



Universidad
Zaragoza

Trabajo Fin de Grado

Modelado y linealización de un transmisor híbrido
Radio-sobre-Fibra en sistemas de comunicaciones
5G.

Modeling and linearization of an hybrid transmitter
Radio over fiber on 5G communications systems.

Autor

Alberto Palomero Ramos

Director

M^a Paloma García Ducar

Escuela de Ingeniería y Arquitectura (EINA)

Enero 2023

Modelado y linealización de un transmisor híbrido Radio-sobre-Fibra en sistemas de comunicaciones 5G.

RESUMEN

En este trabajo de fin de grado se estudian los nuevos sistemas de comunicaciones móviles, caracterizados por señales de banda ancha junto con modulaciones de banda estrecha, agregados de diferentes maneras a las modulaciones y esquemas de transmisión de quinta generación. Se propone analizar las prestaciones de un transmisor de quinta generación sobre el sistema Radio sobre Fibra, modelando su respuesta y empleando técnicas de predistorsión digital adecuadas que permitan la optimización del funcionamiento del transmisor híbrido.

Para completar este estudio se va a emplear un software en Matlab, implementado en otro proyecto, con el que se crean las señales de quinta generación con alguna variación de sus parámetros. Estas señales se validan en el montaje experimental de manera que nos permita conocer las distorsiones que introduce el sistema Radio sobre Fibra. Tras el modelado de este sistema se aplican varias técnicas de predistorsión digital para intentar reducir la distorsión tanto dentro como fuera de banda. Estos resultados se verifican de nuevo sobre el montaje experimental.

Las técnicas de predistorsión digital que se van a emplear se basan en arquitecturas de aprendizaje indirecto, utilizando el modelo polinomial y el modelo canónico lineal a trozos, y en las redes neuronales. Con esto se busca comprobar si las redes neuronales ofrecen también buenos resultados a la hora de linealizar un sistema no lineal como el propuesto.

El rendimiento de estos métodos de linealización se va a evaluar, tanto en simulación como en el montaje experimental, con el error cuadrático medio y con el compromiso entre pérdida de potencia y el Adjacent Channel Power Ratio (ACPR). Se tendrá en cuenta también la carga computacional que requiere cada técnica, pero este no será un factor determinante.

INDICE

1. Introducción	5
1.1. Evolución histórica	5
1.2. Sistemas 5G y nuevas arquitecturas	6
1.3. Objetivos	7
2. Generación de la señal 5G	8
2.1. Introducción	8
2.2. Características de las señales generadas	10
2.3. Figuras de mérito	12
3. Modelado del transmisor RoF	14
3.1. Montaje del transmisor RoF	14
3.2. Caracterización de sistemas no lineales	16
3.2.1. Curvas AM/AM, AM/PM	16
3.3. Modelado de sistemas no lineales	17
3.3.1. Modelo Polinomial	17
3.3.2. Modelo CPWL	18
3.4. Modelado de nuestro transmisor RoF	19
3.4.1. Modelado con modelo Polinomial	19
3.4.2. Modelado con modelo CPWL	21
4. Predistorsión	24
4.1. Introducción	24
4.2. DPD con modelo Polinomial	26
4.3. DPD con modelo CPWL	28
4.3.1. Aplicación del modelo CPWL	29
4.4. DPD utilizando redes neuronales	32
4.4.1. Red neuronal para el cálculo de los umbrales genéticos	33
4.4.2. Red neuronal como DPD	36
5. Evaluación de Resultados	39
5.1. Evaluación de las señales propuestas	39
5.1.1. Escenario 1	39
5.1.2. Escenario 2	41

5.1.3. Escenario 3.....	42
5.1.4. Escenario 4.....	43
5.1.5. Escenario 5.....	44
5.2. Conclusiones de los resultados.....	47
6. Conclusiones.....	49
7. Bibliografía	52
Lista de Figuras.....	54
Lista de Tablas	56
Lista de Acrónimos	57
Anexos	59
A. Generación de señales 5G.....	60
A.1. Simulador de señales 5G en Matlab	60
A.2. Parámetros de las señales utilizadas para entrenar las redes neuronales	61
B. Resultados obtenidos en simulación	63
C. Hojas de características	64

1. Introducción

Durante las últimas décadas el uso de las comunicaciones móviles y de las tecnologías de la información se ha visto incrementado, debido en gran medida al aumento de la demanda de los usuarios, ocasionado principalmente por el rápido crecimiento de las comunicaciones móviles. Este crecimiento se debe principalmente a 4 factores: los avances tecnológicos, la estandarización para que los equipos sean compatibles, la regulación y la liberalización del mercado. Todo esto ha hecho que haya múltiples operadores, generando un mercado con mucha más competencia derivando en un abaratamiento de los equipos y servicios así como en un incremento de la demanda. Para comprender como ha sido esta evolución se van a explicar a continuación las diferentes tecnologías que existen y como fueron mejorando a sus predecesores [1].

1.1. Evolución histórica

Para conocer cuál fue el primer servicio móvil terrestre nos tenemos que remontar a 1920 en Estados Unidos (EEUU), donde se utilizó para que los policías de Detroit y Nueva York se pudieran comunicar. Durante los siguientes años se fueron implementando algunas novedades como la modulación AM, pero no fue hasta 1980 cuando se implementó por primera vez un sistema celular, dando lugar a la primera generación (1G). Algunos países desarrollaron sus propios sistemas como por ejemplo Estados Unidos que creó AMPS (Advanced Mobile Phone Service), Reino Unido que creó la TACS (Total Access Communications Systems) o la NMT-450 (Nordiska Mobil Telefongruppen) los países nórdicos. Estas tecnologías se caracterizaron por ser analógicas e incompatibles entre diferentes sistemas.

En la década de los 90 se implementó la segunda generación (2G). También está basada en sistemas celulares, pero en vez de utilizar tecnología analógica introduce por primera vez el uso de modulaciones digitales ofreciendo una mayor eficiencia espectral. En 2G, se introduce FDD (Frequency Division Duplex) y se controla el acceso al medio con TDMA (Time Division Multiple Access). Presenta numerosas ventajas frente a su predecesor como una mayor calidad de voz o una mayor confidencialidad, además de estandarizar todos los sistemas a nivel internacional. Algunos de estos sistemas son GSM (Groupe Special for Mobile) en Europa y ADC (American Digital Cellular) en EEUU.

Con la llegada del nuevo siglo se desarrolla la tercera generación (3G). Con esta generación se produce la transición de los sistemas GSM a UMTS (Universal Mobile Telecommunications Systems). Utiliza también modulaciones digitales pero a diferencia de 2G, el control de acceso al medio se hace con CDMA (Code Division Multiple Access) y se emplea FDD+TDD (Time Division Duplex). La transición a UMTS supone el uso de terminales multifunción, el uso de una inteligencia

distribuida o el uso de banda ancha entre otros. Todo esto supuso de nuevo una mejora en la calidad y velocidad de las comunicaciones.

En 2010 surge la cuarta generación (4G), que como novedad incorpora el uso de OFDM (Orthogonal Frequency Division Multiplexing) como control de acceso al medio, dividiendo el espectro en subportadoras ortogonales entre sí. Todo esto propició el auge de las tecnologías basadas en el protocolo IP y en que se consiguieran velocidades mayores con respecto a 3G.

4G se creó con el objetivo de que fuera evolucionando con el tiempo además de ser universal, por lo que debía soportar todos los sistemas anteriores. Para ello, el grupo conocido como 3GPP (3rd Generation Partnership Project) definió el estándar LTE (Long Term Evolution), no considerado 4G hasta el desarrollo de LTE-Advanced [2], una ampliación de LTE. Surge con el objetivo de ser capaz de ofrecer altas capacidades de transmisión para anchos de banda de más de 100 MHz. Para ello hace uso de antenas múltiples basadas en MIMO (Multiple-Input-Multiple-Output) y transmisores coordinados multipunto.

1.2. Sistemas 5G y nuevas arquitecturas

Los sistemas de quinta generación (5G) se comenzaron a desarrollar a partir del año 2015. Parte de LTE-Advanced con el objetivo de dar soporte a cualquier sistema de comunicación basado en internet, un ejemplo de estos sistemas son los utilizados en aplicaciones IoT (Internet of Things). 5G deberá proveer, según el ITU (International Telecommunication Union), una mejora en la banda ancha móvil, dar soporte a un gran número de sensores para terminales IoT y deberá ser capaz de soportar conexiones masivas [3]. Una de las características de las señales 5G son los muchos parámetros que tienen, lo que permite generar diferentes tipos de señales.

Como consecuencia de la evolución de las diferentes tecnologías, es necesario el desarrollo de nuevas arquitecturas capaces de soportar el continuo crecimiento de los sistemas móviles. Para ello se propone la arquitectura radio sobre fibra (RoF) [4]. El principio fundamental de este tipo de enlaces es la transmisión de una señal analógica a través de un enlace de fibra óptica, entre la BBU (BaseBand Unit) y el RRH (Remote Radio Head). Esta arquitectura presenta algunas ventajas como son un aumento de la capacidad del enlace debido al elevado ancho de banda ofrecido por la fibra, las bajas pérdidas en potencia que sufre la señal en la fibra, la inmunidad frente a interferencias electromagnéticas y permite distribuir varias señales sobre una misma fibra gracias a la multiplexación por longitud de onda. Debido a que es un sistema de transmisión analógico, es sensible a sufrir distorsiones causadas por los dispositivos no lineales del enlace RoF, especialmente por el amplificador de potencia (PA) ya que para hacer el sistema más eficiente trabaja cerca de la zona de saturación.

1.3. Objetivos

En este TFG se van a desarrollar y probar diferentes sistemas de linealización para compensar las distorsiones que se producen en un enlace RoF cuando se envía una señal 5G. Además se realizará un estudio de la influencia de algunos de los parámetros variables que forman una señal 5G.

Para ello en primer lugar se generan, utilizando un simulador en Matlab [5], todas las señales que se quieren evaluar, y tras pasar estas señales por el montaje del laboratorio, se realizará un estudio de sus no linealidades tratando de modelarlas en Matlab. Para la evaluación de estos resultados se utilizarán tres figuras de mérito, explicadas a lo largo de la memoria. Tras el modelado del sistema de transmisión se aplicará una técnica de linealización conocida como predistorsión digital, la cual se calculará haciendo uso de diferentes técnicas, el modelo polinomial (MPM), el modelo CPWL y las redes neuronales. Tras la obtención de las señales linealizadas en simulación, se llevan al montaje experimental para comprobar los resultados obtenidos en las pruebas por ordenador.

Este trabajo se engloba dentro del grupo de comunicaciones móviles del grupo de investigación CeNIT de la Universidad de Zaragoza, donde gracias a ellos, se ha podido disponer tanto del software de generación de señales 5G, como del montaje del laboratorio que el grupo ya posee en el laboratorio I3A.

Esta memoria se ha estructurado en 6 apartados. En el primero de ellos se pone en contexto el problema que se va a tratar de resolver y como se ha hecho. En el segundo se explica todo lo relacionado con la generación de la señal 5G, que señales se van a utilizar en este trabajo y las figuras de mérito que se emplean para evaluar los resultados. En el apartado 3 se explica, tanto de forma teórica como experimental, cómo se modelan los dispositivos no lineales del enlace RoF, para en el apartado 4 explicar que sistemas de linealización se emplean para compensar las distorsiones causadas por el sistema RoF. En el apartado 5 se prueban esas señales tras haberles aplicado varios métodos de linealización y se verifican los resultados obtenidos experimentalmente. Por último, en el apartado 6 se exponen las conclusiones finales y las posibles líneas futuras del trabajo. En los anexos, se presenta el simulador que se ha empleado para generar las señales 5G, se exponen el resto de señales que se han generado y se han utilizado posteriormente para entrenar las redes neuronales, algunos resultados tras aplicar el predistorsionador que se obtuvieron en simulación y las hojas de características de los dispositivos del montaje experimental.

2. Generación de la señal 5G

2.1. Introducción

Como ya se ha explicado anteriormente la base de 5G es LTE [6], por lo que primero se va a explicar esta tecnología para luego particularizar en los parámetros de 5G. La tecnología LTE se fundamenta principalmente en OFDM [7], que es una técnica de acceso múltiple utilizada en el canal downlink de los sistemas LTE. OFDM presenta una alta flexibilidad, una gran robustez ante desvanecimientos en los canales, una alta eficiencia espectral y su ecualización es muy sencilla. Todo esto le permite ofrecer una alta calidad de servicio (QoS), haciendo que sea la técnica más utilizada en las transmisiones de datos a alta velocidad. OFDM se caracteriza por dividir en múltiples subportadoras ortogonales de banda estrecha el ancho de banda del espectro disponible, permitiendo transmitir una mayor cantidad de datos sin penalizar el ancho de banda necesario. En la figura 2.1 se puede observar una señal que emplea OFDM.





Figura 2.1: Distribución de múltiples subportadoras en una señal que usa OFDM

En los sistemas que emplean LTE, comúnmente conocidos como sistemas 4G, su ancho de banda disponible se encuentra dividido por N subportadoras ortogonales, separadas entre sí 15 kHz. Estas subportadoras se pueden activar o desactivar. En caso de estar activas se utilizan para transmitir datos, mientras que las que se encuentran desactivadas se utilizan para limitar las interferencias que se puedan producir por los canales adyacentes. Por lo general las subportadoras localizadas a ambos lados del canal se encuentran desactivadas, formando una banda de guarda. En las señales LTE, además de encontrarse activas las subportadoras para la transmisión de datos, también se encuentran activas las piloto. Estas subportadoras se utilizan para la transmisión de señales de referencia,

Diagrama de un canal de transmisión OFDM. Muestra una banda de frecuencia dividida en subportadoras. Las subportadoras de datos (verdes) están separadas por subportadoras piloto (azules). Hay una subportadora de DC (punto central). Las bandas de guardia (rojas) están a los extremos. El ancho de banda del canal es el total disponible.

Es importante conocer también cómo se distribuyen los recursos radio ubicados dentro del ancho de banda disponible. La unidad mínima de división es el Resource Element (RE). Este elemento se compone de una subportadora OFDM durante un símbolo al que se le añade un prefijo cíclico. Estos elementos se agrupan cada 12 subportadoras formando lo que se conoce como Physical Resource Block (PRB). Los PRBs son la mínima unidad de asignación para LTE y se agrupan por pares formando una subtrama representada en la figura 2.3. Los PRBs ocupan 180 KHz en frecuencia, (12 subportadoras * 15 KHz).



9

explicadas más adelante, tanto en banda como en la banda de guarda. Otra novedad que introduce 5G es la posibilidad de variar la separación entre subportadoras, permitiendo separaciones de $2^n \cdot 15 \text{ kHz}$, con $n = 0, 1, 2, 3$

Nombre	Rango de frecuencias
FR1	450 MHz – 6000 MHz
FR2	24250 MHz – 52600 MHz

Tabla 2.1: Rango de frecuencias en la tecnología 5G

2.2. Características de las señales generadas

Las señales generadas con tecnología LTE están formadas por una serie de parámetros variables. A razón de estudiar la influencia de estos parámetros en la linealización de un sistema de transmisión, se generan diversas señales a las que se les han variado estos parámetros para probar su efecto. A continuación se detallan los parámetros de las señales que se han generado para la realización de este estudio, el simulador empleado se puede visualizar en el anexo A.1.

Como se ha comentado anteriormente, en las señales LTE la unidad mínima que se puede variar son los PRBs. El número de PRBs que componen una señal LTE varía en función del ancho de banda de la misma. En la tabla 2.2 se recogen los PRBs disponibles para cada ancho de banda (BW) que se va a evaluar en este TFG. Estos PRBs pueden estar activados o desactivados, es decir, pueden transmitir o no datos. Además se puede variar la potencia de cada uno de ellos. Estos 3 parámetros, ancho de banda, número de PRBs activos y la potencia relativa de cada PRB, se van a variar para generar señales con diferentes características y de esta forma poder estudiar la influencia de cada uno de ellos.

Ancho de banda	Número de PRBs disponibles
3 MHz	15 PRBs
5 MHz	25 PRBs

Tabla 2.2: Número de PRBs disponibles para cada ancho de banda

Otros de los parámetros que se varía es el tipo de modulación que se utiliza para modular los datos que se van a transmitir. En nuestro caso se van a generar señales con todas las modulaciones permitidas para el canal PDSCH. Estas modulaciones son: QPSK, 16-QAM, 64-QAM, 256-QAM y 1024-QAM. En los casos en los que no se quiere estudiar el efecto de la modulación, se generarán las señales con modulación 64 QAM.

