Escola d'Enginyeria de Telecomunicació i Aeroespacial de Castelldefels

UNIVERSITAT POLITÈCNICA DE CATALUNYA

TREBALL FINAL DE GRAU

TÍTOL DEL TFG: Linealització d'un amplificador de potència pseudo-Doherty LMBA mitjançant models polinomials

TITULACIÓ: Grau en Enginyeria de Sistemes de Telecomunicació

AUTOR: Íngrid Segura Colomés

DIRECTOR: Pere Lluís Gilabert Pinal

DATA: 1 de febrer de 2024

Títol: Linealització d'un amplificador de potència pseudo-Doherty LMBA mitjançant models polinomials

Autor: Íngrid Segura Colomés

Director: Pere Lluís Gilabert Pinal

Data: 1 de febrer de 2024

Resum

Avui en dia les comunicacions sense fil tenen un paper molt important en el sector de les telecomunicacions degut a l'arribada de noves tecnologies com el 5G i les ciutats intel·ligents. La quantitat de dades que s'han d'enviar són elevades i per tant l'ample de banda necessari augmenta.

Un dels principals elements d'aquestes comunicacions sense fil són els amplificadors de potència (PA), ja que amplifiquen el senyal per a que arribi correctament al receptor. El principal problema d'aquests elements és el gran consum d'energia que utilitzen, per aprofitar els amplificadors al màxim es volen fer treballar de la manera més eficient possible. Això implica que l'amplificador funcioni en una zona no-lineal de manera que el senyal es distorsiona. Existeixen diferents solucions per aquest problema entre eficiència i linealitat, la solució més estesa avui en dia es la tècnica de predistorsió digital (DPD), la qual s'estudia en aquest treball.

La tècnica de predistorsió digital és una tècnica que modela el comportament de l'amplificador amb l'objectiu de linealitzar-lo. Per dur a terme aquesta linealització s'han estudiat diferents models matemàtics com el Memory Polynomial (MP), el Generalized Memory Polynomial (GMP) i el Decomposed Vector Rotation (DVR), aquests models s'han intentat combinar amb l'objectiu d'obtenir un millor resultat. També s'ha estudiat la tècnica de reducció DOMP la qual simplifica el número de coeficients de cada model.

S'ha fet un estudi dels resultats obtinguts utilitzant aquests models tenint en compte els diferents paràmetres que tenen i el número de coeficients. El programa que s'ha utilitzat ha estat el MATLAB. Tot seguit els millors models s'han ficat a prova mitjançant un entorn real de predistorsió digital els quals han complert les expectatives ja que compleixen la normativa 3GPP.

Títol: Linealització d'un amplificador de potència pseudo-Doherty LMBA mitjançant models polinomials

Autor: Íngrid Segura Colomés

Director: Pere Lluís Gilabert Pinal

Data: 1 de febrer de 2024

Resum

Today, wireless communications play a crucial role in the telecommunications sector due to the emergence of new technologies such as 5G and smart cities. The amount of data to be transmitted is high, leading to an increased need for bandwidth.

One of the key components in these wireless communications is Power Amplifiers (PA), as they amplify the signal to ensure it reaches the receiver correctly. However, a significant challenge with these elements is the high energy consumption they entail. To maximize the efficiency of amplifiers, efforts are made to operate them as efficiently as possible. This involves operating the amplifier in a non-linear region, causing signal distortion. Various solutions exist for balancing efficiency and linearity, with the most prevalent solution being the Digital Predistortion (DPD) technique, which is the focus of this study.

The Digital Predistortion technique models the amplifier's behavior to linearize it. Different mathematical models, such as Memory Polynomial (MP), Generalized Memory Polynomial (GMP), and Decomposed Vector Rotation (DVR), have been studied for this purpose. Attempts have been made to combine these models to achieve better results. The DOMP reduction technique, simplifying the number of coefficients in each model, has also been explored.

An analysis of the results obtained using these models has been conducted, considering various parameters and the number of coefficients. MATLAB has been used as the programming environment. Subsequently, the best models have been tested using a real digital predistortion environment, meeting expectations by complying with 3GPP standards.

Primerament m'agradaria agrair al Pere Lluís Gilabert, per l'ajuda constant en aquest treball i per tots els coneixements que m'ha ensenyat

També m'agradaria agrair als meus pares, la meva germana, la meva padrina i a tots els que ja no hi són per haver confiat en mi

Finalment a l'Aleix per la seva infinita paciència i per haver fet aquest camí molt més fàcil

ÍNDEX

CAPÍTOL 1. INTRODUCCIÓ 1
CAPITOL 2. PROBLEMES DE LINEALITAT EN AMPLIFICADORS DE POTÈNCIA 3
2.1.Eficiència 4
2.2. No-linealitat dels amplificadors de potència 6
2.3. Amplificadors altament eficients 11
2.3.1. Envelope Tracking (ET) 11
2.3.2. Doherty 13
2.3.3. Load Modulated Balanced Amplifier (LMBA) 14
2.4. Mètriques 14
2.5. DPD 16
CAPÍTOL 3. MODELAT COMPORTAMENTAL DEL PA 18
3.1. Models d'una sola etapa 18
3.1.1. Series Volterra 18
3.1.2. Memory Polynomial 19
3.1.3. Generalized Memory Polynomial 20
3.1.4. Decomposed Vector Rotation (DVR) 21
3.2. Iterative Learning Control 24
3.3. Extracció de coeficients 25
3.4. Models en cascada 28
3.5. DOMP 28
3.6. Identificació de paràmetres del DPD 30
CAPÍTOL 4. PRINCIPIS DEL DPD 33
CAPÍTOL 5. RESULTATS EXPERIMENTALS 35
5.1. Models comportamentals 35
5.1.1. Resultats amb Memory Polynomial 35
5.1.2. Resultats amb Generalized Memory Polynomial 35
5.1.3. Resultats amb Decomposed Vector Rotation 36
5.1.4. Resultats amb Decomposed Vector Rotation modificat 37
5.1.5. Resultats DOMP 38
5.1.6. Resultats en Cascada 39
5.1.7. Millors resultats 40
5.2. Banc de proves 41
5.3. DPD 42

CAPÍTOL 6. CONCLUSIÓ 47
CAPÍTOL 7. BIBLIOGRAFIA..... 49

ÍNDEX DE FIGURES

Figura 1.1 Tamany de la informació anual de la Global Datasphere [9] 1
Figura 2.1 Amplificador de potència 3
Figura 2.2 Corba d'un amplificador ideal i no-ideal..... 4
Figura 2.3 Linealitat versus eficiència [1]..... 6
Figura 2.4 Corba de la relació d'entrada-sortida d'un amplificador real..... 7
Figura 2.5 Distorsió del senyal en el domini del temps..... 7
Figura 2.6 Espectre test de dos tons en un amplificador de potència [2] 9
Figura 2.7 Densitat espectral de potència de l'entrada i sortida d'un amplificador de potència no-lineal [2] 10
Figura 2.8 Característiques AM-AM i AM - PM..... 11
Figura 2.9 Voltatge aplicat en un amplificador genèric 12
Figura 2.10 Voltatge aplicat en l'Envelope Tracking 12
Figura 2.11 Estructura de l'amplificador Envelope Tracking 13
Figura 2.12 Estructura de l'amplificador Doherty 13
Figura 2.13 Estructura de l'amplificador LMBA 14
Figura 2.14 Esquema amb gràfiques d'un DPD amb un PA..... 17
Figura 3.1 Esquema del Iterative Learning Control 24
Figura 3.2 Esquema del modelat comportamental 26
Figura 3.3 Esquema del modelat comportamental de dos models en cascada28
Figura 3.4 Esquema del procés d'identificació de paràmetres 31
Figura 4.1 Diagrama de bloc del DPD en el mètode directe..... 34
Figura 5.1 Corba dels models MP i GMP 36
Figura 5.2 Taula dels diferents retards en el DVR..... 37
Figura 5.3 Corbes dels models DVR modificat, DVR normal i GMP..... 38
Figura 5.4 Corbes del DVR i GMP amb i sense l'optimització del DOMP 39
Figura 5.5 Corbes dels models en cascada 40
Figura 5.6 Resultats de tots els models..... 41
Figura 5.7 Set-up del laboratori 42
Figura 5.8 Evolució del valor del NMSE de les combinacions en funció del número d'iteracions 43
Figura 5.9 Evolució del valor de l'EVM en funció del número d'iteracions..... 43
Figura 5.10 Espectre del senyal en la iteració 1 i 8 44
Figura 5.11 Corbes AM/AM en la iteració 1 i 8 45
Figura 5.12 Diagrama de constel·lació en la iteració 1 i 8 46
Figura 5.13 Corba AM-PM en la iteració 1 i 8..... 46

LLISTA D'ACRÒNIMS

4G Fourth Generation
5G Fifth Generation
ACEPR Adjacent Channel Error Power Ratio
ACPR Adjacent Channel Power Ratio
AM Amplitude Modulation
CO2 Carbon Dioxide
CPWL Canonical piecewise-linear function
CSP Control Signal Power
DC Direct Current
DOMP Doubly Orthogonal Matching Pursuit
DPD Digital Predistortion
DVR Decomposed Vector Rotation
ET Envelope Tracking
EVM Error Vector Magnitude
GMP Generalized Memory Polynomial
HD Harmonic Distortion
IDC International Data Corportation
ILC Iterartive Learning Control
IMD Intermodulation Distortion
IoT Internet of Things
LMBA Load Modulated Balanced Amplifier
LS Least Square
MP Memory Polynomial
NMSE Normalised Mean Square Error
OFDM Orthogonal Frequency-Division Multiplexing
PA Power Amplifier
PAE Power Added Efficiency
PAPR Peak to Average Power Ratio
PM Phase Modulation
RF Radio Frequency

CAPÍTOL 1. INTRODUCCIÓ

La revolució tecnològica en la que ens trobem aquests últims anys està provocant un increment exponencial de consum de dades. Durant el 2018 el volum total d'informació que es va utilitzar va augmentar a 33 Zettabytes (1 ZB equival a 1000 millons de Terabytes). Segons el IDC (International Data Corportation) es preveu que al 2025 aquesta xifra augmenti a 175 Zettabytes. Aquest fet es degut a l'arribada i implantació de tecnologies com el 5G i per tant la revolució de Internet of Things (IoT).

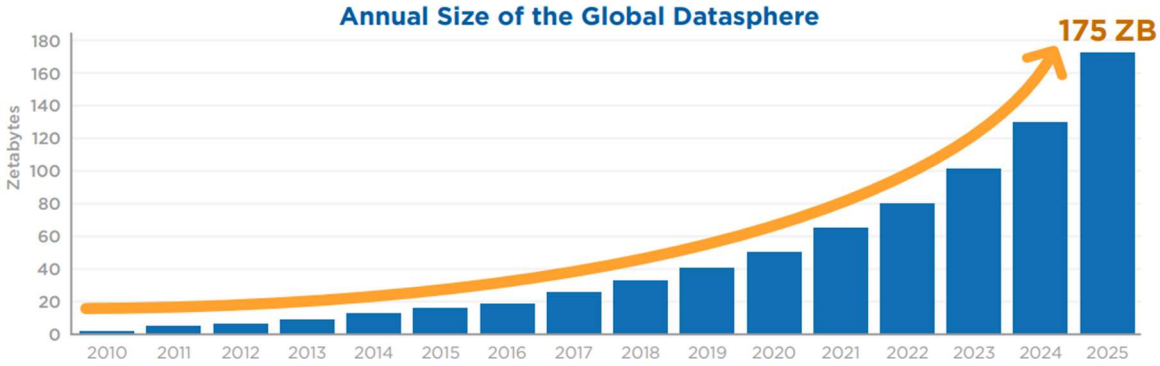

Figura 1.1 Tamany de la informació anual de la Global Datasphere [9]

Les noves implementacions requereixen que les connexions cada cop siguin més ràpides i estables. La tecnologia 5G destaca per 3 grans característiques: gran ample de banda; baixa latència, és a dir el temps de resposta de la transmissió d'informació és molt curt, i alta velocitat d'informació. És per aquest motiu que la implementació d'una taxa de transmissió major provoca la reducció de les emissions de diòxid de carboni (CO_2) en un 15% [10] ja que el seu ús tan sols requereix un 10% de l'energia que es necessita en el 4G.

Un dels elements més importants de les estacions bases és l'amplificador de potència (PA, Power Amplifier), la seva funció principal és amplificar el senyal amb l'objectiu que aquest arribi correctament al receptor. L'amplificador de potència és un element que consumeix molta energia, per tant sempre es fa treballar de la manera més eficient possible. El gran inconvenient es troba quan el PA treballa en la zona eficient ja que en aquesta zona apareixen comportaments no-lineals de manera que provoca distorsió. Per poder solucionar aquest compromís entre eficiència i no-linealitats s'han proposat diferents tècniques, tot i que en aquest treball s'explicarà en detall la tècnica de predistorsió digital (DPD, Digital Predistortion). La predistorsió digital és una tècnica que utilitza models matemàtics que modelen el comportament del PA per així linealitzar-lo.

L'objectiu d'aquest treball és ensenyar diferents models matemàtics que s'utilitzen per fer la predistorsió digital i tot seguit aplicar-los en un entorn real per

veure amb quin model s'obtenen millors resultats, és a dir, quin és el model que fa que l'amplificador sigui el més lineal possible.

Aquest treball consta de 6 capítols: en el capítol 2 s'explica el gran inconvenient sobre les no-linealitats dels amplificadors de potència, en el capítol 3 s'explica els diferents models matemàtics que s'han estudiat i una tècnica de reducció de coeficients aplicada en la part experimental, en el capítol 4 s'explica el funcionament del predistorsionador digital, en el capítol 5 es troba l'aportació d'aquest treball sobre els resultats dels diferents models aplicats al laboratori i finalment en el capítol 6 es troba la bibliografia amb tots els articles que s'han utilitzat.

CAPITOL 2. PROBLEMES DE LINEALITAT EN AMPLIFICADORS DE POTÈNCIA

Els amplificadors de potència (Power Amplifier, PA) són un dels elements més importants en les comunicacions sense fil. Quan es transmet un senyal, aquest s'atenua degut a diversos elements com poden ser la naturalesa o els edificis. A causa d'aquest fet, no arriba correctament el senyal a l'antena receptora i, fins i tot, pot arribar a no detectar-lo. Per tant, el PA s'encarrega d'augmentar la potència del senyal per a poder ser propagat per l'espai radioelèctric mitjançant una antena i que arribi al receptor correctament, sense augmentar el senyal de fora de la banda desitjada. És per això que els amplificadors són tan importants en les telecomunicacions. La figura amb què es representa un amplificador és la següent:

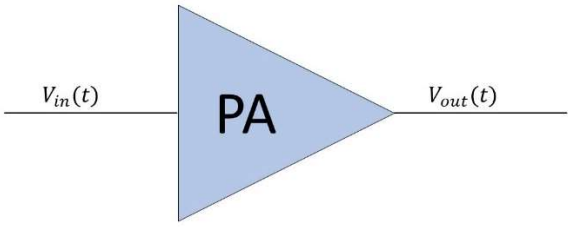

Figura 2.1 Amplificador de potència

El comportament d'un amplificador de potència ve donat per la següent fórmula (2.1) on $P_{in}(t)$ ens indica la potència del senyal d'entrada i $P_{out}(t)$ la potència del senyal de sortida. El guany g és el paràmetre principal de l'amplificador i ens indica quant amplifica el senyal d'entrada. Si el guany és més gran a 1 l'amplificador augmentarà la potència d'entrada, en canvi si és menor a 1 la disminuirà.

$$P_{out}(t) = g \cdot P_{in}(t) \qquad \textbf{(2.1)}$$

El comportament ideal d'un amplificador és una recta que manté la mateixa pendent. Tal i com indica el nom, és el comportament ideal ja que el comportament real és una corba la qual arriba un instant en que el senyal ja no s'amplifica. Aquest comportament no-ideal fa que es produeixi efectes no desitjats anomenats distorsió. En la figura 2.2 s'observa en color vermell el comportament ideal i en color blau el comportament real.

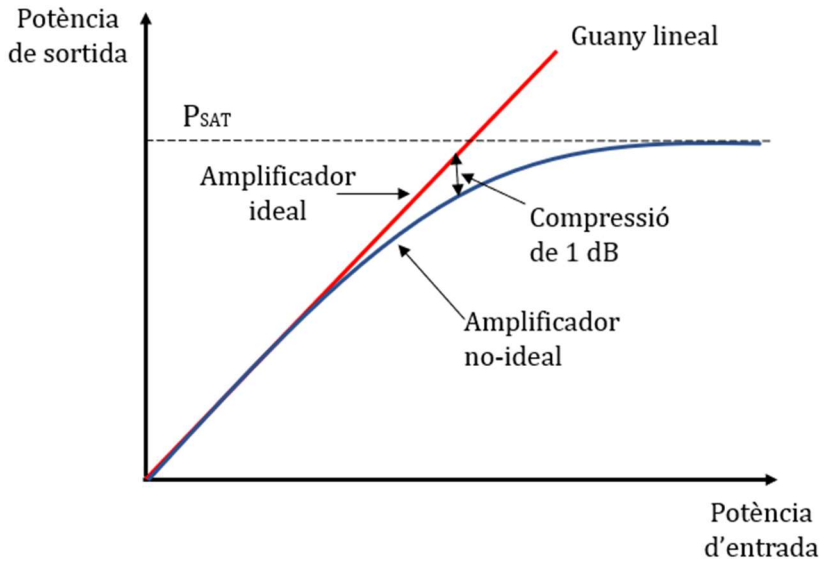

Figura 2.2 Corba d'un amplificador ideal i no-ideal

L'instant en què la corba ideal sobrepassa 1 dB per damunt la corba real s'anomena punt de compressió. Aquest ens indica el límit, ja que a partir d'aquest punt ja no s'amplifica més el senyal i es troba la zona de saturació. En el cas que el senyal es trobi pròxim a la zona de saturació apareixeran distorsions no desitjades. És per aquest motiu que és molt important trobar una solució a aquest problema de distorsió no-lineal ja que es vol treballar de la manera més eficient possible.

2.1.Eficiència

L'eficiència d'un amplificador és la relació entre la potència de sortida i la potència que alimenta l'amplificador, la qual és contínua. Es defineix de la següent manera:

$$\eta = \frac{P_{out}}{P_{DC}} [\%] \tag{2.2}$$

La 'power added efficiency' (PAE) ens dona el valor de l'eficiència, però tenint en compte el guany de l'amplificador.

$$PAE = \frac{P_{out} - P_{in}}{P_{DC}} [\%] \tag{2.3}$$

La forma més comuna d'expressar l'eficiència és la segona, la PAE. Tot i que en el cas que el guany sigui molt alt, els resultats obtinguts en les dos fórmules són molt similars, en canvi si el guany és baix els resultats són diferents.

