

PRIMEROS RESULTADOS DE LA INTEGRACIÓN DE MODELOS NEURONALES MIMO EN LA ESTRATEGIA iMO-NMPC

A. Alonso, A. Zabaljauregi, E. Irigoyen, M. Larrea
EIB, UPV/EHU, {aalonso198,azabaljauregi001}@ikasle.ehu.eus,{eloy.irigoyen,m.larrea}@ehu.eus

Resumen

Este trabajo presenta un estudio preliminar donde se analizará y estudiará la eficiencia de las redes neuronales artificiales de topología NARX (Non-linear Autoregressive eXogenous) en la reproducción del comportamiento de sistemas con dinámicas complejas y su posterior uso en estructuras de control inteligente. Específicamente se valorará el comportamiento de dichas redes NARX, no solo en la estimación de las salidas de los sistemas a una muestra en el futuro, sino que se analizará su comportamiento hasta un horizonte de predicción determinado. Concretamente, debido a las características dinámicas de los sistemas no lineales estudiados este estudio se hará para un horizonte de 10 muestras en configuración closed-loop. El objetivo de este estudio es analizar si existen divergencias en las salidas estimadas por la red NARX al depender su cálculo de los valores anteriores estimados por la propia red. Dichas estructuras NARX se configurarán para reproducir tanto sistemas monovariantes, como multivariantes. En especial, este estudio se extenderá al caso del control predictivo no lineal basado en modelos iMO-NMPC, el cual constituye una línea de trabajo dentro del grupo de investigación de control inteligente (GICI) de la UPV/EHU.

Palabras clave: Modelo NARX, sistemas no lineales, MIMO, iMO-NMPC

1. INTRODUCCIÓN

En el ámbito del Control, las aplicaciones en sistemas reales ofrecen una amplia gama de problemáticas a estudiar debido a sus complejas dinámicas, donde las no linealidades, las restricciones de funcionamiento, los acoplamientos en sistemas multivariantes y otras tantas particularidades dinámicas hacen que sigan existiendo muchos y nuevos retos a solucionar. En lo que respecta a las estrategias de control inteligente basadas en modelo, sigue siendo un reto importante el estudiar qué capacidades y qué eficiencia pueden demostrar los modelos neuronales basados en estructuras NARX (*Nonlinear Autoregressive eXogenous*). Esto supo-

ne que los procesos de identificación para capturar todas los comportamientos y características de un sistema sean complejos, especialmente si el modelo será usado en estrategias como el Control Predictivo basado en Modelo (MPC, del inglés *Model Predictive Control*), que requieren de una buena aproximación del comportamiento del sistema a controlar, en especial de la estimación del conjunto de sus salidas.

En este ámbito, es muy extendido el uso de Redes Neuronales Artificiales (RNA) para la modelización de estos sistemas, ya que se ha comprobado que son muy buenos aproximadores universales [5], [6], [9]. Estos modelos neuronales son así implementables en las estrategias de control mencionadas, como MPC o su versión no lineal (NMPC) [2], ofreciendo buenos resultados en trabajos donde se plantea el control de sistemas, tanto monovariantes (*Single Input Single Output*, SISO), como multivariantes (*Multiple Input Multiple Output*, MIMO) [1].

En este trabajo, se busca modelizar sistemas no lineales mediante redes NARX, con diferentes estructuras respecto a su configuración interna y al número de entradas donde se recibe información de estados pasados de dichos sistemas, tanto en configuración SISO (ecuación 1), como MIMO (ecuación 2), comparando posteriormente las respuestas obtenidas respecto a los sistemas reales.

$$\hat{y}(k+1) = f_S(y(k), y(k-1), \dots, y(k-n), u(k), u(k-1), \dots, u(k-m)) \quad (1)$$

$$\hat{y}(k+1) = f_M(y_1(k), y_1(k-1), \dots, y_1(k-n_1), u_1(k), u_1(k-1), \dots, u_1(k-m_1), y_2(k), y_2(k-1), \dots, y_2(k-n_2), u_2(k), u_2(k-1), \dots, u_2(k-m_2)) \quad (2)$$

