

Interpolation filter based on a neural network

Filtro de interpolación basado en una red neuronal

Camila Munar Torres¹, Nicolas Segura Granados²

Abstract

This work presents an alternative system of interpolation of several signals based on artificial neural networks using MATLAB. Different architectures were tested starting with a neural network with multilayer perceptron topology, seeking to obtain twice as many samples of the original signal, whose training algorithm was performed from a database built by acquiring ECG signals captured in a laboratory by the authors. When testing the performance of the network under more demanding circumstances, such as the generation of more samples and responses to a greater variety of signals, it was evidenced that the performance decreased significantly, so the same architecture was retrained using a new public database of larger size. Looking for alternatives, a model is made using the radial based network topology, then the results obtained in the two topologies are compared using as input signals a composite Sin, SinC, a component of the Lorenz attractor, a high order polynomial and different ECG signals. The results obtained show better results in the radial basis network topology

¹ Electronic engineer student, Distrital University Francisco José de Caldas, Colombia. E-mail: cmunart@correo.udistrital.edu.co. ORCID: <https://orcid.org/0000-0001-8274-799X>

² Electronic engineer student, Distrital University Francisco José de Caldas, Colombia. E-mail: nese gurag@correo.udistrital.edu.co. ORCID: <https://orcid.org/0000-0001-5846-0884>

³ Full-time Professor, Distrital University Francisco José de Caldas, Colombia. E-mail: cperdomo@correo.udistrital.edu.co. ORCID: <https://orcid.org/0000-0001-7310-4618>

compared to the multilayer perceptron topology, however both topologies generate interpolations quite close to the original signal.

Keywords: Computational intelligence, interpolation, neural network, multilayer perceptron, radial basis neural network, sampling.

Resumen

Este trabajo presenta un sistema alternativo de interpolación de varias señales basado en redes neuronales artificiales utilizando MatLab®. Se probaron diferentes arquitecturas comenzando con una red neuronal con topología de perceptrón multicapa, buscando obtener el doble de muestras de la señal original, cuyo algoritmo de entrenamiento se realizó a partir de una base de datos construida mediante la adquisición de señales de ECG capturadas en un laboratorio por los autores. Al probar el rendimiento de la red en circunstancias más exigentes, como la generación de más muestras y respuestas a una mayor variedad de señales, se evidenció que el rendimiento disminuye significativamente, por lo que se reentrenó la misma arquitectura utilizando una nueva base de datos pública de mayor tamaño. Buscando alternativas, se realiza un modelo utilizando la topología de red de base radial, luego se comparan los resultados obtenidos en las dos topologías utilizando como señales de entrada un Sin compuesto, SinC, un componente del atractor de Lorenz, un polinomio de alto orden y diferentes señales de ECG. Los resultados obtenidos muestran mejores resultados en la topología de red de base radial en comparación con la topología de perceptrón multicapa, sin embargo, ambas topologías generan interpolaciones bastante cercanas a la señal original.

Palabras clave: Inteligencia computacional, interpolación, redes neuronales, perceptrón multicapa, redes de base radial, muestreo.

1. Introducción

La conversión analógica-digital consiste en la transcripción de señales analógicas a digitales con el propósito de facilitar su procesamiento, pero se debe tener cuidado ya que, si no se emplean un número suficientes de niveles de cuantificación en el proceso de digitalización, la relación señal a ruido resultante se reducirá con relación a la de la señal analógica original que se cuantificó. Esto es una consecuencia conocida como error de cuantificación.[1] Alrededor de este tema se han desarrollado teorías matemáticas como el Teorema de muestreo de Nyquist-shannon [2] para lograr una correcta discretización. A la hora de discretizar una señal se presentan restricciones de hardware respecto a la frecuencia de muestreo a utilizar, típicamente si se usan componentes económicos que no pueden muestrear a altas tasas, lo que genera una disminución en el ancho de banda máximo de la señal de entrada visto desde el teorema de muestreo de Nyquist y dificulta su reconstrucción. Por lo tanto, se propone un método para realizar dicha reconstrucción de forma digital sin tener que utilizar elementos de hardware muy sofisticados, haciendo uso de las redes neuronales intentando generar una interpolación de datos de la señal digitalizada, implementando diferentes arquitecturas para encontrar la mejor para la reconstrucción de señales analogías digitalizadas.

2. Estado del arte

Para reconstruir la señal a partir de datos de muestreo, generalmente se emplea el método basado en el teorema de muestreo de Shannon. En este método, el error de reconstrucción aparece cuando la señal no satisface la condición de Nyquist. Este artículo propone un nuevo

método de reconstrucción utilizando un perceptrón lineal y un perceptrón multicapa como filtro FIR. El perceptrón que tiene los pesos obtenidos al aprender a adaptar la señal original suprime la diferencia entre la señal reconstruida y la señal original incluso cuando la condición de Nyquist no se mantiene. Aunque el método propuesto necesita datos de peso, el tamaño total de los datos es mucho más pequeño que el método de muestreo ordinario, ya que el filtro de reconstrucción más adecuado se adapta exclusivamente a los datos de muestreo dados,[3]. De otro lado, en una red neuronal de Newton se declaran varios teoremas que revelan esta red entrenada como el mejor aproximador a cualquier curva o superficie con el menor número de patrones de entrenamiento. El número bajo de las muestras de entrenamiento es una ventaja en este tipo de redes neuronales, ya que afecta reduciendo sustancialmente el costo computacional y el tiempo de capacitación, [4].

