

Tipo de artículo: Investigación

Modelado del comportamiento de un amplificador de potencia para 5G utilizando Machine Learning

Modeling the Behavior of a Power Amplifier for 5G Using Machine Learning

Miguel Angel Chiri  Hugo Orlando Condori Quispe

1. Estudiante. Universidad Mayor de San Andrés. La Paz. Bolivia. ma.chiriyp@gmail.com

2. Ingeniero de Hardware RF, Docente. Universidad Mayor de San Andrés. La Paz. Bolivia. hugo.condori@fulbrightmail.org

RESUMEN

El propósito principal de esta investigación es modelar el comportamiento de un amplificador de radiofrecuencia (RF) mediante técnicas de machine learning. Para lograr este objetivo, se utiliza el software Advanced Design System (ADS) de Keysight; primero se obtienen los datos de gráficas relevantes, los cuales se transforman en datos tabulares. Estos datos son esenciales para el entrenamiento del modelo. Se emplea el intérprete de Python de ADS, para este propósito. Los resultados obtenidos muestran una notable concordancia con el comportamiento esperado del amplificador RF, lo que confirma la efectividad del enfoque propuesto. Este hallazgo no sólo valida la viabilidad de modelar amplificadores, sino que también sugiere la aplicabilidad de estas técnicas en el modelado de diversos sistemas electrónicos con un alto grado de precisión y fiabilidad.

Palabras clave: Machine Learning. ADS. Amplificador. Modelado. 5G.

ABSTRACT

The main purpose of this research is to model the behavior of a radio frequency (RF) amplifier using machine learning techniques. To achieve this goal, we use Keysight's ADS software. First, relevant data from graphs is obtained and transformed into tabular data. This data is essential for training the model. The obtained results show a remarkable agreement with the expected behavior of the RF amplifier, which confirms the effectiveness of the proposed approach. This finding not only validates the feasibility of modeling amplifiers, but also suggests the applicability of these techniques in the modeling of diverse electronic systems with a high degree of accuracy and reliability.

Keywords: Machine Learning. ADS. Amplifier. Modeling. 5G.

1. INTRODUCCIÓN

1.1. Contexto Tecnológico

Las tecnologías de comunicación inalámbrica están evolucionando a un ritmo acelerado hacia la quinta generación (5G) (Huo,2017). Esta nueva generación promete avances sin precedentes en velocidad de datos, latencia y capacidad de conexión, con el potencial de revolucionar la forma en que nos comunicamos e interactuamos con el mundo que nos rodea (Yang,2018; Xiom,2021).

Citar como: Chiri Yupanqui, M. A., & Condori Quispe, H. O. Modelado del comportamiento de un amplificador de potencia para 5G utilizando Machine Learning. *Journal Boliviano De Ciencias*, 20(55) 6-14. <https://doi.org/10.52428/20758944.v20i55.1101>

Revisado: 18/03/2024

Aceptado: 14/06/2024

Publicado: 20/12/2023

Declaración: Derechos de autor 2024 Miguel Angel Chiri, Hugo Orlando Condori Quispe, Esta obra está bajo una licencia internacional [Creative Commons Atribución 4.0](https://creativecommons.org/licenses/by/4.0/).

Los autores/as declaran no tener ningún conflicto de intereses en la publicación de este documento.



Para alcanzar estos objetivos, se requiere un desarrollo tecnológico integral que abarca diversos aspectos, incluyendo el diseño y optimización de los subsistemas de hardware que componen las redes 5G. Entre estos subsistemas, los amplificadores de potencia (PA) juegan un rol fundamental al ser responsables de amplificar las señales de radiofrecuencia (RF) para su transmisión efectiva (Colzani,2022; Ji, 2023;Mounir,2022).

1.2. Relevancia del Modelado

El modelado preciso del comportamiento de los amplificadores de potencia (PA) resulta fundamental en el desarrollo eficiente de sistemas 5G. Los modelos desempeñan un papel crucial al permitir simular y analizar el comportamiento del PA en diversas condiciones. Esta capacidad facilita la identificación temprana de posibles problemas de diseño y la optimización del rendimiento del amplificador, lo que es esencial para garantizar un funcionamiento óptimo en entornos de comunicación de alta velocidad como el 5G.