D'altra banda, si el senyal té una envoltant variable, l'eficiència també serà variable. En aquest cas es calcula la mitjana de la potència de sortida i de la potència contínua.

$$\eta = \frac{P_{outAVG}}{P_{DCAVG}} [\%] \qquad \textbf{(2.4)}$$

El terme d'eficiència té molta importància en el camp dels amplificadors de potència ja que si el PA és més eficient podrà augmentar més el senyal, gastant menys energia. Per tant, també és molt important saber quan el PA és el més eficient possible. El PAPR (Peak to average power ratio) és crucial per poder entendre en quin punt treballar de manera més eficient. Es defineix com la relació entre la potència màxima i la potència mitja del senyal complex en pas banda. El back-off ens indica quant s'ha de disminuir el senyal d'entrada per a què la sortida no sobrepassi el punt de compressió. El punt en el qual s'ha de treballar per tal que sigui el més eficient possible és el punt de compressió a 1 dB.

Per a obtenir l'eficiència més alta és desitjable el PAPR més baix possible, atès que d'aquesta manera el back-off disminueix i es treballa just abans del punt de compressió on s'obté el senyal amplificat el més gran possible. En les següents imatges es pot observar que el punt més eficient és just on es troba el punt de compressió, per tant, per a què l'eficiència mitjana sigui el més alta possible es necessita el mínim PAPR possible.

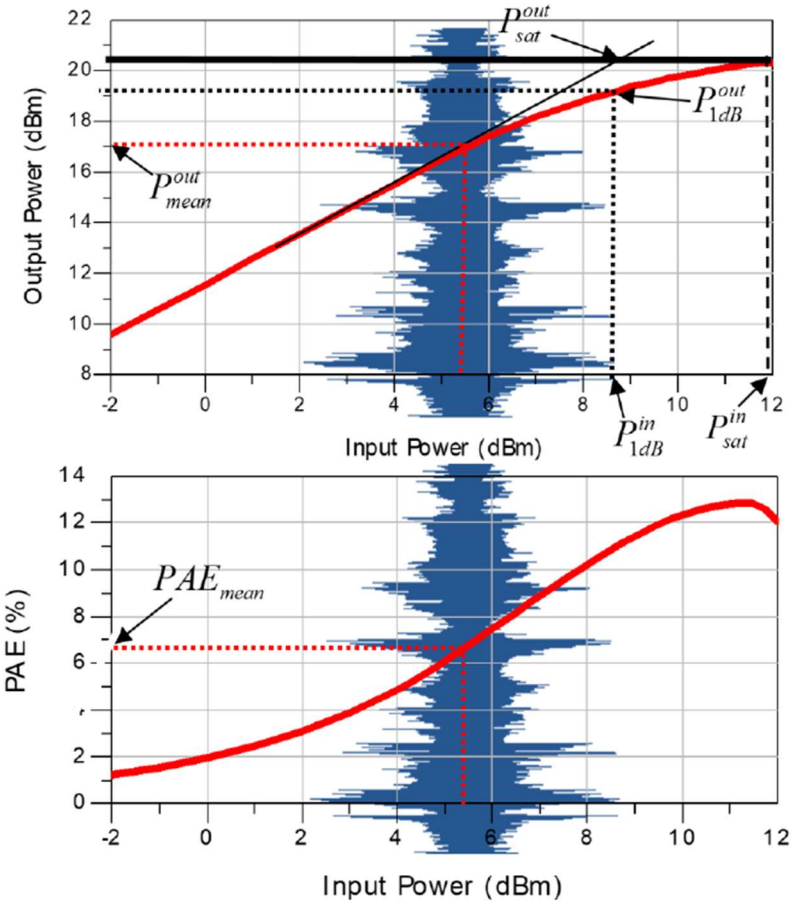

Figura 2.3 Linealitat versus eficiència [1]

2.2. No-linealitat dels amplificadors de potència

En els amplificadors es troben dos comportaments no desitjats, el comportament degut als efectes de memòria i els comportaments deguts a la no-linealitat.

Per una banda, es troben els efectes de memòria. Per un senyal d'entrada en un temps t_o el senyal de sortida que s'obté és el senyal en l'instant t_o i la suma del senyal de sortida en instants anteriors $t_o - 1$, $t_o - 2$, etc. Això és degut a què l'amplificador està compost per elements no-lineals els quals provoquen la reflexió del senyal. En la figura 2.4 s'observa en el gruix de la línia, ja què per una potencia de senyal determinada no sempre obtindrem el mateix resultat de sortida.

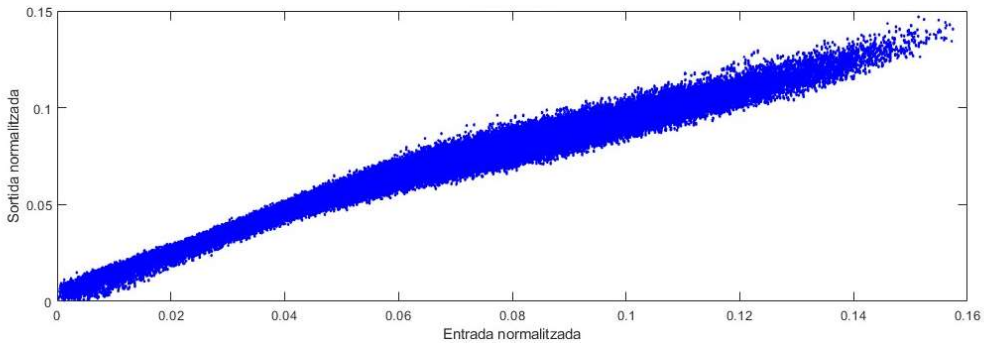

Figura 2.4 Corba de la relació d'entrada-sortida d'un amplificador real

D'altra banda, es troben els comportaments deguts a la no-linealitat de l'amplificador. Per un senyal sinusoidal, si l'amplificador segueix la recta de la imatge s'obtindrà el mateix senyal, però amplificat. En canvi, quan es treballa a prop de la zona de saturació seguint la corba no-lineal el senyal es talla i no s'obté sencer de manera que no s'aconsegueix tota la informació, aquest succés s'anomena clipping. En el domini del temps afecta, tal i com hem explicat i es veu en la figura 2.5, però en el domini freqüencial apareix l'efecte de recreixement espectral que s'explicarà a continuació.

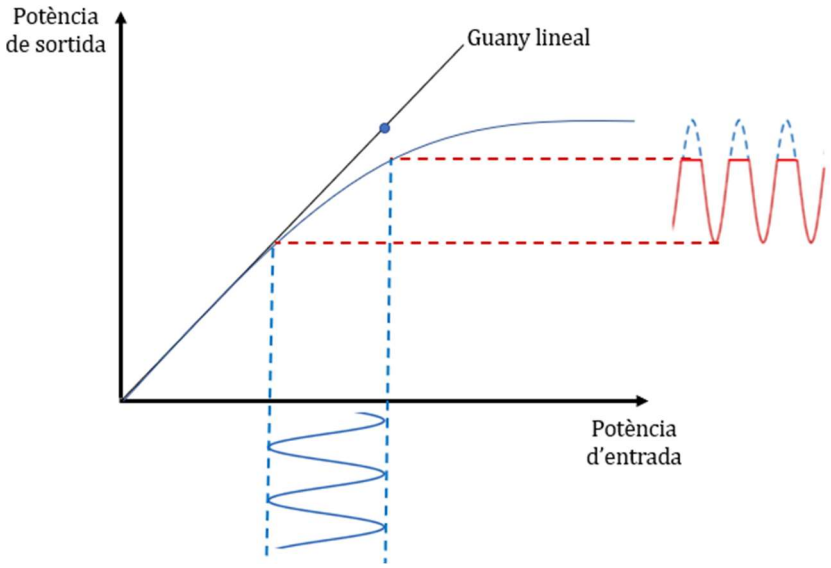

Figura 2.5 Distorsió del senyal en el domini del temps

Un amplificador de potència sense memòria es pot expressar matemàticament de la següent manera, on $v_{in}(t)$ és el senyal d'entrada, i $v_{out}(t)$ el de sortida.

$$v_{out}(t) \approx \sum_{k=1}^{\infty} g_k v_{in}^k(t) \qquad \textbf{(2.5)}$$

El primer terme d'aquesta sèrie és lineal, s'obté el senyal desitjat per tant $v_{out}(t)$ és la mateixa sinusoide que $v_{in}(t)$ però amplificada. Els ordres parells d'aquesta sèrie provoquen components freqüencials en les freqüències múltiples de la freqüència central. Aquestes freqüències que apareixen provoquen distorsió harmònica (Harmonic Distortion, HD), els components freqüencials es poden eliminar amb filtres. En canvi, els ordres impars són els responsables de què apareguin components freqüencials molt a prop de la banda en la qual es treballa i en aquest cas no es poden treure amb filtres. Aquests components introduïts per la intermodulació s'anomenen 'Intermodulation Distortion' (IMD), alguns components es troben directament dins de la banda de senyal provocant distorsió dins la banda de treball.

Per poder entendre més clarament quina distorsió s'introdueix per termes més grans d'ordre 1, ho veurem en aquest exemple que s'ha plantejat en [2] el qual consisteix en un test de dos tons separats entre ells per una freqüència Δf. El senyal d'entrada és el següent:

$$v_{in}(t) = V_1 \cos(\omega_1 t) + V_2 \cos(\omega_2 t) \tag{2.6}$$

$$\omega_1 = 2\pi\left(f_c - \frac{\Delta f}{2}\right), \omega_2 = 2\pi\left(f_c + \frac{\Delta f}{2}\right) \tag{2.7}$$

Per simplicitat només es tindran en compte els primers tres termes en 2.5. El senyal de sortida és el següent:

$$\begin{aligned} v_{out}(t) = {} & \frac{g_2 V_1^2}{2} + \frac{g_2 V_2^2}{2} + \\ & + V_1\left[g_1 + \frac{3g_3V_1^2}{4} + \frac{3g_3V_2^2}{2}\right]\cos(\omega_1 t) + \\ & + V_2\left[g_1 + \frac{3g_3V_2^2}{4} + \frac{3g_3V_1^2}{2}\right]\cos(\omega_2 t) + \\ & + \frac{g_2V_1^2}{2}\cos(2\omega_1 t) + \frac{g_2V_2^2}{2}\cos(2\omega_2 t) + \\ & + g_2V_1V_2\left[\cos\left((\omega_2 - \omega_1)t\right)\right] + \cos\left((\omega_2 + \omega_1)t\right) + \\ & + \frac{g_3V_1^3}{4}\cos(3\omega_1 t) + \frac{g_3V_2^3}{4}\cos(3\omega_2 t) + \\ & + \frac{3g_3V_1^2V_2}{4}\left[cos\left((2\omega_1 + \omega_2)t\right) + cos\left((2\omega_1 - \omega_2)t\right)\right] + \\ & + \frac{3g_3V_2^2V_1}{4}\left[cos\left((2\omega_2 + \omega_1)t\right) + cos\left((2\omega_2 - \omega_1)t\right)\right] \end{aligned} \tag{2.8}$$

En la sortida es pot observar com apareixen components espectrals no desitjades. Aquesta distorsió es pot classificar de dues maneres. Per una banda, els components que es troben en les freqüències centrals:

$$Compression\ at\ \omega_1 + \omega_1 - \omega_1 = \omega_1\ and\ \omega_2 + \omega_2 - \omega_2 = \omega_2$$

$$Capture\ at\ \omega_1 + \omega_2 - \omega_2 = \omega_1\ and\ \omega_2 + \omega_1 - \omega_1 = \omega_2$$

D'altra banda, els components freqüencials que es troben fora de la banda.

-La distorsió harmònica que pot ser classificada en:

-Distorsió harmònica de 2n ordre a $2\omega_1$ i $2\omega_2$
-Distorsió harmònica de 3r ordre a $3\omega_1$ i $3\omega_2$

-La distorsió d'intermodulació que es pot classificar en:

-Distorsió d'intermodulació de 2n ordre a $\omega_1 + \omega_2$ i $\omega_1 - \omega_2$
-Distorsió d'intermodulació de 3r ordre a $2\omega_1 + \omega_2$, $2\omega_1 - \omega_2$ i a $2\omega_2 + \omega_1$, $2\omega_2 - \omega_1$.

La següent imatge mostra l'espectre del test de dos tons. S'observa la distorsió harmònica i la distorsió d'intermodulació. Clarament la distorsió harmònica pot ser eliminada fàcilment ja que els components freqüencials es troben molt allunyades de la freqüència central, però la distorsió d'intermodulació es troba molt pròxima a la banda.

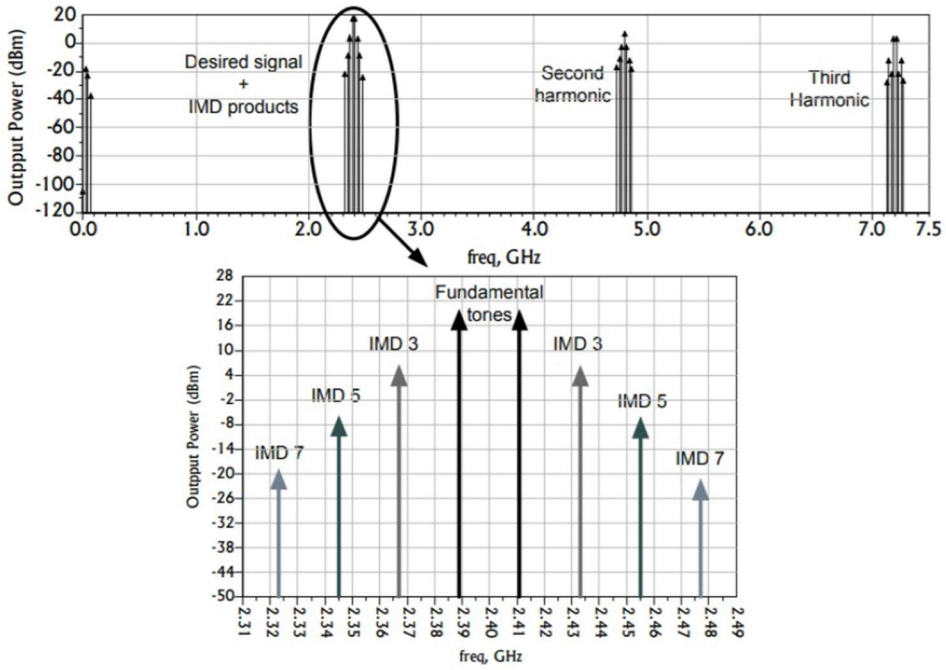

Figura 2.6 Espectre test de dos tons en un amplificador de potència [2]

En aquest test de dos tons discutit en [2], es pot observar les no-linealitats del comportament d'un amplificador de potència. En senyals modulats complexos, les no linealitats apareixen en una banda de freqüència continua com recreixement espectral. És molt important tenir controlat aquest recreixement espectral en l´ús comercial ja que s'ha de complir la normativa per així no molestar els canals adjacents. Per tenir-ho controlat es mesura mitjançant l'EVM (Error Vector Magnitude). En la figura 2.7 s'observa com apareix el recreixement espectral i ocupa les bandes adjacents.

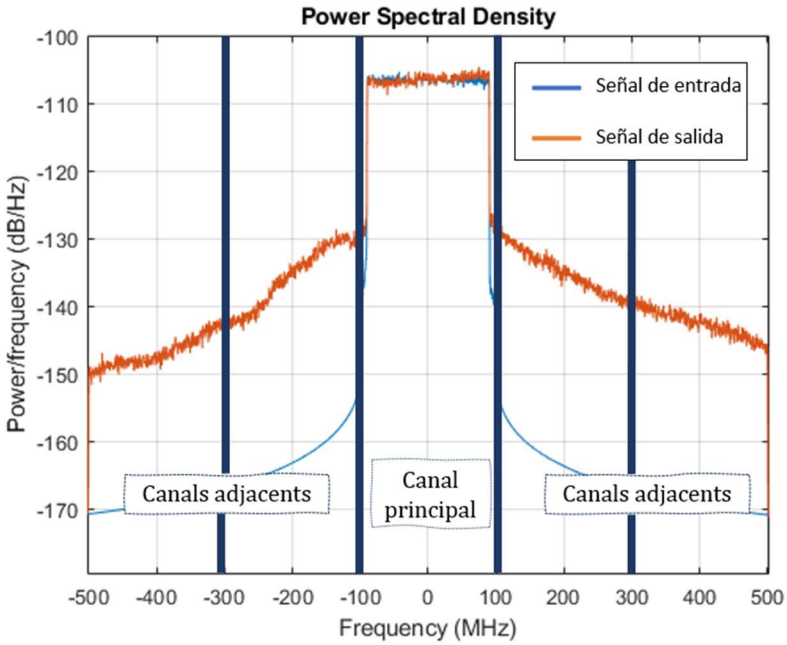

Figura 2.7 Densitat espectral de potència de l'entrada i sortida d'un amplificador de potència no-lineal [2]

Una mesura per poder observar els efectes de les no-linealitats dels amplificadors són les corbes AM-AM i AM-PM. La corba AM-AM és la conversió de la modulació d'amplitud del senyal d'entrada respecte la modulació d'amplitud modificada del senyal de sortida. La AM-PM és la conversió de la modulació d'amplitud del senyal d'entrada i la modulació de fase en el senyal de sortida.

Si considerem un amplificador de potència sense memòria pas banda amb un comportament no-lineal sent $v_{in}(t)$

$$v_{in}(t) = A(t)\cos[\omega_c t + \varphi(t)] \qquad \textbf{(2.9)}$$

El senyal de sortida distorsionat $v_{out}(t)$ es pot respresentar de la següent manera:

$$v_{out}(t) = G[A(t)]\cos\left[\omega_c t + \varphi(t) + \Phi[A(t)]\right] \quad \textbf{(2.10)}$$

On el senyal de sortida és una ona sinusoidal de freqüència ω_c, en la qual l'amplitud és una funció no-lineal de l'amplitud del senyal d'entrada $G[A(t)]$ i la fase també és una funció no-lineal de l'amplitud del senyal d'entrada $\Phi[A(t)]$. En la figura 2.8 s'observa com en alts nivells de potència del senyal d'entrada apareixen les distorsions tant en el guany com en la fase.