Por otra parte, un nuevo modelo de reconstrucción de señal de audio que utiliza un algoritmo de estimación no lineal llamado Cartesian Genetic Programming Evolved Artificial Neural Network (CGPANN) estima los gráficos no lineales de señales de audio con mucha mayor precisión que sus contrapartes: La interpolación y extrapolación. se han comparado en términos de mejora de SNR y capacidad para lidiar con disputas de datos. A diferencia de otros algoritmos de reconstrucción convencionales, el algoritmo propuesto puede restaurar la señal que está dañada al 50% por ruido. Un enfoque de vanguardia para la reconstrucción presenta una señal de audio que utiliza el aprendizaje automático. El rendimiento del algoritmo se evalúa midiendo su mejora de señal a ruido (SNR) y la diferencia entre la señal original y la reconstruida en términos de error de porcentaje absoluto medio (MAPE). La mejora de SNR de hasta 20 dB se registra para la estimación de un solo punto con un 25% de muestras

faltantes, 19 dB para una estimación multipunto (hasta 5) en la que falta la mitad de los datos y 16 dB para una señal con ruido variable aleatorio, [5].

En otra perspectiva, un modelo de interpolación de imágenes basado en la red neuronal probabilística (PNN) ajusta automáticamente los parámetros de suavizado para una región de imagen suave / borde variado, y tiene en cuenta las características de suavidad (región plana) y nitidez (región borde) en el mismo modelo. Se utiliza una sola neurona, combinada con el entrenamiento de PSO, para la adaptación de nitidez / suavidad. Finalmente, informamos del rendimiento de estos métodos recientemente propuestos en otro método de interpolación de imágenes, [6].

Entre otros muchos, un método de interpolación en la red neuronal basado en la descomposición wavelet se ha utilizado para mejorar la calidad de las imágenes. Con la descomposición wavelet, las señales de la imagen se pueden dividir en varias porciones de frecuencias de tiempo. En este trabajo, la señal de descomposición wavelet se usa para entrenar las redes neuronales- Los píxeles de la imagen de baja resolución se utilizan como señal de entrada de la red neuronal para estimar todas las sub-imágenes wavelet de la imagen de alta resolución correspondiente, [7].

3. Construcción de la base de datos

Para la experimentación se toman en cuenta dos bases de datos construidas independientemente: **base de datos A:** Creada mediante 17 señales ECG capturadas experimentalmente por los autores del proyecto, de las cuales una se deja 1 para validación. Las señales son de dimensiones $600 * 2$, Generando una matriz de entrada X de $6 * n$, donde n es el total de datos y Y el vector de etiquetas de longitud n .

base de datos B: Creada mediante 50 señales ECG extraídas de la base de datos de Physionet, cada una con 10000 muestras, se dejan 40 de estas señales para entrenamiento y 10 para validar. Para realizar la interpolación de más muestras, se decide realizar varias reconstrucciones iterativamente, tomando los nuevos puntos generados como entradas para el siguiente ciclo; así, para un vector con n muestras, con una iteración se genera un nuevo vector con $2(n - 4) - 1 = 2n - 9$ muestras, y si se ejecuta más veces, con 4 iteraciones se pueden generar hasta 16 muestras entre cada par de puntos, mientras que con 5 iteraciones se generan hasta 32.

4. Experimentación con MLP

Para elegir la arquitectura apropiada para este problema, se usó la función de entrenamiento que se encuentra por defecto *trainlm* en el software MatLab®, y en la capa oculta y la de salida se usó la función de activación *tansig*. Inicialmente se hizo la experimentación sobre una red neuronal con una capa oculta y la de salida, buscando la interpolación del doble de muestras de la señal original, evaluando los errores de entrenamiento y validación, figura 1.

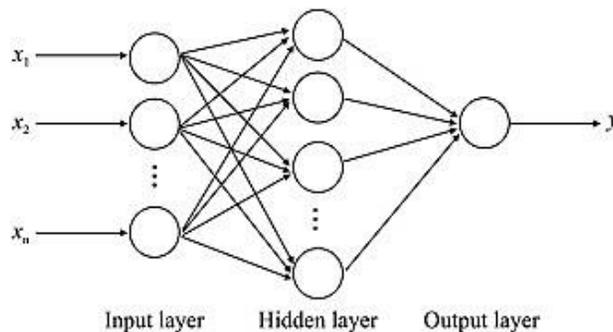


Figura 1. Esquema de la topología perceptrón multicapa. Fuente: Implementation of multilayer perceptron (MLP) and radial basis function (RBF) neural networks to predict solution gas-oil ratio of crude oil systems, [3].

Con el fin de mejorar la generalización de la red con las señales que no se encuentran en la base de datos, se experimentó con arquitectura de 2 capas, utilizando la **base de datos A** entrenando varias veces sobre el mismo número de neuronas hasta conseguir el mínimo error de generalización. Para las pruebas con doble capa oculta, se gráfica en color fucsia las muestras de la señal usadas como entrada a la red neuronal, en color azul se grafican los puntos generados por la red y en rojo, la señal original. Se construye la señal obtenida en negro.

Debido a la alta variabilidad en el entrenamiento entre réplica y réplica, se toman como referencia las arquitecturas que mejor se adaptan al entrenamiento, realizando réplicas sucesivas hasta encontrar los mejores resultados, tabla 1.

Neuronas capa oculta	Neuronas capa de salida	Error de validación	Error de entrenamiento
45	20	0.0335	0.0015
36	8	0.0450	0.0021
15	8	0.0388	0.005
22	10	0.0157	$7.57 \cdot 10^{-4}$
8	10	0.0153	$3.9422 \cdot 10^{-4}$
5	5	0.0155	$3.45 \cdot 10^{-4}$
4	3	0.0150	$2.98 \cdot 10^{-4}$
2	3	0.0164	$2.81 \cdot 10^{-4}$
1	1	0.0150	$2.87 \cdot 10^{-4}$

Tabla 1. Resultados variando el número de neuronas por capa. Fuente: Propia.