Además, el modelado contribuye significativamente a la reducción del tiempo y los costos de desarrollo. Al permitir pruebas virtuales exhaustivas antes de la construcción de prototipos físicos, los modelos agilizan el proceso de desarrollo al eliminar la necesidad de iteraciones costosas y prolongadas (Xiaom, 2021; Huo, 2017). Esto no sólo acelera la llegada al mercado de productos 5G, sino que también reduce los costos asociados con la fabricación y prueba de prototipos físicos, lo que resulta en un ahorro significativo para las empresas y los desarrolladores de tecnología.

1.3. Enfoque Basado en Machine Learning

El Machine Learning (ML) ha emergido como una herramienta poderosa en el modelado de sistemas complejos (Ma,2018). En el contexto del modelado de amplificadores de potencia (PA), el ML presenta ventajas significativas (Dikmese, 2019). Una de ellas radica en su capacidad de aprendizaje a partir de datos. Los algoritmos de ML tienen la capacidad de aprender de grandes conjuntos de datos, como las respuestas gráficas de ganancia y fase proporcionadas en las hojas de datos de los PA comerciales (Liu, 2012).

2. METODOLOGÍA

Para desarrollar el modelado del amplificador de potencia (PA) utilizando redes neuronales artificiales (ANNs), se sigue un proceso sistemático que involucra varias etapas clave.

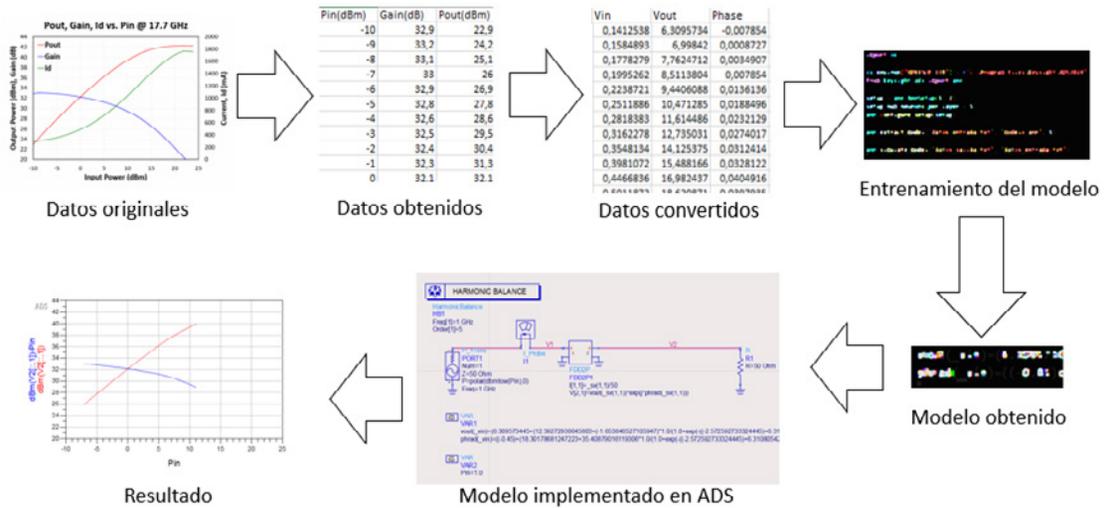


Figura N° 1. Etapas del modelado del PA usando ANNs. Fuente: Elaboración propia, 2024.

En primer lugar, el modelo propuesto puede ser visualizado como un sistema de entrada y salida. Las señales de entrada comprenden los datos experimentales proporcionados por el fabricante del amplificador de potencia, que incluyen la ganancia, la respuesta AM/AM y la respuesta AM/PM en diversas condiciones operativas. Estos datos son esenciales para entrenar y validar la red neuronal artificial (ANN), que se convierte en el núcleo del sistema.

El modelo de machine learning se diseñó considerando las siguientes variables:

- **Entrada:** Voltaje de entrada.
- **Salida:** Voltaje de salida y fase.

