

# Estimación de pérdidas magnéticas en ferritas mediante red neuronal informada por física basada en parámetros físicos

Javier Milla Benito, F. José Pérez Cebolla, Carlos Bernal Ruiz,

Alfonso Latre Gayán, María Teresa Maza Luengo, Carlos Ríos Ferrer

Grupo de Electrónica de Potencia y Microelectrónica, Instituto de Investigación en Ingeniería de Aragón (I3A)

Universidad de Zaragoza, Mariano Esquillor s/n, 50018, Zaragoza, España.

Tel. +34-976762707, e-mail: 475124@unizar.es

## Resumen

En este trabajo se propone una red neuronal informada por física (PINN) para estimar las pérdidas magnéticas en núcleos de ferrita bajo excitaciones arbitrarias. La red aprende siete parámetros del modelo de permeabilidad mediante una función Cole–Cole, garantizando interpretabilidad física. Validado sobre 7 ferritas del dataset MagNet, alcanza un error medio inferior al 5 %.

## Introducción

Las pérdidas magnéticas en núcleos de ferrita constituyen uno de los principales factores limitantes de la eficiencia y la densidad de potencia de los convertidores conmutados modernos. La ecuación de Steinmetz [1] y sus extensiones —como la *improved Generalized Steinmetz Equation* (iGSE) [2]— proporcionan formulaciones compactas y ampliamente utilizadas, pero presentan una degradación sistemática de la precisión cuando la excitación se aleja de formas de onda sinusoidales. Las formas de onda trapezoidales y triangulares con altos *slew-rates*, típicas de los convertidores electrónicos, generan pérdidas que el modelo clásico subestima significativamente.

Las propuestas basadas en aprendizaje automático (ML) han demostrado mejoras sustanciales en la predicción de pérdidas sobre conjuntos de datos como MagNet [3, 4]. Sin embargo, los modelos puramente *data-driven* —redes neuronales densas, LSTM, CNN— requieren grandes volúmenes de muestras por material y carecen de interpretabilidad [5]. El MagNet Challenge 2023 [6] ha mostrado que los modelos que incorporan conocimiento físico previo alcanzan mejores resultados con menor coste de datos.

Las redes neuronales informadas por física (PINN), introducidas por Raissi *et al.* [7], integran leyes físicas dentro de la estructura de la red neuronal. Si bien, su aplicación a la predicción de pérdidas magnéticas en ferritas es todavía incipiente [8]. En este trabajo se propone un modelo PINN cuya capa de salida codifica los parámetros del modelo de permeabilidad [9] del material.

## Modelo PINN propuesto

El modelo se estructura en dos bloques acoplados: un bloque neuronal y un bloque físico (figura 1).

**Bloque neuronal.** Una red MLP (*Multi-Layer Perceptron*) de dos capas ocultas de 64 neuronas recibe como entrada parámetros de la excitación: la temperatura  $T$ , la frecuencia nominal  $f$ , la variación de la densidad del campo  $\Delta B$ , el factor de cresta  $f_c$ , el ciclo de servicio  $D$  y el *slew-rate* normalizado  $SR$ . La capa de salida codifica

parámetros físicamente interpretables del modelo Cole–Cole.

**Bloque físico.** Los siete parámetros generados por la red se introducen en las ecuaciones del modelo Cole–Cole. A partir de estos y de las señales instantáneas de la excitación, se calcula la densidad volumétrica de potencia disipada  $P_v$ .

La inicialización de los parámetros se realiza en dos fases: (i) estimación analítica a partir del *datasheet* del fabricante y (ii) refinamiento de los mismos tras un primer entrenamiento, lo que acelera la convergencia y mejora la estabilidad.

## Resultados

El modelo se ha entrenado y evaluado sobre ferritas comerciales del dataset público MagNet [3]: 3C90, 3C95, N49, N87, 77, 3E6 y 3F4, cubriendo con tres formas de onda (sinusoidal, trapezoidal y triangular):  $f$  de 50 kHz a 1 MHz,  $\Delta B$  de 10 a 300 mT y  $T$  de 25 a 90 °C. Cada material se entrena durante 20000 épocas con optimizador Adam ( $LR = 5 \cdot 10^{-3}$ , *scheduler* OneCycleLR, *early-stopping*) y partición 60/40 de validación.

La tabla 1 resume el error relativo. El modelo alcanza un error medio inferior al 5 % en todas las ferritas, con percentil 95 inferior al 13 % en el peor caso. Estos resultados son comparables a los modelos ML del MagNet Challenge [6], con la ventaja de conservar la interpretabilidad física del material.

