

UNIVERSIDADE FEDERAL DO PARANÁ

LUIS SCHUARTZ

PRÉ-DISTORÇÃO DIGITAL DE AMPLIFICADORES DE POTÊNCIA  
DE BANDAS MÚLTIPLAS CONCORRENTES PARA APLICAÇÕES  
EM TELEFONIA MÓVEL

CURITIBA

2021

LUIS SCHUARTZ

PRÉ-DISTORÇÃO DIGITAL DE AMPLIFICADORES DE POTÊNCIA  
DE BANDAS MÚLTIPLAS CONCORRENTES PARA APLICAÇÕES  
EM TELEFONIA MÓVEL

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, Área de Concentração Telecomunicações, Departamento de Engenharia Elétrica, Setor de Tecnologia, Universidade Federal do Paraná, como parte das exigências para obtenção do título de Doutor em Engenharia Elétrica.

Orientador: Prof. Ph.D. Eduardo Gonçalves de Lima

CURITIBA

2021

Catálogo na Fonte: Sistema de Bibliotecas, UFPR  
Biblioteca de Ciência e Tecnologia

S383p

Schuartz, Luis

Pré-distorção digital de amplificadores de potência de bandas múltiplas concorrentes para aplicações em telefonia móvel [recurso eletrônico] / Luis Schuartz. – Curitiba, 2021.

Tese - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, 2021.

Orientador: Eduardo Gonçalves de Lima .

1. Amplificadores de potência. 2. Sistemas de comunicação em banda larga. 3. Sistemas de telefonia celular. 4. Telefonia 5G. I. Universidade Federal do Paraná. II. Lima, Eduardo Gonçalves de. III. Título.

CDD: 621.382535

Bibliotecário: Elias Barbosa da Silva CRB-9/1894



MINISTÉRIO DA EDUCAÇÃO  
SETOR DE TECNOLOGIA  
UNIVERSIDADE FEDERAL DO PARANÁ  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA  
ELÉTRICA - 40001016043P4

## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA ELÉTRICA da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **LUIS SCHUARTZ** intitulada: **PRÉ-DISTORÇÃO DIGITAL DE AMPLIFICADORES DE POTÊNCIA DE BANDAS MÚLTIPLAS CONCORRENTES PARA APLICAÇÕES EM TELEFONIA MÓVEL**, sob orientação do Prof. Dr. EDUARDO GONÇALVES DE LIMA, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutor 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, 08 de Novembro de 2021.

Assinatura Eletrônica

08/11/2021 14:46:23.0

EDUARDO GONÇALVES DE LIMA  
Presidente da Banca Examinadora

Assinatura Eletrônica

08/11/2021 15:30:13.0

GLAUBER GOMES DE OLIVEIRA BRANTE  
Avaliador Externo (UNIVERSIDADE TECNOLÓGICA FEDERAL DO  
PARANÁ)

Assinatura Eletrônica

08/11/2021 15:04:39.0

LUIS HENRIQUE ASSUMPTÃO LOLIS  
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

08/11/2021 16:00:50.0

LUIS CARLOS VIEIRA  
Avaliador Externo (UNIVERSIDADE TECNOLÓGICA FEDERAL DO  
PARANÁ)

## **AGRADECIMENTOS**

Agradeço primeiro a Deus por me conceder o dom da vida e conhecimento.

Ao orientador Eduardo Gonçalves de Lima por todo incentivo e dedicação para que este trabalho fosse concluído.

Aos professores e colegas do GICS que de alguma forma contribuíram e fizeram parte dessa pesquisa.

Aos familiares e amigos pelo incentivo e consideração durante este período.

A fundação CAPES pelo suporte financeiro.

## RESUMO

Os avanços sobre a telefonia 4G rumo à 5G e além vêm impondo desafios para a comunicação sem fio em relação à linearidade e à eficiência causados principalmente pela comunicação concorrente e de banda larga. Nestes cenários, o amplificador de potência (PA) é o componente crítico do transmissor devido às características de linearidade, eficiência e do nível de potência. Conseqüentemente, a inclusão de um pré-distorcedor digital (DPD), componente que implementa um modelo capaz de compensar os efeitos de distorção, é fundamental para garantir o desempenho do sistema. O DPD é um componente interessante por ser adaptável e efetivo, entretanto, o uso de modelos complexos, a frequência de amostragem e o consumo de potência inadequados podem torná-lo inviável, principalmente em cenários de transmissão de bandas múltiplas. Se por um lado, existem modelos para bandas múltiplas de alta acurácia, sendo uma solução bem desenvolvida, por outro lado, garantir acurácia elevada com poucos parâmetros ainda é desafiador. Dessa forma, o objetivo central desse trabalho é modelar e linearizar um PA com comunicação em bandas múltiplas concorrentes buscando melhorar os métodos de extração de parâmetros, modelos com poucos parâmetros e obter a máxima potência do PA cumprindo os requisitos de espalhamento no espectro de frequência e de magnitude do vetor de erro (EVM) das normas regulamentadoras. Em específico, essa tese apresenta: a comparação entre abordagens de extração de parâmetros direta, indireta e indireta modificada em banda dupla, modelos com vários fatores de truncamento para bandas dupla e tripla concorrentes alinhados a um novo algoritmo de escolha dos fatores de truncamento, e a saturação do DPD para bandas múltiplas. Resultados obtidos da modelagem e linearização de um PA CMOS classe AB de banda larga simulado nos *softwares* Matlab e Cadence Virtuoso apontam ganhos de até 5 dB no erro quadrático médio normalizado (NMSE) e redução máxima de 1,76% para 1,13% em EVM com a aprendizagem indireta modificada; os modelos propostos alinhados ao algoritmo de busca para os fatores de truncamento atingiram ganhos de até 3,76 dB, 8,3 dB e 16,6 dB em NMSE para banda dupla, tripla e tripla com portadoras múltiplas em relação ao estado da arte, respectivamente; e a saturação para banda dupla permitiu elevar o rendimento do PA de 14,7% a 17,3% com degradação abaixo de 1 p.p. no EVM.

Palavras-chave: Amplificador de potência. Pré-distorção digital. Banda dupla concorrente. Banda tripla concorrente. Saturação do DPD para bandas múltiplas. Eficiência. Telefonia 5G.

## ABSTRACT

The advances of the 4G mobile telecommunication to 5G and beyond impose challenges in linearity and efficiency of the wireless communication major by the multiband and broadband communication. In these scenarios, the power amplifier (PA) is the critical component in the transmission system due to the linearity and efficiency characteristics, and the high power level. Consequently, the inclusion of a digital pre-distorter (DPD), a device that implements a behavioral model able to compensate for the PA distortions, is fundamental to guarantee the system performance. The DPD is interesting for being adaptable and effective; however, the use of complex models, the high sampling frequency and the power consumption can make unfeasible its use, mainly for multi-band transmission. If on the one hand, there are multi-band models with high accuracy, being a well developed solution, on the other hand, the high accurate models with few parameters are still a challenge. In this way, the main objective of this work is to model and to linearize a PA in concurrent multi-band improving the extraction of parameters approach, models with few parameters and the maximum output power respecting the requirements of spectral regrowth and of the error vector magnitude (EVM) of the regulatory standards. Specifically, this thesis does: a comparison among the direct, indirect and modified indirect learning approaches for parameters extraction in dual-band, introduces models with various truncation factors for concurrent dual-band and concurrent tri-band aligned with a new algorithm for factors selection, and the DPD saturation for multi-band. Results of modeling and linearization of a broadband PA CMOS class AB simulated in the Matlab and Cadence Virtuoso software reported gain up to 5 dB in the normalized mean square error (NMSE) and maximum reduction from 1.76% to 1.13% in EVM with the proposed modified indirect learning; the introduced models aligned with the algorithm for search of best truncation factors achieve gains up to 3.76 dB, 8.3 dB and 16.6 dB in the NMSE metric for dual-band, tri-band and harmonically tri-band compared with state-of-art, respectively; and the saturation of the dual-band allowed increase the PA efficiency from 14.7% to 17.3% with degradation below 1 p.p. in the EVM.

Keywords: Power amplifier. Digital predistortion. Concurrent dual-band. Concurrent tri-band. Broad-band. DPD saturation for multi-band. Efficiency. 5G mobile communication.

## LISTA DE FIGURAS

|      |   |    |
|------|---|----|
| 2.1  | Sistema de transmissão para a comunicação sem fio. . . . .  | 18 |
| 2.2  | Conexão em cascata do DPD e do PA equivalente em banda base. . . . .  | 18 |
| 2.3  | Conexão em cascata equivalente em banda base representando o DPD e o PA em um cenário de transmissão de banda dupla. . . . .  | 19 |
| 2.4  | Características de operação de um PA desprezando o efeito de memória. . . . .   | 20 |
| 2.5  | Característica de rendimento de um PA em função da potência. . . . .  | 20 |
| 2.6  | Projeção da figura 2.5 na figura 2.4. . . . .   | 21 |
| 2.7  | Conteúdo espectral causado pelo efeito de intermodulação e modulação cruzada para transmissão de banda dupla concorrente no (a) sinal de entrada do PA (b) no sinal de saída do PA. . . . . | 22 |
| 2.8  | Ilustração das interferências harmônicas de portadoras múltiplas para um PA de banda larga. . . . .   | 23 |
| 2.9  | Ilustração do conteúdo espectral gerado por harmônicas dentro da banda passante de um PA de banda larga que abrange o espectro dos múltiplos da portadora. . . . .                          | 23 |
| 2.10 | Conexão em cascata do DPD e do PA apresentando as características de distorção de cada bloco e da cascata. . . . .  | 24 |
| 2.11 | Rede TLP aplicável para modelagem de PAs. . . . .   | 32 |
| 2.12 | Configuração de duas redes TLP para modelagem 2D. . . . .   | 32 |
| 2.13 | Diagrama do algoritmo Ascendente. . . . .   | 37 |
| 2.14 | Diagrama de blocos da aprendizagem direta. . . . .  | 37 |
| 2.15 | Diagrama de blocos da aprendizagem indireta. . . . .  | 38 |
| 3.1  | Diagrama equivalente em banda base da aprendizagem direta utilizando um modelo como PA. . . . .   | 45 |
| 3.2  | Fluxograma da aprendizagem indireta modificada. . . . .   | 47 |
| 3.3  | Bloco aprendizagem indireta modificada. . . . .   | 48 |
| 3.4  | Diagrama completo da aprendizagem indireta modificada. . . . .  | 48 |
| 3.5  | Pseudo código do algoritmo AscFat. . . . .  | 52 |
| 3.6  | Ilustração dos passos do algoritmo AscFat. . . . .  | 54 |
| 3.7  | Implementação da saturação do DPD para banda dupla concorrente. . . . .   | 57 |
| 4.1  | Diagrama de teste para linearização do PA com simulação de envoltória. . . . .  | 59 |
| 4.2  | Diagrama de teste para linearização do PA com simulação de transitório. . . . .   | 59 |
| 4.3  | Diagrama representando o modelo de modulador para 2D aplicado no Matlab. . . . .  | 61 |
| 4.4  | Diagrama representando o modelo de modulador para 3D aplicado no Matlab. . . . .  | 61 |
| 4.5  | Diagrama representando o modelo de demodulador para 2D aplicado no Matlab. . . . .  | 62 |
| 4.6  | Diagrama representando o modelo de demodulador para 3D aplicado no Matlab. . . . .  | 62 |
| 4.7  | Diagrama de combinações das portadoras e sinais para cada teste aplicado. . . . .   | 63 |
| 5.1  | NMSE em função do número de coeficientes comparando MP para 1D modelando cada canal isoladamente e 2D-MP para (a) o canal 1; (b) o canal 2. . . . .   | 66 |

|      |  |    |
|------|--|----|
| 5.2  | Resposta em amplitude do sistema de banda dupla concorrente linearizado com 2D-IMP utilizando as aprendizagens indireta e direta nos cenários 1 ao 4 para (a) o canal 1; (b) o canal 2. . . . .  | 69 |
| 5.3  | PSD obtida do sinal de saída do sistema de banda dupla concorrente linearizado com 2D-IMP utilizando as aprendizagens indireta e direta nos cenários 1 ao 4 para (a) o canal 1; (b) o canal 2. . . . .   | 70 |
| 5.4  | Resposta em amplitude do sistema de banda dupla concorrente linearizado com redes neurais utilizando as aprendizagens indireta e direta nos cenários 1 ao 4 para (a) o canal 1; (b) o canal 2. . . . .   | 72 |
| 5.5  | PSD obtida do sinal de saída do sistema de banda dupla concorrente linearizado com redes neurais utilizando as aprendizagens indireta e direta nos cenários 1 ao 4 para (a) o canal 1; (b) o canal 2. . . . .  | 73 |
| 5.6  | NMSE de extração <i>vs.</i> as iterações de aprendizagem indireta modificada para o sistema de banda dupla concorrente aplicando (a) modelo 2D-IMP; (b) redes neurais. . . . .   | 74 |
| 5.7  | PSDs extraídos do sinal de saída do sistema de banda dupla concorrente linearizado com a aprendizagem indireta modificada aplicando modelo 2D-IMP nas iterações 2, 6, 11, e 16 para (a) cana 1; (b) canal 2. . . . .   | 76 |
| 5.8  | PSDs extraídos do sinal de saída do sistema de banda dupla concorrente linearizado com a aprendizagem indireta modificada aplicando redes neurais nas iterações 2, 6, 11, e 16 para (a) cana 1; (b) canal 2. . . . .   | 77 |
| 5.9  | Melhor combinação do NMSE <i>vs.</i> o número de coeficientes comparando os modelos 2D-IMP com restrição e sem restrição, 2D-MP da literatura aplicando busca exaustiva e 2D-MIMP proposto com busca exaustiva e com algoritmo AscFat na modelagem inversa de banda dupla concorrente para o (a) canal 1; (b) canal 2. . . . . | 78 |
| 5.10 | NMSE <i>vs.</i> o número de coeficientes comparando os modelos da literatura na modelagem banda tripla concorrente com portadoras não múltiplas para o (a) canal 1; (b) canal 2; (c) canal 3. . . . .  | 79 |
| 5.11 | NMSE <i>vs.</i> o número de coeficientes comparando o modelo proposto com os modelos da literatura na modelagem banda tripla concorrente com portadoras não múltiplas para o (a) canal 1; (b) canal 2; (c) canal 3. . . . .  | 80 |
| 5.12 | PSD do sinal de saída do sistema de banda tripla concorrente com portadoras não múltiplas linearizado com 3D-MB e 3D-IMP, limitados a 20 coeficientes, e sem linearização para mesma potência média de saída para (a) o canal 1; (b) o canal 2; (c) o canal 3. . . . .   | 87 |
| 5.13 | Magnitude do erro entre os sinais de entrada e de saída do sistema de banda tripla concorrente com portadoras não múltiplas linearizado com 3D-MB e 3D-IMP, limitados a 20 coeficientes, e sem linearização para mesma potência média de saída para (a) o canal 1; (b) o canal 2; (c) o canal 3. . . . .                       | 88 |
| 5.14 | Resposta em amplitude do sistema de banda tripla concorrente com portadoras não múltiplas linearizado com 3D-IMP limitado a 20 coeficientes e sem linearização para mesma potência média de saída para (a) o canal 1; (b) o canal 2; (c) o canal 3. . . . .  | 89 |
| 5.15 | Constelação do sinal de saída do sistema de banda tripla concorrente com portadoras não múltiplas linearizado com 3D-IMP limitado a 20 coeficientes e sem linearização para mesma potência média de saída para (a) o canal 1; (b) o canal 2; (c) o canal 3. . . . .  | 90 |

|      |  |    |
|------|--|----|
| 5.16 | NMSE <i>vs.</i> o número de coeficientes comparando o modelo proposto com o modelo da literatura na modelagem banda tripla concorrente com portadoras múltiplas para o (a) canal 1; (b) canal 2; (c) canal 3. . . . .  | 91 |
| 5.17 | PSD do sinal de saída do sistema de banda tripla concorrente com portadoras múltiplas linearizado com 3D-HMP e 3D-HIMP, limitados a 40 coeficientes, e sem linearização para mesma potência média de saída para (a) o canal 1; (b) o canal 2; (c) o canal 3. . . . .                                   | 92 |
| 5.18 | Magnitude do erro entre os sinais de entrada e de saída do sistema de banda tripla concorrente com portadoras múltiplas linearizado com 3D-HMP e 3D-HIMP, limitados a 40 coeficientes, e sem linearização para mesma potência média de saída para (a) o canal 1; (b) o canal 2; (c) o canal 3. . . . . | 93 |
| 5.19 | Resposta em amplitude do sistema de banda tripla concorrente com portadoras múltiplas linearizado com 3D-HIMP limitado a 40 coeficientes e sem linearização para mesma potência média de saída para (a) o canal 1; (b) o canal 2; (c) o canal 3. . . . .   | 94 |
| 5.20 | Constelação do sinal de saída do sistema de banda tripla concorrente com portadoras múltiplas linearizado com 3D-HIMP limitado a 40 coeficientes e sem linearização para mesma potência média de saída para (a) o canal 1; (b) o canal 2; (c) o canal 3. . . . .                                       | 95 |
| 5.21 | Amplitude de $x(n)$ e $x_c(n)$ aplicando saturação com limiar $L = 1$ V e abordagem (a) da soma; (b) da divisão. . . . .   | 96 |
| 5.22 | Amplitudes de cada canal aplicando a saturação com abordagem da soma e limiar $L = 1$ V. Amplitudes (a) do canal 1; e (b) do canal 2. . . . .  | 96 |
| 5.23 | PSDs comparando resultados sem linearização, com linearização tradicional e com as abordagens de saturação para (a) do canal 1; e (b) do canal 2. . .  | 97 |

## LISTA DE TABELAS

|      |  |    |
|------|--|----|
| 2.1  | Produtos harmônicos resultantes para os canais 1, 2 e 3 do 3D-HMP. . . . .   | 30 |
| 3.1  | Produtos de intermodulação harmônica considerando até 4 produtos para o modelo proposto 3D-HIMP. . . . .   | 51 |
| 5.1  | Resumo das configurações dos cenários de testes. . . . .   | 67 |
| 5.2  | Resultados de desempenho do PA em banda dupla concorrente linearizado com 2D-IMP e aprendizagens indireta e direta. . . . .  | 68 |
| 5.3  | Resultados de desempenho do PA em banda dupla concorrente linearizado com redes neurais e aprendizagens indireta e direta. . . . .   | 71 |
| 5.4  | Resultados de desempenho do PA em banda dupla concorrente linearizado com 2D-IMP e aprendizagem indireta modificada. . . . .   | 74 |
| 5.5  | Resultados de desempenho do PA em banda dupla concorrente linearizado com redes neurais e aprendizagem indireta modificada. . . . .  | 75 |
| 5.6  | Resultados de desempenho do sistema em banda tripla concorrente com portadoras não múltiplas, linearizado com 3D-MB e 3D-IMP limitados a 20 coeficientes. . . . .                      | 78 |
| 5.7  | Resultados de desempenho do sistema em banda tripla concorrente com portadoras múltiplas, linearizado com 3D-HMP e 3D-HIMP limitados a 40 coeficientes. . . . .                        | 82 |
| 5.8  | Resultados de desempenho da linearização de banda dupla concorrente aplicando saturação com a abordagem da soma. . . . .   | 85 |
| 5.9  | Resultados de desempenho da linearização de banda dupla concorrente aplicando saturação com a abordagem da divisão. . . . .  | 85 |
| 5.10 | Confronto de mesma potência média aplicando a linearização de banda dupla concorrente sem saturação, com saturação de 25% nas abordagens de soma e divisão e sem linearização. . . . . | 86 |

## LISTA DE SIGLAS

|            |   |
|------------|---|
| 1D         | Banda única   |
| 2D         | Banda dupla concorrente   |
| 2D-IMP     | Polinômio de memória de banda dupla melhorado   |
| 2D-MIMP    | Polinômio de memória de banda dupla melhorado multidimensional                        |
| 2D-MP      | Polinômio de memória de banda dupla   |
| 3D         | Banda tripla concorrente  |
| 3D-CR-MGMP | Polinômio de memória de banda tripla generalizado modificado de complexidade reduzida |
| 3D-DDR     | Polinômio de memória de banda tripla com redução de desvio dinâmico                   |
| 3D-GMP     | Polinômio de memória de banda tripla generalizado                                     |
| 3D-HMP     | Polinômio de memória de banda tripla harmônico  |
| 3D-IMP     | Polinômio de memória de banda tripla melhorado  |
| 3D-HIMP    | Polinômio de memória de banda tripla harmônico melhorado                              |
| 3D-MB      | Modelo de bandas múltiplas de banda tripla  |
| 3D-MGMP    | Polinômio de memória de banda tripla generalizado modificado                          |
| 3D-MP      | Polinômio de memória de banda tripla  |
| 3D-PAV     | Volterra de fase alinhada de banda tripla   |
| 4G         | Quarta Geração nos padrões da telefonia móvel   |
| 5G         | Quinta Geração nos padrões da telefonia móvel   |

|        |   |
|--------|---|
| AscFat | Ascendente de fatores                                 |
| BB     | Banda base  |
| BW     | Largura de banda                                      |
| CMOS   | Semicondutor-Metal-Óxido Complementar                 |
| DPD    | Pré-distorcedor digital                               |
| Env    | Bloco de extração da envoltória comum entre os canais |
| EVM    | Magnitude de Vetor de Erro                            |
| in     | Dados medidos de entrada                              |
| LS     | Mínimos Quadrados                                     |
| LTE    | Evolução a longo prazo                                |
| LTE-A  | Evolução a longo prazo Avançado                       |
| LUTs   | Tabelas de Busca                                      |
| MIMO   | Múltiplas entradas e múltiplas saídas                 |
| MP     | Polinômio de memória                                  |
| Mux    | Multiplexador   |
| NMSE   | Erro Quadrático Médio Normalizado                     |
| OCP1   | Ponto de 1 dB de compressão de ganho                  |
| out    | Dados medidos de saída                                |
| PA     | Amplificador de potência                              |
| PAPR   | Razão de potência de pico pela potência média         |
| PAE    | Eficiência de Potência Adicionada                     |

|      |   |
|------|---|
| PD   | Processamento digital                           |
| PoD  | Pós-distorcedor                                 |
| p.p. | Pontos percentuais                              |
| PSD  | Densidade Espectral de potência                 |
| RF   | Rádio Frequência                                |
| Sat  | Bloco que aplica a saturação com em banda dupla |
| TLP  | Perceptron de três camadas                      |

