apreciar que no llegan al grado. Esto implica que la diferencia en el contenido armónico conseguido con el AMH y la ANN serán despreciables.

Este modelo de Red Neuronal es el que se propone como sustituto del Algoritmo Metaheurístico, para calcular los ángulos de desfase de los módulos del convertidor dc/dc *interleaved* bajo estudio.

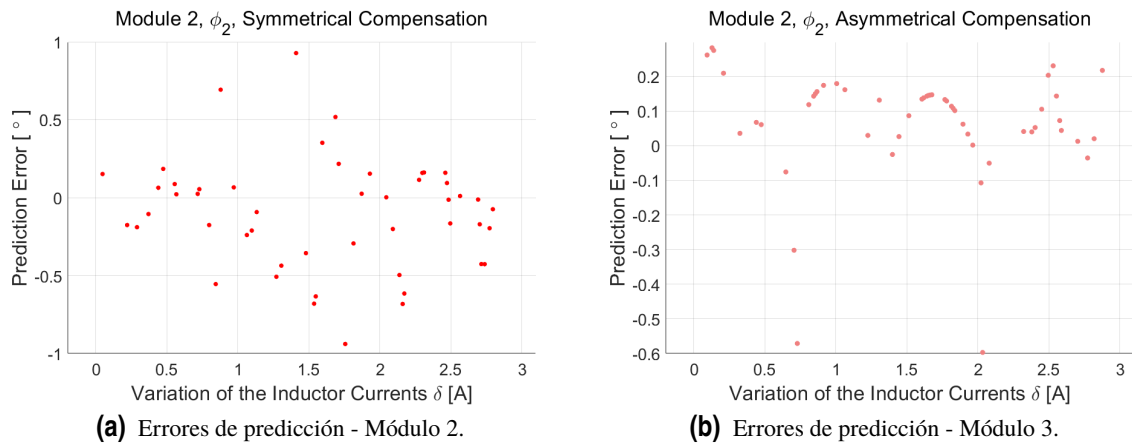


Figura 4.43 Errores del Modelo Final, compensación simétrica de las corrientes de la bobina.

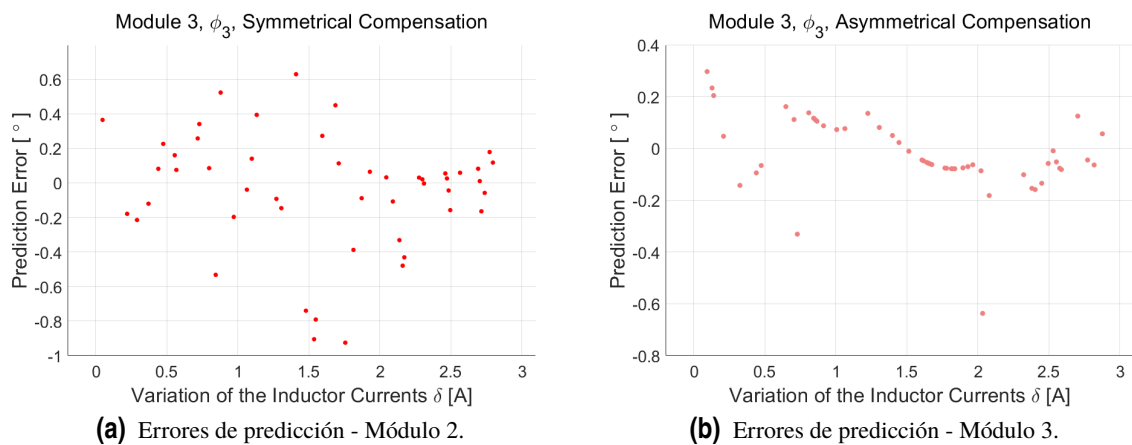


Figura 4.44 Errores del Modelo Final, compensación asimétrica de las corrientes de la bobina.

5 Sustitución del AMH por la ANN

Una vez conseguido un modelo de Red Neuronal con buenos resultados, se comprueba que es capaz de sustituir al Algoritmo Metaheurístico para reducir las componentes de armónicos de baja frecuencia de la corriente del condensador de entrada, i_{ci} . Para ello, se llevan a cabo una serie de simulaciones en *Simulink*, en un modelo de convertidor dc/dc *interleaved*. Se fuerza un desequilibrio en las corrientes por las bobinas, y se comparan los resultados obtenidos por el Algoritmo 1 y por la Red Neuronal.