Como se ha comentado, una de las novedades que introduce la tecnología 5G, es que permite añadir señales creadas bajo el estándar NB-IoT [10] en banda o en la banda de guarda. NB-IoT es una tecnología de acceso definida por 3GPP. Utiliza también la modulación OFDM y en downlink ocupa 180 kHz, coincidiendo con el ancho de banda de los PRBs. En este TFG únicamente se va a trabajar con

señales a las que se les han agregado señales NB-IoT en banda. Para incorporarlas a una señal hay que tener unas consideraciones previas: No se pueden añadir en señales que tengan un ancho de banda menor a 3 MHz y no se pueden agregar en cualquier PRB, ya que esto depende del ancho de banda utilizado. En la tabla 2.3 se recogen los PRBs en los que se pueden añadir estas señales en función del BW.


Ancho de banda	PRBs donde se puede añadir NB-IoT
3 MHz	2, 12
5 MHz	2, 7, 17, 22

Tabla 2.3: PRBs en los que se puede añadir señal NB-IoT para cada BW


Tras la explicación de los parámetros variables de las señales LTE, se recogen en la tabla 2.4 los parámetros de las señales que se han generado para comprobar experimentalmente el funcionamiento de los distintos métodos de linealización. Además, en el anexo A.2 se encuentran el resto de señales que se han generado para utilizar posteriormente como señales de entrenamiento para las redes neuronales.

	<i>PRBs disponibles</i>	<i>PRBs activos</i>	<i>Variación Potencia Relativa</i>	<i>Modulación</i>	<i>Añade señal NB-IoT</i>
Señal 1	25	25	No	64 QAM	No
Señal 2	15	15	Sí(1,2,0,2,0,1,1,1, 0,2,0,2,0,2,0)	64 QAM	No
Señal 3	25	25	No	1024 QAM	No
Señal 4	25	21	No	64 QAM	Sí (2,7,17,22)
Señal 5	25	25	Sí(2,0,2,0,2,0,2,0, 2,0,2,0,2,0,2,0, 2,0,2,0,2,0,2)	64 QAM	No
Señal 6	25	0-3, 7-9, 12-16, 20-24	Sí(2,2,2,2,0,0,0,3, 3,3,0,0,1,1,1,1,0 0,0,0,2,2,2,2)	64 QAM	No


Tabla 2.4: Parámetros de las señales generadas para el estudio del sistema




a)




b)




c)



d)



e)



f)

Figura 2.4: PSD de las señales de la tabla 2.4: a) Señal 1, b) Señal 2, c) Señal 3, d) Señal 4, e) Señal 5, f) Señal 6

En la figura 2.4 se ha representado la densidad espectral de potencia de estas señales, para que de esta manera se vea como varían las señales en función de los parámetros que se cambian.

2.3. Figuras de mérito

Las figuras de mérito son las medidas con las que se van a evaluar los resultados. Nos vamos a centrar principalmente en la linealidad de la señal evaluando la distorsión dentro y fuera de banda. También se estudia la potencia de las señales, ya que se va a buscar un compromiso entre linealidad y la pérdida de potencia de la señal con respecto de la señal sin linealizar.

- **ACPR:**

El Adjacent Channel Power Ratio (ACPR) mide la distorsión del canal adyacente, que es el canal contiguo a la banda de la señal transmitida [11]. Esta distorsión es ocasionada por la potencia de las componentes del recrecimiento espectral que producen las distorsiones no lineales y que están situadas en los canales adyacentes a la banda de la señal transmitida. Relaciona la potencia total introducida por el canal adyacente con respecto a la medida de potencia en la señal transmitida. La expresión del ACPR es:

$$ACPR(dBc) = 10 * \log_{10} \frac{\int_{channel} |Y(f)|^2 df}{\int_{adyp} |Y(f)|^2 df}, \quad p = 1, 2, 3, 4 \quad (2.1)$$

donde $Y(f)$ es la transformada de Fourier de la señal de salida y p representa cada uno de los canales adyacentes. En nuestro caso solo se medirá el primer canal adyacente.

- **EVM:**

El Error Vector Magnitude (EVM) nos da la diferencia entre el símbolo demodulado y el símbolo ideal, debido a las no linealidades del transmisor y del canal [12], y se define como:

$$EVM(n) [\%] = 10 * \log_{10} \left(\frac{\sqrt{I_{err}^2(n) + Q_{err}^2(n)}}{Average Symbol Power} \right) * 100 \% \quad (2.2)$$

donde N es el número total de símbolos, n es el índice e $I_{err} + jQ_{err}$ es el error que se produce con respecto al ideal. El EVM nos da una idea de la distorsión que se produce en la banda de la señal transmitida.

- **Error NMSE:**

El error cuadrático medio normalizado (NMSE) es la normalización del error cuadrático medio entre 2 señales, en nuestro caso se utiliza principalmente para el modelado en el que se comparan la señal medida y la modelada, nos da una medida de lo distintas que son 2 señales [11].

$$NMSE [dB] = 10 * \log_{10} \left(\frac{\sum_{k=1}^N |y_{med}(k) - y_{modelado}(k)|^2}{\sum_{k=1}^N |y_{med}(k)|^2} \right) \quad (2.3)$$

3. Modelado del transmisor RoF

3.1. Montaje del transmisor RoF

Como se ha comentado en la introducción, se va a emplear la arquitectura conocida como radio sobre fibra, donde la señal en RF se transmite a través de una fibra, en nuestro caso de 10 km, para llegar al emisor donde se encuentra la etapa de potencia. En la figura 3.1 se presenta por medio de un diagrama de bloques, el montaje de esta arquitectura radio sobre fibra que se va a emplear para el desarrollo de este trabajo.

El transmisor radio se encuentra compuesto por una placa y un ordenador. La placa permite conectar el sistema RoF con un ordenador que dispone de la aplicación Matlab instalada, de manera que nos permite transmitir y recibir las señales generadas. Se utiliza un amplificador de bajo ruido (LNA) para ajustar, a los niveles del láser, la potencia de la señal enviada. Para tomar una muestra de la señal que se transmite al sistema RoF y así saber su potencia de entrada, se utiliza un splitter, que nos permite enviar una muestra de la señal al osciloscopio y al láser. A la salida del láser la señal ya es óptica por lo que se envía a una fibra óptica de 10 km. Tras pasar la señal por la fibra, es necesario volverla al ámbito eléctrico, para lo que se utiliza un fotodiodo (PD). A su salida se coloca de nuevo un LNA, utilizado como driver para el amplificador de potencia, que amplifica aún más la señal. Para medir en el osciloscopio y que no se dañen ni el aparato de medida ni la placa, se utiliza un atenuador de 30 dB. Mediante un splitter, la señal de salida se mide en el osciloscopio y se vuelve a enviar a la placa.




Figura 3.1: Diagrama de bloques del montaje del laboratorio

Tras ver de forma esquemática los dispositivos que componen el sistema RoF se va a explicar cómo son estos dispositivos en la realidad. El montaje del laboratorio, el de la figura 3.2, simula lo que sería un sistema real. Este montaje se encuentra en el laboratorio de comunicaciones del edificio I3A (Instituto de Investigación en Ingeniería de Aragón) de la Universidad de Zaragoza.




Figura 3.2: Sistema RoF del laboratorio




Figura 3.3: Tarjeta SDR y láser utilizados en el sistema RoF del laboratorio

El transmisor radio se compone de una placa (ZedBoard con el SoC completamente programable Zynq 7020) conectada a una tarjeta SDR (Software Define Radio) modelo AD9361, y está a un ordenador con matlab instalado. En este sistema se va a trabajar con una frecuencia de portadora de 2.1 GHz, en la banda 1 del estándar LTE. El módulo del láser se encuentra formado por un láser de retroalimentación distribuida (DFB) con un modulador por electro absorción (EAM) que emite en tercera ventana, 1550 nm. La fibra óptica es monomodo (SMF) con una longitud de 10 km, una dispersión de 18 ps/(nm/km) y una atenuación de 0.25 dB/km. El fotodetector es un modelo Nortel Networks PP-10G y tiene una responsividad de 0.9 A/W. Los amplificadores de bajo ruido que se utilizan son modelo Mini Circuits ZX60-P33ULN+ y el amplificador de potencia es modelo Mini Circuits ZHL-4240. Las hojas de características de los dispositivos utilizados se pueden consultar en el anexo C. En la figura 3.3 se pueden ver algunos de los elementos más importantes de este sistema como son la placa y el láser.

3.2. Caracterización de sistemas no lineales

Tal y como se ha mostrado en el apartado anterior, en el sistema RoF existen varios dispositivos no lineales. Para contrarrestar las distorsiones no lineales que producen estos dispositivos primero los vamos a modelar para posteriormente tratar de reducir estas al máximo. Para modelar un sistema no lineal tenemos que caracterizarlo previamente.

Para evaluar los modelos se va a utilizar el error NMSE, de las figuras de mérito ya explicadas.

3.2.1. Curvas AM/AM, AM/PM

Las curvas que se van a emplear para caracterizar los elementos no lineales se conocen como curvas de distorsión AM/AM y AM/PM. Debido a su simplicidad son una de las formas más usadas. Utilizando modelos sin memoria se logra separar la distorsión en dos componentes: la distorsión de la amplitud de entrada frente a la amplitud de salida (AM/AM) y la distorsión de amplitud respecto de la fase (AM/PM).

La distorsión AM/AM representa la compresión o la expansión de la envolvente de la señal como una función de la amplitud de la señal de entrada. En cambio, la distorsión AM/PM representa el cambio de fase de la señal como una función de la envolvente de la señal de entrada. En la figura 3.4 se puede ver un ejemplo de estas curvas, que además se corresponde con el resultado de modelar el transmisor RoF con uno de los modelos.




Figura 3.4: Curvas AM/AM de la señal medida frente a la modelada

3.3. Modelado de sistemas no lineales

Para modelar la señal de salida de un sistema no es necesario conocer las características del transmisor RoF, basta con tener unos parámetros de entrada y de salida, que nos permita conocer cómo se comporta. Debido a la dependencia de la muestra de salida actual con las muestras de salida anteriores del sistema RoF, aparece lo que se conoce como efectos de memoria, que también habrá que modelar. Para el modelado existen diferentes modelos que permiten obtener buenos resultados, aunque en este TFG se va a utilizar únicamente el polinomial y el CPWL, explicados a continuación.

3.3.1. Modelo Polinomial

El modelo polinomial es uno de los modelos más utilizados debido a su sencillez. Este modelo permite tener en cuenta la memoria de los dispositivos y está basado en una versión simplificada de las series de Volterra [13]. Estas series consisten en la suma de convoluciones multidimensionales, que se pueden escribir como

$$y(n) = \sum_{k=1}^K y_k(n), \quad (3.1)$$

donde

$$y_k(n) = \sum_{m_1=0}^{M-1} \cdots \sum_{m_k=0}^{M-1} h_k(m_1, \dots, m_k) \prod_{l=1}^k x(n - m_l), \quad (3.2)$$

es la convolución k-dimensional de la entrada con el kernel de Volterra, h_k . Esta es la generalización de la representación de las series de potencia con memoria finita.

El modelo polinomial surge de combinar, en un array de dos dimensiones $\{a_{km}\}$, los diferentes filtros y los coeficientes de las series de potencia, obteniendo una expresión como

$$y_{GH}(n) = \sum_{k=1}^N \sum_{m=0}^{M-1} a_{km} x^k(n - m), \quad (3.3)$$

donde M es la memoria del modelo y N es el orden del polinomio. Si se seleccionan combinaciones de la forma $x(n)|x(n - m)|^{k-1}$, llegamos al modelo que se conoce como modelo polinomial con memoria.

$$y_{MP}(n) = \sum_{k=0}^{N-1} \sum_{m=0}^{M-1} a_{km} x(n - m) |x(n - m)|^k, \quad (3.4)$$

El modelo polinomial sin memoria es un caso específico de este modelo, en el que $m=0$, quedando la expresión matemática:

$$y_{MP}(n) = \sum_{k=1}^N a_k * x(n) * |x(n)|^k, \quad (3.5)$$

3.3.2. Modelo CPWL

Uno de los principales inconvenientes que presentan los modelos basados en las series de Volterra es que, como las no linealidades que presentan los sistemas RoF pueden ser muy diversas, necesitan muchas combinaciones de órdenes y memoria. Por este motivo se propone trabajar con un modelo basado en las funciones canónicas lineales por partes (CPWL) [14]. Por lo general, este modelo ofrece mejores prestaciones que los basados en las series de Volterra.

Estas funciones tienen una estructura muy simple y se pueden utilizar para representar muchas funciones de diferente tipo con una alta precisión. La función no lineal se obtiene como la suma de varias funciones definidas en diferentes planos usando el valor absoluto. Utilizando esta técnica para modelar un sistema no lineal con memoria finita, la función se puede expresar como

$$y(n) = \sum_{i=0}^M a_i x(n-i) + b + \sum_{k=1}^K c_k \left| \sum_{i=0}^M a_{ki} x(n-i) - \beta_k \right|, \quad (3.6)$$

donde $x(n)$ es la señal de entrada e $y(n)$ es la señal de salida, K es el número de particiones y β_k es el umbral que define el límite de cada partición. M es el valor de la memoria y a_i , b , c_k y a_{ki} son los coeficientes.

En la ecuación anterior, b es el valor del offset de la señal, por lo que se puede eliminar. Además debido a la dificultad para encontrar los valores adecuados para a_{ki} y β_k , por su no linealidad con respecto a la salida, se demostró en [14, p. 114], que $x(n-i) = \beta_k$ para $i=0,1,\dots,M$, es decir, la operación del valor absoluto se aplica a cada umbral dado, y por tanto

$$y(n) = \sum_{i=0}^M a_i x(n-i) + \sum_{k=1}^K \sum_{i=0}^M c_{ki} |x(n-i) - \beta_k|. \quad (3.7)$$

Ahora se ha perdido algo de precisión ya que no se tienen en cuenta las interacciones entre las muestras actuales y las anteriores, pero sin embargo, todos los coeficientes son lineales con la salida si se escoge un umbral adecuado. Además esto hace que el modelo sea mucho más simple y se puedan utilizar algoritmos de identificación como el de mínimos cuadrados.

Debido a que las señales son complejas y se trabaja con valores absolutos, hay que realizar algunos cambios para no perder la fase de la señal. Tras la aplicación de estos cambios la ecuación resulta

$$\tilde{y}(n) = \sum_{i=0}^M \tilde{a}_i \tilde{x}(n-i) + \sum_{k=1}^K \sum_{i=0}^M \widetilde{c_{ki}} |\tilde{x}(n-i) - \beta_k| e^{j\theta(n-i)}. \quad (3.8)$$

Tras adaptar el modelo para poder utilizarlo en el modelado del sistema RoF, se añaden más términos para mejorar la precisión del modelado, quedando la ecuación del siguiente modo

$$\begin{aligned}
y(n) = & \sum_{m=0}^M a_m \tilde{x}(n-m) \\
& + \sum_{k=1}^K \sum_{m=0}^M a_{km,1} ||\tilde{x}(n-m)| - \beta_k| e^{j\theta(n-m)} \\
& + \sum_{k=1}^K \sum_{m=0}^M a_{km,21} ||\tilde{x}(n-m)| - \beta_k| e^{j\theta(n-m)} \cdot \tilde{x}(n) \\
& + \sum_{k=1}^K \sum_{m=0}^M a_{km,22} ||\tilde{x}(n-m)| - \beta_k| \cdot \tilde{x}(n) \\
& + \sum_{k=1}^K \sum_{m=0}^M a_{km,23} ||\tilde{x}(n-m)| - \beta_k| \cdot \tilde{x}(n-m) \\
& + \sum_{k=1}^K \sum_{m=0}^M a_{km,24} ||\tilde{x}(n)| - \beta_k| \cdot \tilde{x}(n-m) \\
& + \dots,
\end{aligned} \tag{3.9}$$

3.4. Modelado de nuestro transmisor RoF

Una vez se han introducido y explicado los modelos que se van a utilizar para el modelado de los sistemas no lineales, se va a explicar en este apartado, su implementación en Matlab y los resultados que se obtienen cuando se aplican a las señales que se han generado en este trabajo.

Como se verá a continuación se van a probar ambos modelos con y sin memoria y de esta manera se podrá ver cómo afecta este factor al modelo resultante. Además para comparar los diferentes resultados obtenidos tanto con el modelo polinomial como con el CPWL, se va a utilizar el error NMSE, que es el valor que nos dice que tan parecido es el modelo con respecto a la medida realizada.

