

UNIVERSIDADE FEDERAL DO PARANÁ

JOEL HUANCA CHAVEZ

**ESTUDO COMPARATIVO ENTRE AS ARQUITETURAS DE IDENTIFICAÇÃO DE
PRÉ-DISTORCEDORES DIGITAIS ATRAVÉS DAS APRENDIZAGENS DIRETA E
INDIRETA**

CURITIBA

2018

JOEL HUANCA CHAVEZ

**ESTUDO COMPARATIVO ENTRE AS ARQUITETURAS DE IDENTIFICAÇÃO DE
PRÉ-DISTORCEDORES DIGITAIS ATRAVÉS DAS APRENDIZAGENS DIRETA E
INDIRETA**

Dissertação apresentada como requisito parcial à obtenção do grau de Mestre em Engenharia Elétrica, no Curso de Pós-Graduação em Engenharia Elétrica, Setor de Tecnologia, da Universidade Federal do Paraná.

Orientador: Prof. Dr. Eduardo Gonçalves de Lima
Coorientador: Prof. Dr. Luis H. A. Lolis

CURITIBA
2018

C512e Chaves, Joel Huanca

Estudo comparativo entre as arquiteturas de identificação de pré-distorcedores digitais através das aprendizagens direta e indireta / Joel Huanca Chaves. – Curitiba, 2018.

67f. : il. [algumas color.] ; 30 cm.

Dissertação (mestrado) - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica.


Orientador: Eduardo Gonçalves de Lima

Coorientador: Luis H. A. Lolis

Bibliografia: p. 63-67

1. Amplificadores de potência. 2. Sistemas de comunicação sem fio. I. Universidade Federal do Paraná. II. Lima, Eduardo Gonçalves de. III. Lolis, Luis H.A. IV. Título.

CDD: 621.382



MINISTÉRIO DA EDUCAÇÃO
SETOR TECNOLOGIA
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA
ELÉTRICA

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA ELÉTRICA da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **JOEL HUANCA CHAVEZ** intitulada: **ESTUDO COMPARATIVO ENTRE AS ARQUITETURAS DE IDENTIFICAÇÃO DE PRÉ-DISTORCEDORES DIGITAIS ATRAVÉS DAS APRENDIZAGENS DIRETA E INDIRETA**, após terem inquirido o aluno e realizado a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 23 de Fevereiro de 2018.

Eduardo Gonçalves de Lima
EDUARDO GONÇALVES DE LIMA

Presidente da Banca Examinadora (UFPR)

Luís Carlos Vieira
LUIS CARLOS VIEIRA

Avaliador Externo (UTFPR)

André Augusto Mariano
ANDRÉ AUGUSTO MARIANO

Avaliador Interno (UFPR)

AGRADECIMENTOS

Em primeiro lugar, agradeço a Deus, pelo amor, o cuidado, a sabedoria e pelas pessoas que ele colocou no caminho do mestrado.

A minha amada esposa, Erika, por estar sempre ao meu lado, mesmo na distância. Pela paciência, o sacrifício e sobretudo pelo amor e o apoio que me motivaram em concretizar esta etapa.

A minha família, meus pais Patricio e Juana, meus irmãos Bana e Benjamin. Por me ensinar a dar sempre o melhor de mim, por acreditar na minha capacidade e pelo apoio incondicional, assim como aos meus sogros Eduardo e Alícia.

Ao meu orientador Prof. Eduardo Gonçalves de Lima pela disponibilidade, a paciência e o conhecimento transmitido, assim como ao Prof. Luis Lolis e aos colegas membros do GICS.

Aos amigos e colegas da Universidade Federal do Paraná.

Por fim agradeço à Organização de Estados Americanos (OEA), ao Grupo Coimbra de Universidades Brasileiras (GCUB) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior.

Digo e repito: Seja forte e corajoso!
Nada de desânimo e não fique com medo!
Lembre-se bem: O Senhor, o seu Deus,
estará com você, esteja onde estiver!

(Josué 1:9, Bíblia Viva)

RESUMO

A pré-distorção digital em banda base (DPD) é uma solução econômica no intuito de melhorar o compromisso entre a linearidade e a eficiência de amplificadores de potência (PAs) para comunicações sem fio. O projeto da DPD inclui a identificação de parâmetros de um modelo da pós-inversa ou da pré-inversa. Esse processo é baseado em medições de sinais de envoltória de valor complexo de tempo discreto. Para sinais com grande largura de banda e quando a operação do PA é feita em regimes fortemente não-lineares, os requisitos sobre a frequência de amostragem são muito rigorosos. Para relaxar as especificações no conversor analógico-digital (ADC) e digital-analógico (DAC), pode-se usar uma frequência de amostragem reduzida, ou empregar um polinômio com memória de largura de banda limitada. Além disso, para reduzir a quantidade de cálculos em uma aplicação em tempo real, os polinômios podem ser substituídos por tabelas de busca (LUTs) interpoladas linearmente.

A contribuição deste trabalho é apresentar um estudo comparativo entre as arquiteturas de aprendizagem indireta (pós-inversa) e direta (pré-inversa) para a identificação de parâmetros de uma DPD aplicada em quatro cenários de frequência de amostragem reduzida. Após uma discussão teórica, os quatro estudos de caso são relatados, com base em um sinal com envoltória LTE OFDMA e o modelo polinômio com memória (MP).

Os resultados da simulação em Matlab mostram que a aprendizagem indireta oferece uma capacidade de linearização muito próxima em relação à aprendizagem direta, porém exigindo um custo computacional significativamente menor.

Palavras-chave: Amplificadores de potência, aprendizagem direta, aprendizagem indireta, comunicações sem fio, linearização, LUT, polinômio com memória de largura de banda limitada, pré-distorcedor digital, subamostragem.

ABSTRACT

Digital baseband pre-distortion (DPD) is a cost-effective solution to improve the compromise between linearity and efficiency of power amplifiers (PAs) for wireless communications. The DPD design includes the parameter identification of a post-inverse or a pre-inverse model. This process is based on discrete-time complex-valued envelope signal measurements. For larger envelope bandwidths and stronger nonlinear regimes, the sampling frequency requirements are very stringent. To relax the specifications on the analog-to-digital (ADC) and digital-to-analog converter (DAC), a reduced sampling frequency, or the application of a limited bandwidth memory polynomial can be employed. Furthermore, to reduce the amount of calculations in a real-time application, polynomials can be replaced by linearly interpolated lookup tables (LUTs).

This work contribution is to report a careful comparison between indirect (post-inverse) and direct (pre-inverse) learning architectures for the DPD identification, applied in four scenarios of reduced sampling frequency. After a theoretical discussion, the four case studies are reported, based on an LTE OFDMA envelope signal and the memory polynomial (MP) model.

The results of the simulation in Matlab show that indirect learning offers a linearization capability that is very close to direct learning, but requires a significantly lower computational cost.

Key-words: Band-limited memory polynomial, digital pre-distorter, direct learning, indirect learning, linearization, LUT, power amplifiers, subsampling, wireless communications.

LISTA DE FIGURAS

Figura 1. Evolução da largura de banda em MHz	14
Figura 2. Consumo de energia de uma rede móvel e da estação base.	18
Figura 3. Curva característica de transferência de um PA.	20
Figura 4. Distorção no espectro de frequência de um amplificador de potência excitado por dois tons.	21
Figura 5. a) Ponto de intersecção. b) Alargamento espectral.	22
Figura 6. Conceitos básicos da DPD: a) Diagrama de blocos da conexão em cascata. b) Curva característica de transferência.	24
Figura 7. Elementos do sistema da pré-distorção digital.	25
Figura 8. Processo de amostragem quando cumprido o teorema de Nyquist.	27
Figura 9. (a)-(c) Subamostragem com <i>aliasing</i> . (d)-(f) Subamostragem com filtro anti- <i>aliasing</i>	28
Figura 10. Arquitetura de aprendizagem indireta.	29
Figura 11. Arquitetura de aprendizagem direta.	30
Figura 12. Análise na frequência da conexão em cascata DPD+PA.	31
Figura 13. Amostragem de Nyquist para a identificação do sistema.	32
Figura 14. DPD de largura de banda limitada: a) Diagrama de blocos. b) Modelo MP de largura de banda limitada.	33
Figura 15. Diagrama de blocos do modelo polinomial com largura de banda limitada.	35
Figura 16. Arquitetura de aprendizagem indireta com amostragem convencional: a) primeira iteração da identificação do PoD; b) cenário de identificação do PoD a partir da segunda iteração.	39
Figura 17. Arquitetura de aprendizagem direta com amostragem convencional.	40
Figura 18. Arquitetura de aprendizagem indireta com subamostragem: a) primeira iteração da identificação do PoD; b) cenário de identificação do PoD a partir da segunda iteração.	41
Figura 19. Arquitetura de aprendizagem direta com subamostragem.	41
Figura 20. Arquitetura de aprendizagem indireta em um cenário de largura de banda limitada: a) primeira iteração da identificação do PoD; b) cenário de identificação do PoD a partir da segunda iteração.	42

Figura 21. Arquitetura de aprendizagem direta em um cenário de largura de banda limitada.....	43
Figura 22. Identificação da DPD com largura de banda limitada e LUT: a) Primeira iteração da identificação do PoD com arquitetura de aprendizagem indireta; b) Cenário de identificação do PoD a partir da segunda iteração com arquitetura de aprendizagem indireta; c) Arquitetura de aprendizagem direta.....	44
Figura 23. Considerações no cálculo do ACPR.	46
Figura 24. PSDs dos sinais de saída do PA sem DPD e com as aprendizagens indireta e direta.....	49
Figura 25. PSDs dos sinais de saída do PA sem DPD e com as aprendizagens indireta e direta, recortado em uma banda de 60 MHz.	50
Figura 26. Características de transferência do PA, da DPD e da conexão em cascata usando aprendizagem indireta	51
Figura 27. Resultados de NMSE e ACPR da aprendizagem indireta com frequências de amostragem diferentes.....	52
Figura 28. PSDs dos sinais de saída do PA sem DPD e com a aprendizagem indireta a diferentes frequências de amostragem e aprendizagem direta.....	54
Figura 29. Características de transferência do PA, da DPD e da conexão em cascata usando aprendizagem indireta com subamostragem.....	55
Figura 30. PSDs dos sinais de saída do PA, em que: Conv. indica presença da DPD convencional; Ind. e Dir. referem-se às aprendizagens indireta e direta, respectivamente; BL indica largura de banda limitada.	57
Figura 31. Características de transferência para: o PA, a DPD de largura de banda limitada usando aprendizagem indireta e a conexão em cascata DPD+PA.....	58
Figura 32. PSDs dos sinais de saída do PA sem DPD, com DPD aplicando as arquiteturas de aprendizagens indireta e direta com largura de banda limitada e LUTs.....	59
Figura 33. Características de transferência do PA, da DPD e da conexão em cascata DPD+PA de largura de banda limitada com LUTs usando aprendizagem indireta. ..	60

LISTA DE TABELAS

TABELA I – INFORMAÇÃO ARMAZENADA NA LUT COM Q POSIÇÕES ENDEREÇÁVEIS	36
TABELA II – VALORES NUMÉRICOS DOS COEFICIENTES DO PA.....	45
TABELA III - RESULTADOS DE NMSE E ACPR QUANDO APLICADA AMOSTRAGEM CONVENCIONAL.....	48
TABELA IV - RESULTADOS DE NMSE E ACPR COM SUBAMOSTRAGEM.....	53
TABELA V - RESULTADOS DE NMSE E ACPR: CONVENCIONAL VERSUS LARGURA DE BANDA LIMITADA	56
TABELA VI - RESULTADOS DE NMSE E ACPR DA IDENTIFICAÇÃO DO MODELO MPLBL BASEADO EM LUT	59
TABELA VII - RESULTADOS COMPARATIVOS DE NMSE E ACPR DAS DIFERENTES TÉCNICAS DE REDUÇÃO DA FREQUÊNCIA DE AMOSTRAGEM.	61

LISTA DE ABREVIATURAS E SIGLAS

ACPR	- <i>Adjacent channel power ratio</i>
ADC	- Conversor Analógico-digital (do inglês, <i>Analog-to-Digital Converter</i>)
BLMP	- <i>Band-limited Memory Polynomial</i>
DAC	- Conversor Digital-analógico (do inglês, <i>Digital-to-Analog Converter</i>)
DC	- Corrente Contínua (do inglês, <i>Direct Current</i>)
DPD	- Pré-Distorção Digital em Banda Base (do inglês, <i>Digital Baseband Predistortion</i>)
EER	- <i>Envelope Elimination and Restoration</i>
ERB	- Estação de Rádio Base
IF	- Frequência Intermediária (do inglês, <i>Intermediate frequency</i>)
LINC	- <i>Linear Amplification with Nonlinear Components</i>
LPF	- Filtro Passa-Baixas (do inglês, <i>Low Pass Filter</i>)
LS	- Mínimos Quadrados (do inglês, <i>Least Squares</i>)
LTE	- <i>Long Term Evolution</i>
LUT	- <i>Look-up Table</i>
MP	- <i>Memory Polynomial</i>
NMSE	- Erro Quadrático Médio Normalizado (do inglês, <i>Normalized Mean Square Error</i>)
OFDMA	- <i>Orthogonal Frequency Division Multiple Access</i>
PA	- Amplificador de Potência (do inglês, <i>Power Amplifier</i>)
PAE	- Eficiência Potência Adicionada (do inglês, <i>Power Added Efficiency</i>)
PAPR	- <i>Peak to Average Power Ratio</i>
PARF	- <i>Radio Frequency Power Amplifier</i>
PoD	- Pós-distorcedor (do inglês, <i>Post-Distorter</i>)
PSD	- Densidade Espectral de Potência (do inglês, <i>Power Spectral Density</i>)
QAM	- <i>Quadrature Amplitude Modulation</i>
RF	- Rádio Frequência
UMTS	- <i>Universal Mobile Telecommunications System</i>
WCDMA	- <i>Wideband Code Division Multiple Access</i>

SUMÁRIO

1	INTRODUÇÃO	14
1.1	MOTIVAÇÃO	14
1.2	OBJETIVO	16
1.3	ORGANIZAÇÃO	16
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	AMPLIFICADORES DE POTÊNCIA DE RÁDIO FREQUÊNCIA	18
2.1.1	Eficiência	18
2.1.2	Linearidade	19
2.1.3	Compromisso entre linearidade e eficiência	19
2.1.4	Efeitos de não linearidades e figuras de mérito	20
2.1.5	Técnicas de linearização	22
2.2	PRÉ-DISTORÇÃO DIGITAL EM BANDA BASE (DPD).....	23
2.2.1	Modelo comportamental	25
2.3	SUBAMOSTRAGEM	27
3	IDENTIFICAÇÃO DE PRÉ-DISTORCEDORES DIGITAIS EM BANDA BASE	29
3.1	ARQUITETURAS DE APRENDIZAGEM	29
3.1.1	Aprendizagem indireta	29
3.1.2	Aprendizagem direta.....	30
3.2	TÉCNICAS DE REDUÇÃO DA FREQUÊNCIA DE AMOSTRAGEM.....	31
3.2.1	Amostragem convencional	31
3.2.2	Subamostragem	32
3.2.3	Polinômio com memória de largura de banda limitada (BLMP)	33
3.2.4	Polinômio com memória de largura de banda limitada baseado em LUT.....	34
4	CENÁRIOS DE COMPARAÇÃO ENTRE AS ARQUITETURAS DE APRENDIZAGEM DIRETA E INDIRETA.....	38
4.1	AMOSTRAGEM CONVENCIONAL	38
4.2	SUBAMOSTRAGEM	40
4.3	POLINÔMIO COM MEMÓRIA DE LARGURA DE BANDA LIMITADA.....	42
4.4	POLINÔMIO COM MEMÓRIA DE LARGURA DE BANDA LIMITADA BASEADO EM LUT	43

5	RESULTADOS DA SIMULAÇÃO E VALIDAÇÃO DOS ESTUDOS DE CASO	45
5.1	AMBIENTE DE SIMULAÇÃO	45
5.2	CENÁRIOS DE COMPARAÇÃO	47
5.2.1	Amostragem convencional	47
5.2.2	Subamostragem	51
5.2.3	Polinômio com memória de largura de banda limitada	55
5.2.4	Modelo BLMP baseado em LUT	58
6	CONCLUSÕES	61
	REFERÊNCIAS	63

1 INTRODUÇÃO

Na atualidade, no âmbito das comunicações móveis e das tecnologias sem fio, existe uma demanda crescente por novos serviços de voz, vídeo e dados, impondo a necessidade de elevadas taxas de transmissão, maior largura de banda e melhor nível de eficiência espectral. É por isso que são utilizadas técnicas de acesso múltiplo por divisão de código e modulações multinível, multiportadora ou ambos (M-QAM, OFDMA, WCDMA etc.) dando origem a padrões de sistemas de comunicação como UMTS, IEEE 802.11x, IEEE 802.16x e outros (D. RAYCHAUDHURI; N. MANDAYAM, 2012), conforme ilustra a Figura 1. No entanto, devido a esses padrões modularem a portadora tanto em amplitude quanto em fase, são produzidos sinais com envoltória variável e com uma elevada razão entre a potência de pico e a potência média (PAPR – *Peak to Average Power Ratio*). Assim, tais sinais requerem uma amplificação linear (WUNDER et al., 2013). Porém, o elemento responsável por amplificar a potência do sinal, o amplificador de potência (PA – *Power Amplifier*) de rádio frequência (RF), possui um comportamento não linear (LI; KAVEHRAD, 1999)(D. BRUBAKER, 2009) e é quem mais consome energia na cadeia de transmissão (S. ROY, 2008).




Figura 1. Evolução da largura de banda em MHz

1.1 MOTIVAÇÃO

Deseja-se, então, um sistema de amplificação com alta linearidade e alta eficiência, pois em sistemas móveis e em estações de rádio base (ERB) maior eficiência significa maior autonomia da bateria e menores custos de energia. No

entanto, uma melhora na eficiência está associada à diminuição da linearidade, e vice-versa. Quando o PA trabalha em regimes de compressão, a eficiência é elevada, porém não linearidades são introduzidas ao sistema, produzindo intermodulações e espalhamento espectral, entre outros, o que resulta em interferência nas bandas adjacentes (CRIPPS, 2006).

Neste contexto, a necessidade de encontrar um compromisso ótimo entre eficiência e linearidade nos PAs se torna uma exigência de qualidade essencial para a rede, pois a mesma tem que cumprir os requisitos ditados pelos órgãos regulatórios. Para atingir este compromisso há diferentes técnicas orientadas à busca da eficiência (LINC - *Linear Amplification with Nonlinear Components*, EER - *Envelope Elimination and Restoration*) e da linearidade (*feedforward*, *feedback* e a pré-distorção). Entre elas, a pré-distorção digital em banda base (DPD – *Digital Predistorter*) é uma das abordagens mais desenvolvidas e estudadas na literatura (ABDELAZIZ et al., 2016). Em uma conexão em cascata, a DPD é um bloco funcional que precede um dispositivo não linear (PA), fazendo-o operar na sua região mais eficiente, pois a DPD incrementa a região linear de operação e gera as distorções necessárias para cancelar as produzidas pelo PA.

