

# ANÁLISIS DE VIBRACIONES EN UNA ESTRUCTURA UTILIZANDO ECHO STATE NETWORKS

Ignacio Díaz Blanco, Diego García Pérez, Ana González Muñoz, Abel A. Cuadrado Vega

Área de Ingeniería de Sistemas y Automática, Universidad de Oviedo

Campus universitario de Gijón s/n, 33204

idiaz@uniovi.es, diegogarcia@isa.uniovi.es, anaglezmuniz@gmail.com, cuadrado@isa.uniovi.es

## Resumen

*En este artículo se propone explorar el uso de redes neuronales recurrentes de tipo echo state network (ESN) como herramientas para la detección y diagnóstico de fallos en estructuras. Se trata de una primera experiencia en el uso de las ESN para la detección de anomalías, que ha sido testada sobre datos reales de vibración de una estructura excitada por impacto. El análisis de los residuos entre las estimaciones de los modelos ESN y los valores reales de vibración ha permitido detectar la presencia de condiciones anómalas en la estructura, demostrando con ello el potencial de este enfoque preliminar.*

**Palabras clave:** sensores virtuales, monitorización de salud estructural, métodos basados en vibración, análisis inteligente de datos.

## 1. INTRODUCCIÓN

La monitorización de salud estructural (*structural health monitoring*, SHM) tiene como objetivo la caracterización de estructuras y la implementación de métodos de detección de daños en las mismas, tales como roturas o degradación en los elementos que las integran [1, 2]. Una vía para abordar esta monitorización es el análisis de las relaciones dinámicas entre excitación y respuesta en las estructuras, para lo cual se requiere la obtención de modelos dinámicos capaces de reflejar dichas relaciones.

Estos modelos pueden obtenerse a partir de primeros principios, fundamentalmente conceptos de física y mecánica y concretamente técnicas de *análisis modal*. En estructuras complejas, la obtención de modelos basados en ecuaciones físicas requiere el uso de sistemas basados en elementos finitos, que requieren un conocimiento detallado de la geometría del sistema y resultan laboriosos.

Un enfoque alternativo consiste en el uso de *métodos basados en datos*, que utilizan técnicas estadísticas y algoritmos de aprendizaje automático (*machine learning*) para ajustar las observaciones a modelos genéricos previamente establecidos: <https://doi.org/10.17979/spudc.9788497497169.186>

dos. Una de las ventajas de las técnicas basadas en este enfoque consiste en que requiere menos conocimiento *a priori* de la estructura al basarse en la hipótesis de modelos genéricos, lo que los hace más versátiles.

Para la caracterización basada en datos del comportamiento dinámico de estructuras, es habitual aplicar una excitación. Típicamente, se ejerce una fuerza  $F(t)$  variable (ej. barrido frecuencial, impacto, etc.) en un punto de la estructura y se registran las respuestas, normalmente aceleraciones  $a(t)$ , en uno o varios puntos de la estructura. Esta caracterización suele realizarse mediante curvas de respuesta en frecuencia (*frequency response functions*, FRF), de las que se pueden extraer parámetros, como las frecuencias de resonancia, amortiguamientos, etc., que caracterizan el estado de la estructura; o mediante *modelos dinámicos* genéricos cuyos parámetros son determinados mediante técnicas de *identificación de sistemas* a partir de datos experimentales de respuesta del sistema ante excitaciones conocidas.

En este contexto, se ha explorado el uso de las *echo state networks ESN* para la detección de anomalías en una estructura sometida a impactos. Las ESN se enmarcan en las denominadas técnicas de computación de reservorio (*reservoir computing*, RC), un paradigma para la identificación de sistemas dinámicos no lineales, presentado originalmente en [3] pero que ha tenido un importante impacto en la última década [4], el cual se basa en la generación de un número muy elevado de modos dinámicos (reservorio) mediante un sistema de ecuaciones diferenciales no lineales acopladas a partir de señales de excitación, seguido de una aproximación lineal de la respuesta determinada mediante técnicas estándar (*ridge regression*, pseudoinversa de *Moore Penrose*) a partir de dichos estados.

