



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Estudio de estructuras neuronales NARX para reproducir el comportamiento de sistemas con dinámicas complejas

Aimar Alonso, Asier Zabaljauregi, Eloy Irigoyen, Mikel Larrea

Universidad de País Vasco / Euskal Herriko Unibertsitatea (UPV/EHU)

To cite this article: Alonso, A., Zabaljauregi, A., Irigoyen, E., Larrea, M., 2022. Study of NARX neural structures to reproduce the behaviour of systems with complex dynamics. XVII Simposio CEA de Control Inteligente.

Resumen

Este trabajo presenta un estudio preliminar donde se valorará la eficiencia de las redes neuronales artificiales de topología NARX (Nonlinear Autoregressive eXogenous) en la reproducción del comportamiento de sistemas con dinámicas complejas. Estas estructuras neuronales se diseñarán para reproducir tanto sistemas monovariantes, como multivariantes, siguiendo un mismo planteamiento metodológico. Los mencionados estudios están dirigidos a proporcionar dichos modelos neuronales a futuras estrategias de control dependientes de modelos dinámicos, como es el caso del control predictivo no lineal basado en modelos, el cual constituye una línea de trabajo dentro del grupo de investigación de control inteligente (GICI) de la UPV/EHU.

Palabras clave: Red Neuronal, Sistemas no lineales, Identificación

Study of NARX neural structures to reproduce the behaviour of systems with complex dynamics.

Abstract

This work presents a preliminary study that evaluates the NARX artificial neural network performance in reproducing the behaviour of complex dynamics systems. These neural structures will be designed to reproduce both monovariant and multivariant systems, following the same methodological approach. These studies are aimed at providing neural models to future control strategies dependent on dynamic models, as is the case of non-linear predictive control based on models, which constitutes a new line of work within the Intelligent Control Research Group (GICI) at UPV/EHU.

Keywords: Neural Networks, Nonlinear systems, Identification

1. Introducción

En el mundo real, los sistemas a controlar son complejos, ya que incluyen no linealidades e interacción entre las diferentes entradas y salidas de este. Esto causa que la identificación de las características del sistema para desarrollar un modelo sea un proceso complicado, especialmente si el modelo será usado en métodos como *Model Predictive Control* (MPC), que requieren de una buena aproximación de los parámetros del proceso.

En este ámbito, se ha extendido el uso de Redes Neuronales Artificiales (RNA) para la modelización de estos sistemas, ya que se ha comprobado que son aproximadores universales (Hornik et al., 1990), (Jagannathan y Lewis, 1996), (Perrusquía y Yu, 2021). Estos modelos neuronales son así implementables

en las estrategias de control mencionadas, como MPC o su versión no lineal (NMPC) (Camacho y Bordons, 2007), obteniendo buenos resultados (Bamimore et al., 2021).

En este trabajo, se busca modelizar sistemas no lineales mediante RNA, tanto con una única salida y entrada (*Single Input Single Output*, SISO), como con múltiples (*Multiple Input Multiple Output*, MIMO), comparando la respuesta obtenida respecto al modelo real.

2. Presentación del problema

Los sistemas empleados en este trabajo son sintéticos, que buscan valorar el rendimiento de este método de identificación, debido a que presentan regiones con grandes no linealidades. Estos sistemas han sido empleados anteriormente en otros trabajos relacionados con la identificación de modelos no lineales (Larrea et al., 2015). Para ofrecer una representación de las no linealidades de ambos sistemas, se presenta en la Figura 1 un

Correos electrónicos: aalonso198@ikasle.ehu.eus (Aimar Alonso), azabaljauregi001@ikasle.ehu.eus (Asier Zabaljauregi), eloy.irigoyen@ehu.eus (Eloy Irigoyen), m.larrea@ehu.eus (Mikel Larrea)

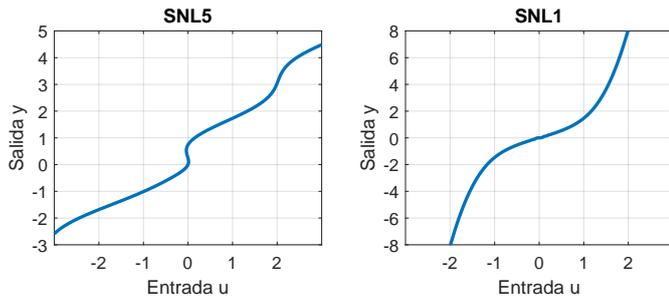


Figura 1: Relación de entradas/salidas de los sistemas en régimen estacionario

conjunto de puntos de operación en régimen estacionario, mediante la relación entrada/salida, cuyos rangos abarcan dinámicas no lineales suficientemente significativas.