## LISTA DE SÍMBOLOS

|                                  |  |
|----------------------------------|--|
| $a$                              | Pesos de uma série de potências  |
| $A$                              | Amplitude do cosseno   |
| <code>avaliarDesempenho()</code> | Função que retorna o erro de modelagem   |
| $\Delta\omega$                   | Diferença da frequência angular central comum e da frequência de um canal de comunicação |
| $e$                              | Amostra de erro  |
| $\mathbf{e}$                     | Vetor de erro  |
| $\eta$                           | Eficiência   |
| $F$                              | Função não linear do PA  |
| $F[\cdot]$                       | Função de ativação da camada escondida da rede neural                                    |
| $\mathbf{Fat}$                   | Vetor contendo a combinação de fatores de truncamento final                              |
| $\mathbf{Fat}_M$                 | Vetor contendo o limite que pode ser atribuído a cada fator de truncamento               |
| $\mathbf{Fat}_t$                 | Vetor contendo a combinação de fatores em teste  |
| $f_O$                            | Função objetivo escalar  |
| $\mathbf{f}_O$                   | Vetor da função objetivo   |
| $f_s$                            | Frequência de amostragem   |
| $f_0$                            | Frequência de portadora  |
| $f_{01}$                         | Frequência de portadora do canal 1   |

|               |  |
|---------------|--|
| $f_{02}$      | Frequência de portadora do canal 2               |
| $g$           | Ganho da região linear do PA                     |
| $G$           | Função não linear do DPD                         |
| $h$           | Coefficiente de um modelo polinomial             |
| $\mathbf{h}$  | Vetor de coeficientes $h$                        |
| $in$          | Amostra de entrada                               |
| $\mathbf{in}$ | Vetor de $N$ amostras $in$                       |
| $in_1$        | Entrada 1  |
| $in_2$        | Entrada 2  |
| $in_{RF}$     | Entrada em RF aplicada na simulação do PA        |
| indiceMenor() | Função que retorna o índice do menor valor       |
| $it$          | iteração   |
| $L$           | Limiar limite para aplicação da saturação        |
| $M$           | Fator de truncamento para comprimento de memória |
| $M_1$         | Fator de truncamento para comprimento de memória |
| $M_2$         | Fator de truncamento para comprimento de memória |
| $M_3$         | Fator de truncamento para comprimento de memória |
| $M_4$         | Fator de truncamento para comprimento de memória |
| $M_5$         | Fator de truncamento para comprimento de memória |
| $M_6$         | Fator de truncamento para comprimento de memória |
| $n$           | Instante da amostra                              |

|            |  |
|------------|--|
| $N$        | Número de amostras                                     |
| $N_{coef}$ | Número de coeficientes                                 |
| $N_{des}$  | Número de coeficientes produzidos pelo modelo          |
| $N_{fat}$  | Número de fatores do modelo                            |
| nParam()   | Função que retorna o número de parâmetros              |
| $\omega$   | Frequência angular comum para os canais de comunicação |
| $\omega_1$ | Frequência angular central do canal 1 de comunicação   |
| $\omega_2$ | Frequência angular central do canal 2 de comunicação   |
| $out$      | Amostra de saída                                       |
| $P$        | Fator de truncamento de não linearidade                |
| $P_1$      | Fator de truncamento de não linearidade                |
| $P_2$      | Fator de truncamento de não linearidade                |
| $P_3$      | Fator de truncamento de não linearidade                |
| $P_4$      | Fator de truncamento de não linearidade                |
| $P_5$      | Fator de truncamento de não linearidade                |
| $P_6$      | Fator de truncamento de não linearidade                |
| $P_7$      | Fator de truncamento de não linearidade                |
| $P_8$      | Fator de truncamento de não linearidade                |
| $P_i$      | Fator de truncamento de não linearidade                |
| $P_{in}$   | Potência média de entrada                              |
| $P_{CC}$   | Potência da fonte contínua                             |

|           |  |
|-----------|--|
| $\phi$    | Fase aleatória da portadora                    |
| $\phi_1$  | Fase aleatória da portadora 1                  |
| $\phi_2$  | Fase aleatória da portadora 2                  |
| $P_{out}$ | Potência média de saída                        |
| $P_{sat}$ | Potência de saturação                          |
| $Q$       | Fator de truncamento de não linearidade        |
| $Q_1$     | Fator de truncamento de não linearidade        |
| $Q_2$     | Fator de truncamento de não linearidade        |
| $Q_3$     | Fator de truncamento de não linearidade        |
| $Q_4$     | Fator de truncamento de não linearidade        |
| $Q_H$     | Número total de parâmetros gerados pelo modelo |
| $r$       | Amplitude da envoltória complexa               |
| $R$       | Número de neurônios da camada escondida        |
| $R_1$     | Fator de truncamento de não linearidade        |
| $R_2$     | Fator de truncamento de não linearidade        |
| $R_3$     | Fator de truncamento de não linearidade        |
| $R_4$     | Fator de truncamento de não linearidade        |
| $R_H$     | Número desejado de parâmetros para Ascendente  |
| $R_x$     | Função de autocorrelação para $x$              |
| $R_y$     | Função de autocorrelação para $y$              |
| $s$       | Sinal modulado em RF                           |

|               |   |
|---------------|---|
| $S_x$         | Densidade espectral de potência de $x$                                      |
| $S_y$         | Densidade espectral de potência de $y$                                      |
| $t$           | Variável de tempo contínua  |
| $T$           | Transposto  |
| $\theta$      | Fase de um sinal  |
| $x$           | Envoltória complexa do sinal de entrada do DPD                              |
| $\mathbf{x}$  | Vetor de $N$ amostras $x(n)$  |
| $\mathbf{X}$  | Matriz de vetores $\mathbf{x}$  |
| $x_1$         | Envoltória complexa do canal 1 do sinal de entrada                          |
| $x_1@f_2$     | Envoltória complexa do canal 1 deslocado para frequência central do canal 2 |
| $x_{1c}$      | Envoltória complexa ceifada do canal 1                                      |
| $x'_{1c}$     | Envoltória complexa ceifada distorcida do canal 1                           |
| $x_2$         | Envoltória complexa do canal 2 do sinal de entrada                          |
| $x_2@f_1$     | Envoltória complexa do canal 2 deslocado para frequência central do canal 1 |
| $x_{2c}$      | Envoltória complexa ceifada do canal 2                                      |
| $x'_{2c}$     | Envoltória complexa ceifada distorcida do canal 2                           |
| $x_3$         | Envoltória complexa do canal 3 do sinal de entrada                          |
| $x_i$         | Envoltória complexa do canal $i$ do sinal de entrada                        |
| $x'$          | Envoltória complexa do sinal de entrada do PA                               |
| $\mathbf{x}'$ | Vetor de $N$ amostras $x'(n)$   |

|              |  |
|--------------|--|
| $y$          | Envoltória complexa do sinal de saída do PA            |
| $\mathbf{y}$ | Vetor de $N$ amostras $y(n)$                           |
| $y_1$        | Envoltória complexa do canal 1 do sinal de saída do PA |
| $y_2$        | Envoltória complexa do canal 2 do sinal de saída do PA |
| $y_I$        | Parte real da envoltória complexa $y$                  |
| $y_Q$        | Parte imaginária da envoltória complexa $y$            |
| *            | Transposto conjugado                                   |

# SUMÁRIO

|          |   |           |
|----------|---|-----------|
| <b>1</b> | <b>INTRODUÇÃO</b>   | <b>13</b> |
| 1.1      | Objetivos . . . . .   | 15        |
| 1.1.1    | Objetivos específicos . . . . .   | 15        |
| 1.2      | Organização . . . . .   | 16        |
| <b>2</b> | <b>REVISÃO BIBLIOGRÁFICA E DESAFIOS DA TELEFONIA 5G E ALÉM</b>  | <b>17</b> |
| 2.1      | Visão geral sobre o sistema de transmissão, o amplificador de potência (PA) e a pré-distorção digital . . . . . | 17        |
| 2.1.1    | O sistema de transmissão e a posição dos blocos de amplificação e pré-distorção . . . . .                       | 17        |
| 2.1.2    | Características de atuação e desempenho do PA . . . . .   | 18        |
| 2.1.2.1  | Efeitos de intermodulação, modulação cruzada, modulação de harmônica e termos fora da banda . . . . .           | 21        |
| 2.1.3    | Teoria sobre a implementação e o desempenho do DPD . . . . .  | 23        |
| 2.1.3.1  | Sinais em RF e sinais em Banda Base . . . . .   | 24        |
| 2.1.3.2  | Procedimentos em tempo-real e de extração de parâmetros do DPD . . . . .  | 26        |
| 2.1.3.3  | A relação com o desempenho do DPD . . . . .   | 26        |
| 2.2      | Modelos polinomiais para o PA e para o DPD . . . . .  | 27        |
| 2.2.1    | Modelos 1D . . . . .  | 27        |
| 2.2.2    | Modelos 2D . . . . .  | 27        |
| 2.2.3    | Modelos 3D . . . . .  | 29        |
| 2.2.3.1  | Modelo 3D para portadoras múltiplas . . . . .   | 30        |
| 2.3      | Visão geral sobre redes neurais para 1D e 2D . . . . .  | 31        |
| 2.4      | A extração e a escolha de parâmetros, e os métodos de aprendizagem . . . . .                                    | 33        |

|          |   |           |
|----------|---|-----------|
| 2.4.1    | Métodos de extração linear . . . . .  | 33        |
| 2.4.2    | Métodos de extração não linear . . . . .  | 34        |
| 2.4.3    | Escolha dos parâmetros significativos dos modelos polinomiais com<br>abordagem Ascendente . . . . .   | 35        |
| 2.4.4    | Aprendizagem direta . . . . .   | 37        |
| 2.4.5    | Aprendizagem indireta . . . . .   | 38        |
| 2.5      | Métricas de desempenho para a modelagem e a linearização de amplifica-<br>dores de potência . . . . . | 39        |
| 2.6      | O estado da arte e os desafios da telefonia 5G e futuras . . . . .                                    | 41        |
| 2.6.1    | O estado da arte . . . . .  | 41        |
| 2.6.2    | Desafios da telefonia 5G e futuras . . . . .  | 42        |
| <b>3</b> | <b>SOLUÇÕES E ALGORITMOS PROPOSTOS</b>  | <b>44</b> |
| 3.1      | Métodos de aprendizado . . . . .  | 44        |
| 3.1.1    | Aprendizagem direta 2D . . . . .  | 44        |
| 3.1.2    | Aprendizagem indireta modificada . . . . .  | 46        |
| 3.2      | Melhorias na configurabilidade dos modelos polinomiais . . . . .                                      | 47        |
| 3.2.1    | Proposta de diversos fatores de truncamento para 2D . . . . .   | 48        |
| 3.2.2    | Proposta de diversos fatores de truncamento para 3D . . . . .   | 49        |
| 3.2.3    | Proposta de diversos fatores de truncamento para 3D-Harmônico . . . . .                               | 50        |
| 3.2.4    | Algoritmo AscFat para obtenção dos fatores de truncamento . . . . .                                   | 51        |
| 3.3      | Saturação para bandas múltiplas . . . . .   | 53        |
| 3.3.1    | Contextualização para a saturação de banda dupla . . . . .  | 54        |
| 3.3.2    | Proposta de saturação para banda dupla . . . . .  | 55        |
| 3.3.2.1  | Abordagem da soma . . . . .   | 56        |
| 3.3.2.2  | Abordagem da divisão . . . . .  | 56        |
| 3.3.2.3  | O sistema de saturação para banda dupla . . . . .   | 57        |
| <b>4</b> | <b>MATERIAIS E METODOLOGIAS</b>   | <b>58</b> |
| 4.1      | Materiais . . . . .   | 58        |

|          |   |            |
|----------|---|------------|
| 4.2      | Metodologias . . . . .  | 59         |
| 4.2.1    | A interação entre Cadence Virtuoso e Matlab . . . . .   | 59         |
| 4.2.2    | Modelos de modulador e demodulador aplicados no Matlab para 2D<br>e 3D . . . . .  | 60         |
| 4.2.3    | Configuração de dados e portadoras para as análises . . . . .   | 63         |
| <b>5</b> | <b>RESULTADOS DE SIMULAÇÃO</b>  | <b>65</b>  |
| 5.1      | Resultados em relação ao método de aprendizado para o cenário 2D . . . . .  | 65         |
| 5.1.1    | Comparação entre as aprendizagens indireta tradicional e direta<br>com um modelo matemático do circuito do PA . . . . .   | 66         |
| 5.1.2    | Desempenho da aprendizagem indireta modificada . . . . .  | 69         |
| 5.2      | Resultados em relação aos modelos propostos . . . . .   | 72         |
| 5.2.1    | Desempenho do modelo 2D proposto e validação em 2D do algo-<br>ritmo AscFat proposto . . . . .  | 73         |
| 5.2.2    | Comparação entre os modelos 3D da literatura, desempenho do mo-<br>delo 3D proposto e validação em 3D do algoritmo AscFat proposto<br>em cenários de portadoras não múltiplas . . . . . | 76         |
| 5.2.3    | Comparação entre o modelo 3D proposto aplicando o algoritmo Asc-<br>Fat com modelo da literatura e resultados da linearização com por-<br>tadoras múltiplas . . . . .                   | 81         |
| 5.3      | Resultados aplicando saturação do DPD em banda dupla . . . . .  | 83         |
| 5.3.1    | Os efeitos da saturação de banda dupla . . . . .  | 83         |
| 5.3.2    | Configuração para os testes de linearização . . . . .   | 84         |
| 5.3.3    | Resultados de linearização de banda dupla com saturação . . . . .   | 84         |
| <b>6</b> | <b>CONCLUSÕES E PROPOSTAS DE TRABALHOS FUTUROS</b>  | <b>98</b>  |
| 6.1      | Conclusões . . . . .  | 98         |
| 6.2      | Publicações relacionadas com essa pesquisa . . . . .  | 100        |
| 6.3      | Propostas para trabalhos futuros . . . . .  | 100        |
|          | <b>BIBLIOGRAFIA</b>   | <b>102</b> |

# CAPÍTULO 1

## INTRODUÇÃO

A demanda crescente por transferência de dados impõe desafios sobre a comunicação sem fio, em especial sobre a eficiência espectral (MANYAM *et al.*, 2018), largura de banda e novas frequências de operação (YU *et al.*, 2020). O espectro utilizado até a telefonia 4G e IEEE 802.11, regulamentado rigorosamente pelas agências competentes (WOOD, 2015), vem tornando-se escasso devido à grande demanda (NAIK; LIU; PARK, 2018). Consequentemente, avanços sobre o 4G rumo ao 5G vêm emergindo com a agregação de portadoras múltiplas (*carrier aggregation*), múltiplas entradas e múltiplas saídas (MIMO - do inglês *multiple input multiple output*) (GILABERT *et al.*, 2019), e o uso de modulações de alta transmissão de dados. Podemos citar como principais aspectos tecnológicos nas comunicações sem fio mais recentes, a utilização de banda larga e bandas múltiplas pela 4G, uma largura de banda que chega a 100 MHz para o LTE-A (WANG; CHEN; SU, 2015; KELLY; CAO; ZHU, 2016; YU *et al.*, 2020), portadoras e portadoras múltiplas que podem variar de 3 a 6 GHz (SHOKAIR *et al.*, 2019; JARAUT; RAWAT; GHANNOUCHI, 2018), 5G com transmissão acima de 10 Gbps (MAYEDA; LIE; LOPEZ, 2017), comunicações bandas múltiplas e MIMO com frequências de ondas milimétricas (JARAUT; RAWAT; GHANNOUCHI, 2018; LI; HUANG; WANG, 2019), além da coexistência entre protocolos múltiplos de comunicação como Wi-Fi e LTE para um mesmo dispositivo de rádio frequência (NAIK; LIU; PARK, 2018; PENG; QIU; MU, 2018).

Neste cenário de transição do 4G para 5G, a transmissão em bandas múltiplas concorrentes vem ganhando espaço e é tema de estudos recentes. Nessas condições, com operação em banda larga, destaca-se a exigência por alta linearidade alinhada à máxima eficiência energética dos sistemas de transmissão (HASIN; KITCHEN, 2017; ACKERMANN *et al.*, 2020). A linearidade é um ponto crítico para satisfazer as exigências da regulamentação (HASIN; KITCHEN, 2017; MAYEDA; LIE; LOPEZ, 2017), enquanto a eficiência é fundamental para reduzir o consumo de energia (DARDAILLON; JABBOUR; SRINI, 2015; WOOD, 2015). Dentro do sistema transmissor, o componente crítico em relação à linearidade e consumo de potência é o amplificador de potência (PA - do inglês *power amplifier*) (CRIPPS, 2006; KHAWAM; ALBASHA; MIR, 2016), e deve ser otimizado (SHOKAIR *et al.*, 2019; ACKERMANN *et al.*, 2020), principalmente para sinais de alta razão de potência de pico pela potência média (PAPR) (YU *et al.*, 2020; ACKERMANN *et al.*, 2020). Devido às características de eficiência e linearidade dos PAs, pontos de máxima eficiência ocorrem com alta distorção, enquanto a linearidade é obtida apenas em pontos de baixa eficiência, criando uma relação de compromisso entre linearidade e eficiência (CRIPPS, 2006; RA-

ZAVI; BEHZAD, 1998). Além disso, considerando um espectro amplo, manter um único PA para todas as frequências torna-se vantajoso em número de componentes e custo, mas dificulta significativamente manter boa relação entre linearidade e eficiência (GILABERT *et al.*, 2019; LI; HUANG; WANG, 2019). Para garantir um compromisso adequado entre linearidade e eficiência, principalmente em banda larga, uma solução viável que apresenta boa estabilidade, linearização e escalabilidade (DARDAILLON; JABBOUR; SRINI, 2015), é a incorporação de um pré-distorcedor digital (DPD - do inglês *digital pre-distorter*) conectado em cascata com o PA (CRIPPS, 2006; VARAHRAM *et al.*, 2016; MANYAM *et al.*, 2018). O DPD é um componente digital que implementa um modelo<sup>1</sup> de característica inversa a do PA (DARDAILLON; JABBOUR; SRINI, 2015), permitindo que o sistema tenha comportamento linear e eficiente simultaneamente.

Para a comunicação em banda única (1D) com banda reduzida, o DPD tem apresentado excelente desempenho, o que permite elevar a amplitude de entrada do PA, saturando o DPD, e distorcendo a informação aos limites da norma para obter a maior potência de saída e rendimento do PA (SCHUARTZ *et al.*, 2018b, 2019a). Na telefonia 5G, a aplicação de sistemas de bandas múltiplas, a exemplo banda dupla concorrente (2D), banda tripla concorrente (3D), e banda larga, tornam o uso do DPD indispensável, por exemplo devido à variação da resposta em frequência dos componentes (JORDAO *et al.*, 2020) e a exigência por linearidade e eficiência (KELLY; CAO; ZHU, 2016). Entretanto, bandas de transmissão de até centenas de MHz, precisão máxima de conversão digital-analógico e analógico-digital, transmissão em bandas múltiplas, células de transmissão de baixa potência<sup>2</sup> e alta razão de potência de pico pela potência média (GUAN; ZHU, 2014; DESGREYS *et al.*, 2017) exigem que o DPD implemente modelos complexos de forma eficiente. Em estudos recentes, propostas e discussões vêm sendo desenvolvidas para implementação do DPD principalmente em relação aos modelos de bandas múltiplas e na solução da implementação dos conversores analógico-digitais e digital-analógicos para bandas largas (DESGREYS *et al.*, 2017; PRATT; KEARNEY, 2017; SHOKAIR *et al.*, 2019; LIU *et al.*, 2014; MANYAM *et al.*, 2018; YU *et al.*, 2020, 2020). No que se refere ao DPD para PAs de banda muito larga, Peng, Qiu & Mu (2018) propõem uma metodologia para cancelar as distorções harmônicas dentro do espectro com base em filtros adaptativos não lineares. O sistema depende de uma aprendizagem iterativa inserindo sinais de treinamento nas frequências harmônicas e a inserção de moduladores nas frequências harmônicas.

Apesar das pesquisas mais recentes proporem conteúdos significativos em implementação para bandas múltiplas concorrentes e banda larga, algumas questões ainda são precárias. A complexidade do modelo, ou o montante de parâmetros para modelar ade-

<sup>1</sup>Entre os principais se destacam os modelos polinomiais e redes neurais, mas também há aplicações com modelos de Saleh, Rapp, Hammerstein Wiener e Volterra (SHOKAIR *et al.*, 2019).

<sup>2</sup>Células de baixa potência podem comprometer o uso de DPD se o consumo de potência do DPD não justificar o ganho de potência da célula de potência além dos efeitos que podem acontecer por causa da densidade.

quadamente bandas múltiplas, pode tornar a implementação do DPD inviável devido ao consumo de potência. Garantir modelos com alta acurácia e poucos parâmetros, tanto quanto metodologias de aprendizagem precisas torna-se fundamental. Amplificadores com bandas elevadas, na ordem de GHz, geram componentes harmônicos em outras bandas (PENG; QIU; MU, 2018), remover esses componentes com filtros analógicos é impraticável devido à reconfigurabilidade e o nível de potência (PENG; QIU; MU, 2018), por outro lado, remover esses termos com DPD ainda é uma tarefa difícil por conta da frequência de amostragem alta, da falta de modelos adequados e a necessidade de *feedback*. Por fim, elevar o desempenho do PA aos limites das normas permitindo a saturação precisamente controlada do DPD, torna-se desafiador para combinação de portadoras múltiplas.

No contexto apresentado, diversos temas e estudos de casos podem ser abordados. Nessa gama de possibilidades, o escopo desse trabalho será restrito aos desenvolvimentos aplicados ao DPD para PAs de bandas múltiplas concorrentes<sup>3</sup> com contribuições desenvolvidas para aprendizagem/treinamento do DPD, modelos polinomiais e saturação para bandas múltiplas. As alterações desse contexto serão adotadas apenas como estudo de caso e não como objeto principal de desenvolvimento.

## 1.1 Objetivos

Modelar e linearizar adequadamente um amplificador de potência de banda larga para aplicação de banda dupla e tripla concorrentes através de modelos de poucos parâmetros, aplicar melhoria nos diagramas de aprendizagem e elevar o desempenho do PA procurando atingir os limites das normas em comunicação para bandas múltiplas.

### 1.1.1 Objetivos específicos

- Avaliar o desempenho dos modelos de bandas múltiplas da literatura e buscar evidenciar as limitações;
- Avaliar o desempenho de métodos de aprendizado de máquina em bandas múltiplas;
- Propor incrementos nos métodos de aprendizagem para banda dupla e verificar os efeitos das alterações;
- Propor modificações, modelos e algoritmos que permitem a acurácia alta com poucos parâmetros para bandas múltiplas;
- Estender a saturação do DPD para bandas múltiplas e avaliar os ganhos de desempenho para linearização em banda dupla.

---

<sup>3</sup>Situação em que um único transmissor (PA) estará emitindo simultaneamente mais de um canal de comunicação em portadoras distintas.

## 1.2 Organização

Esta tese de Doutorado é dividida conforme segue: O Capítulo 2 apresenta a revisão bibliográfica, o histórico de contribuições e detalhes dos desafios impostos pela telefonia 5G; o Capítulo 3 descreve as propostas do trabalho; o Capítulo 4 apresenta os recursos e as metodologias; o Capítulo 5 descreve os resultados obtidos; e o Capítulo 6 resume as conclusões e descreve sugestões para trabalhos futuros.

## CAPÍTULO 2

### REVISÃO BIBLIOGRÁFICA E DESAFIOS DA TELEFONIA 5G E ALÉM

Este capítulo apresenta a revisão bibliográfica dos conceitos fundamentais para esta pesquisa, o estado da arte e uma visão detalhada dos desafios a serem cumpridos. O capítulo está dividido conforme segue: a Seção 2.1 apresenta os conceitos gerais sobre o sistema de transmissão, o amplificador de potência (PA) e o pré-distorcedor digital (DPD); a Seção 2.2 revisa os modelos polinomiais da literatura para modelagem dos amplificadores de potência; a Seção 2.3 apresenta uma visão geral sobre redes neurais e sua aplicação para modelagem de amplificadores; a Seção 2.4 fala sobre métodos e algoritmos de extração de parâmetros dos modelos e a redução de parâmetros; a Seção 2.5 referencia as métricas de desempenho adotadas nesse trabalho; e a Seção 2.6 revisa o estado da arte e detalha os principais desafios para a telefonia 5G e além.

#### **2.1 Visão geral sobre o sistema de transmissão, o amplificador de potência (PA) e a pré-distorção digital**

Entre os componentes dos sistemas de comunicação sem fio, esta pesquisa é focada no desempenho do transmissor, em específico nos blocos de amplificação e pré-distorção digital. Dessa forma, essa seção apresenta uma visão geral do sistema de transmissão e a localização dos blocos de amplificação e pré-distorção, posteriormente aborda separadamente os blocos de amplificação e de pré-distorção digital.

##### **2.1.1 O sistema de transmissão e a posição dos blocos de amplificação e pré-distorção**

O sistema de transmissão é uma das etapas fundamentais presentes no sistema de comunicação sem fio, cujos componentes principais desse sistema estão representados pelo diagrama da figura 2.1 (RAZAVI; BEHZAD, 1998). O sinal de entrada (Fonte) é uma informação digital em conformidade com o protocolo de comunicação e possui frequência de amostragem em banda base adequada à largura de banda. O sinal de saída é uma informação analógica em rádio frequência (RF) contendo envoltória e fase proporcionais ao sinal de entrada em banda base. O sistema é constituído por componentes digitais e analógicos, entre eles, recebem atenção especial, o PA por ser o componente de maior consumo e distorção e o processamento digital (PD) por ser o componente responsável pela

linearização. O DPD é um dos processos digitais e por isso está situado no processamento digital. No desenvolvimento dessa pesquisa, o DPD e o PA são tratados como fundamentais, logo, o sistema de transmissão também pode ser representado por uma conexão em cascata equivalente em banda base entre o DPD e o PA conforme a figura 2.2.

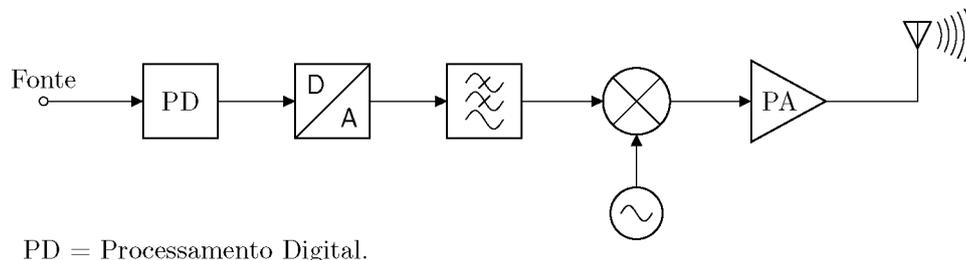


Figura 2.1: Sistema de transmissão para a comunicação sem fio.  
Fonte – O autor, 2021. Adaptado de Razavi & Behzad (1998).