Se anexaron más señales de otros pacientes a los datos de validación, con el fin de probar el entrenamiento de la red, y de las arquitecturas con las que se habían obtenido los mejores resultados, figura 2.

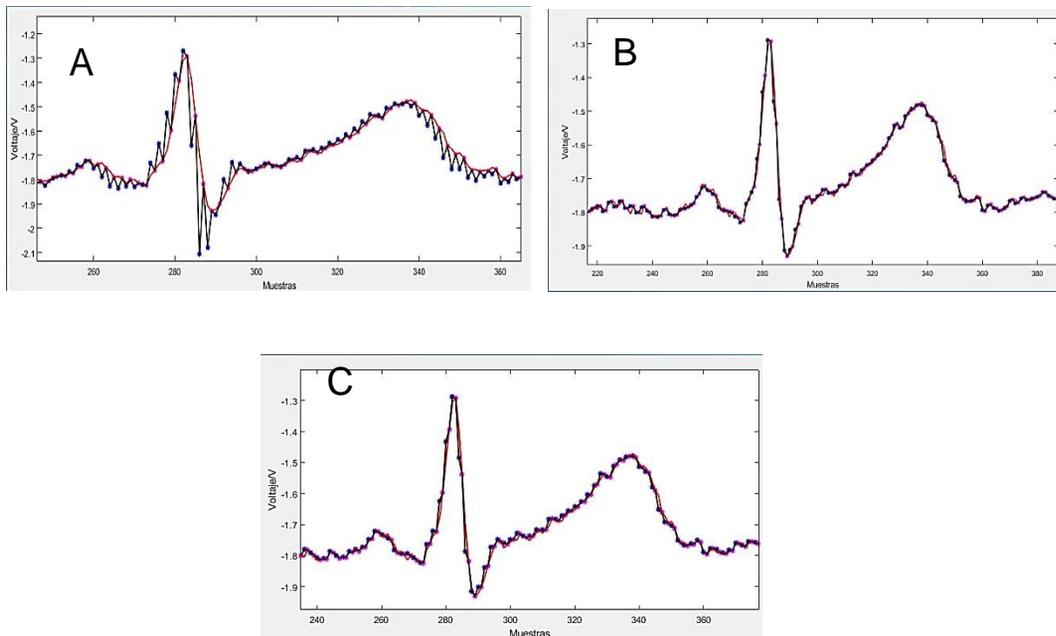


Figura 2. A) Señal de validación para la red con 15 neuronas en la capa oculta y 8 en la capa de salida. B) Señal de validación para la red con 5 neuronas en la capa oculta y 5 en la capa de salida. C) Señal de validación para la red con 1 neurona en la capa oculta y 1 en la capa de salida. Fuente: Propia.

Como última validación se experimenta con la red final sobre una señal completamente distinta a las bases de datos, generada en Matlab, obteniendo excelentes resultados como se muestra en la Figura 3.

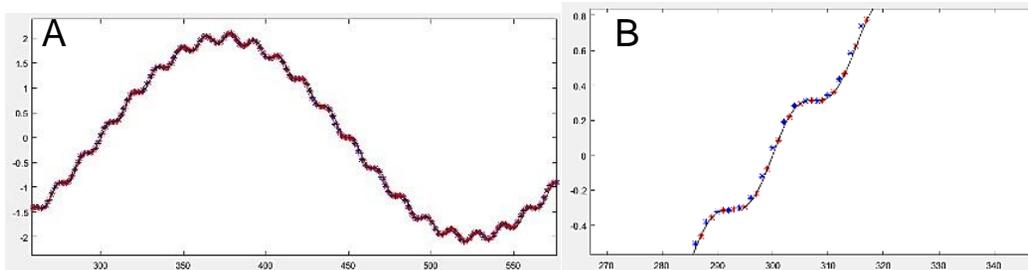


Figura 3. Interpolación sobre señal generada en MatLab. Fuente:Propia.

En la experimentación con nuevas señales, se observó un patrón peculiar; al reducir el número de neuronas manteniendo una estructura de 2 capas ocultas y una de salida, mejoraba el error de generalización, a tal punto de que con una neurona en cada capa se encontró el menor error. Una vez en este punto se realizaron pruebas con diferentes redes, una sola capa oculta, 3 capas ocultas, e incluso el perceptrón de una neurona; para todos estos casos encontrando que la generalización decayó abruptamente si se tenían menos neuronas y relativamente poco para el caso de 3 capas ocultas.

Aplicando el algoritmo de interpolación iterativo sobre la red obtenida en la anterior experimentación con la **base de datos A**, se obtienen los siguientes resultados sobre una señal de validación ECG, Figura 4, traza azul como señal original y roja como interpolación obtenida.

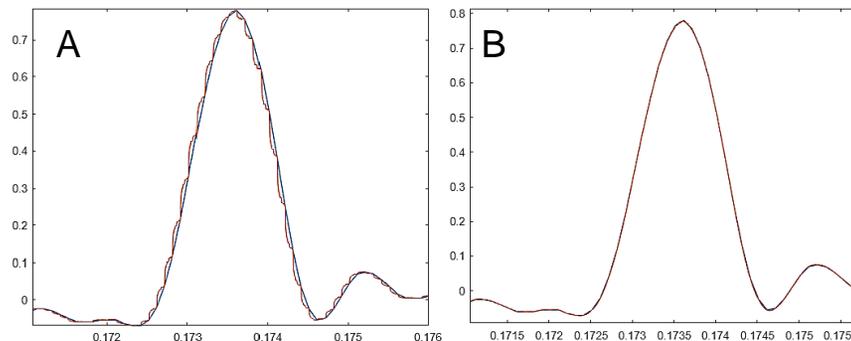


Figura 4.A) Interpolación con MLP entrenado con base de datos A. **B)** Interpolación con MLP entrenado con base de datos B. Fuente: Propia.