Además, se extenderá el estudio de estas redes NARX a pruebas realizadas sobre horizontes de predicción de un máximo de 10 muestras. Las dinámicas no lineales que presentan los sistemas empleados para validar esta propuesta de modelos neuronales SISO y MIMO permiten desarrollar

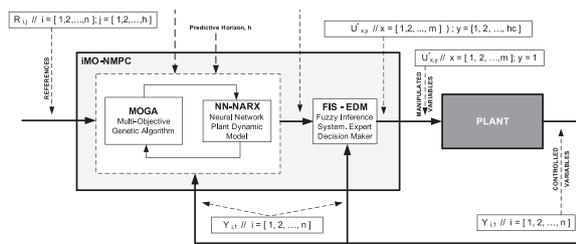


Figura 1: Esquema de control con estrategia iMO-NMPC.

un estudio a dicho número de muestras, aunque a modo de prueba se presentará el comportamiento de una de las redes seleccionadas para estimar en configuración *closed-loop* un total de 130 muestras.

Finalmente, se realizará una prueba de concepto integrando el modelo neuronal correspondiente en el control de dos configuraciones, SISO y MIMO. Se desea observar y presentar cuál es el comportamiento de los mencionados modelos neuronales en una estructura de control que precisa de los mismos. Esta estrategia de control es la conocida como iMO-NMPC [10] y en ella se deben realizar estimaciones futuras en el proceso de optimización que calcula las acciones de control a aplicar a los sistemas no lineales controlados. Esta estrategia de control inteligente integra técnicas del ámbito de la computación inteligente, como son las mencionadas redes neuronales, algoritmos genéticos para realizar los procesos de optimización multiobjetivo integrados en ellas y la lógica difusa que da soporte a la parte de toma de decisiones de cara a elegir la solución óptima extraída de un frente de Pareto. Un esquema representativo de esta estrategia puede verse en la Figura 1.

2. PRESENTACIÓN DEL PROBLEMA

Para establecer este estudio preliminar en el presente trabajo, se ha trabajado con dos sistemas no lineales sintéticos procedentes de trabajos publicados previamente en este área y diseñados para comprobar el comportamiento de las redes neuronales artificiales ante dinámicas complicadas [8, 4].

Estos sistemas han sido empleados anteriormente en otros trabajos relacionados con la identificación de modelos no lineales [7]. Para ofrecer una representación de las no linealidades de ambos sistemas, se presenta en la Figura 2 un conjunto de puntos de operación en régimen estacionario, mediante la relación entrada/salida, cuyos rangos abarcan dinámicas no lineales suficientemente significativas.

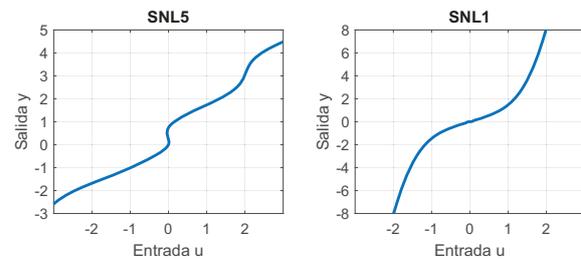


Figura 2: Relación de entradas/salidas de los sistemas en régimen estacionario.

Estos modelos son ambos modelos monovariariables y se ha estudiado uno de ellos, el que denominaremos SNL5, para el primer caso (SISO). Para el estudio del segundo caso (MIMO), se ha generado un sistema multivariable no acoplado añadiendo al anterior un nuevo sistema, el que denominaremos SNL1.

Como se ha mencionado previamente, las redes neuronales empleadas son de arquitectura NARX en lazo abierto, haciéndose un estudio del rendimiento de las mismas con distintas configuraciones respecto al número de neuronas en la capa oculta y retardos de las entradas. En este estudio se ha buscado la configuración NARX que más simple resulte, salvaguardando unos valores de error adecuados, que realice por lo tanto una buena aproximación al sistema real y que facilite en trabajos futuros su utilización en plataformas de control reales donde se puedan analizar requerimientos importantes de tiempo real.