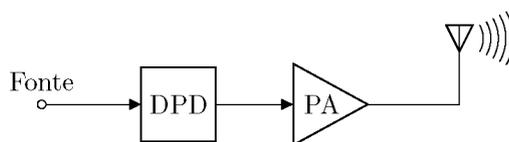


Figura 2.2: Conexão em cascata do DPD e do PA equivalente em banda base.  
Fonte – O autor, 2021.

As representações apresentadas até o momento consideram apenas uma transmissão de banda única. Essa pesquisa é destinada a cenários de aplicações de bandas múltiplas e o conceito de conexão em cascata do DPD e do PA precisa ser estendido para bandas múltiplas. Em bandas múltiplas concorrentes, cada canal é modelado isoladamente, enquanto a amplificação acontece em um único dispositivo. A figura 2.3 apresenta um diagrama para uma situação de banda dupla concorrente (KELLY; CAO; ZHU, 2016; JARAUT; RAWAT; GHANNOUCHI, 2018; GILABERT *et al.*, 2019). Diferente da figura 2.2 que há apenas informação de uma fonte única, para o caso de banda dupla existem duas fontes de informação que alimentam dois blocos de pré-distorção digital. A saída de cada bloco de pré-distorção contém a informação isolada de cada portadora. Os procedimentos de conversão digital para analógico e os misturadores foram suprimidos para simplificar a representação, mas são existentes e devem existir para cada canal. Os sinais resultantes são combinados por um somador para então serem amplificados. Esse sistema de banda dupla pode ser estendido para qualquer número de bandas.

### 2.1.2 Características de atuação e desempenho do PA

O PA é o dispositivo responsável por transmitir maior parte da potência da fonte contínua para a carga (antena) e, por isso, é fundamental que o mesmo opere em pontos de

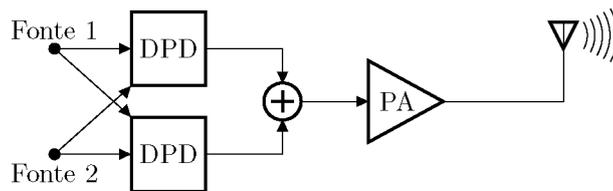


Figura 2.3: Conexão em cascata equivalente em banda base representando o DPD e o PA em um cenário de transmissão de banda dupla.

Fonte – O autor, 2021. Adaptado de Kelly, Cao & Zhu (2016), Jaraut, Rawat & Ghannouchi (2018), Gilabert *et al.* (2019).

eficiência máxima (CRIPPS, 2006; KHAWAM; ALBASHA; MIR, 2016; SHOKAIR *et al.*, 2019). Os PAs podem ser classificados em classes, conforme a topologia aplicada, sendo os PAs classes A e B aqueles que apresentam maior linearidade (RAZAVI; BEHZAD, 1998) e são utilizados para amplificar dados modulados em amplitude e fase.

Idealmente o PA deveria apresentar como característica de transferência o ganho linear até atingir a saturação. Entretanto, os efeitos de não linearidade e memória, provenientes dos componentes que constituem os circuitos, são as duas características que aparecem de forma significativa e comprometem o desempenho do sistema. A não linearidade é mais conhecida por ser uma característica de saturação dos transistores e é efetiva em todo o espectro. Uma das métricas mais utilizadas para mensurá-lá é o ponto de 1 dB de compressão de ganho (OCP1 - do inglês *output compression point*), ponto onde a potência de saída decai em 1 dB da potência esperada extrapolando a região linear de operação, até que seja atingida a potência de saturação ( $P_{sat}$ ) (RAZAVI; BEHZAD, 1998). A figura 2.4 representa graficamente a característica de transferência de um amplificador ideal, do amplificador real e os pontos de OCP1, de  $P_{sat}$  e o ganho, razão entre a potência de saída e a potência de entrada da região linear ( $g$ ). O efeito de memória é característico dos amplificadores em RF. O PA apresenta efeito de memória devido aos elementos armazenadores de energia dos circuitos de casamento de impedâncias e polarização (CRIPPS, 2006). Os efeitos de memória se caracterizam na curva de transferência como um espalhamento e tendem a ficar maiores conforme a largura de banda do sinal transmitido aumenta. Ambos os efeitos causam distorção no sinal.

Outra característica eminente de um PA é o rendimento. É possível demonstrar analiticamente que há uma dependência direta do rendimento com a tensão de saída (RAZAVI; BEHZAD, 1998). Dessa forma, quanto maior a amplitude da tensão de saída, maior o rendimento do PA e, conseqüentemente, para obter máxima eficiência, o PA deve, no limite de amplificação, atingir a potência de saturação. A figura 2.5 ilustra o comportamento típico de rendimento de um PA classe AB (CRIPPS, 2006; REYNAERT; STEYAERT, 2006), que também pode ser verificado nas curvas de desempenho de projetos recentes de amplificadores (ZUREK; CAPPELLO; POPOVIĆ, 2019; FIORELLI *et al.*, 2019; WANG; WU; OKADA, 2018; ESMAEL; ABDALLA; ESHRAH, 2019).

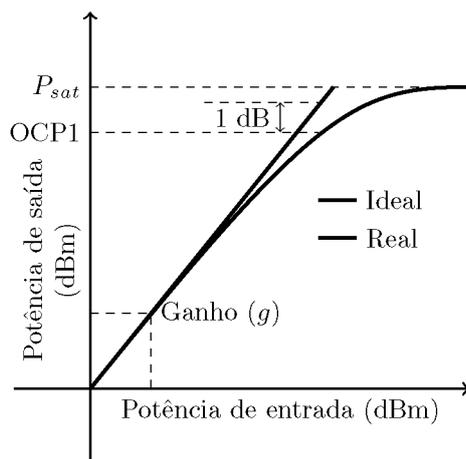


Figura 2.4: Características de operação de um PA desprezando o efeito de memória.  
 Fonte – O autor, 2021. Adaptado de Razavi & Behzad (1998).

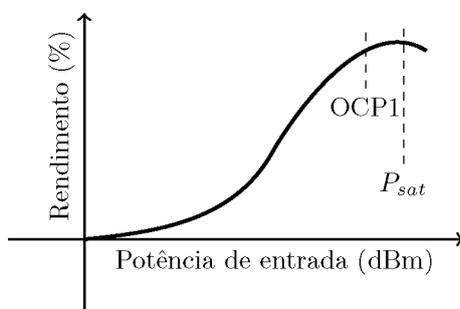


Figura 2.5: Característica de rendimento de um PA em função da potência.  
 Fonte – O autor, 2021. Adaptado de Cripps (2006), Reynaert & Steyaert (2006).

A figura 2.6 mostra a projeção da figura 2.5 na figura 2.4. É possível observar que existe um compromisso entre linearidade e eficiência. A região de maior linearidade, onde a potência de saída é muito menor que a potência de saturação, indica baixo rendimento. Por outro lado, a região de maior eficiência, onde a potência de saída está muito próxima da saturação, gera o maior nível de distorção.

Os PAs classes A e B amplificam sinais modulados em amplitude e fase com certa razão de potência de pico pela potência média (PAPR - do inglês *Peak-to-average power ratio*), logo a potência média de operação do PA é, no melhor dos casos<sup>1</sup>, a potência de saturação menos a PAPR. Se o ponto médio de operação do PA for projetado na curva de eficiência, é perceptível que quanto maior a PAPR, menor será o rendimento. Logo, é fundamental que o PA atue no nível máximo de eficiência (SHOKAIR *et al.*, 2019; YU *et al.*, 2020; ACKERMANN *et al.*, 2020).

Em aplicações de bandas múltiplas, é conveniente que se utilize apenas um único amplificador para todas as frequências, o que permite reduzir o consumo de potência e a área de circuito (GILABERT *et al.*, 2019; LI; HUANG; WANG, 2019). Entretanto, a resposta em frequência dos componentes varia em função da frequência (JORDAO *et al.*, 2020),

<sup>1</sup>Considerando um PA ideal com ganho linear até a potência de saturação.

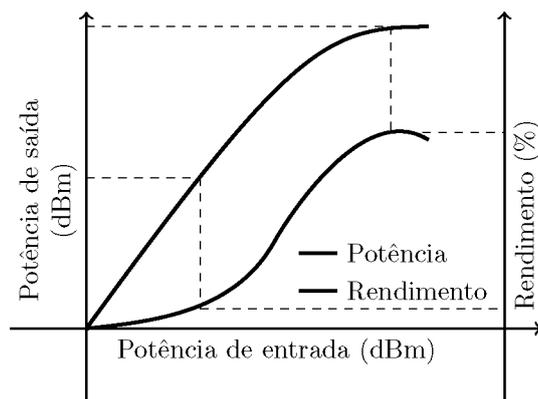


Figura 2.6: Projeção da figura 2.5 na figura 2.4.  
Fonte – O autor, 2021.

logo, além dos comportamentos de não linearidade e eficiência a resposta em frequência de banda larga também dificulta a modelagem, e conseqüentemente a linearização do sistema.

### 2.1.2.1 Efeitos de intermodulação, modulação cruzada, modulação de harmônica e termos fora da banda

O PA apresenta comportamento que relaciona os sinais de entrada (*in*) e saída (*out*) em RF que pode ser representado como uma série de potências ponderada por pesos (*a*)

$$out = \sum_{i=1}^{\infty} a_i in^i. \quad (2.1)$$

Se a entrada for a combinação de dois sinais de amplitudes e frequências constantes, cujas frequências estejam dentro da banda passante, na saída do PA aparecerão componentes de ordem ímpar dentro da banda e componentes dentro e em torno das bandas múltiplas. Os termos que aparecem fora do canal de transmissão, chamados de termos fora da banda, são desprezados porque acabam atenuados pelo próprio PA. Por outro lado, os termos que aparecem em torno da banda não são atenuados e geram os produtos de intermodulação dentro da banda (CRIPPS, 2006). Na prática, os PAs atuam com um sinal modulado em torno de uma portadora central, logo, os produtos entre componentes do próprio sinal modulado geram intermodulações de ordem ímpar dentro do próprio canal de comunicação, o qual apresenta efeito de espalhamento espectral.

Quando o PA está atuando com transmissão em bandas múltiplas concorrentes, além dos produtos de intermodulação dentro da banda, ocorrem produtos entre as bandas, chamados de modulação cruzada. As frequências resultantes destes termos podem situar-se fora da banda de interesse, mas muitas delas situam-se sobre os canais de transmissão

afetando o desempenho de ambos (BASSAM; HELAOUI; GHANNOUCHI, 2011). A figura 2.7b ilustra o efeito causado pelos sinais de entrada da figura 2.7a para uma transmissão em banda dupla concorrente. Na situação apresentada, as portadoras ( $f_{01}$  e  $f_{02}$ ) não são múltiplas.

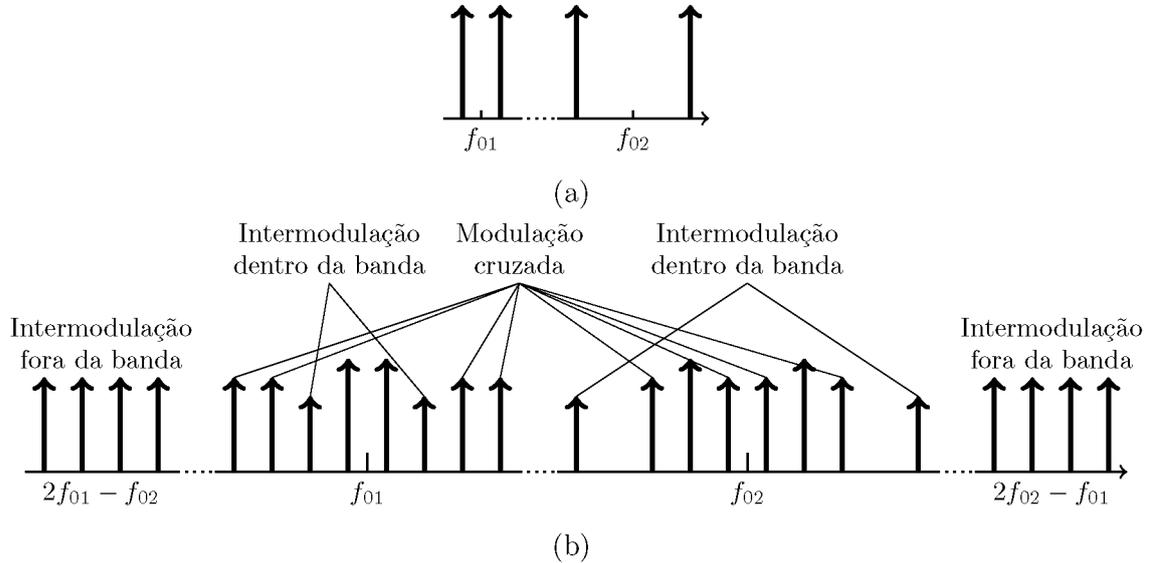


Figura 2.7: Conteúdo espectral causado pelo efeito de intermodulação e modulação cruzada para transmissão de banda dupla concorrente no (a) sinal de entrada do PA (b) no sinal de saída do PA.

Fonte – O autor, 2021. Adaptado de Bassam, Helaoui & Ghannouchi (2011).

Quando as portadoras são múltiplas, além da modulação cruzada dentro da banda, os termos gerados pelos produtos entre as portadoras também situam-se dentro do espectro de interesse. Por exemplo, para uma transmissão de banda dupla concorrente, onde uma portadora é múltipla da outra (RAWAT *et al.*, 2015), o termo quadrático do primeiro canal se sobrepõe com o segundo canal. Tal efeito é chamado de interferência harmônica (JARAUT; RAWAT; GHANNOUCHI, 2018; RAWAT *et al.*, 2015). A figura 2.8 ilustra uma situação de interferência causada por portadoras múltiplas  $f_{c1}$  e  $f_{c2}$ , onde  $f_{c2} = 2f_{c1}$  em um PA de banda larga. O conteúdo espectral em verde é transmitido pelo canal em  $f_{c1}$  e o conteúdo em vermelho é transmitido pelo canal em  $f_{c2}$ , ambos já contêm distorções de interferência dentro da banda e intermodulação cruzada por isso o espectro espalhado. A segunda harmônica de  $f_{c1}$  ( $2f_{c1}$ ) está situada na banda de  $f_{c2}$  representada pelo espectro em azul, enquanto a harmônia  $f_{c2} - f_{c1}$  está situada em  $f_{c1}$ , representada em roxo. Se as portadoras não fossem múltiplas os espectros em roxo e em azul estariam situados fora das bandas de interesse e não atrapalhariam as comunicações em verde e em vermelho.

Até o momento considera-se que o PA apresenta um canal, ou múltiplos canais, de banda limitada e todos os termos fora das bandas de interesse são atenuados. Entretanto, para PAs com banda muito elevada, muitos termos de modulação cruzada ou harmônica situam-se na banda de atuação do PA. Logo estes componentes não são filtrados e inter-

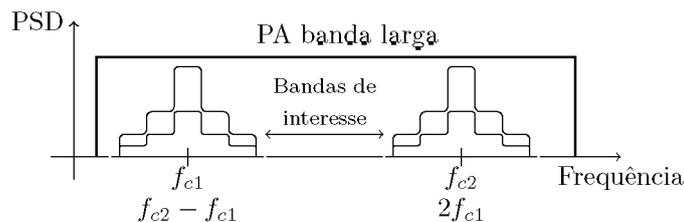


Figura 2.8: Ilustração das interferências harmônicas de portadoras múltiplas para um PA de banda larga.

Fonte – O autor, 2021.

ferem em outras comunicações (PENG; QIU; MU, 2018). A figura 2.9 ilustra o conteúdo espectral de um PA banda larga que abrange múltiplos inteiros da portadora. O canal de transmissão está centrado em  $f_0$  e indicado em vermelho, na figura 2.9 o espalhamento espectral representa as distorções dentro da banda. Os conteúdos em verde são causados pelas harmônicas da portadora e, sendo emitidos, irão interferir em outras comunicações.

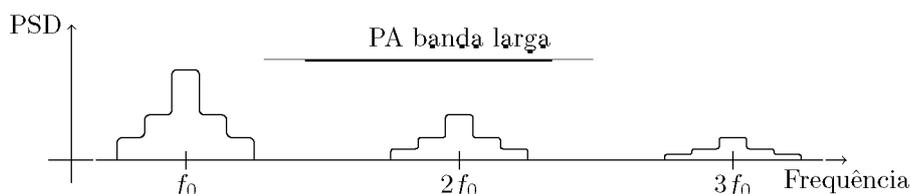


Figura 2.9: Ilustração do conteúdo espectral gerado por harmônicas dentro da banda passante de um PA de banda larga que abrange o espectro dos múltiplos da portadora.

Fonte – O autor, 2021.

### 2.1.3 Teoria sobre a implementação e o desempenho do DPD

O DPD é um sistema digital que implementa um modelo de característica inversa a do PA, e quando conectado em cascata com o PA (vide figura 2.2), permite que o sistema tenha comportamento linear até que o PA atinja a saturação (PRATT; KEARNEY, 2017; DARDAILLON; JABBOUR; SRINI, 2015; ACKERMANN *et al.*, 2020; GILABERT *et al.*, 2019). Para compreender melhor esse comportamento, a figura 2.10 apresenta a cascata equivalente em banda base com as características de transferência de cada componente e do sistema, onde  $x(n)$ ,  $x'(n)$  e  $y(n)$  indicam os sinais na entrada do DPD, entrada do PA e saída do PA, respectivamente. O PA apresenta distorções de não linearidade e memória, as quais podem ser representadas por uma função não linear  $F[x']$ , enquanto o DPD apresenta a característica inversa  $G[x]$ . Considerando que o ganho do PA é igual a um ( $g = 1$ ) se  $G[x] = F^{-1}[x]$  então  $y = F[G[x]] = x$ , ou seja, dentro da faixa de atuação do DPD, o sistema apresenta uma resposta linear de ganho unitário.

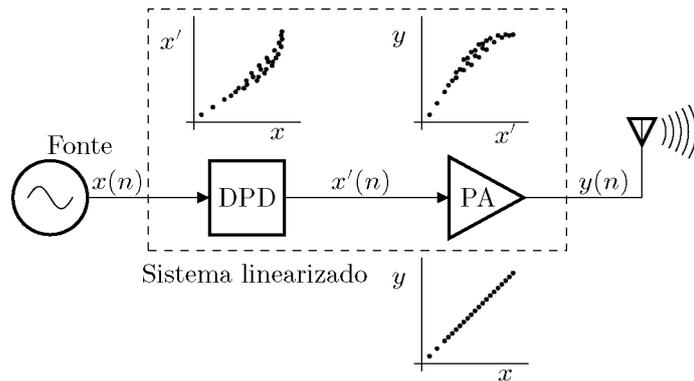


Figura 2.10: Conexão em cascata do DPD e do PA apresentando as características de distorção de cada bloco e da cascata.

Fonte – O autor, 2021.

### 2.1.3.1 Sinais em RF e sinais em Banda Base

O PA transmite um sinal modulado em RF que pode ser descrito no domínio do tempo contínuo ( $t$ ) como (PENG; QIU; MU, 2018)

$$s(t) = \text{Re}\{r(t)e^{j(2\pi f_0 t + \theta(t) + \phi)}\}, \quad (2.2)$$

onde  $s(t)$  é o sinal em RF,  $f_0$  e  $\phi$  são a portadora e a fase aleatória e constante do oscilador, respectivamente,  $r(t)$  e  $\theta(t)$  representam a amplitude e fase da envoltória complexa  $x(t)$ :

$$x(t) = r(t)e^{j\theta(t)}. \quad (2.3)$$

Enquanto o sinal em banda passante  $s(t)$  varia na ordem de GHz, a envoltória complexa  $x(t)$  varia em função da informação em banda base, na ordem de MHz. Se a portadora  $f_0$  e a fase  $\phi$  são constantes, então o comportamento dinâmico do PA depende apenas da envoltória complexa da entrada  $x(t)$  e da envoltória complexa da saída  $y(t)$ . Logo, o comportamento do PA pode ser descrito por um modelo equivalente em banda base em tempo discreto  $n$ , amostrado em uma taxa constante ( $f_s$ ) que obedece ao menos 5 vezes a largura de banda do sinal em banda base (GILABERT *et al.*, 2019; SHOKAIR *et al.*, 2019; YU *et al.*, 2020). Lembrando que em banda base não há simetria entre os espectros positivo e negativo, logo toda a largura de banda possui informação relevante, consequentemente, a frequência máxima é igual a metade da largura de banda e o critério de Nyquist é respeitado se a taxa de amostragem for igual a largura de banda. Dessa forma, a frequência máxima da quinta harmônica contém até 2,5 vezes a largura de banda do canal e pode ser representada adequadamente com  $f_s$  igual a 5 vezes a largura de banda do canal.

Quando se trata de comunicação de bandas múltiplas concorrentes, (2.2) pode ser reescrita como uma combinação de envoltórias complexas moduladas pelas respectivas

portadoras

$$s(t) = \text{Re}\{x_1(t)e^{j(2\pi f_1 t + \phi_1)} + x_2(t)e^{j(2\pi f_2 t + \phi_2)}\}, \quad (2.4)$$

onde  $\phi_1$  e  $\phi_2$  são fases aleatórias das portadoras 1 e 2, respectivamente. Idealmente, a saída deveria conter o mesmo conteúdo de entrada, exceto por um ganho linear. Entretanto, com os efeitos de intermodulação e modulação cruzada, cada envoltória de saída contém a contribuição de todas as entradas deslocadas em torno da portadora analisada. Em uma comunicação de banda dupla, onde  $x_1$  e  $x_2$  são as entradas das bandas 1 e 2, e  $y_1$  e  $y_2$  as saídas das bandas 1 e 2, respectivamente, para modelar  $y_1$ , deve-se utilizar a entrada  $x_1$  na própria banda e a entrada  $x_2$  deslocada em torno da banda do canal 1, idem para o canal 2, mas deslocando  $x_1$  em torno de  $x_2$ . Ou seja,  $y_1 = F(x_1, x_2 @ f_1)$  e  $y_2 = F(x_2, x_1 @ f_2)$ , onde  $x_2 @ f_1$  indica a entrada do canal 2 deslocado para o canal 1 e  $x_1 @ f_2$  indica a entrada do canal 1 deslocado para o canal 2. A forma normalmente aplicada nos modelos da literatura para o deslocamento entre as bandas é primeiro realizar o deslocamento para a frequência zero, aplicando o módulo ou a diferença de fases, e posteriormente deslocar para a banda desejada multiplicando pela fase do canal principal. O procedimento aplicado na banda tripla é idêntico, mas considerando três entradas (ACKERMANN *et al.*, 2020; GILABERT *et al.*, 2019; KELLY; CAO; ZHU, 2016; JARAUT; RAWAT; GHANNOUCHI, 2018). A figura 2.7b apresenta componentes de intermodulação (em azul) situadas fora da banda de interesse. Essas componentes são geradas por produtos complexos envolvendo  $x_1$ ,  $x_2$  ou o complexo conjugado (\*). Por exemplo, se  $x_1^*$  está na portadora  $-f_1$  e  $x_2$  na portadora  $f_2$ , então a resultante de  $x_1^* x_2$  estará em  $(f_2 - f_1)$ . Ou seja, se as portadoras não são múltiplas entre si, então os produtos resultantes não estarão nas bandas de interesse. Por outro lado, se as portadoras são múltiplas, algumas ocorrências podem estar situadas nas bandas de interesse. Para o exemplo apresentado se  $f_2 = 2f_1$ , a resultante  $f_2 - f_1 = f_1$ . Conseqüentemente, na modulação de portadoras múltiplas, além das interferências de intermodulação cruzada, outras componentes não filtradas precisam ser modeladas e compensadas (JARAUT; RAWAT; GHANNOUCHI, 2018). Neste caso, o DPD deve ser capaz de eliminar essas interferências implementando os produtos harmônicos.

Os efeitos apresentados até o momento consideram componentes que estejam nas bandas de interesse de uma comunicação concorrente. Se esses efeitos forem compensados adequadamente pela pré-distorção que os trate corretamente não existe garantia alguma que efeitos fora das bandas de interesse tenham sido compensados automaticamente. Nesses casos, quando tratamos de PAs com bandas muito elevadas, aplicar filtros analógicos e adaptativos com a frequência é impraticável devido à reconfigurabilidade e o nível de potência. Nessa situação, modelar adequadamente todo o espectro torna-se desafiador devido à frequência de amostragem necessária (PENG; QIU; MU, 2018). Todo o conteúdo espectral emitido mas que não é útil para as transmissões desejadas influenciam negativa-

mente no desempenho do PA. Se esses componentes não existirem toda potência de saída útil do PA estará sendo aplicada para a banda de interesse.