En este trabajo se presentan resultados preliminares de aplicación de las ESN para relacionar las aceleraciones registradas en diversos puntos de la estructura tras someterla a un impacto. Los modelos obtenidos permiten estimar una aceleración  $a_i(t)$  a partir de una aceleración  $a_j(t)$  en las condiciones de operación en las que se obtienen los datos

empleados para el ajuste del modelo. En la fase de inferencia, se analizan las diferencias –residuos– entre la estimación y el valor real de la aceleración de respuesta para determinar la presencia de condiciones anómalas.

El resto del artículo está organizado de la siguiente manera. En la sección 2 se describen en detalle las ESN y los procedimientos de aprendizaje empleados; en la sección 3 se expone el procedimiento de aplicación de las ESN para la detección de fallos; en la sección 4 se presentan los resultados obtenidos; finalmente, en la sección 5 se presenta una discusión general y líneas futuras.

## 2. ECHO STATE NETWORKS

La representación en espacio de estados es un modelo matemático que permite definir el comportamiento de un sistema físico, determinando la evolución de un vector de salidas  $\mathbf{y}(k) \in \mathbb{R}^q$  a partir de un vector de entradas  $\mathbf{u}(k) \in \mathbb{R}^p$  y de un vector de estados  $\mathbf{x}(k) \in \mathbb{R}^n$  mediante un sistema de ecuaciones diferenciales de primer orden. Formalmente:

$$\begin{aligned} \mathbf{x}(k+1) &= f(\mathbf{x}(k), \mathbf{u}(k)) \\ \mathbf{y}(k) &= g(\mathbf{x}(k), \mathbf{u}(k)) \end{aligned} \quad (1)$$

donde las funciones  $f$  y  $g$  son, en general, no lineales. El modelo (1) es muy general y describe una clase muy amplia de sistemas dinámicos, siendo la base de la mayoría de sistemas de simulación como simulink o Easy Java Simulator (EJS), por citar algunos bien conocidos en la comunidad de Automática.

Para poder modelar este tipo de sistemas suelen asumirse hipótesis de linealidad, pero la naturaleza no lineal de las funciones  $f$  y  $g$  hace difícil (o imposible) plantear una identificación del sistema en términos de una regresión mínimo-cuadrática lineal (2):

$$\mathbf{y}(k) = \theta(k)^T \varphi(k) \quad (2)$$

donde  $\theta = (\theta_1, \dots, \theta_n)^T$  son los parámetros del modelo y  $\varphi = (\varphi_1, \dots, \varphi_n)$  es un vector de datos o regresores compuesto de salidas y entradas, actuales y previas, del sistema y/o funciones no lineales de ellas.

Las denominadas *echo state networks* [3, 5, 4] son un caso particular de (1), basado en el concepto de *expansión no lineal* [5] en el que se considera un vector de estados de muy alta dimensión, un modelo no lineal en la ecuación de estado y un modelo lineal de la salida a partir del estado

$$\begin{aligned} \mathbf{x}(k) &= \sigma(\mathbf{W}_{res}\mathbf{x}(k-1) + \mathbf{W}_{in}\mathbf{u}(k)) \\ \mathbf{y}(k) &= \mathbf{W}_{out}\mathbf{x}(k) \end{aligned} \quad (3)$$

<https://doi.org/10.17979/spudc.9788497497169.186>

El modelo (3) es un caso particular de (1) que tiene como parámetros la matriz de reservorio  $\mathbf{W}_{res} \in \mathbb{R}^{n,n}$ , una matriz de entradas  $\mathbf{W}_{in} \in \mathbb{R}^{n,p}$  y una matriz de salidas  $\mathbf{W}_{out} \in \mathbb{R}^{q,n}$ .