5.1 Compensación Simétrica

Primero se proponen desequilibrios de corriente simétricos, del 10% y del 23% respectivamente. En las Figuras 5.1 y 5.2 se muestran los espectros de la corriente por el condensador de entrada i_{ci} , aplicando a las portadoras de cada módulo del convertidor dc/dc *interleaved* el desfase calculado por el Algoritmo Metaheurístico (izquierda) y por la Red Neuronal (derecha).

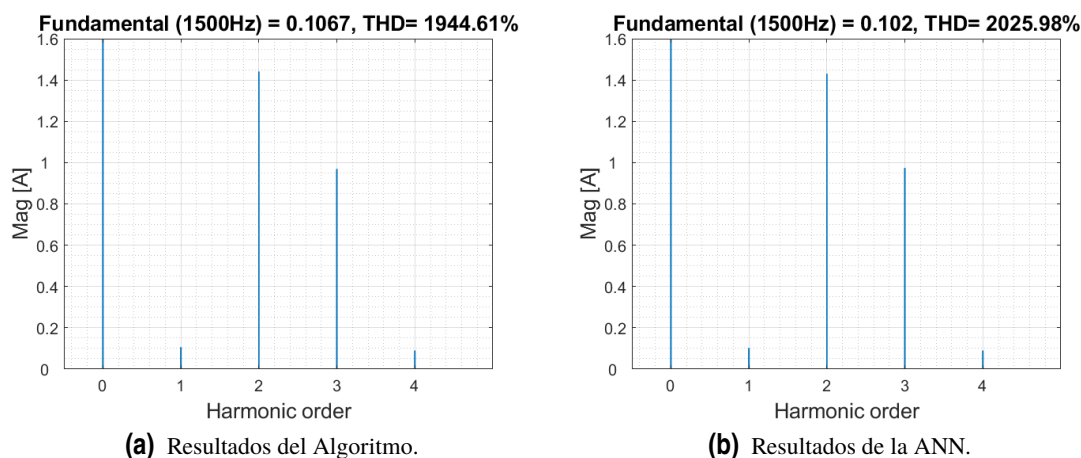


Figura 5.1 Compensación simétrica, del 10% de la corriente equilibrada.

Se puede observar que en los dos casos de desequilibrio, el espectro de corriente conseguido por la Red Neuronal se parece mucho al obtenido con los ángulos calculados por el Algoritmo Metaheurístico.

En la Tabla 5.1 se reflejan los datos numéricos de las Figuras 5.1 y 5.2. Como se puede comprobar, la ANN es capaz de predecir los ángulos de desfase de las portadoras de los módulos con mucha precisión, la suficiente como para reproducir muy fielmente el comportamiento del Algoritmo 1.




Figura 5.2 Compensación simétrica, del 23% de la corriente equilibrada.

Tabla 5.1 Contenidos de los Armónicos, desequilibrio simétrico.

Desequilibrio	Cálculo	ϕ_1	ϕ_2	ϕ_3	1 ^{er} Arm [A]	2 ^{do} Arm [A]	3 ^{er} Arm [A]
10%	AMH	0	84.86	232.27	0.1067	1.4410	0.9693
	ANN	0	85.24	232.12	0.1020	1.4300	0.9742
23%	AMH	0	6.76	186.92	0.5324	2.755	0.2250
	ANN	0	7.04	187.20	0.5304	2.755	0.2280

5.2 Compensación Asimétrica

A continuación se proponen desequilibrios de la corriente asimétricos, del 6.6% y del 16% respectivamente. Las Figuras 5.3 y 5.4 muestran el espectro armónico de la corriente del condensador de entrada i_{ci} en cada caso, aplicando a las portadoras de cada módulo del convertidor dc/dc *interleaved* el desfase calculado por el Algoritmo Metaheurístico (izquierda) y por la Red Neuronal (derecha).