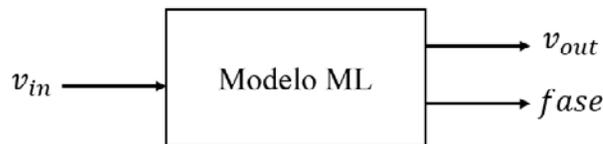


Figura N° 2. Modelo del amplificador de potencia con ANN: entradas (datos experimentales) y salidas (voltaje y fase predichos). Fuente: Elaboración propia, 2024.

Esta configuración permite que la red neuronal artificial procese eficientemente la información de entrada y genere predicciones precisas del voltaje de salida y la fase correspondiente. Esencialmente, la red neuronal actúa como un componente central que interpreta los datos experimentales y los transforma en salidas útiles, lo que proporciona un marco sólido para entender y modelar el comportamiento del amplificador de potencia.

2.1. Obtención de los datos

Se obtuvieron los datos experimentales del datasheet del amplificador comercial TGA4548, operando en la banda de frecuencia de 17 a 20 GHz, con énfasis en la frecuencia central de 17.7 GHz. Se seleccionaron las respuestas de ganancia (dB) y AM-PM (grados) como las variables principales para el modelado.

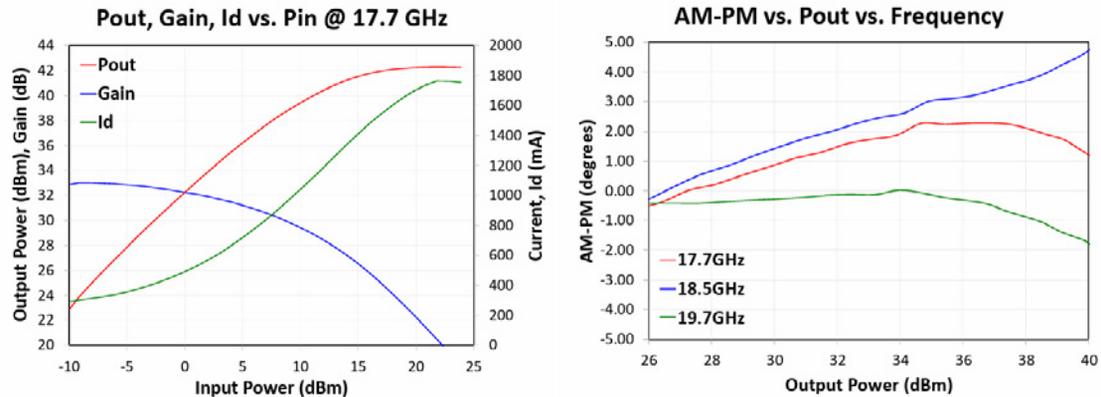


Figura N° 3. Gráficas de Ganancia (dB) y AM-PM (grados). Fuente: Datasheet amplificador TGA4548, 2020.

Dado que la potencia de salida en la gráfica de fase varía entre 26 y 40 dBm, se limitó la simulación del comportamiento del amplificador a este rango. En consecuencia, se consideraron solo los datos en esta región para la gráfica de ganancia y potencia de salida, las cuales varían para una potencia de entrada desde aproximadamente -7 hasta 11 dBm.

Se realizó la digitalización manual de las gráficas para obtener datos tabulares que representarían el comportamiento del amplificador. Posteriormente, se calcularon los voltajes de entrada y salida utilizando ecuaciones matemáticas derivadas de los datos tabulares:

$$\text{Para calcular el voltaje de entrada: } v_{in} = \sqrt{2R_L * 10^{\frac{P_{in(dBm)} - 30}{10}}}$$

$$\text{Para calcular el voltaje de salida: } v_{out} = 10^{\frac{G_{(dB)}}{20}} * v_{in}$$

$$\text{La fase se convierte a radianes: } fase_{(rad)} = fase_{(grados)} * \frac{\pi}{180}$$

2.2. Entrenamiento del Modelo

Se utilizó un script de Python, cuyo flujograma se muestra a continuación:

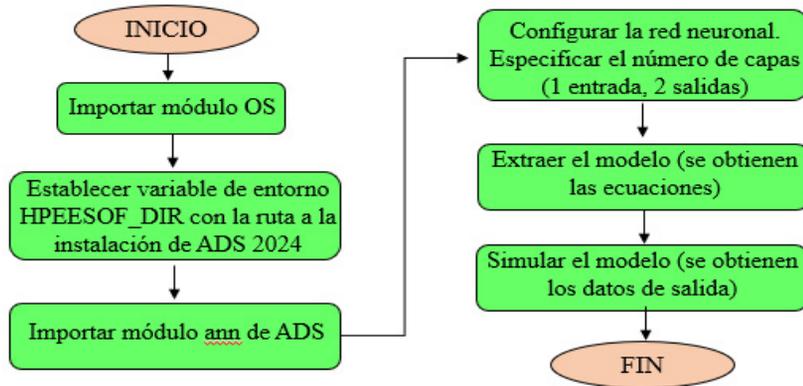


Figura N° 4. Flujograma del script usado para crear el modelo. Fuente: Elaboración propia, 2024.

El entrenamiento del modelo se realizó utilizando un archivo de texto generado previamente, el cual contiene los datos de voltaje de entrada, voltaje de salida y fase. Se configuró la red neuronal con 1 capa de entrada y 1 capa oculta, ambas con 5 nodos. Durante este proceso, se generaron dos archivos: uno que contiene los datos de salida del modelo, y el otro presenta el modelo en forma de ecuación, que se describe a continuación:

$$y = c_1 + (c_2 + S_1 + S_2 + S_3 + S_4 + S_5)c_3$$

Donde:
$$S_i = \frac{\beta}{1 + e^{-(\alpha + M_1^i + M_2^i + M_3^i + M_4^i + M_5^i)}}$$

Y donde:
$$M_j^i = \frac{m_1}{1 + e^{-(m_2 + m_3(-1 + \frac{2(x - K_1)}{K_2}))}}$$

Las constantes $c_1, c_2, c_3, \alpha, \beta, m_1, m_2, m_3, K_1, K_2$ son generadas en el entrenamiento.

2.3. Implementación en ADS

Las ecuaciones del modelo se implementaron en un esquemático de ADS utilizando variables, permitiendo su integración en el entorno de simulación de ADS. Se utilizó un controlador de equilibrio armónico HB, con la potencia de entrada como parámetro, variando desde -7 dBm hasta 11 dBm. Para conectar el modelo con la entrada y salida del circuito, se empleó el componente FDD (Frequency Domain Defined Device) proporcionado por ADS. Con FDD, se puede detectar la señal eléctrica en cualquier puerto y convertirla en parte de una función, permitiendo un control preciso de la entrada y salida del circuito.

3. RESULTADOS

Se procedió a la simulación del modelo para obtener las respuestas gráficas de diversas variables de interés. Entre estas variables se incluyeron la potencia de entrada y salida, la fase, la ganancia.