Estos modelos son ambos modelos monovariantes y se ha estudiado uno de ellos, el SNL5, para el primer caso (SISO). Para el estudio del segundo caso (MIMO), sin embargo, se ha generado un sistema multivariable no acoplado con ambos. Para ello se ha creado un sistema compuesto por SNL1 y SNL5.

Las RNA empleadas son de arquitectura NARX en lazo abierto, haciéndose un estudio del rendimiento de las mismas con distintos valores para el número de neuronas en la capa oculta y retardos de las entradas, con el objetivo de obtener redes neuronales que realicen una buena aproximación al sistema real, pero sin sobredimensionamiento.

2.1. SISO

En primer lugar, se ha estudiado el sistema no lineal denominado SNL5:

$$y_{k+1} = \frac{1,5 \cdot y_k \cdot y_{k-1}}{1 + y_k^2 + y_{k-1}^2} + 0,7 \cdot \sin(0,5(y_k + y_{k-1})) \cdot \cos(0,5(y_k + y_{k-1})) + 1,2u_k \quad (1)$$

Al ser un sistema con una única entrada y una única salida, se variarán el valor del número de neuronas entre 2 y 6, siendo los retardos de las entradas externas (u) 0 o 0/1, y los retardos de la salida real ($target$) 1 o 1/2.

2.2. MIMO

En segundo lugar, se ha estudiado el caso de un sistema MIMO desacoplado, compuesto por el sistema SNL5, y otro sistema no lineal denominado SNL1:

$$\begin{cases} y_{1,k+1} = \frac{1,5 \cdot y_{1,k} \cdot y_{1,k-1}}{1 + y_{1,k}^2 + y_{1,k-1}^2} + 0,7 \cdot \sin(0,5(y_{1,k} + y_{1,k-1})) \cdot \cos(0,5(y_{1,k} + y_{1,k-1})) + 1,2u_{1,k} \\ y_{2,k+1} = \frac{y_{2,k}}{1 + y_{2,k}^2} + u_{2,k}^3 \end{cases} \quad (2)$$

Al ser un sistema MIMO, más complejo, se aumentará el rango de valores de número de neuronas entre 8 y 20, en saltos de 2, para reducir el número de redes a entrenar; 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.

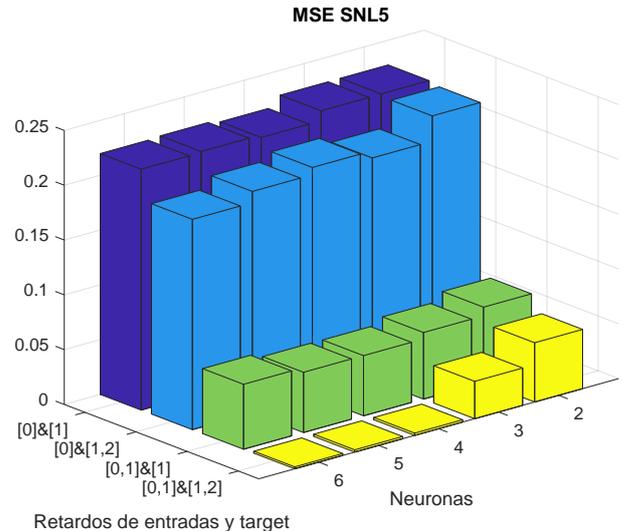


Figura 2: MSE de configuraciones de redes para el sistema SISO

3. Resultados

Para la obtención de los modelos neuronales se ha realizado un barrido de parámetros, siendo las entradas y $targets$ de entrenamiento iguales para todas las redes.

Debido a que el punto de comienzo de cada entrenamiento es aleatorio, no se puede asegurar que la red sea óptima, por lo que se han entrenado 4 redes distintas para cada combinación de parámetros, y de estas se ha escogido aquella con mejor rendimiento en validación con entradas distintas a las de entrenamiento.

Tras obtener la mejor red para cada combinación de parámetros, se ha realizado un gráfico de barras del Error Cuadrático Medio (*Mean Square Error*, MSE) para tomar la decisión de la mejor red del conjunto. Finalmente, se ha realizado un gráfico de la validación de esta red para observar el comportamiento y la aproximación del sistema a identificar.

3.1. SISO

Realizando el proceso de entrenamiento de las redes mencionado, se ha obtenido el gráfico de MSE de las redes (figura 2). En este gráfico se observa que el parámetro que mayor impacto tiene en la disminución del error son los retardos de entrada y $target$. Así, observando el gráfico, se ha decidido elegir la red con 4 neuronas, y retardos de entradas 0/1 y retardos de $targets$ 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.

Graficando la respuesta del sistema frente a una entrada u en el rango $[-2, 2]$ (figura 3), se ha obtenido una respuesta muy buena, siguiendo la salida real del sistema con error muy reducido.