La idea detrás de este modelo se basa en el concepto de *expansión no lineal* [5] — también aplicado en las *máquinas de vectores de soporte* [6] y *extreme learning machines* [7] para el aprendizaje de mapeos estáticos— en el que se considera un mapeo no lineal a un espacio de alta dimensión en el que se resuelve un problema lineal. En el modelo (3) se considera un vector de estados de muy alta dimensión, con una función no lineal  $f$  (habitualmente funciones sigmoideas) en la ecuación de estado, en la que las matrices  $\mathbf{W}_{res}, \mathbf{W}_{in}$  son generadas a partir de valores aleatorios, con algunas restricciones menores de dispersión (*sparsity*) y escalado de la matriz de reservorio  $\mathbf{W}_{res}$  para asegurar que la ecuación de estados (3) es estable<sup>1</sup>.

En estas condiciones, la ecuación de estados de la ESN es un sistema de ecuaciones en diferencias de primer orden, acopladas y no lineales que, a partir de las entradas conocidas  $\mathbf{u}(k)$  permite generar, aplicándola de forma iterativa, secuencias de valores para los  $n$  estados  $x_1(k), x_2(k), \dots, x_n(k)$  de  $\mathbf{x}(k)$ , para  $k = 1, \dots, N$ . Con una adecuada elección en la generación de las matrices  $\mathbf{W}_{in}$  y sobre todo  $\mathbf{W}_{res}$  este numeroso conjunto de estados  $x_i(k)$  puede verse como un *reservorio* de modos transitorios con una elevada riqueza y variedad de comportamientos dinámicos, que pueden recomponerse después mediante una combinación lineal para reconstruir una dinámica dada. A este proceso de generación del reservorio se le conoce como recolección de estados o *state harvesting*.

Al ser lineal la ecuación de salidas de (3) y conocerse esta reconstrucción, nos encontramos ya ante un problema lineal. Definiendo la matriz que contiene todos los estados recolectados

$$\mathbf{X} = (\mathbf{x}(1), \mathbf{x}(2), \dots, \mathbf{x}(n)) \in \mathbb{R}^{n,N}$$

y la matriz que contiene las salidas

$$\mathbf{Y} = (\mathbf{y}(1), \mathbf{y}(2), \dots, \mathbf{y}(n)) \in \mathbb{R}^{q,N}$$

la ecuación de salidas de (3) conduce a un problema de regresión lineal

$$\mathbf{Y} = \mathbf{W}_{out}\mathbf{X}$$

que puede resolverse mediante técnicas de mínimos cuadrados como *ridge regression*  $\mathbf{W}_{out} \approx$

<sup>1</sup>Esto se consigue asignando  $\mathbf{W}_{res} \leftarrow \mathbf{W}_{res} \frac{\lambda^*}{\lambda_{max}}$ , siendo  $\lambda_{max}$  el máximo valor propio y  $\lambda^*$  el radio espectral objetivo, lo que implica estabilidad en el caso de  $\sigma$  lineal. El carácter saturado de  $\sigma$  dificulta aún más que el sistema se inestabilice, por lo que a veces puede elegirse  $\lambda^*$  ligeramente mayor que 1.

