

Recibido: 05.02.2025 • Aceptado: 29.01.2026

Palabras clave: Inteligencia artificial, redes neuronales, Morlet wavelet, sistemas dinámicos, caos.

“Redes neuronales recurrentes: El cerebro artificial que aprende del pasado”

DANIEL ALEJANDRO MAGALLÓN GARCÍA
daniel.magallon6532@academicos.udg.mx
COORDINACIÓN ACADÉMICA REGIÓN ALTIPLANO OESTE, UASLP
LUIS JAVIER ONTAÑÓN GARCÍA PIMENTEL
luis.ontanon@uaslp.mx
COORDINACIÓN ACADÉMICA REGIÓN ALTIPLANO OESTE, UASLP
JOSÉ LUIS ECHENEUSIA MONROY
echeneusia@cicese.mx
CENTRO DE INVESTIGACIÓN CIENTÍFICA Y DE EDUCACIÓN
SUPERIOR DE ENSENADA (CICESE)
JONATAN PEÑA RAMÍREZ
jpena@cicese.mx
CENTRO DE INVESTIGACIÓN CIENTÍFICA Y DE EDUCACIÓN
SUPERIOR DE ENSENADA (CICESE)



Las redes neuronales artificiales recurrentes de primer orden con activación *Morlet wavelet* representan un enfoque innovador para la identificación y el análisis de sistemas dinámicos, incluidos aquellos con comportamientos caóticos. En este artículo se explican los fundamentos de las redes neuronales, las funciones de activación y los algoritmos de entrenamiento, destacando el uso de *wavelets* para el modelado de dinámicas temporales, lo que resulta en aplicaciones clave en la predicción, el control y la simulación de sistemas dinámicos.

Comprender cómo funciona el cerebro es uno de los hitos más importantes de la ciencia. Su exploración se basa en la idea de que su funcionamiento depende de la interconexión de pequeños agentes que llamamos neuronas, donde cada una de ellas puede exhibir un amplio comportamiento no lineal. En este sentido, la ciencia busca crear modelos cada vez más realistas y biológicamente plausibles que muestren capacidades de aprendizaje y adaptación similares a las observadas en el cerebro humano.

Hoy en día, gracias a los avances en electrónica y computación, es posible desarrollar sistemas de inteligencia artificial más avanzados, capaces de manejar tareas complejas como el reconocimiento de patrones, la toma de decisiones y el aprendizaje a partir de la experiencia, imitando el comportamiento dinámico del cerebro.

La inteligencia artificial es una rama de las ciencias computacionales (Figura 1) y, dentro de ella, se subdividen áreas específicas de aplicación, como los sistemas expertos, el procesamiento de lenguaje natural (lo que hace ChatGPT) y el aprendizaje de máquina. En esta última área se exploran la catalogación y clasificación precisa de grandes cantidades de información.

Los algoritmos de aprendizaje profundo tienen sus raíces a principios de la década de 1980, con el trabajo de John Hopfield (Hopfield, 1982), quien presentó un modelo capaz de almacenar y recuperar patrones de información. Desde entonces, se ha intensificado la investigación y el desarrollo de algoritmos más robustos y eficientes, que ahora se utilizan para resolver problemas ordinales o temporales; por ejemplo, la traducción de idiomas, el reconocimiento de voz y el etiquetado de imágenes.

En particular, las redes neuronales (RN) artificiales forman parte del aprendizaje profundo y son utilizadas en disciplinas como la neurociencia, las matemáticas, la estadística, física, ciencias de la computación e ingeniería. Estas redes nos permiten realizar las siguientes tareas: Clasificación de información: determinar si la imagen de una foto corresponde a un perro o no, por ejemplo. Predicción de valores: Calcular el costo de vivienda del siguiente año a partir de datos históricos de costos. Identificación de datos o estados: Seguir o imitar los estados o valores que ciertos sistemas adquieren en el tiempo.