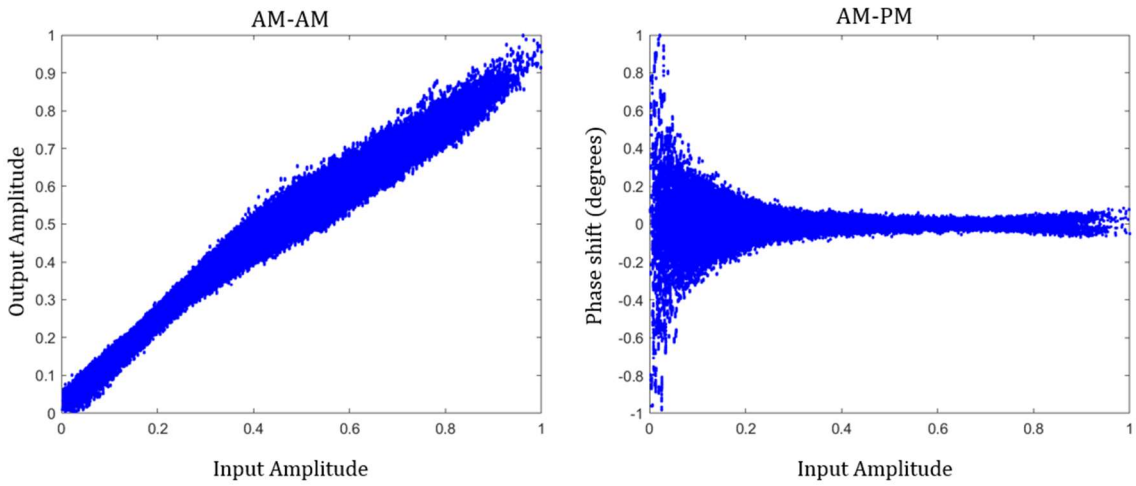

Figura 2.8 Característiques AM-AM i AM - PM

2.3. Amplificadors altament eficients

En el món dels amplificadors podem trobar-hi diferents classes, com amplificadors de classe A, B, C, etc. Però aquests no són tant eficients com es desitja, és per això que es van proposar diferents combinacions d'amplificadors que són altament eficients. En aquest treball s'explicarà tres amplificadors altament eficients: l'Envelope Tracking, l'amplificador Doherty i el Load Modulated Balanced Amplifier.

2.3.1. Envelope Tracking (ET)

L'objectiu del Envelope Tracking és obtenir la millor eficiència. Per a obtenir la millor eficiència possible s'ha de treballar el més pròxim al punt de compressió. L'Envelope Tracking té en compte l'envoltant del senyal de manera que modifica la font d'alimentació podent treballar sempre a prop del punt de compressió. Per exemple, si l'amplificador de potència està treballant a una potència baixa, la font d'alimentació disminuirà.

Aquest tipus d'amplificador és molt important en l'OFDM ja que hi ha molta diferència entre la potència mitjana i els pics. Si no s'utilitza l'Envelope Tracking en aquests casos, gran part de la potència no s'utilitzaria durant els instants de senyal baixos i seria dissipada, tal i com es pot observar en la imatge 2.9. En

canvi, si s'utilitza la tècnica d'Envelope Tracking la font d'alimentació es coordina amb el voltatge necessari de l'amplificador i d'aquesta manera es dissipa menys potència. En la imatge 2.10 s'observa com la font d'alimentació es coordina amb el voltatge necessari.

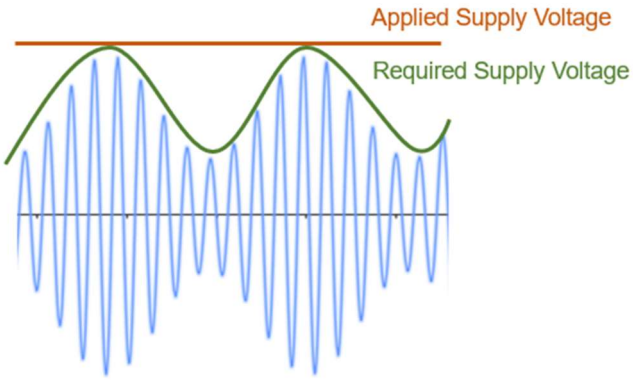

Figura 2.9 Voltatge aplicat en un amplificador genèric

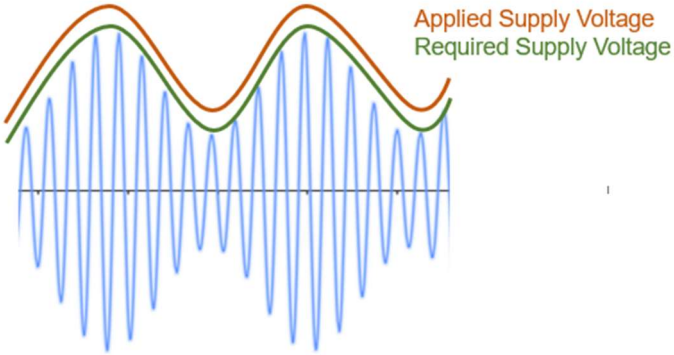

Figura 2.10 Voltatge aplicat en l'Envelope Tracking

L'estructura de l'Envelope Tracking consisteix en un amplificador que li entra un senyal en RF, el $V_{DD}(t)$ es troba controlat per l'envoltant i finalment obtenim la sortida amplificada de la manera més eficient possible.

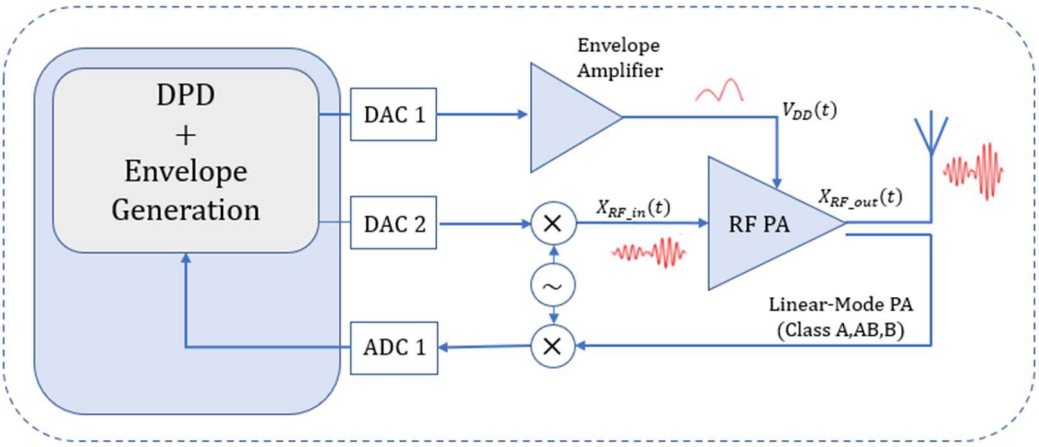

Figura 2.11 Estructura de l'amplificador Envelope Tracking [1]

2.3.2. Doherty

L'amplificador Doherty és famós per la seva gran eficiència, és per això que s'utilitza en estacions base. Va ser dissenyat per W.H.Doherty el 1936. Està compost per un splitter, dos amplificadors de potència i un combinador. Per una banda, hi ha l'amplificador principal (Carrier Amplifier) de classe AB i d'altra banda, l'amplificador secundari o de cresta (Peak Amplifier) de classe C.

El funcionament del Doherty és el següent: quan el senyal d'entrada és baix l'amplificador de cresta es troba apagat, de manera que tan sols funciona l'amplificador principal. A mesura que el senyal va creixent i arriba a prop del límit del punt de compressió, l'amplificador de cresta s'activa i amplifica junt amb el principal. Bàsicament el funcionament de l'amplificador Doherty consisteix en què l'amplificador principal amplifica la gran part del senyal de manera molt eficient, però quan hi ha senyals que requereixen més potència entra en joc l'amplificador secundari.

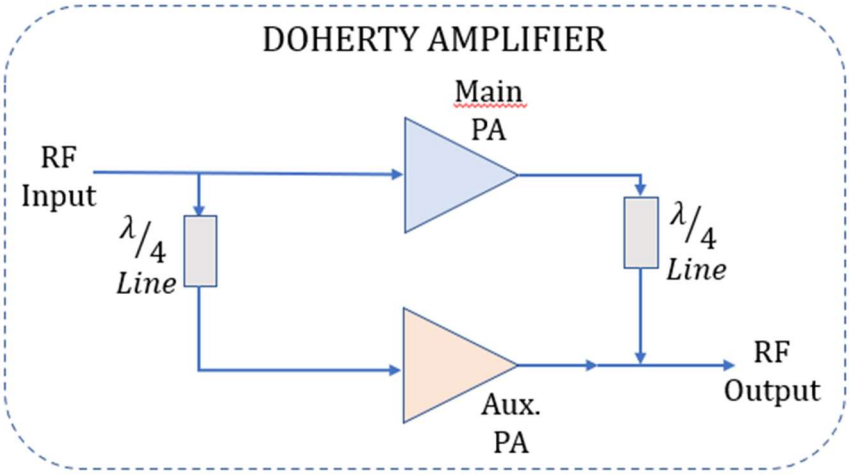

Figura 2.12 Estructura de l'amplificador Doherty

L'amplificador Doherty té distorsió no-lineal degut a la compressió de guany que apareix just després del canvi d'amplificadors. Aquesta distorsió es pot solucionar amb DPD.

2.3.3. Load Modulated Balanced Amplifier (LMBA)

El Load Modulated Balanced Amplifier (LMBA) va ser proposat per Shepphard. Està compost per un senyal de control de potència (Control Signal Power, CSP) el qual s'injecta pel port aïllat d'un acoplador de 90º de manera que la carga es modula en cada dispositiu equilibrat. Principalment es diferencia de l'amplificador Doherty perquè en el LMBA la recuperació de potència del CSP i la modulació de carga són independents. També es caracteritza per poder operar amb un gran ample de banda, la modulació de carga es pot aplicar per tota la banda freqüencial de l'acoplador de 90º, que és normalment més gran que l'ample de banda del Doherty.

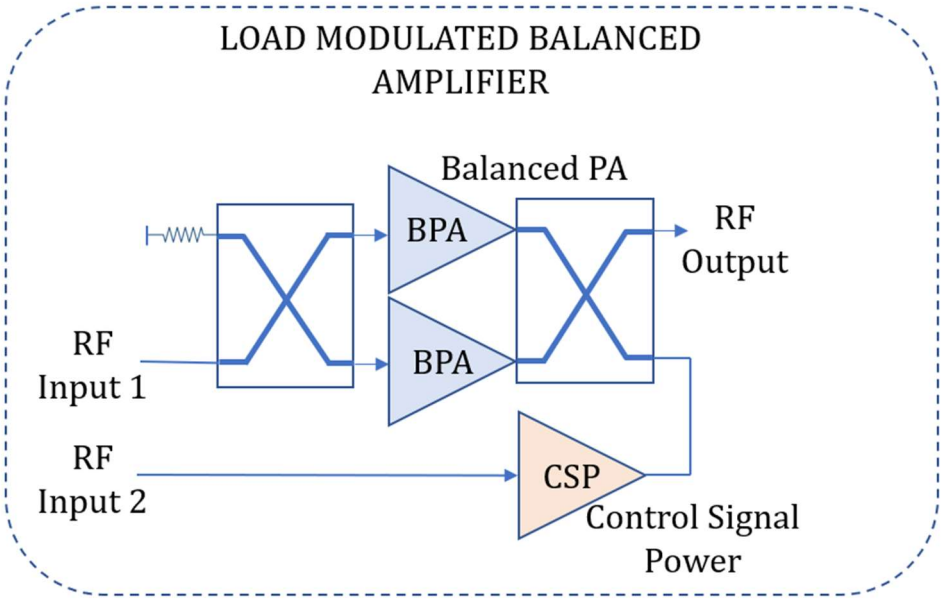

Figura 2.13 Estructura de l'amplificador LMBA [1]

2.4. Mètriques

Per poder calcular quant s'aproxima el model i així saber si un és més bo que l'altre es necessiten les mètriques que ens ho indiquen. Aquestes són: el "Normalised Mean Square Error" (NMSE), el "Adjacent Channel Power Error Ratio" (ACPER) i "el Adjacent Channel Power Ratio" (ACPR).

El NMSE es calcula amb la següent fórmula:

$$NMSE_{db} = 10log_{10}\left[\frac{\sum_{n=1}^{N}|y_{meas}(n) - y_{model}(n)|^2}{\sum_{n=1}^{N}|y_{meas}(n)|^2}\right] \quad \textbf{(2.11)}$$

On y_{meas} és la sortida mesurada a la sortida de l'amplificador, y_{model} és la sortida modelada pels coeficients que obtenim mitjançant el model seleccionat. Aquest paràmetre indica com de bé el model està imitant el senyal a la sortida de l'amplificador.

El ACPR és la relació entre la potència espectral que es troba en els canals adjacents i la potència espectral que es troba en l'ample de banda desitjat, es calcula amb la següent fórmula:

$$ACPR(dB) = 10log_{10}\sum_{k=1}^{K}\left|\frac{y_{out-band}(n)}{y_{in-band}(n)}\right|^2 \quad \textbf{(2.12)}$$

On $y_{out-band}$ fa referència a l'espectre de senyal fora de la banda i $y_{in-band}$ és l'espectre de senyal dins de la banda desitjada. Com més negatiu sigui l'ACPR menys espectre de senyal fora de la banda hi ha i més lineal és l'amplificador. Aquest paràmetre és molt important, ja que per poder transmetre un senyal s'ha de complir un valor mínim d'ACPR.

L'ACEPR (Adjacent Channel Error Power Ratio) és molt similar a l'ACPR, però amb un petit canvi. És la relació entre la potència espectral que es troba en els canals adjacents i la potència espectral desitjada en l'ample de banda determinat.

$$ACEPR(dB) = 10log_{10}\sum_{k=1}^{K}\left|\frac{y_{out-band}(n)}{y_{desired}(n)}\right|^2 \quad \textbf{(2.13)}$$

L'EVM (Error Vector Magnitude) és una mètrica de rendiment que es defineix en molts estàndards de comunicació, com les xarxes d'àrea local sense fils (WLA 802.11), comunicacions mòbils (4G LTE, 5G), etc. L'EVM mesura els efectes de la distorsió en l'amplitud i fase (és a dir, en els components en fase i en quadratura) del senyal de sortida modulat, és defineix com l'arrel quadrada de la relació entre la potència del vector d'error mitjà i la potència de referència expressada en percentatge.

$$EVM\ (\%) = \sqrt{\frac{\sum_{n=1}^{N}(\Delta I^2[n] + \Delta Q^2[n])}{\sum_{n=1}^{N}(I_{ref}^2[n] + Q_{ref}^2[n])}} \cdot 100 \quad \textbf{(2.14)}$$

On $\Delta I = I_{ref}[n] - I_{meas}[n]$, $\Delta Q[n] = Q_{ref}[n] - Q_{meas}[n]$. Sent $I_{meas}[n]$ i $Q_{meas}[n]$ en fase ($I_{meas}[n] = Re\{y_{demod}[n]\}$) i en quadratura ($Q_{meas}[n] = Im\{y_{demod}[n]\}$) components del senyal de sortida mesurat i demodulat del PA ($y_{demod}[n]$). N és el número de mostres.

2.5. DPD

Les tècniques de linealització són molt importants per poder millorar la linealització i l'eficiència. Existeixen 3 tipus: les tècniques Feedback, Feedforward i Digital Predistortion (DPD). En aquest treball ens centrarem en la predistorsió digital.

La predistorsió digital avui en dia és una tècnica molt popular degut a la seva gran eficiència. El funcionament es basa en obtenir una funció H, totalment inversa a la funció de la sortida de l'amplificador y(t), de manera que ambdues es contraresten i finalment s'obté la recta ideal de l'amplificador. D'aquesta manera estem fent que el PA amb el qual treballem sigui totalment lineal.

Matemàticament es pot formular de la següent manera:

$$x(t) = H^{-1}[y_d(t)] \tag{2.15}$$

$$y(t) = H[x(t)] = H\{H^{-1}[y_d(t)]\} \tag{2.16}$$

Si la funció inversa H^{-1} s'aproxima a la funció inversa de la funció de l'amplificador, la sortida de l'amplificador $y(t)$, s'aproximarà a la sortida desitjada $y_d(t)$.

En la següent figura s'observa el diagrama de blocs d'aquest procés, en primer lloc es troba el bloc de predistorsió digital i seguidament l'amplificador de potència. En les gràfiques s'observa com s'intenta aconseguir una recta lineal a partir de les dos corbes inverses.

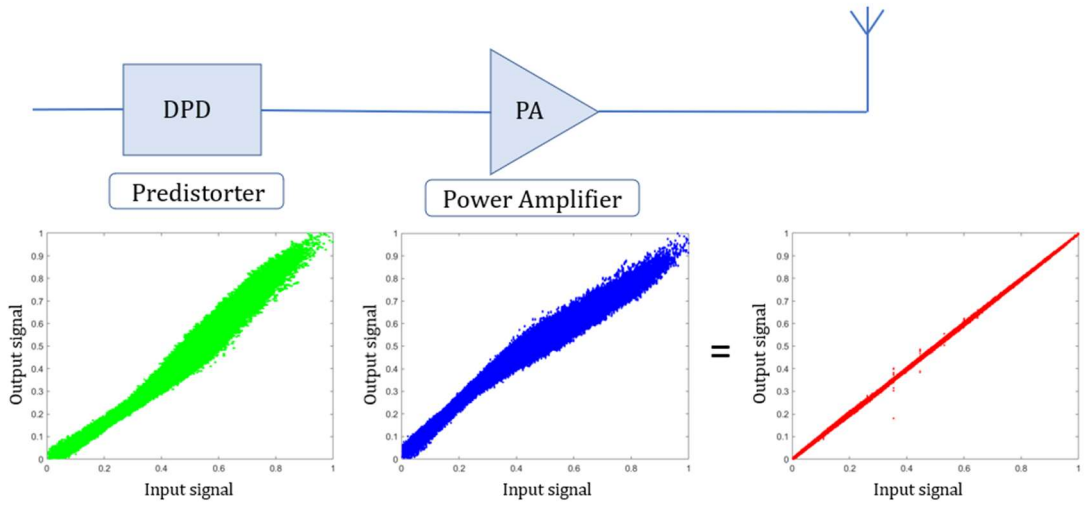

Figura 2.14 Esquema amb gràfiques d'un DPD amb un PA

La funció de predistorsió digital s'obté mitjançant diferents models que s'explicaran més endavant.

CAPÍTOL 3. MODELAT COMPORTAMENTAL DEL PA

El modelat d'amplificadors de potència ens serveixen per poder aconseguir un senyal idèntic al de la sortida d'un PA de manera que es pugui aplicar en el DPD i així corregir els problemes de sistemes no-lineals explicats anteriorment. Aquests models són representacions matemàtiques del comportament no ideal dels amplificadors, l'objectiu d'aquests és intentar imitar el comportament dinàmic d'un amplificador de potència. Aquests han de complir unes condicions específiques:

1. El model ha d'estar en el domini de temps discret per tal de facilitar la implementació en circuits digitals.
2. Ha de tenir en compte la no-linealitat i els efectes de memòria.
3. Ha de poder suportar senyals amb valors complexes ja que DPD normalment és en banda base.
4. El model ha de ser lineal en paràmetres, és a dir, la sortida del model ha de ser lineal amb els coeficients d'aquest.