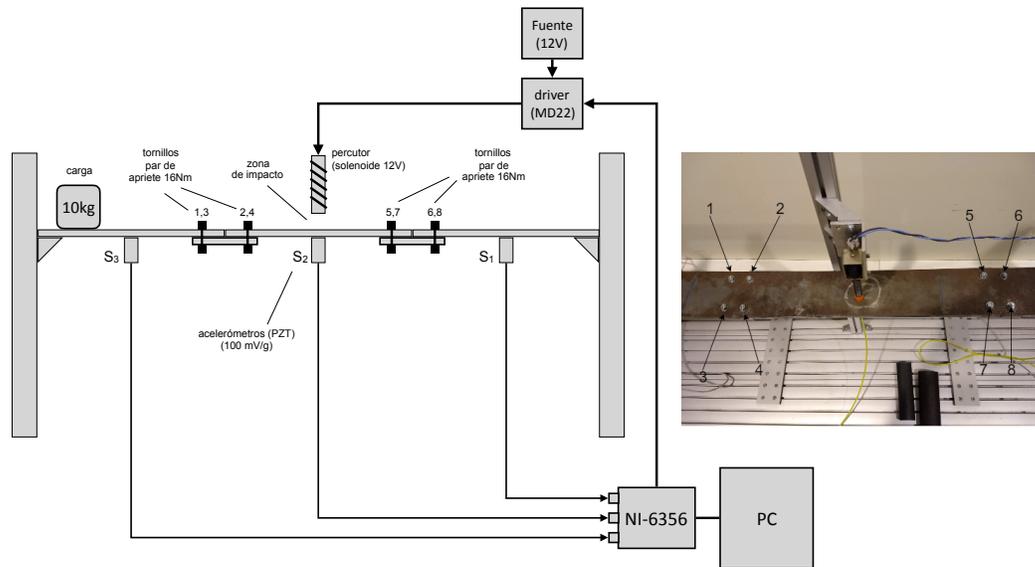


Figura 1: Esquema de la bancada SHM y foto de detalle del percutor y los tornillos.

$(\mathbf{X}\mathbf{X}^T + \lambda\mathbf{I})^{-1}\mathbf{X}^T\mathbf{Y}^T$ , donde  $\lambda$  (regularización de Tikhonov) se elige con un valor cercano a cero, o utilizando la *pseudoinversa de Moore-Penrose*,  $\mathbf{X}^+$ , para calcular  $\mathbf{W}_{out} \approx \mathbf{X}^+\mathbf{Y}$ .

La matriz  $\mathbf{W}_{out}$  resultante combina linealmente los estados del reservorio generados a partir de las entradas  $\mathbf{u}(k)$  para generar las salidas  $\mathbf{y}(k)$  del sistema dinámico. Así, esta matriz actúa seleccionando las dinámicas del reservorio que mejor describen el comportamiento dinámico del sistema y combinándolas. Con una adecuada elección de los parámetros, el conjunto de las operaciones de (3), a) recolección de estados y b) combinación lineal de los estados, es un sistema dinámico que modela el sistema objetivo con precisiones muy altas<sup>2</sup> que requiere un tiempo de entrenamiento muy inferior, por ejemplo, al de las redes neuronales profundas que usan algoritmos iterativos como el *backpropagation* o variantes del mismo.

### 3. DETECCIÓN DE FALLOS

La capacidad de las ESN para modelar la relación dinámica entre una secuencia de entradas o excitaciones  $\mathbf{u}(k)$  y una secuencia de salidas o respuestas  $\mathbf{y}(k)$  de un sistema dinámico genérico, permite la implementación de *sensores virtuales*. Un sensor virtual permite la estimación de una propiedad o variable de un proceso a partir de medidas indirectas disponibles que afectan a la variable estimada. Esto permite medir una propiedad para la que no

<sup>2</sup>En el trabajo [4] de 2009, se reportan para algunos problemas, precisiones hasta tres órdenes de magnitud mayores que los métodos anteriores de identificación no lineal.  
<https://doi.org/10.17979/spudc.9788497497169.186>

se dispone de sensor (o es muy caro), o bien ésta se desea medir en un punto diferente a aquél en el que está ubicado el sensor físico.

Sin embargo, otro uso interesante de los sensores virtuales es la generación de medidas redundantes, a través de la estimación de una variable que ya se está midiendo con un sensor físico. Esta idea, denominada *redundancia analítica* es de gran utilidad en el ámbito de la detección y diagnóstico de fallos a través de la generación de *residuos* mediante la diferencia entre las  $q$  variables medidas por el sensor real  $\mathbf{y}(k) = (y_1(k), \dots, y_q(k))^T$  y las  $q$  estimaciones del sensor virtual  $\hat{\mathbf{y}}(k) = (\hat{y}_1(k), \dots, \hat{y}_q(k))^T$ .