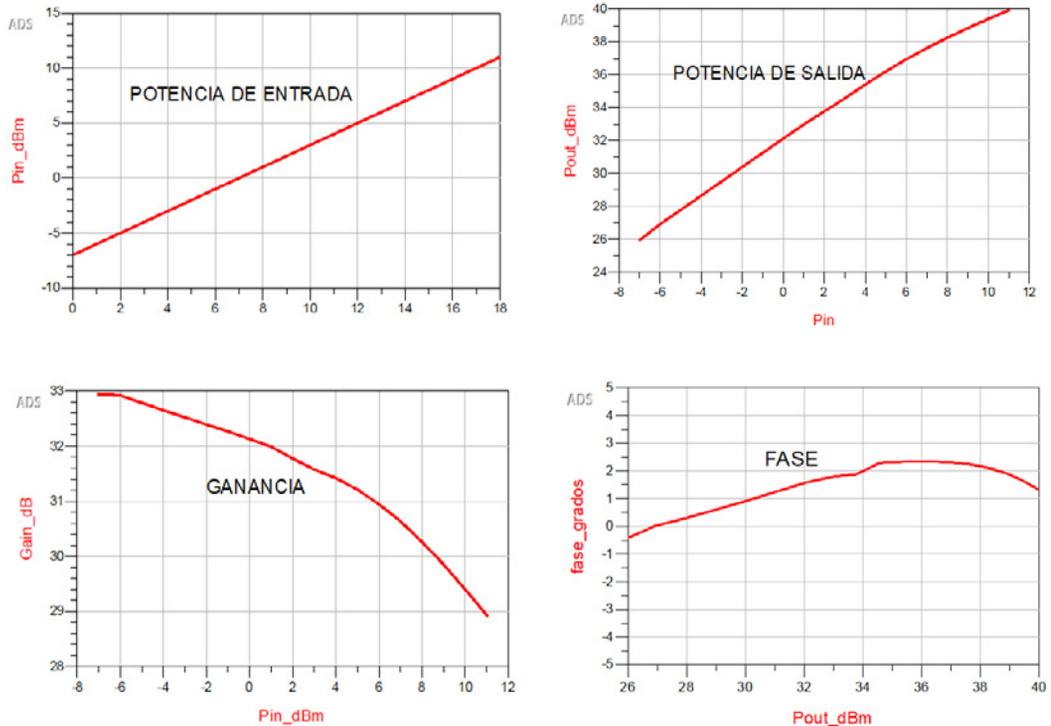


Figura N° 5. Resultados obtenidos de la simulación. Fuente: Elaboración propia, 2024.

4. DISCUSIÓN, DESARROLLO Y ANÁLISIS

4.1 Discusión

Se consideraron las siguientes especificaciones para el componente FDD:

- El voltaje de entrada del FDD es $_{sv}(1,1)$, entonces para emular una resistencia de entrada de 50 ohms se estableció la corriente de entrada en $I[1,1]=_{sv}(1,1)/50$ ($I=V/R$)
- El voltaje de salida del FDD es $V[2,1]$, presentado de manera polar como:

Para validar el modelo, se presenta a continuación una tabla que compara los datos originales con los generados por el modelo. Adicionalmente, se calcula porcentaje de error para las dos variables estimadas: el voltaje de salida y la fase.

vin	DATASHEET		MODELO	
	vout	fase	vout	fase
0,14125375	6,30957344	-0,00785398	6,27018834	-0,00783111
0,17782794	7,76247117	0,003490659	7,74928015	0,00429459
0,19952623	8,51138038	0,007853982	8,56274395	0,00863299
0,22387211	9,44060876	0,013613568	9,46581474	0,01323755
0,25118864	10,4712855	0,018849556	10,4655031	0,01805527
0,28183829	11,6144861	0,023212879	11,5675636	0,02300346
0,31622777	12,7350308	0,027401669	12,7759207	0,02793755
0,35481339	14,1253754	0,031241394	14,1089305	0,03122337
0,39810717	15,4881662	0,03281219	15,4468009	0,03281915
0,44668359	16,9824365	0,040491639	16,9324399	0,03994675
0,50118723	18,6208714	0,039793507	18,6599488	0,04062058
0,56234133	20,4173794	0,040491639	20,4419864	0,04077219
0,63095734	22,1309471	0,040666172	22,2535082	0,04030093
0,70794578	23,9883292	0,039793507	24,0730245	0,03903895
0,79432823	26,0015956	0,036302848	25,8860102	0,03683531
0,89125094	27,8612117	0,033161256	27,6906702	0,03356849
1	29,5120923	0,029670597	29,5036296	0,02915535
1,12201845	31,2607937	0,023387412	31,3650408	0,02355591

porcentaje de error vout	0,32104739
porcentaje de error fase	3,06759033

Como se puede observar, los valores del porcentaje de error para ambas variables, el voltaje de salida y la fase, se encuentran dentro de un rango considerado aceptable para la precisión del modelo. Este resultado sugiere una adecuada concordancia entre los datos originales y los generados, lo cual valida la capacidad predictiva del modelo bajo las condiciones evaluadas. Existe la posibilidad de mejorar la precisión incrementando el número de nodos en la capa de entrada y en las capas ocultas, o bien, aumentando el número de capas ocultas. Sin embargo, esto también incrementaría la complejidad del modelo.

