

# **ESTUDIO COMPARATIVO DE DIFERENTES REDES NEURONALES PARA PREDISTORSIÓN DIGITAL DE AMPLIFICADORES DE RF**

*COMPARATIVE STUDY OF DIFFERENT NEURAL NETWORKS FOR DIGITAL PREDISTORTION OF RF AMPLIFIERS*

***Ulises Carpinteyro Ponce***

CINVESTAV unidad Guadalajara, México  
*ucarpinteyro@gdl.cinvestav.mx*

***Caín Pérez Wences***

CINVESTAV unidad Guadalajara, México  
*cperez@gdl.cinvestav.mx*

***José Raúl Loo Yau***

CINVESTAV unidad Guadalajara, México  
*rloo@gdl.cinvestav.mx*

**Recepción:** 6/noviembre/2019

**Aceptación:** 23/noviembre/2019

## **Resumen**

En este trabajo se presenta una comparativa de diversas arquitecturas de redes neuronales artificiales, como método de modelado de comportamiento, para realizar predistorsión digital de amplificadores de potencia. Las arquitecturas de redes neuronales que se compararan son RVFTDNN, FC2HLANN, M2HLANN y NARX, con las cuales se realiza el modelado de un amplificador Doherty RTH21007-10 de RFHIC que trabaja con una señal LTE con frecuencia central de 2.1 GHz, ancho de banda de 5 MHz y PAPR de 7 dB. Se compara el error cuadrático medio normalizado (NMSE) obtenido con cada uno de las arquitecturas y se muestra la reducción de la no linealidad del amplificador, por medio de sus características AM-AM y AM-PM, al usarlos como modelos en la predistorsión digital. Por último, se presenta una tabla comparativa donde se muestra el desempeño de cada arquitectura de red neuronal artificial. Se observa que las redes neuronales recurrentes son capaces de reproducir mejor el comportamiento no lineal del amplificador, sin embargo, se logra una mayor reducción de la distorsión con la red *feedforward*.

**Palabras Clave:** Amplificador de potencia, modelado de comportamiento, pre distorsión digital, red neuronal artificial.

## **Abstract**

*This paper presents a comparison of several architectures of artificial neural networks, as a method of behavioral modeling, to perform digital predistortion of power amplifiers. The architectures of neural networks that are compared are RVFTDNN, FC2HLANN, M2HLANN and NARX, with which it is performed the modeling of a Doherty amplifier RTH21007-10 of RFHIC that works with an LTE signal with a central frequency of 2.1GHz, a bandwidth of 5MHz and PAPR of 7dB. The normalized mean square error (NMSE) obtained with each of the architectures is compared and the reduction of the non-linearity of the amplifier is shown, by means of its AM-AM and AM-PM characteristics, when used as models in digital predistortion. Finally, a comparative table is presented where the performance of each artificial neural network architecture is shown. It is observed that the recurrent neural networks are able to reproduce better the non-linear behavior of the amplifier, however, a greater reduction of the distortion is achieved with the feedforward network.*

**Keywords:** Artificial neural network, behavioral modeling, digital predistortion, power amplifier.

## **1. Introducción**

En los últimos años ha existido una rápida evolución en los sistemas electrónicos. Uno de los más notorios se encuentra en los sistemas de telecomunicaciones donde los usuarios demandan más y mejores servicios y con mayor velocidad de transferencia de datos. Esto ha generado la necesidad de desarrollar nuevos dispositivos, algoritmos y sistemas que logren satisfacer los requerimientos que las nuevas tecnologías exigen.

Un ejemplo de lo antes mencionado, se encuentra en el *front-end* de los sistemas de telecomunicaciones. Ya que se busca que los sistemas sean más eficientes, pero algunos elementos del sistema como el amplificador de potencia, presentan no

linealidades al operar en su región más eficiente, provocando que se tenga que hacer un compromiso entre eficiencia y linealidad.

El amplificador de potencia (AP) es uno de los dispositivos más importantes dentro del sistema de comunicaciones, debido a que este es quien le aporta la energía a la señal que se busca transmitir. Sin este dispositivo la señal transmitida no tendría la suficiente energía para viajar en el medio y es por eso que es un elemento imprescindible. Sin embargo, también lo convierte en el dispositivo con mayor consumo de energía en el sistema. Si la eficiencia del sistema es prioritaria, entonces es necesario hacer lo más eficiente posible al AP. Sin embargo, como se muestra en la figura 1 cuando el AP trabaja con mayor eficiencia, éste se encuentra operando en su región no lineal, esto quiere decir que la linealidad del AP es baja, por lo tanto, la señal de salida del AP está distorsionada.