Como se puede ver en la Figura 4-A la muestra central entre cada punto tiene un error muy grande, por lo que con cada iteración este error es acumulativo, generando patrones de curvas erróneas entre cada par de puntos de la señal. Para resolver este inconveniente, se decide reentrenar la red con la **base de datos B**. Los resultados del reentrenamiento de la misma arquitectura sobre la misma señal de prueba se muestran en la Figura 4-B, a partir de este momento esta red será conocida como *mejornet1*.

5. Experimentación con redes de base radial

Debido a su similitud en aplicaciones con la topología de perceptrón multicapa, se elige la arquitectura red de base radial para resolver de manera alternativa el problema, como nuevo parámetro de evaluación se decide utilizar la función de correlación cruzada disponible en Matlab eligiendo el valor máximo del arreglo resultante. Se realizó el entrenamiento de estas redes variando el número de neuronas de base radial y el spread, obteniendo las siguientes redes, figura 5:

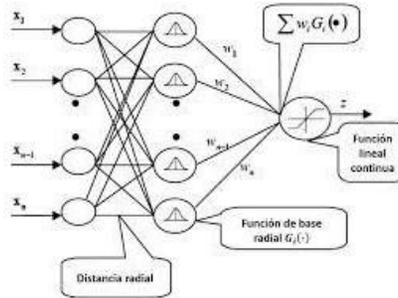


Figura 5. Esquema de la arquitectura Base Radial. Fuente: “Artificial Neural Model based on radial basis function networks used for prediction of compressive strength of fiber-reinforced concrete mixes”, [4], tabla 2

Nombre de la red	SPREAD	Número de neuronas
<i>r_0135</i>	0.1	35
<i>r_0150</i>	0.1	50
<i>mejornet2</i>	90	9
<i>r_905</i>	90	5
<i>r_509</i>	50	9
<i>r_19</i>	1	9
<i>r_0530</i>	0.5	30
<i>r_1015</i>	10	15
<i>r_3010</i>	30	10
<i>r_04535</i>	0.45	35

Tabla 2. Redes obtenidas con el entrenamiento en base radial. Fuente: Propia.

5.1 Señal ECG

Se muestran resultados gráficos de algunas de estas redes sobre la misma señal ECG en las siguientes figuras:

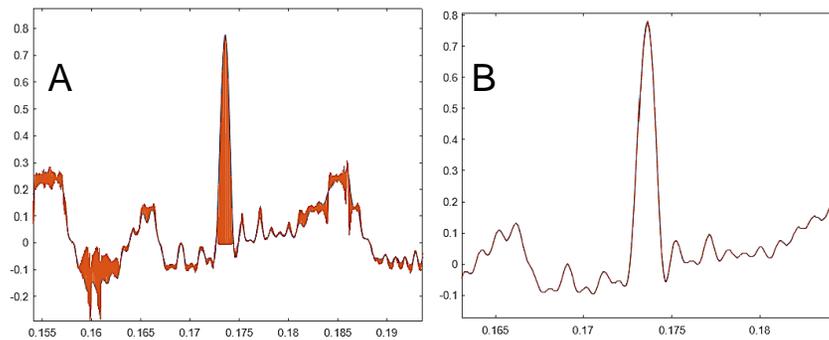


Figura 6. A) Señal ECG con la red r_0150. B) Señal ECG con la red r_1050. Fuente: Propia.

Como se puede notar en los resultados gráficos, un mayor spread genera un rendimiento mayor como las mismas neuronas, según el problema, el rendimiento tiende a su valor mínimo más rápido con un spread grande, para luego estabilizarse a partir de cierto número de neuronas, como se muestra en la Figura 7.

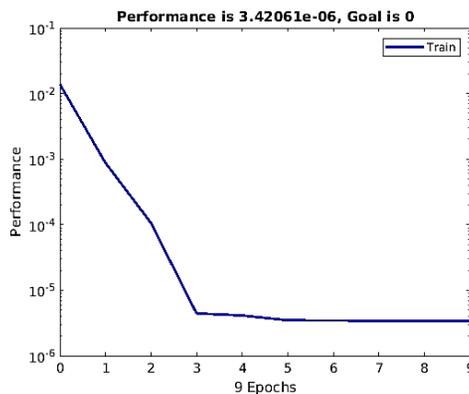


Figura 7. Rendimiento con spread de 90. Fuente: Propia.

A simple vista la generalización parece mejorar bastante con la nueva base de datos, sin embargo, debido a que estamos obteniendo puntos de señales previamente muestreadas, y no tenemos la señal continua original, resulta imposible cuantificar el error; por lo que se opta por cambiar el conjunto de validación a 4 señales que, a criterio del autor, son desafiantes para el entrenamiento y están definidas a partir de una función continua.

5.2 Señal sinusoidal

Esta señal está definida con $0 < x < 4\pi$ y se compone de la suma de señales *Sin* a diferente amplitud y frecuencia a modo de ecuación 1. $y = 2\text{Sin}(x) + 0.1\text{Sin}(20x)$ (1)

Se usa la señal sinusoidal con las diferentes redes vistas anteriormente. A continuación, se muestran algunos resultados gráficos de las pruebas. Los resultados numéricos se condensan en la tabla 4. Para esta señal se logró interpolar 16 muestras por cada muestra original, figura 8.