Els models s'obtenen mitjançant l'entrada i sortida d'un amplificador. És molt important escollir bé un model pel correcte funcionament del predistorsionador digital. Genèricament les dades d'entrada i sortida, x i y, són senyals complexes en banda base.

3.1. Models d'una sola etapa

A continuació s'explicarà els models que s'han estudiat en aquest treball, és començarà pel model Volterra, seguidament el Memory Polynomial (MP), el Generalized Memory Polynomial (GMP) i finalment el Decomposed Vector Rotation (DVR).

Els models poden ser de dos tipus, els models amb memòria i sense memòria. Amb memòria tenen en compte que el senyal de sortida no tan sols depèn de l'entrada en aquell instant, sinó que els instants anteriors també tenen repercussió en el resultat. En aquest treball tots els models explicats són amb memòria.

3.1.1. Series Volterra

El 1887 Vito Volterra va proposar les Series Volterra com un model de comportament no-lineal. Les Series Volterra són molt útils per modelar sistemes no-lineals amb efectes de memòria. La forma general de les Series Volterra en discret és la següent:

$$y[n] = \sum_{p=1}^{P} \sum_{q_1=0}^{Q-1} \sum_{q_2=q_1}^{Q-1} \cdots \sum_{q_p=q_p-1}^{Q-1}, \cdots \qquad \textbf{(3.1)}$$

$$\sum_{q_{2p-1}=q_{2p-2}}^{Q-1} h_{2p-1}(q_1, q_2, \cdots, q_{2p-1}) \prod_{i=1}^{p} x[n-q_i] \prod_{j=p+1}^{2p-1} x^*[n-q_j] \quad \textbf{(3.2)}$$

On $y(n)$ és la mostra de sortida, $x(n)$ la mostra d'entrada, Q és el número de retards en cada nucli de P, P és l'ordre de memòria del sistema i $h_{2p-1}(q_1, q_2, \cdots, q_{2p-1})$ és un coeficient el qual és una funció que depèn de p i q_1 fins q_{2p-1}. Aquest model es capaç de modelar sistemes no-lineals amb efectes de memòria degut al gran número de coeficients relacionats amb cada combinació de cada mostra d'entrada i les mostres retardades de la mateixa mostra d'entrada. El gran inconvenient d'aquest model és el gran número de coeficients que es necessiten i el gran cost computacional que comporta, és per aquest motiu que s'han estudiat altres models més simples que provenen de les Series Volterra.

3.1.2. Memory Polynomial

Com s'ha observat en l'apartat anterior amb el model Volterra Series s'obtenen molts bons resultats ja que és capaç de modelar sistemes no lineals amb efectes de memòria, però el problema d'aquest és la seva complexitat i el seu gran nombre de coeficients. Per això, s'han estat estudiant diferents models més simples, un d'aquests models és el Memory Polynomial (MP).

Comparat amb el model Volterra Series, el Memory Polynomial redueix el número de coeficients considerablement i disminueix la dificultat d'extracció de paràmetres. El Memory Polynomial ve donat per:

$$y_{MP}(n) = \sum_{k=0}^{K-1} \sum_{m=0}^{M-1} h_{km} x(n-m) |x(n-m)|^k \quad \textbf{(3.3)}$$

On $y_{MP}(n)$ és la sortida; $x(n)$ és l'entrada, la qual és complexa; K és l'ordre de no-linealitat del sistema; M és l'ordre de memòria del sistema i h_{km} representa els coeficients els quals depenen del paràmetre 'k' i 'm'.

L'equació del MP consta de 3 parts: h_{km} és el coeficient que canvia segons els paràmetres 'k' i 'm'; $x(n-m)$ és el valor de l'entrada amb magnitud i fase, aquesta depèn de 'm' ja que recorre tot el vector $x(n)$ des de 0 fins $M-1$; $|x(n-m)|^k$ és l'envoltant del valor anterior elevat a 'k'.

Donat que el model està compost per una suma de coeficients i de mostres que estan amb retard i d'altres sense, la manera més eficient de representar-la és de forma matricial:

$$\boldsymbol{y} = \boldsymbol{X}\boldsymbol{w}_{\boldsymbol{MP}} \tag{3.4}$$

De manera no simplificada es representa de la següent manera:

$$\begin{bmatrix} y(n) \\ \vdots \\ y(n+N) \end{bmatrix} = \begin{bmatrix} x(n) & \cdots & x(n-m)|x(n-m)|^k \\ \vdots & \ddots & \vdots \\ x(n+N) & \cdots & x(n+N-m)|x(n+N-m)|^k \end{bmatrix} \begin{bmatrix} w_{00} \\ \vdots \\ w_{km} \end{bmatrix} \tag{3.5}$$

On $\boldsymbol{y}$ és un vector de $[Nx1]$, que conté els resultats que s'obtenen amb el MP, $\boldsymbol{w}_{\boldsymbol{MP}}$ és un vector de $[Ox1]$, format per tots els coeficients obtinguts i $\boldsymbol{X}$ és una matriu de $[NxO]$, on N és el nombre de mostres i O el nombre de coeficients del model, la qual conté totes les possibles combinacions, aquesta es nombrada la 'delay matrix'. Aquesta representació matricial es pot aplicar en tots els altres models.

3.1.3. Generalized Memory Polynomial

El Generalized Memory Polynomial (GMP) és un model que combina el Memory Polynomial amb termes creuats. És a dir, per cada dada del vector del MP té en compte les mostres que l'envolten, tant les anteriors com les posteriors. Destaca per la seva alta exactitud.

La fórmula del Generalized Memory Polynomial és la següent:

$$\begin{aligned} y_{GMP}(n) = & \sum_{m=0}^{M_a} \sum_{k=1}^{K_a} a_{mk} \cdot x(n-m) \cdot |x(n-m)|^{k-1} \\ & + \sum_{m=0}^{M_b} \sum_{k=2}^{K_b} \sum_{p=1}^{P} b_{mkp} \cdot x(n-m) \cdot |x(n-m-p)|^{k-1} \\ & + \sum_{m=0}^{M_c} \sum_{k=2}^{K_c} \sum_{a=1}^{Q} C_{mkq} \cdot x(n-m) \cdot |x(n-m+q)|^{k-1} \end{aligned} \tag{3.6}$$

La sortida $y_{GMP}(n)$ està composta per tres funcions. La primera funció és idèntica al Memory Polynomial, aquesta simplement té en compte un valor de tot el vector $x(n)$; La segona part de la fórmula té en compte l'envoltant dels P valors anteriors al valor nombrat en la primera funció; Finalment, la tercera funció té en compte l'envoltant dels Q valors posteriors del valor nombrat en la primera funció. a_{mk}, b_{mkp}, c_{mkq} són els coeficients calculats en cada una de les tres funcions.

En molts casos no es necessiten tots els coeficients calculats, ja que normalment els ordres imparells dominen en les no-linealitats.

3.1.4. Decomposed Vector Rotation (DVR)

Fins ara només s'han explicat mètodes que provenen del Volterra Series, però aquests tenen unes limitacions ja que tan sols són adequats per sistemes molt poc no-lineals i continus.

En molts amplificadors es troben problemes d'efectes no-lineals de memòria degut al control intern dels múltiples amplificadors, per això es necessita un model diferent al Volterra. El Decomposed Vector Rotation (DVR) és un model que prové de la funció CPWL (Canonical Piecewise-Linear Function). La funció CPWL es va proposar el 1970 per Chua, té una estructura molt simple i s'ha pogut comprovar que es pot utilitzar per funcions amb un rang molt ampli de discontinuïtats obtenint uns resultats molt precisos.

La funció CPWL està composta per una suma de funcions lineals definides en múltiples particions utilitzant el valor absolut. La fórmula del CPWL per un model de memòria finit es la següent:

$$y(n) = \sum_{i=0}^{M} a_i x(n-i) + b + \sum_{k=1}^{K} c_k \left| \sum_{i=0}^{M} a_{ki} x(n-i) - \beta_k \right| \qquad \textbf{(3.7)}$$

On $x(n)$ és l'entrada, $y(n)$ la sortida, les $|\cdot|$ fan referència al valor absolut, K és el número de particions i $\beta_k$és l'umbral que defineix els límits de la partició. El paràmetre s'obté de la següent relació:

$$\beta_k = \frac{k}{K} \qquad \textbf{(3.8)}$$

Però aquesta funció no compleix totes les condicions nombrades al principi d'aquest capítol, les úniques que compleix són que el model es troba en domini del temps discret i que té en compte la no-linealitat i els efectes de memòria.

El Decomposed Vector Rotation és una variant de la funció del CPWL, però amb la gran diferència que compleix les altres 2 condicions sobrants. Seguidament es nombraran els diferents canvis que s'han aplicat a la funció CPWL per poder complir totes les condicions i així acabar obtenint el DVR.

1. Paràmetres lineals: El valor absolut que s'aplica és per tot un filtre de manera que no existeix una linealitat entre els coeficients a_{ki} i β_k respecte la sortida. Així que en comptes d'aplicar el valor absolut a un filtre, s'aplicarà a una mostra concreta. Per tant, es passa de:

$$\sum_{k=1}^{K} c_k \left| \sum_{i=0}^{M} a_{ki} x(n-i) - \beta_k \right| \quad \textbf{(3.9)}$$

a

$$\sum_{k=1}^{K} \sum_{i=0}^{M} c_{ki} |x(n-i) - \beta_k| \quad \textbf{(3.10)}$$

De manera que tots els coeficients a_i, b i c_{ki} ara són lineals respecte la sortida.

2. Suportar senyals amb valors complexes: Tal i com s'ha explicat anteriorment els senyals són complexes en banda base. El terme b de la fórmula (3.5) fa referència al DC offset, per la qual cosa es pot eliminar en un model de DPD.

   Per la part que té en compte les particions s'ha de considerar tant la magnitud com la fase. Per tant, la solució és: es calcula la magnitud del senyal, es resta el llindar, s'aplica el valor absolut i finalment se li afegeix la fase corresponent. Finalment s'obté:

$$\left| |x(n-i)| - \beta_k \right| e^{j\theta(n-i)} \quad \textbf{(3.11)}$$

   D'aquesta manera s'obté una rotació de fase en el vector, ja que si la senyal original és més gran que β_k, la fase no canvia. Però si el senyal d'entrada es menor a β_k llavors s'aplica una rotació de 180 graus. Aquest procés és l'anomenat Decomposed Vector Rotation.

   Si expressem β_k com un vector format, es pot escriure de la següent manera:

$$\left| |x(n-i)| - \beta_k \right| e^{j\theta(n-i)} = \begin{cases} x(n-i) - \beta_k e^{j\theta(n-i)} & |x(n-i)| \geq \beta_k \\ \left[x(n-i) - \beta_k e^{j\theta(n-i)}\right] e^{j180^\circ} & |x(n-i)| < \beta_k \end{cases} \quad \textbf{(3.12)}$$

Després de l'explicació d'aquestes dues condicions ja podem definir el primer terme del DVR, el qual s'anomena base de 1r ordre:

$$B_{ki,1}(n) = \left| |x(n-i)| - \beta_k \right| e^{j\theta(n-i)} \quad \textbf{(3.13)}$$

Un cop es compleixen les 4 condicions es poden afegir més termes donat que l'objectiu d'aquest model és tenir la màxima precisió possible. Els problemes de distorsió no-lineals majoritàriament venen causats de les variacions d'amplitud. Per tant, s'afegeix més informació de l'amplitud per a què així sigui més robust, multiplicant la base de 1r ordre per la magnitud de $x(n)$. Obtenint la base de 2n ordre de tipus 1:

$$B_{ki,21}(n) = \big||x(n-i)| - \beta_k\big| e^{j\theta(n-i)} \cdot |x(n)| \qquad \textbf{(3.14)}$$

El terme de 2n ordre tipus 2 s'obté creuant els termes, ja que aquest fenomen ha donat molt bons resultats en models anteriors.

$$B_{ki,22}(n) = \big||x(n-i)| - \beta_k\big| \cdot x(n) \qquad \textbf{(3.15)}$$

El terme de 2n ordre tipus 3 s'obté multiplicant $x(n-i)$ en comptes de $x(n)$

$$B_{ki,23}(n) = \big||x(n-i)| - \beta_k\big| \cdot x(n-i) \qquad \textbf{(3.16)}$$

Es pot afegir d'altres termes equivalents al model DDR-Volterra, el terme 1 es defineix com:

$$B_{DDR,term1}(n) = \big||x(n)| - \beta_k\big| x(n-i) \qquad \textbf{(3.17)}$$

El següent terme, és:

$$B_{DDR,term2}(n) = \big||x(n)| - \beta_k\big| \cdot x^2(n) x^*(n-i) \qquad \textbf{(3.18)}$$

Si encara es vol aconseguir millors resultats es pot augmentar l'ordre amb els següents termes:

$$B_{ki,p1}(n) = \big||x(n-i)| - \beta_k\big| e^{j\theta(n-i)} \cdot |x(n)|^p \qquad \textbf{(3.19)}$$

On p és un nombre enter. Però amb un ordre tant alt s'ha d'estudiar si realment val la pena ja que igual la millora del resultat no és tan significativa respecte el cost.

Finalment, podem obtenir l'equació final del DVR, on $y(n)$ és la sortida, $x(n)$ és l'entrada, β_k és el llindar, K és el número del llindar i M és la longitud de memòria.

$$
\begin{aligned}
y(n)|_{DVR} = \sum_{i=0}^{M} a_i x(n-i) \\
&+ \sum_{k=1}^{K}\sum_{i=0}^{M} c_{ki,1}\big||x(n-i)| - \beta_k\big| \\
&+ \sum_{k=1}^{K}\sum_{i=0}^{M} c_{ki,21}\big||x(n-i)| - \beta_k\big| e^{j\theta(n-i)} \cdot |x(n)| \\
&+ \sum_{k=1}^{K}\sum_{i=0}^{M} c_{ki,22}\big||x(n-i)| - \beta_k\big| \cdot x(n) \\
&+ \sum_{k=1}^{K}\sum_{i=0}^{M} c_{ki,23}\big||x(n-i)| - \beta_k\big| \cdot x(n-i) \\
&+ \sum_{k=1}^{K}\sum_{i=0}^{M} c_{ki,24}\big||x(n)| - \beta_k\big| \cdot x(n-i) + \cdots
\end{aligned}
\tag{3.20}
$$

3.2. Iterative Learning Control

El Iterartive Learning Control (ILC) és un mètode que busca l'entrada d'un sistema que introdueixi el mínim error possible. La idea principal del ILC és: donat un sistema F on $y[n] = F(x[n])$ l'objectiu és aproximar el màxim possible la sortida $y[n]$ a la sortida ideal $y_d[n]$. Per aconseguir-ho s'ha de buscar una entrada òptima $x^*[n]$ la qual quan s'introdueixi a l'amplificador de potència s'obtingui una sortida el més similar possible a $y_d[n]$. Es fan K iteracions per anar corregint l'entrada.

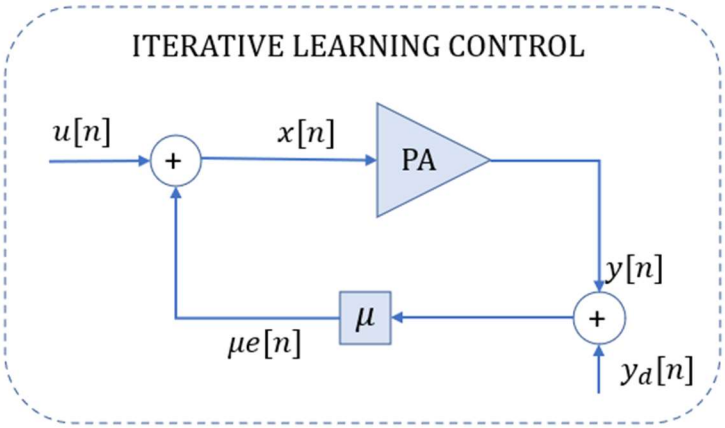

Figura 3.1 Esquema del Iterative Learning Control

El funcionament del ILC s'explica mitjançant la figura 3.1. El senyal $u[n]$ és el vector d'entrada del bucle del ILC, $x[n]$ i $y[n]$ és el vector d'entrada i de sortida de l'amplificador de potència, respectivament.

El vector d'entrada de l'amplificador de potència $x[n]$ es calcula mitjançant el senyal d'entrada del sistema $u[n]$, l'error $e[n]$ i el factor de correcció μ calculats en la iteració anterior, els quals s'expliquen més endavant. En la primera iteració el factor de correcció és 0 per tant $x[n]$ és $u[n]$.

$$x[n] = u[n] + \mu e[n] \tag{3.21}$$

El senyal de sortida $y[n]$ es descriu de la següent manera:

$$y[n] = F(u[n]) \tag{3.22}$$

Sent F la funció de transferència no-lineal de l'amplificador de potència. L'error produït en aquesta iteració es calcula:

$$e[n] = y_d[n] - y[n] \tag{3.23}$$

Sent

$$y_d[n] = u[n] \cdot G_o \tag{3.24}$$

on G_o és el guany lineal del PA.

De manera que el ILC calcula el factor de pes que condiciona la velocitat de convergència de l'algoritme μ per tal de corregir l'error calculat i obtenint un senyal nou i més òptim d'entrada de l'amplificador de potència calculat en (3.21).

3.3. Extracció de coeficients

Donat un model i una entrada $u[n] = (u[0], \cdots, u[n])^T$ la qual s'introdueix al predistorsionador digital, s'obté la sortida $\hat{x}[n] = (\hat{x}[0], \cdots, \hat{x}[n])^T$ calculada mitjançant el model escollit. Dins del DPD es calculen els coeficients w per així poder calcular la sortida, aquests es calculen mitjançant l'algoritme Least Square.