$$\mathbf{r}(k) = \mathbf{y}(k) - \hat{\mathbf{y}}(k) \quad (4)$$

Si el sistema o proceso se comporta de forma acorde con el modelo del sensor virtual, los  $q$  residuos  $r_1(k), \dots, r_q(k)$  de la ecuación (4) serán cercanos a cero, o bien  $\|\mathbf{r}(k)\|^2 \approx 0$ . Si el proceso, por el contrario, sufre un cambio en su comportamiento, el modelo ya no es válido y uno o más residuos se desvían de cero,  $\|\mathbf{r}(k)\|^2 \gg 0$ . Los residuos, por tanto, son indicadores de que la condición del proceso no concuerda con las hipótesis hechas en el modelado. Si las hipótesis del modelado cubren razonablemente el espectro de condiciones de funcionamiento “normales”, los residuos son indicadores de anomalías y por tanto de fallos potenciales. Los residuos portan información altamente específica de los espacios de fallo, ya que idealmente todas las condiciones contempladas como normales son descontadas, por lo que son muy útiles como entradas a algoritmos de aprendizaje automático (ej. clasificadores) o simplemente visualizados, por ejemplo

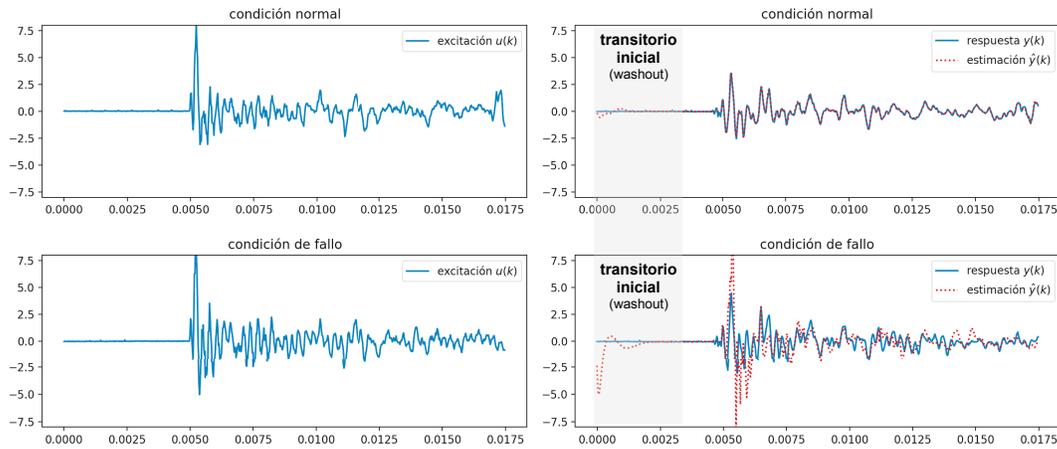


Figura 2: Pareja excitación-respuesta  $\{\mathbf{u}(k), \mathbf{y}(k)\}$  para dos de los impactos (normal y con fallo). A la izquierda, excitación en la zona de impacto ( $S_2$ ); a la derecha, respuesta en un extremo ( $S_1$ ) y estimación del modelo ESN.

en sistemas de supervisión SCADA.

- 
- 0 - condiciones normales (tornillos apretados)
  - 1 - tornillo aflojado (1)
  - 2 - tornillo aflojado (2)
  - 3 - tornillo aflojado (5)
  - 4 - tornillo aflojado (8)
  - 5 - carga situada en el lado izquierdo
  - 6 - carga situada en el lado derecho
- 

Cuadro 1: Condiciones de los ensayos de impacto.

## 4. RESULTADOS

### 4.1. Ensayos de impacto

La metodología descrita se aplicó a datos reales de vibración de una bancada –ver Figura 1– para monitorización de salud estructural (SHM), consistente en una estructura metálica tipo puente con tres piezas atornilladas en el vano, dotada de un percutor (solenoides a 12V) y tres acelerómetros piezoeléctricos  $S_1, S_2, S_3$  (sensibilidad 100mV/g), ubicados uno en cada pieza. El sensor  $S_2$  está ubicado justo en el punto de impacto del percutor.