2.1. SISO

En primer lugar, se ha estudiado un sistema no lineal extraído de la publicación de Harris titulada *-Advances in Intelligent Control-* [4], denominado *SNL5* para este trabajo:

$$y(k+1) = \frac{1,5 \cdot y(k) \cdot y(k-1)}{1 + y(k)^2 + y(k-1)^2} + 0,7 \cdot \sin(0,5(y(k) + y(k-1))) \cdot \cos(0,5(y(k) + y(k-1))) + 1,2 \cdot u(k) \quad (3)$$

En lo que respecta al entrenamiento del modelo neuronal NARX y su configuración, al ser un sistema con una única entrada y una única salida, se han estudiado un rango de valores del número de neuronas de una única capa oculta entre 2 y 6, siendo los retardos de las entradas externas (u) 0 o $0/1^1$, y los retardos de la salida real (*target*) 1 o $1/2$.

¹Notación MATLAB

2.2. MIMO

En segundo lugar, se ha estudiado el caso de un sistema MIMO desacoplado, compuesto por el sistema *SNL5*, ecuación (4) y un nuevo sistema no lineal tomado del trabajo de Narendra [8], denominado para este trabajo como *SNL1*, mostrado en la ecuación (5).

$$y_1(k+1) = \frac{1,5 \cdot y_1(k) \cdot y_1(k-1)}{1 + y_1(k)^2 + y_1(k-1)^2} + 0,7 \sin [0,5 (y_1(k) + y_1(k-1))] \cdot \cos [0,5 (y_1(k) + y_1(k-1))] + 1,2u_1(k) \quad (4)$$

$$y_2(k+1) = u_2(k)^3 + \frac{y_2(k)}{1 + y_2(k)^2} \quad (5)$$

De igual manera, de cara a configurar los modelos neuronales NARX, al ser un sistema MIMO más complejo, se ha estudiado el rango de valores de número de neuronas de la capa oculta entre 8 y 20, en intervalos de 2, para reducir el número de redes a analizar; y los retardos, al igual que en el anterior caso, de las entradas externas (u) 0 o 0/1, y los retardos de la salida real (*target*) 1 o 1/2.

3. RESULTADOS

Para la obtención de los modelos neuronales se ha realizado un barrido de parámetros, siendo las entradas y salidas (*targets*) de los sistemas en los procesos de entrenamiento iguales para todas las casos.

Debido a que la inicialización de los pesos y bias de las redes NARX en cada entrenamiento es aleatorio, no se puede asegurar que con un solo entrenamiento se pueda lograr la mejor solución (red NARX óptima), por lo que se han realizado repeticiones con cada una de las configuraciones seleccionadas, entrenado 4 redes distintas para cada combinación de parámetros. De su posterior análisis se ha escogido aquella con mejor rendimiento en validación, estudiando los resultados de estimación de salidas del modelo neuronal para entradas distintas a las de los entrenamientos.

Del estudio de los resultados globales, se ha seleccionado en cada configuración realizada la red NARX que mejor comportamiento ha mostrado en lo que respecta al Error Cuadrático Medio (*Mean Square Error*, MSE). Estos resultados numéricos han sido presentados en sus correspondientes diagramas de barras, para cada uno de los casos estudiados, modelos SISO y modelos MIMO. Esto ha permitido seleccionar la mejor configuración de modelo neuronal para integrarlo posteriormente en la estrategia de control iMO-NMPC [10]. A

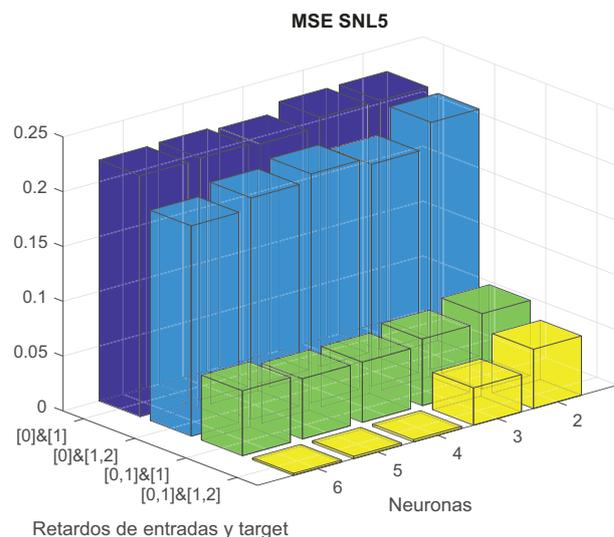


Figura 3: MSE de configuraciones de redes para el sistema SISO.

estas representaciones se acompañarán los gráficos obtenidos en diferentes pruebas de validación realizadas con los mejores modelos NARX.