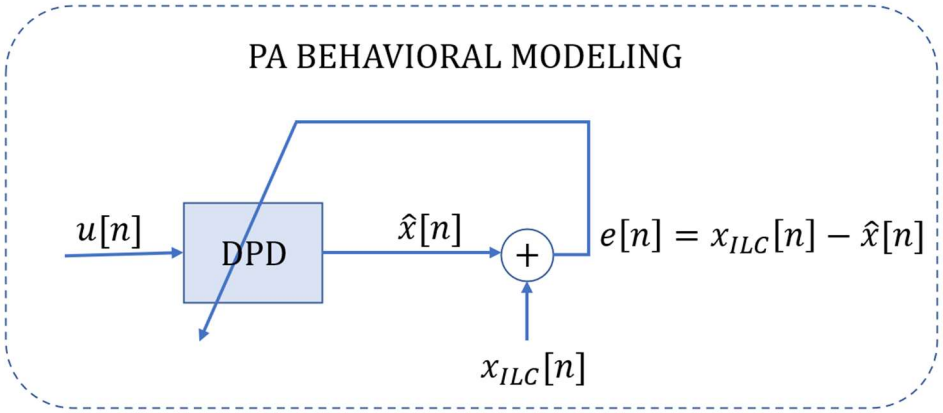

Figura 3.2 Esquema del modelat comportamental

L'objectiu principal d'aquest algoritme és buscar els coeficients w dels models que millor s'ajusten en termes d'error quadràtic. El vector de coeficients és molt més gran que el vector d'entrada i sortida, per tant ens trobem davant d'un sistema incompatible en el qual no es pot trobar una solució que compleixi totes les equacions. És per aquest motiu que es recorre al Least Square, ja que aquest busca la solució que minimitzi l'error quadràtic.

De manera genèrica, la sortida d'un model comportamental d'un amplificador de potència $\hat{x}[n]$ (per $n = 0, 1, \cdots, N-1$) es pot definir de la següent manera:

$$\hat{\boldsymbol{x}} = \boldsymbol{U}\boldsymbol{w} \tag{3.25}$$

On $\boldsymbol{w} = (w_1, \cdots, w_i, \cdots, w_M)^T$ és el vector de paràmetres $M\ x\ 1$ i $\boldsymbol{U}$ és la matriu $N\ x\ M$ (sent $N \gg M$) que conté les funcions base. La matriu $\boldsymbol{U}$ es pot definir de la següent manera:

$$\boldsymbol{U} = (\boldsymbol{\varphi_u}[0], \boldsymbol{\varphi_u}[1], \cdots, \boldsymbol{\varphi_u}[n], \cdots \boldsymbol{\varphi_u}[N-1])^T \tag{3.26}$$

On $\boldsymbol{\varphi_u}[n] = (\phi_1^u[n], \cdots, \phi_i^u[n], \cdots, \phi_M^u[n])^T$ és el vector $M\ x\ 1$ de les funcions base $\phi_i^u[n]$ (sent $i = 1, \cdots, M$) en el temps n. Aquesta equació pot ser particularitzada per qualsevol model de comportament.

L'error quadràtic acumulat es pot definir com:

$$\sum_{i=0}^{N} \left|\left|e[i]\right|\right|^2 = \left|\left|x_{ILC}[i] - \hat{x}|i|\right|\right|^2 = \left|\left|x_{ILC}[i] - \varphi_u^T[i] \cdot w\right|\right|^2 \tag{3.27}$$

Aquesta expressió es pot reescriure en notació matricial com:

$$\boldsymbol{J}(w) = (\boldsymbol{x} - \boldsymbol{U} \cdot \boldsymbol{w})^H \cdot (\boldsymbol{x} - \boldsymbol{U} \cdot \boldsymbol{w}) \quad \textbf{(3.28)}$$

On $J(w)$ és la funció que ens dona l'error quadràtic acumulat en funció del vector de coeficients w. L'objectiu principal és trobar els coeficients w que minimitzin la funció $J(w)$. El procés per poder aconseguir-ho és fer el càlcul de les derivades parcials de la funció respecte cada un dels coeficients del vector w i seguidament igualar-les a 0.

$$\frac{\partial \boldsymbol{J}(w)}{\partial w_j} = 0 \quad \textbf{(3.29)}$$

Recuperant l'equació matricial nombrada anteriorment en (3.30)

$$\begin{aligned} \boldsymbol{J}(w) = (\boldsymbol{x} - \boldsymbol{U} \cdot \boldsymbol{w}) \cdot (\boldsymbol{x} - \boldsymbol{U} \cdot \boldsymbol{w})^H = \\ = \boldsymbol{x}^H \cdot \boldsymbol{x} - 2 \cdot \boldsymbol{x}^H \cdot \boldsymbol{U} \cdot \boldsymbol{w} + \boldsymbol{w}^H \cdot \boldsymbol{U}^H \cdot \boldsymbol{U} \cdot \boldsymbol{w} \end{aligned} \quad \textbf{(3.30)}$$

Derivant s'obté

$$\frac{\partial \boldsymbol{J}(w)}{\partial w} = -2 \cdot \boldsymbol{U}^H \cdot \boldsymbol{x} + 2 \cdot \boldsymbol{U}^H \cdot \boldsymbol{U} \cdot \boldsymbol{w} \quad \textbf{(3.31)}$$

Un cop s'ha obtingut l'expressió de la derivada, s'ha d'igualar a 0 per així poder obtenir el mínim.

$$-2 \cdot \boldsymbol{U}^H \cdot \boldsymbol{x} + 2 \cdot \boldsymbol{U}^H \cdot \boldsymbol{U} \cdot \boldsymbol{w} = 0 \quad \textbf{(3.32)}$$

$$\boldsymbol{U}^H \cdot \boldsymbol{U} \cdot \boldsymbol{w} = \boldsymbol{U}^H \cdot \boldsymbol{x} \quad \textbf{(3.33)}$$

$$\boldsymbol{w} = (\boldsymbol{U}^H \cdot \boldsymbol{U})^{-1} \cdot \boldsymbol{U}^H \cdot \boldsymbol{x} \quad \textbf{(3.34)}$$

Per tant, la solució del LS en el problema de minimització és (3.34).

Un cop s'han obtingut els coeficients es calcula la sortida del DPD $\hat{x}[n]$, la qual seguidament es resta de la sortida desitjada calculada mitjançant el mètode ILC explicat anteriorment. L'error introduït entre aquests dos senyals es defineix:

$$e[n] = x_{ILC}[n] - \hat{x}[n] \quad \textbf{(3.35)}$$

Finalment, amb $e[n]$ es calcula els paràmetres desitjats: el NMSE i el ACEPR.

3.4. Models en cascada

Per així obtenir un millor resultat, s'ha recorregut a ficar un model, model1, en cascada amb un altre model, model 2. Aquest procés és exactament el mateix que l'explicat anteriorment, però amb l'ampliació de què la sortida del DPD $\hat{x}[n]$ es torna a introduir en el mateix procés, però en aquest el DPD utilitza el model2. Ambdós models poden ser el mateix.

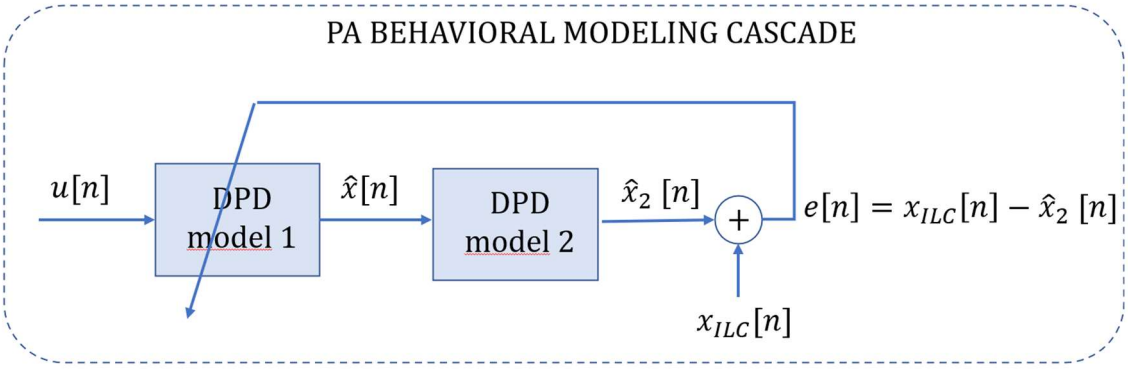

Figura 3.3 Esquema del modelat comportamental de dos models en cascada

En la figura 3.3 s'observa més detalladament. El senyal $u[n]$ s'introdueix en el DPD utilitzant el model1, mitjançat el Least Square es calcula $\hat{x}[n]$, aquest vector s'introdueix en el DPD utilitzant el model 2 i de nou es torna a calcular mitjançant el Least Square $\hat{x}_2[n]$, finalment es compara $\hat{x}_2[n]$ amb $x_{ILC}[n]$ la qual s'ha obtingut amb el ILC calculant l'error amb què es calculen els paràmetres NMSE i ACEPR.

$$e[n] = x_{ILC}[n] - \hat{x}_2[n] \tag{3.36}$$

3.5. DOMP

Per poder optimitzar el màxim possible el número de coeficients en els models utilitzats s'ha recorregut a l'algoritme DOMP.

El Doubly Orthogonal Matching Pursuit (DOMP) és un tipus de Greedy Pursuit. El Greedy pursiuts és una tècnica de processat del senyal que consisteix en fer una gran decisió en cada iteració classificant quins coeficients del model té més

repercussió en el resultat. De manera que es disminueix el número de coeficients.

L'algoritme DOMP retorna un vector el qual ens indica de major a menor quin és l'element del vector de coeficients w té més impacte en el resultat i el número recomanat de coeficients per tal que no variï el resultat final. Les variables d'entrada necessàries són la matriu d'informació X i el senyal de sortida del DPD $\hat{x}[n]$.

En l'article [8] s'explica més detalladament el procés d'aquest algoritme. A continuació s'adjunta la codificació del DOMP extret de [8].

$$\boldsymbol{Input}: \boldsymbol{X}, \boldsymbol{y}$$

$$\boldsymbol{Output}: S, \widehat{w}$$

$$Initialization: \boldsymbol{Z}^{(0)} \leftarrow \boldsymbol{X}, \boldsymbol{r}^{(0)} \leftarrow \boldsymbol{y}, S^{(0)} \leftarrow \emptyset$$

$$\boldsymbol{for}\ t \leftarrow 1\ \boldsymbol{to}\ m_{max}\ \boldsymbol{do}$$

$$g_{\{i\}}^{(t)} \leftarrow \frac{\boldsymbol{Z}_{\{i\}^H}}{\left\|\boldsymbol{Z}_{\{i\}}\right\|_2} \boldsymbol{r}^{(t-1)}$$

$$s^{(t)} \leftarrow supp\left(H_1 \middle| \boldsymbol{g}^{(t)}\right) \qquad \textbf{(3.37)}$$

$$S(t) \leftarrow S^{(t-1)} \cup s^{(t)}$$

$$\boldsymbol{p}^{(t)} \leftarrow \boldsymbol{Z}_{\{i^{(t)}\}}^{(t-1)^H} \boldsymbol{Z}^{(t-1)}$$

$$\boldsymbol{Z}^{(t)} \leftarrow \boldsymbol{Z}^{(t-1)} - \boldsymbol{p}^{(t)} \otimes \boldsymbol{Z}_{\{i^{(t)}\}}^{(t-1)}$$

$$\widehat{\boldsymbol{w}}_{S^{(t)}} \leftarrow \boldsymbol{X}_{S^{(t)}}^{\dagger} \boldsymbol{y}$$

$$\widehat{\boldsymbol{y}}^{(t)} \leftarrow \boldsymbol{X}_{S(t)} \widehat{\boldsymbol{w}}$$

$$\boldsymbol{r}^{(t)} \leftarrow \boldsymbol{y} - \widehat{\boldsymbol{y}}^{(t)}$$

Aquest algoritme retorna el conjunt de suport S, en el qual els seus elements estan ordenats en l'impacte que tenen sobre la sortida de manera decreixent, i també retorna el vector de coeficients $\widehat{\boldsymbol{w}}$. L'estat inicial de S és nul, $S^{(0)} \leftarrow \emptyset$ ja que encara no se li ha agregat components. La matriu $\boldsymbol{Z}$ a l'inici està definida de la següent manera: $\boldsymbol{Z}^{(0)} \leftarrow \boldsymbol{X}$, aquesta matriu guarda la informació dels regressors ortogonals, tot i que després de l'execució de l'algoritme aquesta matriu serà igual al resultat d'aplicar el procediment de Gram-Schmidt a la matriu de regressors $\boldsymbol{X}$ amb l'ordre del vector $\boldsymbol{S}$. Les variables d'entrada són la matriu de dades $\boldsymbol{X}$ i el senyal de sortida del PA y. Quan comença el bucle primerament

es fa el càlcul de la correlació normalitzada $g_{\{i\}}$ entre la i-esima columna de la matriu de regresors $X\{i\}$ i el residu. Aquesta variable és un vector de longitud M que conté en cada posició un valor que indica quant de correlacionades estan les columnes de la matriu mesurada respecte l'error residual.

Seguidament mitjançant l'operació $supp\left(H_1 \middle| \boldsymbol{g}^{(t)}\right)$ s'obté l'índex del valor màxim del vector $\boldsymbol{g}$, de manera que s'aconsegueix l'element més correlacionat. Tot seguit, l'índex $s^{(t)}$ s'inclou en $S(t)$.

En el següent pas:

$$\boldsymbol{p}^{(t)} \leftarrow \boldsymbol{Z}_{\{i^{(t)}\}}^{(t-1)^H} \boldsymbol{Z}^{(t-1)} \tag{3.38}$$

l'algoritme realitza una ortogonalització de Gram-Schmidt obtenint el vector de projecció $\boldsymbol{p}$ del regressor seleccionat sobre cada una dels components de la següent base. Aquesta projecció s'utilitza per a descorrelacionar les funcions base amb el regressor seleccionat com es fa a continuació:

$$\boldsymbol{Z}^{(t)} \leftarrow \boldsymbol{Z}^{(t-1)} - \boldsymbol{p}^{(t)} \otimes \boldsymbol{Z}_{\{i^{(t)}\}}^{(t-1)} \tag{3.39}$$

Per tant, el component seleccionat és ortogonal a la resta del conjunt base, de manera que es realitza una doble ortogonalització tal i com indica el nom. Finalment, el vector principal es calcula mitjançant LS i s'actualitza l'error residual.

3.6. Identificació de paràmetres del DPD

Per poder dur a terme el modelat de comportament s'han de calcular els coeficients, els quals rectifiquen el senyal de sortida final. Per poder calcular els coeficients es divideix el procés en dues parts. Per una banda es troba la part de la cerca dels coeficients i d'altra banda, es troba la validació d'aquests coeficients. Finalment és fa el càlcul del ACEPR i del NMSE. A continuació s'explicarà detalladament.

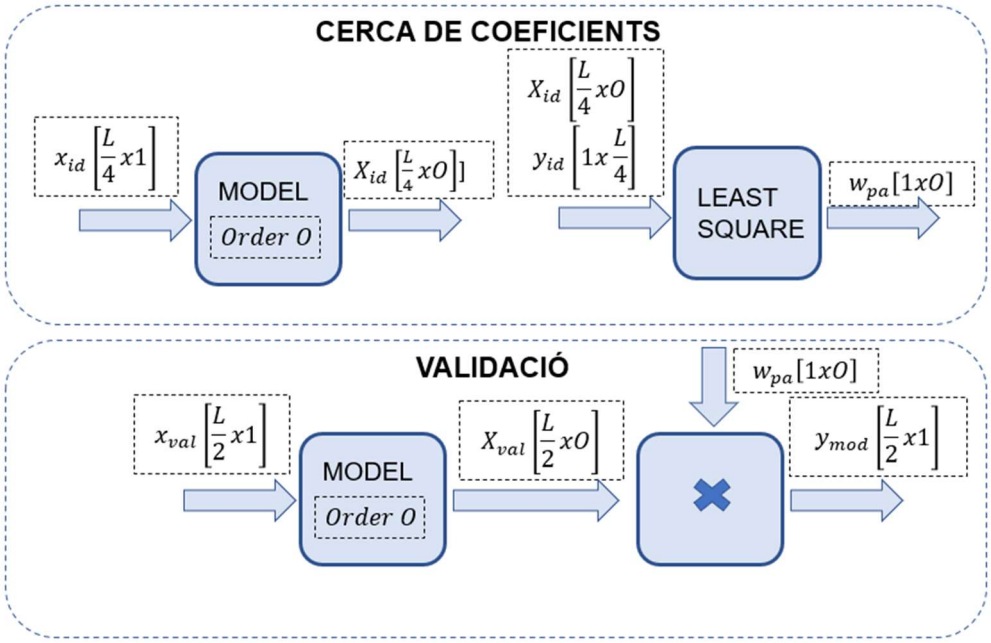

Figura 3.4 Esquema del procés d'identificació de paràmetres

Donat un vector de mostres d'entrada $\boldsymbol{xBB}$ i un vector de mostres de sortida $\boldsymbol{yBB}$. En cada part, tant en la de cerca com en la de validació, s'utilitza una part del vector diferent, de manera que el funcionament sigui totalment correcte i s'obtinguin uns resultats racionals.

Pel que fa a la part de cerca de coeficients, s'utilitza el primer quart de mostres del senyal: $\boldsymbol{x_{id}}$ i $\boldsymbol{y_{id}}$. En canvi, per la part de validació s'utilitza la segona meitat de mostres del senyal: x_{val} i y_{val}.

$$\boldsymbol{x_id} = \boldsymbol{xBB}\left(1{:}\frac{L}{4}\right) \tag{3.40}$$

$$\boldsymbol{y_{id}} = \boldsymbol{yBB}\left(1{:}\frac{L}{4}\right) \tag{3.41}$$

$$\boldsymbol{x_val} = \boldsymbol{xBB}\left(\frac{L}{2} + 1{:}\,end\right) \tag{3.42}$$

$$\boldsymbol{y_val} = \boldsymbol{yBB}\left(\frac{L}{2} + 1{:}\,end\right) \tag{3.43}$$

Un cop s'han definit les entrades i sortides ja es pot explicar el procés. Primerament, s'utilitza el model desitjat en el qual se li introdueix el vector $\boldsymbol{x_{id}}$ i els paràmetres del model que siguin necessaris, aquest retorna la matriu de bases $\boldsymbol{X_id}$ de dimensió $\frac{L}{4}xO$. Tot seguit es fa l'operació Least Square amb la matriu obtinguda $\boldsymbol{X_{id}}$ i la sortida $\boldsymbol{y_{id}}$, de manera que s'obté el vector de coeficients $\boldsymbol{w_{pa}}$, de dimensió $1xO$.

Un cop s'ha acabat el procés de cerca de coeficients, es comença amb la part de validació de coeficients. Es torna a utilitzar el mateix model, però en aquest cas amb el vector d'entrada $\boldsymbol{x_{val}}$, aquest procés ens retorna la matriu de dades $\boldsymbol{X_{val}}$ amb la qual es calcula la sortida desitjada:

$$\boldsymbol{y_{mod}} = \boldsymbol{X_{val}} \cdot \boldsymbol{w_{pa}} \tag{3.44}$$

Un cop s'obté el vector de sortida $\boldsymbol{y_{mod}}$ el qual és la sortida desitjada, ja es poden calcular les mètriques NMSE i ACEPR mitjançant $\boldsymbol{y_{mod}}$ i $\boldsymbol{y_{val}}$.