Estas aplicaciones abarcan diversas áreas, incluyendo modelado, análisis de series temporales, reconocimiento de patrones, procesamiento de señales e imágenes, y control, gracias a su capacidad fundamental:

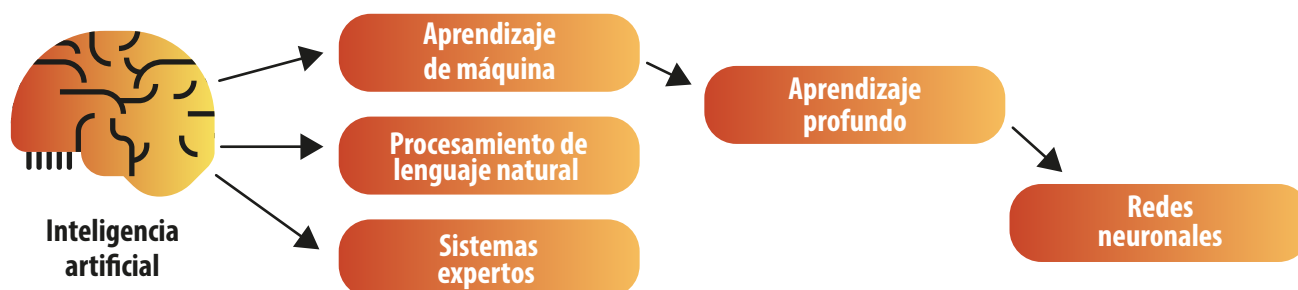


Figura 1.
Diagrama del campo de la inteligencia artificial y algunas de sus áreas

aprender de los datos de entrada y adaptarse a los cambios que se presenten.

Desde el punto de vista estructural, la figura 2 ofrece un panorama general de la conformación de las RN. Estas redes contienen varios elementos o neuronas que pueden representarse mediante parámetros, variables o funciones simples, en cada fila (de 1,2 , hasta i) determina el número de neuronas. Además, el orden de una RN está determinada por la interconexión de neuronas, donde se procesa la información; además de depender del tipo de problema o complejidad que se esté analizando o identificando.

Los parámetros ($a_{-1}, a_{-2}, \dots, a_{-i}; b_{-1}, b_{-2}, \dots, b_{-i}; c_{-1}, c_{-2}, \dots, c_{-i}$) denotados en cada proceso o capa de una red se conocen como pesos sinápticos (como se muestran en la Figura 2). Estos deben ajustarse mediante procesos iterables para converger hacia una salida deseada, empleando ciertos métodos de entrenamiento y validación.

Cada RN tienen entradas y salidas de información interconectadas entre sí, como se observa en las flechas y su sentido. Dependiendo del tipo de conexiones que

muestran, las RN se clasifican principalmente en dos categorías: a) las RN de alimentación hacia adelante (*feedforward*); y b) las RN recurrentes o con realimentación.

Las redes neuronales recurrentes (RNN, por sus siglas en inglés) se caracterizan por la presencia de lazos de retroalimentación entre sus neuronas, lo que las distingue de las redes neuronales *feedforward*, en las cuales la salida de cada neurona se conecta únicamente con las neuronas de la siguiente capa.

Para que una RN realice su tarea, es necesario someterla a procesos de entrenamiento y, posteriormente, validar si lo realizado concuerda con lo esperado. A continuación, se profundiza en estos aspectos.

Función de activación

Para que una RNN pueda catalogar o identificar una persona, una mascota o incluso una señal que contenga información se requieren de funciones de activación, las cuales permiten indicar numéricamente la probabilidad de aparición entre las cosas. Existen varias funciones de activación, pero resaltan dos de las más relevantes, las cuales se muestran gráficamente en la figura 3.

Función sigmoideal: Toma su nombre de la curvatura que surge al graficarla. Esta función asigna valores cercanos a cero cuando no existe similitud y valores cercanos a uno cuando sí la hay, dependiendo de las características de la señal de entrada.

Función Morlet Wavelet: El termino *wavelet* se traduce al español como ondeleta. Esta función se enfoca en detectar periodicidades y singularidades en las señales de entrada, lo que hace que la activación en RN sea adecuada en el uso de señales que varían en el tiempo, como las señales de audio o algunas otras generadas por sistemas físicos. Las wavelets permiten aproximar funciones o datos de señales de entrada incluso cuando presentan señales discontinuas, a diferencias de las señales trigonométricas de seno y coseno. La cantidad o rapidez de oscilaciones que presentan son las que permiten el análisis en la identificación de señales.