3.4.1. Modelado con modelo Polinomial

Para su implementación en Matlab [13], se parte de la ecuación (3.4). Debido a que trabajar con ecuaciones no resulta del todo práctico, se va a trabajar con matrices. De esta manera la ec. (3.4) se puede expresar de forma matricial como

$$y = Xa, \tag{3.10}$$

Donde a representa el vector de coeficientes, X es la señal de entrada del sistema no lineal e y es el vector de salida. Ahora X es de la forma

$$X = [X_1 \dots X_K \dots X_N], \tag{3.11}$$

donde

$$X_k = \begin{bmatrix} x_{k,1}(n) & \cdots & x_{k,M}(n) \\ x_{k,1}(n) & \cdots & x_{k,M}(n+1) \\ \vdots & \ddots & \vdots \\ x_{k,1}(n) & \cdots & x_{k,M}(n+L-1) \end{bmatrix}, \quad (3.12)$$

y

$$x_{k,m}(n) = x(n-m)|x(n-m)|^{k-1}, \quad (3.13)$$

con L la longitud de la entrada.

Como en el modelo polinomial la dependencia de los coeficientes con la señal de entrada es lineal, se puede aplicar la minimización de mínimos cuadrados. Mediante la pseudoinversa, se pueden obtener los coeficientes según

$$\hat{a} = (X^H X)^{-1} X^H y, \quad (3.14)$$

donde $(X^H X)^{-1} X^H$ representa la pseudoinversa de la señal de entrada de forma matricial y $\hat{a}$ el vector de coeficientes. De esta manera la salida del sistema se podrá calcular como

$$\hat{y} = X \cdot \hat{a} \quad (3.15)$$

Una vez se tiene implementado el modelo en Matlab, se procede a calcular la combinación entre orden y memoria del polinomio que nos permita obtener un modelo lo más parecido posible a lo medido. En la figura 3.5 han representado todas las posibles combinaciones con sus respectivos valores del error NMSE.

En la figura 3.5, se puede observar cómo influye la memoria a la hora de aproximar el modelo a la realidad. A medida que se aumenta la memoria del modelo los resultados mejoran considerablemente, excepto con memoria 3 cuya mejora no hace que merezca la pena asumir el aumento del coste computacional que supone. Por esta razón se descarta hacer más pruebas con el modelo polinomial con memoria 3.

En cuanto al orden del polinomio, es un valor que no produce tantos cambios como la memoria. Se puede apreciar una mejoría entre utilizar orden 3 u orden 5, sin aumentar en exceso el coste computacional. En cambio la mejora que se produce entre el polinomio de orden 5 y los de órdenes superiores, no compensa el aumento del coste computacional que se produce.




Figura 3.5: Representación del error NMSE en función del orden y la memoria

Tras analizar los resultados obtenidos con las diferentes memorias y órdenes del polinomio, se decide modelar el sistema RoF con un polinomio de orden 5 y memoria 2. El resultado que se obtiene tras el modelo es el que se puede ver en la figura 3.4, y como se puede observar se modela muy bien, excepto en las muestras más grandes que se produce algún error más.

3.4.2. Modelado con modelo CPWL

Para implementar este modelo en Matlab, se parte de la ec. (3.9). Teniendo en cuenta las prestaciones del modelo y la complejidad de su implementación, se va a trabajar en Matlab con una versión truncada [14], en la que se consideran únicamente los 4 primeros términos

$$\begin{aligned}
 y(n)_{MC} = & \sum_{m=0}^M a_m^{MC} \tilde{x}(n-m) \\
 & + \sum_{k=1}^K \sum_{m=0}^M a_{km,1}^{MC} ||\tilde{x}(n-m)| - \beta_k| e^{j\theta(n-m)} \\
 & + \sum_{k=1}^K \sum_{m=0}^M a_{km,21}^{MC} ||\tilde{x}(n-m)| - \beta_k| e^{j\theta(n-m)} \cdot \tilde{x}(n) \\
 & + \sum_{k=1}^K \sum_{m=0}^M a_{km,22}^{MC} ||\tilde{x}(n-m)| - \beta_k| \cdot \tilde{x}(n).
 \end{aligned} \tag{3.16}$$

Esta es la ecuación que se va a implementar en Matlab. Si nos fijamos en la ecuación 3.16 se puede comprobar que hay 3 parámetros que se pueden variar para el modelado del transmisor RoF. Estos 3 parámetros son el número de

particiones, K , la memoria del modelo, M , y el umbral que define cada partición, β_k . En la figura 3.6 se ha representado, al igual que en el caso del modelo polinomial, el error NMSE, pero ahora se ha variado la memoria del modelo y el número de particiones. Los umbrales se han definido igual para todos los casos y se han considerado los umbrales más básicos, los calculados con una distribución uniforme.




Figura 3.6: Representación del error NMSE en función de la configuración del modelo CPWL

En la figura 3.6 se puede observar cómo, al igual que en el caso del modelo polinomial, la memoria es un factor bastante determinante, ya que supone una mejora considerable el usar memoria 2 respecto de sin memoria. Al igual que ha ocurrido con el modelo MPM, la mejora que supone utilizar memoria 3 no hace que merezca la pena asumir el aumento del coste computacional que supone trabajar con esa memoria.

En cuanto al número de particiones, el NMSE sí que mejora si se aumenta, pero esta mejora no es muy notable. Para modelar el transmisor, se va utilizar el modelo CPWL con memoria 2 y 5 particiones.

Si se comparan los resultados, en término del error NMSE, entre ambos modelos, se puede ver como con el modelo CPWL hay una leve mejora con respecto al modelo polinomial, como se ve en la tabla 3.1. A pesar de que el nivel de complejidad aumenta, merece la pena utilizar el modelo CPWL ya que los resultados son mejores.

NMSE (dB)				
M	N	K	MPM	CPWL
0	3	2	-19,68	-21,15
0	5	4	-19,697	-21,207
0	7	5	-19,698	-21,21
0	9	6	-19,698	-21,211
1	3	2	-31,123	-31,62
1	5	4	-31,4	-32,37
1	7	5	-31,422	-32,42
1	9	6	-31,423	-32,44
2	3	2	-35,47	-34,8
2	5	4	-36,28	-36,48
2	7	5	-36,36	-36,61
2	9	6	-36,364	-36,67
3	3	2	-36,3	-35,36
3	5	4	-37,34	-37,26
3	7	5	-37,45	-37,43
3	9	6	-37,45	-37,51

Tabla 3.1: Valores del error NMSE obtenidos tras modelar los dispositivos no lineales del transmisor RoF aplicando los modelos MPM y CPWL

También se puede ver el espectro de la señal de salida modelada con respecto de la medida, y de esta manera ver gráficamente cuanto se parecen. Esto se muestra en la figura 3.7 y se corresponde con el espectro de las señales de salida, tanto medida como modelada, de la señal 1 de la tabla 2.4, con el modelo polinomial y los parámetros $M=2$ y $N=5$.




Figura 3.7: PSD de la señal 1 de la tabla 2.4, tras pasar por el sistema RoF, modelada frente a la medida

4. Predistorsión

4.1. Introducción

La predistorsión es el sistema de linealización que se ha decidido emplear para compensar la distorsión introducida por el transmisor RoF. Una de las características de la predistorsión es que se puede aplicar tanto sobre una señal analógica como sobre una digital.

Cuando se aplica predistorsión sobre una señal analógica se emplea una técnica conocida como predistorsión analógica. Esta técnica consiste en añadir elementos que producen nuevas no linealidades con la misma amplitud pero con la fase contraria a los propios efectos no lineales producidos por el sistema RoF.

En cambio, si se aplica predistorsión sobre una señal digital, la técnica se conoce como linealización digital. Esta técnica consiste en enlazar el bloque encargado de compensar las no linealidades, introducidas principalmente por el amplificador de potencia, con el propio PA. Esto se logra aplicando la función inversa del comportamiento del PA a la señal de entrada. En la figura 4.1 se muestra el esquema básico del funcionamiento de la predistorsión digital.




Figura 4.1: Esquema del funcionamiento del predistorsionador digital

Para calcular el predistorsionador digital (DPD) se utiliza una técnica sencilla conocida como arquitectura de aprendizaje indirecto, ILA (Indirect Learning Architecture) [15], que permite utilizar el método de mínimos cuadrados para el cálculo de los coeficientes del DPD. Esta estructura se encuentra representada en la figura 4.2 [16]. Como se puede observar en la figura, el uso del DPD supone una ventaja frente a otro tipo de sistemas, ya que para su implementación, no es necesario conocer la electrónica de los dispositivos no lineales, sino que solo es necesario obtener las muestras de la señal de entrada y de salida, $x(n)$ e $y(n)$ en el sistema. $v(n)$, es la señal de salida dividida por una ganancia lineal, siendo esta la entrada del post-distorsionador que es donde se calculan los coeficientes. Estos coeficientes son los que utiliza el pre-distorsionador para generar una señal, $u(n)$,

que compense las no linealidades del transmisor RoF. La forma de calcular los coeficientes del DPD condicionará el comportamiento del pre-distorsionador. Este comportamiento se evaluará utilizando las figuras de mérito ya explicadas en el apartado 2.




Figura 4.2: Estructura indirecta ILA para el cálculo del DPD

Si nos fijamos en la figura 4.2 aparece un término que no había aparecido hasta ahora que es la ganancia de normalización, G_{norm} . Es un factor de escalado que se utiliza para normalizar la señal de salida de manera que tenga la misma potencia que la señal de entrada al DPD. Se calcula multiplicando la ganancia máxima del amplificador por un factor de normalización. En [17] se realizó un estudio sobre la influencia de este factor en la eficiencia del PA y en la linealización del transmisor RoF. Determinaron que en el PA no influye, es decir, es independiente, mientras que en el DPD es un factor determinante. Concluyeron que ajustando este factor se podían conseguir mejoras considerables en términos de ACPR. En la figura 4.3 se representan los extremos del valor de la ganancia entre los que se puede ajustar la ganancia de normalización y su punto de saturación. Este ajuste se realiza utilizando un factor, α_{norm} , con el que se busca que la señal esté el menor tiempo posible en saturación pero sin perder mucha potencia con respecto de la señal sin DPD, por lo que éste va a ser un factor importante a la hora de determinar el DPD del transmisor.




Figura 4.3: Curvas $P_{salida}/P_{entrada}$ con la ganancia de normalización variable

Una vez se ha explicado en que consiste el DPD se procede a explicar los métodos con los que se va a probar, que van a ser varios. Por una parte se va a calcular utilizando el modelo polinomial y el CPWL, y por otra parte se van a usar redes neuronales.

4.2. DPD con modelo Polinomial


En este apartado se va a estudiar el comportamiento del predistorsionador utilizando un modelo polinomial. La teoría y la implementación de este modelo ya se han explicado en el apartado 3.

Como ya se vio en el modelado del transmisor RoF, el modelo polinomial puede ser con memoria o sin memoria. Esto implica que habrá que realizar estudios de cómo influye la memoria en la salida además del orden del polinomio aunque, al igual que ocurrió en el modelado del sistema RoF, se ha comprobado cómo el modelo polinomial sin memoria ofrece peores resultados, por lo que se descarta como posible solución. Como se ha explicado antes, la ganancia de normalización influye en el rendimiento del DPD, luego el factor α_{norm} se variará también.

Para determinar que memoria, orden y factor de normalización hacen que el DPD se comporte de la mejor manera posible, se van a representar, en la figura 4.4, los espectros de las señales de salida 1 y 5, de la tabla 2.4, sin DPD con respecto de las linealizadas, a las que se les varía en a) y b) la memoria; en c) y d) el orden; y en e) y f) el factor α_{norm} . Este estudio se ha realizado dejando fijo dos de los parámetros, por ejemplo orden y memoria, y variando el otro parámetro, el factor de normalización en este caso.


La manera de determinar qué configuración era la más acertada ha sido utilizando la figura de mérito del ACPR. En cuanto a la potencia, el único parámetro que de verdad influía en este valor era el α_{norm} , y la manera de escoger este factor era quedarse con el que más se acercará a una pérdida de potencia no superior a 2 dB, sin afectar mucho al compromiso entre potencia y ACPR.

PSD de la señal de salida con DPD calculado con diferentes memorias



a)

PSD de la señal de salida con DPD calculado con diferentes memorias



b)




Figura 4.4: PSD de la señal de salida con y sin DPD estudiando la mejor configuración posible: a) Señal 5 con $N=5$ y $\alpha_{norm} = 0,77$ con $M=1, 2$; b) Señal 1 con $N=5$ y $\alpha_{norm} = 0,77$ con $M=1, 2$; c) Señal 5 con $M=2$ y $\alpha_{norm} = 0,77$ con $N=5, 7$; d) Señal 1 con $M=1$ y $\alpha_{norm} = 0,77$ con $N=5, 7$; e) Señal 5 con $M=2$ y $N=7$ con $\alpha_{norm} = 0,74, 0,76, 0,78$; f) Señal 1 con $M=1$ y $N=7$ con $\alpha_{norm} = 0,74, 0,76, 0,78$;

Con ayuda de la figura 4.4 y de la tabla 4.1, en la que se recogen los valores de la mejora en ACPR que supone el uso de cada DPD, se puede determinar que configuración es la que mejor resultado ofrece para cada señal.

Para la señal 5 se obtiene que el mejor resultado se da cuando se utiliza memoria 2, orden 7 y $\alpha_{norm}=0,78$. En cambio para la señal 1, el mejor resultado se obtiene cuando se utiliza memoria 1, orden 7 y $\alpha_{norm}=0,78$, lo que nos permite decir que el modelo polinomial no se puede generalizar. Lo que conlleva a que para cada señal se tenga que calcular la configuración que mejores prestaciones ofrezca, lo que lo hace poco eficiente. Esto se ha podido observar en el resto de señales en las que se ha calculado el DPD, ya que a pesar de que la configuración memoria 1 y orden 7 ha sido la que más veces se ha repetido, se puede comprobar como por ejemplo en el caso de la señal 5, si se utilizan esos

valores los resultados empeorarían. También se ha podido ver como α_{norm} no influye en exceso en los resultados en términos de ACPR, por lo que siempre se trabajará con el factor que de una pérdida de potencia inferior a 2 dB. En el anexo B se pueden ver algunos resultados más para las otras señales.

Estudio de la mejor configuración de los parámetros de la señal 5		
<i>Parámetros fijos</i>	<i>Variación introducida</i>	<i>Mejora ACPR (dB)</i>
$N=5$ y $\alpha_{norm} = 0,77$	$M=1$	9,34
	$M=2$	9,91
$M=2$ y $\alpha_{norm} = 0,77$	$N=5$	7,83
	$N=7$	10,1
$M=2$ y $N=7$	$\alpha_{norm} = 0,74$	9,96
	$\alpha_{norm} = 0,76$	9,77
	$\alpha_{norm} = 0,78$	9,6

a)

Estudio de la mejor configuración de los parámetros de la señal 1		
<i>Parámetros fijos</i>	<i>Variación introducida</i>	<i>Mejora ACPR (dB)</i>
$N=5$ y $\alpha_{norm} = 0,77$	$M=1$	8,92
	$M=2$	7,06
$M=1$ y $\alpha_{norm} = 0,77$	$N=5$	8,5
	$N=7$	9,84
$M=1$ y $N=7$	$\alpha_{norm} = 0,74$	9,73
	$\alpha_{norm} = 0,76$	9,66
	$\alpha_{norm} = 0,78$	9,61

b)

Tabla 4.1: Valores de la mejora en ACPR utilizando diferentes configuraciones para las señales linealizadas con el modelo MPM de la tabla 2.4: a) Señal 5; b) Señal 1

4.3. DPD con modelo CPWL

En este apartado se va a estudiar el comportamiento del predistorsionador cuando los coeficientes se calculan utilizando el modelo CPWL. Al igual que con el modelo polinomial, su teoría y su implementación ya se han explicado en el apartado del modelado del transmisor RoF.

Como ya se explicó, este modelo puede ser con memoria o sin memoria, luego éste va a ser un parámetro a determinar. Ocurre lo mismo con el número de particiones ya que es un valor que influye en el resultado, luego también se tendrá que definir. A diferencia de lo que se hizo en el modelado del transmisor RoF donde se calcularon los coeficientes únicamente con una distribución uniforme, ahora se van a calcular los umbrales de las dos maneras descritas a continuación:

- Umbrales uniformes:

Tal y como se explicó, estos umbrales se calculan utilizando una distribución uniforme. Esto hace que no requieran prácticamente operaciones para su cálculo, utilizando un coste computacional muy reducido. Presentan la desventaja de no ajustar los umbrales a la zona de la que se requiere más información, la no lineal.

- Umbrales genéticos:

Los umbrales genéticos se calculan como solución para mejorar los resultados obtenidos con los umbrales uniformes. Estos umbrales se calculan con algoritmos genéticos (GA) con el objetivo de calcular la localización óptima de estos. GA es un algoritmo muy poderoso basado en los principios de la selección natural. Este algoritmo mantiene la población de individuos y la va modificando probabilísticamente mediante algunos operadores genéticos como la selección, la mutación o crossover, con el objetivo de encontrar la solución óptima. Tras realizar varias iteraciones el algoritmo converge a la mejor solución encontrada. [16]

Para utilizar el GA hay que definir primero unos límites que determinen los límites de los segmentos en los que se fijaran los umbrales iniciales. Con los límites fijados, se definen los umbrales para la población. Cada individuo de la población es evaluado con una función de ajuste, en este caso se ha utilizado el error NMSE como función de ajuste.

