

Estudio del comportamiento de modelos neuronales de sistemas MIMO acoplados

Iturbe, L.^a, Irigoyen, E.^{a,*}, Larrea, M.^b, Gomez-Garay, V.^a, Sanchís, J.^c

^aUPV/EHU, Escuela de Ingeniería de Bilbao, Pl. Ingeniero Torres Quevedo, 1, 48013, Bilbao, España.

^bUPV/EHU, Escuela de Ingeniería de Gipuzkoa, Plaza Europa, 1, 20018 Donostia / San Sebastián

^cDepartamento de Ingeniería de Sistemas y Automática, Universitat Politècnica de Valencia, Camino de Vera, nº14, 46022, Valencia, España.

To cite this article: Iturbe, L., Irigoyen, E., Larrea, M., Gomez-Garay, V., Sanchís, J. 2023. Study of the neural models behaviour of coupled MIMO systems. XLIV Jornadas de Automática, 162-167. <https://doi.org/10.17979/spudc.9788497498609.162>

Resumen

En la actualidad, son muchos los trabajos donde se utilizan modelos neuronales para reproducir las dinámicas de complejos sistemas no lineales. Existe un amplio estudio para propuestas que contemplan sistemas monovariantes. Pero cuando se trata de lograr un modelo integral de un sistema multivariable (MIMO) son muchas las incógnitas que se presentan, además de las clásicas relacionadas con la capacidad de la red neuronal de reproducir la salida del sistema en predicciones a una muestra o con la robustez de dicho modelo neuronal a determinadas perturbaciones o incertidumbres aparecidas en el sistema. Cuando se trata de trabajar con sistemas MIMO surgen nuevos retos como son la predicción a futuro realizada por dicho modelo y los acoplamientos inherentes en el mismo. Por ello, este trabajo propone introducir en la validación de modelos neuronales un análisis metodológico donde se consideren todas estas variantes. Como caso de uso, este trabajo presentará el modelo neuronal de un sistema de refrigeración de una pila de combustible tipo PEM.

Palabras clave: Modelo neuronal, Sistemas multivariantes, Dinámicas complejas, Variables acopladas, Control Predictivo

Study of the neural models behaviour of coupled MIMO systems.

Abstract

At present, there are many works where neural models are used to reproduce the dynamics of complex non-linear systems. There is an extensive study for proposals that contemplate monovariant systems. But when it comes to achieving an integral model of a multivariable system (MIMO), many issues arise, in addition to the classic ones related to the capacity of the neural network to reproduce the output of the system in one-sample predictions or with the robustness of the neural model to certain perturbations or uncertainties appearing in the system. When it comes to working with MIMO systems, new challenges arise, such as the forward prediction performed by the model and the couplings inherent in it. Therefore, this work proposes to introduce in the validation of neural models a methodological analysis where all these variants are considered. As a use case, this work will present the neural model of a PEM fuel cell cooling system.

Keywords: Neural Model, Multivariable Systems, Complex Dynamics, Coupling Variables, Predictive Control

1. Introducción

La utilización de las Redes Neuronales Artificiales (RNA) como herramienta de modelización está ampliamente establecido desde hace lustros. Prueba de ello son los innumerables trabajos que presentan sus desarrollos apoyados en modelos neuronales, con independencia del tipo de estructura emplea-

do, los cuales se ajustan según el problema a resolver, como en los trabajos de Poznyak et al. (2019), Martínez et al. (2023) o Continelli et al. (2023). En lo que respecta a la modelización de sistemas reales con dinámicas complejas, las cuales engloban comportamientos no lineales, saturaciones, modificación temporal de parámetros, entre otras, es frecuente encontrarse con

*Autor para correspondencia: eloy.irigoyen@ehu.eus
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

RNA recurrentes para realizar una estimación de la salida de dichos sistemas. Ejemplos recientes de estas topologías se pueden encontrar en trabajos como el artículo de Orang et al. (2022) donde se hace referencia a diversos dominios de aplicación de las estructuras neuronales *Fuzzy Cognitive Maps*. Otro ejemplo se encuentra en el trabajo de Mao and Sejdic (2022) donde se presentan múltiples soluciones en el área de la fisiología.