Tabla 1. Error relativo del modelo vs. pérdidas reales.

| Material | Media [%] | Mediana [%] | P95 [%] |
|----------|-----------|-------------|---------|
| 3C90     | 3,2       | 2,4         | 8,7     |
| 3C95     | 2,8       | 2,1         | 7,5     |
| N87      | 3,4       | 2,6         | 9,1     |
| N49      | 4,1       | 3,1         | 11,3    |
| 77       | 3,7       | 2,8         | 9,8     |
| 3F4      | 4,5       | 3,3         | 12,9    |
| 3E6      | 3,9       | 2,9         | 10,2    |

## Discusión

La principal aportación de este trabajo es obtener precisiones equivalentes a las de modelos ML puros, manteniendo la interpretabilidad física de los materiales. Cada parámetro de la capa de salida tiene un significado claro en el modelo Cole–Cole (permeabilidad de alta frecuencia, dispersión dieléctrica, frecuencia de relajación, exponentes de modulación). Esto facilita la transferencia entre materiales de una misma familia, ya que los valores

finales de los parámetros obtenidos para un material sirven como semillas de inicialización para otros.

Frente a los enfoques ML puros [5,6], el modelo propuesto requiere aproximadamente un orden de magnitud menos de muestras de entrenamiento para alcanzar errores comparables. Lo cual, es consecuencia directa de la restricción física impuesta por la estructura Cole–Cole. Además, la descomposición en dos términos de las pérdidas permite identificar qué mecanismo domina en cada material.

## Conclusiones

Se ha desarrollado y validado una PINN para la estimación de las pérdidas magnéticas en núcleos de ferrita bajo excitaciones arbitrarias. La red aprende siete parámetros del modelo de permeabilidad y calcula la potencia disipada mediante la parametrización física. El modelo alcanza un error medio inferior al 5 % sobre los materiales del *dataset* de MagNet, combinando la precisión del aprendizaje automático con la interpretabilidad del modelado físico.

## AGRADECIMIENTOS

Este trabajo ha sido financiado por el Ministerio de Ciencia e Innovación (MCIN/AEI/10.13039/501100011033) y por la Unión Europea a través de los programas FEDER y NextGenerationEU/PRTR. Asimismo, el proyecto se enmarca en la ayuda del Gobierno Vasco dentro del programa ELKARTEK 2025 (expediente KK-2025/00012) en el proyecto DBaskin. Los autores agradecen también el apoyo de las ayudas DGA-FSE y del Gobierno de Aragón a través del programa de Grupos de Investigación de Referencia, así como la colaboración y el soporte del Centro de Tecnologías Aeronáuticas (CTA).

## REFERENCIAS

- [1] C. P. Steinmetz, “On the law of hysteresis,” *Trans. AIEE*, vol. 9, pp. 3–64, 1892 (reimpr. *Proc. IEEE*, vol. 72, no. 2, pp. 197–221, 1984).
- [2] K. Venkatachalam, C. R. Sullivan, T. Abdallah and H. Tacca, “Accurate prediction of ferrite core loss with nonsinusoidal waveforms using only Steinmetz parameters,” in *Proc. IEEE COMPEL*, 2002, pp. 36–41.
- [3] H. Li, D. Serrano, T. Guillod et al., “MagNet: An open-source database for data-driven magnetic core loss modeling,” in *Proc. IEEE APEC*, Houston, TX, 2022, pp. 588–595.
- [4] H. Li, D. Serrano, S. Wang and M. Chen, “MagNet-AI: Neural network as datasheet for magnetics modeling and material recommendation,” *IEEE Trans. Power Electron.*, vol. 38, no. 12, pp. 15846–15860, 2023.
- [5] D. Serrano, H. Li, S. Wang and M. Chen, “Why MagNet: Quantifying the complexity of modeling power magnetic material characteristics,” *IEEE Trans. Power Electron.*, vol. 38, no. 12, pp. 15861–15873, 2023.
- [6] M. Chen, H. Li, D. Serrano et al., “MagNet Challenge for data-driven power magnetics modeling,” *IEEE Open J. Power Electron.*, vol. 5, pp. 1687–1703, 2024.
- [7] M. Raissi, P. Perdikaris and G. E. Karniadakis, “Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear PDEs,” *J. Comput. Phys.*, vol. 378, pp. 686–707, 2019.
- [8] Y. Guo, Z. Li, X. Wang et al., “A physics-informed neural network with hybrid architecture for magnetic core loss prediction,” *Magnetochemistry*, vol. 12, no. 1, Art. no. 7, 2026.
- [9] K. S. Cole and R. H. Cole, “Dispersion and absorption in dielectrics. I. Alternating current characteristics,” *J. Chem. Phys.*, vol. 9, no. 4, pp. 341–351, 1941.

## Figuras




Figura 1. Diagrama de red neuronal utilizada.




Figura 2. Evolución de las curvas de aprendizaje para varias temperaturas.




Figura 3. Dispersión de valores y error % para el material 3C90.




Figura 4. Histogramas de error obtenidos para el material 3C90.