Para aplicar esta técnica, é necessário conhecer e modelar o comportamento não linear e os efeitos de memória do PA (KU; KENNEY, 2003). Entre os modelos disponíveis na literatura, é comum o emprego de modelos descritos por equações matemáticas que possuem coeficientes ajustáveis. O modelo polinomial com memória (MP – *Memory Polynomial*), que é um caso especial das séries de Volterra, é um dos mais completos, com alta acurácia e baixa complexidade computacional. Nesse caso, o ajuste dos coeficientes é feito por um algoritmo de treinamento, baseado em um conjunto de medidas discretas no tempo das envoltórias complexas na entrada e na saída do PA (PEDRO; MAAS, 2005). Duas abordagens para a identificação dos coeficientes do modelo de uma DPD (BRAITHWAITE, 2011) serão comparadas neste trabalho. Na arquitetura de aprendizagem direta, os coeficientes são obtidos da pré-inversa (ou seja, da inversa que está localizada antes do PA na conexão em cascata) (BAUDOIN; JARDIN, 2001)(LIM et al., 1998). Na arquitetura de aprendizagem indireta, os coeficientes da pós-inversa (ou seja, da inversa que está localizada após o PA na conexão em cascata) são primeiramente obtidos e então copiados para uma pré-inversa de mesma topologia (EUN; POWERS, 1997)(MARSALEK et al., 2003).

Por outro lado, sinais como LTE *advanced* e futuras comunicações de onda milimétrica (*mm-wave*) possuem grande largura de banda, trazendo novos desafios para o projeto da DPD (KENINGTON, 2001)(FA-LONG, 2011)(GHANNOUCHI; HAMMI, 2010)(KIM; KONSTANTIINOOU, 2001), pois a largura de banda sofre um alargamento espectral causado pelas não linearidades introduzidas (LIU et al., 2015)(MONTORO; GILABERT, 2011), fazendo com que os conversores analógico-digital (ADC - *Analog-to-Digital Converter*) e digital-analógico (DAC - *Digital-to-Analog Converter*) possuam elevadas velocidades e altas taxas de amostragem (MURMANN, 2017), aumentando o consumo de energia, encarecendo o sistema de transmissão e tornando o projeto da DPD inviável. A frequência de amostragem de ambos será analisada em combinação com as arquiteturas direta e indireta, com ênfase no efeito de alargamento da largura de banda.

1.2 OBJETIVO

Este trabalho tem como objetivo avaliar comparativamente a acurácia de DPDs identificadas com base em duas abordagens diferentes: arquitetura de aprendizagem direta (BAUDOIN; JARDIN, 2001)(LIM et al., 1998) (ZHOU; DEBRUNNER, 2007) e arquitetura de aprendizagem indireta (EUN; POWERS, 1997)(MARSALEK et al., 2003), fornecendo como contribuição principal sua aplicação em quatro diferentes cenários de frequência de amostragem reduzida ou equivalentemente subamostragem. As avaliações são realizadas em termos de NMSE (*Normalized Mean Square Error*), ACPR (*Adjacent Channel Power Ratio*), complexidade computacional e convergência.

1.3 ORGANIZAÇÃO

Este trabalho está organizado da seguinte maneira.

O Capítulo 2 contém os fundamentos básicos e a teoria necessária para o desenvolvimento do trabalho. São aqui apresentados o compromisso entre a linearidade e a eficiência do PA, a técnica de linearização através da DPD e uma breve descrição do conceito de subamostragem.

O Capítulo 3 relata o desenvolvimento do projeto, detalhando as arquiteturas de aprendizagem indireta e direta e o funcionamento de quatro técnicas de redução da frequência de amostragem.

O Capítulo 4 detalha a contribuição deste trabalho, onde é relatada a aplicação das quatro técnicas de redução de frequência de amostragem anteriormente explicadas, junto com as aprendizagens indireta e direta.

O Capítulo 5 primeiramente detalha as características do ambiente de simulação, logo depois mostra os resultados das simulações dos quatro cenários de comparação. Por fim, o Capítulo 6 apresenta as conclusões deste trabalho.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 AMPLIFICADORES DE POTÊNCIA DE RÁDIO FREQUÊNCIA

O amplificador de potência de rádio frequência é um dispositivo ativo (não linear) que pertence à cadeia de transmissão de um sistema de comunicação sem fio e tem a função de amplificar a potência do sinal RF de entrada, convertendo a energia da fonte de alimentação de corrente contínua (DC – *Direct Current*) em potência RF, de modo que o sinal de saída possua maior energia no momento de ser transmitido (S. CRIPPS, 2006). Neste processo de transmissão, o PA é o elemento que mais consome energia (ROY, 2008), como mostrado na Figura 2.

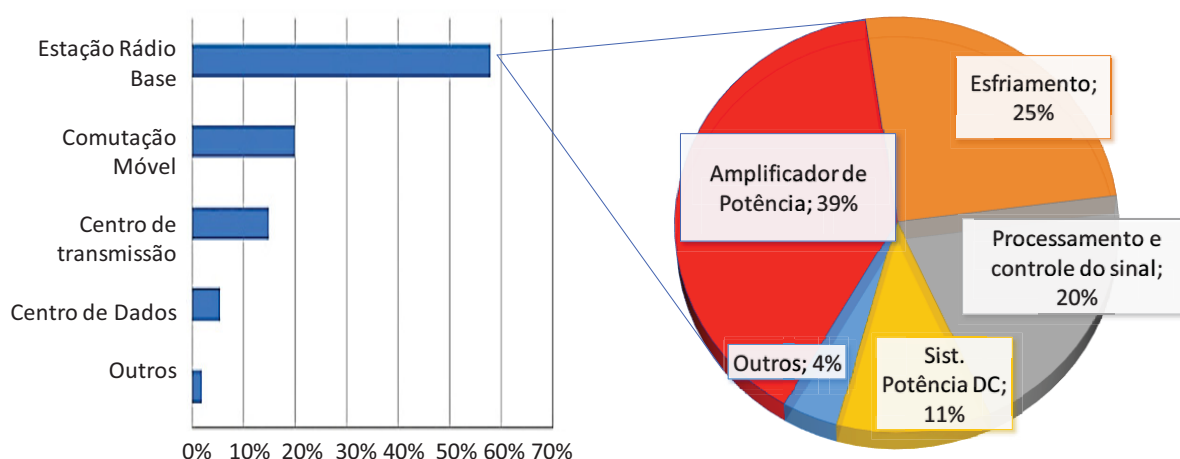


Figura 2. Consumo de energia de uma rede móvel e da estação base. FONTE: Modificado pelo autor de (ROY, 2008)

2.1.1 Eficiência

A eficiência é um dos parâmetros mais importantes do PA. Ela representa a diferença entre a quantidade de potência que é entregue à antena (P_{out}) e a potência de entrada (P_{in}), em relação à potência consumida pela fonte DC (P_{DC}), também chamada de eficiência de potência adicionada (PAE – *Power Added Efficiency*) (MKADEM, 2014), dada por:

$$PAE = \frac{P_{out} - P_{in}}{P_{DC}}. \quad (1)$$

Se o ganho do PA for baixo (menor que 10 dB) P_{in} é significativo em relação a P_{out} . Caso o ganho seja elevado, P_{in} é pequeno quando comparado com P_{out} . Então a eficiência é chamada de eficiência de conversão DC-RF (η), descrita por:

$$\eta = \frac{P_{out}}{P_{DC}}. \quad (2)$$

Para garantir que o sinal a ser transmitido tenha a máxima potência possível, deve-se obter uma alta eficiência. Isto significa um menor consumo da potência da fonte DC, uma menor potência de dissipação e, conseqüentemente, uma redução no custo do sistema de transmissão e um aumento da autonomia dos dispositivos móveis. Porém, a eficiência é um parâmetro conflitante com a linearidade.

2.1.2 Linearidade

Um sistema é linear se cumpre com os princípios de sobreposição e proporcionalidade, ou seja, para um sinal de entrada $x(t)$:

$$x(t) = h_1x_1(t) + h_2x_2(t), \quad (3)$$

o sistema produz um sinal de saída $y(t)$:

$$y(t) = h_1y_1(t) + h_2y_2(t), \quad (4)$$

onde h_1 e h_2 são constantes arbitrárias, $y_1(t)$ e $y_2(t)$ são as respostas respectivas às entradas isoladas $x_1(t)$ e $x_2(t)$. Um sistema que não obedece a estas condições é um sistema não linear (MAAS, 2003). Com essa ideia, a linearidade do amplificador é a capacidade de reproduzir, na saída, um sinal proporcional ao sinal de entrada. No domínio da frequência, linearidade significa que o sinal de saída deve manter valores não nulos nas mesmas frequências que o sinal de entrada. No entanto, o PA apresenta uma característica de transferência não linear, onde a amplitude na saída se comprime, como mostrado na Figura 3.

2.1.3 Compromisso entre linearidade e eficiência

Para evitar efeitos não desejados devido às não linearidades do PA, o mesmo deve ser mantido dentro da sua região linear, ou seja, deve ser operado em

baixos níveis de potência, onde o ganho (P_{in}/P_{out}) é constante. Porém, este comportamento é ineficiente. Para obter uma alta eficiência, a potência de entrada deve ser aumentada. Como mostrado na Figura 3, depois de um certo ponto a potência de saída deixa de ter uma correspondência linear com a potência de entrada e o ganho começa a diminuir. Esse fenômeno é conhecido como compressão de ganho, cuja figura de mérito é o ponto de compressão de 1 dB, definido como o ponto onde a potência de saída diminui 1 dB em relação à potência que seria obtida de forma linear ou ideal (PEDRO; CARVALHO, 2003).

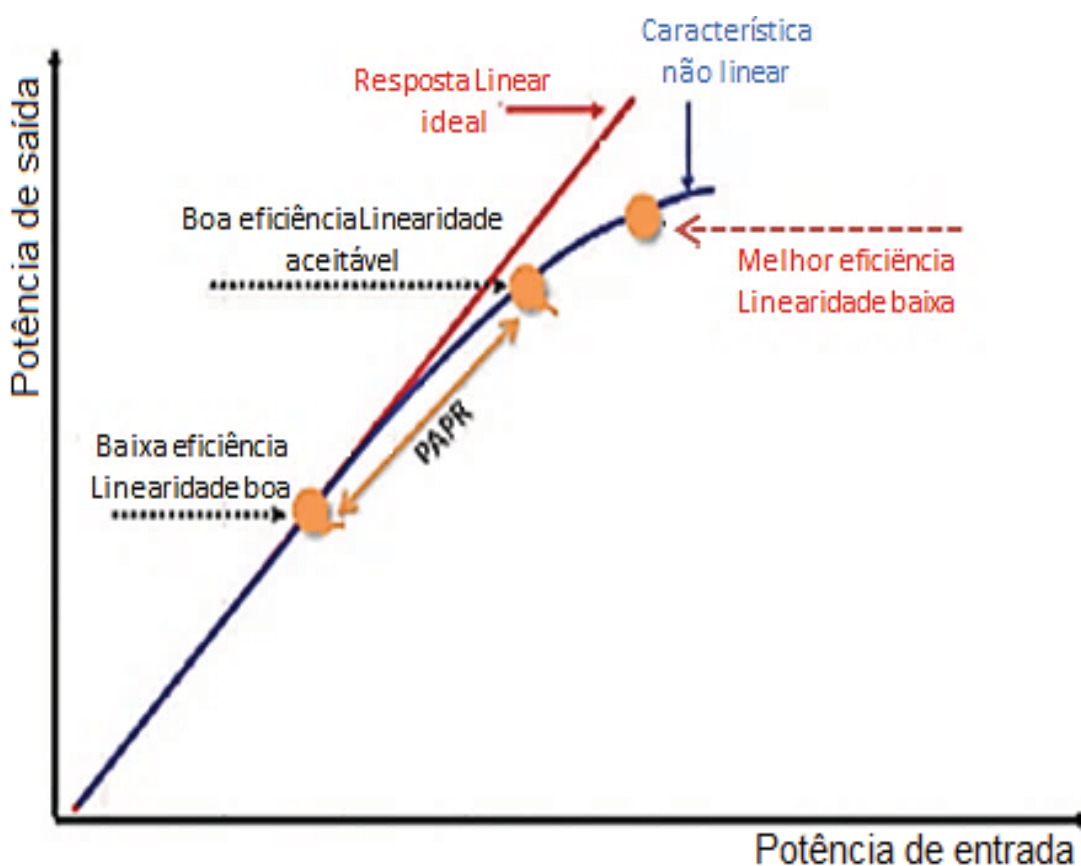


Figura 3. Curva característica de transferência de um PA. FONTE: Modificado pelo autor de (MINIHOLD; WAGNER, 2010)

O ponto de compressão de 1 dB é considerado um padrão de referência do ponto limite da operação linear, onde também a eficiência atinge um valor máximo, ilustrando claramente o compromisso entre eficiência e linearidade.

2.1.4 Efeitos de não linearidades e figuras de mérito

Na saída do PA podem existir valores não nulos em frequências não excitadas pelo sinal de entrada, conhecidas como distorções harmônicas e

distorções de intermodulação, causando interferências entre canais adjacentes (KU; KENNEY, 2003) e descumprindo as exigências de linearidade exigidas pelos órgãos regulatórios.

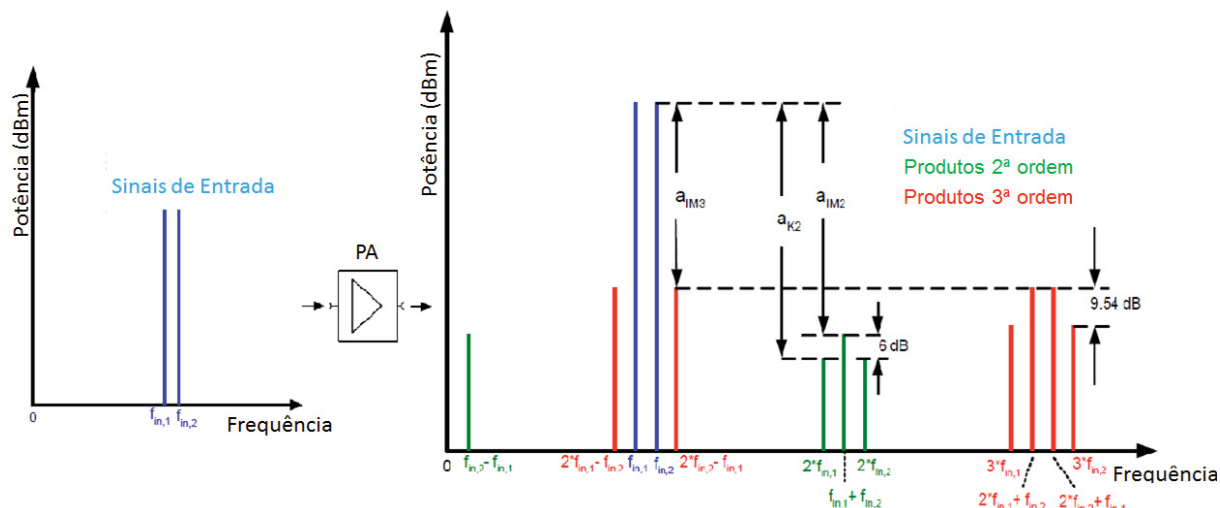


Figura 4. Distorção no espectro de frequência de um amplificador de potência excitado por dois tons.
 FONTE: Modificado pelo autor de (MINIHOLD; WAGNER, 2010)

A Figura 4 representa os espectros de frequência das distorções produzidas na saída de um PA excitado por um sinal senoidal de dois tons (ω_1 e ω_2) (MINIHOLD; WAGNER, 2010), onde pode-se ver que a distorção harmônica ocorre fora da banda passante do PA e pode ser eliminada facilmente por filtragem, assim como os produtos de intermodulação de ordem maior. Isso não acontece com os produtos de intermodulação que estão localizados perto da frequência fundamental (KENINGTON, 2001)(LAERT, 2003). O ponto de intersecção de terceira ordem (IP3) (PEDRO, CARVALHO, 2003)(GILMORE; BESSER, 2003) é uma outra figura de mérito para caracterizar a linearidade do PA, representada na Figura 5a. É definido como o ponto em que a inclinação da reta da componente fundamental intercepta a inclinação da reta do produto de intermodulação de terceira ordem, em uma representação logarítmica da potência de saída em função da potência de entrada. Quanto maior o valor de IP3, menor é a distorção para um determinado nível de potência, ou seja, um ponto de intersecção grande indica uma maior região de linearidade.

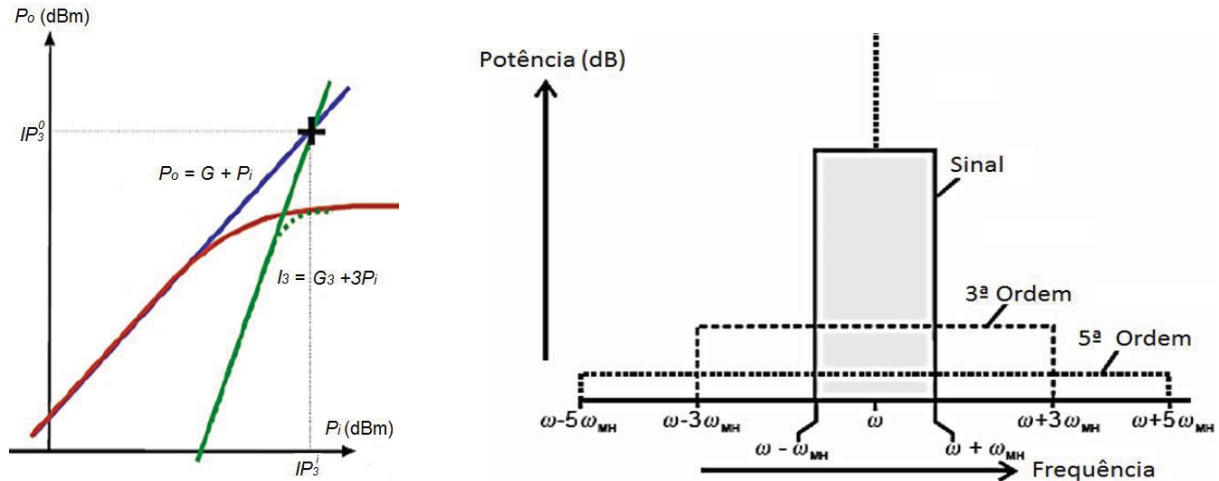


Figura 5. a) Ponto de intersecção. b) Alargamento espectral. FONTE: Modificado pelo autor de (MINIHOLO; WAGNER, 2010)

Em virtude dos produtos de intermodulação, a não linearidade do PA produz alargamento espectral, que é uma extensão da banda original para uma faixa tantas vezes maior quanto a ordem da não linearidade (TSIMBINOS; LEVER, 1998), como mostrado na Figura 5b, ocasionando ocupação dos canais adjacentes ao canal principal (MAAS, 2003). Para quantificar esse fenômeno, a razão de potência de canal adjacente (ACPR - *Adjacent Channel Power Ratio*) é definida como a relação entre a potência da saída integrada no canal principal e a potência total nas bandas adjacentes (PEDRO; CARVALHO, 2003), ou seja:

$$ACPR = 10 \log_{10} \left[\frac{\int_{adj} |Y_{ref}(f)|^2 df}{\int_{main} |Y_{ref}(f)|^2 df} \right], \quad (5)$$

em que $Y_{ref}(f)$ indica a densidade espectral de potência (PSD - *Power Spectral Density*) do sinal.