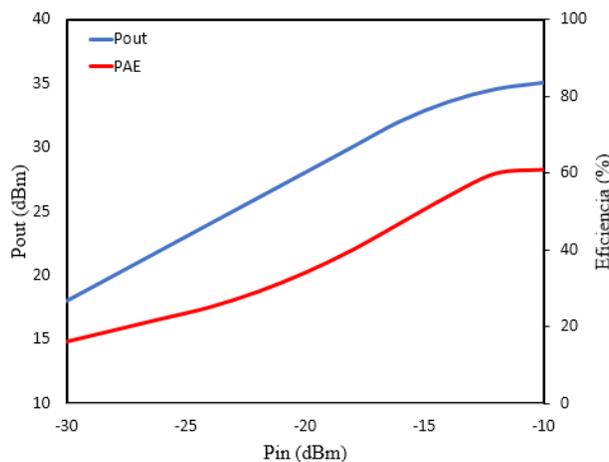


Figura 1 Potencia de salida y eficiencia de un amplificador AB.

Puesto que el amplificador, por sí solo, no puede ofrecer eficiencia y linealidad al mismo tiempo, se han desarrollado métodos o técnicas para mejorar la linealidad del AP sin sacrificar la eficiencia [Lavrador, 2010].

Existen distintos métodos que se clasifican en tres grandes grupos: *Feedforward* [Xiang, 2009], *Feedback* [Shi, 1999] y Predistorsión [Nezami, 2004]. Dentro de la predistorsión existe la técnica de predistorsión digital [Nezami, 2004] (figura 2) y ésta es la que se mostrará en este trabajo debido a las ventajas que ofrece, como son: gran versatilidad para realizar modelado de comportamiento, flexibilidad del

método de predistorsión, tratamiento de la señal vía software, entre otros [Mkadem, 2011]. La predistorsión tiene como requisito el desarrollo del modelo inverso del amplificador. El modelo inverso se puede realizar por medio de un modelado de comportamiento del AP usando series matemáticas, redes neuronales o cualquier algoritmo que permita realizar un modelo dinámico no lineal. Este modelo inverso modifica la señal de entrada para que la señal de salida del AP sea más lineal.

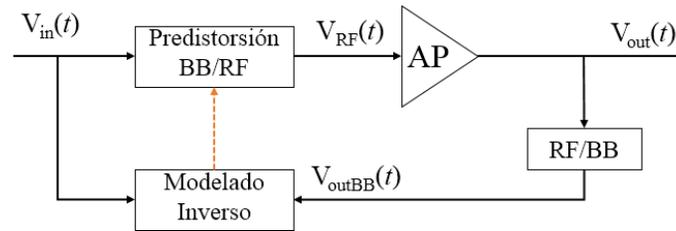


Figura 2 Diagrama general predistorsión digital.

En este trabajo, se usarán redes neuronales para realizar el modelado del amplificador y se realizará una comparativa de diferentes redes neuronales.

## 2. Métodos

El proceso para realizar la técnica de predistorsión digital consta de 6 etapas principales: I) generación de la señal, II) captura de entrada y salida de AP, III) procesamiento de datos para obtener las características AM-AM y AM-PM, IV) modelado de comportamiento, V) predistorsión y VI) validación de la predistorsión. Para llevar a cabo este método es necesario un generador de señales vectoriales, un AP operando en la región de alta eficiencia, un equipo para capturar las señales obtenidas y, en caso de ser necesario, un preamplificador para llevar al AP a la región de operación deseada. En la figura 3 se muestra el diagrama a bloques del banco de medición utilizado.

### Generación de la Señal

La señal que se usa es una LTE de 5 MHz de ancho de banda con PAPR de 7.5 dB y frecuencia central de 2.1 GHz. El espectro de la señal generada se muestra en la figura 4. Esta señal será enviada al generador a través de sus valores IQ.

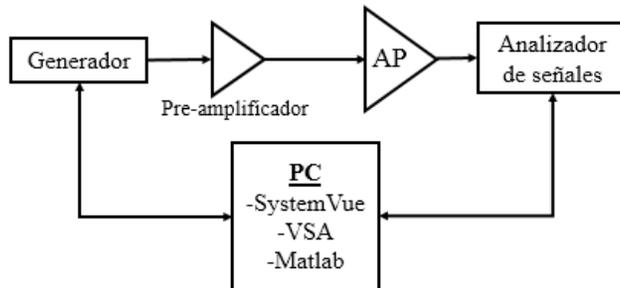


Figura 3 Diagrama de banco de medición.