CAPÍTOL 4. PRINCIPIS DEL DPD

La predistorsió digital (Digital Predistortion, DPD) és la tècnica de linealització que més s'utilitza avui en dia com a solució entre la batalla de linealitat versus eficiència. Tal i com s'ha explicat anteriorment, el DPD consisteix en fer la inversa dels models ja explicats. És a dir, la inversa dels models anteriors contraresta la no-linealitat del PA de manera que finalment s'obté una corba la qual és molt similar a una recta.

El mètode que s'utilitza en aquest treball en el funcionament del predistorsionador digital és el mètode directe.

La relació entrada-sortida en el bloc del DPD és la següent:

$$x[n] = u[n] - d[n] \tag{4.1}$$

On $x[n]$ és el senyal de sortida del DPD, $u[n]$ el senyal d'entrada i $d[n]$ és la distorsió, la qual s'ha calculat mitjançant models comportamentals. També és pot descriure de la següent manera:

$$x[n] = u[n] - {\varphi_u}^T[n]w[n] \tag{4.2}$$

On $\boldsymbol{w}[n]$ és el vector de coeficients $\boldsymbol{w}[n] = (w_1[n], \dots, w_i[n], \dots, w_M[n])^T$ en el temps n de dimensió $M \times 1$, on M és l'ordre del model. ${\boldsymbol{\varphi_u}}^T[n] = (\phi_1^u[n], \dots, \phi_i^u[n], \dots, \phi_M^u[n])$ és el vector que conté les funcions base $\phi_i^u[n]$ (sent $i = (1, \dots, M)$ al temps n.

Els models de comportament explicats anteriorment, els quals ens serveixen per buscar la resposta del PA, també es poden utilitzar per objectius del DPD, estimant la inversa de la resposta del PA amb la intenció d'eliminar la màxima distorsió possible. L'equació (4.2) es pot reescriure de la següent manera:

$$\boldsymbol{x} = \boldsymbol{u} - \boldsymbol{U}\boldsymbol{w} \tag{4.3}$$

On $\boldsymbol{x} = (x[0], \dots, x[n], \dots, x[N-1])^T$ i $\boldsymbol{u} = (u[0], \dots, u[n], \dots, u[N-1])^T$ sent $n = 0, \dots, N-1$ són el vector predistorsionat i el vector d'entrada, respectivament, ambdós de dimensió $N \times 1$. La matriu d'informació $N \times M$ es defineix de la següent manera:

$$\boldsymbol{U} = (\boldsymbol{\varphi_u}[0], \dots, \boldsymbol{\varphi_u}[n], \dots, \boldsymbol{\varphi_u}[N-1])^T \tag{4.4}$$

En el DPD la identificació de paràmetres no té perquè ser en temps real, es pot implementar en un sistema de processat. Els coeficients en el DPD es poden extreure i adaptar en diferents iteracions.

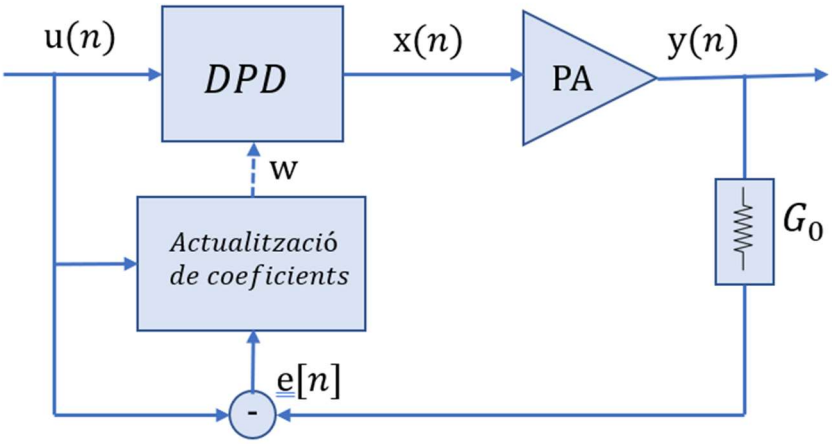

Figura 4.1 Diagrama de bloc del DPD en el mètode directe

En la figura 4.1 s'observa el diagrama de bloc de l'arquitectura d'un bucle adaptatiu tancat del DPD mitjançant el Direct Learning Control.

Els coeficients es poden extreure de manera iterativa mitjançant la següent equació.

$$\boldsymbol{w}^{j+1} = \boldsymbol{w}^{j} + \mu \boldsymbol{\Delta w} \tag{4.5}$$

On μ és el paràmetre que determina la velocitat de convergència i pren valors entre $0 < \mu < 1$ i on Δw s'obté mitjançant l'algoritme Least Square

$$\Delta w = (\boldsymbol{U}^H \boldsymbol{U})^{-1} \boldsymbol{U}^H \boldsymbol{e} \tag{4.6}$$

On $\boldsymbol{e}$ és el vector d'identificació d'error de dimensió $N \times 1$ que es defineix com:

$$\boldsymbol{e} = \frac{\boldsymbol{y}}{G_0} - \boldsymbol{u} \tag{4.7}$$

G_0 representa el guany lineal desitjat de l'amplificador, $\boldsymbol{y}$ i $\boldsymbol{u}$ són els vectors de sortida i d'entrada transmesa respectivament de l'amplificador de potència de dimensió $N \times 1$.

CAPÍTOL 5. RESULTATS EXPERIMENTALS

5.1. Models comportamentals

El comportament dels diferents models s'ha estudiat utilitzant el programa Matlab R2022b. Per poder modelar correctament mitjançant el programa s'han agafat mostres de dades reals de l'amplificador utilitzat en el laboratori, el qual s'explica més endavant. Utilitzant les dades d'entrada i sortida de l'amplificador es poden modelar les dades i seguidament comparar el resultat obtingut de la sortida modelada entre les dades de sortida de l'amplificador real. D'aquesta manera s'obté el ACPER i el NMSE. Les dades proporcionades tenen un ample de banda de 200 MHz.

L'objectiu d'aquesta part és trobar uns valors pels models en els que s'obtingui el millor resultat, però tenint en compte el número de coeficients. És per aquest motiu que durant aquesta explicació es trobaran resultats amb una gran diferència de coeficients, ja que finalment s'haurà de decidir si es prioritza els coeficients o el resultat.

5.1.1. Resultats amb Memory Polynomial

El Memory Polynomial és el primer model que s'ha estudiat, aquest prové del Volterra i es caracteritza per la gran disminució de coeficients. En la figura 5.1 s'observa com els resultats en aquest model no són gaire òptims, amb 90 coeficients s'obté un NMSE de -27 dB, la corba s'estabilitza als 200 coeficients, aconseguint finalment un valor de -27,7 dB. Aquest resultat és el pitjor que s'observarà de tots els models estudiats ja que no té en compte productes creuats de memòria.

5.1.2. Resultats amb Generalized Memory Polynomial

El Generalized Memory Polynomial és una evolució del Memory Polynomial, la seva gran diferència és que té en compte les dades que l'envolten en cada retard. Els resultats d'aquest model són millors respecte als del MP ja que el GMP conté productes creuats de memòria que permeten caracteritzar millor els efectes de memòria. En la figura 5.1 s'observa la gran diferència de decibels entre ambdós models. La corba del GMP segueix la mateixa tendència que la del MP ja que fins a 200 coeficients el valor de NMSE va disminuint, fins que finalment s'estabilitza obtenint valors que ronden els -33,5 dB. La gran diferència és que el GMP disminueix el valor del NMSE abruptament, en canvi el MP disminueix més suaument. En termes numèrics, la diferència entre aquests dos models és de 6 dB.

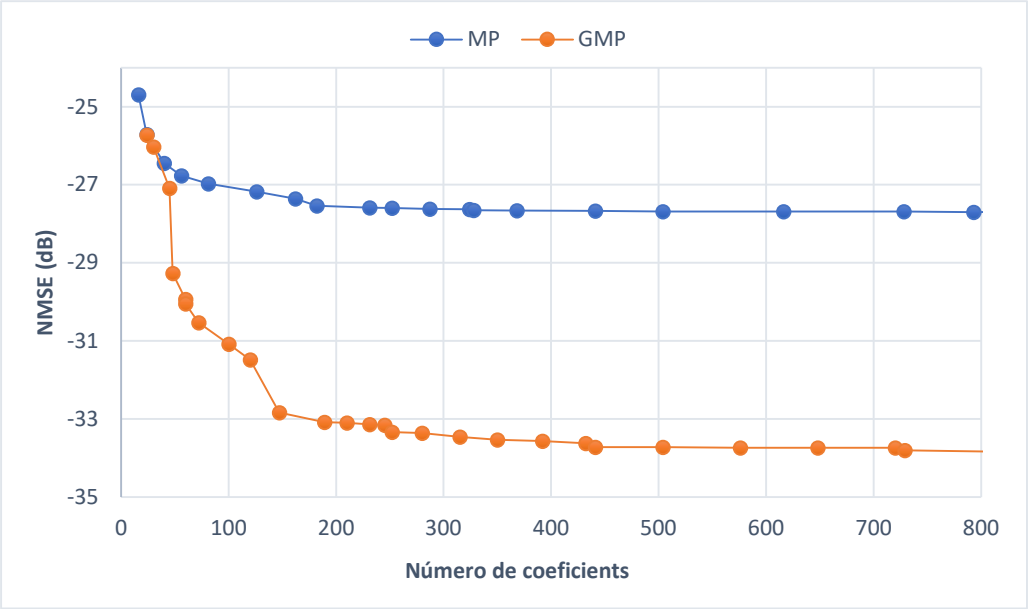

Figura 5.1 Corba dels models MP i GMP

5.1.3. Resultats amb Decomposed Vector Rotation

El DVR es caracteritza en què és una funció per parts i degut a això s'obtenen bons resultats amb un número de coeficients no molt elevat. En aquesta secció s'explicaran els resultats obtinguts pel DVR que s'ha programat en el Matlab. Per una banda, s'obtindrà els resultats del DVR simple i d'altra banda, els resultats del DVR amb diferents retards. Seguidament s'aplicarà l'algoritme DOMP de manera que disminueixi considerablement el número de coeficients. Principalment programar el DVR és la gran aportació d'aquest treball i a partir d'aquí s'intenta millorar el resultat. La fórmula de DVR que s'ha utilitzat és la (3.22), la qual està formada per 6 termes.

En el DVR simple s'han modificat 3 paràmetres: el retard del primer terme, és a dir, de la part lineal; el retard de les altres parts, M, que és el mateix per tota la fórmula exceptuant la part lineal; i finalment el valor K que és el número de partició. En aquest treball el retard de la part lineal s'ha diferenciat dels altres ja que és el terme que més aporta significativament sobre el resultat.

S'han fet diferents proves amb diferents variacions en els paràmetres i el que ha destacat clarament és la importància del retard de la part lineal, ja que aquest valor acostuma a ser el 8, el qual es un bon retard a tenir en compte. Per tant, els valors amb els quals es pot jugar més són M i K.

En la gràfica 5.3 s'observa una gran pendent en els primers 100 coeficients fins que finalment als 150 coeficients s'estabilitza. El valor de NMSE amb 25 coeficients és -27,97 dB i amb 50 coeficients -29,25 dB, per tant es troba una diferència d'1,28 dB. En canvi, si aquesta diferència de 25 coeficients l'apliquem en 250 coeficients, s'obté un NMSE de -33,32 dB i amb 25 coeficients més s'obté -33,38 dB. La diferència de NMSE en el segon cas és 0,6 dB, és a dir, la meitat

que en el primer cas. S'observa que amb 700 coeficients s'obté gairebé el mateix resultat que amb 400 coeficients. És per aquest motiu que no s'han aconseguit més resultats de coeficients més alts.

5.1.4. Resultats amb Decomposed Vector Rotation modificat

Un cop s'han obtingut resultats amb el DVR simple s'ha seguit amb el DVR modificat, el qual consisteix en què cada terme de la fórmula té un retard diferent. En aquest cas hi ha 7 paràmetres: 6 retards, un per cada terme, i el número de particions K. Els noms dels retards es nombraran retardA, retardB, etc., respectivament, amb el retard del primer terme, del segon terme, etc.

És important saber quins valors donar en cada retard, ja que tot i que el retardA sigui el més important no significa que els altres retards no aportin res. A continuació s'explicarà un exemple en el qual s'observarà la importància dels altres retards. En aquest exemple s'obtindran diferents resultats, però sempre amb el mateix número de coeficients, en aquest cas seran 95 coeficients.

Taula 5.1. Taula dels diferents retards en el DVR

	retardA	retardB	retardC	retardD	retardE	retardF	K	Coeff	NMSE (dB)	ACEPR (dB)
1ª proba	7	8	6	5	3	2	3	95	-31,82	-36,27
2ª proba	7	5	5	5	5	4	3	95	-31,97	-36,29
3ª proba	7	7	5	5	4	3	3	95	-32	-36,42
4ª proba	7	6	5	5	4	4	3	95	-32,02	-36,37

En la primera prova, s'ha donat molta més importància als primers termes que als últims, obtenint un resultat de NMSE de -31,82 dB. En la segona prova s'ha intentat igualar el retard en tots els termes (exceptuant el primer) i el resultat ha estat -31,97 dB. En la tercera prova s'han tornat a prioritzar els primers termes, però no tan exageradament com en la primera. Finalment, en la quarta prova s'ha anat disminuint progressivament el retard en cada terme, obtenint un resultat de -32,02 dB. Comparant el primer resultat amb l'últim s'observa una diferència de 0,2 dB, la qual aparentment pot semblar insignificant, però si es té en compte que s'ha utilitzat el mateix nombre de coeficients en els 4 casos són 0,2 dB que estem menyspreant.

Els resultats del DVR amb diferents retards és molt similar al DVR normal, tot i que en alguns trams s'observa una millora gairebé minúscula respecte el DVR normal. En la figura 5.3 s'observa com les corbes dels dos DVR són molt similars, per tant no s'obté una millora important.

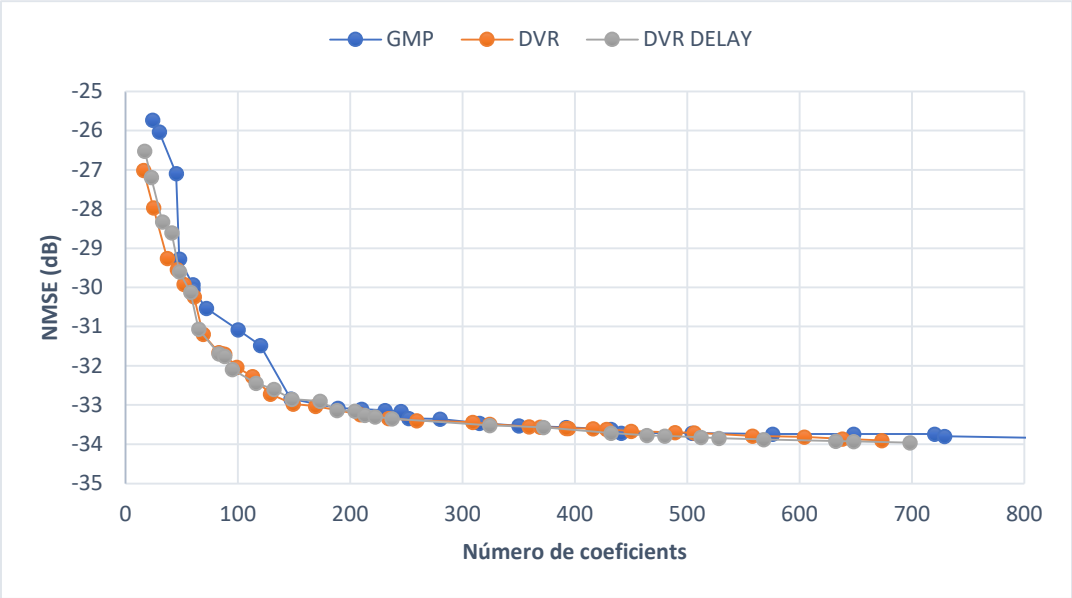

Figura 5.3 Corbes dels models DVR modificat, DVR normal i GMP

5.1.5. Resultats DOMP

Per seguir en la cerca de més bons resultats s'ha recorregut a l'ús del DOMP, explicat en l'apartat 3.5, el qual disminueix considerablement el número de coeficients mantenint el resultat. Per una part, s'ha aplicat el DOMP en el model GMP i d'altra part, en el model DVR. En la gràfica 5.4 s'observa que la corba dels resultats utilitzant DOMP tenen més pendent ja que es passa a un millor resultat amb menys coeficients. Un exemple per veure clarament l'eficiència del DOMP és agafant un valor de NMSE qualsevol, en aquest cas s'ha escollit un NMSE de -33,72 dB. En el DVR sense DOMP el valor nombrat anteriorment s'obté amb 432 coeficients, en canvi utilitzant el DOMP aquest valor s'ha obtingut amb 160 coeficients. És a dir, s'han disminuït 272 coeficients. És per aquest motiu que el DOMP és molt important, ja que s'aconsegueixen resultats molt més bons que en els d'un model simple. En la gràfica 5.4 es pot veure clarament la gran diferència entre els models sense DOMP i amb DOMP. S'observa que a partir de 300 coeficients el NMSE gairebé no millora i no surt a compte fer el DOMP amb coeficients més elevats ja que no s'obtindrien millors resultats.