4.3.1. Aplicación del modelo CPWL

Tras explicar cómo se calcula el DPD utilizando el modelo CPWL, se va a probar en las señales que se han generado. Como se ha visto en los apartados anteriores, este modelo se puede aplicar con los umbrales calculados de distinta forma, por lo que se probarán ambos tipos de umbrales y se podrá comprobar si efectivamente con los umbrales genéticos se obtienen mejores resultados que con los umbrales uniformes.

Antes de calcular los valores de los umbrales que se van a utilizar se necesita conocer la memoria y el número de particiones que se van a emplear para calcular los coeficientes del DPD. Para elegir los valores más óptimos de M y K se va a utilizar la mejora en ACPR como medida de evaluación. Los resultados obtenidos se recogen en la tabla 4.2. Como la memoria y el número de particiones no son los únicos valores que influyen en el comportamiento del modelo, el resto de parámetros, α_{norm} y el factor del DPD, que se explicará a continuación, se dejan fijos.

Elección de la memoria y número de particiones del modelo CPWL, en función de la mejora en ACPR (dB)					
		<i>K</i> =2	<i>K</i> =4	<i>K</i> =5	<i>K</i> =6
Señal 1	<i>M</i> =1	8,56	9,66	9,85	9,7
	<i>M</i> =2	8,02	9,15	9,24	9,4
Señal 5	<i>M</i> =1	7,82	9,62	9,7	9,61
	<i>M</i> =2	7,26	8,22	8,06	8,04

Tabla 4.2: Mejora en ACPR en función de la memoria y particiones del modelo CPWL para el cálculo del DPD

Como se puede comprobar en la tabla 4.2 y se verificó con el resto de señales que se generaron, en el caso de utilizar el modelo CPWL para calcular los coeficientes del DPD, sí que se puede generalizar el número de particiones y la memoria del modelo para todos los casos. Esto implica que independientemente de la forma en que se calculen los umbrales, cuando se utiliza el modelo CPWL como método de linealización, se usará memoria 1 y 5 particiones.

Al igual que ocurría con el modelo polinomial el factor α_{norm} sí que varía en función de las características de la señal que se quiera linealizar. Aunque este valor varía entre 0,77 y 0,78 y la diferencia que supone en el resultado es mínima, si se quisiera obtener el mayor rendimiento posible a este modelo no se puede generalizar este valor.

Como ya se ha explicado, cuando se calculan los umbrales utilizando un algoritmo genético se busca que estos se localicen en la zona menos lineal de la señal. En el caso de utilizar los umbrales uniformes se intenta hacer algo parecido. Para ello se utiliza un factor, al que hemos llamado factor DPD, que nos permite variar la localización de los umbrales, manteniendo la distribución uniforme, de manera que se ajusten lo máximo posible a la zona menos lineal de la señal. Esto hace que tanto para los umbrales genéticos como para los uniformes, tengamos que calcular los umbrales específicos para cada señal.

En la figura 4.5 se representa la localización de los diferentes umbrales, los uniformes y los genéticos, frente a la curva AM/AM de la señal de salida medida con respecto de la señal de entrada medida. En ella se puede observar como los umbrales genéticos se encuentran localizados en la zona menos lineal, mientras que los uniformes se encuentran localizados principalmente en la zona lineal de la señal.

Al igual que con el modelo polinomial, las prestaciones del modelo se medirán en función de la mejora en ACPR, teniendo en cuenta el compromiso entre ACPR y potencia. Las señales que se van a emplear para comprobar el comportamiento del modelo CPWL son la señal 1 y la señal 5 de la tabla 2.4, cuyos resultados se encuentran representados en la figura 4.6 y reflejados en la tabla 4.3.




Figura 4.5: Curva AM/AM de la señal medida con los umbrales uniformes y genéticos representados sobre ella




Figura 4.6: PSD de las señales de salida con y sin DPD utilizando el modelo CPWL y variando entre umbrales uniformes y genéticos. a) Señal 1; b) Señal 5

Mejora de ACPR (dB) en función de los umbrales utilizados		
	<i>Umbrales uniformes</i>	<i>Umbrales Genéticos</i>
<i>Señal 1</i>	9,53	9,98
<i>Señal 5</i>	9,41	10,04

Tabla 4.3: Valores de la mejora en ACPR utilizando diferentes umbrales para las señales linealizadas 1 y 5 de la tabla 2.4

Con los resultados recogidos en la tabla 4.3, se verifica que con los umbrales genéticos se obtienen mejores resultados. Aun así, a pesar de su sencillez y del coste computacional tan reducido que requieren, se observa como los resultados que se obtienen con los umbrales uniformes son realmente buenos, convirtiéndolos en una solución más que viable para linealizar una señal.

A pesar de que la mejora con respecto de los uniformes no es mucha, merece la pena utilizar los umbrales genéticos independientemente del coste computacional que suponen. Es por ello, que para hacer el modelo CPWL con los umbrales genéticos más eficiente, se propone a continuación otro método para calcular estos umbrales. Este método consiste en utilizar redes neuronales.

4.4. DPD utilizando redes neuronales

Las redes neuronales (NN) son modelos simplificados que emulan el modo en que el cerebro procesa la información [18]. Las unidades básicas que conforman la red son las neuronas, que generalmente se organizan en capas, como se muestra en la figura 4.7. Normalmente son 3 las partes que conforman una red neuronal: Una capa de entrada, con sus respectivos datos de entrada; una o varias capas ocultas; y una capa de salida que representa los datos de salida. Los valores de la capa de entrada se propagan desde cada neurona de esa capa hasta cada neurona de la capa siguiente. Estas neuronas realizan una serie de cálculos con esos datos de entrada que después transmiten como entrada a otras neuronas. A pesar de que una neurona sea un elemento muy simple, al combinarse miles o millones de éstas, se logra dar solución a problemas muy complejos.

La estructura de una neurona está dividida en una serie de funciones que son necesarias para obtener las variables de salida deseadas. Estas funciones son: La función de entrada es la encargada de buscar relaciones entre las variables de entrada que han sido previamente multiplicadas por unos pesos. La siguiente es la función de activación cuyo objetivo es determinar el estado de la neurona, si esta excitada o no lo está. Existen distintas funciones de activación pero en los casos en los que hay más de una capa oculta se utiliza la función de activación ReLU. Con esta función los valores de la salida se encuentran comprendidos entre 0 y ∞ . La última función es la de salida que determina el valor a la salida de la neurona.

Otros de los parámetros que hay que definir para generar la arquitectura de la red neuronal son las capas ocultas y el número de neuronas que comprenden cada una de estas capas. Estos parámetros se conocen como hiperparámetros. Estos son muy importantes ya que determinan el rendimiento de la red. En la figura 4.9, se muestra un ejemplo de una red con todos los parámetros mencionados. En este trabajo lo que se ha hecho para determinar la solución que mejor resultados ofrecía, ha sido ir probando diferentes redes neuronales hasta dar con una en la que el coste computacional y los resultados fueran aceptables.

Un aspecto importante de las redes neuronales es que éstas tienen que aprender, éste es el proceso que se conoce como entrenamiento. Existen distintos tipos de funciones de entrenamiento. El objetivo que se busca conseguir con el entrenamiento es minimizar el error que se produce en los resultados obtenidos con la red con respecto a los medidos. Para comprobar esto se construye el modelo matemático con tres conjuntos de datos diferentes: Los datos de entrenamiento que

tienen como objetivo ajustar los pesos de los coeficientes entre las neuronas de la red; Los datos de validación que se utilizan para predecir las respuestas de las observaciones con el modelo ajustado y para detectar sobreajuste y aplicar regularización para corregirlo; Por último los datos de test que se utilizan para evaluar la red de manera imparcial y realizar un último ajuste a los valores de los coeficientes de la red.

El último aspecto que queda por estudiar es el tipo de red neuronal que se va a emplear. Las redes que existen son la red feedforward, la red en cascada, la red recurrente o la red convolucional, pero en este trabajo nos vamos a centrar en la red feedforward. Este tipo de red se caracteriza por que la información se desplaza únicamente hacia delante, esto implica que no hay ningún tipo de realimentación. Este tipo de red utiliza una técnica de entrenamiento conocida como backpropagation, que se caracteriza por comparar los valores obtenidos a la salida de la red con los valores esperados para calcular el error.




Figura 4.7: Esquema típico de una red neuronal

En este trabajo se han propuesto 2 soluciones con las redes neuronales. La primera propuesta consiste en una red neuronal que permita obtener los umbrales genéticos de manera rápida y de forma correcta. La segunda propuesta es utilizar la red neuronal como DPD, es decir, que nos devuelva la señal de entrada predistorsionada. A continuación se va a explicar su implementación y sus prestaciones.

4.4.1. Red neuronal para el cálculo de los umbrales genéticos

Como se ha comentado anteriormente, el objetivo de esta red neuronal es ser capaz de obtener los umbrales genéticos del modelo CPWL. Lo primero que hay que hacer es definir el tipo de red que se va a utilizar, que en este caso va a ser una red feedforward. No se va a generar esta red desde cero, sino que se va a hacer uso de la función *feedforwardnet* de Matlab, que devuelve una red neuronal prealimentada. Se hace uso de esta red ya que con un número adecuado de capas ocultas y de neuronas puede adaptarse a cualquier problema de aplicación de entrada-salida. Además tras aplicar esta red a las señales que se han generado, los resultados eran ya suficientemente buenos. La función de entrenamiento que emplea esta red neuronal es la función backpropagation de Levenberg-Marquardt.

Para entrenar esta red, se han utilizado las señales definidas en el anexo A.2. De cada una de estas señales, se han calculado sus coeficientes utilizando la ec. (3.13) y la varianza de las señales de entrada y salida medidas. También se ha hecho uso de los umbrales genéticos específicos, obtenidos en el apartado 4.3.2, para cada una de estas señales. En la figura 4.8 se puede ver que parámetros de entrada y de salida se han usado para entrenar la red.




Figura 4.8: Parámetros de entrada y de salida de la red NN para el cálculo de los umbrales genéticos

Lo último que hay que definir son los hiperparámetros. Para elegir estos parámetros de manera correcta se ha realizado un estudio. En este estudio se ha ido variando el número de capas ocultas y de neuronas en cada uno de ellas, y se ha probado con cuál de las redes se obtenía una mejora mayor en términos de ACPR respecto de la señal sin DPD. Algunos de estos resultados se encuentran en la tabla 4.4, en la que se recogen las mejoras de ACPR de las señales (2, 3, 5, 6) explicadas en la tabla 2.4. Los números que aparecen como parámetros NN corresponden al número de neuronas que hay en cada capa oculta, es decir, en el caso de que la red sea [20 15 10 5], implica que hay 4 capas ocultas y que hay 20 neuronas en la primera capa oculta, 15 en la segunda y así sucesivamente. Tras el análisis de todos los resultados se escoge la red [20 15 10 5], representada en la figura 4.9. Como se observa en la tabla, es la que mejor resultados ofrece, en términos de ACPR, en todas las señales en las que se ha probado.

Como se comentó en el apartado 2.2 se han generado varias señales, de las cuales, las explicadas en la tabla 2.4, son las que se van a utilizar para validar el comportamiento de los diferentes DPD, el resto de las señales se van a utilizar para entrenar la red.

Mejora de ACPR (dB) en función de los parámetros de la red				
<i>Parámetros NN</i>	<i>Señal 2</i>	<i>Señal 3</i>	<i>Señal 5</i>	<i>Señal 6</i>
[20 15 10 5]	15,57	10,58	9,36	10,1864
[25 18 12 9]	14,65	10,18	9,98	10,184
[25 20 15 10 5]	13,4	9,76	8,64	10,1812
[25 18 12 9 5]	12,97	9,55	7,97	9,974
[30 25 20 15 10]	13,145	9,58	7,99	10,15

Tabla 4.4: Valores de mejora de ACPR para diferentes señales con distintas redes NN




Figura 4.9: Red neuronal utilizada para calcular los umbrales genéticos

Una vez se tiene la red entrenada se puede poner a prueba con las señales 3 y 4 de la tabla 2.4. En la figura 4.10 se puede observar cómo los umbrales calculados con la red neuronal son muy similares a los obtenidos previamente con el algoritmo genético. Lo mismo ocurre con los resultados representados en la figura 4.11, ya que las señales linealizadas por ambos métodos son bastante similares.




Figura 4.10: Curva AM/AM de la señal medida con los umbrales genéticos y los calculados con la red neuronal representados sobre ella




Figura 4.11: Representación de los resultados obtenidos calculando los coeficientes del DPD con el modelo CPWL y utilizando los umbrales genéticos y los obtenidos con la red NN. a) Señal 3; b) Señal 4

Mejora de ACPR (dB) en función de los umbrales utilizados		
	<i>Umbrales Genéticos</i>	<i>Umbrales con red NN</i>
<i>Señal 3</i>	9,96	10,18
<i>Señal 4</i>	9,52	10,93

Tabla 4.5: Valores de la mejora en ACPR utilizando diferentes umbrales para las señales linealizadas 3 y 4 de la tabla 2.4

Con ayuda de los valores reflejados en la tabla 4.5, se observa cómo la red neuronal ofrece unos resultados muy similares, incluso mejores, que los obtenidos con los umbrales genéticos. Se concluye por tanto que usar una red neuronal como forma de calcular los umbrales del modelo CPWL, es un método más que válido para linealizar una señal.

4.4.2. Red neuronal como DPD

El uso de una red neuronal como DPD es algo que no se había probado en el montaje experimental propuesto por el grupo de investigación, por lo que todavía no se estaba muy seguro de si ofrecía unos resultados igual de buenos que los obtenidos con los modelos MPM y CPWL. A pesar de que la forma en que se entrena y después se aplica la red varía con respecto a la utilizada para calcular los umbrales, el tipo de red que se va a utilizar es el mismo que en ese caso, la red *feedforwardnet* de matlab, ya que el problema que se intenta resolver es de entrada-salida.




Figura 4.12: Esquema de la red neuronal como DPD

Como se puede ver en la figura 4.12, los parámetros de entrada y de salida cuando se entrena la red no son los mismos que cuando se aplica la red. Esto se debe a que con el entrenamiento, se busca que la red aprenda la distorsión que introduce el sistema, para así poder añadírsela a la señal medida y obtener de esta manera la señal predistorsionada. Como se puede ver en el esquema de la figura 4.12, esta distorsión se obtiene dividiendo la señal tras pasar por todo el sistema

RoF entre la *Glin* que le aplica el amplificador de potencia. Se considera que el sistema es el PA por simplicidad, ya que es el dispositivo no lineal que más distorsión introduce.

A la hora de utilizar la red neuronal como DPD se han planteado 2 propuestas. La primera de ellas es entrenar la red con única señal similar a la que se quiere linealizar, y la segunda es entrenar la red con 5 señales similares a las que se van a probar. Para cada una de estas redes se ha empleado una configuración diferente debido a que la duración del entrenamiento de estas redes es muy elevado, ya que las redes se entrenan con las señales enteras.

Para optimizar la red se probó a añadir más parámetros de entrada, como en [19]. Estos parámetros fueron la señal con memoria 1, con memoria 2 o incluso el valor absoluto o la potencia de la señal. Excepto en el caso de utilizar la señal con memoria 1 como parámetro de entrada que sí que mejoraba, en el resto de casos no merecía la pena su incorporación debido al aumento del tiempo de entrenamiento que suponía. Su rendimiento se medía en función de un valor de las redes conocido como performance. Las redes finalmente empleadas están representadas en la figura 4.13.




Figura 4.13: Hiperparámetros de las redes neuronales empleadas como DPD. a) red específica; b) red general

Como se ha comentado, las señales con las que se va entrenar la red son señales similares a las que se van a querer linealizar, ya que al menos una tiene características similares a la señal que se va a probar. Las señales utilizadas para entrenar las redes están explicadas y representadas en el anexo A.2, pero se explican de forma general para que resulte más sencillo. Estas señales son:

- Señal 4.1: Señal de 3 MHz con todos los PRBs activos
- Señal 4.2: Señal de 5 MHz con todos los PRBs activos y modulación 64-QAM
- Señal 4.3: Señal de 5 MHz con señal NB-IoT en los PRBs 7 y 17
- Señal 4.4: Señal de 5 MHz a la que se le han variado los PRBs activos
- Señal 4.5: Señal de 5 MHz a la que se le han variado los PRBs activos y sus potencia relativa

En la figura 4.14 se representan las señales 4 y 6 de la tabla 2.4 tras pasarlas por la red neuronal. Con los valores recogidos en la tabla 4.6, se puede comprobar como con ambas redes se reduce la distorsión en canal adyacente y como en ambos casos la red específica ofrece mejores resultados que la red general.