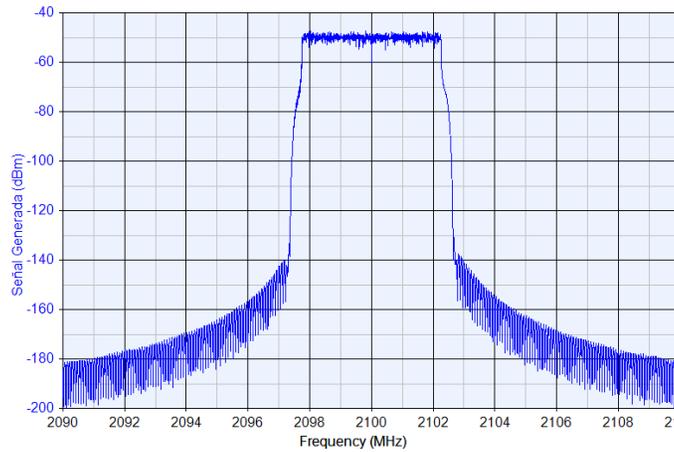


Figura 4 Señal LTE 5 MHz de ancho de banda generada.

### Captura de Entrada y Salida del AP

Para realizar el modelo de comportamiento del amplificador, son necesarias las señales de entrada y salida del AP, que en la figura 2 las podemos identificar como  $V_{RF}(t)$  y  $V_{out}(t)$ . En la figura 5 se muestra el espectro de ambas señales capturadas.

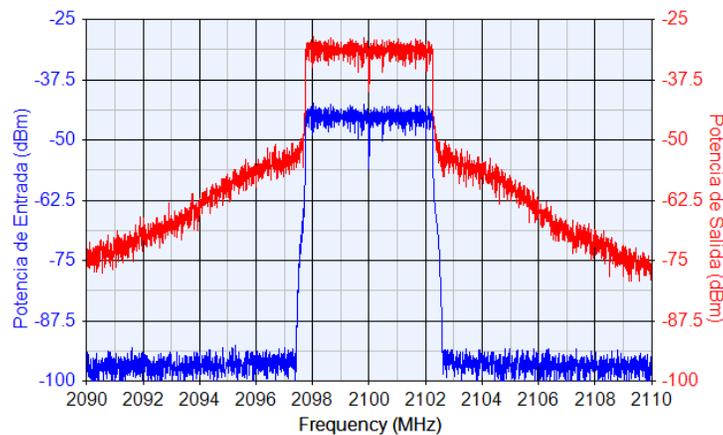


Figura 5 Señal de entrada (azul) y de salida (rojo) del AP.

Se puede observar que el espectro de la señal de salida es una versión amplificada y distorsionada de la señal de entrada. Por otro lado, el espectro de la señal de salida muestra recrecimiento espectral fuera de la banda central, esto se debe a las no linealidades del AP, y por medio de la predistorsion digital se busca reducir el recrecimiento espectral de la señal de salida.

### Características AM-AM y AM-PM

La característica AM-AM representa distorsión en amplitud del AP. Puede representarse como  $P_{in}-P_{out}$  o  $P_{in}-G_p$ , donde  $P_{in}$ ,  $P_{out}$  y  $G_p$  representan potencia de entrada, potencia de salida y ganancia del AP respectivamente. La característica AM-PM es la distorsión en fase del AP, es decir, la diferencia de fase entre la señal de salida y la señal de entrada. Estas características muestran la no linealidad y los efectos de memoria del AP [Lavrador, 2010], es por eso que son los que se usan como guía para corroborar si el modelado que se realizó es correcto.

Las características AM-AM y AM-PM de las señales capturadas en la etapa II y normalizadas, se muestran en las figuras 6 y 7 respectivamente. Se realiza la normalización de las señales debido a que se está interesado en el comportamiento del AP y no en la ganancia. La dispersión que existe entre los puntos, a baja potencia de entrada, se debe a los efectos de memoria del AP.

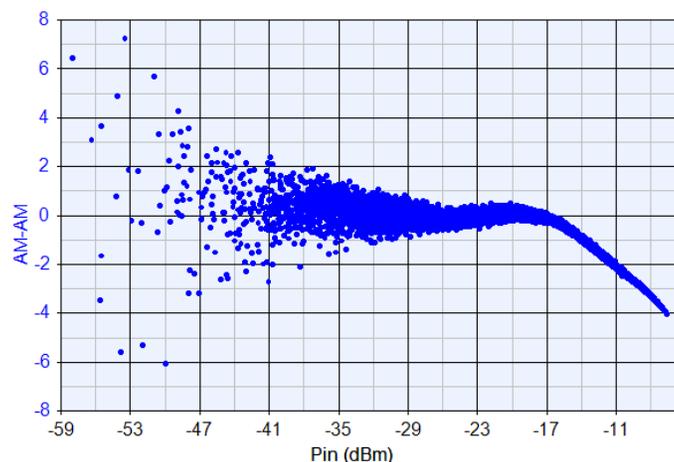


Figura 6 Característica AM-AM normalizada.