### 2.1.3.2 Procedimentos em tempo-real e de extração de parâmetros do DPD

A atuação da pré-distorção pode ser dividida em atuação em tempo-real e de extração de parâmetros. A atuação em tempo-real está diretamente ligada ao custo necessário, em termos de tempo e potência, para pré-distorcer uma amostra de entrada. Se o sinal em banda base possui frequência de amostragem  $f_s$ , então a cada  $1/f_s$  segundos, uma amostra deve ser distorcida, ou em outras palavras, no prazo de  $1/f_s$  segundos, a função  $F^{-1}[x]$  deve ser executada para uma amostra  $x$ . Por outro lado, a extração de parâmetros é um procedimento executado uma única vez, ou poucas vezes, e não é uma atuação em tempo-real. A extração implementa funções complexas para a solução de sistemas, algoritmos e otimização. Contudo, apesar da complexidade na extração, o tempo para que um algoritmo seja executado não é crítico como o tempo para realizar a pré-distorção.

### 2.1.3.3 A relação com o desempenho do DPD

O desempenho do DPD está associado ao consumo de potência e à capacidade de linearização, o que demanda uma relação de custo-benefício. A capacidade de linearização está ligada à acurácia do modelo, ao algoritmo de extração e ao método de extração dos parâmetros, enquanto o consumo de potência está ligado ao número de operações básicas necessárias para distorção de uma amostra. O custo para a distorção é dependente do número de parâmetros do modelo, e é natural que modelos com maior acurácia implementem algoritmos mais complexos para extração de parâmetros e contêm mais parâmetros (TEHRANI *et al.*, 2010; SCHUARTZ *et al.*, 2019). Para garantir alto desempenho, um modelo preciso e de poucos parâmetros é desejável.

Modelos para o PA ou para o DPD implementam funções não lineares. Tais funções podem ser implementadas por tabelas de busca (LUTs - do inglês *look-up tables*) com interpolação linear. Por exemplo para  $y = h_1x^3 + h_2\log(x)$ , onde  $h_1$  e  $h_2$  são parâmetros ajustáveis,  $x^3$  e  $\log(x)$  podem ser substituídos por duas LUTs, havendo apenas a necessidade de multiplicar a saída de cada LUT pelo respectivo parâmetro e somar as resultantes. Consequentemente, o gargalo é associado ao montante de parâmetros, quanto mais parâmetros maior o número de operações básicas e maior o consumo de potência. Para o exemplo apresentado, se dentro do domínio de  $x$  apenas o termo  $x^3$  é significativo,  $\log(x)$  e  $h_2$  podem ser desprezados reduzindo o número de multiplicações pela metade e zerando o número de somas. Este processo de redução do número de parâmetros dos

modelos para PA e DPD podem ser executados por algoritmos propostos na literatura, como a análise dos componentes principais (GILABERT *et al.*, 2013), os mínimos quadrados ortogonais (CHEN; COWAN; GRANT, 1991), o Ascendente (SCHUARTZ *et al.*, 2019), entre outros. Entretanto, os algoritmos de redução de coeficientes não necessariamente reduzem o montante de operações aritméticas quando exigem mudança de base (SCHUARTZ *et al.*, 2019) e ainda assim dependem da acurácia do modelo completo para obter resultados bons. É conveniente que se utilize modelos de alta acurácia e poucos parâmetros.

## 2.2 Modelos polinomiais para o PA e para o DPD

Modelos polinomiais com base nas séries de Volterra possuem como principais características a acurácia elevada, a linearidade em seus parâmetros e o aumento significativo no número de parâmetros (MATHEWS; SICURANZA, 2000). Abaixo seguem os principais modelos presentes na literatura para banda única (1D), banda dupla concorrente (2D) e banda tripla concorrente (3D).

### 2.2.1 Modelos 1D

O polinômio de memória unidimensional (MP - do inglês *memory polynomial*) é amplamente difundido na literatura para modelagem do PA e implementação do DPD, e possui a equação constitutiva (KIM; KONSTANTINOU, 2001):

$$y(n) = \sum_{p=1}^P \sum_{m=0}^M h_{p,m} x(n-m) |x(n-m)|^{p-1}, \quad (2.5)$$

onde  $M$  é o fator de truncamento de comprimento de memória,  $P$  é o fator de truncamento de não linearidade,  $x$  é a entrada,  $y$  é a saída,  $n$  é o instante da amostra considerada e  $h$  o coeficiente. O MP considera apenas as componentes unidimensionais, ou seja, cada termo do somatório é composto por apenas um instante de tempo. Outras abordagens que incluem termos bidimensionais, como o polinômio de memória generalizado (MORGAN *et al.*, 2006) e o polinômio de memória avançado (BONFIM; LIMA, 2015) apresentam maior acurácia, em contrapartida o número de coeficientes aumenta consideravelmente com os fatores.

### 2.2.2 Modelos 2D

Modelos de banda dupla concorrente são aptos a modelar interferências dentro da banda e termos de modulação cruzada. Para o polinômio de memória de banda dupla concorrente (2D-MP) os canais 1 e 2 são descritos por (BASSAM; HELAOUI; GHANNOUCHI, 2011)

$$y_1(n) = \sum_{m=0}^M \sum_{k=0}^P \sum_{j=0}^k h_{k,j,m}^{(1)} x_1(n-m) |x_1(n-m)|^{k-j} |x_2(n-m)|^j, \quad (2.6)$$

e

$$y_2(n) = \sum_{m=0}^M \sum_{k=0}^P \sum_{j=0}^k h_{k,j,m}^{(2)} x_2(n-m) |x_1(n-m)|^{k-j} |x_2(n-m)|^j, \quad (2.7)$$

respectivamente, onde  $P$  é o fator de truncamento de não linearidade,  $M$  é o fator de truncamento do comprimento de memória,  $x_1$  e  $x_2$  são as entradas dos canais 1 e 2, respectivamente, e  $h$  o coeficiente. Cada saída é dependente de ambas as entradas e o mesmo fator de truncamento é utilizado para as interferências dentro da banda e interferências cruzadas. Em Bassam, Helaoui & Ghannouchi (2011) o limite do primeiro somatório é  $M - 1$ , em (2.6) e (2.7) o limite do primeiro somatório foi alterado para  $M$  para manter coerência na comparação com os demais modelos.

Buscando manter maior acurácia com menos parâmetros, o polinômio de memória de banda dupla melhorado (2D-IMP - do inglês *improved memory polynomial*) acrescenta o fator de truncamento  $Q$ , logo cada saída é descrita por (RIBA; LIMA, 2016):

$$y_1(n) = \sum_{p=0}^{P-1} \sum_{m=0}^M h_{p,m}^{(1)} x_1(n-m) |x_1(n-m)|^p + \sum_{q=0}^{Q-1} \sum_{p=1}^{P-1} \sum_{m=0}^M h_{q,p,m}^{(1)} x_1(n-m) |x_1(n-m)|^q |x_2(n-m)|^p, \quad (2.8)$$

e

$$y_2(n) = \sum_{p=0}^{P-1} \sum_{m=0}^M h_{p,m}^{(2)} x_2(n-m) |x_2(n-m)|^p + \sum_{q=0}^{Q-1} \sum_{p=1}^{P-1} \sum_{m=0}^M h_{q,p,m}^{(2)} x_2(n-m) |x_2(n-m)|^q |x_1(n-m)|^p. \quad (2.9)$$

O modelo 2D-IMP contém os mesmos termos do 2D-MP, mas a possibilidade de manter mais combinações possíveis permite que o 2D-IMP apresente melhor desempenho. Uma condição adicional pode ser incluída no segundo somatório do segundo termo do 2D-IMP onde  $q + p < P$ . Se a condição for inserida e  $Q$  for igual a  $P + 1$ , então o 2D-MP

torna-se um caso particular do 2D-IMP (RIBA; LIMA, 2016).

### 2.2.3 Modelos 3D

Na modelagem de banda tripla concorrente, cada saída é descrita pelos termos de intermodulação dentro da banda e pelos produtos de modulação cruzada entre os três canais concorrentes. Logo, a saída de cada canal possui a contribuição das entradas dos três canais deslocados para a banda do respectivo canal principal. O modelo MP é estendido para 3D, logo o polinômio de memória de banda tripla (3D-MP) possui a seguinte equação construtiva (YOUNES *et al.*, 2013b):

$$y_i(n) = \sum_{m=0}^M \sum_{p=0}^{P-1} \sum_{a=0}^p \sum_{b=0}^a h_{m,p,a,b}^{(i)} x_i(n-m) |x_i(n-m)|^{p-a} |x_j(n-m)|^{a-b} |x_k(n-m)|^b, \quad (2.10)$$

onde  $i$ ,  $j$  e  $k$  são os canais 1, 2 e 3, respectivamente,  $P$  é fator de truncamento de não linearidade e  $M$  o comprimento de memória. A modelagem dos canais 2 e 3 é obtida invertendo  $i$  com  $j$  e  $i$  com  $k$ . O limite do primeiro somatório foi modificado de  $M - 1$  para  $M$  em relação ao modelo original (YOUNES *et al.*, 2013b) para manter coerência com os demais modelos.

O 3D-MP apresenta apenas dois fatores de truncamento, sendo  $P$  o mesmo fator de truncamento para os termos de intermodulação e para os termos de modulação cruzada. Em (KWAN *et al.*, 2017) um modelo para bandas múltiplas foi desenvolvido e se diferencia do 3D-MP pela separação dos termos com e sem memória e a inclusão de fatores de truncamento distintos. O modelo de bandas múltiplas para banda tripla (3D-MB - do inglês *multi-band*) possui a equação construtiva (KWAN *et al.*, 2017):

$$\begin{aligned} y_i(n) = & \sum_{p_1=0}^{P_1} \sum_{p_2=0}^{P_1-p_1} \sum_{p_3=0}^{P_1-(p_1+p_2)} \sum_{m=1}^{M_1} h_{1,p_1,p_2,p_3,m}^{(i)} x_i(n-m) |x_1(n-m)|^{p_1} \\ & |x_2(n-m)|^{p_2} |x_3(n-m)|^{p_3} + \sum_{p_1=0}^{P_2} \sum_{p_2=0}^{P_2-p_1} \sum_{p_3=0}^{P_2-(p_1+p_2)} h_{2,p_1,p_2,p_3}^{(i)} x_i(n) |x_1(n)|^{p_1} \\ & |x_2(n)|^{p_2} |x_3(n)|^{p_3} + \sum_{p_1=0}^{P_3} \sum_{p_2=0}^{P_3-p_1} \sum_{p_3=0}^{P_3-(p_1+p_2)} \sum_{m=1}^{M_2} h_{3,p_1,p_2,p_3,m}^{(i)} x_i^2(n) x_i^*(n-m) \\ & |x_1(n)|^{p_1} |x_2(n)|^{p_2} |x_3(n)|^{p_3}, \quad (2.11) \end{aligned}$$

onde  $x_1$ ,  $x_2$  e  $x_3$  são as entradas dos canais 1, 2 e 3, respectivamente, o índice  $i$  indica a banda atual,  $h$  o coeficiente,  $M_1$  e  $M_2$  indicam o comprimento de memória,  $P_1$ ,  $P_2$ , e  $P_3$  o grau de não linearidade e  $(.)^*$  o complexo conjugado.

Outros modelos para modelagem de banda tripla concorrente são abordados na literatura, como é o caso do Volterra de fase alinhada de banda tripla (3D-PAV - do inglês *phase-aligned pruned Volterra*) (YOUNES *et al.*, 2013a), redução de desvio dinâmico de banda tripla (3D-DDR - do inglês *dynamic deviation reduction*) (TIAN *et al.*, 2015), polinômio de memória generalizado de banda tripla (3D-GMP - do inglês *generalized memory polynomial*), polinômio de memória generalizado modificado de banda tripla (3D-MGMP - do inglês *modified generalized memory polynomial*) e polinômio de memória generalizado de complexidade reduzida de banda tripla (3D-CR-MGMP - do inglês *complexity-reduced generalized memory polynomial*) (MKADEM; ISLAM; BOUMAIZA, 2016).

### 2.2.3.1 Modelo 3D para portadoras múltiplas

Os modelos apresentados até o momento consideravam apenas as interferências causadas pelos termos de intermodulação e modulação cruzada. Ou seja, todos os termos eram produtos de amplitude dos canais, por exemplo  $|x_1||x_2||x_3|$  cujas frequências são nulas pelo uso do módulo, e deslocados para a banda da entrada  $x_i$  que carrega o termo de fase. Estas operações não são hábeis a modelar interferências harmônicas entre as portadoras, cujas frequências resultantes de dois termos complexos situam-se dentro de algum dos canais e não podem ser filtrados (JARAUT; RAWAT; GHANNOUCHI, 2018).

Jaraut, Rawat & Ghannouchi (2018) propuseram a inclusão dos termos harmônicos que resultam nos canais transmitidos para o modelo 3D-MP. O polinômio de memória tri-dimensional harmônico (3D-HMP - do inglês *harmonically memory polynomial*) replica o 3D-MP com todos os termos da tabela 2.1, três réplicas são idênticas ao 3D-MP enquanto outras doze incluem termos harmônicos. Esse modelo só é válido se as portadoras forem múltiplas entre si, ou seja  $f_{c2} = 2f_{c1}$  e  $f_{c3} = 3f_{c1}$ , onde  $f_{c1}$ ,  $f_{c2}$  e  $f_{c3}$  são as portadoras dos canais 1, 2 e 3, respectivamente. Cada réplica do 3D-MP substitui a variável complexa pelos produtos harmônicos, por exemplo, a primeira réplica substitui  $x_1(n)$  por  $x_3(n)x_1^{*2}(n)$ , cuja resultante está centrada na frequência de  $x_1(n)$ .

Tabela 2.1: Produtos harmônicos resultantes para os canais 1, 2 e 3 do 3D-HMP.

| Canal 1             | Canal 2                | Canal 3            |
|---------------------|------------------------|--------------------|
| $x_1(n)$            | $x_2(n)$               | $x_3(n)$           |
| $x_3(n)x_1^{*2}(n)$ | $x_3(n)x_1^*(n)$       | $x_1(n)x_2(n)$     |
| $x_2(n)x_1^*(n)$    | $x_3^2(n)x_2^{*2}(n)$  | $x_2^2(n)x_1^*(n)$ |
| $x_3(n)x_2^*(n)$    | $x_1^2(n)$             | $x_1^3(n)$         |
| $x_2^2(n)x_3^*(n)$  | $x_1(n)x_3(n)x_2^*(n)$ | $x_2^3(n)x_3^*(n)$ |

Fonte – Jaraut, Rawat & Ghannouchi (2018).

Cada coluna da tabela 2.1 contém a informação harmônica cuja resultante está centrada na portadora do respectivo canal principal, logo uma representação gráfica de

todos os termos da tabela conteria apenas 3 componentes, onde cada componente é a composição da fundamental mais 4 harmônicas. Tomando como exemplo os 3 primeiros termos da primeira coluna,  $x_1(n)$  possui componente fundamental centrada em  $f_1$ ,  $x_3(n)x_1^{*2}(n)$  possui componente resultante centrada em  $f_1 = f_3 - 2f_1$  e  $x_2(n)x_1^*(n)$  possui componente resultante centrada em  $f_1 = f_2 - f_1$ , ou seja, todos os termos estão situados em  $f_1$  e interferem no canal de portadora  $f_1$ . Da mesma forma, as resultantes da segunda coluna estão em  $f_2$  e as resultantes da terceira coluna estão em  $f_3$ .

### 2.3 Visão geral sobre redes neurais para 1D e 2D

Redes neurais artificiais buscam reproduzir a formação neural humana e aplicam-se a diversos sistemas. Dentro das abordagens existentes, a rede neural *feedforward* ou perceptron, é uma estrutura em camadas conectadas por pesos, que possui a capacidade de representar funções de comportamento contínuo (OJHA; ABRAHAM; SNÁŠEL, 2017).

A estrutura *feedforward* de três camadas, ou perceptron de três camadas (TLP - do inglês *three layer perceptron*), possui uma camada de entrada, uma camada escondida e uma camada de saída, conectadas entre si por pesos. Há a possibilidade de incluir entradas constantes (*bias*) e o número de neurônios é variável (OJHA; ABRAHAM; SNÁŠEL, 2017). Configurações distintas podem ser feitas com a estrutura TLP na modelagem de PAs modificando a combinação das entradas, a função de ativação, o uso de uma única rede de valores complexos ou duas redes de valores reais, e o uso de *bias*. A figura 2.11 apresenta uma rede TLP aplicável para modelagem de PAs, as entradas e saídas são conectadas aos neurônios por meio de pesos, adicionalmente, podem ser incluídos os *bias*.  $F[.]$  indica a função de ativação da camada escondida e é a responsável por fornecer a não linearidade da rede. Os parâmetros ajustáveis das redes são os pesos e *bias*, cuja quantidade é diretamente dependente das combinações de entradas e podem ser alteradas conforme o tamanho de memória considerada, a remoção de *bias* e o número de neurônios da camada escondida. Na modelagem de PAs os fatores ajustáveis e que definem a quantidade de parâmetros são a memória ( $M$ ) e o número de neurônios ( $R$ ) da camada escondida.

Em Freire *et al.* (2020) foi demonstrado que a rede neural de valores complexos sem o uso de *bias* e com a função de ativação

$$F = \{\text{tansig}[|x(n)|]\} \exp[j\angle x(n)], \quad (2.12)$$

onde  $x(n)$  é uma entrada contendo componentes em fase e em quadratura, apresenta o melhor resultado em relação ao número de parâmetros.

As Redes Neurais e os modelos polinomiais são comparados em Pedro & Maas (2005). Entre as principais vantagens das redes neurais, estão o desempenho com poucos parâmetros e a possibilidade de configurações flexíveis, entretanto, a aprendizagem é um

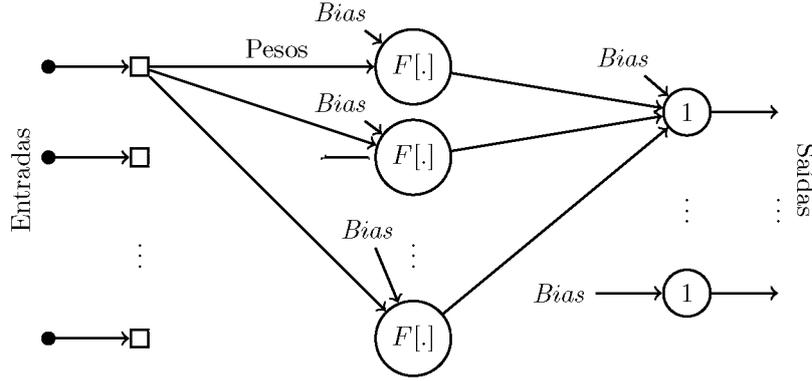


Figura 2.11: Rede TLP aplicável para modelagem de PAs.  
 Fonte – O autor, 2021. Adaptado de Ojha, Abraham & Snášel (2017).

dos fatores críticos porque tende a ser mais onerosa em consumo de tempo e potência e tem uma susceptibilidade maior para mínimos locais, principalmente se forem aplicados métodos genéricos de otimização.

No que se refere à modelagem 1D, uma rede neural de valores complexos estima a saída em função de uma combinação das entradas complexas dos instantes  $n$  a  $n - M$ . Para modelagem 2D, duas redes complexas (TLP1 e TLP2) estimam cada uma das saídas modelando as intermodulações dentro da banda e produtos de modulação cruzada utilizando as informações de ambos os canais conforme a figura 2.12.

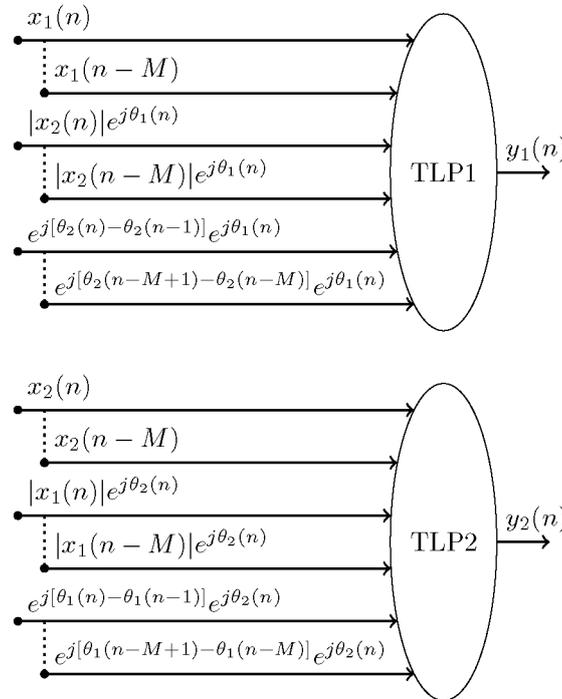


Figura 2.12: Configuração de duas redes TLP para modelagem 2D.  
 Fonte – O autor, 2021.

Cada saída complexa é dependente das entradas dos dois canais, as entradas do

canal principal são aplicadas diretamente na rede, enquanto as entradas do canal concorrente primeiro são deslocadas para a frequência zero por meio das funções módulo e diferença de fase, e então deslocadas para a frequência do canal modelado pela multiplicação da exponencial complexa cujo argumento contém a frequência do canal modelado. A descrição apresentada para 2D também pode ser estendida para 3D.

## 2.4 A extração e a escolha de parâmetros, e os métodos de aprendizagem

Os modelos descritos nas Seções 2.2 e 2.3 são aplicados para a modelagem do PA e implementação do DPD. Na modelagem direta a entrada do modelo é igual a entrada do PA e a saída desejada do modelo é a saída do PA, já na modelagem inversa, a entrada do modelo é a saída do PA, e a saída estimada é a entrada do PA. No que se refere à acurácia do modelo, basta implementar a modelagem direta ou inversa com um algoritmo de extração de parâmetros, por outro lado, se tratando do desempenho de linearização, a variação da resposta do PA com a pré-distorção precisa ser levada em consideração durante a extração de parâmetros para o DPD. Dessa forma, na sequência estão apresentados os algoritmos de extração linear e não linear dos parâmetros, o algoritmo Ascendente para a redução do número de parâmetros, e as aprendizagens direta e indireta para a compensação dinâmica do PA com a pré-distorção.

### 2.4.1 Métodos de extração linear

Os modelos polinomiais apresentados na Seção 2.2 possuem equações lineares em seus parâmetros (MATHEWS; SICURANZA, 2000). Tomando o MP em (2.5) como exemplo e fazendo  $M = 1$  e  $P = 2$ , a saída do instante  $n$  é expressa por

$$y(n) = h_{1,0}x(n)|x(n)|^0 + h_{1,1}x(n-1)|x(n-1)|^0 + h_{2,0}x(n)|x(n)|^1 + h_{2,1}x(n-1)|x(n-1)|^1, \quad (2.13)$$

essa mesma operação pode ser expressa por um produto interno entre dois vetores da forma

$$y(n) = \mathbf{x}(n)\mathbf{h}, \quad (2.14)$$

onde

$$\mathbf{x}(n) = [ x(n)|x(n)|^0 \quad x(n-1)|x(n-1)|^0 \quad x(n)|x(n)|^1 \quad x(n-1)|x(n-1)|^1 ] \quad (2.15)$$

e

$$\mathbf{h} = [ h_{1,0} \quad h_{1,1} \quad h_{2,0} \quad h_{2,1} ]^T, \quad (2.16)$$

onde  $(.)^T$  indica o vetor transposto. Para  $N$  amostras de entradas e saídas, o vetor de saídas pode ser expresso por uma operação linear da forma

$$\mathbf{y} = \mathbf{X}\mathbf{h}, \quad (2.17)$$

onde  $\mathbf{X}$  é uma matriz contendo  $N$  vetores  $\mathbf{x}(n)$  e  $\mathbf{y}$  é o vetor coluna contendo as  $N$  amostras  $y(n)$ . A representação vetorial de (2.14) aplicado ao MP é aplicável aos outros modelos polinomiais, onde os modelos 2D possuem 2 equações e os modelos 3D possuem 3 equações, uma para cada canal.

O vetor de coeficientes ( $\mathbf{h}$ ) é obtido pela extração de parâmetros e os métodos de extração linear podem ser aplicados. Os mínimos quadrados (LS - do inglês *least squares*) são um método que permite obter a melhor aproximação por meio da inversa do sistema conforme (MATHEWS; SICURANZA, 2000):

$$\mathbf{h} = (\mathbf{X}^*\mathbf{X})^{-1}\mathbf{X}^*\mathbf{y}, \quad (2.18)$$

onde  $(.)^*$  indica o complexo conjugado da matriz transposta. LS garante a melhor aproximação mas possui como principais pontos negativos a sensibilidade ao ruído (SHOKAIR *et al.*, 2019) e a necessidade de obter a matriz inversa. Outras abordagens como mínimos quadrados médio e mínimos quadrados recursivo permitem extrair os parâmetros sem a necessidade de calcular a matriz inversa, mas por outro lado dependem da especificação de valores constantes e da estimativa inicial (MATHEWS; SICURANZA, 2000). Nesta pesquisa, LS é adotado como o método de extração linear de parâmetros.