En lo que respecta al área de la Automática y el Control, estos modelos neuronales son utilizados por diversas estrategias de control avanzado (p.e. control predictivo) que necesitan de un modelo del sistema real y en los casos donde es muy complicado disponer de un modelo aproximado definido matemáticamente o mediante algún otro método de identificación Calle Chojeda et al. (2022); Gomez et al. (2022); Zabaljauregi et al. (2023). Estos modelos neuronales dinámicos se logran en todos los casos mediante una buena metodología en la fase de entrenamiento de dichas RNA, considerando aspectos tan relevantes como: el rango de operación del sistema real, las dinámicas predominantes en el tiempo que marcan los períodos de muestreo adecuados, una experimentación ajustada al rango de trabajo del sistema para recoger ejemplos de funcionamiento representativos del sistema y un estudio detallado de las posibles estructuras a configurar con la RNA elegida (Zhao et al. (2023); Alhajeri et al. (2021); Li and Tong (2021); Zhang et al. (2023); Friese et al. (2023)).

Una posible debilidad de los procesos de selección del mejor modelo neuronal radica en un estudio simplificado de su comportamiento a la hora de reproducir la salida de un sistema real. Sobre todo, este estudio se ve más debilitado cuando lo que se desea es disponer de una RNA que modelice un sistema multivariable, más aún si en dicho sistema sus variables controladas están significativamente acopladas. Es muy común encontrarse con estudios que basan la selección del mejor modelo neuronal en un proceso de validación que valora el error cometido en la predicción a una muestra en el tiempo. Ciertamente es que en ciertas estrategias de control esto puede ser suficiente para garantizar un desempeño satisfactorio del control aplicado Calle Chojeda et al. (2022); Gomez et al. (2022), más aún si se trata de un sistema monovariable Continelli et al. (2023). Pero esto puede resultar poco adecuado si la estrategia de control requiere de un modelo que, además de la estimación a un período de muestreo, necesite proyectar dichas estimaciones a futuro (p.e. control predictivo) y no se haya tenido en cuenta esta cuestión en los mencionados procesos de validación del mejor modelo neuronal. Además, este aspecto se hace especialmente crítico si el problema de control aborda sistemas multivariables, donde la influencia de las entradas afecta a todas las salidas, mostrando un comportamiento de acoplamiento entre sus variables. Tampoco es muy frecuente encontrarse estudios de los modelos neuronales seleccionados, en cuanto a su robustez en la estrategia de control elegida en lo referente a incertidumbres en el modelo o la aparición de perturbaciones. Ciertamente es que para estas últimas cuestiones existen técnicas de control que ofrecen soluciones a dichos inconvenientes, pero no deja de ser conveniente robustecer el proceso de selección del mejor modelo neuronal, si se decide trabajar en esta línea, considerando todos los aspectos mencionados.

Este trabajo desea ofrecer una propuesta de desarrollo metodológico en lo que respecta a la selección de la mejor estruc-

tura de RNA en los procesos de entrenamientos de las mismas, cuando se desea emular el comportamiento de sistemas reales con complejas dinámicas y que muestran acoplamiento entre sus variables. Se presentará como caso de uso un sistema de refrigeración de una pila de combustible tipo PEM, en cuyo estudio comparativo de modelos neuronales se aplicarán diferentes pautas para elegir dicho modelo. A continuación, se presentará sintéticamente el sistema multivariable a controlar. Posteriormente, se determinará en qué fases se divide el proceso de validación propuesto. Se seguirá con una presentación comparativa de resultados por fase. Finalmente, se concluirá remarcando las aportaciones propuestas y los logros alcanzados en este trabajo.

2. Sistema de refrigeración de una pila de combustible tipo PEM

El caso de uso sobre el que se va a desarrollar este trabajo está integrado en el sistema de control de un intercambiador de calor como el mostrado en la Figura 1, que cumple la función de refrigerar a su vez a una pila de combustible tipo PEM diseñada por Navarro Giménez et al. (2019) en el Grupo de Control Predictivo y Optimización Heurística de la UPV. En este sistema de refrigeración se desea controlar las temperaturas de entrada $T_{w_{in}}(t)$ y salida $T_{w_{out}}(t)$ a la pila de combustible, actuando sobre los caudales $VM_{T_{w_{in}}}(t)$ y $VM_{T_{w_{out}}}(t)$ del intercambiador de calor interno, junto a una perturbación medible $i(t)$ (intensidad) derivada de la demanda de la red (Navarro Giménez et al. (2020)). Todo ello se realizará en torno a un punto de trabajo de la pila PEM, donde la temperatura de funcionamiento interno es 54.45°C , la temperatura ambiente es 30°C y se desea controlar las mencionadas temperaturas de entrada y salida del fluido de refrigeración a la pila PEM a los valores de 60°C y 65°C , respectivamente.