Figura 4.14: Ejemplos de resultados obtenidos utilizando las 2 redes neuronales que se han creado como DPD. a) Señal 4; b) Señal 6

Mejora de ACPR (dB) en función de la red NN usada como DPD		
	<i>NN general</i>	<i>NN única</i>
<i>Señal 4</i>	7,44	9,15
<i>Señal 6</i>	5,09	7,42

Tabla 4.6: Valores de la mejora en ACPR utilizando diferentes redes NN como DPD para las señales linealizadas 4 y 6 de la tabla 2.4

5. Evaluación de Resultados

Una vez se han explicado los sistemas de linealización que se van a emplear para predistorsionar las señales originales y se ha probado su correcto funcionamiento en simulación, se procede con la evaluación de estas señales sobre un montaje de un transmisor híbrido Radio sobre Fibra como el que se explicó en el apartado 3.1.

Para evaluar cómo funciona cada uno de los DPD que se han creado con los distintos sistemas, se va a hacer uso de algunas de las figuras de mérito explicadas en el apartado 2.3. Principalmente nos vamos a fijar en el compromiso entre ACPR y pérdida de potencia, y que el EVM mejore con respecto a la señal sin DPD.

5.1. Evaluación de las señales propuestas

Para valorar el comportamiento de los sistemas linealizadores se van a utilizar las señales descritas en el apartado 2.2, correspondientes a diferentes escenarios en los que se ha variado alguno de los parámetros de la señal.

Para la evaluación se van a realizar dos análisis por separado. Por una parte se comparan los resultados obtenidos con los modelos polinomial y el CPWL, y por otra los resultados obtenidos cuando se utiliza una red neuronal como DPD. El modelo CPWL se evalúa en dos formas distintas, la primera es con los umbrales uniformes y la segunda es con los umbrales genéticos calculados con la red neuronal descrita en el apartado 4.4.1. Cuando se evalúa la red como DPD se prueba con 2 redes distintas, una red específica para cada tipo de señal, y una red general, descritas también en el apartado 4.4.2. Esta separación se realiza porque como son redes totalmente diferentes, la forma de entrenarlas y sus parámetros de entrada y de salida no coinciden.

En cuanto al análisis de la influencia de los parámetros variables que componen la señal, se utilizará como señal modelo la señal 1 de la tabla 2.4, y la medida que se utilizará para comparar su efecto será el valor exacto de ACPR de la señal modelo y de la señal que se esté evaluando. En cambio, para valorar cada uno de los DPD se calcula la mejora que supone el uso de este frente a la señal sin linealizar.

5.1.1. Escenario 1

En este escenario se expone la señal más básica que va a ser la que se va tomar como referencia para evaluar la influencia de cada uno de los parámetros variables de una señal cuando se intenta linealizar. Esta es la señal 1 explicada en la tabla 2.4 y era una señal de 5 MHz, 25 PRBs, con todos los PRBs activos y con la misma potencia relativa, con modulación 64QAM. Esta señal tiene la particularidad de que también se ha usado para entrenar las redes NN, con el fin de saber si las redes NN funcionan mejor en esta señal que sobre el resto.

MODELO LINEALIZACIÓN	ACPR (dBc)	Mejora ACPR (dB)	Diferencia de Potencia (dB)	EVM (%)
Sin linealizar	-37,16			4,648
Polinomial	-43,77	6,614	-2,17	1,972
CPWL Uniforme	-44,27	7,11	-2,77	1,371
CPWL Red NN umbrales	-44,93	7,77	-2,57	1,941
Red NN general	-41,76	4,607	-2,57	2,16
Red NN específica	-44,2	7,02	-2,17	1,856

Tabla 5.1: Resultados experimentales de aplicar predistorsión a la señal 1

Tras enviar a la placa las señales originales predistorsionadas, se miden las nuevas señales linealizadas. Estos resultados experimentales se recogen en la tabla 5.1, donde para cada señal se da el valor de ACPR, la mejora en ACPR frente a la señal sin DPD, la pérdida de potencia que sufre con respecto a la señal sin linealizar así como el EVM. Aunque la diferencia entre los resultados obtenidos con el modelo polinomial y el CPWL no es mucha, cabe destacar el DPD calculado con el modelo CPWL con los umbrales calculados con la red neuronal, ya que en términos de ACPR es la que mejor solución ofrece.

En cuanto a los resultados obtenidos con las redes neuronales como DPD, se observa como no mejora al modelo CPWL, pero los resultados que ofrecen son también válidos puesto que mejoran con respecto a la original, sobre todo el caso de la red específica.

Estos resultados se pueden ver gráficamente en la figura 5.1 donde se muestra la densidad espectral de potencia de la señal de salida que se obtiene tras aplicar los diferentes modelos de linealización. Se observa la disminución de la distorsión fuera de banda reflejada en la tabla 5.1.




Figura 5.1: Densidad espectral de potencia normalizada de la señal de salida 1 medida en el laboratorio con y sin DPD al aplicar los distintos modelos de linealización

5.1.2. Escenario 2

En este escenario se va a realizar un estudio de la influencia que tiene el ancho de banda en las prestaciones ofrecidas al linealizar estas señales. Para realizar este estudio se utiliza la señal 2 recogida en la tabla 2.4.

MODELO LINEALIZACIÓN	ACPR (dBc)	Mejora ACPR (dB)	Diferencia de Potencia (dB)	EVM (%)
Sin Linealizar	-35,83			5,885%
Polinomial	-44,68	8,854	-1,43	1,495%
CPWL Uniforme	-44,99	9,1617	-2,08	1,466%
CPWL Red NN umbrales	-45	9,1634	-1,73	1,786%
Red NN general	-41,88	6,05	-1,83	2,494%
Red NN específica	-45,81	9,98	-2,43	1,473%

Tabla 5.2 Resultados experimentales de aplicar predistorsión a la señal 2

Si se comparan los resultados obtenidos con esta señal, en la tabla 5.2, con respecto a los conseguidos en el escenario 1 se observa una mejora mayor con respecto de la señal sin DPD. El causante de esto es la distorsión de la señal sin DPD, ya que al comparar sus respectivos niveles de ACPR, se comprueba como en esta segunda señal la distorsión es mayor. Esta distorsión, más que venir ocasionada por el propio ancho de banda, se debe a la variación de la potencia relativa de los PRBs.

En este escenario se observa que la diferencia entre las señales con DPD obtenidas mediante el modelo polinomial y el modelo CPWL, es menor que en el escenario anterior, pero aun así se observa como el sistema que mejor resultados da es el CPWL con los umbrales calculados con la red NN.

Al aplicar las redes neuronales como DPD se observa un comportamiento similar al escenario anterior. Los resultados obtenidos con la red NN específica en este caso sí que son los mejores en términos de ACPR, mientras que con la red general sí que disminuye la distorsión fuera de banda pero no tanto como con los otros métodos.

Estos resultados se pueden ver gráficamente en la figura 5.2 donde se muestra la densidad espectral de potencia de la señal de salida que se obtiene tras aplicar los diferentes modelos de linealización.




Figura 5.2: Densidad espectral de potencia normalizada de la señal de salida 2 medida en el laboratorio con y sin DPD al aplicar los distintos modelos de linealización

5.1.3. Escenario 3

En este escenario se analiza el efecto que tiene la modulación empleada cuando se trata de linealizar una señal. Para ello se propone trabajar con la señal 3 definida en la tabla 2.4.

MODELO LINEALIZACIÓN	ACPR (dBc)	Mejora ACPR (dB)	Diferencia de Potencia (dB)	EVM (%)
Sin linealizar	-36,34			3,174%
Polinomial	-43,85	7,5	-2	1,4%
CPWL Uniforme	-43,4	7,05	-2	1,55%
CPWL Red NN umbrales	-44,1	7,762	-1,87	1,474%
NN red general	-42,91	6,5718	-2,21	1,929%
NN red específica	-44,65	8,3177	-2,15	1,337%

Tabla 5.3: Resultados experimentales de aplicar predistorsión a la señal 3

En la tabla 5.3, en la que se recogen todos los resultados obtenidos con las señales con DPD. Se observa de nuevo como el DPD calculado con el modelo CPWL con los umbrales calculados con la red NN, ofrece mejores resultados que los obtenidos con el modelo polinomial. A diferencia de los escenarios anteriores, en este caso el modelo polinomial ofrece mejores resultados que el CPWL con umbrales uniformes, pero como esta diferencia no es mucha se tomará únicamente como una excepción.

En cuanto a los resultados obtenidos cuando se utiliza la red neuronal como DPD, se observa la misma tendencia que en los escenarios anteriores. Como novedad, se observa, como con la red general, el resultado obtenido ha mejorado a los de los escenarios anteriores. Esto se debe a que a pesar de haber variado la

modulación de la señal, los cambios con respecto a las señales con las que se ha entrenado la red no son tan notables como en el escenario 2 por ejemplo, ya que en este caso se ha utilizado el mismo BW y la misma variación de potencia que la mayoría de estas señales.

Al igual que antes, utilizar una modulación diferente genera algo de distorsión, pero esa diferencia se debe más a la potencia de entrada de la señal que al hecho de usar una modulación diferente. Aun así al igual que en los escenarios anteriores esto se compensa con el uso del DPD, obteniendo en las señales finales unos valores de ACPR similares en todos los casos.

Los resultados de la tabla 5.3, se encuentran representados en la figura 5.3 en la que se muestra la densidad espectral de potencia de la señal de salida que se obtiene tras aplicar los diferentes modelos de linealización.




Figura 5.3: Densidad espectral de potencia normalizada de la señal de salida 3 medida en el laboratorio con y sin DPD al aplicar los distintos modelos de linealización

5.1.4. Escenario 4

En este escenario se evalúa el efecto que tiene añadir en la banda de la señal una señal NB-IoT. Se utiliza la señal 4 detallada en la tabla 2.4.

MODELO LINEALIZACIÓN	ACPR (dBc)	Mejora ACPR (dB)	Diferencia de Potencia (dB)	EVM (%)
Sin Linealizar	-35,26			5,785
Polinomial	-42,62	7,36	-1,85	1,632
CPWL Uniforme	-43,34	8,08	-2,55	1,5
CPWL Red NN umbrales	-43,53	8,27	-2,25	1,805
NN red general	-42,28	7,02	-2,2	2,455
NN red específica	-44,55	9,29	-2,7	1,596

Tabla 5.4: Resultados experimentales de aplicar predistorsión a la señal 4

En la tabla 5.4 se puede observar como los resultados siguen la misma tendencia que en los escenarios anteriores, tanto con el modelo polinomial y el CPWL como cuando se utilizan las redes neuronales como DPD. En este segundo caso, funciona tan bien porque, como se puede comprobar en la figura 5.5, el añadir señal NB-IoT no altera mucho la señal, y como las redes se entrenan con señales básicas sin apenas modificaciones, el resultado que se obtiene en este caso es realmente bueno. Estos resultados se pueden ver en la figura 5.4.

Comparando el valor del ACPR de la señal 4 con el de la señal 1, se puede pensar que el añadir señal NB-IoT en banda genera distorsión extra, aunque como se comprobó en [20], esto no es así, si no que se deba a la diferencia de potencia.




Figura 5.4: Densidad espectral de potencia normalizada de la señal de salida 4 medida en el laboratorio con y sin DPD al aplicar los distintos modelos de linealización

5.1.5. Escenario 5

En este escenario se va a analizar cómo influye que las señales tengan diferente potencia relativa en sus PRBs. Para ello se utilizan las señales 5 y 6 expuestas en la tabla 2.4. Las diferencias entre estas señales van a ser el número de PRBs que tienen activos y la potencia relativa de cada uno de ellos.

a) Señal 5

MODELO LINEALIZACIÓN	ACPR (dBc)	Mejora ACPR (dB)	Diferencia de Potencia (dB)	EVM (%)
Sin Linealizar	-35,9			5,424%
Polinomial	-42,56	6,661	-2,2	1,788%
CPWL Uniforme	-44,14	8,247	-2,2	1,576%
CPWL Red NN umbrales	-44,29	8,397	-2,7	1,647%
NN red general	-39,67	3,77	-2,2	2,721%
NN red específica	-44,25	8,352	-2,9	1,668%

Tabla 5.5: Resultados experimentales de aplicar predistorsión a la señal 5

b) Señal 6

MODELO LINEALIZACIÓN	ACPR (dBc)	Mejora ACPR (dB)	Diferencia de Potencia (dB)	EVM (%)
Sin Linealizar	-37,8			3,502%
Polinomial	-44,09	6,29	-2,03	1,356%
CPWL Uniforme	-43,98	6,184	-1,83	1,286%
CPWL Red NN umbrales	-44,14	6,34	-2,23	1,44%
NN red general	-42,14	4,34	-2,63	2,646%
NN red específica	-44,53	6,73	-1,87	1,345%

Tabla 5.6: Resultados experimentales de aplicar predistorsión a la señal 6

En este escenario se verifica lo que se había visto en el escenario 2, que cuando se varía la potencia relativa de los PRBs el nivel de ACPR de la señal sin DPD disminuye. En cambio, si esa modificación no se la aplicas a todos los PRBs, algunos se encuentran desactivados, el nivel de ACPR se mantiene, que es lo que ocurre con la señal 6.

En las tablas 5.5 y 5.6 se observa la misma tendencia que ha aparecido en los escenarios anteriores cuando se utilizan el modelo polinomial y el CPWL para linealizar una señal. En cuanto a los resultados que se obtienen cuando se emplean las redes neuronales como DPD se observa alguna diferencia en el comportamiento para cada una de las señales, a pesar de que las redes utilizadas han sido entrenadas de la misma manera en ambos casos. Para la señal b), se obtiene con la red neuronal específica el mejor resultado y con la red general hay unos 2 dB de diferencia con respecto al resto de modelos, esta es la tendencia que se venía observando en todos los escenarios. En cambio, con la señal a), el resultado con la red neuronal específica es bueno pero no mejora al obtenido con el resto de modelos. Y con la red neuronal general se obtiene un resultado bastante peor que con el resto. Esto se debe principalmente al hecho de que en la señal b) no estén todos los PRBs activos. La densidad espectral de potencia de las señales de salida que se obtienen tras aplicar los diferentes modelos de linealización se encuentran representadas en las figuras 5.5 y 5.6 respectivamente.




Figura 5.5: Densidad espectral de potencia normalizada de la señal de salida 5 medida en el laboratorio con y sin DPD al aplicar los distintos modelos de linealización




Figura 5.6: Densidad espectral de potencia normalizada de la señal de salida 6 medida en el laboratorio con y sin DPD al aplicar los distintos modelos de linealización




Figura 5.7: Representación de la constelación de la señal 5 medida en el laboratorio. a) Sin DPD; b) Con DPD

En la figura 5.7 se representa la constelación correspondiente a la señal de prueba 5 medida en el laboratorio sin linealizar y la linealizada con DPD calculado con la red NN específica. Esta figura nos permite ver de manera gráfica la distorsión que se produce en la banda de la señal. Además se observa claramente como con el uso del DPD se obtiene una mejora considerable.

5.2. Conclusiones de los resultados

Tras evaluar todos los resultados que se han obtenido con los diferentes modelos se pueden llegar a varias conclusiones. La primera de ellas es que a pesar de que todas las señales son diferentes, y por eso el nivel de ACPR de la señal sin linealizar varía, se consigue obtener en todos los casos niveles de ACPR cercanos a -45 dBc tras aplicar el DPD.

En cuanto al comportamiento de todos los métodos se ha comprobado que entre el modelo polinomial y el CPWL con el que mejor resultados se obtienen es con el CPWL, por lo que se verifica que a medida que aumenta la complejidad del modelo los resultados mejoraban. Dentro del CPWL, el que mejor funciona es en el que los umbrales se calculan con redes neuronales.

En cuanto a los resultados obtenidos con las redes neuronales como DPD se ha comprobado que para todas las señales, cuando se utilizaba la red específica para cada señal, se obtienen los mejores resultados en términos de ACPR. Se puede constatar también como cuando las señales eran más básicas y no introducían apenas cambios, la red general ofrecía un resultado aceptable, en cambio si la señal de prueba introducía más variaciones, los resultados empeoraban notablemente.

Otro de los puntos que se intentaba comprobar era sí al aplicar las redes neuronales sobre una señal con la que han sido entrenadas, mejoraba los resultados. Debido a que en el caso de la red para calcular los umbrales sí que mejoraban, mientras que en la red NN como DPD no, no se puede sacar una conclusión clara, por lo que habría que hacer más pruebas.