## 2.4.2 Métodos de extração não linear

Os métodos de extração não linear de parâmetros são aplicados nas situações onde o vetor de saídas  $\mathbf{y}$  não pode ser obtido ou quando não há linearidade entre os parâmetros, como é o caso das redes neurais TLP da Seção 2.3. Também podem ser aplicados para melhorar a acurácia (ajuste fino) de um método de extração linear aplicado nos modelos lineares da Seção 2.2.

Os métodos não lineares fazem o ajuste das variáveis otimizáveis que produzem um valor mínimo global ou local de uma função objetivo previamente definida. Na modelagem de PAs é desejável que o modelo seja capaz de produzir o mesmo comportamento do circuito, logo, uma das possíveis definições da função objetivo é a diferença entre as saídas estimada e desejada, cujas variáveis otimizáveis são os parâmetros do modelo. Por um lado, os métodos não lineares permitem definições distintas dos parâmetros ajustáveis

e da função objetivo. Conseqüentemente, podem ser aplicados nos modelos lineares e não lineares. Por outro lado, durante a extração de parâmetros os métodos iterativos consomem mais potência do que os métodos lineares (MANYAM *et al.*, 2018), dependem de uma estimativa inicial adequada e são susceptíveis aos mínimos locais. Entretanto, a possibilidade de melhorar o desempenho em acurácia do modelo e/ou de aplicar modelos mais simples, justificam a aplicação de métodos de treinamentos complexos.

Na modelagem de PAs, o erro a ser minimizado contém informações de fase e amplitude, e as funções objetivo em termos do erro são definidas por (MATLAB, 2020)

$$\mathbf{f}_O = |\mathbf{e}|^2 \quad (2.19)$$

e

$$f_O = \frac{1}{N} \sum_{n=1}^N |e(n)|^2, \quad (2.20)$$

onde  $\mathbf{e}$  é um vetor de  $N$  amostras de erro,  $\mathbf{f}_O$  é um vetor da função objetivo,  $e(n)$  é a amostra de erro e  $f_O$  é a função objetivo escalar. As funções objetivo são utilizadas pelas funções *lsqnonlin* e *fminunc* do *software* Matlab e implementam os algoritmos de otimização, respectivamente.

Os algoritmos padrões implementados pelas funções *lsqnonlin* e *fminunc* são *trust-region-reflective* (COLEMAN; LI, 1996, 1994) e *quasi-Newton* (BROYDEN, 1970; FLETCHER, 1970; SHANNO, 1970), respectivamente. Ambos são métodos iterativos que partem de uma estimativa inicial, atualizam as variáveis de busca com base no gradiente da função objetivo e são sensíveis a mínimos locais.

Redes neurais também podem ser otimizadas por algoritmos específicos implementados no Matlab como o *backpropagation* ou algoritmos meta-heurísticos com base nos comportamentos naturais, como o desenvolvimento genético (OJHA; ABRAHAM; SNÁŠEL, 2017). O objetivo desse trabalho é de utilizar as redes neurais como um estudo de caso aplicando os algoritmos de aprendizado para valores complexos, tanto em redes neurais quanto em modelos polinomiais. Dessa forma, apesar da existência de abordagens específicas para redes neurais ou desafios específicos de implementação de otimizadores em circuitos dedicados, é optado por utilizar algoritmos genéricos de otimização implementados pelas funções do *software* Matlab.

### 2.4.3 Escolha dos parâmetros significativos dos modelos polinomiais com abordagem Ascendente

Modelos polinomiais aumentam o número de coeficientes de forma acelerada com o aumento dos fatores de não linearidade e memória (Seção 2.2). Por outro lado, o desem-

penho do DPD pode ser comprometido com o número de operações básicas (Seção 2.1.3.3) e, conforme pode ser verificado em (2.14), cada amostra  $y(n)$  é gerada pela multiplicação do vetor de coeficientes  $\mathbf{h}$  pelas entradas  $\mathbf{x}(n)$ . A combinação das entradas pode ser desenvolvida com tabelas de busca, entretanto a multiplicação pelos parâmetros depende da multiplicação por  $\mathbf{h}$ , logo, quanto menor o vetor  $\mathbf{h}$ , menor será o consumo de potência do DPD.

Modelos polinomiais, em geral, apresentam acurácia satisfatória com quantidade elevada de parâmetros, em torno de algumas centenas. Reduzir esse número de parâmetros é desejável. Métodos consolidados na literatura como a análise dos componentes principais (GILABERT *et al.*, 2013), mínimos quadrados ortogonal (CHEN; COWAN; GRANT, 1991; SCHUARTZ; LIMA, 2016) entre outros permitem reduzir o número de parâmetros mas exigem mudança de base dos modelos<sup>2</sup>, e esta conversão pode tornar o sistema em tempo real mais complexo porque a cada nova amostra a ser distorcida, uma mudança de base precisa ser executada primeiro. Em Schuartz *et al.* (2019) foi desenvolvido o algoritmo Ascendente que entre todos os coeficientes do vetor  $\mathbf{h}$ , escolhe os mais significativos, desprezando os demais e permitindo reduzir o número de parâmetros sem a necessidade de mudança de base.

O algoritmo Ascendente, representado na figura 2.13, faz a redução conforme segue (SCHUARTZ *et al.*, 2019). Sendo  $Q_H$  o número total de parâmetros e  $R_H$  o número desejado de parâmetros,  $R_H$  iterações precisam ser executadas para se escolher os  $R_H$  parâmetros mais significativos. A cada iteração um novo parâmetro é eleito como o mais significativo. Seja  $r$  a iteração atual onde  $r = 1, 2, 3 \dots R_H$ . Na iteração  $r$ , já são conhecidos  $r - 1$  parâmetros mais significativos, e o  $r$ -ésimo parâmetro mais significativo será selecionado entre os  $Q_H - r + 1$  parâmetros restantes. Para fazer a escolha, devem ser feitos  $Q_H - r + 1$  realizações (testes), a cada realização os  $r - 1$  parâmetros já selecionados anteriormente são mantidos e um entre os restantes é acrescentado aos  $r - 1$ , formando um conjunto de  $r$  parâmetros. A cada iteração os  $r$  parâmetros são recalculados por um método linear (Seção 2.4.1) ou não linear (Seção 2.4.2). Aquela realização que gerou o melhor desempenho contém o  $r$ -ésimo parâmetro mais significativo, o qual passa a estar fixo nas próximas iterações, os demais parâmetros são desprezados.

O Ascendente apresenta resultados de busca quase ótimos e permite redução acima de 90% no número de parâmetros (SCHUARTZ *et al.*, 2019), pode ser aplicado para modelos 2D e 3D, e permite obter a capacidade de modelagem para situações de sobreajuste (*overfitting*) e mau-condicionamento da matriz  $\mathbf{X}$ .

---

<sup>2</sup>Multiplicação por uma matriz de conversão de base de um sub espaço vetorial de dimensão  $a$  para outro sub espaço vetorial  $b$ , onde  $a$  pode ou não ter dimensão igual a  $b$ .

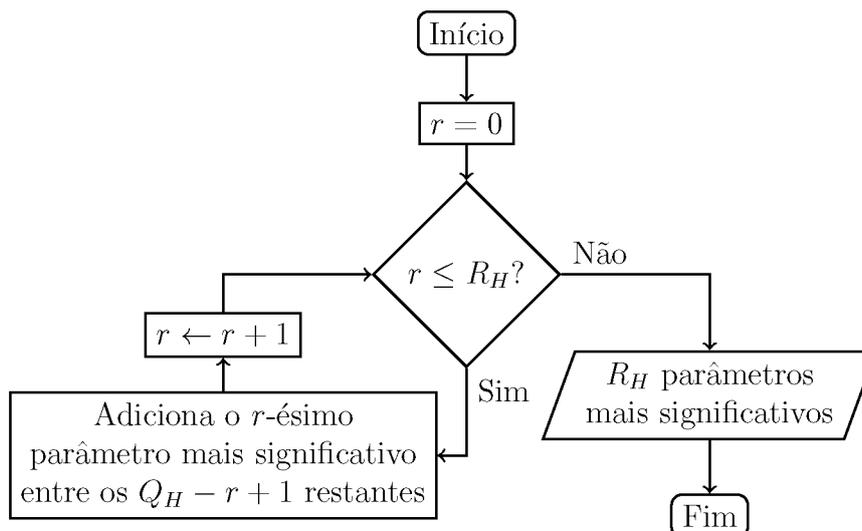


Figura 2.13: Diagrama do algoritmo Ascendente.  
Fonte – O autor, 2021.

#### 2.4.4 Aprendizagem direta

A aprendizagem direta é uma arquitetura iterativa para a extração dos parâmetros do DPD através da minimização de uma função objetivo conforme apresenta a figura 2.14 (BAUDOIN; JARDIN, 2001; CHAVEZ *et al.*, 2018).

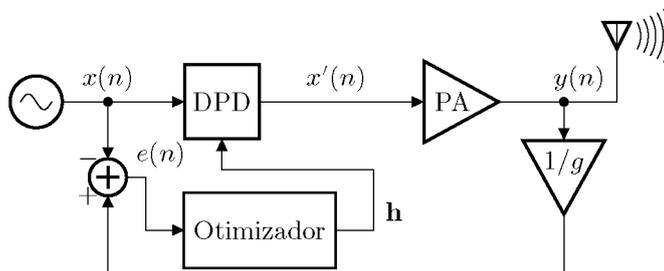


Figura 2.14: Diagrama de blocos da aprendizagem direta.  
Fonte – O autor, 2021. Adaptado de Baudoin & Jardin (2001).

Não é possível definir uma entrada desejável para o PA, o que inibe a aplicação de um método linear de obtenção dos parâmetros. Entretanto, o sinal de saída do PA deve ser igual ao de entrada do DPD, exceto por um ganho linear. Portanto, a função a ser minimizada é o sinal de erro entre a saída do PA e a entrada do DPD, onde as variáveis de ajuste são os parâmetros do DPD. Na situação ilustrada, o sinal aplicado na entrada do DPD é uma informação sem distorção e o sinal de entrada do PA já apresenta a pré-distorção, conseqüentemente, o modelo extraído nesse sistema já compensa a resposta do PA para uma informação pré-distorcida. Os principais aspectos negativos da aprendizagem direta são a necessidade de uma estimativa inicial dos parâmetros  $\mathbf{h}$  e a necessidade de um algoritmo de otimização (CHAVEZ *et al.*, 2018; KELLY; CAO; ZHU, 2016). Além disso, o PA faz parte do processo de otimização, e o número de vezes que o comportamento do

PA é avaliado pode tornar o sistema impraticável. Dessa forma, utilizar um modelo do PA durante o processo de otimização é uma possibilidade já utilizada em outros trabalhos com intuito de contornar problemas de coleta de informações, por exemplo a restrição de largura de banda do conversor analógico-digital (NARAHARISSETTI *et al.*, 2013; LIU *et al.*, 2014).

Os métodos de aprendizagem precisam ser executados conforme a demanda de atualização de parâmetros, ou seja, a atualização é eventual (Seção 2.1.3.2). Dessa forma, um mecanismo independente do PA para extração de parâmetros é necessário. Quando um PA é substituído por um modelo comportamental, ao invés de haver uma função de otimização dependente de um circuito inteiro, há uma função puramente matemática, permitindo o uso de algoritmos de convergência tradicionais (Seção 2.4.2). O modelo matemático do PA pode ser extraído utilizando um modelo comportamental com base em um conjunto de dados de entrada e saída do PA (Seção 2.2), nesse caso o PA não faz parte do processo de otimização porque as entradas e saídas são bem conhecidas. Ou seja, a maior dificuldade da aprendizagem direta é a necessidade de avaliar um circuito em RF continuamente e não o nível de distorção ou possibilidade de reconfigurabilidade. Tratando da aprendizagem, um PA reconfigurável pode ser visto como vários PAs de características distintas e cada modo é tratado isoladamente, ou comutando entre os modos em tempo real, nesse caso uma avaliação é necessária para compensar o efeito descontínuo que uma configuração desse tipo pode causar (SCHUARTZ *et al.*, 2019; FREIRE *et al.*, 2021).

### 2.4.5 Aprendizagem indireta

A arquitetura de aprendizagem indireta calcula os parâmetros de um pós-distorcedor (PoD) de forma que a entrada do PA seja igual a saída do PoD, e posteriormente copia os parâmetros do PoD para o DPD. A figura 2.15 apresenta o diagrama de blocos equivalente em banda base da aprendizagem indireta (CHAVEZ *et al.*, 2018; EUN; POWERS, 1997).

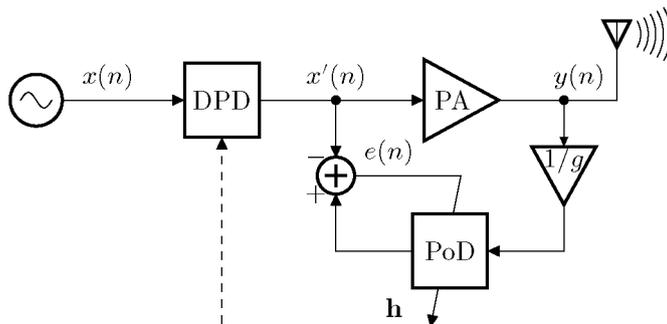


Figura 2.15: Diagrama de blocos da aprendizagem indireta.  
Fonte: O autor, 2021. Adaptado de Eun & Powers (1997).

As amostras de entrada e saída do PA são conhecidas, logo é possível calcular os parâmetros do PoD aplicando um método linear com base em um conjunto de dados.

O procedimento não é executado em tempo real e podem ser feitas várias iterações. Na primeira extração o DPD não aplica a pré-distorção e portanto  $x'(n)$  é igual a  $x(n)$ , a saída do PA  $y(n)$  é dividida pelo ganho  $g$  do PA e os parâmetros do PoD são obtidos reduzindo o erro  $e(n)$ . Na primeira iteração  $y(n)/g \neq x(n)$  porque as não linearidades do PA não são compensadas, logo, ao aplicar a pré-distorção o comportamento do PA será ligeiramente modificado. Entretanto, na segunda iteração o DPD já aplica a pré-distorção, ou seja,  $x'(n) \neq x(n)$  e  $y(n)/g \approx x(n)$ , e portanto a próxima extração já considera o comportamento do PA com a pré-distorção digital. Várias iterações podem ser executadas para a extração dos parâmetros, entretanto, duas iterações são suficientes para obter resultados satisfatórios (CHAVEZ *et al.*, 2018).

A possibilidade de aplicar métodos lineares e a necessidade de poucas iterações com o PA são as principais vantagens dessa arquitetura. Por outro lado, a cópia dos parâmetros de um PoD para o DPD e a sensibilidade ao ruído limitam o desempenho da pré-distorção (PENG; QIU; MU, 2018).

## 2.5 Métricas de desempenho para a modelagem e a linearização de amplificadores de potência

Esta seção apresenta o conceito e referencia as métricas aplicadas nesta pesquisa para mensurar o desempenho da modelagem e linearização dos PAs.

A relação entre potência de entrada e saída de um PA é (CRIPPS, 2006):

$$\eta = \frac{P_{out}}{P_{CC}}, \quad (2.21)$$

onde  $\eta$  é a eficiência,  $P_{out}$  é a potência de saída e  $P_{CC}$  é a soma de toda potência contínua consumida pelo PA. Também é comum referir-se à eficiência em termos de eficiência de potência adicionada (PAE - do inglês *power added efficiency*) (CRIPPS, 2006):

$$\text{PAE} = \frac{P_{out} - P_{in}}{P_{CC}}. \quad (2.22)$$

O erro quadrático médio normalizado (NMSE - do inglês *normalized mean square error*) é uma das principais métricas que determina a acurácia de um modelo para o PA. O NMSE compara resultados desejados e estimados por um modelo considerando o conteúdo de fase e quadratura, cujo resultado é apresentado em dB conforme (MUHA *et al.*, 1999):

$$\text{NMSE} = 10 \log \left\{ \frac{\sum_{k=1}^N \left[ \left( y_{I,k}^{\text{desejado}} - y_{I,k}^{\text{estimado}} \right)^2 + \left( y_{Q,k}^{\text{desejado}} - y_{Q,k}^{\text{estimado}} \right)^2 \right]}{\sum_{k=1}^N \left[ \left( y_{I,k}^{\text{desejado}} \right)^2 + \left( y_{Q,k}^{\text{desejado}} \right)^2 \right]} \right\}, \quad (2.23)$$

onde  $y_I$  indica o sinal em fase,  $y_Q$  indica o sinal em quadratura e  $N$  é a quantidade total de amostras. Na modelagem 2D e 3D, o NMSE é avaliado separadamente para cada canal.

A densidade espectral de potência (PSD - do inglês *power spectral density*) é uma das métricas para verificar a potência de intermodulação harmônica através da resposta em frequência em unidade de potência por unidade de frequência (W/Hz ou dBm/Hz). A PSD permite mensurar a ocupação nas bandas adjacentes ao canal ou distorção fora da banda.

A PSD  $S_x(f)$  é definida como a transformada de Fourier da função de autocorrelação  $R_x(\tau)$  conforme (HAYKIN, 2004):

$$S_x(f) = \int_{-\infty}^{\infty} R_x(\tau) e^{-j2\pi f\tau} d\tau, \quad (2.24)$$

sendo a autocorrelação  $R_x(\tau)$  o valor esperado do produto de uma variável aleatória observada nos instantes  $t + \tau$  e  $t$ . Para uma função cossenoidal, a autocorrelação  $R_x(\tau)$  é dada por:

$$R_x(\tau) = \frac{A^2}{2} \cos(2\pi f_c \tau), \quad (2.25)$$

logo, a densidade espectral de potência para um tom senoidal é

$$S_x(f) = \frac{A^2}{4} [\delta(f - f_c) + \delta(f + f_c)], \quad (2.26)$$

onde  $\delta(\cdot)$  é a função impulso unitário e  $y(t)$  é um sinal composto por  $x(t)$  multiplicado por um cosseno de frequência  $f_c$

$$y(t) = x(t) \cos(2\pi f_c t + \theta), \quad (2.27)$$

onde  $\theta$  é uma fase aleatória, a função de autocorrelação para  $y(t)$  é (HAYKIN, 2009)

$$R_y(\tau) = \frac{1}{2} R_x(\tau) \cos(2\pi f_c \tau). \quad (2.28)$$

Sendo  $S_y(f)$  e  $S_x(f)$  as densidades espectrais de potência de  $y(t)$  e  $x(t)$ , respectivamente, ambas são relacionadas por (HAYKIN, 2009)

$$S_y(f) = \frac{1}{4} [S_x(f - f_c) + S_x(f + f_c)]. \quad (2.29)$$

Portanto, a densidade espectral de potência  $S_y(f)$  é obtida deslocando a densidade espectral de potência de  $S_x(f)$  para  $f_c$  e  $-f_c$ , somando ambas as contribuições e dividindo o resultado por 4 (HAYKIN, 2009).

A Magnitude do Vetor de Erro (EVM - do inglês *error vector magnitude*) é a métrica aplicada para comparar quantitativamente a constelação transmitida por um sinal de modulação com os símbolos desejados. O resultado pode ser expresso em valor eficaz ou em porcentagem calculando a raiz quadrada da razão entre a média do quadrado da diferença entre os símbolos esperados e medidos pela média do quadrado dos símbolos esperados (MCKINLEY *et al.*, 2004).

## 2.6 O estado da arte e os desafios da telefonia 5G e futuras

### 2.6.1 O estado da arte

Em relação à extração linear de parâmetros, as abordagens mínimos quadrados (LS), mínimos quadrados recursivo e mínimos quadrados médio, aplicadas a casos específicos com modelo MP indicam a melhor relação custo-desempenho para LS (SCHUARTZ; LIMA, 2015). Já no que se refere à redução do número de parâmetros dos modelos, além dos métodos de análise dos componentes principais (GILABERT *et al.*, 2013) e mínimos quadrados ortogonais (CHEN; COWAN; GRANT, 1991) tradicionais, os métodos propostos recentemente, em específico Incrementador, Decrementador (SCHUARTZ *et al.*, 2018a), Ascendente e Descendente (SCHUARTZ *et al.*, 2019) são capazes de aplicar a redução significativa do número de parâmetros sem a necessidade de mudança de base do modelo, o que permite aplicar modelos complexos, com vários parâmetros, negligenciando a maior parte deles.

Em relação ao aumento de eficiência do PA, em Schuartz *et al.* (2018b) foi proposta a saturação do DPD para transmissão 1D, o que permite elevar a eficiência aos limites da norma comprimindo o sinal. A mesma proposta foi aplicada para um PA de banda larga atuando com transmissão 1D em Schuartz *et al.* (2019a) e que permitiu elevar a eficiência em até 45% (a eficiência teve ganho de 1,5 vezes). Uma proposta aplicada em Kelly, Cao & Zhu (2016) aplica um método de limite de sinal para portadoras múltiplas. Tal abordagem pode ser útil para tratar limites de envoltória de mais de uma portadora.

Em relação à comunicação concorrente, modelos para transmissão 2D estão apresentados na literatura (BASSAM; HELAOUI; GHANNOUCHI, 2011; RIBA; LIMA, 2016). No que se refere à modelagem 3D diversos modelos são propostos na literatura apresentando algumas características específicas de desenvolvimento afim de melhorar a acurácia (YOUNES *et al.*, 2013b; KWAN *et al.*, 2017; YOUNES *et al.*, 2013a; TIAN *et al.*, 2015; MKADEM; ISLAM; BOUMAIZA, 2016). Jaraut, Rawat & Ghannouchi (2018) desenvolvem um modelo para portadoras múltiplas, e Gilabert *et al.* (2019) aplicam a linearização para PAs

utilizando *Envelope Tracking* e *dynamic-load modulation*<sup>3</sup>.

No que se refere à aprendizagem, Shokair *et al.* (2019) propõem uma metodologia de aprendizado iterativo, baseado na aprendizagem direta onde, a cada iteração, a banda do conversor analógico-digital é deslocada aos canais adjacentes, permitindo obter conteúdo espectral de banda larga com um conversor de largura de banda do sinal em banda base. Narahariseti *et al.* (2013) aplicam o aprendizado direto utilizando um modelo de PA durante o aprendizado e os resultados são apresentados para 1D. Liu *et al.* (2014) também fazem o uso de um modelo de PA para extrair os parâmetros do DPD, mas o objetivo nesse caso é reduzir a taxa de amostragem em sinais de banda muito larga, na ordem de 100 MHz. Os sinais mensurados do PA são filtrados e utilizados para extrair um modelo para o PA. Já os parâmetros do DPD são obtidos do modelo do PA, o qual não restringe a frequência de amostragem. Kelly, Cao & Zhu (2016) aplicam a aprendizagem indireta para extração rápida dos parâmetros e depois aplicam a aprendizagem direta para ajuste fino. Yu *et al.* (2020) utilizam uma técnica mencionada como decomposição linear que permite obter acurácia com frequência de amostragem pouco acima da banda do sinal, com aplicação para banda larga.

Em relação ao MIMO, Ackermann *et al.* (2020) utilizam *crosstalk cancellation* DPD (CTC-DPD) para linearizar MIMO 2D com dois blocos de compensação, um estático e um dinâmico, para cada canal. O DPD estático faz a compensação de não linearidade e o DPD dinâmico implementa o conteúdo de memória. São utilizados sinais não correlacionados com modulação OFDM centrados em 3,5 GHz.

Em relação à transmissão com banda muito larga, em Pratt & Kearney (2017) foi aplicada a linearização de um PA classe A para comunicação cabeada de banda muito larga, na ordem de GHz. A pré-distorção digital permitiu elevar a eficiência do PA de 2,5% para 24%. Apesar de trabalhar com banda elevadíssima, os termos fora da banda não são tratados porque não são emitidos. Manyam *et al.* (2018) aplicam a linearização de múltiplas portadoras formando uma banda agregada, na ordem de 80 MHz. O modelo aplicado é o MP com filtro. Por outro lado, em Peng, Qiu & Mu (2018) foi aplicado um filtro não linear adaptativo que permite reduzir os termos das bandas harmônicas considerando uma comunicação 1D. Apesar de apresentar redução do conteúdo harmônico indesejado, a necessidade de misturadores e conversores AD para cada harmônica é um ponto crítico.

### 2.6.2 Desafios da telefonia 5G e futuras

Percebe-se que as pesquisas focadas para a transmissão concorrente e problemas de largura de banda estão bem avançadas de forma que os efeitos de intermodulação

---

<sup>3</sup>*Envelope Tracking* e *dynamic-load modulation* permitem modificar a alimentação e a carga de forma que o PA opere sempre na região de melhor rendimento.

cruzada e distorções dentro da banda podem ser modeladas de forma efetiva mesmo com espectro limitado. Por outro lado, não se dá muita importância para manter acurácia com poucos parâmetros dos modelos, ou a mitigação de conteúdo harmônico.