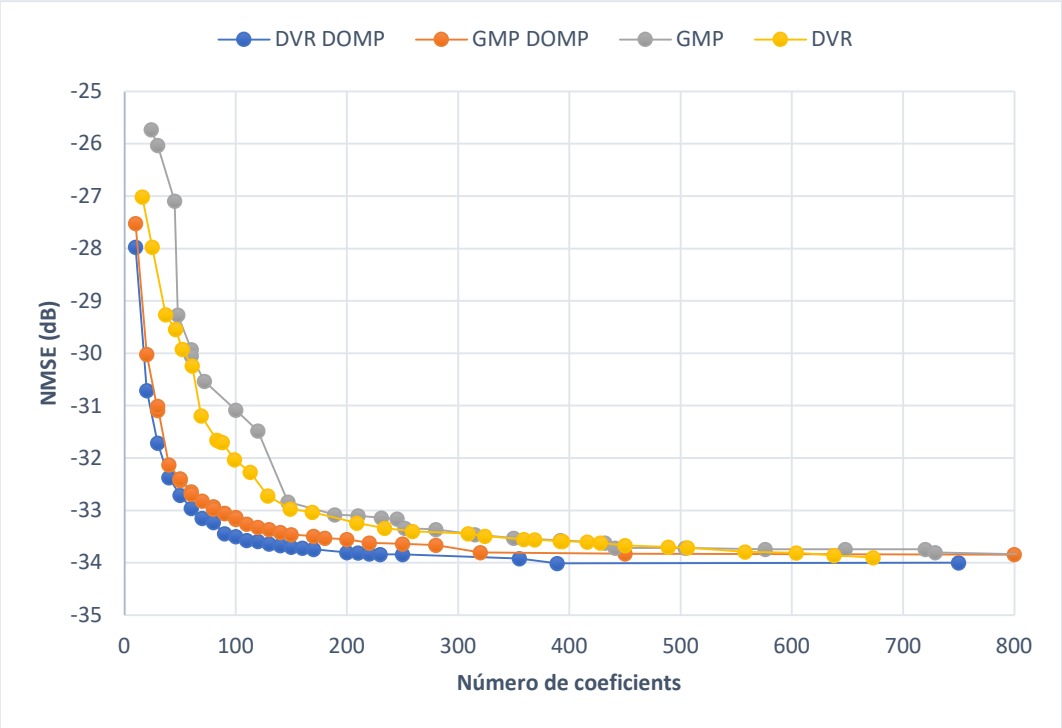

Figura 5.4 Corbes del DVR i GMP amb i sense l'optimització del DOMP

5.1.6. Resultats en Cascada

L'objectiu de passar les dades per dos models és obtenir un millor resultat en la sortida. En aquest apartat s'estudiarà quant millora el resultat quan les dades estan modelades per dos models. Per una banda, s'han fet proves en cascada, sent el model 1 el DVR DOMP i el model 2 el GMP DOMP i d'altra banda, quan els dos models són el DVR DOMP, però utilitzant diferents paràmetres.

En el cas que ambdós models siguin el Decomposed Vector Rotation optimitzats amb el DOMP s'ha observat que funciona millor quan en el model 1 es fica el DVR que té menys coeficients i en el model 2 el DVR que té més coeficients. S'han fet múltiples combinacions i seguidament s'ha fet una tria dels millors resultats respecte el número de coeficients. En el gràfic 5.5 s'observa que la corba no té tanta pendent i costa que s'estabilitzi, a partir de 450 coeficients el resultat tan sols millora 0,01 dB cada 10 coeficients, per tant no surt a compte fer combinacions més enllà de 600 coeficients ja que no s'obtenen millors resultats.

En l'altre cas, quan el model 1 és el DVR i el model 2 és el GMP ambdós resultats optimitzats amb el DOMP s'obté el següent resultat: en els primers 100 coeficients no s'observa una gran millora respecte els DVR en cascada, però més endavant es troba una disminució del NMSE, el qual arriba fins a un valor de -35,08 dB, tot i que aquest s'aconsegueix amb 669 coeficients, pel que s'ha de fer una balança i veure que es prioritza més: si fer servir un model que tingui un número elevat de coeficients obtenint el resultat anterior o utilitzar un número de coeficients menor de manera que no s'obtingui aquet valor de NMSE.

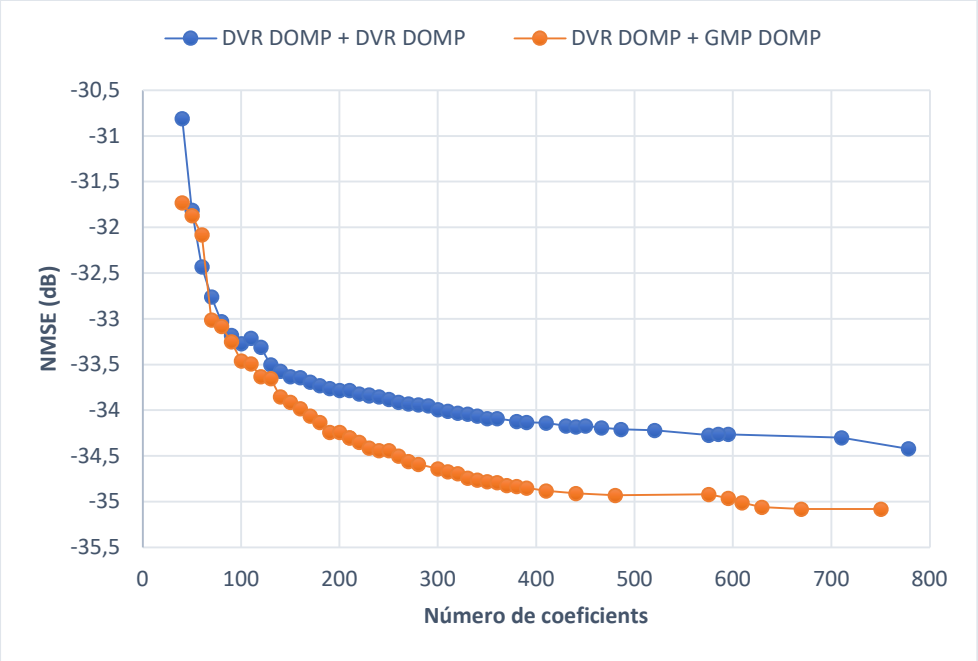

Figura 5.5 Corbes dels models en cascada

5.1.7. Millors resultats

Un cop s'han obtingut tots els resultats es pot fer una comparació entre ells. El que més sobresurt de la mitja és el Memory Polynomial, amb el qual s'obté uns resultats molt pitjors que en els altres models. Seguidament es troba el Decomposed Vector Rotation, el qual la seva corba és molt similar a la del Generalized Memory Polynomial. Finalment, el GMP i el DVR amb el DOMP són molt similars al model en cascada del DVR DOMP + DVR DOMP, tot i que en aquest últim a la llarga s'aconsegueixen uns millors resultats. Com a conclusió, el model que més destaca ha estat el Decomposed Vector Rotation, reduït mitjançant el DOMP, en cascada amb el Generalized Memory Polynomial, reduït mitjançant el DOMP, aquest es diferencia dels altres a partir dels 150 coeficients, ja que la corba va disminuint. Tot i que aquest model s'ha d'utilitzar amb un mínim de 100 coeficients ja que per sota d'aquest número s'obtenen millors resultats amb el DVR DOMP.

Evidentment aquests models no estan fets per a números molt elevats de coeficients ja que el valor de NMSE respecte el número de coeficients és molt baix. Es poden obtenir bons resultats amb un número de coeficients petit, com en el cas de 100 coeficients que s'obté -33,5 dB. A partir de 150 coeficients la corba decreix més lentament de manera que el NMSE tan sols disminueix dècimes, arribant fins a un valor de -35,08 dB amb 750 coeficients. En aquests casos s'ha d'avaluar que és prioritari, un gran nombre de coeficients amb un millor valor, o aquest mateix valor amb unes dècimes menys, però utilitzant molts menys coeficients.

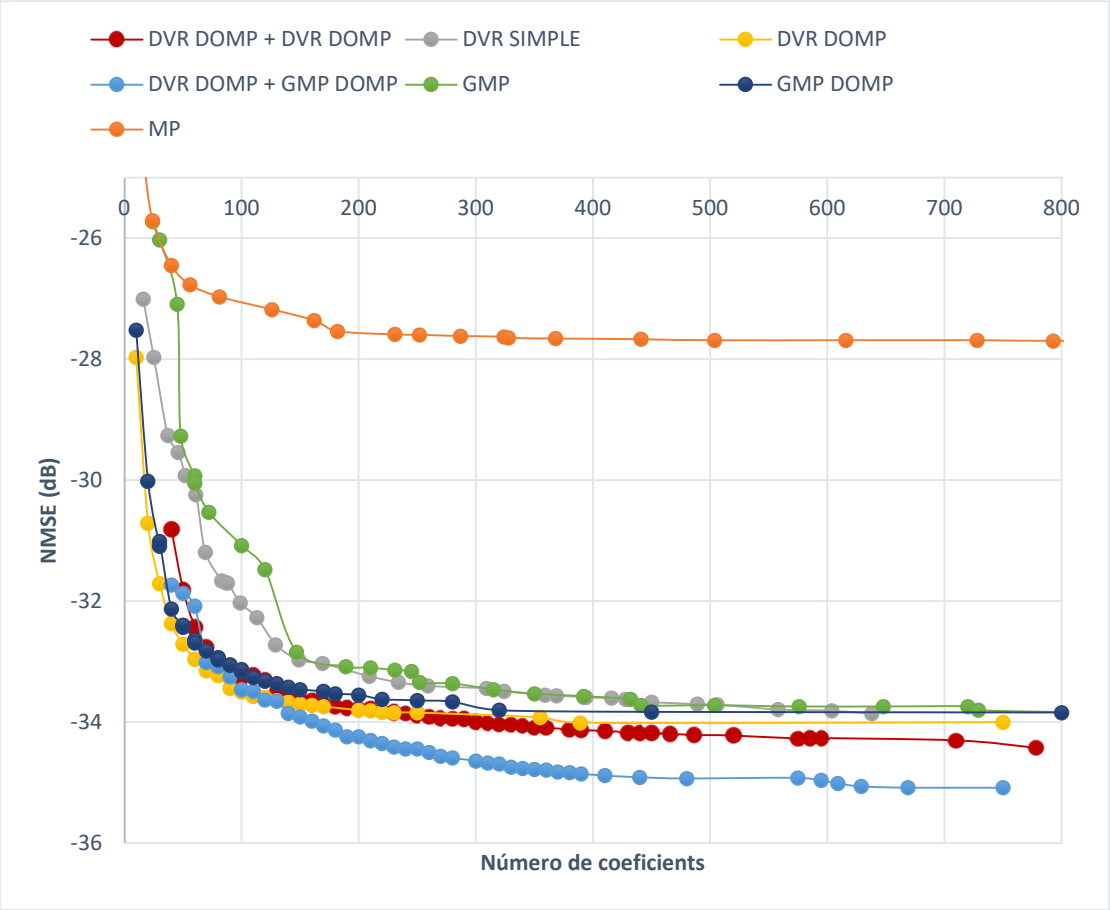

Figura 5.6 Resultats de tots els models

5.2. Banc de proves

Els resultats experimentals s'han obtingut utilitzant diferents proves controlades per MATLAB, tal i com s'observa en la figura 5.7. El transmissor ADRV903x RF i la placa d'avaluació ADS10-V1EBZ de l'Analog Devices van ser utilitzats per generar i adquirir les senyals modulades en RF 5G-NR. L'amplificador d'entrada dual PD-LMBA DUT està dissenyat per Analog Devices. La funció de conformació (shaping function) utilitzada per generar el senyal de control està descrit en [11] i està dissenyat de manera que respecte la potència sigui el més eficient possible. Per la validació experimental s'utilitza un senyal 64-QAM OFDM amb un ample de banda de 100 MHz. El PAPR del senyal està limitat a 8 dB mitjançant una tècnica de reducció del factor de cresta (CFR) que prové de la família de clipping i filtering.

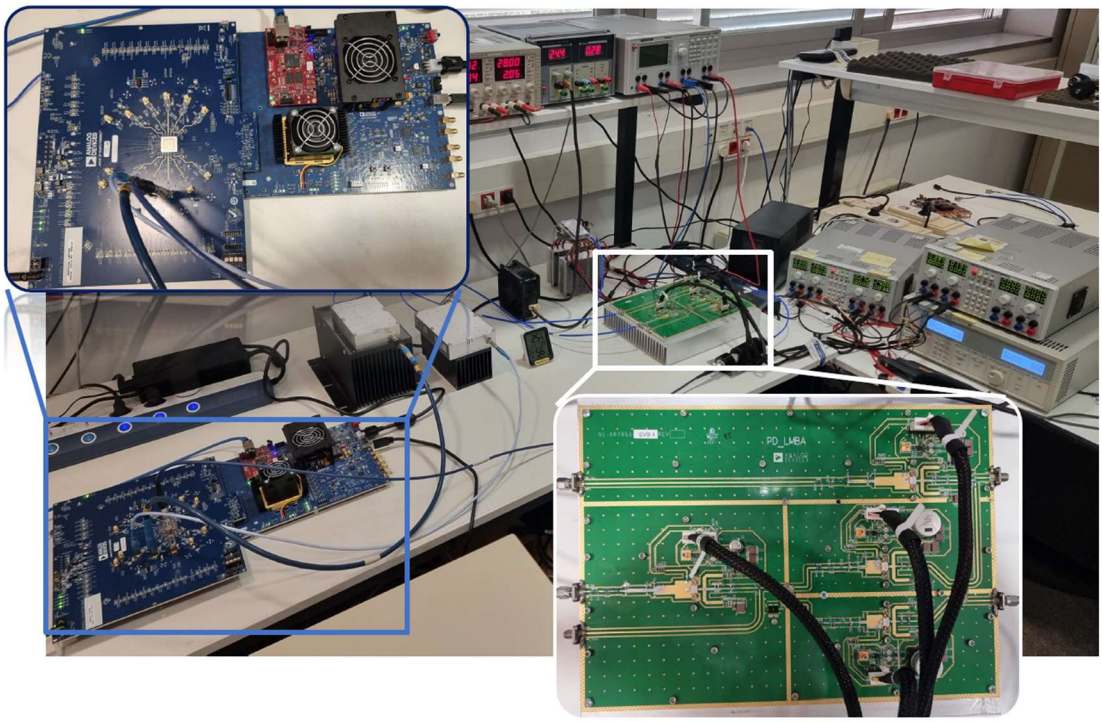

Figura 5.7 Set-up del laboratori

5.3. DPD

En l'entorn real s'han utilitzat 3 combinacions diferents dels models GMP i DVR amb diferents coeficients cadascun per així comprovar que els models funcionen correctament sense tenir en compte el número de coeficients. La combinació A té 150 coeficients, la combinació B 280 coeficients i la combinació C 390 coeficients. L'objectiu d'aquesta part experimental és comprovar que els models estudiats anteriorment serveixen en l'ús del DPD.

Per poder dur a terme aquestes proves s'han fet de nou les simulacions de les 3 combinacions en el Matlab ja que en el DPD es treballa amb un ample de banda de 100 MHz. S'observa una millora en els resultats obtinguts en aquesta segona simulació ja que s'està treballant amb la meitat de l'ample de banda.

En cada prova el número d'iteracions han estat 8 ja que a partir d'aquest número d'iteracions el resultat gairebé no millorava. En la figura 5.8 s'observa com a partir de la segona iteració els resultats milloren exponencialment i són molt similars fins a la 7a iteració en la que ja es troba una diferència de dècimes de dB entre les diferents combinacions.

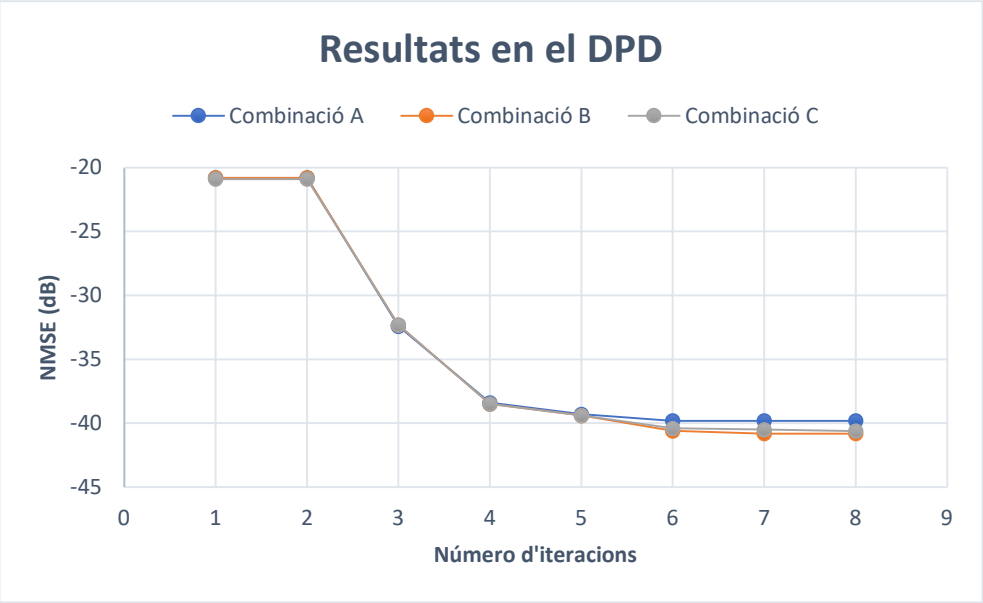

Figura 5.8 Evolució del valor del NMSE de les combinacions en funció del número d'iteracions

És necessari segons la normativa 3GPP que el EVM sigui igual o menor a un 8% per a una modulació 64QAM. En la figura 5.9 s'observa l'evolució de l'EVM a mesura que augmenta el número d'iteracions. En la iteració 1 ja compleix la normativa, tot i que a partir de la iteració 3 el valor de l'EVM millora considerablement obtenint un valor d'1,3%.

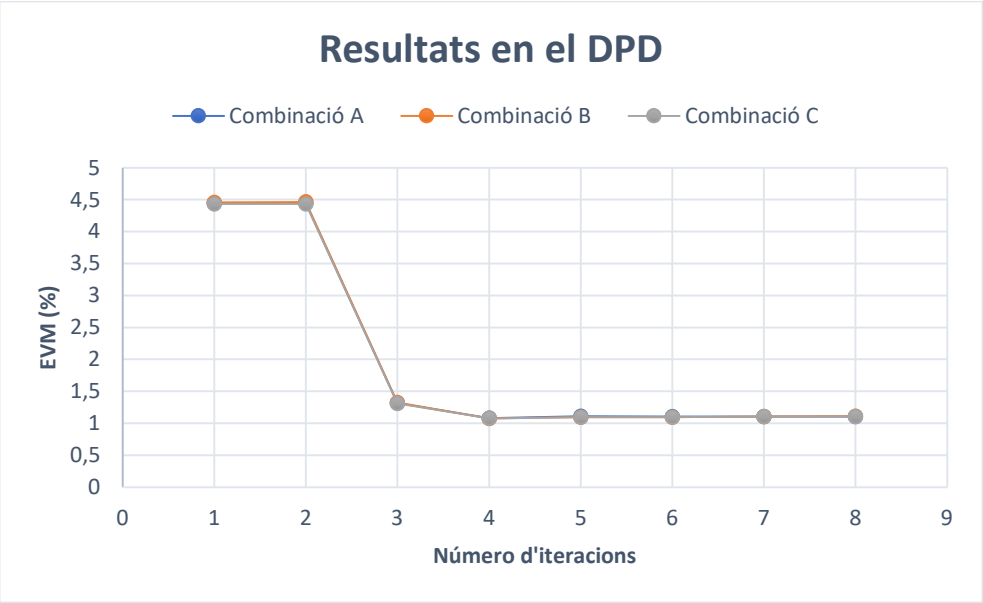

Figura 5.9 Evolució del valor de l'EVM en funció del número d'iteracions

A continuació s'observen les diferents gràfiques dels resultats de la combinació B. La figura 5.10 ens mostra el canal que s'utilitza i els seus adjacents. El senyal blau representa el senyal en la iteració 1 mentre que el senyal vermell representa

el de la iteració 8. Es pot contemplar una millora de 20 dB respecte les dues iteracions, on finalment el ACPR obtingut per la banda inferior és de -50 dB i per la banda superior és de -48,2 dB.