3.1. SISO

Realizando el proceso de entrenamiento de las redes mencionado, se ha obtenido el gráfico presentado en la Figura 3, donde se presentan los errores MSE que presentan los diferentes modelos neuronales NARX al reproducir las salidas del sistema SNL5 en las pruebas de validación. En este gráfico se observa que el parámetro que mayor impacto tiene en la disminución del error son los retardos de entrada u y salida $y_{targets}$ del sistema incorporados a las entradas de la NARX. Así, observando el gráfico, se ha decidido elegir la red con 4 neuronas, y retardos de entradas 0/1 y retardos de $y_{targets}$ 1/2. No se ha seleccionado un número mayor de neuronas, debido a que la reducción del error obtenida es muy pequeña en comparación con el aumento del tiempo de computación necesario.

En la Figura 4 se puede observar el comportamiento que muestra una red NARX al reproducir la salida del sistema no lineal SNL5, en el rango de salida $[-3, 3]$, con un MSE de 0,001925 y un error absoluto máximo detectado de 0,1949. Esta red tiene una configuración de 4 neuronas en la capa oculta y 4 neuronas de entrada divididas en: variable u con 2 retardos 0-1 y salida del sistema y_{target} con 2 retardos 1-2.

El anterior resultado ha sido muy satisfactorio, lo que permite seguir estudiando el comportamiento de la red NARX en nuevas configuraciones operativas. En este caso, el análisis de comportamien-

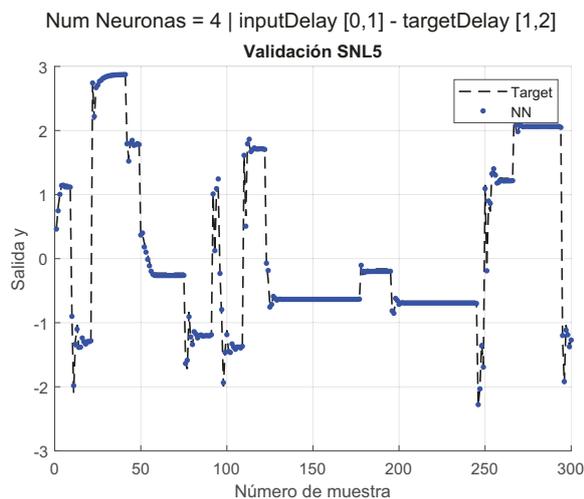


Figura 4: Respuesta de la red neuronal obtenida frente a una entrada de validación.

Horizontes predicción (H)	Error MSE	Error MaAE
1	1.9253e-3	0.1949
2	1.1581e-3	0.2183
3	1.1403e-3	0.2342
4	1.1602e-3	0.2089
5	1.1675e-3	0.2168
6	1.1585e-3	0.2209
7	1.1570e-3	0.2231
8	1.1575e-3	0.2241
9	1.1539e-3	0.2246
10	1.1506e-3	0.2248

Cuadro 1: Errores en las estimaciones a diferentes horizontes de predicción (H).

to del modelo neuronal se amplia a la situación de *closed-loop*, donde las estimaciones futuras que debe hacer dicho modelo deben basarse en sus propias salidas, es decir, sus estimaciones anteriores. Con objeto de analizar la divergencia que se pudiera dar con estos modelos y sus limitaciones en esquemas de control como el MPC se han desarrollado un conjunto de pruebas para conocer los rangos de error cometidos en horizontes que alcanzan las 10 muestras. En la Tabla 1 se muestran los buenos resultados obtenidos, donde los errores analizados se mantienen en órdenes semejantes a los obtenidos en *open-loop*, lo que permite seguir trabajando en esta línea. Para visualizar qué efecto tendría la configuración *closed-loop* en un mayor número de muestras, barriendo todo el espacio de trabajo, se ha realizado como prueba conceptual la simulación a 300 muestras, obteniéndose como resultado un MSE de $1,6291e - 3$ y un MaAE de 0,2250, cuya evolución se muestra en la Figura 5.