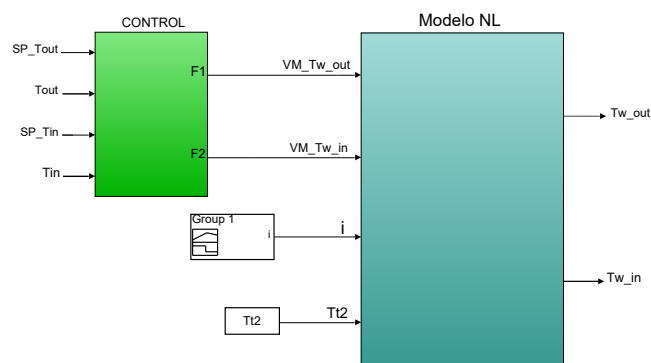


Figura 1: Esquema de control de temperatura - PEMFC

El modelo neuronal a extraer sería el resultante de tomar, con período de muestreo $T_s = 0,1s$, las siguientes variables: Como entradas los caudales muestreados $VM_{T_{w_{in}}}(k)$ y $VM_{T_{w_{out}}}(k)$, junto a la demanda $i(k)$; Como salidas las temperaturas $T_{w_{in}}(k)$ y $T_{w_{out}}(k)$. En una simulación realizada con controladores lineales de configuración PI se ha obtenido la evolución de ambas temperaturas, representadas en la Figura 2, las cuales son controladas con respecto a un punto de trabajo de la pila de combustible ($54,45^{\circ}\text{C}$), donde se han alterado las demandas de potencia abastecida por la pila $i(k)$, lo que ocasiona variaciones en la temperatura interna de la propia pila PEM.




Figura 2: Señales I/O sistema PEMFC

3. Proceso de validación de un modelo neuronal MIMO

Como en todo proceso de generación y ajuste de modelos neuronales, previo a analizar cuál es la RNA más eficiente en lo que respecta a la reproducción del comportamiento dinámico de un sistema y la estimación de sus variables de salida, debe de diseñarse un conjunto de experimentos con el sistema real (o simulado) para llevar a cabo la etapa previa de entrenamiento de forma correcta. Este conjunto de experimentos debe abarcar todo el espacio de trabajo en el cual se desea controlar el sistema a modelar, recorriendo de forma calibrada diferentes puntos de trabajo que ofrezcan información de las diferentes dinámicas implícitas en dicho sistema. Además de generar este conjunto de experimentos, dicho conjunto se distribuirá entre los que deben ser empleados en la etapa de entrenamiento y aquellos que lo serán en la de validación, ya que esto podrá garantizar que los resultados serán analizados, entre otras cuestiones, en la medida de la capacidad de generalización que tiene el modelo neuronal. Por otro lado, otra estrategia adecuada en la etapa de entrenamiento para garantizar la generalización del modelo neuronal seleccionado es replicar el entrenamiento de una misma estructura en un número de veces significativo (p.e. 10 veces), a fin de evitar malos resultados derivados del sobre-entrenamiento de una única estructura. Estos entrenamientos deben tener suficientes ejemplos (muestras), ya que es posible lograrlo en el diseño de los experimentos, como para que no se tengan que utilizar métodos como la validación cruzada.

En el presente trabajo se han estudiado los rangos en torno a $T_{w_{in}} = 60 \pm 2^\circ C$ y $T_{w_{out}} = 65 \pm 2^\circ C$, junto a $i(t) \in [140, 210]$, además de las acciones de control $VM_{T_{w_{in}}} \in [2, 10]$ y $VM_{T_{w_{out}}} \in [2, 10]$. Por otro lado, se ha considerado estudiar estructuras de RNA con una configuración para la capa oculta de un número de neuronas $N \in [4, 20]$ y con una repetición de 10 entrenamientos por cada una de las estructuras creadas (cuya inicialización de parámetros de la RNA es siempre aleatoria).