Algoritmo de entrenamiento

Las RNN deben ser entrenadas para llevar a cabo la tarea que se les asignan, como, por ejemplo, la identificación de sistemas mecánicos o señales que estos producen a lo largo del tiempo. Para ello, es necesario considerar que las RNN




Figura 2.
Redes neuronales con alimentación: a) hacia adelante (*feedforward*); b) recurrente

funcionan de forma repetitiva o iterada; es decir, repiten sus procesos varias veces durante los entrenamientos para poder comprobar el desempeño de su salida.

A pesar de que existen diferentes métodos de entrenamiento, uno de los más comunes es el filtrado del error. Este algoritmo es usado para ajustar los pesos sinápticos de la red, los cuales deben estar acotados para llevar a cabo la identificación del sistema dinámico. El procedimiento consiste en estimar la diferencia o error entre lo que se desea que la red identifique, comparado con lo que está identificando en algún paso intermedio de salida.

Aplicaciones de las redes neuronales artificiales recurrentes Morlet wavelet

Como se mencionó anteriormente, las RNN tienen múltiples aplicaciones (Magallón-García *et al.* 2024). Sin embargo, las redes neuronales recurrentes de primer orden basadas en wavelets resaltan del resto, ya que desempeñan un papel crucial en el análisis y control de sistemas dinámicos.

En el ámbito académico, un sistema dinámico se define como un conjunto de reglas que describen el comportamiento de una

entidad que cambia con el tiempo. La naturaleza de la entidad puede ser tan simple como el péndulo de un reloj o mucho más compleja como el comportamiento del clima. En este sentido, cualquier agente cuyo comportamiento cambia en el tiempo puede considerarse un sistema dinámico. Estas reglas suelen expresarse mediante ecuaciones diferenciales, ya que las derivadas son herramientas matemáticas que permiten medir los cambios temporales.

Por ejemplo, es posible modelar y medir los cambios en la estatura de una persona a lo largo de su vida o la cantidad de peces capturados por un pescador durante una temporada. Las derivadas permiten describir los cambios entre las relaciones y los elementos presentes en un sistema dinámico. Dado que prácticamente todo lo que nos rodea experimenta cambios con el tiempo, es posible afirmar que se está rodeado de sistemas dinámicos; como el movimiento de los planetas, los flujos de agua en los mantos acuíferos y los de agua potable, la transmisión de energía eléctrica, el comportamiento de la sociedad e incluso el propio ser humano

Las redes neuronales recurrentes de primer orden wavelets son especialmente

eficaces para modelar sistemas dinámicos no lineales, gracias a su capacidad para descomponer señales en diferentes escalas temporales y capturar la evolución de sus dinámicas (Eche-
nausía-Monroy *et al.* 2024). En la identificación de sistemas, estas redes aprenden las relaciones entre entradas y salidas utilizando datos históricos. En el control de sistemas dinámicos, estas redes predicen dinámicas en tiempo real, permitiendo diseñar controladores adaptativos que mejoran la estabilidad y el desempeño.

Un ejemplo de esto se puede apreciar en la figura 4, donde la señal en color negro corresponde a un sistema dinámico con comportamiento caótico. En color naranja, se muestra el resultado de la RNN *Morlet wavelet* tras haber realizado una identificación correcta del sistema en un tiempo muy corto (alrededor de un segundo). A partir de este tiempo, los sistemas permanecen oscilando de manera sincrónica, con un error muy bajo entre sus trayectorias a pesar de la curvatura o cantidad de oscilaciones que presenta la señal original.

Estos resultados pueden ser de utilidad en la identificación de anomalías como vibraciones o irregularidades en sistemas