La bancada fue sometida a ensayos de impacto en 7 condiciones distintas (ver Cuadro 1), realizando 30 impactos en cada una de las condiciones. En todos los ensayos se impactó la estructura con el percutor y se registraron las aceleraciones instantáneas de los sensores  $S_1, S_2, S_3$  antes y después del impacto, con una frecuencia de muestreo de 40 kHz, utilizando una tarjeta de adquisición de datos NI-6356.

<https://doi.org/10.17979/spudc.9788497497169.186>

3

### 4.2. Tratamiento de los datos

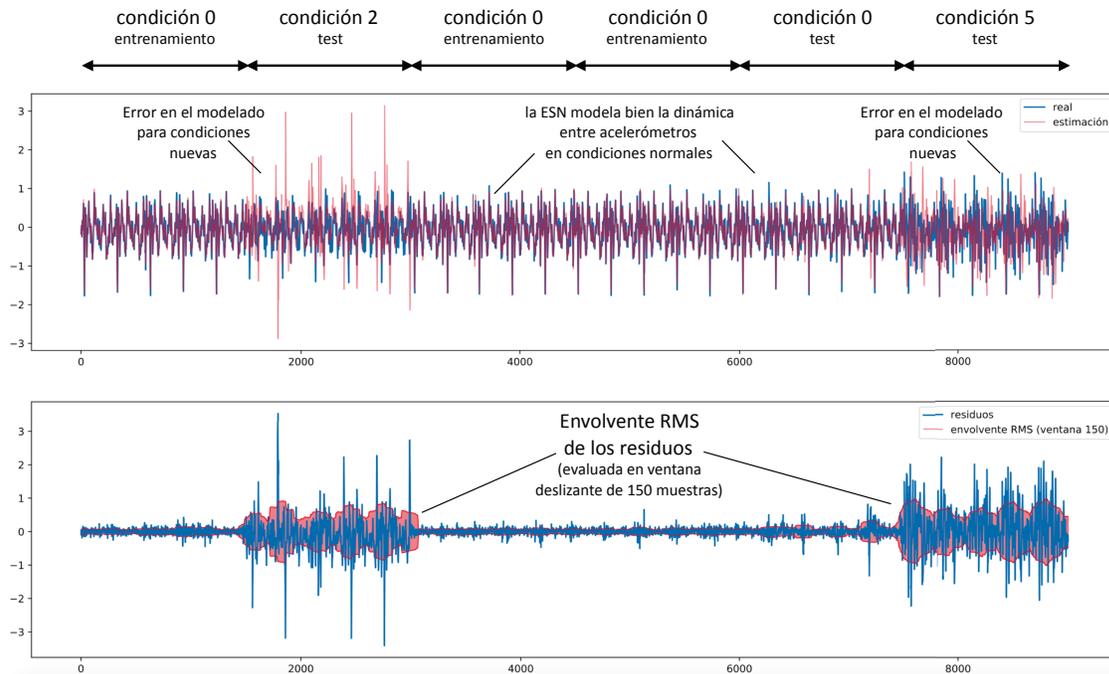
Para cada ensayo de impacto, se generó una pareja excitación-respuesta  $\{\mathbf{u}(k), \mathbf{y}(k)\}$  de 700 muestras, abarcando desde 200 muestras (5 ms) antes del golpe hasta 500 muestras (12,5 ms) después del golpe. En total se procesaron 30 impactos para las 7 condiciones del Cuadro 1.