3.2. MIMO

En el caso del sistema MIMO estudiado, se ha analizado el comportamiento de una única red NARX, en base a sus diferentes configuraciones, que si-

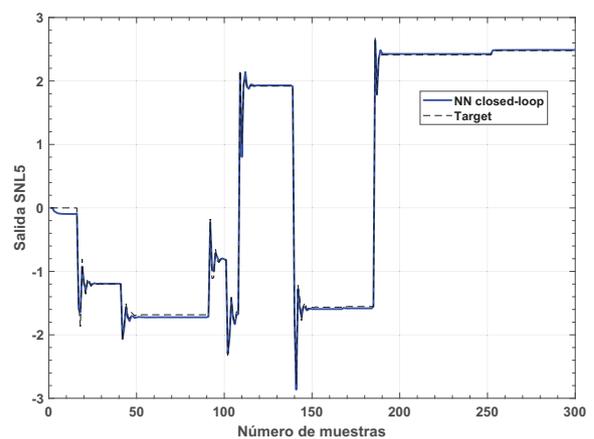


Figura 5: Salida estimada del sistema SNL5 en configuración *closed-loop* para todo el espacio de trabajo.

multáneamente reproduzca las salidas del sistema compuesto por ambos subsistemas, SNL1 y SNL5. Se han realizado una batería de experimentos para valorar el grado de eficiencia de esta red NARX a la hora de estimar los valores futuros de ambas salidas. Tras realizar el entrenamiento del lote de redes NARX con la combinación de parámetros mencionada, se han obtenido los resultados mostrados en las figuras de MSE para ambas salidas, Figuras 6 y 7, respectivamente.

En estos gráficos de barras se puede observar de nuevo que el parámetro que mayor influencia tiene en la reducción del error MSE es el retardo, en este caso, de las entradas u , aunque el retardo de los y_{target} también tiene su influencia al combinarlo con el anterior.