Conforme a los valores de EVM que se han conseguido, se ha podido verificar que independientemente del método usado para calcular el DPD, el valor del EVM se ha reducido frente a no utilizar DPD, aunque no en todos de igual medida. Se ha observado una mayor reducción del EVM con los modelos MPM y CPWL que con la red NN como DPD, pero como la diferencia no era muy grande se concluye que utilizar la red NN como DPD, en términos del EVM, es una opción más que viable.

Con ayuda de los resultados reflejados en la tabla 5.7, en la que se muestran los resultados obtenidos en simulación y en el laboratorio, se va a estudiar como varían las prestaciones de los modelos al pasarlo a un sistema experimental.

Como se puede observar en la tabla 5.7, existe una diferencia entre lo medido y lo simulado algo mayor en la señal de 3 MHz (señal 2) que en las de 5 MHz. Esto se debe a las limitaciones del hardware, ya que limita las prestaciones en todos los casos. En 5 MHz se nota menos ya que los resultados en simulación eran peores, pero en cambio en las de 3 MHz, como la limitación es la misma, se nota más porque los resultados en simulación eran mejores. En los demás casos se observa un empeoramiento entre 1 o 2 dB de lo medido en el laboratorio respecto a la simulación.

Mejora del ACPR (dB) en simulación y experimentalmente				
	<i>Simulación</i>		<i>Laboratorio</i>	
	<i>CPWL umbrales NN</i>	<i>NN como DPD</i>	<i>CPWL umbrales NN</i>	<i>NN como DPD</i>
<i>Señal 1</i>	9,67	9,2	7,77	7,02
<i>Señal 2</i>	15,57	13,45	9,163	9,98
<i>Señal 3</i>	10,58	9,92	7,76	8,32
<i>Señal 4</i>	10,92	9,15	8,27	9,29
<i>Señal 5</i>	9,36	8,7	8,4	8,352
<i>Señal 6</i>	10,184	7,42	6,34	6,73

Tabla 5.7: Comparación de la mejora en ACPR de las señales de la tabla 2.4 obtenidas en simulación y experimentalmente

6. Conclusiones

Este último apartado se va a utilizar para recapitular todo lo expuesto en la memoria y para hacer un resumen de los resultados obtenidos. Además se explicará si se han cumplido los objetivos propuestos para este TFG y se indicarán algunos de los problemas que han surgido durante el desarrollo de este trabajo para tratar de darles solución en futuros proyectos.

Se comenzó esta memoria exponiendo las tecnologías que se iban a emplear en este trabajo y a partir de esas tecnologías se generaron las señales que se utilizarían posteriormente para validar las diferentes técnicas de linealización. Tras la explicación del montaje experimental en el que se medían estas señales, se hizo el modelado de los dispositivos no lineales del mismo, utilizando dos modelos diferentes, el MPM y el CPWL, concluyendo que a mayor complejidad del modelo mejores resultados se obtenían.

Una vez modeladas las no linealidades introducidas por el transmisor RoF, se propuso la predistorsión digital como técnica para compensar las distorsiones que se hubieran podido producir, siendo éste el principal objetivo de este TFG. Para calcular este DPD se propusieron diferentes métodos para hacerlo. Por un lado estaban los modelos MPM y CPWL, de los que ya se tenía certeza de que bien utilizados ofrecían buenos resultados, y por otro lado se propuso utilizar una red neuronal como DPD, que a pesar de ofrecer buenos resultados presentó algunos problemas que sería interesante tratar de resolver en futuros proyectos. Una vez se habían calculado las señales predistorsionadas se probaron en el montaje experimental para estudiar su comportamiento.

Lo que se busca probando las señales predistorsionadas en el laboratorio, es probar si utilizando estos sistemas linealizadores, se reducirían estas distorsiones en un sistema real. Tras estas pruebas se han podido sacar algunas conclusiones. La primera de ellas es que con todos los métodos usados para calcular el DPD se ha conseguido reducir la distorsión en el canal adyacente y mejorar el EVM con respecto a la señal sin linealizar, en mayor o menor medida en función del método empleado.

Tras linealizar todas las señales que se generaron, con diferentes variaciones en sus parámetros con el fin de estudiar la influencia de los mismos, se puede concluir que a pesar de que haya parámetros, como la variación de la potencia de los PRBs, que introducen mayor distorsión a la señal, al final, con el uso del DPD se consigue obtener resultados similares en todas las señales.

Como se ha comentado en la evaluación de los resultados, introducir señales NB-IoT en banda, no empeora ni el ACPR ni el EVM de la señal sin DPD, además

de que con el uso del DPD se consigue mejorar el ACPR de la señal NB-IoT, como se concluyó en este trabajo [20].

En cuanto al comportamiento de los modelos más convencionales para calcular el DPD, se comprueba que el modelo CPWL con los umbrales calculados con la red neuronal es el que mejor resultado ofrece. Respecto al comportamiento de las redes neuronales como DPD se observa que cuando se utiliza la red neuronal específica, los resultados obtenidos mejoran a los del modelo CPWL con los umbrales calculados con la red neuronal, mientras que con la red general, a pesar de que también mejora a la señal sin linealizar, se obtienen los peores resultados de entre todos los métodos. Esta mejora es en ACPR, en cambio, al comparar los valores del EVM, este efecto no ocurre en todos los casos. Cuando se trata de reducir el EVM son las señales linealizadas con los modelos MPM y CPWL las que mejores resultados ofrecen, mientras que con las redes neuronales, también mejora el EVM con respecto de la señal sin DPD, aunque en menor medida.

También se ha medido la carga computacional que suponía el uso de cada modelo. El que menos carga computacional necesita es el modelo polinomial con memoria, y como consecuencia es el que peor resultados ofrece. El modelo CPWL requiere un poco más de carga computacional, con respecto del modelo polinomial con memoria, pero como los resultados mejoran, merece la pena. En este caso el cálculo de los umbrales hace que haya mayor o menor carga computacional, por lo tanto se han descartado los umbrales genéticos como posible solución. La carga de una distribución uniforme es muy poca, al igual que la de una red neuronal cuando ya está entrenada. En cuanto a las redes neuronales como DPD, la carga computacional que conlleva el entrenamiento de estas es mucha, pero una vez entrenada se reduce de manera considerable.

Tras este análisis yo utilizaría el modelo CPWL con los umbrales calculados con la red neuronal hasta que se consiguieran optimizar las redes neuronales como DPD, ya que con este modelo se han obtenido buenos resultados en todos los escenarios.

Líneas futuras de trabajo

Como se ha indicado, se van a exponer algunos de los problemas que han surgido durante la realización de este proyecto, a los que sería interesante darles solución.


El principal problema surgió cuando se realizaba la red neuronal como DPD debido a tener que pasar las señales enteras como parámetros de entrada y de salida. Además del tiempo de ejecución, que fueron casi 36 horas para la red general, estos parámetros de entrada tenían una limitación que era que había que aplicar la red sobre el mismo número de señales con las que se había entrenado previamente, haciendo imposible aplicar esta red sobre una única señal, a no ser

que se utilizara una red específica como la propuesta. Sería interesante tratar de optimizarla ya que se han visto que los resultados que ofrece son bastante buenos.

Sería interesante también probar con señales con anchos de banda mayores para comprobar si con las redes neuronales como DPD se mejoran los resultados obtenidos con los métodos ILA, como se comenta en [21]. A día de hoy no es posible por limitaciones del hardware de la placa que se está utilizando actualmente en el laboratorio, aunque el grupo de investigación posee otra placa con mayor ancho de banda que en breve se pondrá en marcha.

Adicionalmente se podría probar con señales a las que se les hayan variado algunos de los parámetros nuevos que incluía 5G, como por ejemplo señales con diferentes separaciones entre subportadoras.

El orden cronológico que se ha seguido para realizar este Trabajo de Fin de Grado es el que se muestra en el diagrama de Gantt de abajo.



7. Bibliografía

- [1] F. Gutierrez Soler, Tema 1. Comunicaciones Móviles. Asignatura Comunicaciones Móviles y Vía Satélite, Universidad de Zaragoza, 2022.
- [2] P. Alonso, "TELDAT Blog. ¿Qué es LTE Advanced?," [Online]. Available: <https://www.teldat.com/es/blog/que-es-lte-advanced/>. [Accessed 01 2023].
- [3] International Telecommunication Union, Radiocommunication Sector (ITU-R), "Minimum requirements related to technical performance for IMT-2020 radio interface(s). Report ITU-R M.2410-0," 11 2017. [Online]. Available: https://www.itu.int/dms_pub/itu-r/opb/rep/R-REP-M.2410-2017-PDF-E.pdf. [Accessed 01 2023].
- [4] David Wake; Anthony Nkansah; Nathan J. Gomes, "Radio Over Fiber Link Design for Next Generation Wireless Systems," in *Journal of Lightwave Technology*, 2010, pp. 2456 - 2464.
- [5] V. Mustieles Pérez, "Generación y evaluación de formas de onda en un transmisor 5G con agregación de señales banda ancha-estrecha," Universidad de Zaragoza, 2020.
- [6] R. Agusti, F. Bernardo, F. Casadevall, R. Ferrús, J. Pérez-Romero and O. Sallent, LTE: nuevas tendencias en comunicaciones m'oviles, Fundación Vodafone España, 2010.
- [7] M. S. Navita and A. P. Amandeep, "PERFORMANCE ANALYSIS OF OFDMA, MIMO AND SC-FDMA TECHNOLOGY IN 4G LTE NETWORKS," IEEE Communications Magazine, Hisar, India, 2016 6th International Conference - Cloud System and Big Data Engineering (Confluence).
- [8] 3GPP, User Equipment (UE) radio transmission and reception; Part 1: Range 1 Standalone TS 38.101-1 version 15.5.0 Release 15.
- [9] 3GPP, 5G and NR, User Equipment (UE) radio transmission and reception; Part 2: Range 2 Standalone. TS 38.101-2 version 15.3.0 Release 15.
- [10] J. S. a. D. Raddino, "Narrowband Internet of Things," 2016. [Online]. Available: https://cdn.rohde-schwarz.com/pws/dl_downloads/dl_application/application_notes/1ma266/1MA266_0e_NB_IoT.pdf.
- [11] M. Aziz and M. Rawat, "Low Complexity Distributed Model for the Compensation of Direct Conversion Transmitter's Imperfections," *IEEE TRANSACTIONS ON BROADCASTING*, vol. 60, no. 3, 2014.
- [12] R. A. Shafik, M. S. Rahman and A. R. Islam, "On the Extended Relationships Among EVM, BER and SNR as Performance Metrics," *Proceedings of 4th International Conference on Electrical and Computer Engineering, ICECE 2006*, p. 408–411, 2007.

- [13] D. R. Morgan, Z. Ma, J. Kim, M. G. Zierdt and J. Pastalan, "A Generalized Memory Polynomial Model for Digital Predistortion of RF Power Amplifiers," *IEEE Transactions on Signal Processing*, vol. 54, no. 10, 2006.
- [14] C. M. Pérez, "Contribución a la mejora de la eficiencia y linealidad de arquitecturas híbridas rf-ópticas (hrf) para sistemas de comunicaciones móviles," in *Tesis doctoral*, Universidad de Zaragoza, 2019, pp. 113-115.
- [15] C. Eun and E. J. Powers, "A new Volterra predistorter based on the indirect learning architecture," *IEEE Transactions on Signal Processing*, vol. 45, pp. 223-227, 1997.
- [16] C. Mateo, P. L. Carro, P. García-Dúcar, J. D. Mingo and Í. Salinas, "Radio-over-fiber linearization with optimized genetic algorithm CPWL model," *Optic Express*, vol. 25, no. 4, 2017.
- [17] O. Hammi and F. M. Ghannouchi, "Power Alignment of Digital Predistorters for Power Amplifiers Linearity Optimization," *IEEE Transactions on Broadcasting*, vol. 55, pp. 109-114, 2009.
- [18] D. J. Matich, "Redes Neuronales: Conceptos Básicos y Aplicaciones," in *Informática Aplicada a la Ingeniería de Procesos – Orientación I*, 2001.
- [19] T. Liu, S. Boumaiza and F. M. Ghannouchi, "Dynamic Behavioral Modeling of 3G Power Amplifiers Using Real-Valued Time-Delay Neural Networks," *IEEE Transactions on Microwave Theory and Techniques*, vol. 52, pp. 1025-1033, 2004.
- [20] P. Lorient, "Análisis de la distorsión y evaluación de métodos de linealización concurrente de cabezales remotos de RF 5G," Universidad de Zaragoza, 2021.
- [21] E. G. Berenguer, "Linealización de un Amplificador Balanceado con Modulación de Carga Mediante un Predistorsionador Digital Basado en Redes Neuronales para Comunicaciones en Vehículos Aéreos no Tripulados," Universidad Politécnica de Cataluña, 2020.

Lista de Figuras

Figura 2.1: Distribución de múltiples subportadoras en una señal que usa OFDM .	8
Figura 2.2 : Espectro en LTE formado por el conjunto de subportadoras	9
Figura 2.3: Estructura de una subtrama en tiempo-frecuencia de una señal LTE...	9
Figura 2.4: PSD de las señales de la tabla 2.4: a) Señal 1, b) Señal 2, c) Señal 3, d) Señal 4, e) Señal 5, f) Señal 6	12
Figura 3.1: Diagrama de bloques del montaje del laboratorio	14
Figura 3.2: Sistema RoF del laboratorio	15
Figura 3.3: Tarjeta SDR y láser utilizados en el sistema RoF del laboratorio.....	15
Figura 3.4: Curvas AM/AM de la señal medida frente a la modelada.....	16
Figura 3.5: Representación del error NMSE en función del orden y la memoria...	21
Figura 3.6: Representación del error NMSE en función de la configuración del modelo CPWL	22
Figura 3.7: PSD de la señal 1 de la tabla 2.4, tras pasar por el sistema RoF, modelada frente a la medida.....	23
Figura 4.1: Esquema del funcionamiento del predistorsionador digital	24
Figura 4.2: Estructura indirecta ILA para el cálculo del DPD.....	25
Figura 4.3: Curvas Psalida/Pentrada con la ganancia de normalización variable .	25
Figura 4.4: PSD de la señal de salida con y sin DPD estudiando la mejor configuración posible: a) Señal 5 con $N=5$ y $\alpha_{norm} = 0,77$ con $M=1, 2$; b) Señal 1 con $N=5$ y $\alpha_{norm} = 0,77$ con $M=1, 2$; c) Señal 5 con $M=2$ y $\alpha_{norm} =$ $0,77$ con $N=5, 7$; d) Señal 1 con $M=1$ y $\alpha_{norm} = 0,77$ con $N=5, 7$; e) Señal 5 con $M=2$ y $N=7$ con $\alpha_{norm} = 0,74, 0,76, 0,78$; f) Señal 1 con $M=1$ y $N=7$ con $\alpha_{norm} = 0,74, 0,76, 0,78$;.....	27
Figura 4.5: Curva AM/AM de la señal medida con los umbrales uniformes y genéticos representados sobre ella	31
Figura 4.6: PSD de las señales de salida con y sin DPD utilizando el modelo CPWL y variando entre umbrales uniformes y genéticos. a) Señal 1; b) Señal 5	31
Figura 4.7: Esquema típico de una red neuronal.....	33
Figura 4.8: Parámetros de entrada y de salida de la red NN para el cálculo de los umbrales genéticos	34
Figura 4.9: Red neuronal utilizada para calcular los umbrales genéticos.....	35

Figura 4.10: Curva AM/AM de la señal medida con los umbrales genéticos y los calculados con la red neuronal representados sobre ella	35
Figura 4.11: Representación de los resultados obtenidos calculando los coeficientes del DPD con el modelo CPWL y utilizando los umbrales genéticos y los obtenidos con la red NN. a) Señal 3; b) Señal 4	35
Figura 4.12: Esquema de la red neuronal como DPD	36
Figura 4.13: Hiperparámetros de las redes neuronales empleadas como DPD. a) red específica; b) red general.....	37
Figura 4.14: Ejemplos de resultados obtenidos utilizando las 2 redes neuronales que se han creado como DPD. a) Señal 4; b) Señal 6.....	38
Figura 5.1: Densidad espectral de potencia normalizada de la señal de salida 1 medida en el laboratorio con y sin DPD al aplicar los distintos modelos de linealización.....	40
Figura 5.2: Densidad espectral de potencia normalizada de la señal de salida 2 medida en el laboratorio con y sin DPD al aplicar los distintos modelos de linealización.....	42
Figura 5.3: Densidad espectral de potencia normalizada de la señal de salida 3 medida en el laboratorio con y sin DPD al aplicar los distintos modelos de linealización.....	43
Figura 5.4: Densidad espectral de potencia normalizada de la señal de salida 4 medida en el laboratorio con y sin DPD al aplicar los distintos modelos de linealización.....	44
Figura 5.5: Densidad espectral de potencia normalizada de la señal de salida 5 medida en el laboratorio con y sin DPD al aplicar los distintos modelos de linealización.....	46
Figura 5.6: Densidad espectral de potencia normalizada de la señal de salida 6 medida en el laboratorio con y sin DPD al aplicar los distintos modelos de linealización.....	46
Figura 5.7: Representación de la constelación de la señal 5 medida en el laboratorio. a) Sin DPD; b) Con DPD	46
Figura A.1: Simulador para la generación de las señales 5G.....	60
Figura A.2: PSD de las señales de la tabla A.1: a) Señal 1, b) Señal 2, c) Señal 3, d) Señal 4, e) Señal 5, f) Señal 6, g) Señal 7	62