Dessa forma, os principais desafios em relação à pré-distorção para 5G estão em reduzir ao máximo o consumo do DPD, o que permitiria aplicação para células de baixa potência (GUAN; ZHU, 2014) mesmo implementando modelos complexos, e a mitigação das harmônicas de forma efetiva sem a necessidade de leitura das componentes de todas as bandas ou uma única leitura envolvendo todo o espectro. Adicionalmente, a saturação do DPD em bandas múltiplas pode ser explorada melhor, permitindo maior eficiência aos limites das normas. Os desenvolvimentos dessa pesquisa estão restritos à transmissão concorrente, logo, a mitigação de conteúdo espectral harmônico causado por PAs de banda muito larga não será abordada nos desenvolvimentos.

O 5G já pode ser verificado como uma realidade em algumas regiões e a estrutura de comunicação (largura de banda, frequências de comunicação e esquemas de modulação) vêm se consolidando. O uso de frequências das transmissões atuais e de 26 GHz com modulação de 256-QAM já são tomadas como realidade. Por outro lado, o futuro das comunicações tende cada vez mais a aplicar o uso de comunicação em multi-protocolos e múltiplas frequências com o objetivo de aumentar as taxas de transmissão de dados e de desempenhar maior confiabilidade. Dessa forma essa pesquisa está bem alinhada com a situação atual que a aplicação se encontra e tende para cenários futuros. Naik, Liu & Park (2018) já previam esse comportamento tratando especificamente a coexistência de vários protocolos de comunicação e o uso de uma técnica chamada *Interface Diversity* cuja ideia de explorar múltiplas bandas concorrentes afim de possuir diferentes interfaces de comunicação para aumentar a confiabilidade também representa o mesmo seguimento de tendências do 5G e das comunicações futuras (NIELSEN; LIU; POPOVSKI, 2017).

## CAPÍTULO 3

### SOLUÇÕES E ALGORITMOS PROPOSTOS

Para organizar melhor as propostas dessa pesquisa, as contribuições sobre a transmissão de bandas múltiplas concorrentes estão divididas em três grupos tratando isoladamente: 3.1 os métodos de aprendizado, 3.2 a acurácia dos modelos com poucos parâmetros e 3.3 a saturação do DPD.

#### 3.1 Métodos de aprendizado

Já é conhecido da literatura que para 1D a aprendizagem indireta apresenta desempenho pior que a aprendizagem direta devido à inversão entre modelo de pós-inversa e pré-inversa. As duas contribuições desta pesquisa são avaliar se o desempenho pior da aprendizagem indireta conhecido para 1D se mantém para o caso de bandas múltiplas e propor uma modificação na aprendizagem indireta para melhorar seu desempenho. Os testes são limitados em uma investigação utilizando modelo polinomial 2D-IMP (2.8) e (2.9) e estendidos para redes neurais utilizando o modelo descrito na Seção 2.3.

Nesta seção, os testes são limitados para 2D e o objetivo é avaliar apenas o método de aprendizado. Os modelos para PA/DPD e os respectivos algoritmos de otimização utilizados já estão consolidados na literatura, são algoritmos bem desenvolvidos no Matlab e não serão pontos de investigação.

##### 3.1.1 Aprendizagem direta 2D

O modelo polinomial 2D-IMP permite a aplicação de um método de extração linear, por exemplo LS (2.18) distinto para cada banda, o que faz com que as entradas da outra banda sejam tratadas como constantes, ou com uma única extração aplicando um algoritmo de otimização descrito na Seção 2.4.2, dessa forma, ambas as entradas são tratadas como dinâmicas. Ao fazer uma única extração de parâmetros espera-se que o desempenho do DPD seja melhor que ao fazer extrações distintas. O algoritmo LS exige o uso da aprendizagem indireta, enquanto o algoritmo de otimização permite aplicar ambas as abordagens. Dessa forma, a comparação é realizada com as abordagens indireta e direta e os algoritmos LS e de otimização, respectivamente.

A aprendizagem indireta pode ser aplicada conforme apresentado na literatura, entretanto a quantidade significativa de iterações da aprendizagem direta torna-a impraticável nos circuitos de teste mesmo que sejam reais, pois o algoritmo teria que ser implementável em tempo real. Dessa forma, a aprendizagem direta é implementada da

seguinte forma: o PA utilizado para o processo iterativo é um modelo do circuito em teste. Os parâmetros do DPD, extraídos com o modelo do PA, são validados sobre o circuito do PA. A figura 3.1 apresenta o diagrama da aprendizagem direta utilizando um modelo para o PA.

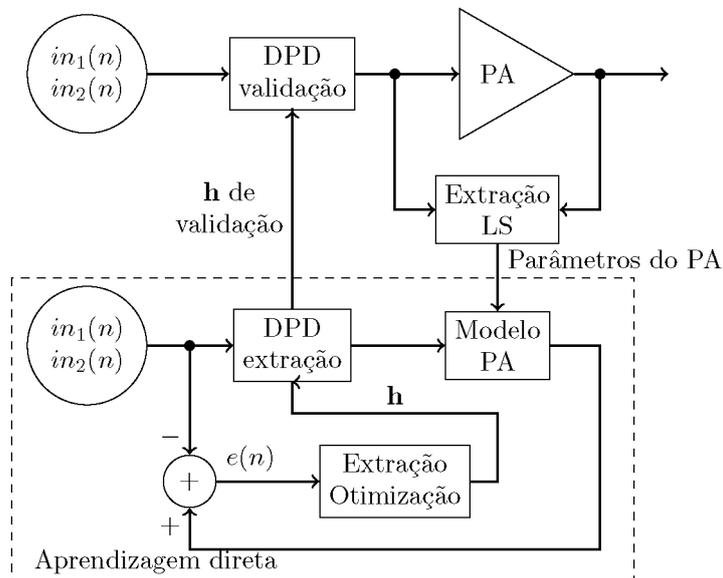


Figura 3.1: Diagrama equivalente em banda base da aprendizagem direta utilizando um modelo como PA.

Fonte – O autor, 2021.

Na aprendizagem direta proposta, apenas o modelo do PA passa pelo processo iterativo, ou seja, o circuito precisa ser avaliado apenas para obter o modelo e validar a linearização, caso contrário, o circuito teria que ser avaliado a cada iteração da otimização. Em particular, o circuito do PA é avaliado uma primeira vez com ou sem a presença do DPD, isso será discutido posteriormente, para a extração do modelo do PA, e uma segunda vez para validar a extração dos parâmetros pela aprendizagem direta realizada com o modelo do PA. A extração do PA é realizada com LS e o modelo aplicado para o DPD é o 2D-IMP (2.8) e (2.9). Estes testes realizados com o modelo 2D-IMP são estendidos para redes neurais. O que diferencia ambos é apenas o modelo do DPD, substituindo o 2D-IMP para TLP 2D descrito na Seção 2.3.

A acurácia dos modelos comportamentais é condicionada ao conjunto de dados utilizados para sua extração. Um sinal não distorcido possui características diferentes de um sinal pré-distorcido, por exemplo a PAPR de um sinal pré-distorcido é muito maior que a de um sinal não distorcido. Um modelo de PA extraído com medições onde a entrada do PA não é distorcida tem sua fidelidade comprometida ao ser utilizado para estimar o comportamento de um PA linearizado. Dessa forma, para obter o melhor desempenho da aprendizagem direta, os dados de extração do modelo do PA são obtidos de medições no PA linearizado, chegando mais próximo ao cenário ideal que é utilizar o próprio circuito na otimização. Torna-se necessária então a escolha de um DPD como ponto de partida.

Nesse trabalho, optou-se por extrair o modelo do PA baseado em medições da segunda iteração da linearização com a aprendizagem indireta. De fato é possível considerar que há uma combinação entre as metodologias indireta e direta, mas optou-se por manter o termo aprendizagem direta já que a otimização final leva em consideração a posição de pré-inversa do DPD.

### 3.1.2 Aprendizagem indireta modificada

Com a proposta descrita anteriormente, é possível aplicar a aprendizagem direta, entretanto ainda assim o desempenho pode ser fortemente comprometido pelo modelo do PA. Afim de buscar obter o melhor desempenho do DPD, uma modificação na aprendizagem indireta é proposta de forma que os coeficientes possam ser otimizados após a segunda iteração. A modificação pode ser vista como um complemento da aprendizagem indireta convencional. As duas primeiras iterações são mantidas, e as iterações adicionais são modificadas. A cada iteração executada, modificada ou não, o comportamento do PA linearizado é avaliado para uma atualização dos parâmetros.

A modificação consiste em manter o sistema tradicional mas substituir as entradas pelas saídas do PA da iteração passada. Dessa forma, o sistema pode ser executado até atingir um equilíbrio garantindo a melhor inversa. A figura 3.2 mostra o fluxograma do sistema proposto. Na segunda iteração da aprendizagem indireta os coeficientes do PoD e o vetor com as amostras de saída do PA são armazenados, o bloco chamado de Caso decide se a modificação sugerida será incluída na aprendizagem tradicional ou não. Se o Caso for falso (0) a aprendizagem indireta tradicional será mantida e os coeficientes da segunda iteração serão utilizados na validação. Se Caso for verdadeiro (1), então o bloco com a modificação é executado, o qual atualiza a saída do PA e os coeficientes do PoD. A modificação pode ser mantida até atingir o critério de parada desejado.

O bloco com a aprendizagem modificada está apresentado na figura 3.3. O bloco modificado utiliza os dados armazenados da saída do PA e os coeficientes do PoD como entradas e coeficientes do DPD. Se o sistema estiver perfeitamente linearizado, a entrada será exatamente igual a saída. Caso contrário, os coeficientes e os dados de saída armazenados são atualizados.

O sistema completo está representado na figura 3.4. O sistema está apresentado em função da respectiva iteração ( $it$ ) contendo  $N$  amostras cada, dessa forma,  $\mathbf{in}$  representa  $in(n)$ ,  $\mathbf{x}$  representa  $x(n)$ ,  $\mathbf{x}'$  representa  $x'(n)$ ,  $\mathbf{y}$  representa  $y(n)$  e  $\mathbf{e}$  representa  $e(n)$ . O bloco Situação foi incluído substituindo o bloco Caso da figura 3.2 porque o bloco Caso assume apenas uma mudança de estado, enquanto o bloco Situação assume duas mudanças de estado. Também foi incluído um multiplexador (Mux) para fazer a seleção entre as entradas. Situação é mantido falso para as iterações tradicionais e de validação da aprendizagem indireta onde a entrada é original, e verdadeiro para as iterações adici-

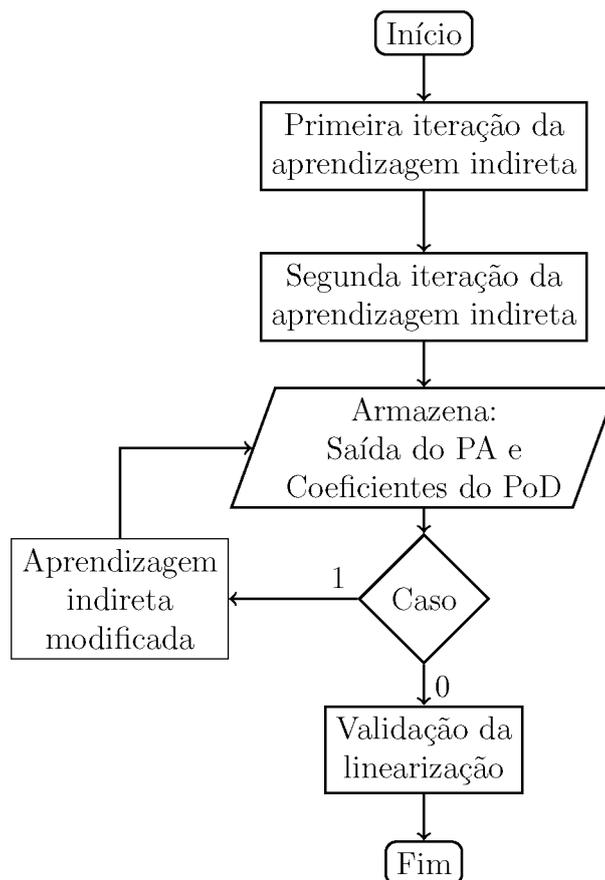


Figura 3.2: Fluxograma da aprendizagem indireta modificada.  
Fonte – O autor, 2021.

onais onde a entrada é a saída do PA da iteração passada. O procedimento de extração é idêntico.

Critérios de parada distintos podem ser implementados. Um critério plausível é manter a modificação até que o erro entre saída do PA e a entrada do DPD se mantenha estável. Outro critério possível é manter um número fixo de iterações. A modificação proposta exige iterações com o PA, entretanto o número esperado é bem menor do que para um otimizador da aprendizagem direta.

### 3.2 Melhorias na configurabilidade dos modelos polinomiais

Os modelos para amplificadores em bandas múltiplas são bem desenvolvidos em relação à inclusão de termos para a mitigação das interferências de intermodulação e modulação cruzada entre os canais. Entretanto, geram quantidades significativas de coeficientes porque a configurabilidade com poucos fatores de truncamento é limitada. Dessa forma, o objetivo nessa seção é de garantir configurabilidade que mantém desempenho elevado em acurácia, mas permite garantir quantidade mínima de coeficientes em cenários distintos para 2D, 3D e 3D de portadoras múltiplas.

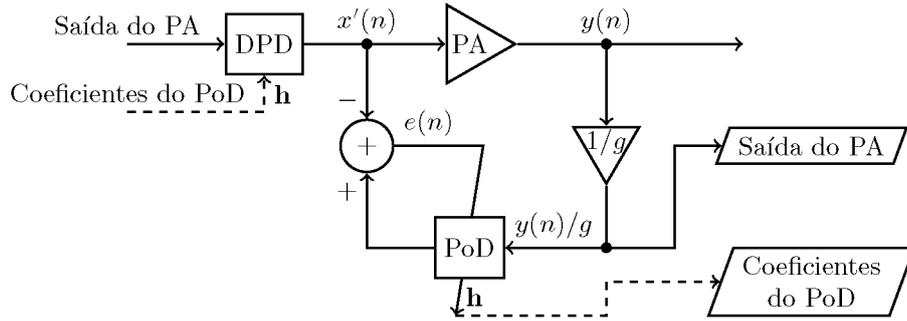


Figura 3.3: Bloco aprendizagem indireta modificada.

Fonte – O autor, 2021.

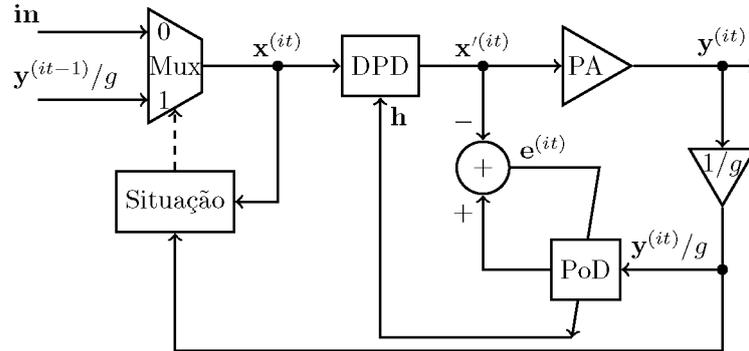


Figura 3.4: Diagrama completo da aprendizagem indireta modificada.

Fonte – O autor, 2021.

Nos desenvolvimentos dessa subseção, apenas o modelo para o DPD será abordado. Dessa forma, a metodologia para extração de parâmetros e o algoritmo de extração serão os melhores casos conhecidos da literatura para esta finalidade.

### 3.2.1 Proposta de diversos fatores de truncamento para 2D

A proposta para 2D incorpora termos multidimensionais e inclui o máximo de fatores de truncamento distintos incluindo termos dentro da banda e de interferência cruzada. Para o modelo proposto, polinômio de memória de banda dupla melhorado multidimensional (2D-MIMP), sendo  $i$  e  $j$  os 2 canais onde  $i \neq j$  e  $i$  e  $j$  podem assumir 1 ou 2, o canal  $i$  é modelado conforme

$$\begin{aligned}
y_i(n) = & \sum_{p_1=0}^{P_1-1} h_{p_1} x_i(n) |x_i(n)|^{p_1} + \sum_{p_2=1}^{P_2-1} \sum_{m_1=1}^{M_1} h_{p_2, m_1} x_i(n) |x_i(n - m_1)|^{p_2} + \\
& \sum_{p_3=0}^{P_3-1} \sum_{m_2=1}^{M_2} \sum_{m_3=0}^{M_3} h_{p_3, m_2, m_3} x_i(n - m_2) |x_i(n - m_3)|^{p_3} + \sum_{p_4=0}^{P_4-1} \sum_{q_1=1}^{Q_1-1} h_{p_4, q_1} x_i(n) |x_i(n)|^{p_4} |x_j(n)|^{q_1} + \\
& \sum_{p_5=0}^{P_5-1} \sum_{q_2=1}^{Q_2-1} \sum_{m_4=1}^{M_4} h_{p_5, q_2, m_4} x_i(n) |x_i(n - m_4)|^{p_5} |x_j(n - m_4)|^{q_2} + \\
& \sum_{p_6=0}^{P_6-1} \sum_{q_3=1}^{Q_3-1} \sum_{m_5=1}^{M_5} \sum_{m_6=0}^{M_6} h_{p_6, q_3, m_5, m_6} x_i(n - m_5) |x_i(n - m_6)|^{p_6} |x_j(n - m_6)|^{q_3}, \quad (3.1)
\end{aligned}$$

onde  $P_1, P_2, P_3, P_4, P_5, P_6$  indicam ordem de não linearidade para termos de intermodulação,  $Q_1, Q_2$  e  $Q_3$  indicam não linearidade dos termos de modulação cruzada, e  $M_1, M_2, M_3, M_4, M_5$  e  $M_6$  indicam comprimento de memória,  $x_i$  é a entrada da própria banda e  $x_j$  da banda concorrente. Para modelar o outro canal, basta inverter  $i$  com  $j$ . O modelo proposto possui o montante de 15 fatores de truncamento o que possibilita fazer combinações distintas para obter acurácia com montante de parâmetros menor.

### 3.2.2 Proposta de diversos fatores de truncamento para 3D

O modelo proposto para 3D considera apenas termos unidimensionais, com apenas um instante de tempo procurando incorporar o máximo possível de fatores de truncamento. Cada canal do modelo proposto, polinômio de memória de banda tripla melhorado (3D-IMP), é modelado conforme:

$$\begin{aligned}
y_i(n) = & \sum_{p_1=0}^{P_1-1} h_p^{(i)} x_i(n) |x_i(n)|^{p_1} + \sum_{p_2=0}^{P_2-1} \sum_{m_1=1}^{M_1} h_{m_1, p_2}^{(i)} x_i(n - m_1) |x_i(n - m_1)|^{p_2} + \\
& \sum_{p_3=0}^{P_3-1} \sum_{q_1=1}^{Q_1} h_{p_3, q_1}^{(i, j)} x_i(n) |x_i(n)|^{p_3} |x_j(n)|^{q_1} + \\
& \sum_{p_4=0}^{P_4-1} \sum_{q_2=1}^{Q_2} \sum_{m_2=1}^{M_2} h_{m_2, p_4, q_2}^{(i, j)} x_i(n - m_2) |x_i(n - m_2)|^{p_4} |x_j(n - m_2)|^{q_2} + \\
& \sum_{p_5=0}^{P_5-1} \sum_{r_1=1}^{R_1} h_{p_5, r_1}^{(i, k)} x_i(n) |x_i(n)|^{p_5} |x_k(n)|^{r_1} + \\
& \sum_{p_6=0}^{P_6-1} \sum_{r_2=1}^{R_2} \sum_{m_3=1}^{M_3} h_{m_3, p_6, r_2}^{(i, k)} x_i(n - m_3) |x_i(n - m_3)|^{p_6} |x_k(n - m_3)|^{r_2} + \\
& \sum_{p_7=0}^{P_7-1} \sum_{q_3=1}^{Q_3} \sum_{r_3=1}^{R_3} h_{q_3, p_7, r_3}^{(i, j, k)} x_i(n) |x_i(n)|^{p_7} |x_j(n)|^{q_3} |x_k(n)|^{r_3} + \\
& \sum_{p_8=0}^{P_8-1} \sum_{q_4=1}^{Q_4} \sum_{r_4=1}^{R_4} \sum_{m_4=1}^{M_4} h_{q_4, p_8, r_4, m_4}^{(i, j, k)} x_i(n - m_4) |x_i(n - m_4)|^{p_8} |x_j(n - m_4)|^{q_4} |x_k(n - m_4)|^{r_4}, \quad (3.2)
\end{aligned}$$

onde  $h$  é o coeficiente a ser ajustado,  $y_i$  é a saída do canal  $i$ ,  $x_i$  é a entrada do canal  $i$ ,  $x_j$  é a entrada do  $j$ -ésimo canal e  $x_k$  é a entrada do  $k$ -ésimo canal, com  $i$ ,  $j$  e  $k$  variando de 1 a 3. O modelo proposto inclui 20 fatores de truncamento distintos. Onde  $P_1, P_2, P_3, P_4, P_5, P_6, P_7, P_8, Q_1, Q_2, Q_3, Q_4, R_1, R_2, R_3$  e  $R_4$  são ordem de não linearidade e  $M_1, M_2, M_3$  e  $M_4$  os comprimentos de memória. Para modelar as outras bandas basta trocar  $i$  com  $j$  e  $i$  com  $k$ .

### 3.2.3 Proposta de diversos fatores de truncamento para 3D-Harmônico

O modelo proposto para 3 canais harmônicos baseia-se no 3D-HMP cujos termos harmônicos estão descritos na tabela 2.1<sup>1</sup>. O modelo proposto, polinômio de memória de banda tripla harmônico melhorado (3D-HIMP - do inglês *harmonically improved memory polynomial*), utiliza todos os 16 termos harmônicos até a quarta ordem conforme a tabela 3.1 ao invés de 12 termos do modelo 3D-HMP. Além disso utiliza a equação construtiva do 3D-IMP (3.2) para descrever cada saída substituindo o termo complexo pelo termo da tabela e aplica fatores de truncamento específicos para cada termo, o que totaliza em 140 fatores de truncamento. O modelo proposto só é válido se as portadoras forem múltiplas entre si, ou seja,  $f_{c2} = 2f_{c1}$  e  $f_{c3} = 3f_{c1}$ , onde  $f_{c1}, f_{c2}$  e  $f_{c3}$  são as portadoras

<sup>1</sup>Termos harmônicos do 3D-HMP conforme apresentado na literatura.

dos canais 1, 2 e 3, respectivamente.

Tabela 3.1: Produtos de intermodulação harmônica considerando até 4 produtos para o modelo proposto 3D-HIMP.

| Canal 1                  | Canal 2                  | Canal 3                    |
|--------------------------|--------------------------|----------------------------|
| $x_1(n)$                 | $x_2(n)$                 | $x_3(n)$                   |
| $x_2(n)x_1^*(n)$         | $x_3(n)x_1^*(n)$         | $x_1(n)x_2(n)$             |
| $x_3(n)x_2^*(n)$         | $x_1^2(n)$               | $x_2^2(n)x_1^*(n)$         |
| $x_3(n)x_1^{*2}(n)$      | $x_1(n)x_3(n)x_2^*(n)$   | $x_1^3(n)$                 |
| $x_2^2(n)x_3^*(n)$       | $x_2^2(n)x_1^{*2}(n)$    | $x_2^3(n)x_3^*(n)$         |
| $x_1^3(n)x_2^*(n)$       | $x_3^2(n)x_2^{*2}(n)$    | $x_1^2(n)x_3(n)x_2^*(n)$   |
| $x_1^2(n)x_2(n)x_3^*(n)$ | $x_2^2(n)x_1(n)x_3^*(n)$ | $x_3^2(n)x_1^*(n)x_2^*(n)$ |

Fonte – O autor, 2021.

### 3.2.4 Algoritmo AscFat para obtenção dos fatores de truncamento

Para encontrar os fatores de truncamento ótimos, uma busca exaustiva pode ser aplicada. Os fatores são variados de um valor mínimo até um valor pré definido e com a combinação possível o NMSE é avaliado. A combinação que gera o melhor desempenho para cada montante de parâmetros é escolhida como a melhor combinação. Outra opção aplicável é a verificação dos limites possíveis de modelagem por exemplo em relação à frequência de amostragem. Se a frequência de amostragem limita o conhecimento de ordem 5, não há o porquê elevar os fatores de truncamento acima desse valor.