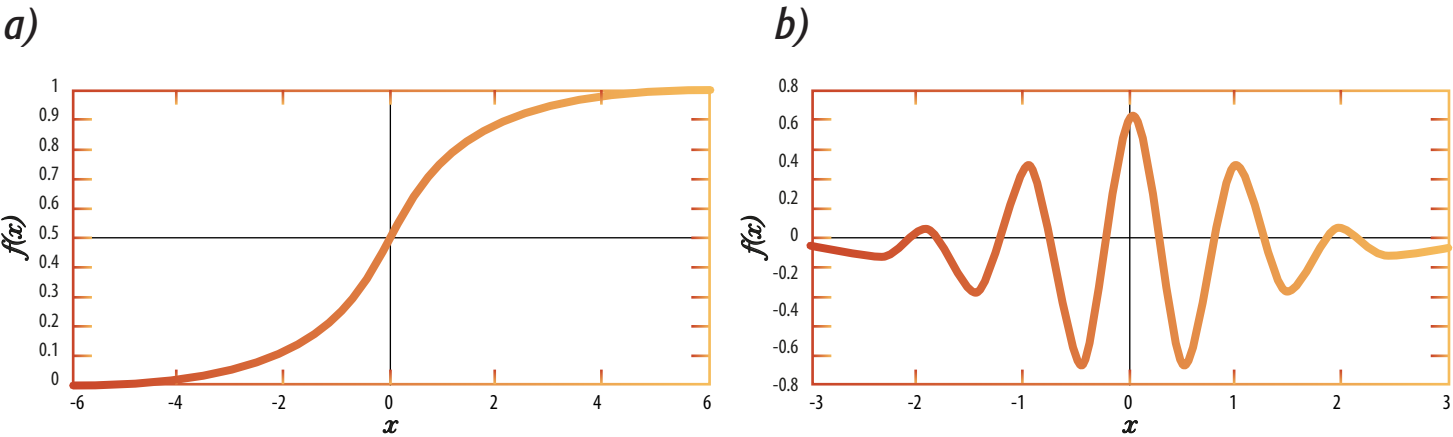


Figura 3.
Funciones de activación: a) Función sigmoidal; b) Función Morlet wavelet.

Doctor en Matemáticas Aplicadas por el Centro Universitario de los Lagos de la Universidad de Guadalajara. Miembro del Sistema Nacional de Investigadoras e Investigadores (SNI), así como también de la Academia Mexicana de Sistemas Dinámicos y Complejidad (AMESDYC). Cuenta con 14 artículos científicos, con más de 100 citas. En la actualidad se desempeña como profesor asignatura nivel B en el Departamento de Ciencias Exactas y Tecnología del Centro Universitario de los Lagos, Universidad de Guadalajara, y en el Departamento de Matemáticas de la Preparatoria Regional de Lagos de Moreno, Universidad de Guadalajara.



de transporte. En aplicaciones industriales, estas redes optimizan procesos al modelar dinámicas complejas y permitiendo ajustes en tiempo real para maximizar la eficiencia y reducir costos. Asimismo, al simular sistemas difíciles de modelar con enfoques tradicionales, estas RNN generan aproximaciones basadas en datos que integran múltiples escalas temporales, proporcionando representaciones más completas y precisas de los sistemas simulados.

La combinación de Redes Neuronales Artificiales (RNA) y sistemas dinámicos ha dado lugar a avances significativos, entre los que destacan:

a) La anticipación del movimiento de objetos físicos o sistemas dinámicos.

b) La aplicación de las RNA en robótica para optimizar su desempeño en tiempo real.

c) La identificación de patrones en datos meteorológicos o mercados financieros.

d) La predicción de datos futuros basados en patrones pasados.

e) El diseño de controladores neuronales para manejar sistemas no lineales en tiempo real.

Conclusiones

En conclusión, las redes neuronales recurrentes de primer orden wavelet son herramientas versátiles y potentes para enfrentar los desafíos relacionados con los sistemas dinámicos. Su capacidad para modelar, predecir, controlar y optimizar

estos sistemas las posiciona como una tecnología clave en una variedad de disciplinas científicas e industriales.

Referencias bibliográficas:

- Echenausía-Monroy, J.L., Pena Ramírez, J., Álvarez, J., Rivera-Rodríguez, R., Ontañón-García, L. J., Magallón García, D. A. (2024). A Recurrent Neural Network for Identifying Multiple Chaotic Systems. *Mathematics*, 12(12), 1835.
- Hopfield, J.J. (1982). "Neural networks and physical systems with emergent collective computational abilities". *Proceedings of the National Academy of Sciences*. 79 (8): 2554–2558.
- Magallón-García, D. A., García-López, J. H., Huerta-Cuellar, G., Jaimes-Reátegui, R., Díaz-Díaz, I. A., & Ontañón-García, L. J. (2024). Real-time neural identification using a recurrent wavelet first-order neural network of a chaotic system implemented in an FPAA. *Integration*, 96, 102134.




Figura 4.
Ejemplo de identificación del estado de un sistema dinámico mediante una RNN