2.1.5 Técnicas de linearização

Até agora, é claro que um dos grandes desafios no projeto de um PA é a busca por uma solução ótima ao compromisso linearidade e eficiência, ou seja, que permita uma amplificação altamente linear mantendo bons níveis de eficiência, que permita compensar as distorções de intermodulação e que garanta um menor consumo de energia no sistema de transmissão. Na literatura se encontram diferentes técnicas de linearização:

- a nível de dispositivo, controlando os efeitos de carga do transistor na entrada (*Source-Pull*), na saída (*Load-Pull*) e no ponto de polarização (*Sweet-spot*) (SÁNCHEZ et al., 2009);

- a nível de sistema, encaminhadas à eliminação da distorção (LINC, EER) e as que buscam a redução das distorções (*Feedforward*, *feedback* e pré-distorção) (KENINGTON, 2001).

As técnicas em nível de dispositivo são difíceis de controlar e as destinadas a eliminar a distorção são utilizadas no projeto de amplificadores em arquiteturas mais eficientes que fogem do escopo deste trabalho. Por outro lado, as técnicas que buscam a redução da distorção são utilizadas para modulações multinível como as que são objeto de estudo neste trabalho, entre elas, podem-se citar:

- a técnica *feedforward* (RUMMERY; BRANNER, 1997), que tem bom desempenho de largura de banda e boa estabilidade, porém apresenta baixa eficiência energética, além de alta complexidade;

- a técnica de *feedback*, que apresenta problemas de instabilidade e não atende altas larguras de banda (KIM et al., 2010);

- a técnica de pré-distorção (BONDAR; BUDIMIR, 2009) pode ser implementada de forma analógica (Pré-distorção em RF/IF) (YI et al., 2000) ou digital (Pré-distorção em Banda Base) (LARSON et al., 2006). A primeira tem baixo custo, capacidade de linearização modesta e controle complexo. Dessa forma, a pré-distorção digital é escolhida como objeto de estudo deste trabalho. A justificativa da escolha é detalhada na seção seguinte.

2.2 PRÉ-DISTORÇÃO DIGITAL EM BANDA BASE (DPD)

A pré-distorção é um dos esquemas de linearização mais comuns e amplamente utilizada em sistemas de comunicação sem fio terrestres e por satélite, devido a sua capacidade de linearização e sua simplicidade de aplicação, para atingir alta eficiência e alta linearidade. Do ponto de vista de eficiência, pode-se usar um PA menos linear e mais econômico, mas com elevado rendimento, logo irá consumir menos potência. Do ponto de vista de linearização, eliminam-se os produtos de intermodulação, asseguram-se razoáveis larguras de banda e compensam-se efeitos de memória. A DPD tem simplicidade de aplicação no uso de

diversos algoritmos adaptativos na identificação dos seus parâmetros, melhorando seu desempenho ante sinais de envoltória variável.

Conceitualmente, consiste em conectar um bloco pré-distorcedor (DPD), diante do dispositivo não linear (PA), representados pelas funções compostas $G(x_n)$ e $F(v_n)$ respectivamente, com a ideia de inserir o inverso desse comportamento não linear. Matematicamente, a Figura 6a mostra a relação funcional dos blocos DPD e PA conectados em cascata, onde os sinais de entrada x_n e saída v_n da DPD estão relacionados por $v_n = G(x_n)$, e os sinais de entrada v_n e saída y_n do PA por $y_n = F(v_n)$. Então, y_n tem de ser uma réplica linear de x_n :

$$y_n = F[G(x_n)] = kx_n, \quad (6)$$

onde k é um ganho linear. Para cumprir com (6):

$$G(x_n) = F^{-1}(y_n). \quad (7)$$

Então o operador da DPD, $G(x_n)$, proporciona uma característica de transferência inversa em relação ao operador do PA, $F(v_n)$, de modo que, na saída do sistema em cascata DPD+PA, é obtido um sinal que é uma versão linear do sinal de entrada, como mostrado na Figura 6b, onde também pode-se observar a característica expansiva da DPD, em contraste com o aspecto da compressão que possui o PA.




Figura 6. Conceitos básicos da DPD: a) Diagrama de blocos da conexão em cascata. b) Curva característica de transferência. FONTE: O autor (2017)

A Figura 7 mostra os elementos que complementam o sistema DPD+PA para o seu correto funcionamento. Têm-se os conversores analógico-digital (ADC), usado na realimentação da saída do amplificador de potência, e o digital-analógico (DAC), usado para atuar sobre a entrada do amplificador. Também, são usados misturadores, demoduladores e moduladores, para deslocar a saída de RF do PA para a banda base (BB) e vice-versa. As imperfeições desses elementos limitam a eficácia e o desempenho da linearização de uma DPD, estando assim condicionada pela quantidade de parâmetros ou coeficientes do modelo comportamental, a quantidade e o tipo de operações envolvidas na pré-distorção, a frequência de amostragem dos ADCs e DACs e as imperfeições nos filtros de reconstrução e nos moduladores IQ.

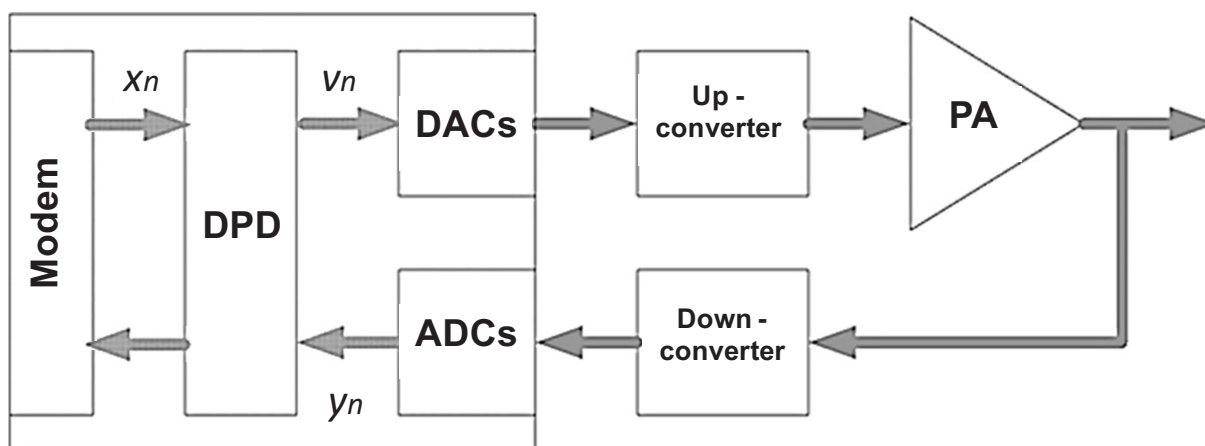


Figura 7. Elementos do sistema da pré-distorção digital. FONTE: Modificado pelo autor de (YU et al., 2012)

2.2.1 Modelo comportamental

Para projetar uma DPD, o primeiro passo é escolher a topologia do modelo comportamental que o implementa. Este modelo deve:

- considerar efeitos de memória, não desprezíveis em comunicações de banda larga, atribuídos a respostas em frequência não ideais do circuito de polarização e das redes de casamento de impedâncias;
- considerar não linearidades, associadas à compressão e saturação do ganho de potência dos transistores;
- manipular sinais de envoltória de valores complexos;
- fornecer uma relação não linear entre os sinais de envoltória de entrada e saída;

- executar a menor quantidade de cálculos possível, ou seja, ter baixo custo computacional, além de ser de fácil implementação.

Entre os modelos disponíveis na literatura, as escolhas mais comuns são as redes neurais artificiais (NASKAS; PAPANANOS, 2004) (CHIPANSKY, 2015), e as séries de Volterra (PEDRO; MAAS, 2005) (BAUDOIN; JARDIN, 2001) (EUN; POWERS, 1997)(YU et al., 2012). Em comum, todos eles têm coeficientes ajustáveis e podem ser identificados com as duas arquiteturas de identificação apresentadas neste trabalho. Porém, sendo o foco deste trabalho a maneira de encontrar o conjunto ótimo destes coeficientes, utiliza-se o modelo baseado em simplificações da série de Volterra conhecido como polinômio com memória (MP) (KIM; KONSTANTIINO, 2001)(MKADEM, 2014), uma vez que ele estima os efeitos de memória, pois utiliza amostras de entradas passadas ($n-m$, com m de 0 a M) para estimar a amostra de saída instantânea (n), apresenta uma boa relação entre acurácia de modelagem e complexidade computacional, ao fornecer um mapeamento não linear fazendo com que a saída seja uma função polinomial da envoltória complexa de entrada, e, em contraste com as redes neurais, é linear nos seus parâmetros $h_{2p-1,m}$. A equação característica do modelo MP é (KIM; KONSTANTIINO, 2001) :

$$v_n = \sum_{p=1}^P \sum_{m=0}^M h_{2p-1,m} |x_{n-m}|^{2p-2} x_{n-m}, \quad (8)$$

onde $h_{2p-1,m}$ são coeficientes de valor complexo, P é a ordem de truncamento polinomial e M é o tamanho da memória.

Uma vez escolhido o modelo comportamental, o passo seguinte é a identificação de seus coeficientes ou parâmetros. Dois tipos de arquiteturas permitem encontrar os valores ótimos destes parâmetros (BRAITHWAITE, 2011): a arquitetura de aprendizagem direta (BAUDOIN; JARDIN, 2001)(LIM et al., 1998) (ZHOU; DEBRUNNER, 2007) e a arquitetura de aprendizagem indireta (EUN; POWERS, 1997)(MARSIALEK et al., 2003).

Na arquitetura de aprendizagem direta, a função objetivo a minimizar é o erro quadrático médio de um sinal de erro definido pela diferença entre os sinais de entrada e saída de uma conexão em cascata dada por um modelo da pré-inversa, seguida por um modelo do PA. Na arquitetura de aprendizagem indireta, a

otimização destina-se a minimizar o erro quadrático médio de um sinal de erro definido pela diferença entre os sinais desejados e medidos na saída de um modelo da pós-inversa.

2.3 SUBAMOSTRAGEM

Na implementação da DPD são empregados tanto conversores digital-analógicos (DACs), para que sequências digitais pré-distorcidas fornecidas pela DPD sejam usadas para alimentar o PA analógico, quanto conversores analógico-digitais (ADCs), para que saídas analógicas do PA possam ser usadas de maneira adequada para a identificação digital do pré-distorcedor. Nesse processo, a frequência de amostragem (ω_s) desses conversores é uma característica muito importante pois seu consumo de potência aumenta proporcionalmente com a ω_s , elevando o custo desses dispositivos. Segundo o teorema de Nyquist (NYQUIST, 1928), um sinal pode ser reconstituído se forem extraídas amostras em intervalos de tempo de no mínimo o inverso da largura de banda do sinal, sendo essa largura de banda definida pela diferença entre a maior frequência (positiva) e a menor frequência (negativa) contida no sinal, como mostrado no espectro de frequência da Figura 8, onde a frequência de amostragem ω_s do trem de impulsos que amostra o sinal $X_c(\omega)$ é maior do que a largura de banda $2\omega_N$ do sinal. Assim para reconstruir o sinal original é aplicado um filtro passa-baixas (LPF - *Low Pass Filter*),

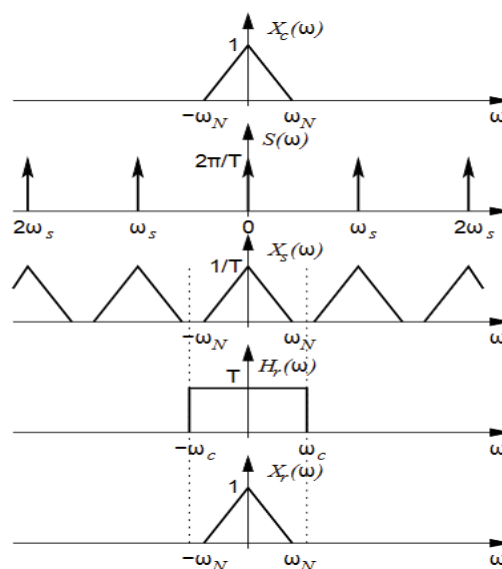


Figura 8. Processo de amostragem quando cumprido o teorema de Nyquist. FONTE: Modificado pelo autor de (LYONS, 2004)

O cumprimento do teorema de Nyquist na aplicação da DPD pode ser uma tarefa difícil de ser realizada. De fato, a frequência de amostragem que cumpre essa restrição é muito alta quando a largura de banda do sinal é elevada. Nos últimos anos, foram relatadas na literatura algumas técnicas para a identificação de esquemas de DPD baseadas em medidas que adotam a técnica de subamostragem ou frequências de amostragem reduzidas (YU et al., 2012)(LIU et al., 2014)(BRAITHWAITE, 2015)(LIU et al., 2015)(ZHANG et al., 2015)(CHAVEZ; LIMA, 2017a)(CHAVEZ et al., 2017). A redução da frequência de amostragem produz um fenômeno conhecido como *aliasing*, que é a superposição dos espectros do sinal original, deformando o sinal durante a reconstrução, como se vê na Figura 9.

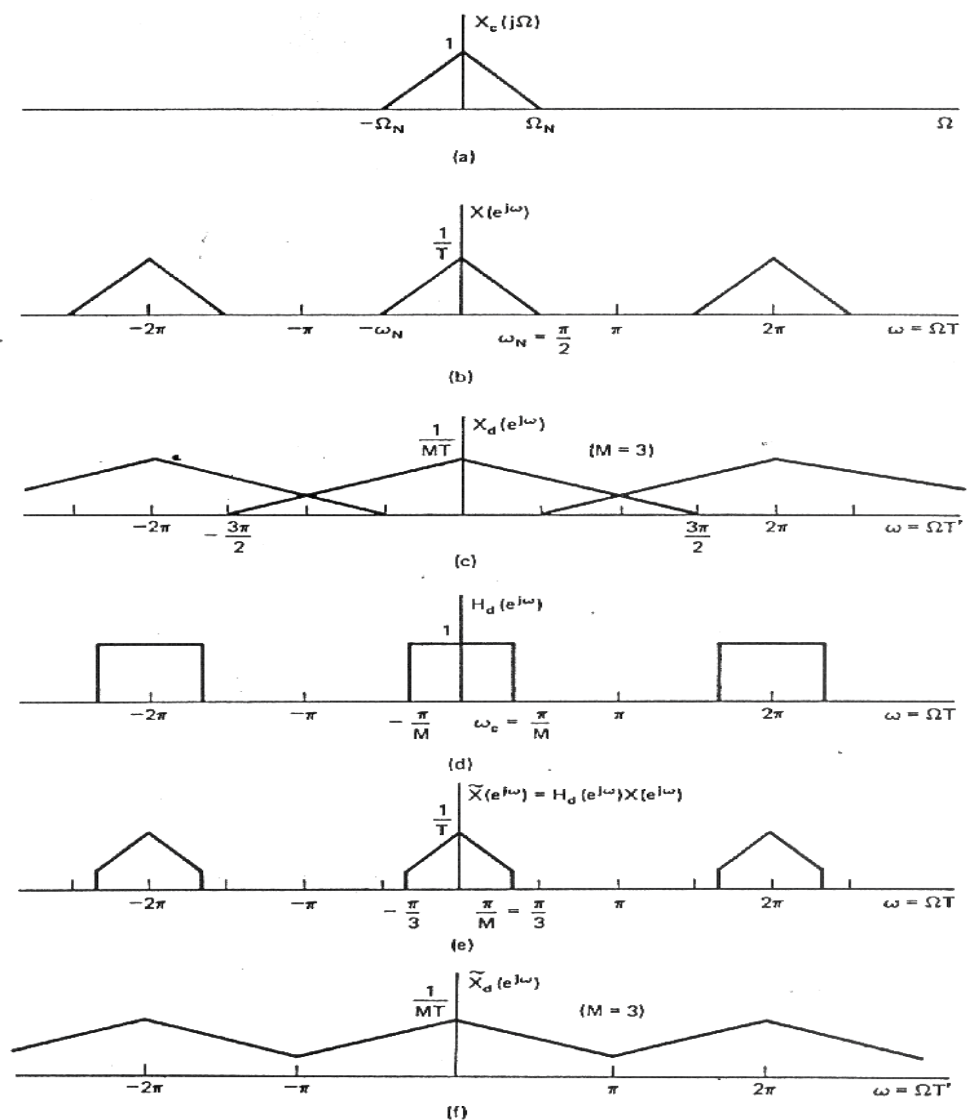


Figura 9. (a)-(c) Subamostragem com *aliasing*. (d)-(f) Subamostragem com filtro anti-*aliasing*. FONTE: Modificado pelo autor de (LYONS, 2004)

3 IDENTIFICAÇÃO DE PRÉ-DISTORCEDORES DIGITAIS EM BANDA BASE

Neste capítulo, é explicado o funcionamento dos algoritmos de identificação de parâmetros das arquiteturas de aprendizagem direta e indireta. Logo depois, são detalhadas as técnicas de subamostragem e redução de frequências de amostragem e, finalmente, é discutida uma técnica onde são empregadas tabelas de busca (LUTs – *Look-up Tables*).

3.1 ARQUITETURAS DE APRENDIZAGEM

A aprendizagem da DPD é realizada por um algoritmo de identificação dos valores ótimos dos coeficientes ou parâmetros do seu modelo. A seguir se detalham duas técnicas para a identificação desses coeficientes ajustáveis presentes no modelo que implementa a DPD: a aprendizagem indireta e a aprendizagem direta.

3.1.1 Aprendizagem indireta

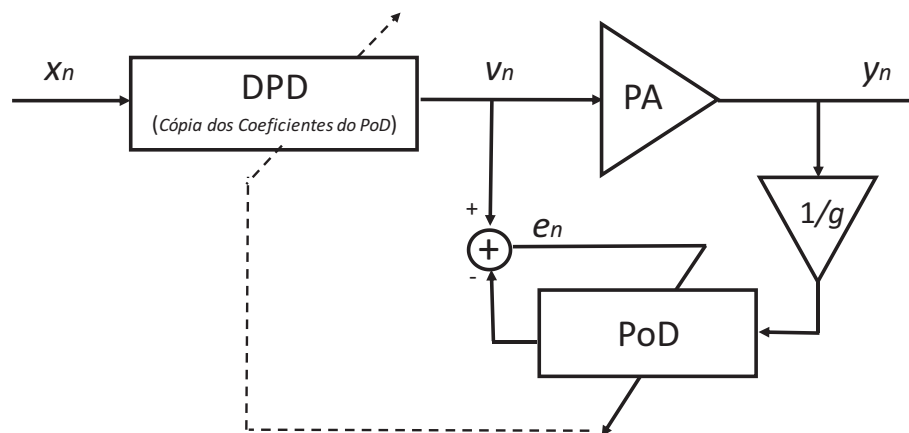


Figura 10. Arquitetura de aprendizagem indireta. FONTE: Modificado pelo autor de (EUN; POWERS, 1997)

A arquitetura de aprendizagem indireta identifica (EUN; POWERS, 1997)(MARSALEK et al., 2003) os parâmetros de um modelo pós-distorcedor (PoD - *Post-Distorter*), ou seja, de uma inversa localizada após o PA na conexão em cascata, como mostra a Figura 10. A identificação é baseada em medições realizadas nos sinais de entrada v_n e saída do PA y_n , sem a necessidade de conhecimento do modelo do PA, os papéis da entrada e da saída são trocados, ou seja, a entrada do PoD é igual à saída do PA (dividida por um ganho linear g), enquanto que a saída desejada do PoD é igual à entrada do PA. Aproveitando que

para modelos baseados em polinômios truncados na $(2P-1)$ -ésima ordem, a pré- e a pós-inversa são idênticas (DPD e PoD) (SCHETZEN, 1976), o modelo da DPD é então usado como um modelo de PoD, que é linear do ponto de vista dos coeficientes desconhecidos. Assim, pode-se obter os $h_{2p-1,m}$ parâmetros de (8) através de um algoritmo linear, como os mínimos quadrados (LS – *Least Squares*). Uma vez identificados os parâmetros do PoD, esses valores são copiados para uma DPD, idêntica no modelo polinomial. A aprendizagem indireta é realizada em malha aberta, já que o bloco da DPD não é envolvido na estimativa dos coeficientes.