Para os modelos citados da literatura, a quantidade de avaliações é relativamente baixa, conseqüentemente, não é necessária/conhecida uma metodologia específica para esse tipo de busca. A exemplo para 3D-MP e 3D-MB, se o comprimento de memória estiver limitado em 3, as ordens de não linearidade em 6 e não houver limite do número de parâmetros, o número de avaliações será 24 e 5488, respectivamente. Se o número de parâmetros for limitado, essa quantidade pode ser reduzida significativamente. Entretanto, para os modelos propostos, o número elevado de fatores gera quantidades significativas de combinações, na ordem de Tera combinações. Realizar a escolha dos fatores simplesmente aplicando o algoritmo Ascendente em um modelo completo não é interessante porque a escolha dos coeficientes mais significativos podem exigir a inclusão de outros não significativos, elevando consideravelmente o número de parâmetros.

Para permitir uma escolha otimista<sup>2</sup> e com custo computacional controlável o algoritmo Ascendente é aplicado na escolha dos fatores de truncamento. Dessa forma

<sup>2</sup>Que tende ao ótimo, mas não há uma garantia de que o resultado seja ótimo.

o algoritmo Ascendente dos fatores de truncamento (AscFat) faz a escolha dos fatores conforme apresenta o pseudo código da figura 3.5.

---

**Algoritmo:** AscFat

---

```

1: Fat = {0}
2:  $N_{coef} \leftarrow \text{nParam}(\mathbf{Fat})$ 
3: while  $N_{coef} < N_{des}$  do
4:   for  $i \leftarrow 1$  to  $N_{fat}$  do
5:     Fatt  $\leftarrow$  Fat
6:     Fatt[i]  $\leftarrow$  Fatt[i] + 1
7:     if  $\text{nParam}(\mathbf{Fat}_t) = \text{nParam}(\mathbf{Fat})$  then
8:       E[i]  $\leftarrow$   $\infty$ 
9:       continue
10:    end if
11:    if Fatt[i] > FatM[i] then
12:      E[i]  $\leftarrow$   $\infty$ 
13:      continue
14:    end if
15:    E[i]  $\leftarrow$  avaliarDesempenho(Fatt)
16:  end for
17:   $i = \text{indiceMenor}(\mathbf{E})$ 
18:  Fat[i] = Fat[i] + 1
19:   $N_{coef} \leftarrow \text{nParam}(\mathbf{Fat})$ 
20: end while

```

---

Figura 3.5: Pseudo código do algoritmo AscFat.  
Fonte – O autor, 2021.

Os seguintes parâmetros são definidos:  $N_{fat}$  é o número de fatores de truncamento do modelo,  $N_{coef}$  é o número de coeficientes gerados pelo modelo para uma combinação de fatores,  $N_{des}$  é o número de coeficientes desejados, **Fat** é um vetor que contém as escolhas dos fatores, **Fat**<sub>*t*</sub> é o vetor de fatores de truncamento em teste, **Fat**<sub>*M*</sub> é o vetor contendo o limite que pode ser atribuído a cada fator de truncamento, e **E** é o vetor contendo as informações de erro NMSE. As seguintes funções são definidas: nParam() retorna o número de coeficientes que o modelo gera para a combinação de fatores de truncamento que recebe como argumento, avaliarDesempenho() retorna o NMSE de modelagem para a combinação de fatores de truncamento recebida como argumento, e indiceMenor() retorna o índice que possui o menor valor no vetor recebido como argumento.

Todos os fatores são inicializados com os valores mínimos possíveis (linha 1). Em geral os truncamentos de memória recebem 0 e os truncamentos de não linearidade podem ser iniciados com 0 ou 1, dependendo da contribuição. É necessário iniciar com a contribuição de primeira ordem do canal principal. O número inicial de coeficientes é armazenado (linha 2) e o algoritmo entra no laço (linha 3) permanecendo enquanto  $N_{coef}$  é menor que  $N_{des}$ . Para cada truncamento do modelo (linha 4), o vetor em teste recebe como configuração inicial o último vetor de truncamentos (linha 5) e incrementa uma unidade no fator em teste (linha 6). Se para o teste atual o número de coeficientes não foi

alterado (linha 7), ou o fator de truncamento já excedeu o limite (linha 11), é atribuído o NMSE infinito para o vetor de erros (linhas 8 e 12) e a próxima iteração é chamada (linhas 9 e 13) descartando o resto do código para a iteração atual. Se a iteração não é descartada, então o desempenho em NMSE do modelo para a configuração em teste é avaliado e armazenado no vetor de erros (linha 15). Cada iteração de  $N_{fat}$  testes é avaliada e o incremento no fator de truncamentos que gerou o melhor desempenho (linha 17) torna-se fixo (linha 18). O número de coeficientes para a combinação que passa a ser fixa é atualizado (linha 19) até que o critério de parada seja atingido (linha 3).

O critério de parada adotado é o número de parâmetros produzidos pelo modelo. Outros critérios podem ser implementados sem prejuízo ao algoritmo. Por exemplo uma aplicação onde um determinado desempenho de acurácia seja suficiente.

A cada iteração, o algoritmo proposto seleciona o fator que melhor contribui na acurácia, podendo incluir mais de um parâmetro. No caso mais exaustivo, onde nenhum fator é insignificante, nenhum excede o número máximo permitido, e cada fator inclui um único parâmetro,  $N_{fat}$  avaliações são necessárias por iteração e o número de iterações é igual a  $N_{des}$ , logo no pior dos casos,  $N_{fat}N_{des}$  avaliações são necessárias.

A figura 3.6 ilustra a situação na linha 5 do pseudo código da figura 3.5 para um caso onde há 5 fatores de truncamento e a linha vermelha indica os respectivos limites dos fatores ( $\mathbf{Fat}_M$ ). Todos os fatores são inicializados com zero e podem ser acrescidos de uma unidade a cada passo. No passo 0, cada parâmetro possui valor zero e é capaz de produzir ao menos a primeira ordem do canal principal; no passo 1, já foi executada uma varredura dos fatores e o que gerou menor erro foi  $\mathbf{Fat}[1]$ ; no passo 2 a segunda verificação foi realizada e o fator incrementado foi o  $\mathbf{Fat}[4]$ ; no passo 3, novamente  $\mathbf{Fat}[4]$  foi incrementado e já atingiu o valor limite, logo, para os próximos passos  $\mathbf{Fat}[4]$  permanece fixo e não é mais avaliado; no passo 4 o  $\mathbf{Fat}[2]$  recebe o incremento porque gerou a melhor contribuição; no passo 5 um incremento em  $\mathbf{Fat}[1]$  gera a melhor contribuição e é incrementado. O algoritmo segue essa sequência até atingir o critério de parada.

O AscFat é um algoritmo que faz parte do processo de aprendizagem da linearização (Seção 2.1.3.2) e, dessa forma, os detalhes de implementação ou custo computacional não são avaliados.

### 3.3 Saturação para bandas múltiplas

A saturação para bandas múltiplas apresenta um desafio que para a saturação de banda única é simples. Em uma portadora, a amplitude em RF da informação transmitida pode ser adequadamente representada pela envoltória da própria banda. Dessa forma, a saturação pode ser aplicada considerando apenas uma única informação de envoltória. Por outro lado, para bandas múltiplas, a amplitude do sinal em RF a ser transmitido possui a contribuição de mais de uma banda. Conseqüentemente, a saturação de uma

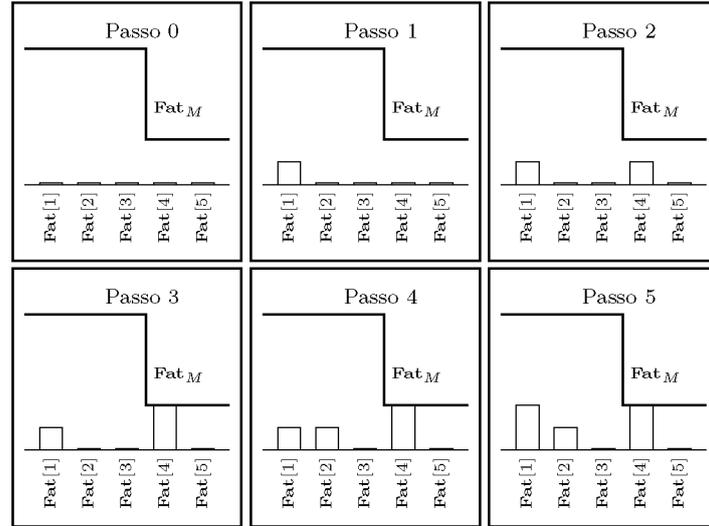


Figura 3.6: Ilustração dos passos do algoritmo AscFat.  
Fonte – O autor, 2021.

portadora não pode considerar apenas a amplitude de uma única portadora, mas sim, da contribuição de todas as portadoras simultaneamente. Para restringir a complexidade do problema, os desenvolvimentos de saturação serão restringidos à banda dupla concorrente para portadoras não múltiplas, mas podem ser estendidos para cenários de complexidade maior.

Esse desenvolvimento está focado para a saturação. Dessa forma, os modelos, metodologia e algoritmo de extração de parâmetros aplicados serão os melhores casos conhecidos da literatura.

### 3.3.1 Contextualização para a saturação de banda dupla

Quando o PA é estimulado por duas portadoras, a informação transmitida pelo PA no tempo contínuo pode ser descrita por:

$$s(t) = \text{Real} [x_1(t)e^{j\omega_1 t} + x_2(t)e^{j\omega_2 t}], \quad (3.3)$$

onde  $x_1(t)$  e  $x_2(t)$  são as envoltórias complexas em tempo contínuo, e  $\omega_1$  e  $\omega_2$  são as portadoras da primeira e segunda banda, respectivamente. Esse cenário de transmissão pode ser abstraído em torno de uma portadora  $\omega$  qualquer, a qual permanecerá definida como:

$$\omega = \frac{\omega_1 + \omega_2}{2}. \quad (3.4)$$

Para esta definição, cada subportadora está deslocada  $\Delta\omega$  da portadora central. Ou seja, sendo

$$\Delta\omega = \frac{\omega_2 - \omega_1}{2}, \quad (3.5)$$

então

$$\omega_1 = \omega - \Delta\omega \quad (3.6)$$

e

$$\omega_2 = \omega + \Delta\omega. \quad (3.7)$$

Reescrevendo (3.3) em termos de  $\omega$  e  $\Delta\omega$ :

$$s(t) = \text{Real} \left[ (x_1(t)e^{-j\Delta\omega t} + x_2(t)e^{j\Delta\omega t}) e^{j\omega t} \right]. \quad (3.8)$$

A equação (3.8) contém exatamente a mesma informação que (3.3). A vantagem da representação em (3.8) é a possibilidade de extrair uma única envoltória complexa  $x(t)$ :

$$x(t) = (x_1(t)e^{-j\Delta\omega t} + x_2(t)e^{j\Delta\omega t}). \quad (3.9)$$

Da mesma forma que  $x(t)$  é a envoltória complexa para  $\omega$ ,  $x(t)$  é composto pela envoltória complexa  $x_1(t)$  deslocada para  $-\Delta\omega$  e  $x_2(t)$  deslocada para  $\Delta\omega$ . Essa informação é importante, pois se o termo  $x_1(t)e^{-j\Delta\omega t}$  possui como informação dinâmica a largura de banda de  $x_1(t)$  sendo  $e^{-j\Delta\omega t}$  apenas um deslocamento em frequência, e o termo  $x_2(t)e^{j\Delta\omega t}$  possui como informação dinâmica a largura de banda de  $x_2(t)$  sendo  $e^{j\Delta\omega t}$  apenas um deslocamento em frequência, então a informação dinâmica de  $x(t)$  possui como frequência dinâmica a frequência máxima entre  $x_1(t)$  e  $x_2(t)$ . Conseqüentemente, a mesma frequência de amostragem dos sinais  $x_1(t)$  e  $x_2(t)$  será aplicada para  $x(t)$  e (3.9) tratada de forma discreta por<sup>3</sup>

$$x(n) = \left( x_1(n)e^{-j\Delta\omega \frac{(n-1)}{f_s}} + x_2(n)e^{j\Delta\omega \frac{(n-1)}{f_s}} \right). \quad (3.10)$$

Nesse ponto, algumas informações são tratadas como verdadeiras: a envoltória complexa  $x(n)$  pode ser sub amostrada sem prejuízo algum para ambos os canais; a fase do misturador para  $x_1(t)$  é igual para  $x_2(t)$ ; e a fase dos misturadores é bem conhecida e alinhada com o algoritmo de saturação.

### 3.3.2 Proposta de saturação para banda dupla

Em Schuartz *et al.* (2018b) foi proposta a saturação do DPD para banda única. Em resumo, a saturação é a atitude de ceifar o sinal de entrada do DPD em um limiar  $L$

---

<sup>3</sup>O instante de tempo  $(n-1)$  na exponencial indica que para o instante de tempo  $n=1$  o argumento da exponencial deve ser nulo.

mantendo a fase original do sinal. Em Schuartz *et al.* (2019a) uma modificação proposta também atua na fase obrigando o DPD manter continuidade em amplitude e fase. Neste trabalho, a atuação do DPD não é alterada, logo, a fase da informação é sempre alterada pelo DPD. Portanto, a base de desenvolvimento é a primeira abordagem ceifando a amplitude da envoltória complexa (SCHUARTZ *et al.*, 2018b).

Em banda dupla, a informação que recebe a envoltória complexa é  $x(n)$ . Sendo  $L$  o limiar escolhido para o sinal de entrada aplicado para o DPD, o sinal ceifado ( $x_c(n)$ ) segue a regra:

$$x_c(n) = \begin{cases} x(n), & \text{se } |x(n)| \leq L \\ Le^{j\angle x(n)}, & \text{se } |x(n)| > L \end{cases} \quad (3.11)$$

$x_c(n)$  é uma informação de envoltória que envolve as entradas  $x_1(n)$  e  $x_2(n)$ . O DPD de banda dupla concorrente atua isoladamente para cada uma das bandas, dessa forma, a saturação precisa, necessariamente, afetar diretamente as informações de cada banda mantendo a relação de (3.10). Na equação (3.10), se  $x(n)$  é pré-definido como  $L$  quando  $|x(n)| > L$ , cada contribuição ceifada  $x_{1c}(n)$  e  $x_{2c}(n)$  precisa assumir o excedente  $|x(n)| - L$ . Não existe uma solução única para esse problema e abordagens distintas podem ser aplicadas. Na sequência duas propostas são apresentadas e aplicadas para a validação da metodologia.

### 3.3.2.1 Abordagem da soma

A primeira abordagem aplicada para obter  $x_{1c}(n)$  e  $x_{2c}(n)$  é dividir o excedente igualmente para cada banda. Sendo  $z(n) = |x(n)| - L$  quando  $|x(n)| > L$ , então

$$x_{1c}(n) = \begin{cases} x_1(n), & \text{se } |x(n)| \leq L \\ \left(|x_1(n)| - \frac{z(n)}{2}\right) e^{j\angle x_1(n)}, & \text{se } |x(n)| > L \end{cases} \quad (3.12)$$

e

$$x_{2c}(n) = \begin{cases} x_2(n), & \text{se } |x(n)| \leq L \\ \left(|x_2(n)| - \frac{z(n)}{2}\right) e^{j\angle x_2(n)}, & \text{se } |x(n)| > L \end{cases} \quad (3.13)$$

### 3.3.2.2 Abordagem da divisão

A segunda abordagem leva em consideração que para a amostra  $n$  em que  $|x(n)| > L$ , a relação

$$z(n) = \frac{|x(n)|}{L} \quad (3.14)$$

é válida. Sempre que essa condição acontecer, cada uma das entradas saturadas recebe a metade de  $x(n)$ . Ou seja

$$x_{1c}(n) = \begin{cases} x_1(n), & \text{se } |x(n)| \leq L \\ \frac{x_1(n)}{z(n)}, & \text{se } |x(n)| > L \end{cases} \quad (3.15)$$

e

$$x_{2c}(n) = \begin{cases} x_2(n), & \text{se } |x(n)| \leq L \\ \frac{x_2(n)}{z(n)}, & \text{se } |x(n)| > L \end{cases} . \quad (3.16)$$

Se essa relação for cumprida sempre que  $x(n) > L$ , então

$$\frac{x_1(n)}{z(n)} + \frac{x_2(n)}{z(n)} = \frac{x(n)}{|x(n)|/L} = Le^{j\angle x(n)}. \quad (3.17)$$

### 3.3.2.3 O sistema de saturação para banda dupla

O diagrama completo de saturação proposto para banda dupla concorrente está apresentado na figura 3.7. Os sinais  $x_1(n)$  e  $x_2(n)$  são as entradas de cada canal para os blocos de extração da envoltória (Env) em  $\omega$ , cuja saída  $z(n)$  é obtida para o limiar  $L$ ; e para os blocos de saturação (Sat), que ceifam a respectiva entrada conforme o valor de  $z(n)$ . Os sinais ceifados  $x_{1c}$  e  $x_{2c}$  passam pela pré-distorção gerando os sinais  $x'_{1c}$  e  $x'_{2c}$ . Na implementação apresentada, o bloco de pré-distorção implementa uma função tradicional de implementação de banda dupla e não sofre alteração. Especificamente nesse trabalho o bloco DPD implementa o modelo da literatura 2D-IMP (Seção 2.2.2).

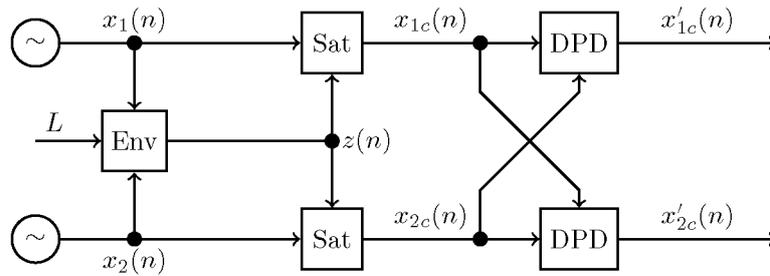


Figura 3.7: Implementação da saturação do DPD para banda dupla concorrente.

Fonte – O autor, 2021.

## CAPÍTULO 4

### MATERIAIS E METODOLOGIAS

#### 4.1 Materiais

Esta pesquisa utiliza o *software* de projeto e simulação de circuitos de RF Cadence Virtuoso, e o *software* matemático Matlab.

O amplificador base disponível para o desenvolvimento dessa pesquisa é um projeto de PA desenvolvido no Cadence Virtuoso com a tecnologia CMOS 130 nm. O projeto é um PA classe AB com dois estágios que permite a atuação em banda larga envolvendo aplicações de transição entre 4G e 5G e protocolos Wi-Fi em 2,4 GHz e 5 GHz com aplicações até 6 GHz. As simulações pós-leiute apresentam as características: ganho acima de 15 dB entre 2 GHz e 6 GHz,  $P_{sat}$  acima de 19 dBm entre 2 GHz e 5 GHz atingindo máximo de 21,7 dBm em 3 GHz, OCP1 acima de 18 dBm entre 2 GHz e 4,5 GHz e 15,7 dBm em 5 GHz, OCP1 máximo de 20,4 em 2,5 GHz, ganho acima de 16,0 dB com máximo de 20,9 dB em 3,0 GHz, e PAE máximo de 22,4% em 2,5 GHz (SCHUARTZ *et al.*, 2021). Apesar dos testes dessa pesquisa estarem limitados a um único PA de testes, as tendências comportamentais dos modelos são muito similares para qualquer amplificador e dados em testes.

Os dados aplicados para a modulação são obtidos por fontes do Cadence Virtuoso e possuem as características: (1) dados Wi-Fi na norma IEEE 802.11n, modulação 64-QAM, largura de banda (BW - do inglês *band width*) de 20 MHz, amostragem média original de 80 MHz e armazenado com amostragem fixa de 120 MHz; (2) dados na norma LTE, modulação 64-QAM, BW de 20 MHz, amostragem média de 120 MHz e armazenado com amostragem fixa de 120 MHz; e (3) dados Wi-Fi na norma IEEE 802.11ac, modulação 256-QAM, BW de 20 MHz, amostragem média original de 80 MHz e armazenado com amostragem fixa de 120 MHz. O *software* Cadence Virtuoso é utilizado para coletar os dados e avaliar os níveis de distorção de EVM. Os 3 dados são reamostrados com frequência fixa de 120 MHz porque para a aplicação no DPD a amostragem precisa ser constante e igual para todos os sinais. Entretanto, as informações relevantes para os dados Wi-Fi estão restritas à 40 MHz.

## 4.2 Metodologias

### 4.2.1 A interação entre Cadence Virtuoso e Matlab

As figuras 4.1 e 4.2 apresentam os diagramas aplicados para as simulações de envoltória e de transitório, respectivamente.

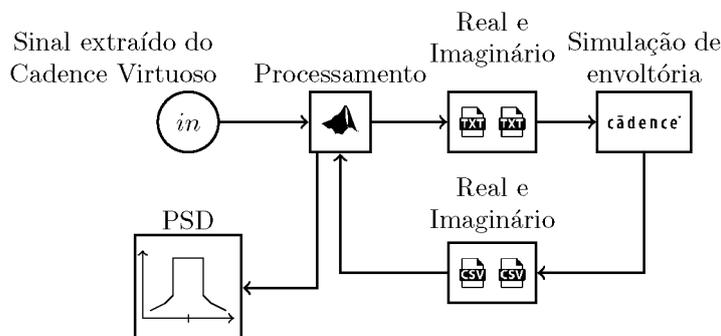


Figura 4.1: Diagrama de teste para linearização do PA com simulação de envoltória.  
Fonte – O autor, 2021.

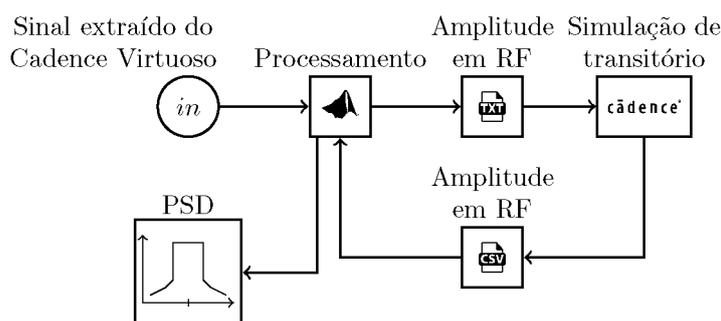


Figura 4.2: Diagrama de teste para linearização do PA com simulação de transitório.  
Fonte – O autor, 2021.

No diagrama da figura 4.1, todas as informações trocadas entre os *softwares* são valores em banda base, logo é necessário haver informações de fase e quadratura dispostos em dois arquivos texto onde cada arquivo contém a informação de tempo e amplitude. O Cadence Virtuoso trata os dois arquivos de entrada como dados de modulação para simulações de envoltória e permite extrair valores de tensão ou corrente sobre componentes por meio de arquivos CSV, os quais passam a ser tratados pelo Matlab para gerar as métricas de desempenho ou aplicar a modelagem/distorção.

Nesta pesquisa as simulações de envoltória são aplicadas para extrair as informações de modulação nas respectivas normas. Dessa forma, uma fonte de dados modulados alimenta uma carga de  $50 \Omega$  e outra fonte do tipo porta (fonte de tensão em série com uma impedância de  $50 \Omega$ ) alimenta uma outra carga de  $50 \Omega$  com informações de arquivos gerados pelo Matlab. Informações de tensão sobre a carga alimentada pela fonte

modulada permitem obter a referência de EVM e geram os dados representados pelas fontes das figuras, os quais passam a ser armazenados pelo Matlab. As informações de tensão sobre a carga alimentada pela porta são utilizadas pelo próprio Cadence Virtuoso para análise de EVM. As simulações de envoltória também permitem analisar as distorções do PA para portadora única, entretanto essa pesquisa utiliza apenas cenários de mais de uma portadora.

No diagrama da figura 4.2, a representação aplicada no Cadence Virtuoso é em RF, logo as informações de entrada e saída são apenas uma informação de amplitude ou corrente no tempo. No Cadence Virtuoso a análise é realizada por simulações de transitório, cuja amplitude da fonte de entrada do PA é obtida pelo arquivo gerado pelo Matlab. Com as simulações de transitório, é possível coletar apenas informações de tensão e corrente sobre os nós do circuito, logo, para obter informações de PSD e EVM é necessário primeiro tratar os dados no Matlab para depois avaliá-los pelo Cadence Virtuoso por meio de simulações de envoltória (figura 4.1). Todo o procedimento de modulação em RF e demodulação é aplicado pelo Matlab.

Nas figuras 4.1 e 4.2 os sinais são extraídos do Cadence Virtuoso e tratados no Matlab para obter controle total da frequência de amostragem dos sinais em banda base e em RF, obter controle do processamento digital (isso inclui o DPD), níveis de amplitude, a mistura dos sinais, e poder aplicar tanto simulações de envoltória quanto simulações de transitório.