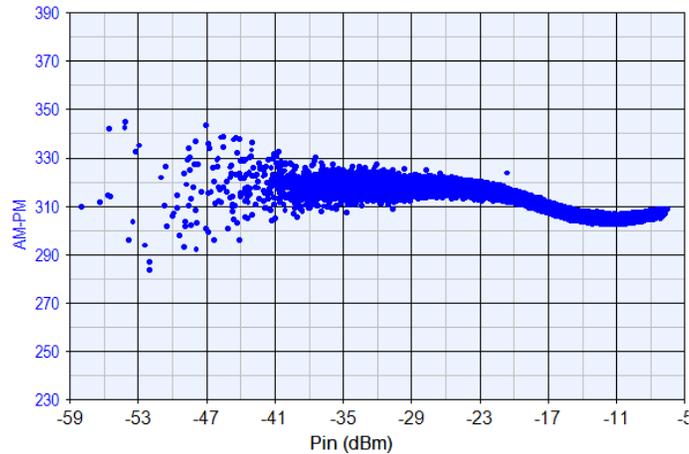


Figura 7 Característica AM-PM normalizada.

### Modelado de Comportamiento

El modelado es la etapa crucial de la técnica de predistorsión, ya que un modelo que sea capaz de reproducir la no linealidad y los efectos de memoria del AP, logrará reducir considerablemente el recrecimiento espectral de la señal de salida del AP. Es por eso que, en la literatura, existen muchas investigaciones que buscan una técnica de modelado que sea robusta y que permita reducir los efectos no deseados [Mkadem ,2011], [Luongvinh,2005].

En este trabajo se utilizarán como método de modelado 4 redes neuronales, una con arquitectura *feedforward* y 3 con arquitectura recurrente. La red *feedforward* es la red RVFTDNN (por sus siglas en inglés *Real-Valued Focused Time-Delay Neural Network*) mientras que las redes con arquitectura recurrente son las redes FC2HLANN (por sus siglas en inglés *Full Connected Two Hidden Layers Neural Network*), M2HLANN (por sus siglas en inglés *Modified Two Hidden Layers Neural Network*) y NARX (por su nombre en inglés *Nonlinear Autoregressive Network with eXogenous inputs*). La arquitectura de la red RVFTDNN se muestra en la figura 8, esta red está basada en el perceptrón multicapa, con la adición de una capa de retardos justo antes de la capa de entrada de la red. Los retardos le dan a la red la capacidad de modelar efectos de memoria y también aumenta la capacidad de reproducir las no linealidades del AP. La configuración de retardos en la entrada, neuronas en la primera capa y neuronas en la segunda capa de la red RVFTDNN que se usa para la comparación es de 9, 25 y 15, respectivamente.

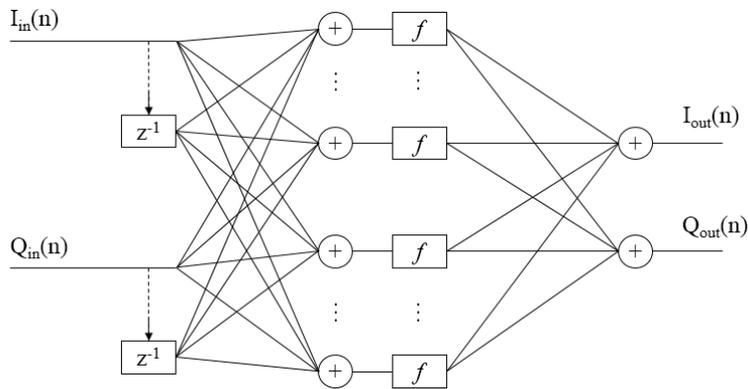


Figura 8 Red Neuronal RVFTDNN.

Las redes neuronales FC2HLANN y M2HLANN son modificaciones de la red *feedforward* 2HLANN [Mkadem, 2010] la cual es una red con dos capas ocultas, la primera con una función de activación lineal y la segunda no lineal. En la figura 9 se muestra la arquitectura de la red FC2HLANN, la característica de esta red es que los datos de entrada están conectados a las neuronas de la primera capa.