Figura 5.3 Compensación asimétrica, del 6.6% de la corriente equilibrada.




Figura 5.4 Compensación asimétrica, del 16 % de la corriente equilibrada.

De nuevo, en ambos casos propuestos, la ANN parece obtener resultados muy parecidos a los que se consiguen con el Algoritmo 1. En la Tabla 5.2 se reflejan los datos numéricos de las Figuras 5.3 y 5.4. Se puede comprobar como, al igual que en el caso de desequilibrio simétrico, la Red Neuronal predice los ángulos de desfase con muy buena precisión, pudiendo simular el comportamiento del Algoritmo Metaheurístico fielmente.

Tabla 5.2 Contenidos de los Armónicos, desequilibrio asimétrico.

Desequilibrio	Cálculo	ϕ_1	ϕ_2	ϕ_3	1 ^{er} Arm [A]	2 ^{do} Arm [A]	3 ^{er} Arm [A]
6.6 %	AMH	0	111.99	249.14	0.0609	0.7484	1.2181
	ANN	0	112.01	249.2	0.0629	0.7506	1.2167
16 %	AMH	0	103.44	260.20	0.1376	1.6513	0.8460
	ANN	0	103.71	260.4	0.1367	1.6524	0.8439

6 Conclusión y futuros proyectos

Los convertidores dc/dc interleaved presentan ventajas frente a un convertidor dc/dc, como la reducción del rizado de la corriente por la bobina y de armónicos. Estas ventajas se pierden en el modo de operación desequilibrada. Para mejorar el comportamiento, se necesita variar los ángulos de desfase de las portadoras de los módulos del convertidor.

Un Algoritmo Metaheurístico es capaz de calcular estos ángulos de forma que se reduzca el contenido de los armónicos de baja frecuencia. Sin embargo, requiere un coste computacional muy alto, lo que dificulta su implementación en tiempo real.

La solución propuesta es una Red Neuronal entrenada con los datos calculados por el Algoritmo, de forma que lo sustituya. La red sería capaz de proporcionar los mismos ángulos que el Algoritmo, pero sin embargo no requiere tanto cálculo y por lo tanto es más rápida. Con los resultados obtenidos, se confirma que esta opción da buenos resultados, pues la red consigue la misma reducción de armónicos que el Algoritmo, en simulaciones realizadas con modelos de Simulink.

La continuación lógica de esta investigación es probar el comportamiento de la red en un entorno más parecido a la realidad, en una simulación en tiempo real o en un prototipo de convertidor en el laboratorio en un entorno controlado.

Índice de Figuras

1.1	Emisiones de gases de efecto invernadero, según la UE	1
1.2	Proyección del crecimiento de la flota de vehículos eléctricos	2
1.3	Tren de carga de un coche eléctrico	3
1.4	Topología del cargador ABB Terra HP 150kW de alta potencia	4
2.1	Configuración de un convertidor de potencia dc/dc <i>interleaved</i>	5
2.2	Régimen permanente del convertidor <i>interleaved</i> con operación equilibrada, $f_{sw} = 2$ kHz: (a) Señales de switch (b) corrientes por las bobinas (c) corrientes de los condensadores de entrada i_{ci} y de salida i_{co}	7
2.3	Espectro de la corriente para la operación equilibrada a frecuencia de conmutación de 2 kHz	7
2.4	Régimen permanente del convertidor <i>interleaved</i> en operación equilibrada (izquierda) y desequilibrada (derecha), con un desfase de portadoras de $\frac{360^\circ}{3}$ y $f_{sw} = 2$ kHz: (a) Corrientes por las bobinas y (b) corrientes por los condensadores	8
2.5	Comparación de los espectros de las corrientes de C_i en el convertidor <i>interleaved</i> con modo de operación equilibrado y desequilibrado, con un desfase de portadoras de $\frac{360^\circ}{3}$ y $f_{sw} = 2$ kHz	8
2.6	a) Topología de un convertidor dc/dc elevador, b) portadora, duty cycle y corriente por el diodo i_{ak} . También se representa el valor medio de la corriente de la bobina, I_L	8
3.1	Algoritmo Metaheurístico	11
3.2	Las cinco posiciones de búsqueda en cada iteración del algoritmo: ángulos actuales, aumento y disminución de x_2 y x_3	13
3.3	Compensación simétrica de las corrientes por las bobinas en operación desequilibrada	13
3.4	Compensación simétrica, del 10 % de la corriente equilibrada	14
3.5	Compensación simétrica, del 23 % de la corriente equilibrada	14
3.6	Compensación asimétrica de las corrientes por las bobinas en operación desequilibrada	15
3.7	Compensación asimétrica, del 6.6 % de la corriente equilibrada	16
3.8	Compensación asimétrica, del 16 % de la corriente equilibrada	16
4.1	Red neuronal	19
4.2	Casos de compensación contemplados	20
4.3	Estructura de la red neuronal	21
4.4	Primer modelo, compensación simétrica de las corrientes de la bobina	22
4.5	Primer modelo, compensación asimétrica de las corrientes de la bobina	23
4.6	Primer modelo, comparación Loss vs <i>Epochs</i>	24
4.7	Primer modelo, comparación MAE y MSE vs <i>Epochs</i>	24