Si bien la etapa de entrenamiento se realiza habitualmente obedeciendo a los estándares de ajuste de parámetros de la

RNA, basado en el estudio del gradiente del error dado en la salida del sistema a modelar, la posterior etapa de validación queda enriquecida si al análisis tradicional de los errores de salida se les añaden nuevas pautas como las establecidas en el presente trabajo. De hecho, este planteamiento de nuevas pautas en la validación podría ser realizado, tanto si el entrenamiento de las estructuras neuronales se hiciese desde un punto de vista de lazoabierto (openloop, según se plantea en herramientas como MATLAB©), o de lazo-cerrado. En lo que corresponde a los entrenamientos y validaciones tradicionales, lo habitual es encontrarse tablas comparativas ofreciendo resultados de índices de error como el error cuadrático medio (del inglés, MSE) o el error absoluto medio (del inglés, MAE).

Lo que se propone añadir en el presente trabajo es una serie de medidas de validación complementarias que permitan analizar con más detalle cuál de las RNA entrenadas cumplirá de forma más satisfactoria los requerimientos de la estrategia de control seleccionada en cada caso. Dichas medidas quedan pautadas en la siguiente lista:

- Error MSE calculado en lazo cerrado. Se compararán los resultados obtenidos de analizar cuál es el error de la salida ante estimaciones en horizontes de un número elevado de muestras.
- Acoplamiento de las variables de salida. Se comparará el nivel de acoplamiento que tiene el sistema a controlar mediante experimentación, con respecto al mismo efecto ofrecido por cada uno de los modelos neuronales.
- Robustez del modelo neuronal ante perturbaciones e incertidumbres. Si bien estas cuestiones están vinculadas principalmente a la estrategia de control seleccionada, el comportamiento del modelo seleccionado debe permitir una corrección satisfactoria de los efectos mencionados.

En el siguiente capítulo se mostrarán comparativas gráficas y numéricas que apoyan una mejor selección del modelo neuronal que será utilizado para reproducir adecuadamente el comportamiento dinámico del sistema MIMO utilizado en este trabajo; el sistema de refrigeración de una pila de combustible tipo PEM, Navarro Giménez et al. (2020).

4. Resultados

Con objeto de validar el estudio de las pautas adoptadas para mejorar el proceso de selección de un modelo neuronal candidato, se van a presentar los resultados obtenidos en las comparativas establecidas entre las metodologías tradicionales y la propuesta en este trabajo. Se presenta a continuación, mediante las tablas y figuras correspondientes, las diferencias encontradas al seleccionar los mejores modelos neuronales candidatos, estableciendo fundamentalmente comparativas sobre los errores establecidos al estimar dicho modelo las futuras salidas del sistema MIMO elegido para este estudio.

4.1. Estimación de salidas futuras dentro de un horizonte definido

En esta sección se presentan los resultados del estudio comparativo del comportamiento del modelo neuronal en estimaciones de salidas a muestras futuras, cuando dichas estimaciones

se deben realizar a partir de sus propias estimaciones previas (configuración lazo-cerrado).

A partir de los procesos de entrenamiento y validación tradicionales realizados bajo los criterios de modificación de parámetros y selección de la estructura de la RNA NARX indicada en el capítulo anterior, los resultados obtenidos para la selección tradicional del mejor modelo neuronal candidato dieron lugar a las mejores estructuras NARX mostradas en la Tabla 1. Esta selección fue hecha teniendo en cuenta exclusivamente el error MSE que ofrecía cada red NARX en su reproducción de las salidas, para la configuración lazo-abierto.

Retardos In / Out	Num Neur	MSE MIMO	MSE Tw_in	MSE Tw_out
[0] / [1:4]	4	4,02E-08	2,48E-08	1,54E-08
[0:3] / [1:4]	7	1,54E-06	7,30E-07	8,13E-07
[0:1] / [1:3]	10	1,84E-06	1,04E-06	7,91E-07
[0:1] / [1:4]	6	2,34E-06	1,61E-06	7,27E-07
[0:2] / [1:4]	4	2,54E-06	2,13E-06	4,10E-07
[0] / [1:3]	7	4,33E-06	2,43E-06	1,91E-06
[0:2] / [1:4]	9	4,35E-06	3,08E-06	1,27E-06
[0:3] / [1:2]	5	5,05E-06	2,65E-06	2,40E-06
[0:2] / [1:3]	5	5,07E-06	3,15E-06	1,92E-06
[0:2] / [1:3]	7	5,46E-06	2,35E-06	3,12E-06

Tabla 1: Selección modelo neuronal: lazo-abierto

Si bien estas estructuras elegidas como las mejores ofrecían unos resultados de validación muy satisfactorios en lo que respecta a la estimación de la muestra siguiente, no mostraron un comportamiento muy adecuado en configuración lazo-cerrado, tal y como se muestra en la Figura 3.