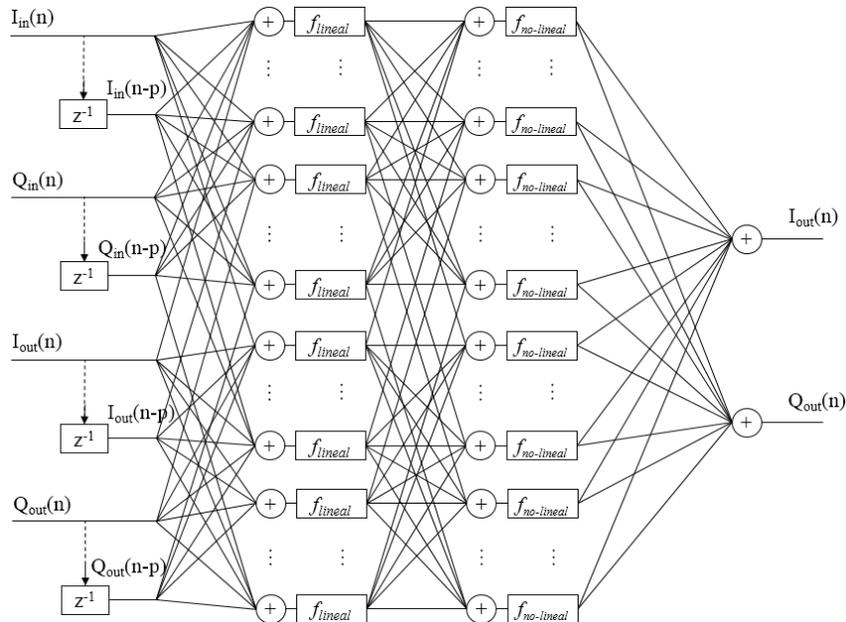


Figura 9 Red Neuronal FC2HLANN.

En la figura 10 se muestra la arquitectura de la red M2HLANN, ésta tiene como característica principal que los datos de entrada no están conectados a todas las neuronas de la primera capa, y que pasan directamente a la segunda capa.

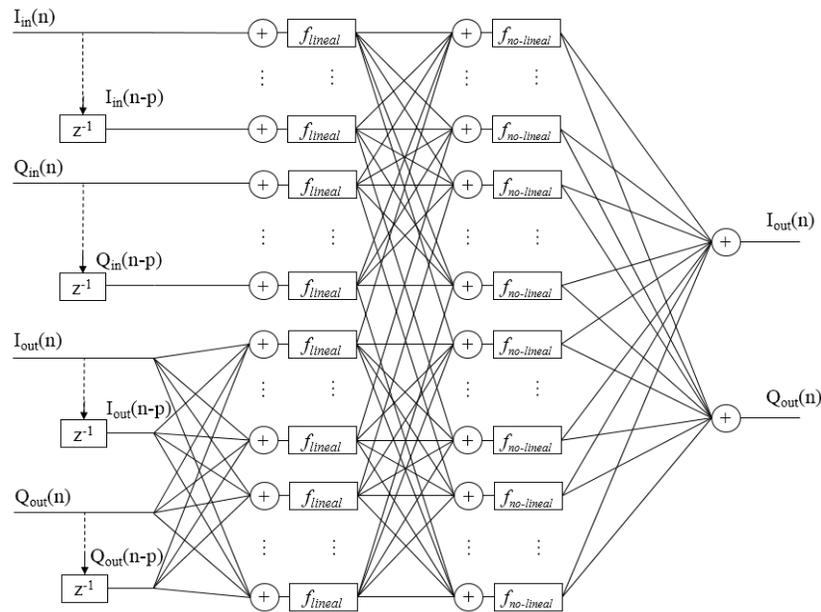


Figura 10 Red neuronal M2HLANN.

La configuración de retardos en la entrada, retardos en la salida, neuronas en la primera capa y neuronas en la segunda capa de la red FC2HALNN que se usa para la comparación es 2, 3, 4 y 25, respectivamente. Para la red M2HLANN la configuración de retardos en la entrada, retardos en la salida, neuronas en la primera capa y neuronas en la segunda capa es 3, 4, 2 y 20, respectivamente.

Por último, la red NARX tiene como característica principal el no utilizar las entradas presentes de las señales de entrada, únicamente trabaja con los retardos de estas señales y eso le proporciona una gran capacidad de para modelar comportamientos no lineales [Aguilar,2015] como se muestra en la figura 11. La configuración de la red que se usa para la comparación es 1 y 2 retardos en la entrada y en la salida, respectivamente, así como 25 neuronas.

### Predistorción

Una vez que tenemos el modelo de comportamiento inverso, se realiza la predistorción de la señal generada en banda base. Dependiendo del tipo de modelo que se esté usando será la forma de predistorcionar la señal. La figura 12 muestra el esquema a utilizar en el caso de emplear las redes neuronales de tipo feedforward; mientras que, para las redes neuronales recurrentes, se debe realizar

el tratamiento de la banda base como se muestra en el esquema de la figura 13. Una vez realizada la predistorsión, se vuelve a enviar los valores IQ al generador de señales vectoriales y se realiza la validación de la predistorsión.

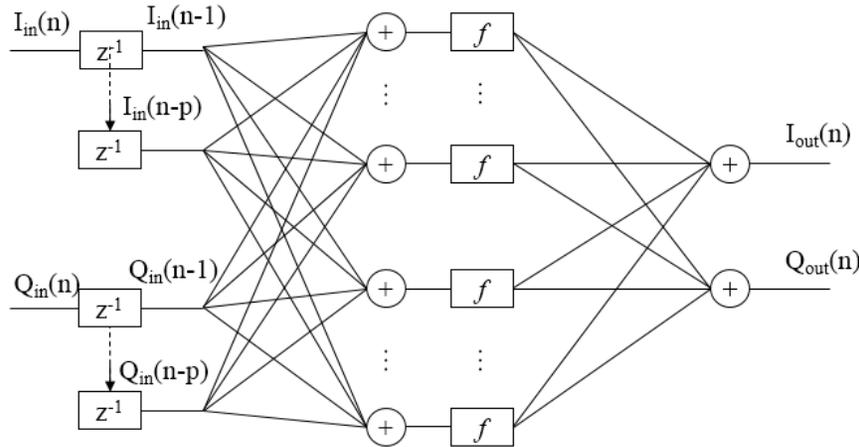


Figura 11 Red neuronal NARX.