4.8	Fenómeno de <i>overfitting</i> . A la izquierda, un modelo ajustado a los datos correctamente, siguiendo a los datos. A la derecha, un modelo que presenta <i>overfitting</i> [21]	25
4.9	Segundo modelo, compensación simétrica de las corrientes de la bobina	26
4.10	Segundo modelo, compensación asimétrica de las corrientes de la bobina	27
4.11	Red neuronal, entradas y salidas simplificadas	27
4.12	Tercer modelo, compensación simétrica de las corrientes de la bobina	28
4.13	Tercer modelo, compensación asimétrica de las corrientes de la bobina	28
4.14	Tercer modelo, comparación Loss vs Número de capas y neuronas	29
4.15	Tercer modelo, comparación Error Absoluto Medio vs Número de capas y neuronas	29
4.16	Tercer modelo, comparación Error Cuadrático Medio vs Número de capas y neuronas	29
4.17	Esquema de la red neuronal con datos estandarizados	31
4.18	Cuarto modelo, compensación simétrica de las corrientes de la bobina	31
4.19	Cuarto modelo, compensación asimétrica de las corrientes de la bobina	32
4.20	Cuarto modelo, comparación Loss vs la función de activación	33
4.21	Cuarto modelo, comparación MAE y MSE vs la función de activación	33
4.22	Cuarto modelo, comparación Loss vs <i>Epochs</i>	34
4.23	Cuarto modelo, comparación MAE y MSE vs <i>Epochs</i>	34
4.24	Cuarto modelo, comparación Loss vs Número de Datos	34
4.25	Cuarto modelo, comparación MAE y MSE vs Número de Datos	35
4.26	Quinto modelo, compensación simétrica de las corrientes de la bobina	36
4.27	Quinto modelo, compensación asimétrica de las corrientes de la bobina	36
4.28	Comparación de la Tangente Hiperbólica con la aproximación utilizada	37
4.29	Modelo entrenado con Tangente Hiperbólica, prediciendo con la Aproximación, compensación simétrica de las corrientes de la bobina	37
4.30	Modelo entrenado con Tangente Hiperbólica, prediciendo con la Aproximación, compensación asimétrica de las corrientes de la bobina	37
4.31	Errores del modelo entrenado con Tangente Hiperbólica, prediciendo con la Aproximación, compensación simétrica de las corrientes de la bobina	38
4.32	Errores del modelo entrenado con Tangente Hiperbólica, prediciendo con la Aproximación, compensación asimétrica de las corrientes de la bobina	38
4.33	Modelo entrenado con la Aproximación de la Tangente Hiperbólica, compensación simétrica de las corrientes de la bobina	39
4.34	Modelo entrenado con la Aproximación de la Tangente Hiperbólica, compensación asimétrica de las corrientes de la bobina	39
4.35	Errores del modelo entrenado con la Aproximación de la Tangente Hiperbólica, compensación simétrica de las corrientes de la bobina	40
4.36	Errores del modelo entrenado con la Aproximación de la Tangente Hiperbólica, compensación asimétrica de las corrientes de la bobina	40
4.37	Quinto modelo, comparación Loss vs <i>Epochs</i> y Neuronas.	41
4.38	Quinto modelo, comparación Error Absoluto Medio vs <i>Epochs</i> y Neuronas	41
4.39	Quinto modelo, comparación Error Cuadrático Medio vs <i>Epochs</i> y Neuronas	41
4.40	Quinto modelo, comparación Error Máximo vs <i>Epochs</i> y Neuronas	42
4.41	Modelo Final, compensación simétrica de las corrientes de la bobina	43
4.42	Modelo Final, compensación asimétrica de las corrientes de la bobina	43
4.43	Errores del Modelo Final, compensación simétrica de las corrientes de la bobina	44
4.44	Errores del Modelo Final, compensación asimétrica de las corrientes de la bobina	44
5.1	Compensación simétrica, del 10 % de la corriente equilibrada	45
5.2	Compensación simétrica, del 23 % de la corriente equilibrada	46
5.3	Compensación asimétrica, del 6.6 % de la corriente equilibrada	46