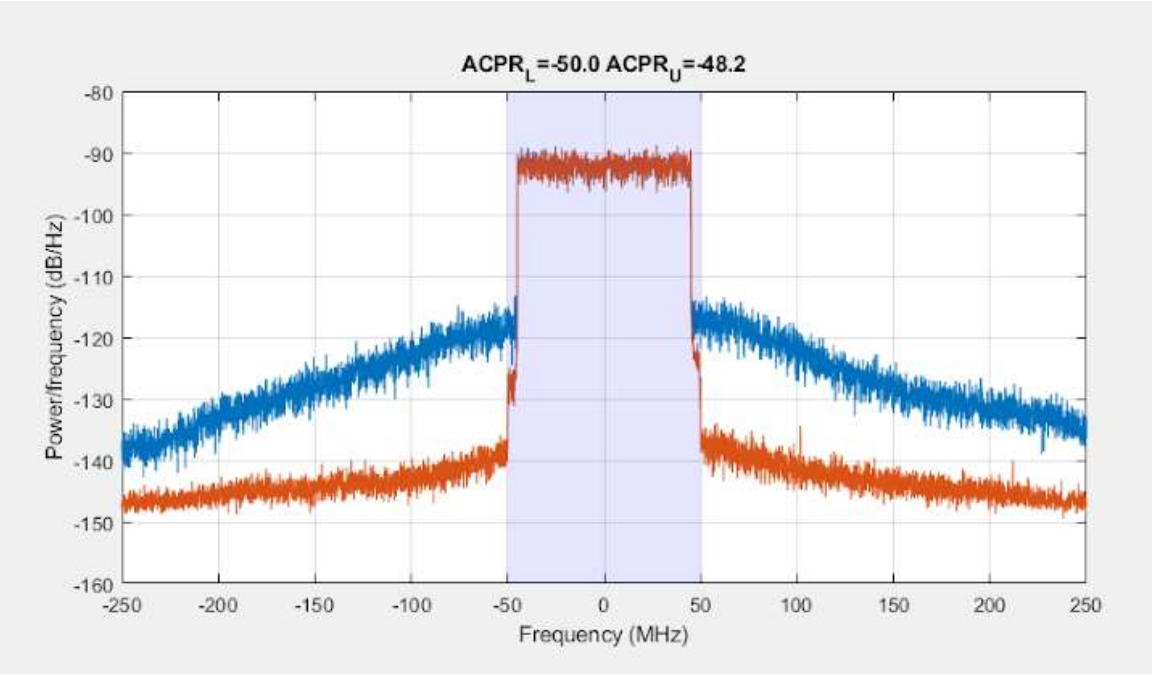

Figura 5.10 Espectre del senyal en la iteració 1 i 8

En la següent figura s'observen les corbes AM-AM i el valor del NMSE en l'última iteració. El traç de color blau s'ha obtingut en la iteració 1. El traç de color vermell fa referència a la iteració 8. És diferencia clarament com la corba de l'última iteració és molt similar a una recta, de manera que el DPD fa que el PA sigui el més lineal possible.

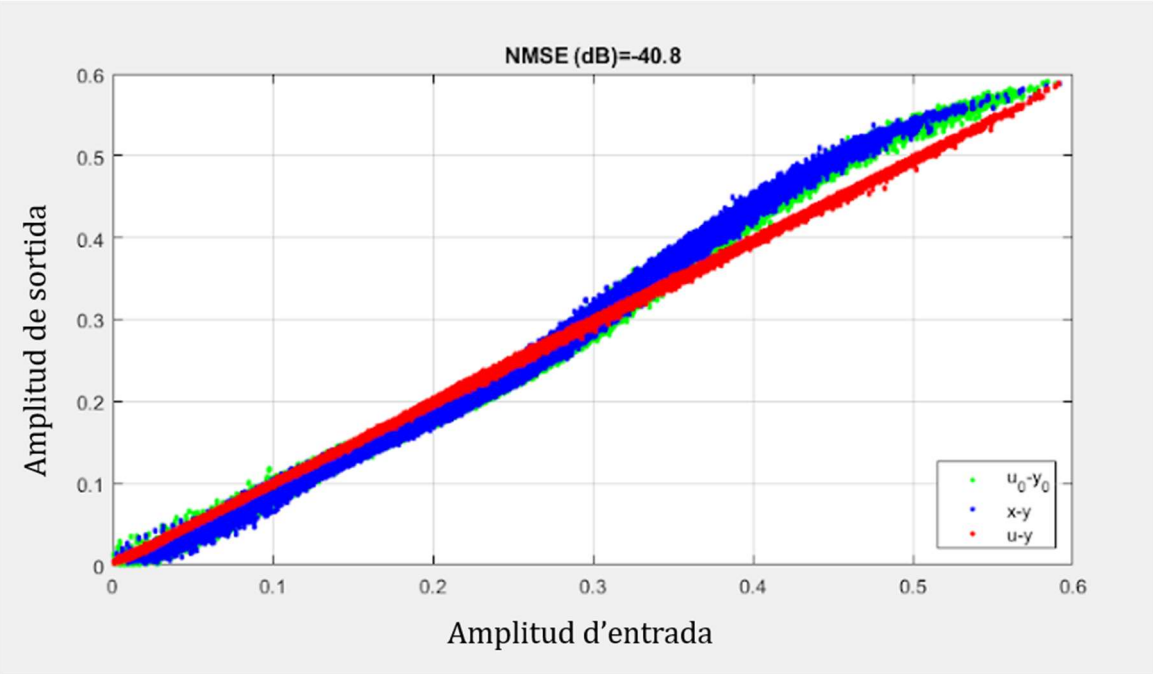

Figura 5.11 Corbes AM/AM en la iteració 1 i 8

El diagrama de constel·lació és un mètode de representació en el pla complex dels estats dels símbols en termes d'amplitud i fase. En color blau es troben els símbols sense DPD on s'observen les diferents mostres molt disperses, de manera que significa que hi ha soroll en el sistema. En color vermell es diferencien clarament els símbols ja que tots estan concentrats en les seves respectives caselles. En aquest últim cas no hi ha tant soroll com en la iteració 1.

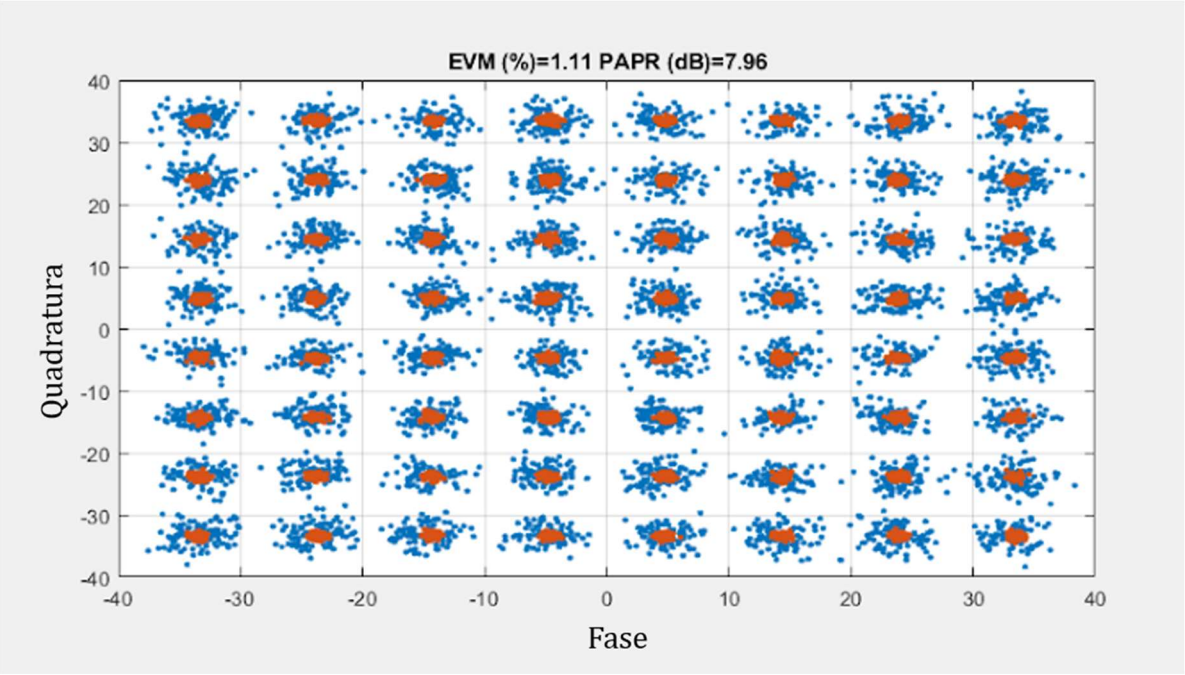

Figura 5.12 Diagrama de constel·lació en la iteració 1 i 8

En la figura 5.13 per una banda s'observa la corba característica AM-PM, la qual ens indica la conversió de la modulació d'amplitud del senyal d'entrada i la modulació de fase en el senyal de sortida. El traç de color blau fa referència a la iteració 1 que a diferència del traç vermell es pot observar que aquest últim no varia tant i es manté més pròxim dels 0º. És a dir, en la iteració 8 s'observa que hi ha menys desfasament. D'altra banda, en la part superior central del gràfic s'observa el número d'iteració, la potència de sortida i l'eficiència.

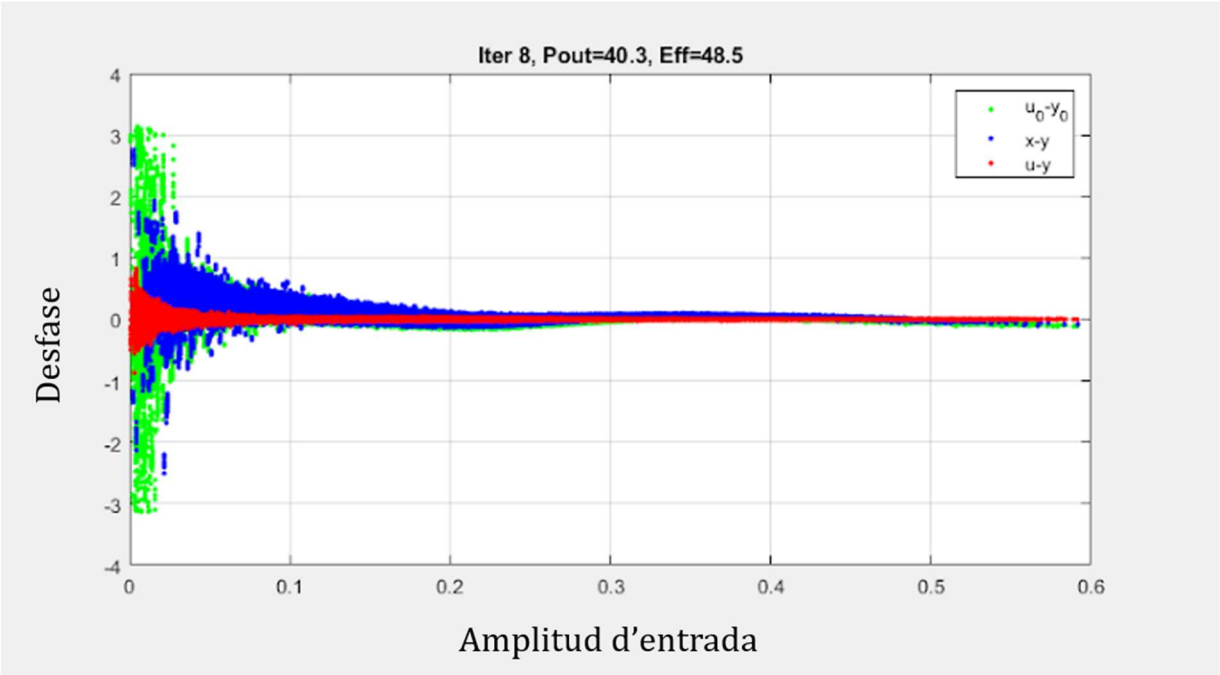

Figura 5.13 Corba AM-PM en la iteració 1 i 8

Gràcies als gràfics anteriors es pot observar el gran funcionament que té el DPD. La diferència significativa en tots els gràfics entre la iteració 1 i 8 ens permet observar la millora que comporten els diferents models escollits. Finalment es pot confirmar que les diferents combinacions escollides funcionen tant en l'entorn simulat com en l'entorn real.

CAPÍTOL 6. CONCLUSIÓ

L'amplificador de potència és un element molt important quan es parla sobre les comunicacions sense fil, és crucial que aquest dispositiu treballi de la millor manera possible. És per aquest motiu que el PA ha de ser el més eficient possible, això implica que treballi a prop del punt de compressió, per tant que treballi en una zona de no-linealitats. La predistorsió digital és la solució més extesa a aquest problema ja que corregeix les no-linealitats. Escollir correctament els models polinomials en el DPD és molt important.

En aquest treball s'han estudiat diferents models polinomials, dels quals alguns han donat millors resultats que d'altres. També s'ha estudiat la tècnica de reducció de coeficients DOMP, la qual ens ha donat uns molts bons resultats. Els millors resultats s'han obtingut amb els models GMP i DVR, el DVR ens ha donat uns resultats lleugerament millors que el GMP, tot i que ambdós models amb DOMP i en cascada ha estat la combinació que ens ha donat uns millors resultats arribant a un valor de NMSE en el modelat de la predistorsió ideal de -35 dB amb un ample de banda de 200 MHz.

Un altre model polinomial que s'ha estudiat ha estat el MP, encara que aquest no ens ha donat tants bons resultats, ja que el millor resultat de NMSE en el modelat de la predistorsió ideal que s'ha obtingut ha estat de -27,7 dB amb un ample de banda de 200MHz. Aquest model va ser un dels primers que es va proposar i a partir d'aquest es va crear el GMP. Per tant, clarament el GMP dona més bons resultats que el MP ja que és una evolució d'aquest.

La tècnica de reducció DOMP ha pres un paper molt important en aquest treball ja que ha estat el protagonista de la reducció de coeficients. Aquesta tècnica ens ha permès reduir el nombre de coeficients significativament ja que un valor de DVR que s'obté amb 230 coeficients ens ha permés obtenir-lo amb 70 coeficients. Per tant la reducció de número de coeficients ha estat de 160 coeficients.

L'objectiu principal d'aquest treball era que els models estudiats ens servissin com a models per a l'ús del DPD. Veient els resultats obtinguts es pot confirmar que l'objectiu ha estat satisfactori ja que tots els models escollits finalment compleixen la normativa del 3GPP, és a dir, el EVM de tots els models es troba per sota d'un 8%.

Aquests models polinomials no són els únics que s'estan estudiant per a un bon resultat en el DPD, actualment les xarxes neuronals (ANN, Artificial Neuronal Networks) tenen un paper molt important en aquest sector. En [15] s'ha estudiat quins resultats s'obtenen mitjançant les xarxes neuronals, i s'ha obtingut un valor de NMSE en el modelat de la predistorsió ideal de -40 dB amb 2000 coeficients.

Com a reflexió final en aquest treball, la combinació de models que ens ha donat un millor resultat ha estat el DVR i el GMP en cascada amb l'ús del DOMP. Com

a feina per al futur es troben dos camins diferents: per una banda, seguir investigant en la millora dels models i tècniques estudiats i d'altra banda, investigar en les xarxes neuronals, amb les quals s'obtenen uns molts bons resultats.

CAPÍTOL 7. BIBLIOGRAFIA

[1] Gilabert, P.L., López-Bueno D., Quyn Anh Pham T. and Montoro G.
Main de la teoria del Pere, “Machine Learning for Digital Front-End: a Comprehensive Overview”, , , 2-19 ()

[2] Gilabert, P.L., “Multi look-up table digital predistortion for RF power amplifier linearization”, Universitat Politècnica de Catalunya, Barcelona, 2007.

[3] Everything RF, “What is Envelope Tracking?”
https://www.everythingrf.com/community/what-is-envelope-tracking

[4] Prakash Nandi, O., “Behavioral Modeling of Power Amplifier with Memory Effect and Linearization Using Digital Pre Distortion”, University of Gävle, Gävle, 2016

[5] A. Zhu, "Decomposed Vector Rotation-Based Behavioral Modeling for Digital Predistortion of RF Power Amplifiers," *IEEE Transactions on Microwave Theory and Techniques*, vol. 63, no. 2, 737-744, (2015)

[6] Z. Dunn, M. Yeary, C. Fulton and N. Goodman, "Memory polynomial model for digital predistortion of broadband solid-state radar amplifiers," *2015 IEEE Radar Conference (RadarCon)*, 1482-1486, (2015).

[7] 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, 3852-3860, (2006)

[8] Barry, A.; Li, W.; Becerra, J.A.; Gilabert , P.L., “Comparison of Feature Selection Techniques for Power Amplifier Behavioral Modeling and Digital Predistortion Linearization”, Sensors, 21, 5772 (2021)

[9] Rydning, D. R. J. G. J., Reinsel, J., & Gantz, J., “The digitization of the world from edge to core” *Framingham: International Data Corporation*, 16, 1-28, (2018)

[10] Europa Press, “El 5G reducirá un 15% las emisiones de CO2 con respecto a las redes actuales, según el sector”
https://www.europapress.es/economia/noticia-5g-reducira-15-emisiones-co2-respecto-redes-actuales-sector-20191212150341.html

[11] W. Li, G. Montoro, W. Thompson, K. Chuang, and P. L. Gilabert, “Digital shaping and linearization of a dual-input load-modulated balanced amplifier,” *2023 International Workshop on Integrated Nonlinear Microwave and Millimetre-Wave Circuits (INMMiC)*, pp. 1–3, (2023)

[12] J. Chani-Cahuana, P. N. Landin, C. Fager and T. Eriksson, "Iterative Learning Control for RF Power Amplifier Linearization," *IEEE Transactions on Microwave Theory and Techniques*, vol. 64, no. 9, pp. 2778-2789, (2016)

[13] P. L. Gilabert and G. Montoro, "Digital Predistortion Linearization" Encyclopedia of RF and Microwave Engineering, 2nd Edition, Wiley. To be published.

[14] ETSI, “5G; NR; Base Station (BS) radio transmission and reception” 3GPP TECHNICAL SPECIFICATION 38.104version 15.2.0 Release 15. (2018)

[15] Fuentes, Aleix, “Linealización de un amplificador de potencia pseudo-doherty LMBA mediante redes neuronales”. (2024)