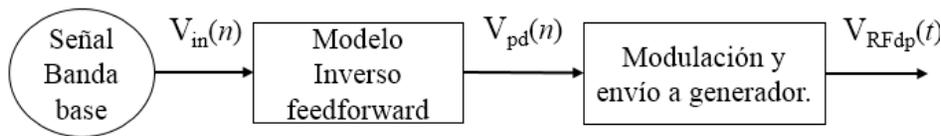


Figura 12 Esquema de predistorsión feedforward.

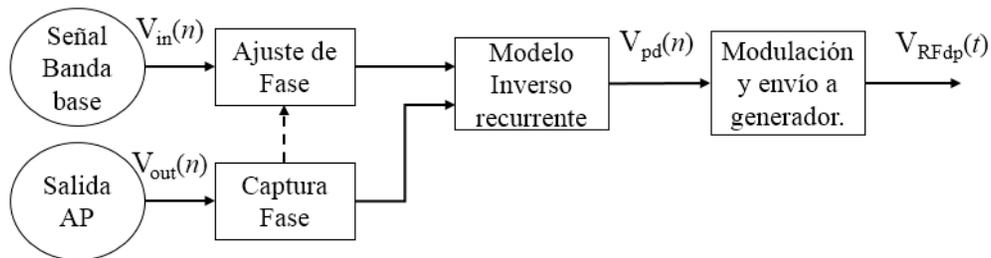


Figura 13 Esquema de predistorsión recurrente.

### Validación de Predistorsión

La validación consiste en cuantificar la reducción del recrecimiento espectral de la señal de salida del AP tipo Doherty modelo RTH21007-10 y compararla contra la

señal de salida del AP sin predistorsionador. El recrecimiento espectral es cuantificado por medio de la medición de la potencia del canal adyacente (ACPR). En la figura 14 se presenta el espectro de potencia de la señal de salida con y sin predistorsión empleando la RVFTDNN. Se puede observar una reducción del recrecimiento espectral del AP, lo cual se traduce en que se redujo exitosamente la distorsión (no linealidad).

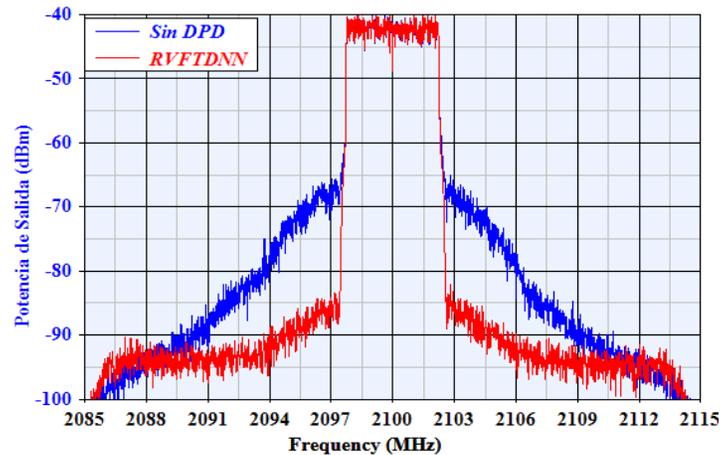


Figura 14 Espectro resultante de predistorsión digital.

### 3. Resultados

Se compararon distintas arquitecturas de redes neuronales, como método para modelar un AP, y dichos modelos se utilizaron para realizar predistorsión digital. De las cuatro arquitecturas de redes neuronales que se estudiaron, las cuatro fueron capaces de modelar correctamente el comportamiento del AP tal como se muestra en la tabla 1 donde podemos ver el error cuadrático medio normalizado (NMSE) de cada modelo. Los resultados mostrados en la tabla 1 indican cuanta diferencia hay entre la respuesta del modelo y la respuesta del AP, este parámetro se calcula como se muestra en la ecuación 1.

$$NMSE[dB] = 10 \log_{10} \left[ \frac{\sum |x_i - y_i|^2}{\sum |x_i|^2} \right] \quad (1)$$

Donde:

$x_i$ : Respuesta del AP    y     $y_i$ : Respuesta del modelo

Tabla 1 NMSE de modelado de comportamiento.