5.4	Compensación asimétrica, del 16% de la corriente equilibrada	47
-----	--	----

Índice de Tablas

3.1	Entradas y salidas del Algoritmo Metaheurístico	11
3.2	Parámetros del modelo de <i>Simulink</i>	13
3.3	Contenidos de los Armónicos, desequilibrio simétrico	15
3.4	Contenidos de los Armónicos, desequilibrio asimétrico	16
4.1	Parámetros del convertidor a estudiar	20
4.2	Primer Modelo, resultados	22
4.3	Segundo Modelo, resultados	25
4.4	Tercer Modelo, resultados	28
4.5	Cuarto Modelo, resultados	31
4.6	Quinto Modelo, resultados	35
4.7	Aproximación de la Tangente Hiperbólica, resultados	38
4.8	Modelo Final, resultados	42
5.1	Contenidos de los Armónicos, desequilibrio simétrico	46
5.2	Contenidos de los Armónicos, desequilibrio asimétrico	47

Bibliografía

- [1] Consejo Europeo. Movilidad limpia y sostenible. <https://www.consilium.europa.eu/es/policies/clean-and-sustainable-mobility/goals>, 2023. Accessed: 2024.
- [2] Consejo Europeo. Infraestructura para los combustibles alternativos: se alcanza un acuerdo provisional para instalar más estaciones de recarga y repostaje en toda europa. <https://www.consilium.europa.eu/es/press/press-releases/2023/03/28/alternative-fuel-infrastructure-provisional-agreement-for-more-recharging-and-refuelling-stations-across-europe/>, 2023. Accessed: 2024.
- [3] Consejo Europeo. Objetivo 55: hacia un transporte más sostenible. <https://www.consilium.europa.eu/es/infographics/fit-for-55-afir-alternative-fuels-infrastructure-regulation/>, 2023. Accessed: 2024.
- [4] Consejo Europeo. Infraestructura para los combustibles alternativos: el consejo adopta un nuevo reglamento para aumentar las estaciones de recarga y repostaje en toda europa. <https://www.consilium.europa.eu/es/press/press-releases/2023/07/25/alternative-fuels-infrastructure-council-adopts-new-law-for-more-recharging-and-refuelling-stations-across-europe/>, 2023. Accessed: 2024.
- [5] Sebastian Rivera, Samir Kouro, Sergio Vazquez, Stefan M. Goetz, Ricardo Lizana, and Enrique Romero-Cadaval. Electric vehicle charging infrastructure: From grid to battery. *IEEE Industrial Electronics Magazine*, 15(2):37–51, 2021.
- [6] Yunfei Yin, Jianxing Liu, Abraham Marquez, Xinpo Lin, José I. Leon, Sergio Vazquez, Leopoldo G. Franquelo, and Ligang Wu. Advanced control strategies for dc-dc buck converters with parametric uncertainties via experimental evaluation. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 67(12):5257–5267, 2020.
- [7] B.A. Miwa, D.M. Otten, and M.E. Schlecht. High efficiency power factor correction using interleaving techniques. In *[Proceedings] APEC '92 Seventh Annual Applied Power Electronics Conference and Exposition*, pages 557–568, 1992.
- [8] Chin Chang and M.A. Knights. Interleaving technique in distributed power conversion systems. *IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications*, 42(5):245–251, 1995.
- [9] Abraham Marquez Alcaide, Youngjong Ko, Markus Andresen, Jose I. Leon, Sergio Vazquez, Vito Giuseppe Monopoli, Giampaolo Buticchi, Marco Liserre, and Leopoldo G. Franquelo.