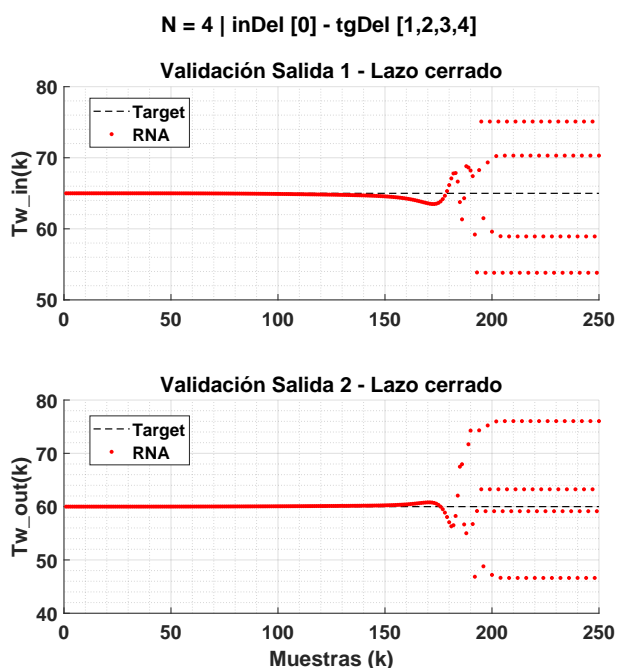


Figura 3: Mejor modelo neuronal: Sel.OL; Sim.CL

Por el contrario, si el criterio de selección de la mejor red NARX se fundamenta en los resultados que ofrece cada estructura en cuanto a la reproducción de las salidas para la configura-

ción lazo-cerrado, se puede observar un mejor comportamiento tal y como se muestra en la Figura 4, a pesar de que los errores presentados en lazo-abierto son algo superiores a la selección anterior, tal y como se puede ver en la Tabla 2.

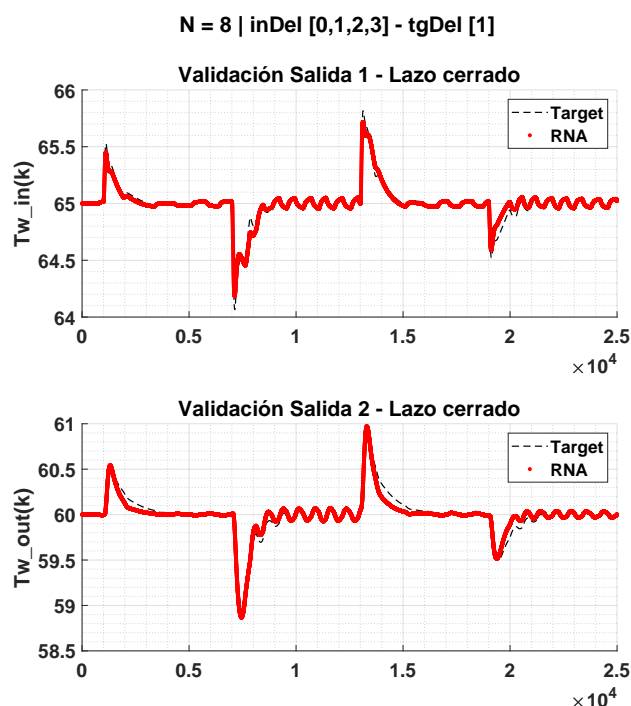


Figura 4: Mejor modelo neuronal: Sel.CL; Sim.CL

Retardos In / Out	Num Neur	MSE MIMO	MSE Tw_in	MSE Tw_out
[0:3] / [1]	8	0,0041	0,0012	0,0028
[0:1] / [1]	9	0,0053	0,0018	0,0035
[0:3] / [1]	6	0,0054	0,002	0,0033
[0:1] / [1]	5	0,0057	0,0019	0,0037
[0:2] / [1]	6	0,0061	0,0022	0,0039
[0:1] / [1]	7	0,0064	0,0027	0,0036
[0:2] / [1]	9	0,0065	0,0025	0,0039
[0:3] / [1]	4	0,0067	0,003	0,0036
[0:3] / [1]	5	0,0068	0,003	0,0038
[0:1] / [1]	4	0,0072	0,003	0,0042