Para mejor visualización de los resultados se convierten los resultados a sus equivalentes en potencia de entrada, potencia de salida, y fase, y se comparan estos con las gráficas provenientes del datasheet, se estableció un rango apropiado a las gráficas de simulación, y se editó la gráfica de ganancia y potencia de salida del datasheet para mejor visualización:

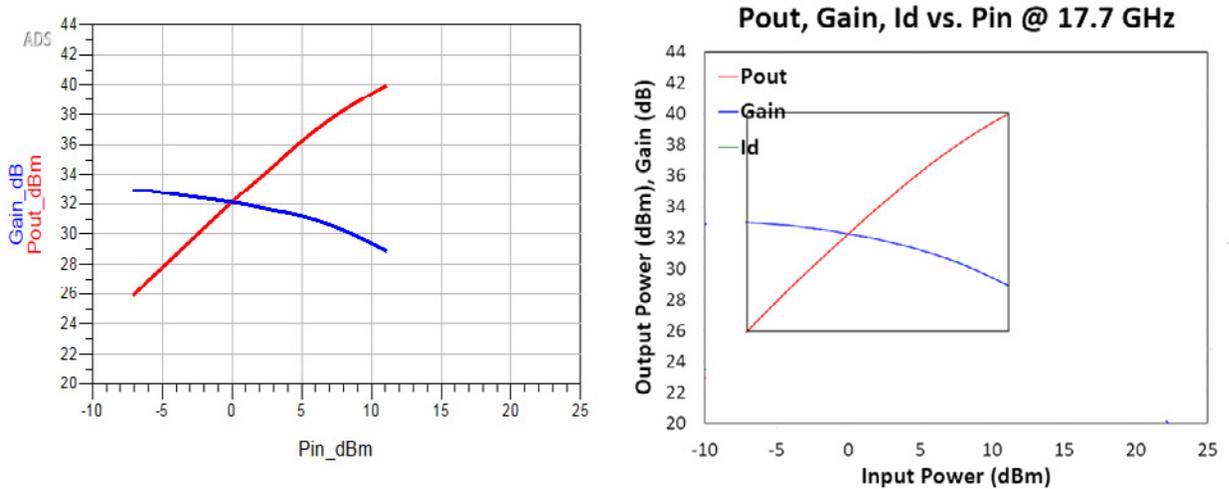


Figura N° 6. Comparación de las respuestas de ganancia y potencia de salida.
Fuente: Elaboración propia, 2024.

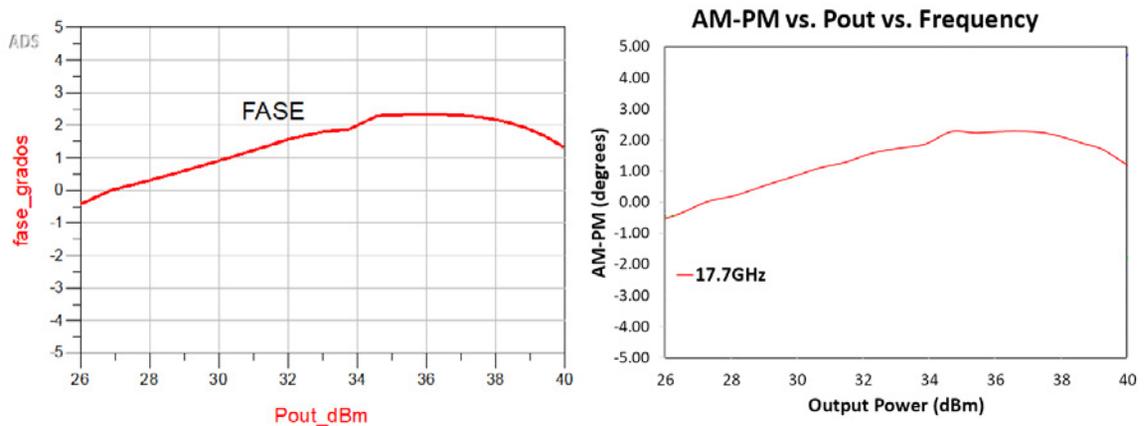


Figura N° 7. Comparación de las respuestas de fase. Fuente: Elaboración propia, 2024.