Red neuronal	Error	Máxima correlación
<i>r_0135</i>	1.9262	599.6497
<i>r_19</i>	1.7113	$1.3332 \cdot 10^3$
<i>mejornet2</i>	$8.402 \cdot 10^{-6}$	$9.5425 \cdot 10^3$
<i>r_905</i>	$3.1873 \cdot 10^{-4}$	$9.5385 \cdot 10^3$
<i>net_vieja</i>	$9.3047 \cdot 10^{-4}$	$9.5364 \cdot 10^3$
<i>mejornet1</i>	0.0038	$9.2243 \cdot 10^3$

Tabla 3. Error y la máxima correlación en la señal seno. Fuente: Propia

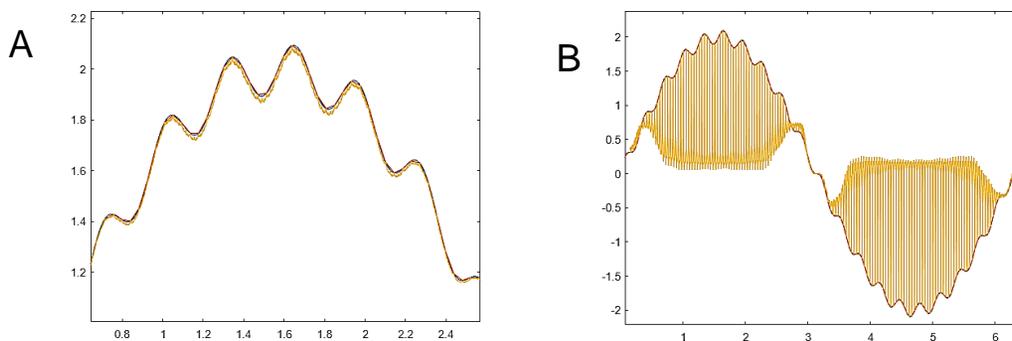


Figura 8. A) Señal sinusoidal con la red r_19. B) Señal sinusoidal con la red mejornet2. Fuente: Propia.

Como siguiente prueba con esta señal, se varió la amplitud de la señal de validación multiplicándose por un factor, para observar cómo incide la magnitud de la señal de entrada en el error de validación y correlación, estos resultados se condensan en la tabla 4.

Factor de multiplicación	Error	Máxima correlación
10	11.7975	$7.5148 \cdot 10^5$
1	$8.4021 \cdot 10^{-5}$	$9.5425 \cdot 10^3$
0.1	$5.2965 \cdot 10^{-8}$	95.7184
0.01	$1.3254 \cdot 10^{-9}$	0.9572
0.001	$8.6224 \cdot 10^{-10}$	0.0096

Tabla 4. Error y la máxima correlación en la señal seno variando su amplitud y con la red mejornet2. Fuente: Propia.

Como se muestra en la tabla 4, normalizar previamente la señal de entrada a valores entre 0.5 y -0.5 incrementa el rendimiento del algoritmo de reconstrucción.

Para el caso de la señal sinusoidal en la tabla 3, el error más bajo se obtuvo con la red *mejornet2*, la cual corresponde a la red entrenada en base radial con un SPREAD de 90 y 9 neuronas, así mismo, la correlación más alta se obtuvo con esta misma red, lo que significa una relación bastante alta entre la señal interpolada y la original. Con la red *r_0135* se obtuvo el error más alto, y la correlación más baja, por lo tanto, con esta se obtuvieron los peores resultados, esto se debe a que la red era más compleja ya que contaba con 35 neuronas y un SPREAD muy pequeño, de 0.1.

5.3 Señal Sinc

Esta señal se define tal que $-10 < x < 10$, a modo de ecuación 2, reemplazando la indeterminación en 0 por $y=1$.

$$y = \frac{\sin(x)}{x} \quad (2)$$

Usando como entrada la señal Sinc, a continuación, se muestran algunos resultados gráficos de las pruebas, los resultados numéricos se condensan en la tabla 5. Para esta señal se logró interpolar 32 muestras por cada muestra original, figura 9.

Red neuronal	Error	Máxima correlación
<i>r_0135</i>	0.0472	19.3673
<i>r_0530</i>	0.0203	114.9768

mejornet2	$9.7330 \cdot 10^{-7}$	244.4457
r_905	$4.0404 \cdot 10^{-6}$	243.4674
mejornet1	$3.3726 \cdot 10^{-6}$	243.6351

Tabla 5. Error y la máxima correlación en la señal SinC con diferentes redes. Fuente: Propia.