	NMSE (dB)	N° Retardos		N° Neuronas	
		Entrada	Salida	1ª capa	2ª capa
<b>RVFTDNN</b>	-35.28	9	-	25	15
<b>FC2HLANN</b>	-37.074	2	3	4	15
<b>M2HLANN</b>	-37.339	3	4	2	20
<b>NARX</b>	-38.599	1	2	3	15

Por otro lado, al usar los modelos para realizar predistorsión digital, se logró observar mejores resultados con la red neuronal *feedforward* que con las arquitecturas recurrentes. En la tabla 2 se presenta el valor del ACPR con y sin predistorsión digital, así como la reducción obtenida con cada red neuronal.

Tabla 2 ACPR con y sin predistorsión digital.

	ACPR		
	Sin DPD [dBc]	Con DPD [dBc]	Reducción [dB]
<b>RVFTDNN</b>	-28.9	-48.8	-19.9
<b>FC2HLANN</b>	-30.56	-44.24	-13.68
<b>M2HLANN</b>	-30.9	-43.66	-12.76
<b>NARX</b>	-30.4	-41.35	-10.95

Por último, en la figura 15 se presenta la característica AM-AM obtenida con la red RVFTDNN y en la figura 16 se muestra el espectro de potencia de la señal de salida de amplificador con y sin predistorsión. Podemos observar que la reducción de la distorsión obtenida usando la red RVFTDNN es notablemente superior en comparación con las demás redes analizadas.

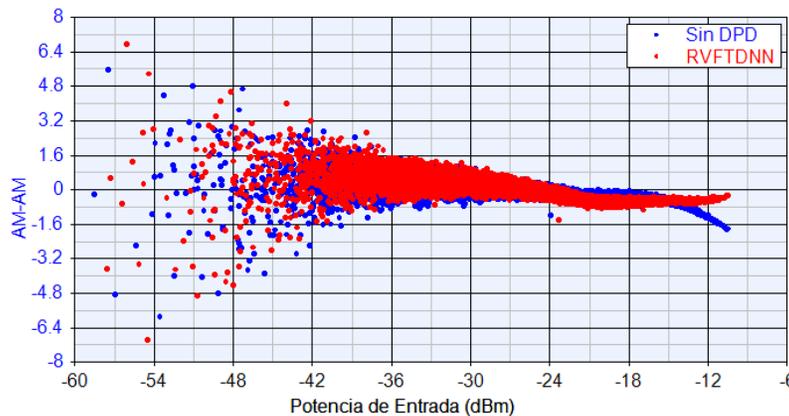


Figura 15 AM-AM resultante de predistorsión digital.

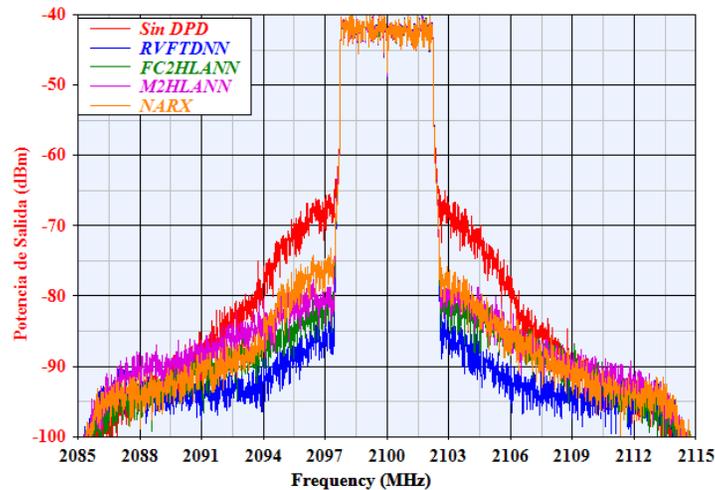


Figura 16 Espectro resultante de predistorsión digital.

#### 4. Discusión

Dentro de las técnicas de linealización de amplificadores de potencia, la predistorsión digital ha sido una de las técnicas más usadas para la investigación debido a las ventajas que ofrece. Una de las partes más importantes de esta técnica radica en el correcto modelado de comportamiento del amplificador que se busca linealizar, es por eso que en la literatura se reportan muchos métodos de modelado y cada uno con distintas ventajas y desventajas.

En el caso de las redes neuronales, existen diversas arquitecturas que se han propuesto para modelar APs. En nuestro caso se utilizaron las redes RVFTDNN, FC2HLANN, M2HLANN y NARX debido a que presentan buenos resultados tanto en la literatura como en la implementación. Al realizar el modelado de comportamiento del AP, todas las redes neurales presentaron un NMSE realmente bajo, lo cual indica que los modelos eran capaces de reproducir el comportamiento del AP. Sin embargo, para realizar correctamente la predistorsión digital, es indispensable que las redes neuronales tengan una buena generalización para poder predecir el comportamiento a valores, en la señal de entrada, diferentes a los valores con los que fue entrenado [Luongvinh, 2005]. Debido a que no hay una manera definitiva para medir la generalización de una red neuronal, se realizaron pruebas de cada arquitectura con distinto número de retardos y de neuronas hasta que se encontraron las redes neuronales con mejor generalización.