Lista de Tablas

Tabla 2.1: Rango de frecuencias en la tecnología 5G.....	10
Tabla 2.2: Número de PRBs disponibles para cada ancho de banda	10
Tabla 2.3: PRBs en los que se puede añadir señal NB-IoT para cada BW.....	11
Tabla 2.4: Parámetros de las señales generadas para el estudio del sistema.....	11
Tabla 3.1: Valores del error NMSE obtenidos tras modelar los dispositivos no lineales del transmisor RoF aplicando los modelos MPM y CPWL	23
Tabla 4.1: Valores de la mejora en ACPR utilizando diferentes configuraciones para las señales linealizadas 1 y 5 de la tabla 2.4	28
Tabla 4.2: Mejora en ACPR en función de la memoria y particiones del modelo CPWL para el cálculo del DPD	30
Tabla 4.3: Valores de la mejora en ACPR utilizando diferentes umbrales para las señales linealizadas 1 y 5 de la tabla 2.4	31
Tabla 4.4: Valores de ACPR para elegir la red neuronal para calcular los umbrales	35
Tabla 4.5: Valores de la mejora en ACPR utilizando diferentes umbrales para las señales linealizadas 3 y 4 de la tabla 2.4	36
Tabla 4.6: Valores de la mejora en ACPR utilizando diferentes redes NN como DPD para las señales linealizadas 4 y 6 de la tabla 2.4.....	38
Tabla 5.1: Resultados experimentales de aplicar predistorsión a la señal 1	40
Tabla 5.2 Resultados experimentales de aplicar predistorsión a la señal 2	41
Tabla 5.3: Resultados experimentales de aplicar predistorsión a la señal 3	42
Tabla 5.4: Resultados experimentales de aplicar predistorsión a la señal 4	43
Tabla 5.5: Resultados experimentales de aplicar predistorsión a la señal 5	44
Tabla 5.6: Resultados experimentales de aplicar predistorsión a la señal 6	45
Tabla 5.7: Comparación de la mejora en ACPR de las señales de la tabla 2.4 obtenidas en simulación y experimentalmente.....	48
Tabla A.1: Parámetros de las señales generadas para entrenar las redes NN.....	61
Tabla A.2: Comparativa de la mejora de ACPR entre los diferentes métodos de linealización aplicados sobre las señales de la tabla 2.4	63
Tabla A.3: Comparativa de la mejora de ACPR entre el modelo MPM y el CPWL aplicado sobre las señales 3, 6 y 7 de la tabal A.1, comparando los resultados obtenidos en simulación frente a lo del laboratorio	63

Lista de Acrónimos

1G	Primera generación
AMPS	Advanced Mobile Phone Service
TACS	Total Access Communications Systems
NMT-450	Nordiska Mobil Telefongruppen
2G	Segunda generación
FDD	Frequency Division Duplex
TDMA	Time Division Multiple Access
GSM	Groupe Special for Mobile
ADC	American Digital Cellular
3G	Tercera generación
UMTS	Universal Mobile Telecommunications Systems
CDMA	Code Division Multiple Access
TDD	Time Division Duplex
4G	Cuarta generación
OFDM	Orthogonal Frequency Division Multiplexing
3GPP	3rd Generation Partnership Project
LTE	Long Term Evolution
MIMO	Multiple-Input-Multiple-Output
5G	Quinta generación
IoT	Internet of Things
ITU	International Telecommunication Union
RoF	Radio sobre Fibra
BBU	BaseBand Unit
RRH	Remote Radio Head
PA	Amplificador de potencia

QoS	Calidad de servicio
RE	Resource Element
PRB	Physical Resource Block
FR	Rangos de frecuencia
NB-IoT	Narrowband Internet of Things
BW	Ancho de banda
ACPR	Adjacent Channel Power Ratio
EVM	Error Vector Magnitude
NMSE	Error cuadrático medio normalizado
MPM	Modelo polinomial con memoria
LNA	Amplificador de bajo ruido
PD	Fotodetector
I3A	Instituto de Investigación en Ingeniería de Aragón
SDR	Software Define Radio
DFB	Láser de retroalimentación distribuida
SMF	Fibra óptica es monomodo
EAM	Modulador por electro absorción
CPWL	Funciones canónicas lineales por partes
DPD	Predistorsionador digital
ILA	Indirect Learning Architecture
GA	Algoritmos genéticos
PSD	Power Spectral Density
NN	Redes neuronales

Anexos

A. Generación de señales 5G

A.1. Simulador de señales 5G en Matlab

Este anexo se va a utilizar para explicar todo lo relacionado con el simulador de Matlab con el que sean generados todas las señales que se van a utilizar [5]. Además se van a definir todas las señales que se han generado y que después se han utilizado para entrenar las redes neuronales.

The image shows a MATLAB-based 5G signal generator simulator interface. It is divided into several sections:

- Transmisor**: Contains input fields for 'Número de tramas' (empty), 'Número de RB' (set to 6), 'Número de RB usados' (empty), 'Prefijo cíclico' (set to Normal), 'Modulación' (set to QPSK), 'Potencia relativa pilotos' (empty), and 'Potencia relativa PRBs' (empty). There are 'Avanzado' buttons next to 'Número de RB usados', 'Potencia relativa pilotos', and 'Potencia relativa PRBs'.
- Agregar señales de banda estrecha:**: Includes an 'NB-IoT' label and two buttons: 'Añadir señales' and 'Eliminar señales'.
- Modelo de no linealidad**: Includes checkboxes for 'Ninguno' (checked), 'Sin memoria', and 'Con memoria'. Below these is a numeric input set to 1 with '-' and '+' buttons.
- Ver resultados:**: Includes checkboxes for 'Dominio temporal' (Señal final), 'Dominio frecuencial' (Antes de amplificar, Amplificada, Medidas ACLR), and 'Matriz de recursos' (Señal de banda ancha, Señales NB-IoT, Señal completa 3D). Below these are buttons for 'Representar' and 'Error Vector Magnitude: Calcular'.
- Canal:**: Includes a 'Seleccionar' button and the text 'Canal ideal'.
- Receptor**: Includes a 'Demodular' button.
- Ver resultados:**: Includes buttons for 'Constelación' and 'BER'.
- Generar señal**: A large button at the bottom left.

Figura A.1: Simulador para la generación de las señales 5G


Como se puede ver en la figura A.1, el simulador incluye algunos de los parámetros variables de las señales 5G. Como se puede ver, su uso es muy intuitivo ya que todos los parámetros son claramente identificables.

A.2. Parámetros de las señales utilizadas para entrenar las redes neuronales


Como se ha comentado, se van a exponer en este anexo también las señales que se han utilizado para entrenar las redes neuronales.

	<i>PRBs disponibles</i>	<i>PRBs activos</i>	<i>Variación Potencia Relativa</i>	<i>Modulación</i>	<i>Añade señal NB-IoT</i>
Señal 1	15	15	No	64-QAM	No
Señal 2	25	25	No	QPSK	No
Señal 3	25	25	No	16-QAM	No
Señal 4	25	25	No	256-QAM	No
Señal 5	25	23	No	64-QAM	Sí (7, 17)
Señal 6	25	0,1,4,5,8,9,12,13, 16,17,20,21,24	No	64-QAM	No
Señal 7	25	0,2,4,6,8,10,12,14 ,16,18,20,22,24	Sí(2,0,2,0,2,0,2,0, 2,0,2,0,2,0,2,0,2,0 ,2,0,2,0,2,0,2)	64-QAM	No


Tabla A.1: Parámetros de las señales generadas para entrenar las redes NN




a)




b)




c)




d)



e)



f)



g)

Figura A.2: PSD de las señales de la tabla A.1: a) Señal 1, b) Señal 2, c) Señal 3, d) Señal 4, e) Señal 5, f) Señal 6, g) Señal 7

B. Resultados obtenidos en simulación

En este anexo, se van a mostrar otros resultados que no se han presentado durante el desarrollo de la memoria.

1º Los resultados que se obtuvieron en simulación con todos los modelos aplicados sobre las señales de la tabla 2.4, las utilizadas para validar las redes neuronales.

Mejora del ACPR (dB) en simulación para las señales de la tabla 2.4					
	MPM	CPWL umbrales unif	CPWL umbrales NN	NN como DPD gen.	NN como DPD esp.
Señal 1	8,8	10,43	9,67	6,52	9,2
Señal 2	14,6	16,12	15,57	6,9	13,45
Señal 3	10,2	11,23	10,58	7,31	9,92
Señal 4	9,7	9,8	10,92	7,44	9,15
Señal 5	9,6	10,32	9,36	4,3	8,7
Señal 6	8,65	9,11	10,184	5,08	7,42

Tabla A.2: Comparativa de la mejora de ACPR entre los diferentes métodos de linealización aplicados sobre las señales de la tabla 2.4

2º Los resultados que se obtuvieron, tanto en simulación como en el laboratorio, de algunas de las señales que se han utilizado para entrenar las redes neuronales, definidas en el anexo 1. El DPD de estas señales se ha calculado con el modelo polinomial y con el modelo CPWL con los umbrales uniformes.

Mejora del ACPR (dB) en simulación y experimentalmente				
	<i>Simulación</i>		<i>Laboratorio</i>	
	MPM	CPWL umbrales unif	MPM	CPWL umbrales unif
Señal 3	8,6	9,56	7,16	7,24
Señal 6	8,3	8,4	6,1	6,2
Señal 7	9	10,22	8,11	8,7

Tabla A.3: Comparativa de la mejora de ACPR entre el modelo MPM y el CPWL aplicado sobre las señales 3, 6 y 7 de la tabla A.1, comparando los resultados obtenidos en simulación frente a lo del laboratorio

C. Hojas de características

En este anexo se exponen las hojas de características de los dispositivos del sistema RoF.

- Amplificador de potencia (PA): ZHL-4240, Mini-Circuits.
- Amplificador de bajo ruido (LNA): ZX60-P33ULN+, Mini-Circuits.
- Diodo láser (LD): DFB-EAM-1550-12 S/N7075, Optilab.
- Diodo fotodetector (PD): PP-10G, Nortel Networks.

Coaxial Amplifier

ZHL-4240+

50Ω Medium High Power 600 to 4200 MHz

The Big Deal

- Wideband, 600 to 4200 MHz
- High gain, 39 dB
- Extremely flat gain, ± 1.3 dB
- High IP3, +38 dBm

Extended
Bandwidth
Covers Telecom
Band 71
(617 – 698 MHz)



Product Overview

Mini-Circuits' ZHL-4240+ is a medium-power connectorized amplifier supporting a wide range of applications from 600 to 4200 MHz, such as test instrumentation, SatCom, and mobile communications systems, including those operating in the new telecom Band 71 allocation (617 to 698 MHz). This model provides +31 dBm output power at saturation and extremely flat gain (39 ± 1.3 dB) across its full bandwidth, making it ideal for systems where consistent performance across frequency is required. The amplifier operates on a 15V DC supply and comes housed in compact aluminum alloy case (7.00 x 3.25 x 2.13") with SMA connectors, built-in bracket for mounting, and an optional heat sink for efficient cooling.

Key Features

Feature	Advantages
Wideband, 600 to 4200 MHz	One amplifier supports a broad range of system and test lab applications. Extended bandwidth down to 600 MHz supports new telecom Band 71 allocation (617 to 698 MHz)
High gain, 39 dB	Reduces the number of gain stages, lowering component count and overall system cost.
Excellent gain flatness, ± 1.3 dB	Provides consistent performance across frequency, minimizing the need for external equalizing networks in wideband applications.
Medium output power, +31 dBm P3dB	Supports a wide range of power requirements.
High OIP3, +38 dBm	Provides highly linear performance with excellent sensitivity and two-tone spur-free dynamic range.

Notes

- A. Performance and quality attributes and conditions not expressly stated in this specification document are intended to be excluded and do not form a part of this specification document.
B. Electrical specifications and performance data contained in this specification document are based on Mini-Circuit's applicable established test performance criteria and measurement instructions.
C. The parts covered by this specification document are subject to Mini-Circuits standard limited warranty and terms and conditions (collectively, "Standard Terms"). Purchasers of this part are entitled to the rights and benefits contained therein. For a full statement of the Standard Terms and the exclusive rights and remedies thereunder, please visit Mini-Circuits' website at www.minicircuits.com/MCStore/terms.jsp



www.minicircuits.com P.O. Box 350186, Brooklyn, NY 11235-0003 (718) 934-4500 sales@minicircuits.com

Page 1 of 4

Coaxial Amplifier

ZHL-4240+


50Ω Medium High Power 600 to 4200 MHz

Features

- wideband, 600 to 4200 MHz
- high IP3, +38 dBm typ.
- high gain, 39 dB min.

Applications

- communication systems
- satellite dist./GPS/PCS
- instrumentation
- laboratory



ZHL-4240X+

ZHL-4240+

CASE STYLE: U36

Connectors	Model
SMA	ZHL-4240+
SMA	7H1 -d240X+

+RoHS Compliant

The +Suffix identifies RoHS Compliance. See our web site for RoHS Compliance methodologies and qualifications

Electrical Specifications at 25°C

Parameter	Condition (MHz)	ZHL-4240+ + ZHL-4240X+			Units
		Min.	Typ.	Max.	
Frequency Range		600	—	4200	MHz
Gain	600-4200	39	42	47	dB
Gain Flatness	600-4200	—	±1.3	±1.8	dB
Output Power at 1dB compression*	600-4200	+28	+30	—	dBm
Output Power at 3dB compression**	600-4200	+29	+31	—	dBm
Noise Figure	600-4200	—	8.0	—	dB
Output third order intercept point	600-4200	—	+38	—	dBm
Input VSWR	600-4200	—	—	2.5	:1
Output VSWR	600-4200	—	—	2.5	:1
DC Supply Voltage		—	15	—	V
Supply Current		—	—	1.0	A

Open load is not recommended, potentially can cause damage.

With no load denote max. input power by 20 dB.

* +27 dBm at 3700-4200 MHz

** +28 dBm at 3700-4200 MHz

*Heat sink not included. Alternative heat sinking and heat removal must be provided by the user to limit maximum base-plate temperature to 65°C, in order to ensure proper performance. For reference, this requires thermal resistance of user's external heat sink to be 1.3°C/W max.

Maximum Ratings

Parameter	Ratings
Operating Temperature	-20°C to 65°C
Storage Temperature	-55°C to 100°C
DC Voltage	+20V
Input RF Power (no damage)	-5 dBm

Permanent damage may occur if any of these limits are exceeded.

Notes

A. Performance and quality attributes and conditions not expressly stated in this specification document are intended to be excluded and do not form a part of this specification document.

B. Electrical specifications and performance data contained in this specification document are based on Mini-Circuits' applicable established test performance criteria and measurement instructions.