Tabla 2: Selección modelo neuronal: lazo-cerrado

A pesar de que el modelo neuronal seleccionado bajo el criterio de lazo-abierto no diverge significativamente en las primeras muestras futuras cuando se realiza una simulación en lazo-cerrado, ha demostrado inestabilizarse y entrar en un comportamiento oscilatorio, tal y como se muestra en la Figura 3. Por el contrario, si el criterio de selección es el de lazo-cerrado, a pesar de evolucionar en el tiempo (hasta 25000 muestras) el modelo neuronal seleccionado no muestra divergencias significativas que lo inestabilicen (Figura 4). Para establecer una comparativa a un número de muestras futuras (20 máximo) acorde a lo que suelen utilizar las estrategias de control que emplean en sus configuraciones los modelos neuronales, se presenta la Figura 5, donde se aprecia el grado de divergencia que podría existir en cada uno de los casos.




Figura 5: Comparación: divergencias(MSE) vs H

Por lo tanto, del análisis de los resultados se puede desprender que, una buena praxis de cara a seleccionar la estructura neuronal NARX que sirva como modelo MIMO y que mejor reproduzca la dinámica de estos sistemas, es aquella que se desarrolla en la etapa de validación mediante la evaluación de las pruebas realizadas en configuración de lazo-cerrado.

4.2. Acoplamiento de las variables del sistema

Cuando se están modelizando sistemas multivariables es necesario tener en cuenta que un modelo neuronal integral aún a todas las entradas y salidas del sistema MIMO en una única RNA, por lo que debido a su estructura siempre habrá un acoplamiento, por pequeño que sea, entre las variables del sistema (entradas activadoras y salidas estimadas). Por ello, se hace igualmente necesario conocer cuál es el nivel de acoplamiento real de las variables del sistema mediante pruebas experimentales y comparar dichos acoplamientos con los que ofrecen los modelos neuronales seleccionados del conjunto de estructuras entrenadas.

En el presente trabajo se ha ensayado con el sistema de la Figura 1. El sistema se ha simulado en un punto de trabajo determinado ($T_{w_{in}} = 60^{\circ}C$ y $T_{w_{out}} = 65^{\circ}C$) y una vez alcanzado dicho punto se han generado variaciones específicas sobre las entradas del sistema: $VM_{T_{w_{in}}}(k)$, $VM_{T_{w_{out}}}(k)$ e $i(k)$. De igual manera, se ha estimulado independientemente cada una de las entradas del modelo neuronal para medir las variaciones que producen en ambas salidas: $T_{w_{in}}(k)$ y $T_{w_{out}}(k)$. Las pruebas para realizar el mencionado estudio han sido realizadas a lo largo de 10 segundos, utilizando el mismo período de muestreo que se configuró en la etapa de entrenamiento de las RNA, $T_s = 0,1$. El punto de operación empleado se ha fijado en valores de entrada de $VM_{T_{w_{in}}} = 5,00$, $VM_{T_{w_{out}}} = 4,33$ e $i = 170$, con sus correspondientes valores de salida de $T_{w_{in}} = 60$ y $T_{w_{out}} = 65$. El estudio de acoplamientos del modelo matemático integrado en el sistema de control implementado en Simulink ha dado como resultado la Tabla 3.