3.1.2 Aprendizagem direta

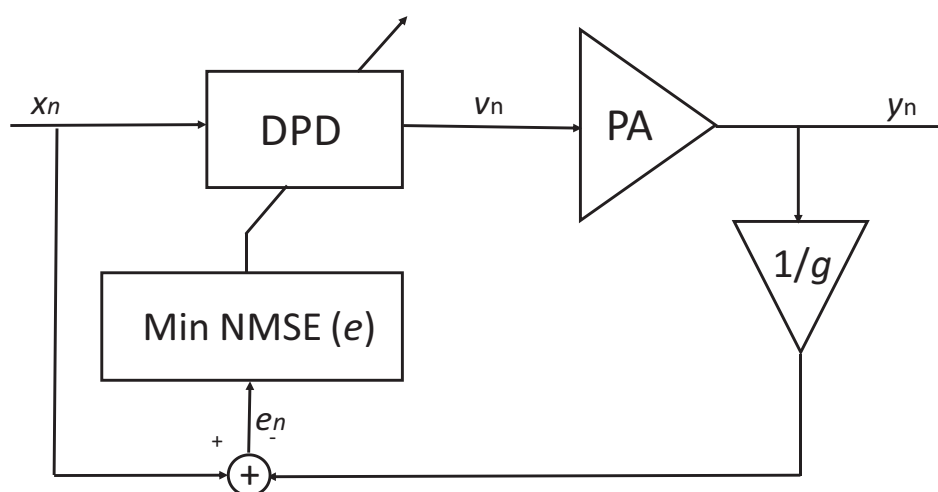


Figura 11. Arquitetura de aprendizagem direta. FONTE: Modificado pelo autor de (BAUDOIN; JARDIN, 2001)

A aprendizagem direta (BAUDOIN; JARDIN, 2001)(LIM et al., 1998) identifica os parâmetros da função pré-inversa (DPD) em uma conexão em cascata com o PA (como mostrado na Figura 11), onde se deseja que a saída do PA seja uma réplica linear do sinal de entrada da DPD. Como a saída desejada da DPD é desconhecida, a aprendizagem direta deve minimizar o erro quadrático médio entre os sinais na entrada x_n e saída y_n da cascata (dividido por um ganho linear g). Nesse caso, o modelo do PA manipula de forma não linear o sinal de saída da DPD. Assim, embora o modelo da DPD seja linear nos parâmetros, o sinal de erro é uma função não linear dos parâmetros da DPD, mostrando a necessidade de ferramentas de otimização não linear, como Levenberg-Marquardt (OSBORNE, 1976) e Gauss-Newton, entre outros, que são fortemente condicionados pela estimativa inicial, o que pode levá-los a ficar presos em mínimos locais, que só podem ser corrigidos

pela inclusão de algoritmos adicionais (por exemplo, algoritmos genéticos, arrefecimento simulado, etc), o que resulta em maior complexidade computacional do que um algoritmo linear como os mínimos quadrados.

3.2 TÉCNICAS DE REDUÇÃO DA FREQUÊNCIA DE AMOSTRAGEM

Como foi explicado no Capítulo 2, a DPD gera distorções produzindo um alargamento espectral do sinal. Isto afeta o emprego dos conversores analógico/digital (ADC) e digital/analógico (DAC), pois se veem obrigados a atingir elevadas frequências de amostragem. Com o intuito de relaxar as especificações desses conversores, são relatadas algumas técnicas de redução de frequência de amostragem e a sua influência no processo de linearização quando aplicado e implementado junto à DPD.

3.2.1 Amostragem convencional

Na Figura 12, observa-se que a presença de não linearidades no circuito do PA faz com que a largura de banda da envoltória complexa seja aumentada ao passar pelo PA. Isto significa que, para uma não linearidade polinomial de $(2P-1)$ -ésima ordem, a largura de banda de saída é $2P-1$ vezes maior do que a largura de banda de entrada (TSIMBINOS; LEVER, 1998). Quando implementada a DPD, ela é alimentada com um sinal de envoltória não distorcida x_n . As não linearidades dentro do modelo da DPD distorcem intencionalmente o sinal de entrada da DPD x_n , causando o aumento do espectro do sinal na sua saída v_n , aplicado como entrada do PA. As distorções não lineares geradas pelo PA cancelam as produzidas pela DPD, fornecendo uma saída do PA não distorcida y_n , como mostrado na Figura 12.




Figura 12. Análise na frequência da conexão em cascata DPD+PA. FONTE: O Autor (2017)

Portanto, para garantir que nenhum sinal seja corrompido pela sobreposição das réplicas (efeito *aliasing*), de acordo com o critério de Nyquist o sinal de

envoltória complexa deve ser amostrado a uma frequência igual ou superior a sua largura de banda. Ou seja, a frequência de amostragem (f_s) na saída da DPD deve ser definida, pelo menos, como $2P-1$ vezes a largura de banda do sinal de envoltória não distorcida.

3.2.2 Subamostragem

Para sinais com grande largura de banda, como LTE *advanced* e futuras comunicações de onda milimétrica (*mm-wave*), a largura de banda do sinal distorcido e a ordem de truncamento não linear $2P-1$ assumem valores elevados ao mesmo tempo, tornando a frequência de amostragem ainda mais alta e, às vezes, tecnologicamente impossível de ser atingida. Isto implica que, para uma mesma quantidade de *bits* de resolução, a energia consumida pelos conversores ADCs e DACs aumenta significativamente (MURMANN, 2017), pois o consumo de energia dos conversores é fortemente dependente da frequência de amostragem e da quantidade de *bits* de resolução.

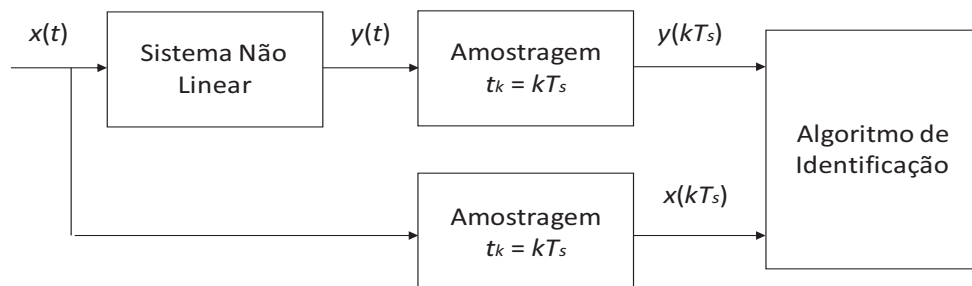


Figura 13. Amostragem de Nyquist para a identificação do sistema. FONTE: Modificado pelo autor de (TSIMBINOS; LEVER, 1998)

Para diminuir as especificações de amostragem nos ADCs, em (TSIMBINOS; LEVER, 1998)(ZHU, 1992)(FRANK, 1996) é teoricamente justificado que, exclusivamente para fins de identificação, basta amostrar os sinais, tanto de entrada quanto de saída de um sistema não linear, a uma frequência que atende ao critério de Nyquist somente para o sinal de envoltória não distorcida $x(t)$, ou seja, apenas amostrar os sinais, na entrada e saída, com um mesmo período de amostragem (T_s), ou seja, os instantes de amostragem serão $t_k = kT_s$ (com $k = 0, 1, 2, 3, \dots$), como mostrado na Figura 13. O *aliasing* produzido não impede que a relação entrada/saída seja unívoca. Assim, a largura de banda que condiciona a frequência de amostragem do ADC não é a do sinal de saída (sinal com alargamento espectral), e sim a do sinal de entrada.

3.2.3 Polinômio com memória de largura de banda limitada (BLMP)

Uma outra abordagem que evita o efeito *aliasing*, sem necessidade de aumentar a frequência de amostragem, é a limitação em banda do sinal de medição do ADC e de atuação do DAC (YU et al., 2012)(LIU et al., 2014)(BRAITHWAITE, 2015)(LIU et al., 2015)(ZHANG et al., 2015)(CHAVEZ et al., 2017). Em (YU et al., 2012), se identifica uma DPD de largura de banda limitada, como mostrado na Figura 14a, onde um filtro passa-baixas LPF com largura de banda BW , definida pela frequência de amostragem dos conversores ADCs e DACs, permite atenuar apenas as distorções em torno do canal principal do sinal que tem uma largura de banda B , e que estão localizadas dentro da largura de banda BW do filtro, descartando parte dos componentes da saída do PA. Além disso, o sinal pré-distorcido fornecido na saída da DPD deve possuir um conteúdo espectral localizado inteiramente dentro de BW . As demais distorções, mais distantes do canal principal, são atenuadas através de um processo de filtragem linear. Nesta abordagem, o modelo comportamental que implementa a DPD deve ser alterado através do uso de funções que limitem a largura de banda dos sinais pré-distorcidos.

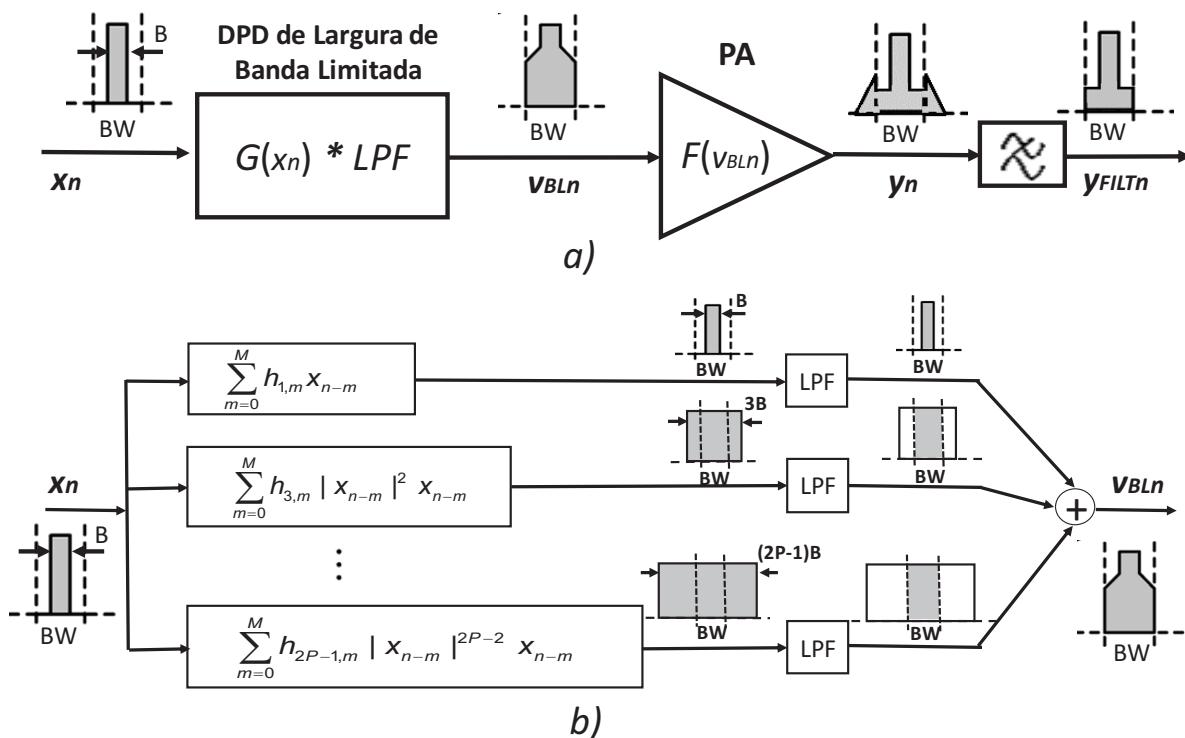


Figura 14. DPD de largura de banda limitada: a) Diagrama de blocos. b) Polinômio com memória de largura de banda limitada. FONTE: O Autor (2017)

No MP descrito por (8), a saída é dada por uma somatória de termos de diferentes ordens. Termos de primeira ordem, que envolvem apenas uma informação de entrada, por exemplo $h_{1,m}x_{n-m}$, possuem uma largura de banda idêntica à da envoltória de entrada (ou seja, B). Termos de terceira ordem, que envolvem o produto de três informações de entrada, por exemplo $h_{3,m}x_{n-m}|x_{n-m}|^2$, possuem uma largura de banda três vezes maior que a da envoltória de entrada (ou seja, $3B$). Em geral, termos de $(2P-1)$ -ésima ordem, que envolvem o produto de $(2P-1)$ informações de entrada, por exemplo $h_{2P-1,m}x_{n-m}|x_{n-m}|^{2P-2}$, possuem uma largura de banda $(2P-1)$ vezes maior que a da envoltória de entrada, ou seja, $(2P-1)B$, como mostrado na Figura 14b. Dessa forma, é necessário modificar (8) para garantir que as suas contribuições estejam totalmente localizadas dentro de BW . Conforme apresentado em (YU et al., 2012), para obter-se um sinal em banda limitada v_{BLn} na saída da DPD, é suficiente realizar a convolução entre o sinal completo v_n na saída da DPD e um filtro passa-baixas (LPF), ou seja,

$$v_{BLn} = \left\{ \sum_{p=1}^P \sum_{m=0}^M h_{2p-1,m} |x_{n-m}|^{2p-2} x_{n-m} \right\} * LPF, \quad (9)$$

em que $*$ indica o operador de convolução e $h_{2p-1,m}$ são os coeficientes complexos. Considerando que o operador de convolução é um operador linear, é possível aplicar a propriedade distributiva, ou seja, substituir uma única convolução envolvendo uma somatória de várias parcelas por um conjunto de convoluções, cada uma sobre uma determinada parcela dessa soma, conforme mostra a Figura 14b. Ressalta-se que o modelo MP de largura de banda limitada de (9) não perde a característica linear nos seus coeficientes $h_{2p-1,m}$.

3.2.4 Polinômio com memória de largura de banda limitada baseado em LUT

Em modelos baseados em polinômios, como os definidos por (8) e (9), a quantidade de adições e multiplicações necessárias para processar uma única amostra em todo o modelo da DPD aumenta com a ordem polinomial e a profundidade da memória. Para diminuir a carga computacional na aplicação da DPD em tempo real, em (RIZENTAL, 2016) é estudada uma proposta onde as funções polinomiais são substituídas por tabelas de busca unidimensional com interpolação linear ou *Lookup Tables* (LUTs) (GHANNOUCHI et al., 2012)(FENG et

al., 2016)(MUHONEN et al., 2000)(RIZENTAL, 2016). LUTs são representações matriciais que substituem a execução de cálculos por operações de indexação de matrizes, pois armazenam na sua memória dados pré-calculados que são utilizados como referência para encontrar outros valores. Assim, para os modelos baseados em LUT, os valores a serem armazenados nas LUTs tornam-se os coeficientes ajustáveis. Então, para substituir as LUTs no modelo DPD de largura de banda limitada da seção anterior, primeiro (9) é reescrita como:

$$v_n = \left(\sum_{m=0}^M x_{n-m} f_m^{POL}(a_{n-m}^2) \right) * \{LPF\}, \quad (10)$$

onde os polinômios unidimensionais f_m^{POL} (para m variando de 0 a M) são dados por:

$$f_m^{POL}(a_{n-m}^2) = \sum_{p=1}^P h_{m,p} a_{n-m}^{2(p-1)}, \quad (11)$$

onde a_n é a componente de amplitude de x_{n-m} . Esta reorganização da equação (9) é mostrada no diagrama de blocos da Figura 15. Conforme relatado em (YU et al., 2012), o filtro passa-baixas LPF tem como objetivo restringir o conteúdo espectral do sinal predistorcido dentro da frequência de amostragem da ADC / DAC de BW . Devido à largura de banda limitada de (9), a DPD só consegue linearizar a saída do PA na faixa de frequência de $-BW/2$ a $+BW/2$. Para fins de DPD, a saída do PA deve estar sujeita a um filtro passa-faixa de mesma largura de banda

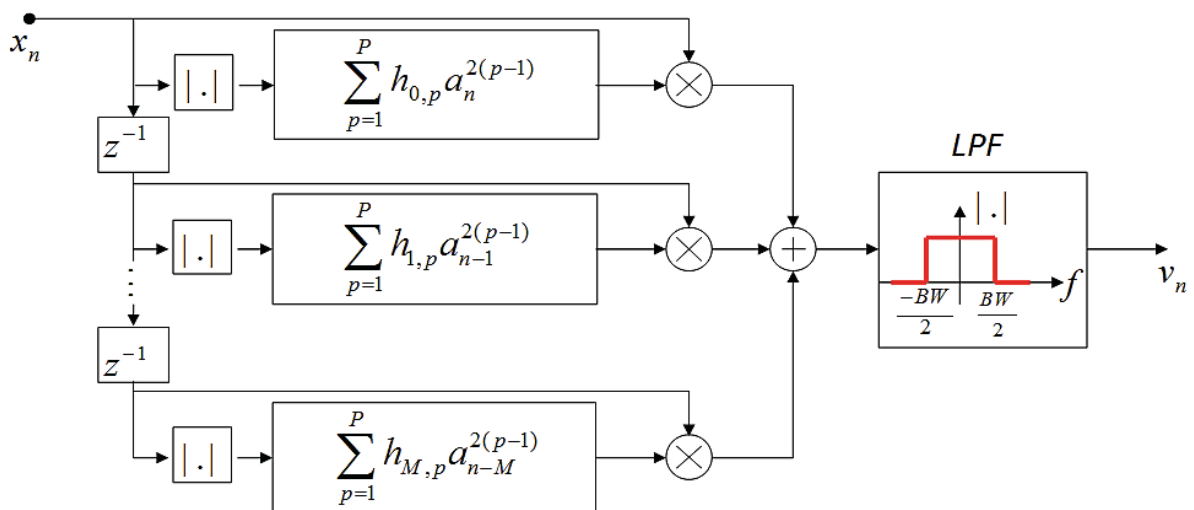


Figura 15. Diagrama de blocos do modelo polinomial com largura de banda limitada. FONTE: O Autor (2017)

Cada f_m^{POL} tem como argumento uma única informação de valor real, dada pelo quadrado da componente de amplitude de entrada a_{n-m}^2 , retornando um valor complexo de acordo com (11). Em vez de realizar todas as adições e multiplicações exigidas por (11) a cada vez que um novo argumento é aplicado, na abordagem baseada em LUT, cada f_m^{POL} é substituída pelo armazenamento de um número finito (Q) de valores de entrada e saída, conforme relatado na Tabela I.

TABELA I – INFORMAÇÃO ARMAZENADA NA LUT COM Q POSIÇÕES ENDEREÇÁVEIS

Entrada de valor real - LUT	Saída de valor complexo - LUT
$e_{m,1}$	$s_{m,1}$
$e_{m,2}$	$s_{m,2}$
\vdots	\vdots
$e_{m,Q}$	$s_{m,Q}$

FONTE: (RIZENTAL, 2016).