En cuanto a la predistorsión digital, la mayor reducción de no linealidad y efectos de memoria se logró usando la red RVFTDNN. Esta red es la única analizada con arquitectura *feedforward*, mientras que las otras redes analizadas tienen una arquitectura recurrente.

Para realizar la predistorsión con redes recurrentes, fue necesario realizar un tratamiento a la banda base (señal a predistorsionar) que consiste en un ajuste en tiempo y en fase.

## **5. Conclusiones**

Se realizó un análisis comparativo de distintas arquitecturas de las redes neuronales RVFTDNN, FC2HLANN, M2HLANN y NARX. Se compararon las capacidades de cada una para realizar modelado de comportamiento de un amplificador de potencia Doherty.

En cuanto al modelado de comportamiento del AP, la arquitectura que presentó un menor NMSE de modelado fue la NARX con -38.599 dB, sin embargo, fue con la que se obtuvieron los resultados más pobres de predistorsión digital. De los resultados obtenidos en las pruebas de los modelados, se logró observar que las redes recurrentes mostraban mejores capacidades para modelar la no linealidad y efectos de memoria. Esto debido a que la red dispone de mayor información que le permite reproducir estos comportamientos. La predistorsión digital se realizó con éxito con las 4 redes analizadas.

A diferencia de los resultados obtenidos en el modelado, la red que presentó mejores resultados en la predistorsión fue la red RVFTDNN. Mientras que la red que presentó los resultados más pobres fue la red NARX. Con lo anterior, podemos concluir que, aunque las redes neuronales recurrentes son capaces de reproducir de mejor forma el comportamiento no lineal del AP, la red *feedforward* presenta mejores resultados en la predistorsión digital. Esto puede deberse a la generalización de las redes recurrentes, pero dado a que no es posible medir esta característica, es necesario realizar un estudio enfocado en la generalización de las redes para poder confirmar esta hipótesis.

## **Agradecimientos**

Se agradece a la Comisión Nacional de Ciencia y Tecnología CONACYT por el apoyo para realizar este trabajo.

Se agradece al Centro de Investigación y de Estudios Avanzados del IPN CINVESTAV por todas las facilidades brindadas en el desarrollo del trabajo.

## **6. Bibliografía y Referencias**

- [1] Aguilar, L. M. Linealización de Amplificadores de Potencia Mediante un Modelo de Predistorsión Digital Basado en la Red Neuronal NARX, Ph. D Tesis, CINVESTAV. Guadalajara, Jal, México. 2015.
- [2] Bogya R. I. and Magana, M. E. Linear radio frequency power amplifier design using nonlinear feedback linearization techniques, IEEE 60th Vehicular Technology Conference, 2004. VTC2004-Fall. 2004, Los Angeles, CA, 2004, pp. 2259-2263 Vol. 3.
- [3] Lavrador, P. M. Cunha, T. R. Cabral P. M. and Pedro, J. C. The Linearity-Efficiency Compromise, in IEEE Microwave Magazine, vol. 11, no. 5, pp. 44-58, Aug. 2010.
- [4] Luongvinh, D. and Kwon, Y. Behavioral modeling of power amplifiers using fully recurrent neural networks, IEEE MTT-S International Microwave Symposium Digest, 2005, Long Beach, CA, 2005, pp. 1979-1982.
- [5] Mkadem, F. Ayed, M. B. Boumaiza, S. Wood J. and Aaen, P. Behavioral modeling and digital predistortion of Power Amplifiers with memory using Two Hidden Layers Artificial Neural Networks, 2010 IEEE MTT-S International Microwave Symposium, Anaheim, CA, 2010, pp. 656-659.
- [6] Mkadem F. and Boumaiza, S. Physically Inspired Neural Network Model for RF Power Amplifier Behavioral Modeling and Digital Predistortion, in IEEE Transactions on Microwave Theory and Techniques, vol. 59, no. 4, pp. 913-923, April 2011.
- [7] Nezami, M. Fundamentals of power amplifier linearization using digital pre-distortion, in High Frequency Electronics, Vol. 3, no 8, pp. 54-59, September 2004.

- [8] Shi, B and Sundstrom, L. Linearization of RF power amplifiers using power feedback, 1999 IEEE 49th Vehicular Technology Conference, Houston, TX, 1999, pp. 1520-1524 vol.2.
- [9] Xiang, T. and Wang, G. Doherty power amplifier with feedforward linearization, 2009 Asia Pacific Microwave Conference, Singapore, 2009, pp. 1621-1624.