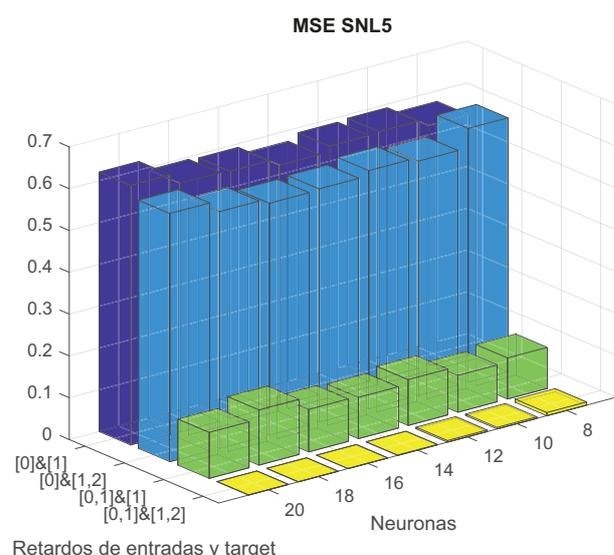


Figura 6: MSE de configuraciones de redes para el sistema MIMO: Subsistema SNL5

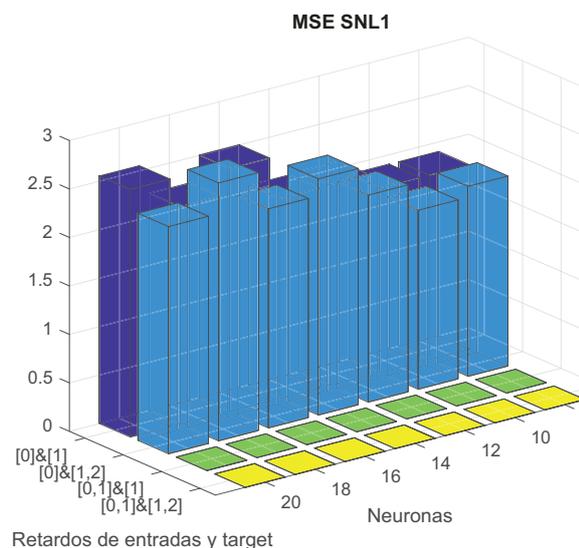


Figura 7: MSE de configuraciones de redes para el sistema MIMO: Subsistema SNL1

Analizando los errores obtenidos de todas las pruebas realizadas, se ha decidido elegir la red NARX con 14 neuronas en la capa oculta y retardos de entradas (u_1 y u_5) 0/1 y retardos de y_{target} (y_1 y y_5) 1/2. De nuevo, no se ha seleccionado un número mayor de neuronas debido a la pequeña disminución del error MSE mostrada a medida que dicho número de neuronas iba en aumento y con el objetivo de ofrecer modelos neuronales de estructuras sencillas que, manteniendo un nivel de error satisfactorios, puedan ser empleados en aplicaciones reales futuras.

Para estudiar el comportamiento de la red NARX MIMO seleccionada se han realizado una serie de pruebas que arrojan unos resultados muy satisfactorios. En la Figura 8 se puede observar la evolución de ambas salidas, con ambos rangos de trabajo en el intervalo $[-5,0,5,0]$, donde se han dado errores MSE de $6,5192e - 4$ para el caso de la salida y_5 y de $1,1892e - 6$ para el caso de la salida y_1 . A su vez, se han obtenido unos errores MaAE de 0,1455 y de 0,0034, para las salida y_5 y y_1 , respectivamente.

De igual manera al estudio del modelo neuronal SISO, se ha estudiado el comportamiento de la red NARX MIMO en configuración *closed-loop* para un total de 300 muestras. Nuevamente los resultados han sido muy satisfactorios, arrojando unos valores de error MSE combinado ($y_1 + y_5$) de $6,0188e - 4$, con errores MaAE de 0,1828 y 0,0062 en ambas salidas. La Figura 9 muestra un ejemplo de la evolución de ambas salidas en un horizonte de predicción de 300 muestras. Además, los datos de errores MSE y MaAE para ambas salidas, para horizontes de predicción (estimación) de hasta 10

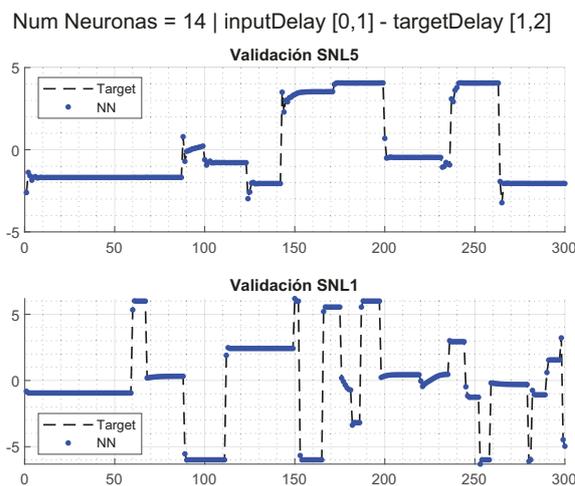


Figura 8: Respuesta ante validación de la red neuronal elegida para el sistema MIMO

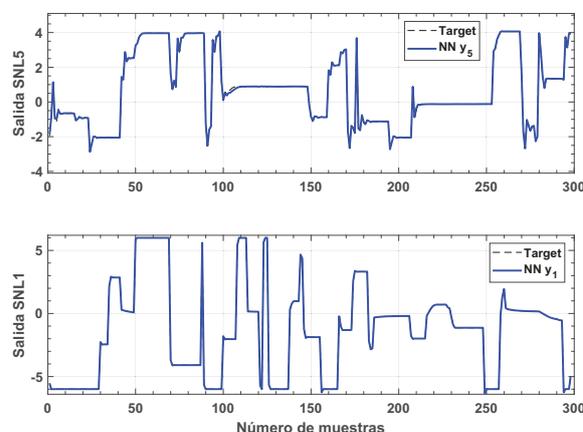


Figura 9: Salidas estimadas del sistema MIMO en configuración *closed-loop* para todo el espacio de trabajo.

muestras quedan recogidos en la Tabla 2.