Na Tabela I, as entradas de valor real da LUT são designadas por $e_{m,q}$ (com q variando de 1 a Q) e as saídas de valor complexo da LUT são designadas por $s_{m,q}$ (com q variando de 1 a Q). Toda vez que se aplica um novo argumento a_{n-m}^2 , a operação comparativa $e_{m,q-1} < a_{n-m}^2 < e_{m,q}$ é realizada para encontrar o índice inteiro q , que deve estar no intervalo de 2 a Q. As saídas $s_{m,q-1}$ e $s_{m,q}$ associados às duas entradas consecutivas da LUT $e_{m,q-1}$ e $e_{m,q}$ são lidas e, usando interpolação linear, cada f_m^{POL} é aproximado por:

$$f_m^{POL}(a_{n-m}^2) \approx f_m^{LUT}(a_{n-m}^2) = s_{m,q-1} + \left(\frac{s_{m,q} - s_{m,q-1}}{e_{m,q} - e_{m,q-1}} \right) (a_{n-m}^2 - e_{m,q-1}), \quad (12)$$

onde o cálculo de uma saída é sempre realizado pelo mesmo número de adições e multiplicações, independentemente da ordem polinomial.

3.2.4.1 Identificação de parâmetros do modelo BLMP baseado em LUT

Aproveitando que o polinômio com memória de largura de banda limitada (BLMP) baseado em LUT é de fato linear nos parâmetros $s_{m,q}$, em (RIZENTAL, 2016) é relatada uma técnica capaz de fornecer diretamente, e em um único passo do LS, um conjunto ótimo de valores complexos para as saídas da LUT $s_{m,q}$, sem

conhecer previamente qualquer função polinomial. Dado um conjunto de N dados de entrada e saída, todos os $s_{m,q}$ podem ser encontrados com:

$$S = (X_{LUT}^H X_{LUT})^{-1} (X_{LUT}^H V), \quad (13)$$

onde $S = [s_{0,1} \ \dots \ s_{M,Q}]^T$ é o vetor linha que contém todos os parâmetros de valor complexo da LUT, $V = [v_{1+M} \ \dots \ v_N]^T$ é o vetor linha contendo todas as saídas e X_{LUT} é a matriz de regressão que manipula as amostras de entrada por:

$$X_{LUT} = \begin{bmatrix} x_{1+M} f_0^{LUT}(a_{1+M}^2) * LPF & \dots & x_1 f_M^{LUT}(a_1^2) * LPF \\ \vdots & \vdots & \vdots \\ x_N f_0^{LUT}(a_N^2) * LPF & \dots & x_{N-M} f_M^{LUT}(a_{N-M}^2) * LPF \end{bmatrix}, \quad (14)$$

em que $f_m^{LUT}(a_{n-m}^2)$ indica vetores coluna com Q colunas. A saída interpolada de uma determinada LUT depende apenas da informação de duas posições consecutivas dessa LUT. Então, para cada uma dessas f_m^{LUT} , existem apenas duas colunas com valores não nulos, ou seja, qualquer f_m^{LUT} é preenchida com $(Q-2)$ valores nulos. Para obter os dois valores diferentes de zero a serem inseridos em cada f_m^{LUT} , primeiramente o índice inteiro q entre 2 e Q que satisfaça $e_{m,q-1} \leq a_{n-m}^2 \leq e_{m,q}$ deve ser calculado. Então:

$$f_m^{LUT}(a_{n-m}^2) = [0 \ \dots \ 0 \ r_{q-1} \ r_q \ 0 \ \dots \ 0], \quad (15)$$

com:

$$r_{q-1} = 1 - \left[\frac{a_{n-m}^2 - e_{m,q-1}}{e_{m,q} - e_{m,q-1}} \right], \quad (16)$$

$$r_q = \left[\frac{a_{n-m}^2 - e_{m,q-1}}{e_{m,q} - e_{m,q-1}} \right]. \quad (17)$$

4 CENÁRIOS DE COMPARAÇÃO ENTRE AS ARQUITETURAS DE APRENDIZAGEM DIRETA E INDIRETA

Este trabalho apresenta um estudo comparativo entre as arquiteturas de aprendizagem direta e indireta para identificar os parâmetros ótimos de modelos baseados em MP. As duas arquiteturas são avaliadas em diferentes cenários de frequências de amostragem reduzidas. Assim, em um primeiro cenário é empregada a amostragem convencional (CHAVEZ; LIMA, 2017b). Depois, em um segundo cenário é aplicada subamostragem no processo de identificação dos parâmetros (CHAVEZ; LIMA, 2017a). A seguir, os algoritmos são novamente comparados quando implementada uma limitação na largura de banda (CHAVEZ et al., 2017). Finalmente, é relatada uma comparação onde no modelo da DPD são aplicadas tabelas de busca com o intuito de reduzir a complexidade da modelagem.

4.1 AMOSTRAGEM CONVENCIONAL

Uma primeira contribuição deste trabalho é comparar as arquiteturas direta e indireta. Isso resultou na publicação do artigo (CHAVEZ; LIMA, 2017b). No entanto, em (CHAVEZ; LIMA, 2017b) a análise é limitada ao caso em que se usa uma frequência de amostragem que atende ao critério de Nyquist para sinais de envoltória não distorcidos e distorcidos.

No caso da aprendizagem indireta, uma primeira identificação de PoD é feita, como mostrado na Figura 16a, onde o PA é excitado por uma entrada sem distorção, v'_n , e é medido um sinal distorcido corrompido pelo alargamento espectral na sua saída. Isso faz com que o sinal aplicado à entrada do PoD y'_n/g seja distorcido, enquanto que a saída do PoD é um sinal não distorcido. Imediatamente, os parâmetros polinomiais de (8) são calculados através de um algoritmo linear, como LS, e depois copiados como parâmetros de uma DPD colocada no início da conexão em cascata, como mostrado na Figura 16b, ou seja, na primeira extração os parâmetros são calculados para um sinal de entrada não distorcido e um sinal de saída distorcido. No entanto, a DPD funciona em uma configuração diferente em relação aos níveis de distorção de entrada e saída, em comparação com o primeiro PoD identificado, pois a entrada da DPD é sempre um sinal sem distorção x_n ,

enquanto que o sinal na saída da DPD é sempre uma sequência distorcida v_n . Como consequência, espera-se uma degradação na capacidade de linearização.




Figura 16. Arquitetura de aprendizagem indireta com amostragem convencional: a) primeira iteração da identificação do PoD; b) cenário de identificação do PoD a partir da segunda iteração. FONTE: O Autor (2017)

Para resolver este problema na modelagem da inversa, uma abordagem recomendada é a realização de outras identificações de PoD, repetindo o processo de identificação de parâmetros do PoD, mas agora com o PA excitado por um sinal pré-distorcido v''_n , obtido com base nos parâmetros obtidos na primeira extração do PoD, como mostrado na Figura 16b (LIU et al., 2014). Em particular, o mesmo sinal sem distorção é aplicado à entrada da DPD. O sinal de saída distorcido e estimado pela DPD é usado para excitar o PA. Mede-se novamente a saída do PA y''_n , para aplicá-la (dividida por g) como entrada do PoD. Um segundo PoD é então identificado, porém agora operando em uma situação semelhante ao funcionamento da DPD (entrada não distorcida e saída distorcida). Tal procedimento pode ser repetido de maneira iterativa, para obter novos conjuntos de parâmetros de PoD, até o ponto em que o erro de modelagem se estabilize em um valor mínimo. A cada iteração, parte-se sempre da excitação do PA por meio de uma sequência pré-distorcida obtida a partir dos coeficientes identificados na iteração anterior. Ou seja, esse procedimento não altera a quantidade de blocos presentes na conexão em cascata. Portanto, usa-se sempre um único bloco para a DPD, porém os valores numéricos dos coeficientes do modelo são atualizados a cada iteração, até que o erro se estabilize em um valor mínimo.

Já no caso da aprendizagem direta, é utilizado um algoritmo de otimização não linear, onde é definido um critério de parada e um conjunto de valores ou estimativas iniciais que permitem inicializar o processo iterativo do algoritmo. Além disso, como mostra a Figura 17, a aprendizagem direta é forçada a uma topologia em malha fechada que exige o conhecimento prévio de um modelo para o PA, uma vez que a cada nova escolha de valores – feita pelo algoritmo de otimização – dos coeficientes da DPD, novos sinais são usados para excitar o PA. Uma vantagem da aprendizagem direta é que não utiliza um modelo de pós-distorcedor, dessa forma, a capacidade de linearização e a qualidade dos coeficientes extraídos não é afetada pela troca de posição da inversa durante as etapas de extração e aplicação, como acontece com a aprendizagem indireta.

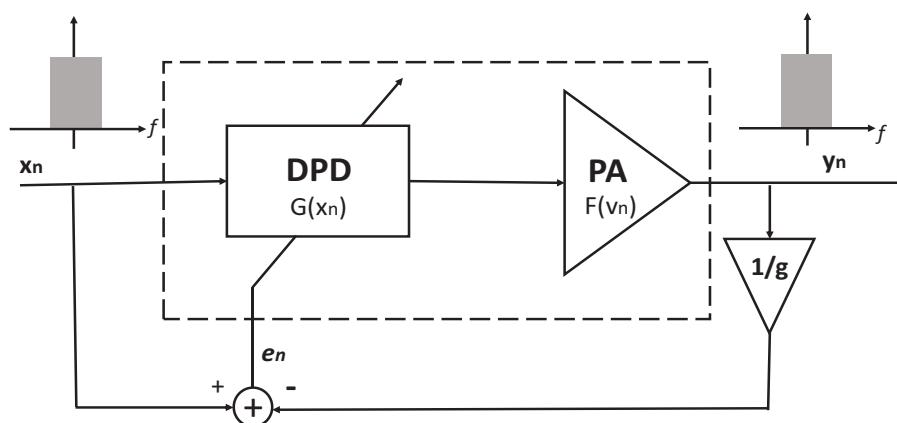


Figura 17. Arquitetura de aprendizagem direta com amostragem convencional. FONTE: O Autor (2017)

4.2 SUBAMOSTRAGEM

As arquiteturas de aprendizagem direta e indireta são baseadas em medições de sinais de envoltória de valor complexo de tempo discreto. Quando o sinal de erro é discretizado no tempo, réplicas do conteúdo espectral original são geradas no domínio de frequência. O efeito da frequência de amostragem dos conversores ADC/DAC na identificação dos parâmetros da DPD não foi analisado no caso anterior. Nesta abordagem, é realizada uma redução da frequência de amostragem f_s no processo de extração ou identificação dos parâmetros da DPD, partindo de uma f_s que cumpre com o critério de Nyquist para o sinal distorcido, até reduzir a taxa de amostragem para um valor que cumpre com o critério Nyquist apenas para a envoltória não distorcida, como foi exposto no artigo (CHAVEZ; LIMA, 2017a).

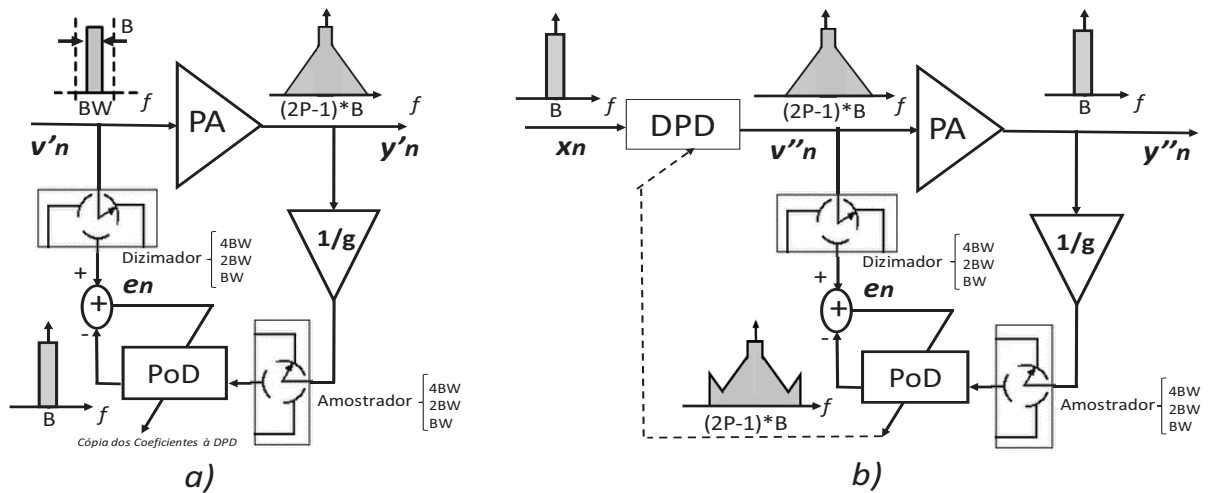


Figura 18. Arquitetura de aprendizagem indireta com subamostragem: a) primeira iteração da identificação do PoD; b) cenário de identificação do PoD a partir da segunda iteração. FONTE: O Autor (2017)

Na arquitetura de aprendizagem indireta, em uma primeira identificação de PoD, os sinais usados no cálculo do erro são sinais puros, de largura de banda igual ao sinal original (sem distorção), como mostrado na Figura 18a. Portanto, quando são amostrados no tempo, basta respeitar o critério de Nyquist para o sinal não distorcido, utilizando por exemplo $f_s = BW$. Porém, como foi detalhado na seção anterior, este não é o cenário de funcionamento da DPD. Já a partir da segunda iteração na identificação do PoD, e assim por diante, o sinal de erro e_n a ser minimizado é calculado como a diferença entre dois sinais distorcidos, obtendo uma largura de banda $2P-1$ vezes maior que a do sinal distorcido ($(2P-1)*B$), como mostrado na Figura 18b. Então, em princípio, para respeitar o critério de Nyquist, pode-se usar por exemplo uma f_s igual a $2P-1$ vezes maior que a largura de banda do sinal. Contudo, para a etapa de identificação, basta amostrar com f_s à largura de banda do sinal.

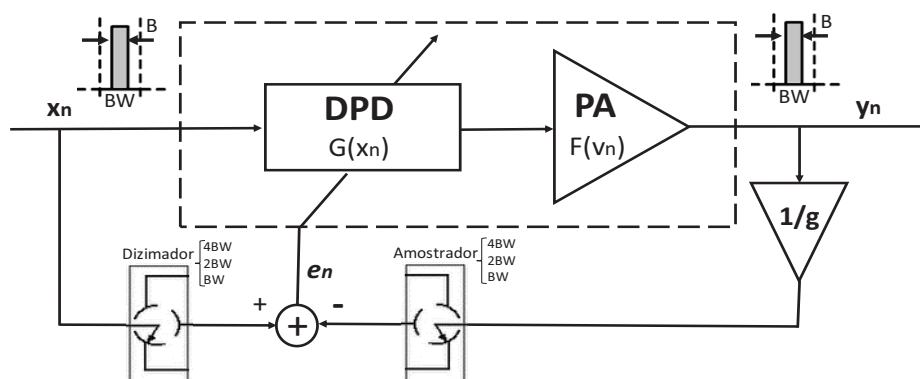


Figura 19. Arquitetura de aprendizagem direta com subamostragem. FONTE: O Autor (2017)

Contrariamente, na arquitetura de aprendizagem direta o sinal de erro de tempo discreto a ser minimizado, definido pela diferença entre os sinais de entrada e saída da conexão em cascata DPD+PA (como mostrado na Figura 19), possui uma largura de banda igual ao sinal de envoltória não distorcido.

4.3 POLINÔMIO COM MEMÓRIA DE LARGURA DE BANDA LIMITADA

Nesta seção se apresentam as abordagens de aprendizagem direta e indireta em um contexto de DPDs de largura de banda limitada (CHAVEZ et al., 2017). O tamanho da limitação da mesma é determinado pela frequência de amostragem dos conversores ADC (medidor) e DAC (atuador).

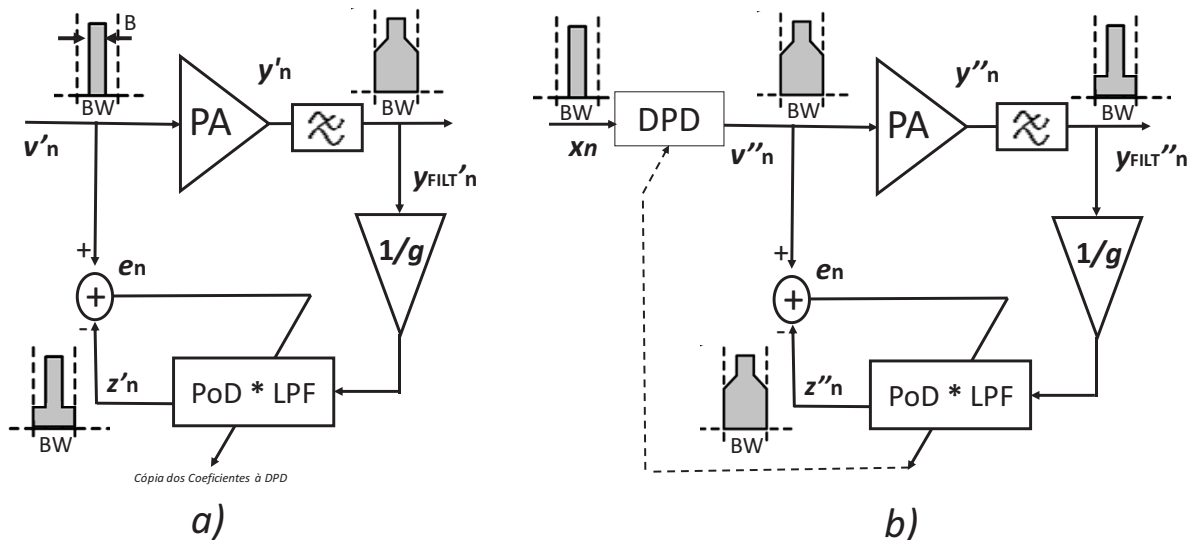


Figura 20. Arquitetura de aprendizagem indireta em um cenário de largura de banda limitada: a) primeira iteração da identificação do PoD; b) cenário de identificação do PoD a partir da segunda iteração. FONTE: O Autor (2017)

No caso da arquitetura de aprendizagem indireta, a abordagem convencional é modificada da seguinte maneira. Em uma primeira identificação do PoD, conforme a Figura 20a, o PA é excitado por uma entrada sem distorção v'_n . O sinal distorcido na saída do PA y'_n é então filtrado de tal forma a deixar passar apenas as componentes em frequências em torno da portadora e localizadas dentro de BW , para obter a saída filtrada do PA $y_{FILT}'_n$, utilizada no caminho de retorno da arquitetura como entrada do PoD, descrito por (9). Minimiza-se então o erro quadrático médio descrito pela diferença entre a saída estimada pelo PoD z'_n e o sinal não distorcido v'_n . Os parâmetros obtidos são copiados como parâmetros de

uma DPD de mesma topologia, conforme a Figura 20b. Novamente, nessa primeira extração de coeficientes, a natureza dos sinais de entrada e saída para identificação e aplicação são completamente diferentes. Um sinal pré-distorcido v''_n , gerado a partir dos coeficientes obtidos na primeira extração do PoD, é agora usado para excitar o PA. Mede-se novamente a saída filtrada do PA $v_{FILT}''_n$, conforme a Figura 20b, para então aplicá-la (dividida por g) como entrada do PoD. Um segundo PoD é então identificado, porém agora operando em uma situação semelhante ao funcionamento da DPD, ou seja, com entrada não distorcida e com saída distorcida. Esse processo é repetido de forma iterativa, até que o erro se estabilize em um valor mínimo.

Na implementação da arquitetura de aprendizagem direta é empregado o modelo MP de largura de banda limitada descrito por (9) como topologia para a DPD, como mostrado na Figura 21, onde se vê a filtragem para a limitação em banda do sinal na saída da DPD. A minimização do erro ainda é um problema de otimização não linear, pois os coeficientes da DPD são manipulados de maneira não linear pelo PA.