valor $T_{w_{in}}$	Δ $T_{w_{in}}$	valor $T_{w_{out}}$	Δ $T_{w_{out}}$	Prueba realizada
60,0008	-0,0008	64,9975	0,0025	Punto Operación
59,9958	-0,0050	64,9970	-0,0004	+10 % $VM_{T_{w_{in}}}$
59,9942	-0,0066	64,9969	-0,0005	+20 % $VM_{T_{w_{in}}}$
60,0064	0,0056	64,9979	0,0005	-10 % $VM_{T_{w_{in}}}$
60,0083	0,0075	64,9981	0,0006	-20 % $VM_{T_{w_{in}}}$
60,0168	0,0160	64,9548	-0,0426	+10 % $VM_{T_{w_{out}}}$
60,0688	0,0680	64,8194	-0,1780	+20 % $VM_{T_{w_{out}}}$
59,9828	-0,0179	65,0454	0,0480	-10 % $VM_{T_{w_{out}}}$
59,9186	-0,0822	65,2186	0,2212	-20 % $VM_{T_{w_{out}}}$
60,0041	0,0033	65,2854	0,2880	+10 % i
60,0064	0,0056	65,5536	0,5561	+20 % i
59,9980	-0,0028	64,7554	-0,2421	-10 % i
59,9962	-0,0046	64,5468	-0,4507	-20 % i

 Tabla 3: Influencia del acoplamiento I-O: $\Delta vs \%$

Del análisis de las pruebas resultantes se ha observado que la variación de la demanda $i(k)$ es la que mayor influencia tiene sobre las salidas. Además, en lo que respecta a las entradas es especialmente interesante observar que la entrada $VM_{T_{w_{out}}}$ afecta mayormente a su salida contraria $T_{w_{in}}$.

5. Conclusiones

Este trabajo ha presentado un método de validación de modelos neuronales de sistemas MIMO con complejas dinámicas, pautado según criterios complementarios que permiten mejorar el proceso de selección de la estructura de RNA tipo NARX que reproduzca de forma satisfactoria el comportamiento de un sistema MIMO. En concreto, este trabajo ha utilizado como caso de uso el sistema de refrigeración de una pila de combustibles de tipo PEM, modelizando un sistema multivariables de 3 entradas (2 acciones de control y 1 perturbación medible) y 2 salidas (2 variables controladas, las temperaturas del intercambiador de calor).

Los resultados han demostrado lo importante que es considerar incorporar las pautas propuestas en este trabajo en los procesos de validación, ofreciendo los modelos neuronales seleccionados mejores estimaciones de las salidas, en lo que respecta a la reproducción del comportamiento dinámico de los sistema MIMO.

Agradecimientos

Este trabajo se ha desarrollado en el marco del proyecto PID2020-120087GB-C22 financiado por el Ministerio de Ciencia e Innovación del Gobierno de España.

(AEI / <http://dx.doi.org/10.13039/501100011033>)

Referencias

- Alhajeri, M. S., Wu, Z., Rincon, D., Albalawi, F., Christofides, P. D., 2021. Estimation-based predictive control of nonlinear processes using recurrent neural networks**financial support from the national science foundation and the department of energy is gratefully acknowledged. mohammed alhajeri would like to express his sincere appreciation to kuwait university for its support through the ku-scholarship program. IFAC-PapersOnLine 54 (3), 91–96, 16th IFAC Symposium on Advanced Control of Chemical