Finalmente, con objeto de dar validez a los modelos neuronales estudiados, se ha incluido uno de los mejores modelos NARX analizados en una estrategia de control inteligente, denominada iMOMPC [10]. La Figura 10 muestra el desempeño

Horizontes predicción (H)	SNL5	SNL5	SNL1	SNL1
	Error MSE	Error MaAE	Error MSE	Error MaAE
1	6.5192e-4	0.1455	1.1892e-6	0.0034
2	7.0905e-4	0.1617	1.3028e-6	0.0034
3	8.2245e-4	0.1674	1.5320e-6	0.0034
4	9.0881e-4	0.1666	1.7590e-6	0.0034
5	9.6716e-4	0.1653	1.9866e-6	0.0034
6	9.7896e-4	0.1861	2.1918e-6	0.0039
7	1.0406e-3	0.1865	2.3675e-6	0.0043
8	1.0714e-3	0.1843	2.5118e-6	0.0047
9	1.0876e-3	0.1843	2.6410e-6	0.0050
10	1.0874e-3	0.1838	2.7390e-6	0.0053

Cuadro 2: Errores en las estimaciones a diferentes horizontes de predicción (H).

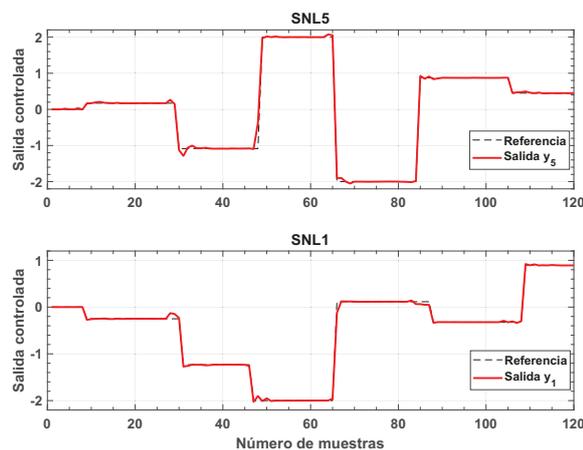


Figura 10: Salidas estimadas del sistema MIMO en configuración *closed-loop* para todo el espacio de trabajo.

logrado en el control de un sistema MIMO compuesto por los sistemas no lineales estudiados, *SNL1* y *SNL5*, en cuyo NMPC se han seleccionado, tanto para el horizonte de predicción, como el de control, un número de 4 muestras ($H = 4, H_c = 4$).

4. CONCLUSIONES

Este trabajo ha presentado el análisis y validación de modelos neuronales de sistemas no lineales de dinámicas complejas, en estructura SISO y MIMO, en base a topologías NARX (Nonlinear Autoregressive eXogenous). Para su evaluación se han realizado repetidos experimentos con estructuras diferenciadas en lo que respecta a las redes NARX, barriendo un rango adecuado de neuronas de la capa oculta, así como el número de retardos de las variables de entrada u y salida y_{target} de dos sistemas no lineales, *SNL1* y *SNL5*.

Los resultados presentados han permitido validar el uso de las redes NARX como modelos, tanto del planteamiento SISO, como del MIMO. Este estudio se ha realizado inicialmente enfocado en la evaluación de la eficiencia de los modelos neuronales en la estimación de las salidas de los mencionados sistemas. Posteriormente se ha trabajado en el estudio del comportamiento de los modelos neuronales en diferentes horizontes de predicción, donde se ha utilizado una configuración *closed-loop* para las estimaciones futuras de las mencionadas salidas. En ambos casos los resultados han sido muy satisfactorios, tal y como muestran las tablas presentadas en este trabajo.

Además, para finalizar se ha realizado una prueba del modelo neuronal MIMO con la mejor red NARX en una estrategia de control predictivo de-

nominada iMO-NMPC [10]. Esta prueba se ha hecho para horizontes de predicción y control de 4 muestras, mostrando unos resultados de control muy satisfactorios.

