

Estimación paramétrica en dispositivos de bajo coste mediante redes neuronales.

Vicente Martínez, J.^{a,*}, Prats Mindán, M.^a, Moya Lasheras, E.^a, Ramírez Laboreo, É.^a, Blasco Rueda, N.^b

^aDepartamento de Informática e Ingeniería de Sistemas (DIIS) e Instituto de Investigación en Ingeniería de Aragón (I3A),
Universidad de Zaragoza, Calle María de Luna 1, 50018, Zaragoza, España

^bResearch and Development Department, Induction Technology, Product Division Cookers, BSH Home Appliances Group, Zaragoza 50016, España

To cite this article: Vicente Martínez, J., Prats Mindán, M., Moya Lasheras, E., Ramírez Laboreo, É., Blasco Rueda, N. 2025. Parametric estimation in low-cost devices using neural networks. Actas del I Simposio CEA de los GT: Ingeniería de Control - Modelado, Simulación y Optimización - Educación en Automática. Sevilla, España.

Resumen

En este trabajo se presenta un enfoque basado en el uso de redes neuronales para la estimación rápida y automatizada de parámetros en sistemas físicos no lineales. La producción en masa de dispositivos de bajo coste generalmente implica unas tolerancias físicas que generan una variabilidad no despreciable en el sistema, afectando a su modelado y posterior control. Un claro ejemplo de ello son los relés electromecánicos. El control de estos dispositivos presenta un reto importante, ya que su dinámica es no lineal, y las medidas que se pueden obtener con el dispositivo funcionando en la aplicación final son limitadas. De esta forma, disponer de un modelo dinámico preciso y fiable de estos dispositivos permite, entre otras cosas, diseñar estrategias de control de la posición de su contacto móvil que permitan lograr que su llegada al contacto fijo sea suave, reduciendo problemas de ruido y desgaste. En este sentido, llevamos años trabajando con el modelado, estimación y control de estos dispositivos en colaboración con empresas que los utilizan (Ramírez Laboreo, 2019; Ramirez-Laboreo et al., 2019, 2023). El principal obstáculo en la aplicación de estos modelos está en la identificación de sus parámetros, puesto que al tratarse de sistemas no lineales, los métodos clásicos de estimación paramétrica (Ljung, 1999) implican un proceso lento y en parte artesanal. Además, en el caso de sistemas como los relés, que presentan fenómenos de histéresis magnética, el proceso se vuelve más complejo, requiriendo llevar a cabo ajustes manuales y suposiciones que dificultan su aplicación a nivel industrial.

La estimación de parámetros mediante redes neuronales para controlar dispositivos destinados al mercado presenta algunos desafíos, principalmente relacionados con la robustez y la fiabilidad de los resultados. Aunque la estimación paramétrica con redes neuronales no es un concepto novedoso (Samad and Mathur, 1992), los avances recientes en las tecnologías disponibles y en el rendimiento de las redes neuronales, principalmente gracias a su éxito en el procesamiento de imágenes y textos, han aumentado la viabilidad práctica de esta solución. Actualmente existen distintos ejemplos en la literatura de estimación de parámetros físicos con redes neuronales a partir de señales de audio (Gabrielli et al., 2017), o en redes de fibra óptica (Jiang et al., 2022), entre otros, demostrando su potencial en contextos diversos.

Con el apoyo en esta aplicación, se propone el uso de redes neuronales para obtener una aproximación inicial de los parámetros físicos que definen la dinámica del sistema, combinando capas convolucionales para procesar señales temporales y capas densas para calcular los parámetros. Dado que el objetivo no es modelar la dinámica temporal del sistema, sino obtener estimaciones directas de los parámetros que definen su comportamiento, se propone usar redes convolucionales que combinen la información de todo un experimento en lugar de recurrentes que permitan obtener una estimación instantánea a instantánea. Este enfoque destaca por su capacidad de realizar estimaciones a partir de un único ensayo, haciéndolo especialmente atractivo para aplicaciones industriales donde la velocidad y la automatización son cruciales. Además, este método ofrece una ventaja significativa en situaciones donde los valores iniciales de los parámetros son inciertos o desconocidos, proporcionando estimaciones iniciales que pueden ser refinadas mediante métodos de optimización, si es necesario. En resumen, esta técnica permite trasladar la complejidad computacional a un paso previo, garantizando una estimación rápida y eficiente en la aplicación final.