C. The parts covered by this specification document are subject to Mini-Circuits standard limited warranty and terms and conditions (collectively, "Standard Terms"). Purchasers of this part are entitled to the rights and benefits contained therein. For a full statement of the Standard Terms and the exclusive rights and remedies thereunder, please visit Mini-Circuits' website at www.minicircuits.com/MCStore/terms.jsp




www.minicircuits.com P.O. Box 350166, Brooklyn, NY 11235-0003 (718) 934-4500 sales@minicircuits.com


REV. A
M10702
ZHL-4240+
CH/CP/AM
180507

Page 2 of 4

Outline Drawing for models with heatsink



MOUNTING INFORMATION FOR MODELS WITHOUT HEATSINK



Outline Dimensions (inch / mm)

A	B	C	D	E	F	G	H	J	K	L	M	N	P	Q	R	S	wt
7.00	3.25	2.13	.25	6.500	.38	2.500	.156	.73	.88	.63	1.13	2.23	.125	.50	6.00	2.23	grams
177.80	82.55	54.10	6.35	165.10	9.65	63.50	3.96	18.54	22.35	16.00	28.70	56.64	3.18	12.70	152.40	56.64	900

*600 grams without heatsink

Notes







- Performance and quality attributes and conditions not expressly stated in this specification document are intended to be excluded and do not form a part of this specification document.
- Electrical specifications and performance data contained in this specification document are based on Mini-Circuit's applicable established test performance criteria and measurement instructions.
- The parts covered by this specification document are subject to Mini-Circuits standard limited warranty and terms and conditions (collectively, "Standard Terms"). Purchasers of this part are entitled to the rights and benefits contained therein. For a full statement of the Standard Terms and the exclusive rights and remedies thereunder, please visit Mini-Circuits' website at www.minicircuits.com/MCStore/terms.jsp



www.minicircuits.com P.O. Box 350166, Brooklyn, NY 11235-0003 (718) 934-4500 sales@minicircuits.com

Page 3 of 4

FREQUENCY (MHz)	GAIN (dB)	DIRECTIVITY (dB)	VSWR (:1)		POUT at 1 dB COMPR. (dBm)	POUT at 3 dB COMPR. (dBm)	NOISE FIGURE (dB)	IP3 (dBm)
	15V	15V	IN	OUT	15V	15V	15V	15V
600	44.37	50.13	1.53	1.50	31.45	31.91	8.03	48.11
950	42.33	66.82	1.47	1.75	31.74	31.65	7.71	46.30
1200	41.86	73.44	1.50	2.02	31.68	31.74	7.94	45.16
1450	42.94	61.55	1.46	2.23	31.11	30.91	7.82	41.23
1700	42.88	53.56	1.34	1.88	30.20	30.43	7.76	41.89
1950	42.31	56.25	1.20	1.68	30.30	31.36	7.82	49.01
2200	41.69	61.87	1.11	1.61	30.92	32.04	7.71	47.98
2450	42.63	60.47	1.12	1.62	30.94	31.70	7.87	44.99
2700	42.44	60.33	1.19	1.88	31.93	32.09	8.08	45.51
2950	42.74	70.24	1.21	2.00	31.01	32.06	8.15	53.12
3200	42.34	49.82	1.08	2.04	32.03	32.40	7.88	47.31
3450	41.71	54.55	1.34	1.98	32.65	32.59	8.03	47.97
3700	42.00	50.76	1.34	1.73	31.82	32.14	8.22	48.81
3950	42.15	50.28	1.25	1.24	30.66	31.30	8.32	45.68
4200	41.78	45.95	1.25	1.51	29.13	29.78	8.54	39.05
4200	41.78	45.95	1.25	1.51	29.13	29.78	8.54	39.05



Notes

- Performance and quality attributes and conditions not expressly stated in this specification document are intended to be excluded and do not form a part of this specification document.
- Electrical specifications and performance data contained in this specification document are based on Mini-Circuits' applicable established test performance criteria and measurement instructions.
- The parts covered by this specification document are subject to Mini-Circuits' standard limited warranty and terms and conditions (collectively, "Standard Terms"). Purchasers of this part are entitled to the rights and benefits contained therein. For a full statement of the Standard Terms and the exclusive rights and remedies thereunder, please visit Mini-Circuits' website at www.minicircuits.com/MCStore/terms.jsp





Mini-Circuits

COAXIAL

Low Noise Amplifier

ZX60-P33ULN+

50Ω 0.4 to 3.0 GHz SMA Female

THE BIG DEAL

- Ultra Low Noise Figure, 0.38 dB typ.
- High Dynamic Range
- Ultra small connectorized package
- Protected by US patent 6,790,049

APPLICATIONS

- Base station infrastructure
- Portable Wireless
- LTE
- GPS
- GSM
- Airborne radar



Generic photo used for illustration purposes only

Model No.	ZX60-P33ULN+
Case Style	GC957
Connectors	SMA Female

+RoHS Compliant

The + Suffix identifies RoHS Compliance.
See our website for methodologies and qualifications.

PRODUCT OVERVIEW

The ZX60-P33ULN+ (RoHS compliant) uses Mini-Circuits' E-pHEMT technology to offer ultra low noise figure over a broad frequency range and high IP3. Housed in a rugged, cost effective unibody chassis, this amplifier supports a wide variety of applications requiring moderate power output, low distortion and 50 ohm matched input/output ports.

KEY FEATURES

Feature	Advantages
Ultra Low Noise Figure, 0.38 dB at 0.9 GHz	Outstanding world class noise figure performance.
High IP3 vs. DC power consumption +34 dBm typical at 0.9 GHz +38 dBm typical at 3 GHz	Combining Low Noise and High IP3 makes this model ideal for use in Low Noise Receiver Front End (RFE)
Max. Input Power, +14 to +22 dBm (continuous)	Ruggedized design operates to high input powers often seen at receiver inputs.
Very Small Size, 0.75" x 0.74"	The unique unibody size and construction enable the ZX60-P33ULN+ to be used in extremely compact connectorized applications.



www.minicircuits.com P.O. Box 350166, Brooklyn, NY 11235-0003 (718) 934-4500 sales@minicircuits.com

REV. C
ECO-016369
ZX60-P33ULN+
SH/CPIAM
221129
PAGE 1 OF 4



Mini-Circuits

COAXIAL

Low Noise Amplifier **ZX60-P33ULN+**

50Ω 0.4 to 3.0 GHz SMA Female

ELECTRICAL SPECIFICATIONS AT 25°C AND +3.0V, UNLESS NOTED OTHERWISE

Parameter	Condition (GHz)	Min.	Typ.	Max.	Units
Frequency Range		0.4		3.0	GHz
Noise Figure	0.4		0.43		
	0.9		0.38		
	1.5		0.46	0.70	
	2.0		0.49		
	3.0		0.90		dB
Gain	0.4		24.5		
	0.9	17.3	19.0	21.1	
	1.5		14.8		
	2.0		12.4		
	3.0		8.8		dB
Output Power at 1dB Compression	0.4		17.3		
	0.9		17.4		
	1.5	15.5	17.4		
	2.0		17.6		
	3.0		17.5		dBm
Output IP3	0.4		30.3		
	0.9		33.6		
	1.5	30.6	35.3		
	2.0		36.2		
	3.0		38.0		dBm
Input VSWR	0.4		1.90		
	0.9		1.90		
	1.5		1.90		
	2.0		1.90		
	3.0		1.80		:1
Output VSWR	0.4		1.20		
	0.9		1.20		
	1.5		1.30		
	2.0		1.30		
	3.0		1.30		:1
Active Directivity (Isolation-Gain)	0.4 - 3.0		4		dB
DC Supply Voltage		—	3.0	—	V
Supply Current		—	56	67	mA


www.minicircuits.com P.O. Box 350166, Brooklyn, NY 11235-0003 (718) 934-4500 sales@minicircuits.com

PAGE 2 OF 4



Mini-Circuits

COAXIAL

Low Noise Amplifier

ZX60-P33ULN+


50Ω 0.4 to 3.0 GHz SMA Female

ABSOLUTE MAXIMUM RATINGS

Parameter	Ratings
Operating Temperature	-40°C to 85°C Case
Storage Temperature	-55°C to 100°C
DC Voltage	+5.5V
Input RF Power (no damage)	+27 dBm (5 minutes max.) +14 dBm to 1.5 GHz and +22 dBm over 1.5 to 3 GHz (continuous)
Power Consumption	0.5W

Permanent damage may occur if any of these limits are exceeded.

OUTLINE DRAWING



⚠ NOTE: When soldering the DC connections, caution must be used to avoid overheating the DC terminal. See Application Note. AN-40-010.

OUTLINE DIMENSIONS (Inches)

A	B	C	D	E	F	G	H	J	K	L	M	N	P	Q	R	wt
.74	.75	.46	1.18	.04	.17	.45	.59	.33	.21	.22	.14	1.00	.37	.18	.106	grams
18.80	19.1	11.68	30.0	1.02	4.32	11.4	14.99	8.38	5.33	5.59	3.56	25.40	9.40	4.57	2.69	23.0

Mini-Circuits

www.minicircuits.com P.O. Box 350166, Brooklyn, NY 11235-0003 (718) 934-4500 sales@minicircuits.com

PAGE 1 OF 4



Mini-Circuits

COAXIAL







Low Noise Amplifier

ZX60-P33ULN+

50Ω 0.4 to 3.0 GHz SMA Female

TYPICAL PERFORMANCE DATA/CURVES

Frequency (MHz)	Gain (dB)	Directivity (dB)	VSWR (:1)		Power Out @ 1 dB COMPR. (dBm)	Noise Figure (dB)	Output IP3 (dBm)
			IN	OUT			
400.0	24.06	3.7	1.9	1.2	17.3	0.43	30.3
900.0	18.71	3.4	1.9	1.2	17.5	0.38	33.6
1500.0	14.52	3.7	1.9	1.3	17.4	0.46	35.3
2000.0	12.10	3.9	1.9	1.3	17.6	0.49	36.2
3000.0	8.49	4.7	1.8	1.3	17.5	0.90	38.0



NOTES

- Performance and quality attributes and conditions not expressly stated in this specification document are intended to be excluded and do not form a part of this specification document.
- Electrical specifications and performance data contained in this specification document are based on Mini-Circuits' applicable established test performance criteria and measurement instructions.
- The parts covered by this specification document are subject to Mini-Circuits standard limited warranty and terms and conditions (collectively, "Standard Terms"); Purchasers of this part are entitled to the rights and benefits contained therein. For a full statement of the standard. Terms and the exclusive rights and remedies thereunder, please visit Mini-Circuits' website at www.minicircuits.com/terms/viewterm.html


www.minicircuits.com P.O. Box 350166, Brooklyn, NY 11235-0003 (718) 934-4500 sales@minicircuits.com

PAGE 4 OF 4



DFB-1550-EAM-12



EAM DFB Laser Diode, 12 GHz, 5 mW

OVERVIEW

The Optilab DFB-1550-EAM-12 laser diode is a cost effective and compact laser solution for optical transmission applications. Consisting of a DFB laser with an integrated Electro-Absorption Modulator (EAM), this allows for modulation speeds of over 12 GHz on one 7-pin butterfly package device. Including a thermoelectric cooler (TEC), temperature thermistor, optical isolator and a GPO RF connector. Contact Optilab for more information.


FEATURES

- 1550 nm DFB + EAM Modulator
- Hermetic, 7 pin butterfly package
- Single-mode fiber pigtail
- 12 GHz bandwidth
- 5 mW output power
- TEC Cooler

APPLICATION

- Optical Communication
- RFoF
- Microwave Link
- Pulse Source

FUNCTION DIAGRAM





DFB-1550-EAM-12

SPECIFICATIONS

GENERAL

Wavelength Range	1532nm $\pm$ 2nm
Output Power	5 mW typ.
Extinction Ratio	10 dB min.
Side Mode Suppression Ratio	40 dB min.
Optical Isolation	30 dB min.
Operating Current	100 mA max.
Threshold Current	15 mA typ.
Forward Voltage	2 V max.
Modulation Bandwidth	12 GHz min.
Rise/Fall Time	40 ps max.
Monitor Current	0.1 mA min.
Thermistor Resistance	10 k Ω typ.
TEC Voltage	2.5 V max.
TEC Current	1.2 V max.
TEC Power	3 W max.

MECHANICAL

Operating Case Temperature	-40 °C to +70 °C
Storage Temperature	-50 °C to +85 °C
Optical Connector	FC/APC
Fiber Type	SMF-28, 900 μ m buffer
RF Connector	GPD




Product specifications and description are subject to change without notice. © 2020 Optilab, LLC. DFB-1550-EAM-12. June 2020 Rev. 1.1

Page 2




DFB-1550-EAM-12

MECHANICAL DRAWING




TYPICAL S21 BANDWIDTH



High Performance Optical Component Solutions

DATASHEET



PP - 10G

10Gb/s PIN Preamp Receiver

Features

Low capacitance high speed
InGaAs PIN detector.

GaAs HBT preamp IC chip.

Single polarity power supply.

11GHz bandwidth.

Wide dynamic range.

Hermetically sealed.

Bellcore TR-NWT-000468
compliant.

Applications

Long and short reach SONET/SDH systems


Optically preamplified receivers

Datacom systems up to 12.5 Gb/s

Description

The PP-10G module consists of a low
capacitance photodetector and a low
noise GaAs transimpedance amplifier in

an hermetic package with a connectorized
single-mode fibre pigtail and a 50 Ω SMA
electrical output.



NORTEL
NETWORKS™

PP - 10G

Characteristics

Over entire temperature range, at end-of-Life

General	Min	Typ	Max	Unit
NRZ data rate		10		Gb/s
Operating case temperature	0		70	°C
Physical dimensions		30 x 19 x 13.6		mm
SM fibre pigtail connector options		Standard SC-PC, Custom ST-PC, FC-PC		

Performance	Symbol	Min	Typ	Max	Unit
Module PIN bias voltage	V_{in}	9.5	11.5	13.5	V
Positive supply	V_{cc}	7.5	8	8.5	V
Power dissipation	P_d		1	1.6	W
PIN responsivity (1)	R		0.88		A/W
PIN responsivity (5)	R		0.83		A/W
Responsivity variation with temperature 0°C to 70°C			5		%
Dark current (25°C)	I_d			10	nA
Optical connector loss			0.3		dB
Sensitivity (2)		-18	-19		dBm
Optical saturation power ($BER < 10^{-4}$)	P_{sat}	0			dBm
Average input equivalent noise current density 30kHz - 10GHz	I_n			16.5	pA/√Hz
High frequency -3dB corner (3)			11		GHz
Transimpedance gain (3,4)	TZG	400	500	650	Ohms
Trans. gain variation with supply voltage and temperature (3)		-15		+15	%
Output return loss (3) 100kHz - 8GHz		10			dB


Notes :

1. Excluding optical connector loss. Optical wavelength is in the 1300nm region and between 1525 - 1575nm.
2. For 10^{-10} BER, PRBS $2^{23}-1$. NRZ @10Gb/s
3. Load impedance is 50Ω with a return loss > 20dB, up to 20GHz.
4. Excluding PIN responsivity factor and connector loss.
5. Excluding optical connector loss. Optical wavelength is in the range 1576 - 1610nm.

PP - 10G
10Gb/s PIN Preamp Receiver

Outline Drawing

Dimensions in mm



Instructions for Use - PP-10G

Pin 1 PIN Bias

A DC voltage, between 9.5V and 13.5V, to reverse bias the PIN. This voltage should be present BEFORE the Positive Supply (pin 3) is applied to prevent the possibility of forward biasing the PIN (which will damage the device). Power down sequence is: pin 3, then pin 1. This pin should be decoupled externally to minimise conducted noise from the power rails.

Pin 2, 4, 5 Ground

Ground all pins for optimum performance.

Pin 3 Positive Supply

DC voltage between 7.5 and 8.5V provides power to the pre-amplifier IC. This pin should be decoupled externally to minimise conducted noise from the power rails. The source should be capable of supplying up to 150 mA.

SMA Electrical Output

Device output is via the SMA connector and should be delivered into a 50Ω load. There is a DC offset of approximately 3V on this pin, so most applications will require that the output is AC coupled.

PP - 10G

Absolute Ratings

Parameter	Symbol	Ratings	Units
Positive supply	V_{cc}	9	V
Operating temperature (1)	T_{op}	0 to 70	°C
Storage temperature (2)	T_{stg}	-50 to 70	°C
Maximum optical input (3)	P_o	10	dBm
Maximum module PIN bias voltage	V_m	15	V
Maximum peak module PIN current	I_m	3	mA
Minimum fibre bend radius		35	mm

Notes :

1. The operating temperature is defined as the temperature of the module case.
2. The storage temperature is defined as the ambient temperature.
3. The optical level that causes no damage to the module. Performance specified in this document is not guaranteed at this input power.

Device Ordering Information

PP - 10G (Standard connector SC/PC (C28B))

Connector type FC/PC = C33

A Qualification Test Report QR1317B is also available for this device

Nortel Networks Optical Components Ltd.

Brixham Road
Paignton
Devon
TQ4 7BE
United Kingdom
Tel: +44 1803 662106
Fax: +44 1803 662801

Email: opticalcomponents@nortelnetworks.com
www.nortelnetworks.com/components/

PB0095 ISSUE 2 July 2000

All data in this document is subject to change in accordance with Nortel Networks Corporation policy of continual product improvement. No data in this document is intended to be used in connection with any contract except as may be first confirmed in writing by Nortel Networks Corporation. The publication of information in this document does not imply freedom from patent or other rights of Nortel Networks Corporation or others.

© 2000 Nortel Networks. All rights reserved.

© Nortel Networks, Nortel Networks Logo, the Globemark and Unified Networks are trademarks of Nortel Networks.

Information in this document is subject to change without notice. Nortel Networks assumes no responsibility for errors that might appear in this document. Printed in England.

NORTEL
NETWORKS™