3.2. MIMO

Tras realizar el entrenamiento de las redes con la combinación de parámetros mencionada, se han obtenido los gráficos de los MSE para ambas salidas (figuras 4 y 5). En estos gráficos,

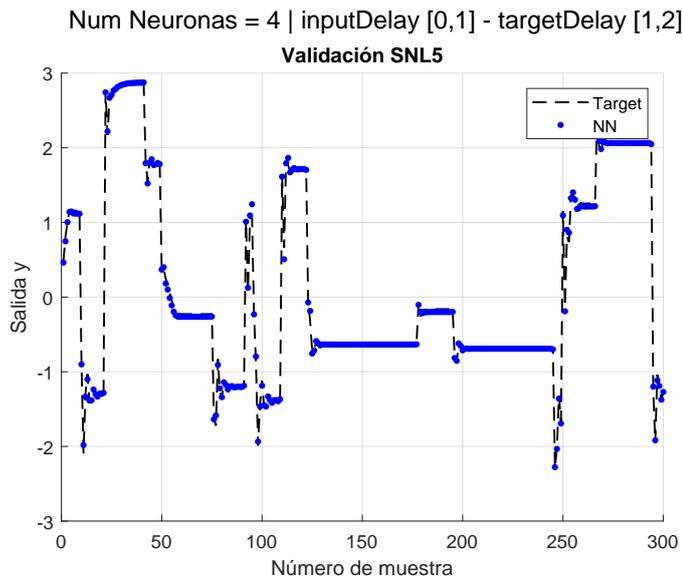


Figura 3: Respuesta de la red neuronal obtenida frente a una entrada de validación

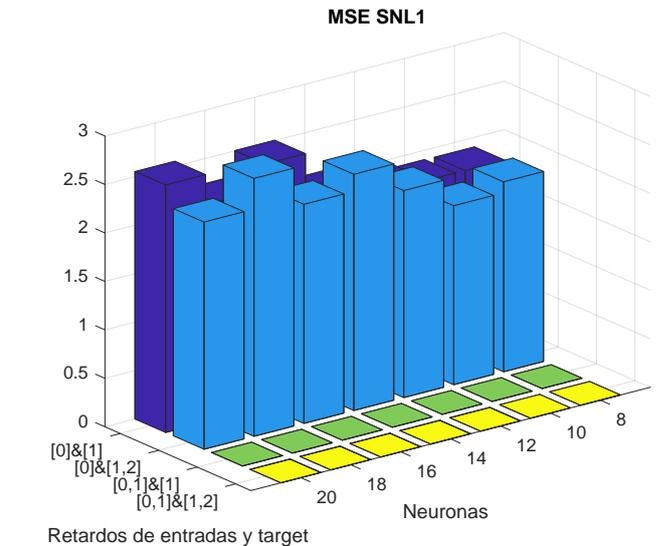


Figura 5: MSE de configuraciones de redes para el sistema MIMO: Subsistema SNL1

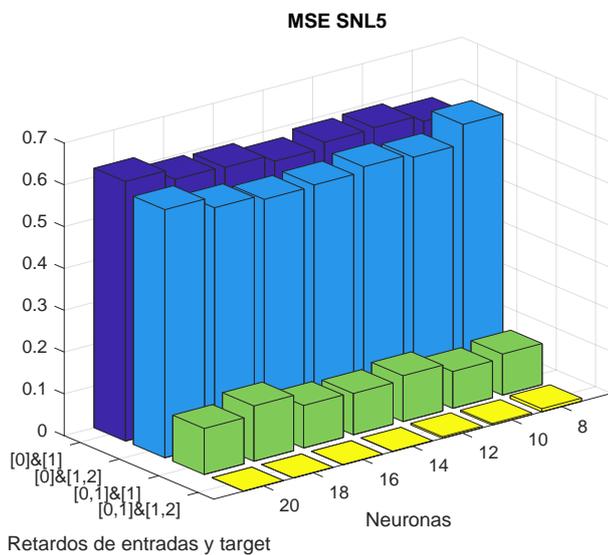


Figura 4: MSE de configuraciones de redes para el sistema MIMO: Subsistema SNL5

se puede observar de nuevo que el parámetro que mayor impacto tiene en la reducción del error es el retardo, en este caso, de las entradas u , aunque el retardo de los $target$ también tiene impacto al combinarlo con el anterior.

Observando los errores, se ha decidido elegir la red neuronal con 14 neuronas, y retardos de entradas 0/1 y retardos de $targets$ 1/2. De nuevo, no se ha seleccionado un número mayor de neuronas debido a la pequeña disminución del error relacionada con aumentar más el número de neuronas.