En este trabajo se ha optado por trabajar con un modelo híbrido no lineal de tercer orden del relé cuya dinámica depende de 6 parámetros físicos, $\hat{k}_g$, $\hat{k}_s$, $\hat{F}_k$, λ_{sat} , $\hat{R}_{co}$ y R (Ramírez Laboreo, 2019). Al sistema se aplica una tensión, u , y se mide la intensidad

*Autor para correspondencia: j.vicente@unizar.es

consumida, i , y el tiempo de final del ensayo, t_{fin} . Teniendo en cuenta esto, la primera parte de la red tiene como objetivo calcular características similares a las derivadas temporales de las señales, además de filtrar y suavizar las señales cuando sea necesario. Sin embargo, al ser un sistema no lineal, estas características no tienen por qué ser exactamente las derivadas, pudiendo ser por ejemplo combinaciones o aproximaciones. Por ello, para optimizar el proceso de entrenamiento, se preentrena esta primera etapa para calcular derivadas temporales y, posteriormente, se permite que la red completa ajuste sus pesos según lo que realmente necesite para realizar la estimación. A continuación, las señales pasan por distintas capas que buscan eliminar la dimensión temporal y conseguir extraer las características que permitan estimar los parámetros físicos. La Figura 1 muestra un esquema conceptual de la red completa. Para eliminar la dependencia con respecto a la duración del ensayo en la primera parte de la red, se utiliza un tiempo normalizado $\tau = t/t_{fin}$, siendo t el tiempo.




Figura 1: Esquema conceptual de la red neuronal propuesta.

En las pruebas realizadas se han utilizado 500 épocas de entrenamiento con 50 000 conjuntos de datos obtenidos mediante la simulación del modelo físico (75 % para entrenamiento y 25 % para validación) en las que se ha generado la salida del sistema con una tensión senoidal amortiguada con distintas frecuencias y amplitudes. Los parámetros para cada simulación se determinan de forma aleatoria, a partir de unos límites fijados por los valores nominales. En la Figura 2 se muestra un análisis de los resultados obtenidos en validación, normalizados al valor de referencia, junto con el coeficiente R^2 para cada parámetro. En estos, cinco de los seis parámetros presentan un coeficiente R^2 elevado, apoyando la viabilidad de esta propuesta. No obstante, se han observado peores resultados en uno de ellos, $\hat{k}_s$. Por ello, los siguientes trabajos se centrarán en estudiar la estimación de este parámetro, además de incluir datos de experimentos con dispositivos reales.




Figura 2: Valores estimados frente a los reales, normalizados al valor de referencia, junto al coeficiente R^2 obtenidos en la validación de la red.

Agradecimientos

Esta publicación es parte del proyecto de I+D+i CPP2021-008938, financiado por MCIN/AEI/10.13039/501100011033 y por la Unión Europea NextGenerationEU/PRTR. También ha contado con financiación de Fundación Ibercaja y la Universidad de Zaragoza, mediante el proyecto JIUZ2023-IA-07, y del Gobierno de Aragón, mediante subvenciones para la contratación de personal investigador predoctoral en formación 2024-2028 (contrato de J. Vicente Martínez) y subvenciones destinadas a fomentar la actividad investigadora de los grupos de investigación (grupo “Robótica, Visión por Computador e Inteligencia Artificial”, T45_23R).

Referencias

- Gabrielli, L., Tomassetti, S., Squartini, S., Zinato, C., 2017. Introducing deep machine learning for parameter estimation in physical modelling. In: Proc. 20th Int. Conf. Digital Audio Effects (DAFx-17). Edinburgh, United Kingdom, pp. 11–16.
- Jiang, X., Wang, D., Chen, X., Zhang, M., 2022. Physics-informed neural network for optical fiber parameter estimation from the nonlinear Schrödinger equation. J. Lightwave Technology 40 (21), 7095–7105. DOI: 10.1109/JLT.2022.3199782
- Ljung, L., 1999. System Identification: Theory for the User. Prentice Hall PTR.
- Ramírez Laboreo, É., Octubre 2019. Modeling and control of reluctance actuators. Tesis doctoral, Universidad de Zaragoza.
- Ramírez-Laboreo, E., Moya-Lasheras, E., Sagues, C., 2019. Real-time electromagnetic estimation for reluctance actuators. IEEE Trans. Ind. Electron. 66 (3), 1952–1961. DOI: 10.1109/TIE.2018.2838077
- Ramírez-Laboreo, E., Moya-Lasheras, E., Sagues, C., 2023. Design of a perfect-tracking soft-landing controller for electromagnetic switching devices. Nonlinear Dynamics 111 (1), 427–438. DOI: 10.1007/s11071-022-07853-1
- Samad, T., Mathur, A., 1992. Parameter estimation for process control with neural networks. Int. J. Approximate Reasoning 7 (3), 149–164. DOI: 10.1016/0888-613X(92)90008-N