- Capacitor lifetime extension of interleaved dc-dc converters for multistring pv systems. *IEEE Transactions on Industrial Electronics*, 70(5):4854–4864, 2023.
- [10] Abraham M. Alcaide, Sandro Guenter, Jose I. Leon, Giampaolo Buticchi, Samir Kouro, and Leopoldo G. Franquelo. Common dc-link capacitor lifetime extension in modular dc/dc converters for electric vehicle fast chargers via variable-angle interleaved operation. *IEEE Transactions on Industrial Electronics*, pages 1–10, 2022.
- [11] César A. Silva and Juan I. Yuz. On sampled-data models for model predictive control. In *IECON 2010 - 36th Annual Conference on IEEE Industrial Electronics Society*, pages 2966–2971, 2010.
- [12] D.R. Garth, W.J. Muldoon, G.C. Benson, and E.N. Costague. Multi-phase, 2-kilowatt, high-voltage, regulated power supply. In *1971 IEEE Power Electronics Specialists Conference*, pages 110–116, 1971.
- [13] Vito G. Monopoli, Abraham Marquez, Jose I. Leon, Marco Liserre, Giampaolo Buticchi, Leopoldo G. Franquelo, and Sergio Vazquez. Applications and modulation methods for modular converters enabling unequal cell power sharing: Carrier variable-angle phase-displacement modulation methods. *IEEE Industrial Electronics Magazine*, 16(1):19–30, 2022.
- [14] Morteza Esteki, Behzad Poorali, Ehsan Adib, and Hosein Farzanehfard. Interleaved buck converter with continuous input current, extremely low output current ripple, low switching losses, and improved step-down conversion ratio. *IEEE Transactions on Industrial Electronics*, 62(8):4769–4776, 2015.
- [15] Lorand Bede, Ghanshyamsinh Gohil, Tamas Kerekes, and Remus Teodorescu. Optimal interleaving angle determination in multi paralleled converters considering the dc current ripple and grid current thd. In *2015 9th International Conference on Power Electronics and ECCE Asia (ICPE-ECCE Asia)*, pages 1195–1202, 2015.
- [16] J. S. Siva Prasad and G. Narayanan. Minimization of grid current distortion in parallel-connected converters through carrier interleaving. *IEEE Transactions on Industrial Electronics*, 61(1):76–91, 2014.
- [17] S. Kavitha, S. Edward Rajan, and R. Pon Vengatesh. Performance analysis of interleaved dc-dc boost converter for photo-voltaic power generation systems. In *2014 International Conference on Green Computing Communication and Electrical Engineering (ICGCCEE)*, pages 1–6, 2014.
- [18] Jaime W. Zapata, Samir Kouro, Matias Aguirre, and Thierry Meynard. Model predictive control of interleaved dc-dc stage for photovoltaic microconverters. In *IECON 2015 - 41st Annual Conference of the IEEE Industrial Electronics Society*, pages 004311–004316, 2015.
- [19] Ruben Gomez-Merchan, Sergio Vazquez, Abraham Marquez Alcaide, Hossein Dehghani Tafti, Jose I. Leon, Josep Pou, Christian A. Rojas, Samir Kouro, and Leopoldo G. Franquelo. Binary search based flexible power point tracking algorithm for photovoltaic systems. *IEEE Transactions on Industrial Electronics*, 68(7):5909–5920, 2021.
- [20] B. Melián, J.A Moreno Pérez, and J.M. Moreno Vega. Metaheurísticas: un visión global. *Revista Iberoamericana de Inteligencia Artificial*, (19):7–28, 2003.
- [21] Ian Goodfellow. *Deep learning*. Cambridge, Mass. : Mit Press, 2017.