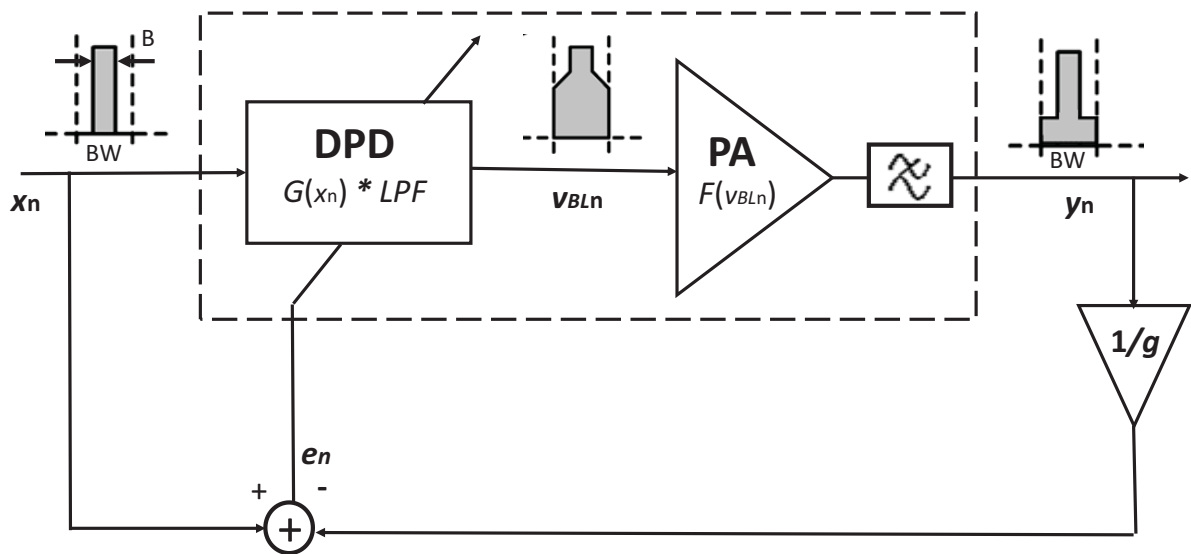


Figura 21. Arquitetura de aprendizagem direta em um cenário de largura de banda limitada. FONTE: O Autor (2017)

4.4 POLINÔMIO COM MEMÓRIA DE LARGURA DE BANDA LIMITADA BASEADO EM LUT

Nas três abordagens anteriores, a DPD adota modelos polinomiais. Com o intuito de reduzir a complexidade computacional na implementação em tempo real, é

recomendável substituir polinômios por LUTs com interpolação linear (GHANNOUCHI et al., 2012). Esta seção aborda o uso de LUTs e a identificação direta dos valores a serem inseridos nas LUTs, como proposto em (RIZENTAL, 2016).

Nas arquiteturas de aprendizagem indireta e direta a ideia de funcionamento é a mesma que nas três seções anteriores, com a diferença que os coeficientes ou parâmetros a serem calculados são agora valores a serem armazenados em tabelas de busca. Neste caso, é importante ressaltar que a ordem do sistema a ser resolvido pelo LS é dependente da quantidade de posições Q endereçáveis nas LUTs e não da ordem polinomial $2P-1$. Os esquemas da Figura 22 representam as duas arquiteturas de estudo, assim como a análise da primeira e segunda iterações no caso da aprendizagem indireta. Pela Figura 22, observa-se que foi escolhido o cenário onde há limitação de largura de banda.

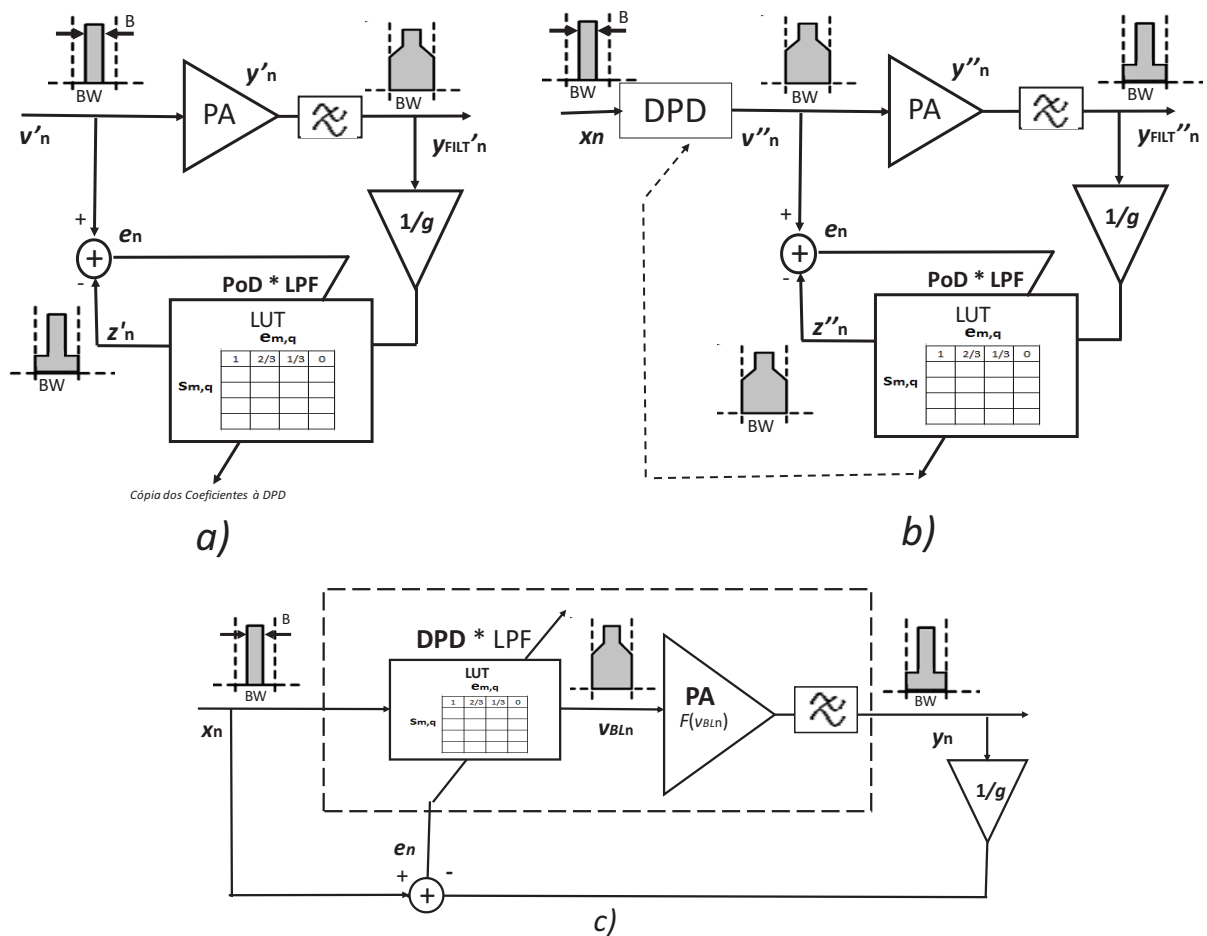


Figura 22. Identificação da DPD com largura de banda limitada e LUT: a) Primeira iteração da identificação do PoD com arquitetura de aprendizagem indireta; b) Cenário de identificação do PoD a partir da segunda iteração com arquitetura de aprendizagem indireta; c) Arquitetura de aprendizagem direta. FONTE: O Autor (2017)

5 RESULTADOS DA SIMULAÇÃO E VALIDAÇÃO DOS ESTUDOS DE CASO

5.1 AMBIENTE DE SIMULAÇÃO

Nesta seção, são apresentados os resultados de simulação em MatLab de quatro estudos de caso que investigam a capacidade de linearização de diferentes DPDs. Nos dois primeiros casos, utiliza-se o modelo MP de (8), e nos dois últimos (nas DPDs de banda limitada) é utilizado o modelo MP de (9) com um filtro ideal passa-baixas com $BW = 38,4$ MHz, todos eles com $M = 1$, $P = 5$ (ou seja, a não linearidade é truncada na 9ª ordem). Para todos os casos, o PA a ser linearizado é descrito por (8), com os valores dos coeficientes mostrados na Tabela II. Para a obtenção desses coeficientes, foram empregados dados medidos em um amplificador de potência fabricado em tecnologia GaN, operando em classe AB e excitado por um sinal 3GPP WCDMA com largura de banda de 3,84 MHz (LIMA, 2006).

TABELA II – VALORES NUMÉRICOS DOS COEFICIENTES DO PA

$h_{1,0} = -0,0515 - j0,0831$	$h_{1,1} = 1,0538 + j0,0612$
$h_{3,0} = 0,5407 + j0,0729$	$h_{3,1} = -1,6840 + j0,3680$
$h_{5,0} = -0,5777 + j0,0293$	$h_{5,1} = 2,9292 - j0,4123$
$h_{7,0} = 0,2852 - j0,1514$	$h_{7,1} = -3,2223 + j0,2051$
$h_{9,0} = -0,0218 + j0,1011$	$h_{9,1} = 1,3383 - j0,0130$

A envoltória complexa utilizada consiste em um sinal *Long Term Evolution* (LTE) *Orthogonal Frequency Division Multiple Access* (OFDMA) com largura de banda $B = 20$ MHz, descrito por uma sequência de 4096 amostras, obtidas com uma frequência de amostragem de 153,6 MHz. Para a coleta dos dados de entrada e saída do PA sob análise, adota-se a mesma frequência de amostragem.

Os coeficientes $h_{2p-1,m}$ de (8) e (9) são então identificados através das duas arquiteturas de aprendizagem descritas anteriormente. Para a arquitetura indireta, utiliza-se o algoritmo dos mínimos quadrados. Para a arquitetura direta, emprega-se um algoritmo de otimização por mínimos quadrados não lineares usando o método de Levenberg-Marquardt (OSBORNE, 1976), com um critério de parada onde a tolerância relativa deve ser menor ou igual a 1×10^{-6} . Assim, a complexidade computacional é avaliada em termos da quantidade de iterações necessária para a minimização do erro em cada caso.

Para avaliar a capacidade de linearização das diferentes DPDs, utiliza-se o erro quadrático médio normalizado (NMSE), definido por:

$$NMSE = 10 \log_{10} \left[\frac{\sum_{n=1}^N | [y_n / g] - x_n |^2}{\sum_{n=1}^N | y_n / g |^2} \right], \quad (18)$$

em que N indica a quantidade total de amostras utilizadas no cálculo, x_n e y_n a entrada e saída da conexão em cascata. Em todos os casos a frequência de amostragem utilizada no cálculo do NMSE é 153,6 MHz.

Outra métrica de avaliação é a razão entre as potências nos canais adjacentes e principal (ACPR), definida como a razão entre a densidade espectral de potência (PSD) do sinal em um canal adjacente e a PSD do sinal no canal principal, por meio de:

$$ACPR = 10 \log_{10} \left[\frac{\int_{adj} | Y(f) |^2 df}{\int_{main} | Y(f) |^2 df} \right], \quad (19)$$

em que $Y(f)$ indica a transformada de Fourier do sinal y_n . Devido ao uso do filtro de 38,4 MHz em dois casos de estudo, o cálculo da ACPR, em todos os casos, considera uma largura de banda de 9 MHz nos canais adjacentes superior e inferior e 18 MHz para o canal principal, com uma separação de 14,7 MHz entre as frequências centrais dos canais principal e adjacentes, como mostrado na Figura 23.




Figura 23. Considerações no cálculo do ACPR. FONTE: O Autor (2017)

5.2 CENÁRIOS DE COMPARAÇÃO

5.2.1 Amostragem convencional

A Tabela III apresenta os resultados de NMSE e ACPR quando adotadas uma amostragem convencional e as duas estratégias de identificação de parâmetros de DPD descritas na Seção 4.1.

Quatro iterações da estratégia de aprendizagem indireta são apresentadas, onde observa-se uma melhora de 2,76 dB (NMSE) e 3,45 dB (ACPR) da primeira para a segunda iteração. Como discutido na Seção 4.1, era esperada a melhora significativa (comparada com as iterações seguintes) na capacidade de linearização da primeira para a segunda iteração, já que os dados de entrada e saída utilizados para a identificação do PoD na segunda iteração correspondem ao cenário em que a DPD é destinada a trabalhar (por exemplo, a entrada sem distorção e a saída distorcida). Mais iterações da aprendizagem indireta não são reportadas, devido a não apresentarem melhoras significativas. Concretamente, uma sétima iteração só melhora o NMSE e a ACPR em 0,01 dB. Nesse procedimento iterativo de extração de coeficientes a partir da aprendizagem indireta, a cada iteração executa-se apenas uma vez o algoritmo dos mínimos quadrados. Dessa forma, o que muda em cada iteração é o conjunto de dados de entrada e saída usados para o treinamento. A partir da segunda iteração, esse conjunto de entradas e saídas é sempre obtido em um cenário próximo da aplicação da DPD, ou seja, o sinal de entrada da inversa é não distorcido enquanto que o sinal de saída da inversa é distorcido. Portanto, a partir da segunda iteração, não há garantia que o erro sempre diminua a cada iteração. De fato, o que se observa na Tabela III é uma oscilação do erro entre a segunda e a quarta iteração.

No que diz respeito à arquitetura de aprendizagem direta, na Tabela III são apresentados os resultados de NMSE e ACPR, quando aplicadas duas estimativas iniciais ao algoritmo de identificação. A estimativa inicial A assume $h_{1,0}$ igual a 1 e impõe os outros 9 parâmetros iguais a zero. Para melhorar a convergência do algoritmo de otimização não linear se propõe utilizar uma combinação das arquiteturas indireta e direta. Assim a estimativa inicial B da aprendizagem direta utiliza os parâmetros obtidos na primeira iteração da aprendizagem indireta e a aprendizagem direta é quem obtém os parâmetros da DPD. Na Tabela III, é

mostrado que os valores de NMSE e ACPR têm uma pequena melhora de 0,2 dB e 0,3 dB respectivamente, quando as estimativas iniciais são trocadas do caso A para o caso B. Então, neste caso de estudo, a aprendizagem direta não ficou presa nos mínimos locais. Porém, quando aplicada uma melhor estimativa inicial proporcionada pelo caso B, a velocidade de convergência aumentou. A estimativa inicial A requer 23 iterações, enquanto a estimativa inicial B requer 18 iterações.

TABELA III - RESULTADOS DE NMSE E ACPR QUANDO APLICADA AMOSTRAGEM CONVENCIONAL

Arquitetura	Casos	NMSE [dB]	ACPR [dB]
Aprendizagem Indireta	1a Iteração	-44,394	-51,023
	2a Iteração	-47,152	-54,474
	3a Iteração	-46,903	-54,063
	4a Iteração	-47,279	-54,554
Aprendizagem Direta	Estimativa Inicial A 23 iterações	-48,866	-56,147
	Estimativa Inicial B 18 iterações	-49,106	-56,474

Observa-se que o melhor valor de NMSE obtido mediante a aprendizagem direta é 1,8 dB menor do que o melhor valor de NMSE obtido com a aprendizagem indireta. Como discutido na Seção 4.1, é esperada uma maior acurácia para a aprendizagem direta, uma vez que ela evita o uso de um PoD durante o processo de identificação. Porém, a melhora na acurácia que a aprendizagem direta oferece quando comparada com a aprendizagem indireta, só é possível mediante um crescimento na complexidade computacional.




Figura 24. PSDs dos sinais de saída do PA sem DPD e com as aprendizagens indireta e direta

Na Figura 24 observam-se as densidades espectrais de potência (PSD) do sinal de saída do PA linearizado e sem linearização. Para uma melhor visualização das PSDs, a Figura 25 mostra o mesmo sinal recortado em uma banda de 60 MHz, onde as reduções de ACPR nos canais adjacentes são mais evidentes quando é comparada a primeira e a quarta iteração da DPD treinada com a aprendizagem indireta. Por outro lado, uma PSD ligeiramente mais baixa é observada com a aplicação da aprendizagem direta, em comparação com a quarta iteração da aprendizagem indireta.

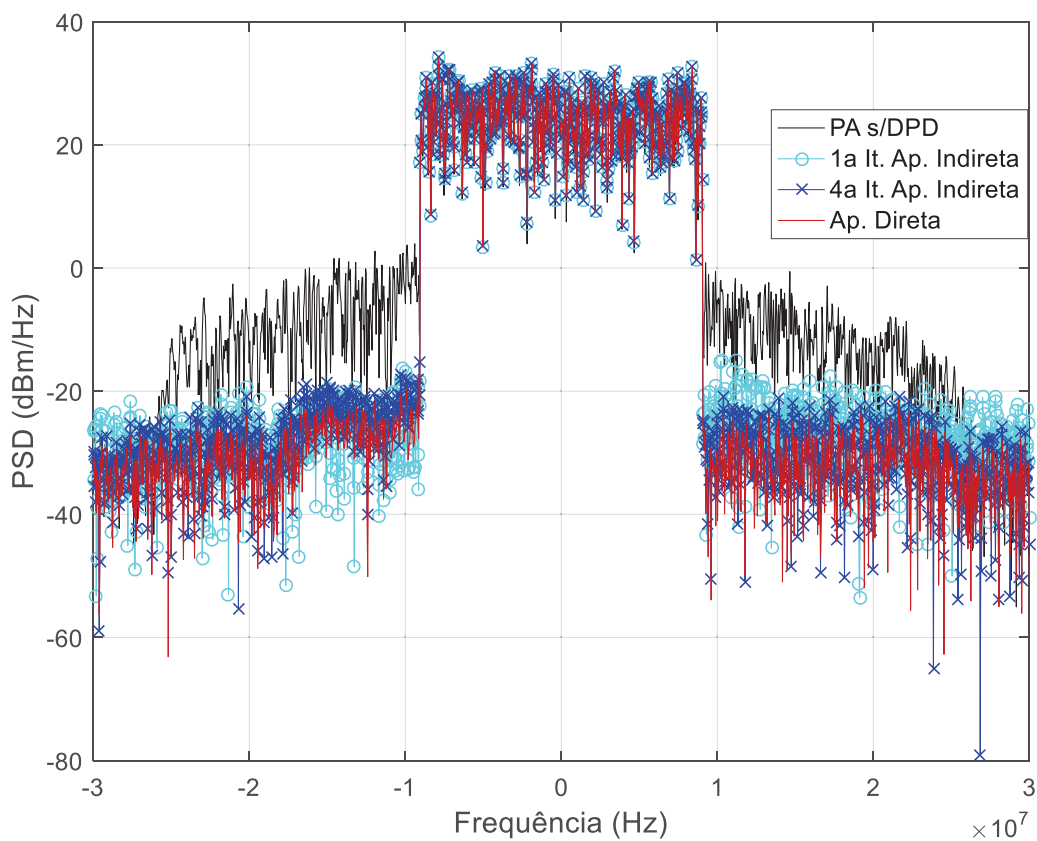


Figura 25. PSDs dos sinais de saída do PA sem DPD e com as aprendizagens indireta e direta, recortado em uma banda de 60 MHz.

A Figura 26 mostra a curva da amplitude de saída em função da amplitude de entrada para o modelo do PA, o modelo da DPD e a conexão em cascata da DPD+PA, quando aplicado o melhor resultado da aprendizagem indireta. Observa-se que a característica de expansão da DPD cancela a característica de compressão do PA.