El modelo se entrenó con 20 ensayos de impacto de la condición 0 (normal, tornillos apretados, con par de apriete de 16 Nm) y se testó por lotes, uno a uno, para un total de 30 impactos en distintas condiciones: 5 impactos de la condición 0 (normal, incluidos en el entrenamiento), 5 impactos en la condición 2 (tornillo flojo, con par de apriete 5 Nm), 15 impactos en la condición 0 (normal, los 5 últimos impactos no incluidos en el entrenamiento) y 5 impactos en la condición 5 (carga en un extremo). La fase de test consistió en aplicar la entrada  $\mathbf{u}(k)$  correspondiente al modelo y obtener la salida  $\hat{\mathbf{y}}(k)$  estimada. En la Figura 2 se muestra la excitación, respuesta y estimación de la respuesta mediante la ESN para dos de los impactos. Puede observarse cómo la estimación de la ESN difiere en el ensayo con condición de fallo.

### 4.3. Residuos del modelo ESN

Se obtuvieron los residuos mediante la diferencia entre la respuesta medida por el sensor y la estimación obtenida por el modelo de la ESN (4).

Al aplicarse la ESN por lotes (una vez por ensayo de impacto), sus condiciones iniciales parten de cero en cada impacto y la ESN atraviesa un breve transitorio hasta que converge –ver Figura 2–, por lo que en las comparaciones se desechó una porción (*washout*) de los residuos de 400 muestras en cada



mpactos incluyendo la condición normal 0 (impactos 2 y 5 (todos los impactos de test)).

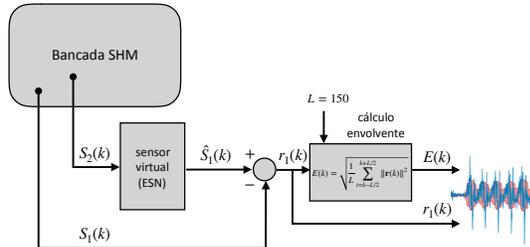


Figura 4: Diagrama de bloques.

Finalmente, se obtuvo la envolvente de los residuos resultantes (Figura 4), calculando el valor eficaz (RMS) de los residuos en ventanas de tamaño  $L = 150$  muestras (5).

$$E(k) = \sqrt{\frac{1}{L} \sum_{i=k-L/2}^{k+L/2-1} \|r(k)\|^2} \quad (5)$$

En la Figura 3 se observan, en la parte superior, la variable original y las estimaciones que produce la ESN. Se aprecia claramente que la estimación es más precisa en los tramos con las condiciones de entrenamiento de la ESN y, sin embargo, el modelo comete error cuando la bancada opera en condiciones diferentes (tornillo flojo y carga en el lateral). Asimismo, el error bajo en condiciones normales no se ve apenas afectado en condiciones normales no utilizadas en el entrenamiento. <https://doi.org/10.17979/spudc.9788497497169.186>

En la figura 5 se muestran indicadores de la calidad de la clasificación. Se obtuvo la curva ROC, representando la tasa de falsas alarmas (FPR) frente a alarmas reales (TPR) para distintos umbrales. A la derecha se muestra la exactitud (accuracy) obtenida en la clasificación en función del umbral. Puede apreciarse que la envolvente RMS propuesta como indicador para la detección de fallos muestra muy buenos resultados, con exactitudes cercanas a 1 para un rango de umbrales.

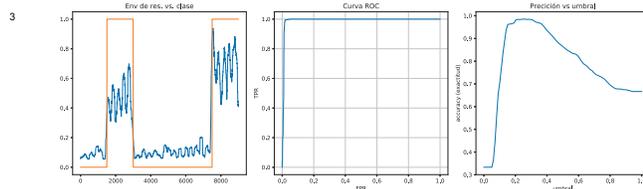


Figura 5: A la izquierda envolvente RMS vs. clase; en el centro, curva ROC; a la derecha se muestra la exactitud (accuracy) en la clasificación en función del umbral

## 5. CONCLUSIONES

Este trabajo muestra resultados preliminares de aplicación de redes neuronales recurrentes de tipo *echo state network (ESN)* para detección de anomalías en estructuras. Estos resultados muestran que la ESN permite una identificación de dinámicas no lineales en problemas complejos como el

análisis modal en estructuras, en las que se producen fenómenos vibratorios complejos en medios no continuos (estructuras con uniones atornilladas). A diferencia de otros enfoques, basados en arquitecturas con varias capas (perceptrones multicapa, MLP o deep MLP) que requieren procedimientos de entrenamiento largos, generalmente basados en *backpropagation* y variantes de esta técnica, las ESN requieren solo la generación de estados y una regresión lineal (inversión de una matriz), lo que las hace mucho más rápidas y versátiles en la configuración de esquemas de detección y diagnóstico de fallos.