Como línea de trabajo futuro, el siguiente objetivo será el desarrollo de un modelo neuronal MIMO de un sistema acoplado. Un ejemplo de este tipo de sistemas MIMO con dinámicas complejas y acopladas es la plataforma *Twin-Rotor*, provisto por *Feedback Instruments Ltd* [3], la cual será representada por un modelo MIMO 2x2 fuertemente acoplado, además de disponerse de su plataforma real.

Adicionalmente, también queda ampliar el estudio de estos modelos neuronales a estrategias de Control Inteligente, como el iMO-NMPC [10] para estos sistemas acoplados, en los que resulta crucial que el error del modelo sea mínimo para que el control funcione satisfactoriamente.

Como prueba real de concepto se planteará en un futuro cercano la integración de los modelos neuronales NARX obtenidos en aplicaciones de tiempo real, desarrolladas con MATLAB/Simulink y a través de código adicional en S-functions.

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>)

English summary

FIRST RESULTS OF THE INTEGRATION OF MIMO NEURAL MODELS INTO THE iMO-NMPC STRATEGY

Abstract

This work presents a preliminary study where the efficiency of artificial neural networks of NARX (Nonlinear Autoregressive eXogenous) topology in reproducing the behavior of systems with complex dynamics and their subsequent use in intelligent control structures will be analyzed and studied. Specifically, the behavior of these NARX networks will be evaluated, not only in the estimation of the outputs of the systems to a sample in the future, but also their behavior will be analyzed up to a certain prediction horizon. In particular, due to

the dynamic characteristics of the nonlinear systems studied, this study will be carried out for a horizon of 10 samples in a close-loop configuration. The objective of this study is to analyze whether there are divergences in the outputs estimated by the NARX network as its calculation depends on the previous values estimated by the network itself. These NARX structures will be configured to reproduce both monovariate and multivariate systems. Especially, this study will be extended to the case of nonlinear predictive control based on models, iMO-NMPC, which constitutes a line of work within the intelligent control research group (GICI) of the UPV/EHU.

Keywords: NARX models, Non Linear Systems, MIMO, iMO-NMPC.

Referencias

- [1] A. Bamimore, A. Osinuga, T. Kehinde-Abajo, A. Osunleke, and O. Taiwo. A comparison of two artificial neural networks for modelling and predictive control of a cascaded three-tank system. *IFAC-PapersOnLine*, 54(21):145–150, 2021. Control Conference Africa CCA 2021.
- [2] E. F. Camacho and C. Bordons. *Nonlinear Model Predictive Control: An Introductory Review*, pages 1–16. Springer Berlin Heidelberg, Berlin, Heidelberg, 2007.
- [3] L. Feedback Instruments. *Twin Rotor MIMO System Control Experiments 33-949S*. Feedback, 2001.
- [4] C. Harris, editor. *Advances in Intelligent Control*. CRC Press, 1994.
- [5] K. Hornik, M. Stinchcombe, and H. White. Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks. *Neural Networks*, 3(5):551–560, 1990.
- [6] S. Jagannathan and F. Lewis. Identification of nonlinear dynamical systems using multilayered neural networks. *Automatica*, 32(12):1707–1712, 1996.
- [7] M. Larrea, E. Larzabal, E. Irigoyen, J. Valera, and M. Dendaluce. Implementation and testing of a soft computing based model predictive control on an industrial controller. *Journal of Applied Logic*, 13(2, Part A):114–125, 2015. SI: SOCO12.
- [8] K. S. Narendra and K. Parthasarathy. Identification and control of dynamical systems using neural networks. *IEEE Trans Neural Networks*, 1:4–27, 1990.
- [9] A. Perrusquía and W. Yu. Identification and optimal control of nonlinear systems using recurrent neural networks and reinforcement learning: An overview. *Neurocomputing*, 438:145–154, 2021.
- [10] J. J. Valera García, V. Gómez Garay, E. Irigoyen Gordo, F. Artaza Fano, and M. Larrea Sukia. Intelligent multi-objective nonlinear model predictive control (imo-nmpc): Towards the ‘on-line’ optimization of highly complex control problems. *Expert Systems with Applications*, 39(7):6527–6540, 2012.



© 2022 by the authors.
Submitted for possible
open access publication
under the terms and conditions of the Creative
Commons Attribution CC-BY-NC-SA 4.0
license (<https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>).