Figura 26. Características de transferência do PA, da DPD e da conexão em cascata usando aprendizagem indireta

5.2.2 Subamostragem

Nesta seção, são apresentados os resultados de NMSE e ACPR quando aplicadas as arquiteturas de aprendizagem indireta e direta em um cenário de subamostragem, utilizando três valores distintos de frequência de amostragem f_s ($4BW = 153,6$ MHz, $2BW = 76,8$ MHz, $BW = 38,4$ MHz). Tais frequências representam valores submúltiplos da frequência de amostragem do sinal sem distorção e estão em torno da largura de banda do canal principal do sinal ($B = 20$ MHz), cumprindo com o intuito de demonstrar a redução da frequência de amostragem na identificação de parâmetros DPD, como descrito na Seção 4.2. A validação da capacidade de linearização da DPD utiliza uma f_s fixa igual a 153,6 MHz. A Tabela IV apresenta os resultados obtidos.

No caso da arquitetura de aprendizagem indireta, são apresentadas quatro iterações, onde observa-se que, para todas as f_s utilizadas, é encontrada uma melhora significativa da 1ª para a 2ª iteração (aproximadamente 2,5 dB no NMSE e 3 dB no ACPR) em relação aos melhores resultados obtidos nas iterações seguintes

(aproximadamente 0,3 dB no NMSE e 0,5 dB no ACPR). Estas melhoras refletem o comportamento descrito na Seção 4.2, pois um segundo PoD funciona em um cenário mais próximo à validação da DPD. Ao mudar a frequência de amostragem no processo de identificação, os resultados de NMSE apresentam diferenças mínimas (0,1 a 0,5 dB) quando comparados os melhores resultados obtidos nas quatro iterações. Este resultado é importante, pois mostra que a f_s na identificação de parâmetros pode ser reduzida até um valor igual ao que respeita o critério de Nyquist para o sinal não distorcido sem afetar significativamente a capacidade de linearização, como mostrado na Figura 27 e na Tabela IV, embora a arquitetura de aprendizagem indireta minimize um sinal de erro com largura de banda igual a $2P-1$ vezes a envoltória não distorcida. Assim, a presença de *aliasing* é permitida para fins de identificação.




Figura 27. Resultados de NMSE e ACPR da aprendizagem indireta com frequências de amostragem diferentes

Na Tabela IV, também são apresentados os resultados de NMSE e ACPR da arquitetura de aprendizagem direta, quando aplicadas duas estimativas iniciais ao algoritmo de identificação. A estimativa inicial A assume $h_{1,0}$ igual a 1 e impõe que os outros 9 parâmetros sejam iguais a zero. Por outro lado, assim como no estudo de caso da Seção 5.2.1, uma combinação das duas arquiteturas é utilizada da seguinte forma: a arquitetura indireta é empregada para obter a estimativa inicial B (a partir dos parâmetros da primeira iteração) e a arquitetura direta para obter os coeficientes

da DPD. Como resultado, encontrou-se uma pequena melhora (entre 0,1 e 0,2 dB) no NMSE para todos os valores de f_s utilizados, quando a estimativa B é aplicada ao invés da estimativa A. Também, há uma melhora na velocidade de convergência, pois a estimativa inicial B requer menos iterações do que a estimativa inicial A, ou seja, para uma $f_s = 4BW$ a quantidade de iterações é reduzida de 23 para 18 iterações, de 26 para 19 para uma $f_s = 2BW$ e de 305 para 115 para uma $f_s = BW$. No caso da aprendizagem direta, ao trocar a f_s no processo de identificação, como esperado, as melhoras no NMSE são pequenas. De fato, esta arquitetura minimiza um sinal de erro com largura de banda igual à envoltória não distorcida. Neste caso, o uso de uma f_s maior que BW não produzirá nenhum resultado significativo.

TABELA IV - RESULTADOS DE NMSE E ACPR COM SUBAMOSTRAGEM

fs para identificação		fs=4BW		fs=2BW		fs=BW	
Arquitetura	Casos	NMSE [dB]	ACPR [dB]	NMSE [dB]	ACPR [dB]	NMSE [dB]	ACPR [dB]
Aprendizagem Indireta	1a Iteração	-44,394	-51,023	-45,507	-52,321	-46,567	-55,346
	2a Iteração	-47,152	-54,474	-47,675	-55,293	-46,606	-55,352
	3a Iteração	-46,903	-54,063	-47,886	-56,281	-46,924	-54,680
	4a Iteração	-47,279	-54,554	-47,545	-55,741	-47,097	-54,706
Aprendizagem Direta	Est.Inicial A 23-26-305 Iterações	-48,866	-56,147	-48,785	-56,752	-45,106	-53,575
	Est.Inicial B 18-19-115 Iterações	-49,106	-56,474	-49,232	-56,754	-48,789	-56,757

Ao comparar ambas arquiteturas, observa-se que um melhor valor de NMSE foi obtido com a aprendizagem direta. Em particular, um valor de 1,34 dB melhor em NMSE é obtido pela aprendizagem direta em comparação com a aprendizagem indireta. Este resultado é esperado, já que, na aprendizagem direta, é evitado o uso de um PoD durante o processo de identificação, como discutido na Seção 4.2. Porém, a melhora na acurácia, oferecida pela aprendizagem direta quando comparada com a aprendizagem indireta, só é possível graças a um aumento na complexidade computacional.




Figura 28. PSDs dos sinais de saída do PA sem DPD e com a aprendizagem indireta a diferentes frequências de amostragem e aprendizagem direta

A Figura 28 mostra as PSDs dos sinais de saída do PA linearizado e não linearizado. Pode-se observar uma diferença significativa no nível das distorções presentes nos canais adjacentes sem DPD e com DPD, e uma ligeira diferença quando a frequência de amostragem é trocada na aprendizagem indireta. A Figura 29 mostra a amplitude de saída em função da amplitude de entrada para o modelo do PA, o modelo da DPD e a conexão em cascata (DPD+PA) usando uma frequência de amostragem $f_s = BW$ e a quarta iteração da aprendizagem indireta.

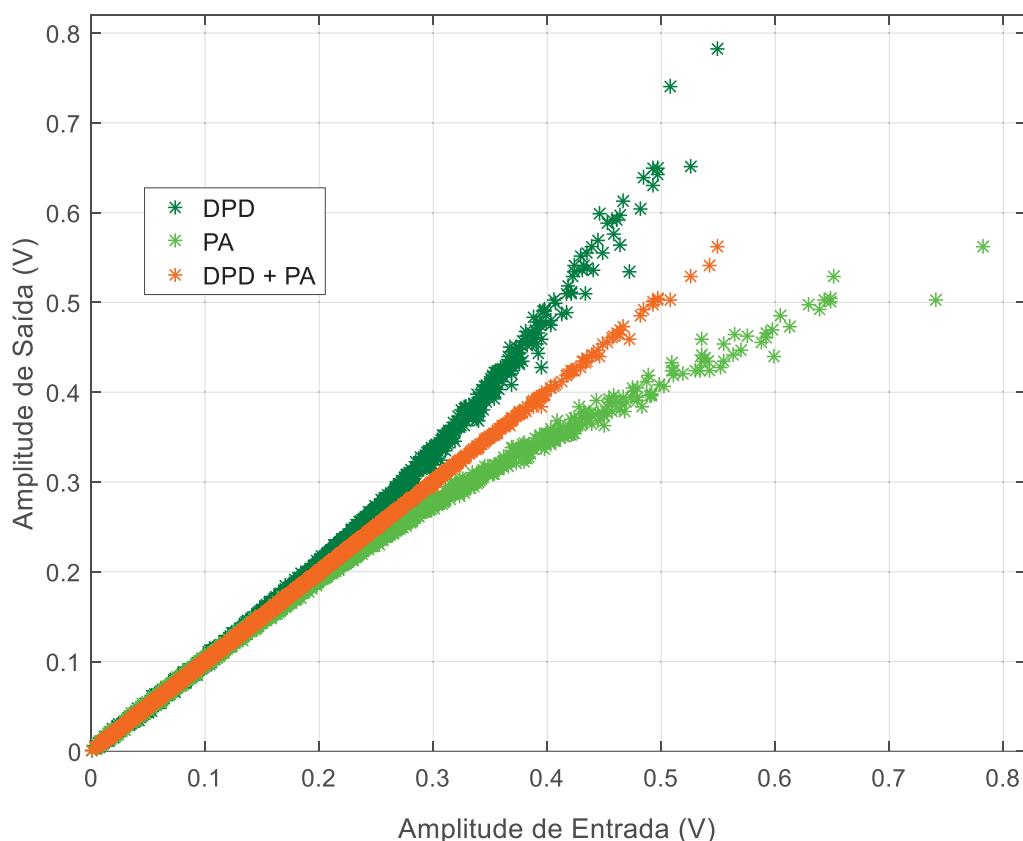


Figura 29. Características de transferência do PA, da DPD e da conexão em cascata usando aprendizagem indireta com subamostragem

5.2.3 Polinômio com memória de largura de banda limitada

Nesta abordagem, obtém-se os resultados de uma DPD convencional e de uma com largura de banda limitada. Para a abordagem de largura de banda limitada, utiliza-se um filtro passa-baixas com $BW = 38,4$ MHz, descrito por uma sequência idealizada no domínio da frequência, ou seja, composta de uns e zeros para frequências desejáveis e indesejáveis, respectivamente. Este filtro é aplicado tanto no sinal de saída do PA, quanto na saída da DPD, para o modelo descrito em (9).

A Tabela V apresenta os resultados de quatro iterações da estratégia de aprendizagem indireta, conforme descrito na Seção 4.3 e, neste caso, os resultados da aprendizagem direta usando como estimativa inicial apenas os parâmetros obtidos na quarta iteração da aprendizagem indireta.

A Tabela V mostra que os valores de NMSE obtidos com as DPDs convencionais são melhores em aproximadamente 3,5 dB com relação aos valores obtidos com as DPDs de largura de banda limitada. Por outro lado, há uma redução de cerca de 3,8 dB nos valores de ACPR obtidos com as DPDs de largura de banda

limitada, quando comparados com os valores obtidos com as DPDs convencionais. No caso da aprendizagem indireta, verifica-se uma melhora bastante significativa ao se utilizar duas iterações ao invés de apenas uma iteração. Isso se justifica pelo fato de que o PoD extraído na segunda iteração trabalha em um cenário muito mais próximo da operação da DPD, ou seja, com entrada não distorcida e saída distorcida. Ao incrementar-se ainda mais a quantidade de iterações da abordagem indireta, os resultados mantêm-se bastante próximos do resultado obtido na segunda iteração.

Para o caso da aprendizagem direta, é utilizado um esquema combinado das arquiteturas, partindo de estimativas iniciais fornecidas pela quarta iteração da abordagem indireta e encontrando os parâmetros da DPD com a arquitetura de aprendizagem direta. Ainda de acordo com a Tabela V, observa-se apenas uma ligeira melhoria na capacidade de linearização, quantificada por reduções de no máximo 0,4 dB e 0,2 dB em termos de NMSE e ACPR, respectivamente.

TABELA V - RESULTADOS DE NMSE E ACPR: CONVENCIONAL VERSUS LARGURA DE BANDA LIMITADA

Arquitetura	Cenários	Convencional		Banda Limitada	
	Iterações	NMSE [dB]	ACPR [dB]	NMSE [dB]	ACPR [dB]
Aprendizagem Indireta	1 ^a	-44,394	-51,023	-41,713	-53,503
	2 ^a	-47,152	-54,474	-43,569	-58,168
	3 ^a	-46,903	-54,063	-43,597	-58,223
	4 ^a	-47,279	-54,554	-43,598	-58,232
Aprendizagem Direta	12 / 14	-47,700	-54,743	-43,661	-57,998

Considerando o maior custo computacional adicional exigido pela aprendizagem direta, seu uso não se justifica no estudo de caso aqui reportado. Destaca-se que, na prática, o modelo de PA, exigido apenas na abordagem direta, não será perfeito, o que pode, por sua vez, reduzir a capacidade de linearização da DPD identificada pela abordagem direta. A Figura 30 mostra as PSDs de diferentes sinais na saída do PA.




Figura 30. PSDs dos sinais de saída do PA, em que: Conv. indica presença da DPD convencional; Ind. e Dir. referem-se às aprendizagens indireta e direta, respectivamente; BL indica largura de banda limitada.

Sem a presença da DPD, há níveis significativos de distorção nos canais adjacentes. Na presença das DPDs convencionais, as distorções são fortemente atenuadas em todo o espectro de frequências. Já as DPDs de largura de banda limitada atenuam apenas as distorções localizadas dentro de uma faixa de frequências igual a BW . Fora desta faixa, a atenuação das distorções é realizada pelo filtro linear (ideal neste caso), conforme ilustra a Figura 30.

A Figura 31 mostra a amplitude de saída em função da amplitude de entrada para o PA, a DPD de largura de banda limitada e a conexão em cascata da DPD seguida pelo PA. A expansão de ganho gerada pela DPD cancela, quase que completamente, a compressão de ganho produzida pelo PA.

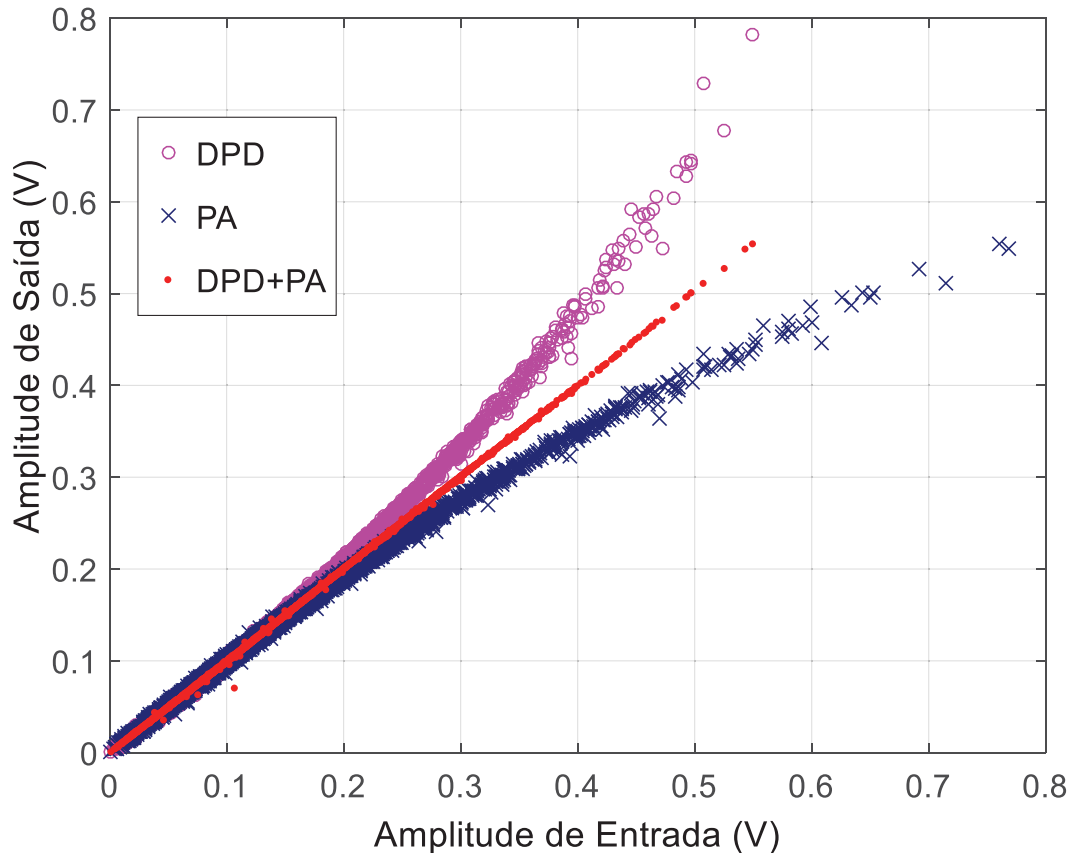


Figura 31. Características de transferência para: o PA, a DPD de largura de banda limitada usando aprendizagem indireta e a conexão em cascata DPD+PA.

5.2.4 Modelo BLMP baseado em LUT

Esta seção aborda a identificação do polinômio com memória de largura de banda limitada baseado em LUT. Todos os valores de entrada de valor real da LUT, $e_{m,q}$ de (12), são predeterminados como valores igualmente espaçados começando em zero. O LPF e os valores para M , P e Q também são assumidos conhecidos: $M = 1$, $Q = 4$, $e_{m,1} = 0$, $e_{m,2} = 1/3$, $e_{m,3} = 2/3$, $e_{m,4} = 1$, e usando a sequência no domínio da frequência idealizada mencionada na seção anterior para implementar o LPF. A Tabela VI apresenta os resultados obtidos com as arquiteturas de aprendizagem direta e quatro iterações da arquitetura de aprendizagem indireta. Os valores de NMSE e ACPR melhoraram significativamente da primeira para a segunda iterações. Essas melhorias refletem o comportamento já explicado de que um segundo PoD identificado funciona em um cenário mais próximo da validação da DPD. Da terceira para a quarta iteração as melhoras são ligeiras na capacidade de linearização. A

estimativa inicial, para a aprendizagem direta, usa os parâmetros encontrados na quarta iteração da aprendizagem indireta.

TABELA VI - RESULTADOS DE NMSE E ACPR DA IDENTIFICAÇÃO DO MODELO MPLBL BASEADO EM LUT

Arquitetura	Cenários	Convencional		MPLBL com LUT	
	Iterações	NMSE [dB]	ACPR [dB]	NMSE [dB]	ACPR [dB]
Aprendizagem Indireta	1 ^a	-44,394	-51,023	-35,558	-49,14
	2 ^a	-47,152	-54,474	-40,036	-52,798
	3 ^a	-46,903	-54,063	-40,065	-52,852
	4 ^a	-47,279	-54,554	-40,069	-52,864
Aprendizagem Direta	12 / 24	-47,700	-54,743	-40,969	-55,305

Em comparação com a aprendizagem indireta, a aprendizagem direta melhora os resultados de NMSE e ACPR em até 0,9 dB e 2,4 dB, respectivamente. No entanto, essa pequena melhoria só pode ser alcançada à custa de um maior custo computacional quando comparado com a aprendizagem indireta. A Figura 32 mostra as PSDs dos sinais de saída do PA linearizado e não linearizado, evidenciando as diferenças.