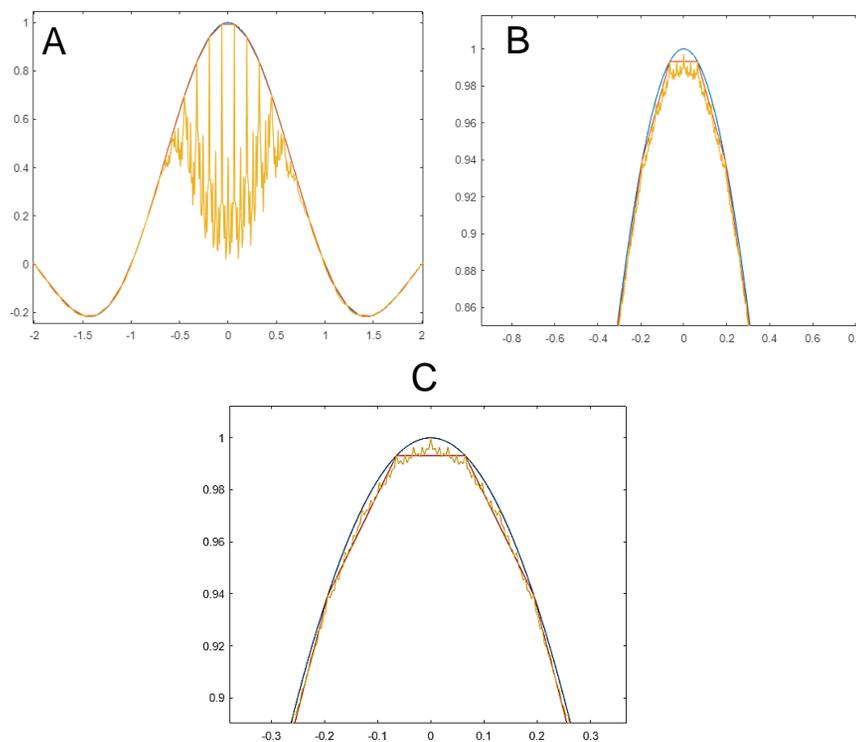


Figura 9. A) Señal SinC con la red r_0530. B) Señal SinC con las red mejornet1. C) Señal SinC con las red mejornet2. Fuente: Propia.

Al igual que en la señal sinusoidal, se varía la amplitud de las señales para ver su efecto en la interpolación de la red, se pueden ver los resultados en la tabla 6.

Factor de multiplicación	Error	Máxima correlación
10	5.821 ⁻⁶	934.2063
1	4.6852*10 ⁻⁶	936.4074
0.1	4.794*10 ⁻⁶	936.5695
0.01	6.197*10 ⁻⁶	933.7566
0.001	5.3182*10 ⁻⁶	935.6643

Tabla 6. Error y la máxima correlación en la señal SinC variando su amplitud y con la red mejornet2..
Fuente:Propia.

En la tabla 5 se puede evidenciar que el menor error se obtuvo con la red *mejornet2*, igualmente se obtuvo la correlación más alta, mientras que con la red *r_0150* se obtuvieron los peores resultados, es una red de 50 neuronas y un SPREAD de 0.1.

5.4 Polinomio de alto orden

Esta señal se define con $-1.6 < x < 1.5$, a modo de ecuación 3, por la suma de un polinomio de grado 15 y una señal sinusoidal con amplitud exponencialmente decreciente.

$$y = x^{15} - x^{13} - x^9 - 10x^5 + 5x^2 + 5e^{-2x} * \sin\left(\frac{x}{0.01}\right) \quad (3)$$

Algunos resultados gráficos de las pruebas, los resultados numéricos se condensan en la tabla 7. Para esta señal se logró interpolar 16 muestras por cada muestra original. Figura 10.

Red neuronal	Error	Máxima correlación
<i>r_0135</i>	0.1466	58.1016
<i>r_1015</i>	0.0023	702.0201
<i>mejornet2</i>	$2.1343 \cdot 10^{-5}$	767.6993
<i>r_905</i>	$9.4433 \cdot 10^{-6}$	771.8631
<i>mejornet1</i>	$7.3327 \cdot 10^{-4}$	731.0506

Tabla 7. Error y la máxima correlación en el polinomio de alto orden con diferentes redes y un $\alpha = 0.01$. Fuente: Propia.

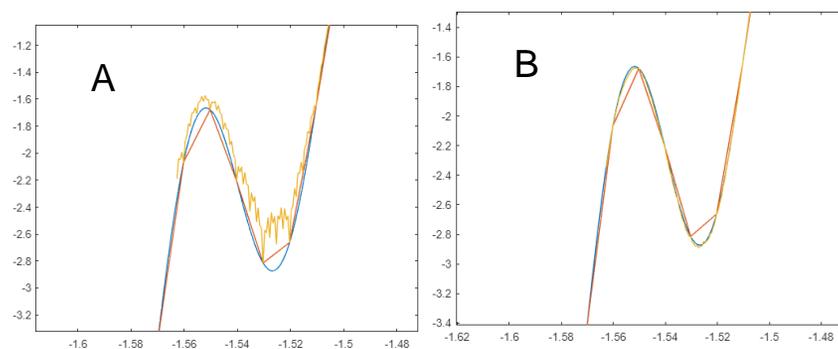


Figura 10. A) Señal Polinomio con la red mejornet1. B) Señal Polinomio con la red r_905. Fuente: Propia.

Al igual que en las anteriores señales, se varía la amplitud de las señales para ver su efecto en la interpolación de la red, se pueden ver los resultados en la tabla 8.

Factor de multiplicación	Error	Máxima correlación
10	1.2548 ⁻⁶	1.2437*10 ⁶
1	0.841	6.2993*10 ⁴
0.1	9.4433*10 ⁻⁶	771.8631
0.01	5.1178*10 ⁻⁸	7.6909
0.001	5.4087*10 ⁻⁹	0.0768

Tabla 8. Error y la máxima correlación en el polinomio de alto orden variando su amplitud y con la red r_{905} . Fuente: Propia.

En la tabla 8, se puede ver que los mejores resultados en cuestión de error y máxima correlación se obtuvieron con la red r_{905} , la cual es una red entrenada en base radial con un SPREAD de 90 y 5 neuronas, con esta red también se obtuvo la más alta correlación, en contraste con este resultado se obtuvo un resultado bastante malo con la red r_{0135} , la cual tiene un SPREAD bastante pequeño comparado con la red con la que se obtuvieron los mejores resultados.