- Processes ADCHEM 2021.
 URL: <https://www.sciencedirect.com/science/article/pii/S2405896321009952>
 DOI: <https://doi.org/10.1016/j.ifacol.2021.08.224>
- Calle Chojeda, E., Oliden Semino, J., Ipanaqué Alama, W., sep. 2022. Control of a non-linear and non-minimum phase multivariable system using a neural predictive controller. *Revista Iberoamericana de Automática e Informática industrial* 20 (1), 32–43.
 URL: <https://polipapers.upv.es/index.php/RIAI/article/view/17375>
 DOI: 10.4995/riai.2022.17375
- Continelli, N. A., Nagua Cuenca, L. F., Monje, C. A., Balaguer, C., mar. 2023. Modeling of a soft robotic neck using machine learning techniques. *Revista Iberoamericana de Automática e Informática industrial*.
 URL: <https://polipapers.upv.es/index.php/RIAI/article/view/18752>
 DOI: 10.4995/riai.2023.18752
- Friese, J., Brandt, N., Schulte, A., Kirches, C., Tegethoff, W., Köhler, J., 2023. Quasi-optimal control of a solar thermal system via neural networks. *Energy and AI* 12, 100232.
 URL: <https://www.sciencedirect.com/science/article/pii/S2666546823000046>
 DOI: <https://doi.org/10.1016/j.egyai.2023.100232>
- Gomez, J., Rossomando, F., Capraro, F., Soria, C., dic. 2022. Real-time neuro-adaptive pi control of soil moisture using a hybrid model. *Revista Iberoamericana de Automática e Informática industrial* 20 (1), 93–103.
 URL: <https://polipapers.upv.es/index.php/RIAI/article/view/17106>
 DOI: 10.4995/riai.2022.17106
- Li, Y., Tong, Z., 2021. Model predictive control strategy using encoder-decoder recurrent neural networks for smart control of thermal environment. *Journal of Building Engineering* 42, 103017.
 URL: <https://www.sciencedirect.com/science/article/pii/S2352710221008755>
 DOI: <https://doi.org/10.1016/j.jobe.2021.103017>
- Mao, S., Sejdic, E., 2022. A review of recurrent neural network-based methods in computational physiology. *IEEE Transactions on Neural Networks and Learning Systems* Cited by: 6.
 URL: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85124749564&doi=10.1109/2fTNNLS.2022.3145365&partnerID=40&md5=34519cbdcbbc907ef4190d9e997b35ec>
 DOI: 10.1109/TNNLS.2022.3145365
- Martinez, S., Garcia-Violini, D., Belluscio, M., Piriz, J., Sanchez-Pena, R., 2023. Dynamical models in neuroscience from a closed-loop control perspective. *IEEE Reviews in Biomedical Engineering* 16, 706 – 721, cited by: 0.
 URL: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85131808758&doi=10.1109/2fRBME.2022.3180559&partnerID=40&md5=b1f2373e313e0115d6940091b789c0e4>
 DOI: 10.1109/RBME.2022.3180559
- Navarro Giménez, S., Durá, J. M. H., Ferragud, F. X. B., Fernández, R. S., 2020. Design and experimental validation of the temperature control of a pemfc stack by applying multiobjective optimization. *IEEE Access* 8, 183324–183343.
 DOI: 10.1109/ACCESS.2020.3029321
- Navarro Giménez, S., Herrero Durá, J. M., Blasco Ferragud, F. X., Simarro Fernández, R., 2019. Control-oriented modeling of the cooling process of a pemfc-based μ -chp system. *IEEE Access* 7, 95620–95642.
 DOI: 10.1109/ACCESS.2019.2928632
- Orang, O., de Lima e Silva, P. C., Guimarães, F. G., 2022. Time series forecasting using fuzzy cognitive maps: a survey. *Artificial Intelligence Review*.
 URL: <https://doi.org/10.1007/s10462-022-10319-w>
 DOI: 10.1007/s10462-022-10319-w
- Poznyak, A., Chairez, I., Poznyak, T., 2019. A survey on artificial neural networks application for identification and control in environmental engineering: Biological and chemical systems with uncertain models. *Annual Reviews in Control* 48, 250 – 272, cited by: 41.
 URL: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85070697749&doi=10.1016/2fj.arcontrol.2019.07.003&partnerID=40&md5=de88439884280eadcd5ab70c1d84f867>
 DOI: 10.1016/j.arcontrol.2019.07.003
- Zabaljauregi, A., Alonso, A., Larrea, M., Irigoyen, E., Sanchis, J., 2023. Control of mimo systems with imo-nmpc strategy. In: García Bringas, P., Pérez García, H., Martínez-de Pison, F. J., Villar Flecha, J. R., Troncoso Lora, A., de la Cal, E. A., Herrero, Á., Martínez Álvarez, F., Psaila, G., Quintián, H., Corchado Rodríguez, E. S. (Eds.), 17th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO 2022). Springer Nature Switzerland, Cham, pp. 474–483.
- Zhang, G., Lu, R., Chen, M., 2023. Drnn-mimo-pid control strategy for multi-point mooring system. *International Journal of Vehicle Design* 91 (1-3), 138–160.
 URL: <https://www.inderscienceonline.com/doi/abs/10.1504/IJVD.2023.131055>
 DOI: 10.1504/IJVD.2023.131055
- Zhao, M., Wan, J., Peng, C., 2023. Generalized predictive control using improved recurrent fuzzy neural network for a boiler-turbine unit. *Engineering Applications of Artificial Intelligence* 121, 106053.
 URL: <https://www.sciencedirect.com/science/article/pii/S0952197623002373>
 DOI: <https://doi.org/10.1016/j.engappai.2023.106053>