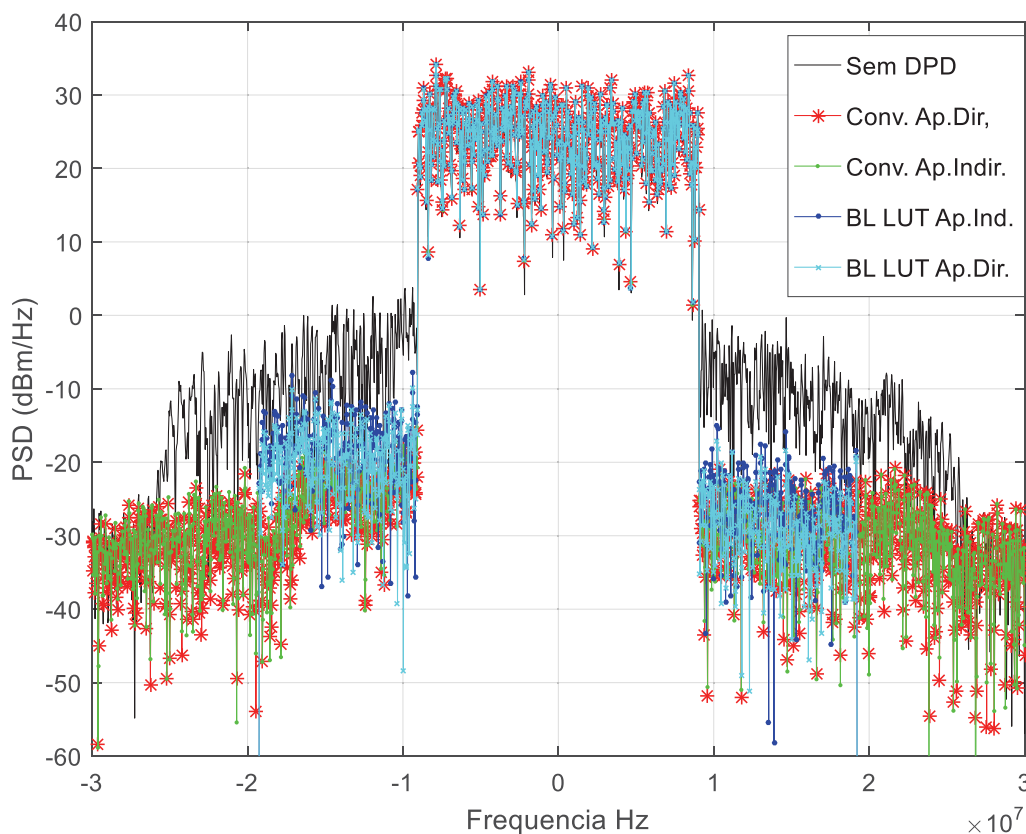


Figura 32. PSDs dos sinais de saída do PA sem DPD, com DPD aplicando as arquiteturas de aprendizagens indireta e direta com largura de banda limitada e LUTs

A Figura 33 mostra a amplitude de saída como uma função da amplitude de entrada para o modelo do PA, o modelo da DPD e a conexão em cascata de DPD seguida de PA. Observa-se que a expansão do ganho da DPD cancela quase que totalmente a compressão do ganho do PA.

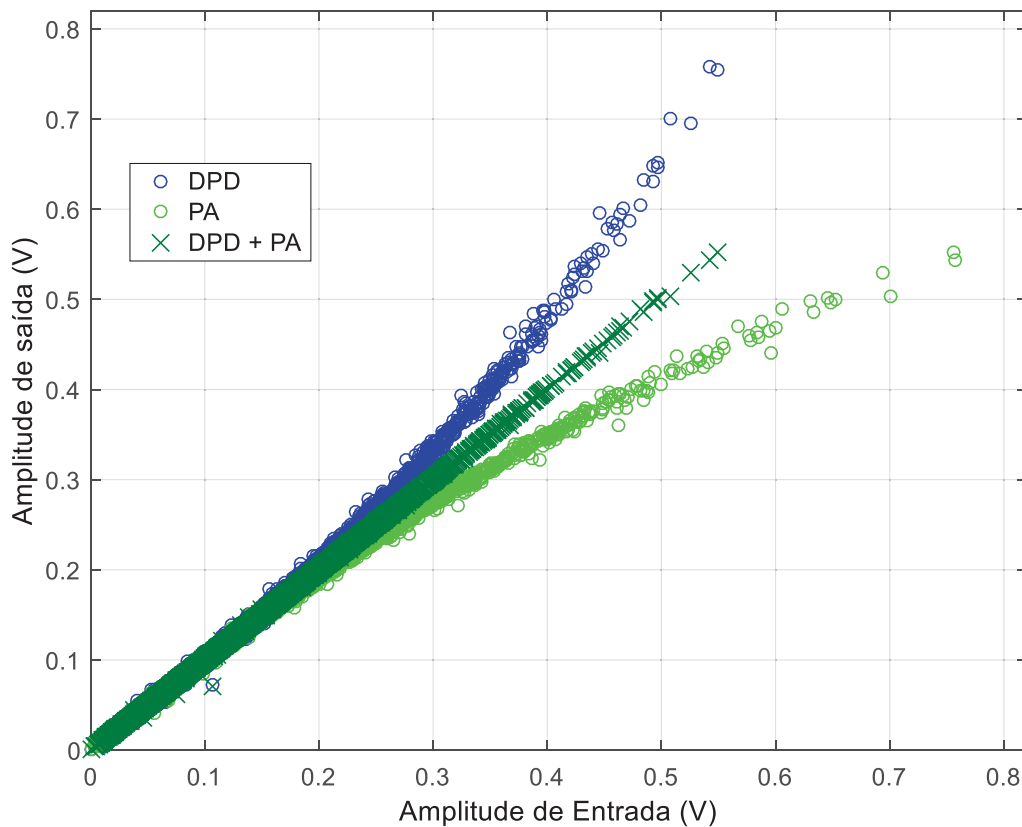


Figura 33. Características de transferência do PA, da DPD e da conexão em cascata DPD+PA de largura de banda limitada com LUTs usando aprendizagem indireta.

6 CONCLUSÕES

Foram avaliadas comparativamente as acurácias de DPDs identificadas através de duas abordagens diferentes, a arquitetura de aprendizagem direta e a arquitetura de aprendizagem indireta, aplicadas em quatro cenários distintos, como mostrado na Tabela VII. Para todos os casos, a aprendizagem indireta fornece uma identificação adequada da DPD quando quatro iterações de mínimos quadrados são feitas. Além disso, a aprendizagem indireta oferece uma complexidade baixa e sem necessidade de ter conhecimento do modelo do PA. No entanto, a aprendizagem direta faz a mesma tarefa com um procedimento não linear, que requer o modelo do PA e estimativas iniciais com o risco de ficar preso em mínimos locais. Este fato aumenta a complexidade computacional desta arquitetura. Portanto, mesmo sendo obtidos os melhores resultados de NMSE e ACPR pela aprendizagem direta, justifica-se a adoção da abordagem indireta, pois ela exige uma quantidade significativamente menor de cálculos quando comparada com a aprendizagem direta, apesar de ter uma pequena redução na capacidade de linearização, atribuída ao deslocamento da inversa durante as etapas de identificação e aplicação.

TABELA VII - RESULTADOS COMPARATIVOS DE NMSE E ACPR DAS DIFERENTES TÉCNICAS DE REDUÇÃO DA FREQUÊNCIA DE AMOSTRAGEM

Técnica Aplicada	Aprendizagem Indireta			Aprendizagem Direta		
	Iterações	NMSE [dB]	ACPR [dB]	Iterações	NMSE [dB]	ACPR [dB]
Convencional	4 ^a	-47,279	-54,554	18	-49,106	-56,474
Subamostragem	4 ^a	-47,097	-54,706	115	-48,789	-56,757
Banda Limitada	4 ^a	-43,598	-58,232	14	-43,661	-57,998
BL LUT	4 ^a	-40,069	-52,864	24	-40,969	-55,305

Os resultados da simulação de um estudo de caso, quando utilizada a técnica de subamostragem, mostram que a capacidade de linearização não é deteriorada significativamente pela presença do *aliasing* no sinal de erro de tempo discreto amostrado a uma frequência que cumpre o critério de Nyquist apenas para o sinal de envoltória não distorcida, quando comparada com a amostragem convencional. Especificamente, há uma diferença entre 0,2 e 0,3 dB no NMSE e ACPR.

Em um terceiro caso de estudo, foi utilizada uma DPD de um modelo MP de largura de banda limitada, para relaxar as especificações de conversores

analógicos-digitais e conversores digitais-analógicos. Resultados de simulação relatam uma redução na capacidade de linearização comparada a uma abordagem convencional, porém uma melhora significativa no ACPR de 2 a 4 dB é observada.

Por último, uma identificação de parâmetros para um modelo polinomial com memória de largura de banda limitada baseado em LUT, é o mais próximo a uma DPD a ser implementada em tempo real, pois aborda problemas de redução de largura de banda e otimização na velocidade de cálculos durante o processamento de um sinal através da DPD. Os resultados indicam uma capacidade de linearização aceitável, assim como bons níveis de ACPR nos canais adjacentes.

REFERÊNCIAS

ABDELAZIZ, M.; FU, Z.; ANTTILA, L.; WYGLINSKI, A. M.; VALKAMA, M. Digital predistortion for mitigating spurious emissions in spectrally agile radios. **IEEE Communications Magazine**, v. 54, n. 3, p. 60–69, 2016.

BAUDOIN, G.; JARDIN, P. Adaptive polynomial pre-distortion for linearization of power amplifiers in wireless communications and WLAN. **EUROCON 2001 - International Conference on Trends in Communications, Proceedings**, p. 157–160, 2001.

BONDAR, D.; BUDIMIR, D. Distortion Improvement of Power Amplifiers with Digital Predistortion. **Wireless Communications Research Group**, n. 2, 2009.

BRAITHWAITE, R. N. General Principles and Design Overview of Digital Predistortion. In: Fa-Long Luo (Ed.); **Digital front-end in wireless communications and broadcasting circuits and signal processing**. p.150–161, 2011. Cambridge University Press.

BRAITHWAITE, R. N. Closed-loop digital predistortion (DPD) using an observation path with limited bandwidth. **IEEE Transactions on Microwave Theory and Techniques**, v. 63, n. 2, p. 726–736, 2015.

BRUBAKER, D. Optimizing Performance and Efficiency of PAs in Wireless Base Stations. **Texas Instruments**, p. 1–5, 2009.

CHAVEZ, J. H.; LIMA, E. G. Direct and Indirect Learning for Predistorter Design Using Data with Reduced Sampling Frequency. **Proceedings of the 32nd South Symposium on Microelectronics**, p.13–16, 2017a. Rio Grande - RS.

CHAVEZ, J. H.; LIMA, E. G. Comparison between Direct and Indirect Learning for the Identification of Digital Baseband Predistorters. **Proceedings XXIII Iberchip Workshop**, p.1–4, 2017b. Bariloche - Argentina.

CHAVEZ, J. H.; LOLIS, L. H.; LIMA, E. G. Aprendizagens Direta e Indireta para a Identificação de Pré-distorsores de Largura de Banda Limitada. **XXXV Simpósio Brasileiro de Telecomunicações e Processamento de Sinais - SBRT 2017**, p.1029–1033, 2017. São Pedro - SP.

CHIPANSKY, L. B. **Modelagem Comportamental e Pré-distorção Digital de Amplificadores de Potência Baseadas em Redes Neurais com Arquitetura Perceptron de Três Camadas**, 2015. Universidade Federal do Paraná.

CRIPPS, S. **RF Power Amplifiers for Wireless Communications**. 2nd ed.

Norwood, MA: Artech House, 2006.

EUN, C.; POWERS, E. J. A New Volterra Predistorter Based on the Indirect Learning Architecture. **IEEE Transactions on Signal Processing**, v. 45, n. 1, p. 223–227, 1997.

FA-LONG, L. **Digital Front-End in Wireless Communications and Broadcasting**. Cambridge University Press, 2011.

FENG, X.; WANG, Y.; FEUVRIE, B.; et al. Analysis on LUT based digital predistortion using direct learning architecture for linearizing power amplifiers. **EURASIP Journal on Wireless Communications and Networking**, p. 1–14, 2016.

FRANK, W. A. Sampling requirements for Volterra system identification. **IEEE Signal Process. Lett**, v. 3, p. 266–268, 1996.

GHANNOUCHI, F. M.; HAMMI, O. Behavioral Modeling and Predistortion. **IEEE microwave magazine**, v. 10, n. 7, p. 52–64, 2010.

GHANNOUCHI, F. M.; KWAN, A.; HAMMI, O.; HELAOUI, M.; SMITH, M. R. Look-up table-based digital predistorter implementation for field programmable gate arrays using long-term evolution signals with 60 MHz bandwidth. **IET Science, Measurement & Technology**, v. 6, n. 3, p. 181–188, 2012.

GILMORE, R.; BESSER, L. **Practical RF circuit design for modern wireless systems**. 1st ed. Artech House, 2003.

KENINGTON, P. B. High-Linearity RF Amplifier Design. **IEEE AEES Systems Magazine**, , n. October, p. 17–18, 2001.

KIM, J.; KONSTANTINOPOULOS, K. Digital predistortion of wideband signals based on power amplifier model with memory. **Electronics Letter**, v. 37, n. 6, p. 1417–1418, 2001.

KIM, J.; PARK, C.; MOON, J.; KIM, B. Analysis of Adaptive Digital Feedback Linearization Techniques. **IEEE Transactions on Circuits and Systems**, v. 57, n. 2, p. 345–354, 2010.

KU, H.; KENNEY, J. S. Behavioral Modeling of Nonlinear RF Power Amplifiers Considering Memory Effects. **IEEE Transactions of Microwave Theory and Techniques**, v. 51, n. 12, p. 2495–2504, 2003.

LAERT, J. **Técnica de Linearização por Pré Distorção Empregando um Modelo Não Linear Exponencial**, 2003. INATEL.

LARSON, L.; KIMBALL, D.; ASBECK, P.; et al. Digital Predistortion Techniques for Linearized Power Amplifiers. **Proceedings of Asia-Pacific**

Microwave Conference, 2006.

LI, J.; KAVEHRAD, M. OFDM-CDMA Systems with Nonlinear Power Amplifier.

Wireless Communications and Networking Conference, p. 1167–1171, 1999.

LIM, Y. H.; CHO, Y. S.; CHA, W.; YOUN, D. H. An adaptive nonlinear prefilter for compensation of distortion in nonlinear systems. **IEEE Transactions on Signal Processing**, v. 46, n. 6, p. 1726–1730, 1998.

LIMA, E. G. **Behavioral Modeling and Digital Predistortion of RF Power Amplifiers**, 2006. Politecnico Di Torino.

LIU, Y.; PAN, W.; SHAO, S.; TANG, Y. A general digital predistortion using Constrained Feedback Bandwidth for Wideband Power Amplifiers. **IEEE Transactions of Microwave Theory and Techniques**, v. 63, n. 5, p. 1544–1555, 2015.

LIU, Y.; YAN, J. J.; DABAG, H.; MEMBER, S.; ASBECK, P. M. Novel Technique for Wideband Digital Predistortion of Power Amplifiers With an Under-Sampling ADC. **IEEE Transactions on Microwave Theory and Techniques**, v. 62, n. 11, p. 2604–2617, 2014.

LYONS, R. G. **Understanding Digital Signal Processing**. 2nd ed. 2004.

MAAS, S. A. **Nonlinear Microwave and RF circuits**. 2nd ed. Artech House, Inc. Norwood, MA, USA, 2003.

MARSALEK, R.; JARDIN, P.; BAUDOIN, G. From post-distortion to pre-distortion for power amplifiers linearization. **IEEE Communications Letters**, v. 7, n. 7, p. 308–310, 2003.

MINIHOLD, R.; WAGNER, R. **Measuring the Nonlinearities of RF-Amplifiers using Signal Generators and a Spectrum Analyzer**. 2010.

MKADEM, F. **Behavioral Modeling and Digital Predistortion of Wide- and Multi-Band Transmitter Systems**, 2014. University of Waterloo.

MONTORO, G.; GILABERT, L. Power Amplifier Nonlinear Modeling for Digital Predistortion. In: Cambridge University (Ed.); **Digital front-end in wireless communications and broadcasting circuits and signal processing**, 2011.

MUHONEN, K. J.; KAVEHRAD, M.; KRISHNAMOORTHY, R. Look-Up Table Techniques for Adaptive Digital Predistortion : A Development and Comparison. **IEEE Transactions on Vehicular Technology**, v. 49, n. 5, p. 1995–2002, 2000.

MURMANN, B. ADC Performance Survey 1997-2016. Disponível em: <<http://web.stanford.edu/~murmman/adcsurvey.html>>. Acesso em: 20/7/2017.

NASKAS, N.; PAPANANOS, Y. Neural-Network-Based Adaptive Baseband Predistortion Method for RF Power Amplifiers. **IEEE Transactions on Circuits and Systems**, v. 51, n. 11, p. 619–623, 2004.

NYQUIST, H. Certain Topics in Telegraph Transmission Theory. **Transactions of the A.I.E.E.**, v. 90, n. 2, 1928.

OSBORNE, M. R. Nonlinear least squares — the Levenberg algorithm revisited. **J. Austral. Math. Society**, v. 19, p. 343–357, 1976.

PEDRO, J. C.; CARVALHO, N. B. **Intermodulation Distortion in Microwave and Wireless Circuits**. 1st ed. Artech House, Inc. Norwood, MA, USA, 2003.

PEDRO, J.; MAAS, S. A Comparative Overview of Microwave and Wireless Power-Amplifier Behavioral Modeling Approaches. **IEEE Transactions on Microwave Theory and Techniques**, v. 53, n. 4, p. 1150–1163, 2005.

RAYCHAUDHURI, D.; MANDAYAM, N. B. Frontiers of Wireless and Mobile Communications. **Proceedings of the IEEE**, v. 100, p.824–840, 2012.

RIZENTAL, C. L. **Modelagem Comportamental de Amplificadores de Potência Usando Soma de Produtos Entre Filtros Digitais de Resposta ao Impulso Finita e Tabelas de Busca Unidimensionais**, 2016. Universidade Federal do Paraná.

ROY, S. **Energy Logic for Telecommunications**. 2008.

RUMMERY, S.; BRANNER, G. R. Power Amplifier Design Using Feedforward Linearization. **Proceedings of 40th Midwest Symposium on Circuits and Systems**, p. 545–548, 1997.

SÁNCHEZ, C.; SAÉNZ, L.; GARCÍA, P.; CARRO, P. L.; VALDOVINOS, A. Performance Evaluation of an Automatic Impedance Synthesizer based on RF Switches. **IEEE Transactions on Vehicular Technology**, p. 1–4, 2009.

SCHETZEN, M. Theory of Pth-order inverses of nonlinear systems. **IEEE Transactions on Circuits and Systems**, v. 23, n. 5, p. 285–291, 1976.

TSIMBINOS, J.; LEVER, K. V. Input Nyquist Sampling Suffices to Identify and Compensate Nonlinear Systems. **IEEE transactions signal processing**, v. 46, n. 10, p. 2833–2837, 1998.

WUNDER, G.; FISCHER, R. F. H.; BOCHE, H.; LITSYN, S. The PAPR Problem in OFDM Transmission. **IEEE Signal Processing**, p. 130–144, 2013.

YI, J.; YANG, Y.; PARK, M.; KANG, W.; KIM, B. Analog Predistortion Linearizer for High-Power RF Amplifiers. **IEEE Transactions of Microwave Theory**

and Techniques, v. 48, n. 12, p. 2709–2713, 2000.

YU, C.; GUAN, L.; ZHU, E.; ZHU, A. Band-Limited Volterra Series-Based Behavioral Modeling of RF Power Amplifiers. **IEEE Transactions of Microwave Theory and Techniques**, v. 60, n. 12, p. 4198–4208, 2012.

ZHANG, Q.; LIU, Y.; ZHOU, J.; et al. A Band-Divided Memory Polynomial for Wideband Digital Predistortion With Limited Bandwidth Feedback. **IEEE Transactions on Circuits and Systems**, v. 62, n. 10, p. 922–926, 2015.

ZHOU, D.; DEBRUNNER, V. E. Novel Adaptive Nonlinear Predistorters Based on the Direct Learning Algorithm. **IEEE Transactions on Signal Processing**, v. 55, n. 1, p. 120–133, 2007.

ZHU, Y.-M. Generalized sampling theorem. **IEEE Trans. Circuits Syst. II**, v. 39, p. 587–588, 1992.