5.5 Atractor de lorenz

Para esta función se usa una de las componentes tridimensionales (Y) respecto al tiempo del atractor de Lorenz, definido por el conjunto de ecuaciones diferenciales:

$$\begin{aligned}
 \dot{x} &= \sigma * (y - x) \\
 \dot{y} &= x * (\rho - z) - y \\
 \dot{z} &= x * y - \beta * z;
 \end{aligned}
 \tag{4}$$

A continuación, se muestran algunos resultados de las pruebas, los resultados numéricos se condensan en la tabla 9. Para esta señal se logró interpolar 16 muestras por cada muestra original, figura 11.

Red neuronal	Error	Máxima correlación
<i>r_19</i>	6.4749*10 ⁻⁴	991.4742
<i>r_0150</i>	0.1461	139.8887
<i>r_905</i>	4.794*10 ⁻⁶	936.5695
<i>r_509</i>	4.6852*10 ⁻⁶	936.4074
<i>net_vieja</i>	7.3265*10 ⁻⁶	933.3367
<i>mejornet1</i>	5.8164*10 ⁻⁶	934.2139

Tabla 9. Error y la máxima correlación en una de las componentes del atractor de Lorenz. Fuente: Propia.

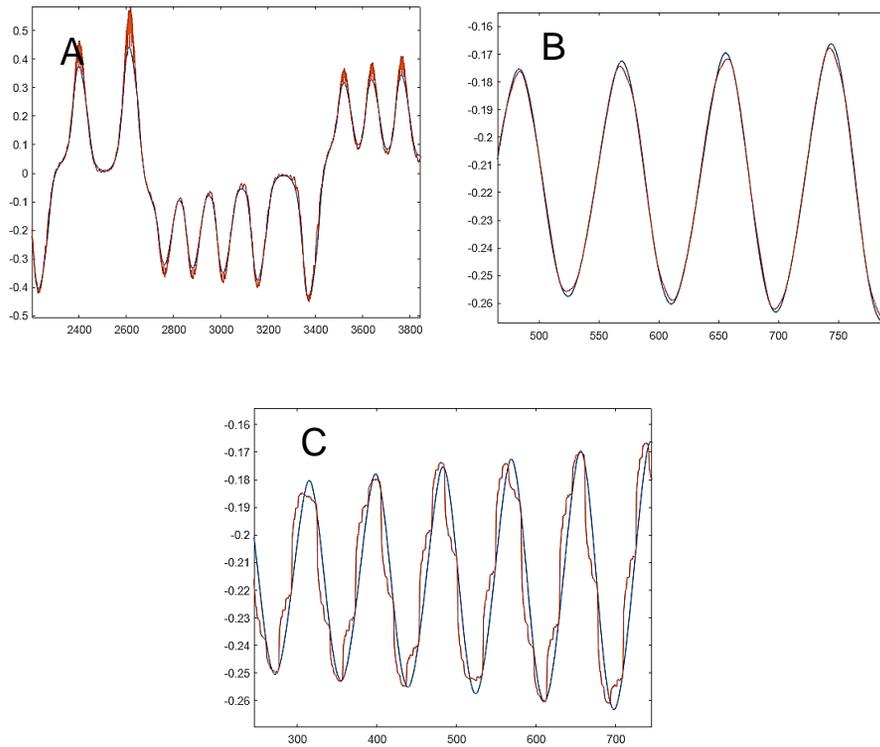


Figura 11. A) Componente del atractor de Lorenz con la red r_19. B) Componente del atractor de Lorenz con la red r_905. C) Componente del atractor de Lorenz con la red net_vieja. Fuente: Propia

Al igual que en las anteriores señales, se varía la amplitud de las señales para ver su efecto en la interpolación de la red, se pueden ver los resultados en la tabla 10.

Factor de multiplicación	Error	Máxima correlación
10	0.0061	$9.1032 \cdot 10^4$
1	$4.6852 \cdot 10^{-6}$	936.4074

Factor de multiplicación	Error	Máxima correlación
0.1	$5.3875 \cdot 10^{-8}$	9.3628
0.01	$7.5314 \cdot 10^{-9}$	0.00932
0.001	$7.0161 \cdot 10^{-9}$	$8.9435 \cdot 10^9$

Tabla 10. Error y la máxima correlación en la componente del atractor de Lorenz variando su amplitud y con la red r_{509} . Fuente:Propia.

Se muestra la forma de la señal de correlación cruzada para el polinomio de alto grado en la figura 12.

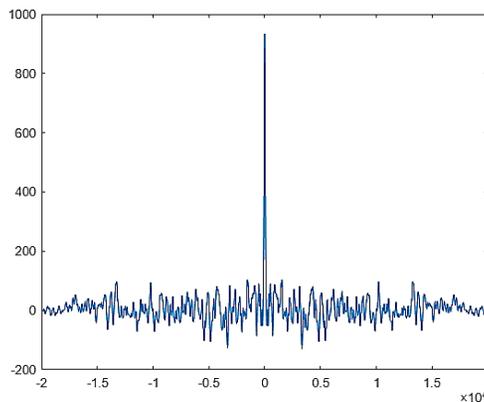


Figura 12. Correlación cruzada entre señal original e interpolación con la red mejornet2. Fuente: Propia.

En la tabla 10 se pueden ver el error y la máxima correlación para cada una de las redes entrenadas, en este caso la red que arrojó el mejor resultado fue la red r_{509} la cual fue entrenada en base radial y tiene un SPREAD de 50 con 9 neuronas, mientras que con con la red r_{0150} , se obtuvieron el error más alto, y la máxima correlación más baja.