Realizando una validación con entradas en los rangos $[-2,5, 2,5]$ para la primera entrada (SNL5), y $[-1,8, 1,8]$ para la segunda entrada (SNL1) (figura 6), se comprueba que la respuesta para ambas salidas es excelente, y sigue muy de cerca ambas salidas simultáneamente, con un error muy ajustado.

Num Neuronas = 14 | inputDelay [0,1] - targetDelay [1,2]

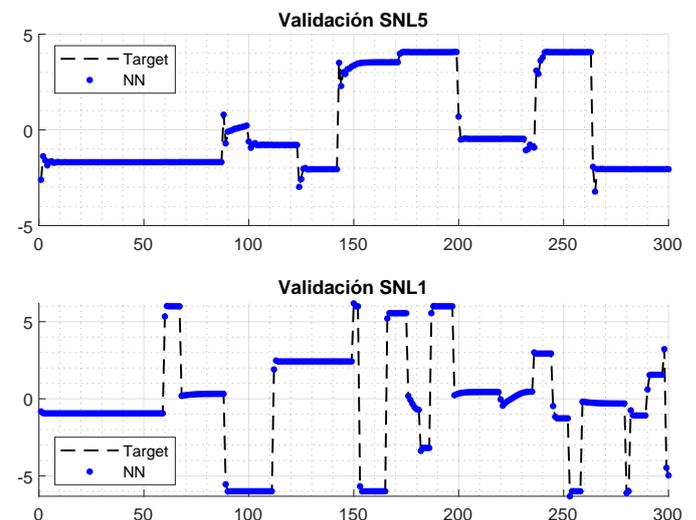


Figura 6: Respuesta ante validación de la red neuronal elegida para el sistema MIMO

4. Líneas de trabajo futuras

En el futuro, el objetivo es el desarrollo de un modelo neuronal MIMO de un sistema acoplado. Un ejemplo de este es el modelo *Twin-Rotor*, provisto por *Feedback Instruments Ltd* (Feedback Instruments, 2001); que se trata de un modelo MIMO 2x2 fuertemente acoplado.

Adicionalmente, también queda ampliar el uso de estos modelos neuronales a estrategia de Control Inteligente, como el iMO-NMPC (Valera García et al., 2012) para estos sistemas acoplados, en los que resulta crucial que el error del modelo sea mínimo para que el control funcione.

Otro posible desarrollo futuro de estos modelos neuronales pasa por la inclusión de otros parámetros no contemplados, como la adición de capas adicionales, o otras arquitecturas de redes.

Finalmente se buscará la integración de los modelos obtenidos en aplicaciones de tiempo real de MATLAB/Simulink a

modo de código adicional de s-functions.

Referencias

- Bamimore, A., Osinuga, A., Kehinde-Abajo, T., Osunleke, A., Taiwo, O., 2021. A comparison of two artificial neural networks for modelling and predictive control of a cascaded three-tank system. *IFAC-PapersOnLine* 54 (21), 145–150, control Conference Africa CCA 2021.
DOI: <https://doi.org/10.1016/j.ifacol.2021.12.025>
- Camacho, E. F., Bordons, C., 2007. *Nonlinear Model Predictive Control: An Introductory Review*. Springer Berlin Heidelberg, Berlin, Heidelberg, pp. 1–16.
DOI: 10.1007/978-3-540-72699-9_1
- Feedback Instruments, L., 2001. Twin Rotor MIMO System Control Experiments 33-949S. Feedback.
- Hornik, K., Stinchcombe, M., White, H., 1990. Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks. *Neural Networks* 3 (5), 551–560.
DOI: [https://doi.org/10.1016/0893-6080\(90\)90005-6](https://doi.org/10.1016/0893-6080(90)90005-6)
- Jagannathan, S., Lewis, F., 1996. Identification of nonlinear dynamical systems using multilayered neural networks. *Automatica* 32 (12), 1707–1712.
DOI: [https://doi.org/10.1016/S0005-1098\(96\)80007-0](https://doi.org/10.1016/S0005-1098(96)80007-0)
- Larrea, M., Larzabal, E., Irigoyen, E., Valera, J., Dendaluze, M., 2015. 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, sI: SOCO12.
DOI: <https://doi.org/10.1016/j.jal.2014.11.005>
- Perrusquía, A., Yu, W., 2021. Identification and optimal control of nonlinear systems using recurrent neural networks and reinforcement learning: An overview. *Neurocomputing* 438, 145–154.
DOI: <https://doi.org/10.1016/j.neucom.2021.01.096>
- Valera García, J. J., Gómez Garay, V., Irigoyen Gordo, E., Artaza Fano, F., Larrea Sukia, M., 2012. 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.
DOI: <https://doi.org/10.1016/j.eswa.2011.12.052>