Aunque los resultados son muy prometedores, este trabajo es una primera experiencia del uso de estas técnicas en un problema de análisis de vibración con datos reales. Queda aún trabajo pendiente, como la realización de una comparación exhaustiva con otras técnicas de identificación de sistemas, incluyendo modelos lineales (ARX) como base para la comparación, modelos no lineales basados en mapeos no lineales estáticos que relacionen entradas y salidas retardadas con la salida (NARX) y el uso de arquitecturas convolucionales (deep CNN), entre otras. Por otra parte, los resultados consideran la relación entre los sensores  $S_1$  y  $S_2$ . El uso concurrente del tercer sensor  $S_3$  para mejorar la capacidad discriminativa plantea otra vía interesante de trabajo. Finalmente, los resultados plantean solo detección de anomalías. Sin embargo, la exactitud mostrada en el método propuesto, permitiría plantear esquemas de diagnóstico si se tienen datos etiquetados de fallo, basados en arrays de residuos y un algoritmo de clasificación.

#### Agradecimientos

Actividad realizada en el marco del proyecto DPI2015-69891-C2-2-R, financiada por el Ministerio de Economía y Competitividad (MINECO), Programa Estatal de I+D+i Orientada a los Retos de la Sociedad y por el Fondo Europeo de Desarrollo Regional (FEDER) “Una manera de hacer Europa”. Además, dos de los co-autores del presente trabajo disfrutaron de una ayuda predoctoral del Gobierno del Principado de Asturias a través de su programa “Severo Ochoa” de ayudas predoctorales para la investigación y docencia del Principado de Asturias.

#### English summary

## VIBRATION ANALYSIS IN STRUCTURES USING ECHO STATE NETWORKS

#### Abstract

*This article proposes to explore the use of recur-*

*rent echo state network (ESN) as tools for the detection and diagnosis of failures in structures. This is a first experience in the use of ESN for anomaly detection, which has been tested on real vibration data of an impact-excited structure. The analysis of the residues between the ESN model estimations and the real vibration values has allowed to detect the presence of anomalous conditions in the structure, thus demonstrating the potential of this preliminary approach.*

**Keywords:** virtual sensors, SHM, vibration-based methods, intelligent data analysis

#### Referencias

- [1] Hoon Sohn, Charles R Farrar, Francois M Hemez, Devin D Shunk, Daniel W Stinemates, Brett R Nadler, and Jerry J Czarnecki. A review of structural health monitoring literature: 1996–2001. *Los Alamos National Laboratory, USA*, 2003.
- [2] Charles R Farrar and Scott W Doebling. Structural health monitoring at los alamos national laboratory. 1999.
- [3] Herbert Jaeger. The “echo state” approach to analysing and training recurrent neural networks-with an erratum note. *Bonn, Germany: German National Research Center for Information Technology GMD Technical Report*, 148(34):13, 2001.
- [4] Mantas Lukoševičius and Herbert Jaeger. Reservoir computing approaches to recurrent neural network training. *Computer Science Review*, 3(3):127–149, 2009.
- [5] Herbert Jaeger. Echo state network. *Scholarpedia*, 2(9):2330, 2007.
- [6] Bernhard Scholkopf. *Support Vector Learning*. PhD thesis, Technischen Universität Berlin, Septiembre 1997.
- [7] Guang-Bin Huang, Qin-Yu Zhu, and Chee-Kheong Siew. Extreme learning machine: theory and applications. *Neurocomputing*, 70(1-3):489–501, 2006.



© 2019 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>).