Al observar los resultados de las tablas en las diferentes señales, observamos que la red con mejores resultados es la red *mejornet2*, igualmente, la red r_{905} también obtiene muy buenos

resultados. Mientras que las redes con un SPREAD bajo como lo son las redes r_{0135} y r_{0150} arrojan unos resultados bastante malos.

6. Conclusiones

Aunque las dos topologías utilizadas en la experimentación obtuvieron un error bastante bajo, las redes neuronales de base radial tienen un desempeño superior en la interpolación obtenida respecto al perceptrón multicapa, superándolo en la mayoría de pruebas por un margen considerable en el error cuadrático medio. Queriendo saber si las redes obtenidas pueden implementarse en señales en tiempo real, se hace necesario evaluar el peso computacional de ambas, el cual inesperadamente resultó ser asequible para hardware de baja potencia para las dos topologías. En términos de costo computacional en entrenamiento y tiempo del mismo, notamos una diferencia clara en que base radial es más costosa por un margen muy amplio, llegando a necesitar casi 10 veces más recursos que MLP. Por otro lado, se puede notar que la eficacia de la interpolación es dependiente de la amplitud de la señal de entrada, esto se debe a que dicha señal debe encontrarse en el mismo rango de las señales de entrenamiento. Se concluye que no siempre las redes más complejas o grandes estructuralmente son siempre las mejores para atacar un problema, existen circunstancias en las que una red simple puede generalizar mejor los nuevos datos de entrada, como es este caso. Para futuras aplicaciones los autores sugieren la implementación del sistema con base radial debido a su rendimiento y ligereza, para mejores resultados también se recomienda normalizar la señal de entrada en un rango de valores de -0.5 hasta 0.5 previo al uso de la red.

Referencias

- [1] R. A. Valdesueiro, "Muestreo digital", p. 12.
- [2] M. Semeria, "Área: Ingeniería Informática", p. 17.
- [3] A. Hashemi Fath, F. Madanifar, y M. Abbasi, "Implementation of multilayer perceptron (MLP) and radial basis function (RBF) neural networks to predict solution gas-oil ratio of crude oil systems", *Petroleum*, vol. 6, núm. 1, pp. 80–91, mar. 2020, doi: [10.1016/j.petlm.2018.12.002](https://doi.org/10.1016/j.petlm.2018.12.002).
- [4] L. O. González Salcedo, A. P. Guerrero Zúñiga, S. Delvasto Arjona, y A. L. E. Will, "Artificial Neural Model based on radial basis function networks used for prediction of compressive strength of fiber-reinforced concrete mixes", *Cien.Ing.Neogranadina*, vol. 29, núm. 2, pp. 37–52, jun. 2019, doi: [10.18359/rcin.3737](https://doi.org/10.18359/rcin.3737).
- [5] A. Sudou, P. Hartono, R. Saegusa, y S. Hashimoto, "Signal reconstruction from sampled data using neural network", en *Proceedings of the 12th IEEE Workshop on Neural Networks for Signal Processing*, Martigny, Switzerland, 2002, pp. 707–715, doi: [10.1109/NNSP.2002.1030082](https://doi.org/10.1109/NNSP.2002.1030082).
- [6] A. Ugena, "THE NEWTON NEURAL NET: A NEW APPROXIMATING NETWORK", *Int. J. of Pure and Appl. Math.*, vol. 82, núm. 4, feb. 2013, doi: [10.12732/ijpam.v82i4.13](https://doi.org/10.12732/ijpam.v82i4.13).
- [7] N. M. Khan, "Audio Signal Reconstruction Using Cartesian Genetic Programming Evolved Artificial Neural Network (CGPANN)", p. 6.
- [8] L. H. C. Casallas, E. H. M. Alfonso, y M. L. C. Martínez, "Clasificación de Plasmodium Falciparum por estadio en cultivos sincrónicos de eritrocitos", *Visión electrónica*, vol. 5, núm. 1, Art. núm. 1, may 2011, doi: [10.14483/22484728.3519](https://doi.org/10.14483/22484728.3519).
- [9] J. A. P. Plaza, D. R. Zapata, y A. T. Tascón, "Implementación de redes neuronales utilizando dispositivos lógicos programables", *Visión electrónica*, vol. 1, núm. 1, Art. núm. 1, jun. 2008, doi: [10.14483/22484728.250](https://doi.org/10.14483/22484728.250).
- [10] O. L. Ramos, D. A. Rojas, y L. A. Góngora, "Reconocimiento de patrones de habla usando MFCC y RNA", *Visión electrónica*, vol. 10, núm. 1, Art. núm. 1, jun. 2016, doi: [10.14483/22484728.11712](https://doi.org/10.14483/22484728.11712).

- [11] E. J. G. Monterroza, "Reconocimiento de primitivas 3D, usando autocorrelación y ANFIS", *Visión electrónica*, vol. 1, núm. 1, Art. núm. 1, 2008, doi: [10.14483/22484728.251](https://doi.org/10.14483/22484728.251).
- [12] L. F. P. Martínez, Ó. F. C. Camargo, y J. E. Roa, "Estudio comparativo de técnicas artificiales para la predicción de una serie de tiempo caótica", *Visión electrónica*, vol. 2, núm. 2, Art. núm. 2, dic. 2008, doi: [10.14483/22484728.792](https://doi.org/10.14483/22484728.792).
- [13] A. E. Díaz y L. A. Calderón, "Modelo tridimensional de extremidad inferior basado en imágenes de resonancia magnética", *Visión electrónica*, vol. 3, núm. 1, Art. núm. 1, jun. 2009, doi: [10.14483/22484728.686](https://doi.org/10.14483/22484728.686).