Se aprecia una notable similitud entre las respuestas del modelo y las especificaciones del datasheet del amplificador comercial. Las gráficas de ganancia, potencia de salida y fase del modelo exhiben una tendencia similar a las del datasheet, aunque se observan pequeñas diferencias que podrían atribuirse a la naturaleza del proceso de modelado.

5. CONCLUSIONES

El presente trabajo ha alcanzado un modelado exitoso del comportamiento de un amplificador de radiofrecuencia (RF) utilizando técnicas de Machine Learning. La validación del modelo se llevó a cabo mediante su comparación con el comportamiento real de un amplificador comercial. Los resultados obtenidos de

esta comparación revelaron una notable concordancia entre ambos, lo que confirma la precisión y fiabilidad del modelo desarrollado en este estudio.

El trabajo realizado representa un avance significativo en el ámbito del modelado de amplificadores RF. La aplicación de técnicas de Machine Learning en este contexto abre nuevas posibilidades para el desarrollo de modelos más precisos y eficientes, los cuales pueden ser utilizados para optimizar el diseño y análisis de amplificadores en sistemas de comunicación 5G y otras aplicaciones de relevancia tecnológica. Las implicaciones y aplicaciones de este trabajo son amplias y prometedoras y abre un abanico de posibilidades para el desarrollo de modelos más precisos de componentes y sistemas electrónicos en diferentes áreas de la ingeniería, como la electrónica de potencia, la electrónica de control y la electrónica automotriz, entre otras.

7. REFERENCIAS

- Colzani, A., Fumagalli, M., Fonte, A., Traversa, A., & Ture, E. (2022, September). Long-Reach E-band HPA for 5G Radio Link. In 2022 52nd European Microwave Conference (EuMC) (pp. 760-763). IEEE.
- Dikmese, S., Anttila, L., Campo, P. P., Valkama, M., & Renfors, M. (2019, August). Behavioral modeling of power amplifiers with modern machine learning techniques. In 2019 IEEE MTT-S International Microwave Conference on Hardware and Systems for 5G and Beyond (IMC-5G) (pp. 1-3). IEEE.
- Huo, Y., Dong, X., & Xu, W. (2017). 5G cellular user equipment: From theory to practical hardware design. *IEEE Access*, 5, 13992-14010.
- Ji, H. G., Jeong, J. H., & Kang, D. M. (2023). Balanced GaN HPA MMIC for 5G FR2 Band Base Station. *The Journal of Korean Institute of Electromagnetic Engineering and Science*, 34(6), 444-449.
- Liu, B., Deferm, N., Zhao, D., Reynaert, P., & Gielen, G. G. (2012). An efficient high-frequency linear RF amplifier synthesis method based on evolutionary computation and machine learning techniques. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 31(7), 981-993.
- Ma, R., Benosman, M., Manjunatha, K. A., Komatsuzaki, Y., Shinjo, S., Teo, K. H., & Orlik, P. V. (2018, August). Machine-learning based digital Doherty power amplifier. In 2018 IEEE International Symposium on Radio-Frequency Integration Technology (RFIT) (pp. 1-3). IEEE.
- Mounir, M., El Mashade, M. B., Aboshosha, A. M., & Youssef, M. I. (2022). Impact of HPA nonlinearity on the performance of power domain OFDM-NOMA system. *Engineering Research Express*, 4(2), 025004.
- Qorvo (2020, diciembre 15). Data Sheet del amplificador TGA4548.
- Xiao, K., & Zhang, W. (2021, April). Systematic study on hardware optimization of 5G communication. In 2021 5th International Conference on Computing Methodologies and Communication (ICCMC) (pp. 92-96). IEEE.
- Yang, Y., Xu, J., Shi, G., & Wang, C. X. (2018). *5G wireless systems*. Springer International Publishing.