### 4.2.2 Modelos de modulator e demodulator aplicados no Matlab para 2D e 3D

A figura 4.2 mostra o fluxo de procedimentos para as simulações de transitório no Cadence Virtuoso cujos sinais de entrada e saída das simulações são valores reais e em RF. Cabe ao Matlab converter as informações BB para RF e de RF para BB por meio da modulação e da demodulação. As figuras 4.3 e 4.4 apresentam os diagramas de modulator para cenários de aplicação 2D e 3D, respectivamente, e as figuras 4.5 e 4.6 apresentam os diagramas de demodulação aplicados no Matlab para cenários de aplicação 2D e 3D, respectivamente.

Para a modulação, apresentada pelas figuras 4.3 e 4.4, os sinais de entrada  $x_1$ ,  $x_2$  e  $x_3$  devem estar amostrados na mesma frequência. Se a simulação faz o uso da pré-distorção, então todas as informações de entrada são aplicadas no DPD, se a simulação não está aplicando a pré-distorção então apenas a entrada do canal principal (indicada pela conexão das setas pretas) é aplicada no DPD, cuja transferência é um ganho unitário. Essa conexão cruzada das entradas é necessária para garantir compensação das interferências cruzadas e harmônicas pelo DPD. Os sinais de saída dos DPDs ( $x'_1$ ,  $x'_2$  e  $x'_3$ ) são valores complexos (contêm fase e quadratura) e estão amostrados em banda base.

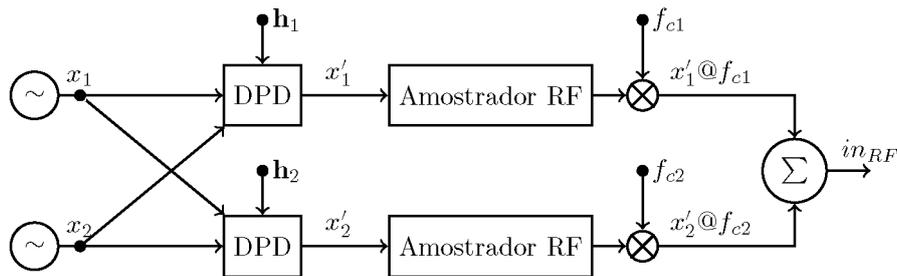


Figura 4.3: Diagrama representando o modelo de modulador para 2D aplicado no Matlab.  
Fonte – O autor, 2021.

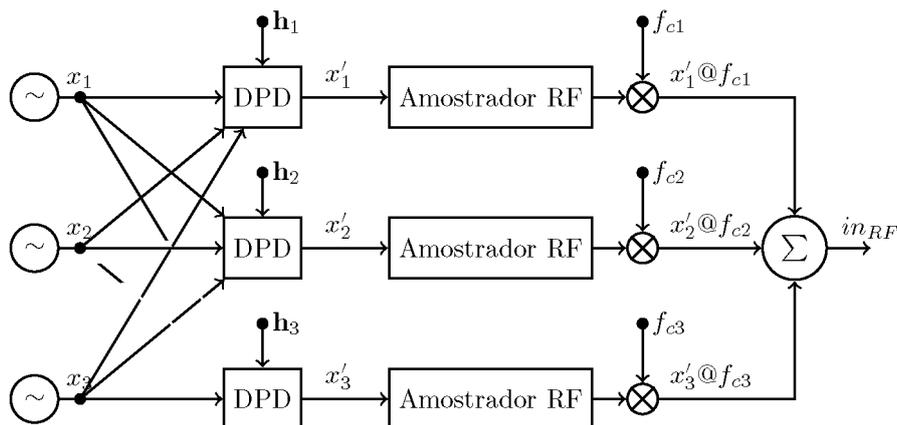


Figura 4.4: Diagrama representando o modelo de modulador para 3D aplicado no Matlab.  
Fonte – O autor, 2021.

O bloco Amostrador RF reamostra os dados a 10 vezes a frequência de portadora mais alta. Apesar de amostrados com frequência de RF, as informações permanecem em BB. O misturador é o responsável por deslocar a informação BB em torno da portadora. A função matemática executada pelo misturador é

$$x_i@f_i = \text{Real} \{ x_i e^{j2\pi f_i t} \} \quad (4.1)$$

onde  $x_i$  e  $f_i$  é a entrada e a portadora  $i$ , onde  $i$  pode ser 1, 2 ou 3, e  $x_i@f_i$  é o sinal complexo  $x_i$  deslocado para portadora  $f_i$ . Por fim, os dados deslocados para as portadoras são somados e formam os dados de bandas múltiplas  $in_{RF}$  de banda dupla ou tripla aplicados no Cadence Virtuoso.

Para a demodulação, apresentada pelas figuras 4.5 e 4.6 para 2D e 3D, respectivamente, a informação recebida pelo Matlab é o sinal de saída do PA contendo tensão sobre a carga (antena) de  $50 \Omega^1$ . O sinal é um valor real, com amostragem variável e na ordem de centenas de GHz, cabe ao Matlab tratar esses dados e extrair as envoltórias complexas e em banda base de cada portadora.

O primeiro bloco na entrada dos sistemas de demodulação é o amostrador RF que

<sup>1</sup>Informações de correntes e tensões sobre as outras fontes do circuito também são coletadas e armazenadas para fazer estimativa de consumo de potência e rendimento.

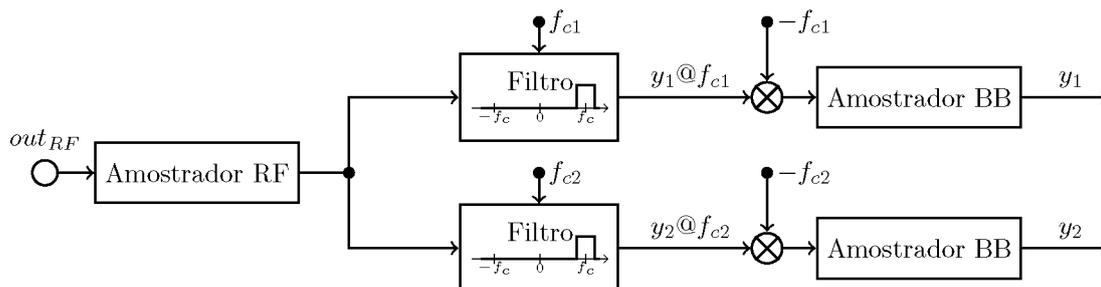


Figura 4.5: Diagrama representando o modelo de demodulador para 2D aplicado no Matlab.

Fonte – O autor, 2021.

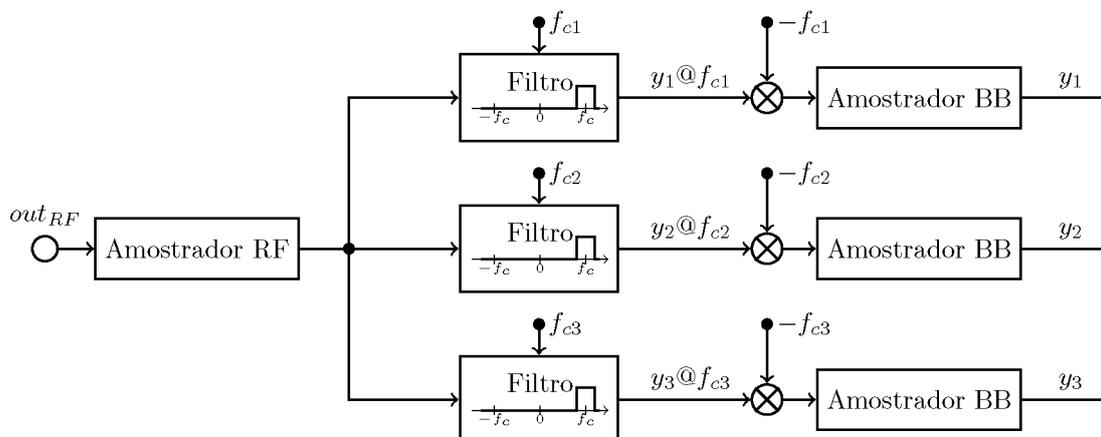


Figura 4.6: Diagrama representando o modelo de demodulador para 3D aplicado no Matlab.

Fonte – O autor, 2021.

possui a função de reduzir a frequência de amostragem gerada pelo simulador (na ordem de centenas de GHz) para 10 vezes a portadora de frequência mais elevada, e também para tornar a frequência de amostragem constante. O sinal na saída do amostrador possui o mesmo conteúdo espectral da entrada: duas ou três envoltórias centradas nas respectivas portadoras. O sinal é filtrado em torno da portadora positiva conforme apresenta a máscara em vermelho dentro do bloco Filtro. Para as frequências não desejadas a informação recebe zero, e o filtro apresenta uma resposta constante, de ganho unitário, dentro da banda de interesse, que possui largura de 120 MHz, sendo 60 MHz acima e abaixo da portadora. A frequência de portadora para cada filtro é ajustada conforme a entrada  $f_{c1}$ ,  $f_{c2}$  e  $f_{c3}$ , e depois de filtrado, o sinal é amplificado para manter coerência de amplitude. Logo, o sinal de saída do filtro é um valor complexo mas centrado em torno das portadoras e amostrado em RF. O misturador possui o papel de deslocar a informação para frequência zero ao multiplicar pela portadora de sinal negativa ( $-f_{c1}$ ,  $-f_{c2}$  ou  $-f_{c3}$ ), ou seja

$$y_i = (y_i @ f_i) e^{-j2\pi f_i t} \quad (4.2)$$

onde  $i$  indica uma das 3 bandas. O misturador desloca a informação para BB mas a amostragem ainda está em RF. O bloco Amostrador BB é incluído para reduzir a frequência de amostragem para 120 MHz e gerar na saída as informações  $y_1$ ,  $y_2$  e  $y_3$ , conforme esperado para aplicar a modelagem ou linearização.

### 4.2.3 Configuração de dados e portadoras para as análises

Para as aplicações 2D e 3D as combinações utilizadas estão apresentadas na figura 4.7. Os dados Wi-Fi nas normas IEEE 802.11n e 802.11ac e LTE alimentam os casos avaliados. Para banda dupla concorrente, apenas situações de portadoras não múltiplas são avaliadas, logo as simulações são realizadas com as portadoras de 2,4 GHz e 3,5 GHz e utilizam os dados Wi-Fi na norma IEEE 802.11n e LTE, respectivamente. Para os testes realizados em banda tripla concorrente, os três sinais de entrada são aplicados nas portadoras 2,4 GHz, 3,5 GHz e 5,0 GHz para situações em que as portadoras não são múltiplas entre si e 1,8 GHz, 3,6 GHz e 5,4 GHz para os testes de portadoras múltiplas, respectivamente. A escolha das frequências de portadora para o caso de frequências múltiplas foi realizada com base na resposta em frequência que o PA disponível para testes atendessem (SCHUARTZ *et al.*, 2021).

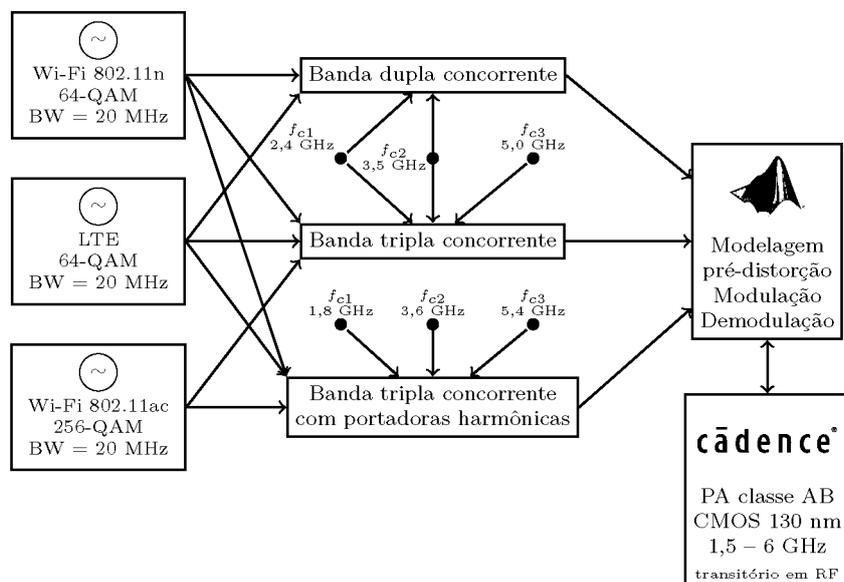


Figura 4.7: Diagrama de combinações das portadoras e sinais para cada teste aplicado.

Fonte – O autor, 2021.

As configurações apresentadas são utilizadas para configurar os esquemas de modulação e demodulação realizados no Matlab. Para o Cadence Virtuoso, as simulações não possuem configurações específicas, o próprio simulador define dinamicamente as configurações necessárias para as simulações. Devido ao custo computacional necessário para gerenciar arquivos amostrados em centenas de GHz, as simulações de validação e que possuem o vetor de dados completo para gerar as informações de EVM são divididas em

8 partes (cada simulação possui 8 simulações) contendo aproximadamente 5000 amostras cada. Para garantir que não haverá problemas de transição, é acrescentado 10% de transpasse descartado durante a demodulação no Matlab.

## CAPÍTULO 5

### RESULTADOS DE SIMULAÇÃO

Este capítulo apresenta os resultados de simulação obtidos para a modelagem e a linearização de transmissão de banda dupla e tripla concorrentes em relação ao método de aprendizagem, aos modelos de transmissão concorrente da literatura e propostos e para a saturação de banda dupla concorrente.

#### 5.1 Resultados em relação ao método de aprendizado para o cenário 2D

As aprendizagens direta, indireta e indireta modificada são aplicadas para a identificação dos parâmetros do DPD para transmissão de banda dupla concorrente utilizando sinais Wi-Fi IEEE 802.11n com modulação 64-QAM, 20 MHz de largura de banda e centrado em 2,4 GHz (canal 1) e LTE de modulação 64-QAM, com 20 MHz de largura de banda e centrado em 3,5 GHz (canal 2). As informações do circuito do PA são obtidas por simulações de transitório onde, a cada simulação, quatro sequências de valores complexos em banda-base são extraídas: duas entradas, uma para cada canal, e duas saídas, uma para cada canal.

Conforme apresentado na Seção 2.1.2.1, um PA atuando com comunicação concorrente gera termos de intermodulação cruzada entre as bandas independentes das frequências de portadora, logo, é necessário modelar esses efeitos para compensá-los ao aplicar a linearização. Apenas como ilustração dessa obrigatoriedade, a modelagem do comportamento do PA na configuração apresentada no início dessa seção é realizada com o MP para 1D (2.5) modelando isoladamente cada canal e 2D-MP (2.6) e (2.7) que considera as modulações cruzadas. As figuras 5.1a e 5.1b apresentam o melhor desempenho dos modelos em função do número de coeficientes comparando os modelos para os canais 1 e 2, respectivamente. Foram avaliados até 20 coeficientes fazendo uma varredura nos fatores de truncamento. Fica evidente que MP para 1D chega a um limite de desempenho próximo de  $-20$  dB e permanece constante independente do número de parâmetros, isso acontece porque o restante da distorção é dependente do canal concorrente e não está sendo considerado em (2.5). Por outro lado, o 2D-MP possui a base MP para 1D e acrescenta as componentes cruzadas, logo, o desempenho do modelo melhorou consideravelmente atingindo valores próximos a  $-35$  dB.

A comparação entre os modelos 1D e 2D foi realizada com MP e 2D-MP para tornar a necessidade de um modelo adequado compreensível. Entretanto, na literatura

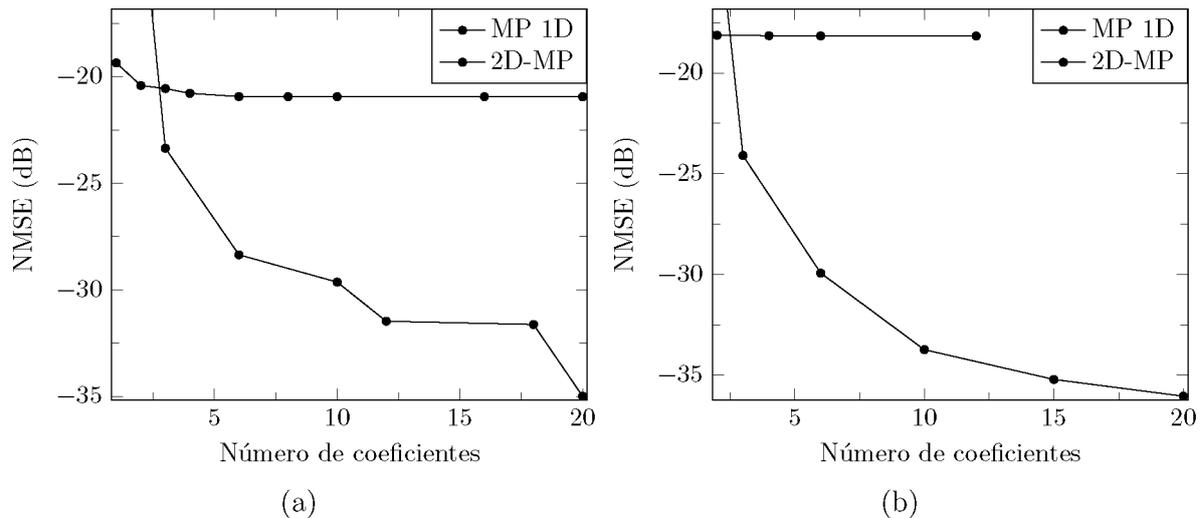


Figura 5.1: NMSE em função do número de coeficientes comparando MP para 1D modelando cada canal isoladamente e 2D-MP para (a) o canal 1; (b) o canal 2.

Fonte – O autor, 2021.

2D-MP não é o melhor caso para modelagem 2D. Dessa forma, a partir desse ponto os resultados são avaliados para o DPD implementando o modelo polinomial 2D-IMP (2.8) e (2.9) e modelo de redes neurais descrito na Seção 2.3.

### 5.1.1 Comparação entre as aprendizagens indireta tradicional e direta com um modelo matemático do circuito do PA

No que se refere à aprendizagem indireta, são necessárias duas simulações do PA sendo uma para cada iteração de extração de parâmetros. Na primeira iteração, o PA está amplificando sinais sem a pré-distorção, na segunda iteração, o PA já amplifica sinais pré-distorcidos da primeira iteração de aprendizado. Uma terceira simulação do PA é efetuada para validação do método de aprendizagem.

Em relação à aprendizagem direta, o PA não pode fazer parte da rotina de otimização devido ao custo de cada iteração e à quantidade significativa de iterações. Logo, o circuito do PA é substituído pelo modelo 2D-IMP em modelagem direta independentemente se o DPD implementa modelo polinomial ou redes neurais. O modelo do PA é obtido em quatro cenários distintos conforme segue. No cenário 1 o modelo é extraído da segunda iteração da aprendizagem indireta aplicando fatores de truncamento  $M = 1$ ,  $P = 4$  e  $Q = 4$ , nessa configuração, o NMSE de cada canal fica próximo de  $-40$  dB; no cenário 2 o modelo do PA é extraído da segunda iteração da aprendizagem indireta aplicando fatores de truncamento  $M = 1$ ,  $P = 2$  e  $Q = 1$  cujo NMSE é próximo de  $-30$  dB para cada canal; no cenário 3 o modelo do PA é extraído da primeira iteração da aprendizagem indireta com fatores de truncamento ajustados para  $M = 2$ ,  $P = 5$  e  $Q = 4$ , nessa configuração o NMSE de cada canal é aproximadamente  $-40$  dB; e no

cenário 4 o modelo é extraído da segunda iteração da aprendizagem indireta com fatores ajustados para  $M = 1$ ,  $P = 2$  e  $Q = 0$  com NMSE de  $-20$  dB aproximadamente. A tabela 5.1 resume os cenários de testes.

Tabela 5.1: Resumo das configurações dos cenários de testes.

|           |  |
|-----------|--|
| Cenário 1 | Modelo bom da segunda iteração da aprendizagem indireta              |
| Cenário 2 | Modelo parcialmente bom da segunda iteração da aprendizagem indireta |
| Cenário 3 | Modelo bom da primeira iteração da aprendizagem indireta             |
| Cenário 4 | Modelo ruim da segunda iteração da aprendizagem indireta             |

Fonte – O autor, 2021.

A tabela 5.2 apresenta o desempenho do PA em banda dupla concorrente e os EVMs dos canais 1 e 2 obtidos do sinal de saída do PA após aplicar a linearização com as aprendizagens indireta e direta para os cenários descritos. As figuras 5.2a e 5.2b apresentam a resposta em amplitude do sistema linearizado aplicando as abordagens indireta e direta nos cenários distintos para os canais 1 e 2, respectivamente; e as figuras 5.3a e 5.3b apresentam as PSDs da saída do PA para os respectivos canais. Os fatores de truncamento aplicados para o DPD na primeira iteração foram  $M = 2$ ,  $P = 8$  e  $Q = 6$ , e na segunda iteração  $M = 2$ ,  $P = 6$  e  $Q = 7$  para todos os testes da tabela 5.2. Os dados de extração são separados em extração e validação, cada iteração possui dados distintos, exceto para a última validação, onde o número de amostras deve conter o vetor completo para métrica do EVM. Na aprendizagem direta foi aplicada a função de otimização *fminunc* (Seção 2.4.2) cuja função objetivo é definida conforme (2.20) entre a entrada do DPD e a saída do modelo do PA, onde o critério de parada e as restrições de busca são mantidos conforme a configuração padrão. A estimativa inicial é o resultado obtido com LS (2.18).

Ambas as abordagens, direta para todos os cenários e indireta, com modelo polinomial apresentam capacidades muito próximas de linearização para potências de saída muito próximas. Entretanto, as aprendizagens indireta e direta no cenário 1 obtiveram mesmo EVM. Degradações mínimas de EVM são verificadas para os demais cenários onde os modelos do PA possuem acurácia inferior. O caso mais crítico foi o cenário 3, este efeito foi consequência de um modelo extraído em um cenário diferente do comportamento do PA com sinais de entrada pré-distorcidos.

Pelas figuras de transferência de amplitude, todos os pontos estão sobrepostos, indicando alta linearidade em todos os testes. Pelas curvas de PSD, a aprendizagem indireta obteve o mesmo resultado que a aprendizagem direta nos cenários 1 e 2. Uma leve degradação de desempenho é perceptível para o cenário 4, onde o modelo do PA possui fatores de truncamento reduzidos, o que compromete a acurácia do modelo, e uma degradação mais significativa para o cenário 3 devido ao modelo não ter sido extraído do

Tabela 5.2: Resultados de desempenho do PA em banda dupla concorrente linearizado com 2D-IMP e aprendizagens indireta e direta.

|                               | $P_{CC}$<br>(mW) | $P_{out}$<br>(dBm) | PAE<br>(%) | EVM<br>Wi-Fi<br>(%) | EVM<br>LTE<br>(%) |
|-------------------------------|------------------|--------------------|------------|---------------------|-------------------|
| Aprendizagem indireta         | 827,98           | 17,81              | 7,28       | 0,87                | 1,05              |
| Aprendizagem direta cenário 1 | 827,98           | 17,81              | 7,28       | 0,87                | 1,05              |
| Aprendizagem direta cenário 2 | 827,99           | 17,81              | 7,28       | 0,89                | 1,08              |
| Aprendizagem direta cenário 3 | 827,54           | 17,84              | 7,34       | 1,24                | 1,40              |
| Aprendizagem direta cenário 4 | 827,98           | 17,81              | 7,28       | 0,92                | 1,13              |

Fonte – O autor, 2021.

PA estimulado com dados pré-distorcidos. Os resultados apontam que a aprendizagem direta pode, eventualmente, apresentar desempenho melhor para transmissão em banda dupla concorrente, mas o modelo precisa apresentar acurácia elevada e ser extraído em um cenário onde o PA atua com dados pré-distorcidos. Contudo, o cenário no qual são extraídos os dados do modelo de PA é uma característica mais efetiva que a acurácia.

Os testes realizados com modelo polinomial também são executados aplicando redes neurais mantendo as mesmas configurações de cenários, o modelo do PA é mantido com 2D-IMP, apenas o modelo do DPD é substituído por redes neurais. A rede neural é formada manualmente com  $M = 2$  e  $R = 3$ , utiliza valores complexos e é treinada com a função *fminunc* onde a função objetivo é o erro (2.20) entre entrada do DPD e saída do modelo do PA. A estimativa inicial dos pesos é  $10^{-3}$ , o número máximo de vezes que a função pode ser avaliada é  $10^6$  e número máximo de iterações de otimização é  $10^4$ .

A tabela 5.3 apresenta os resultados comparativos entre a aprendizagem indireta e direta nos cenários 1 ao 4 em banda dupla concorrente.

Os resultados da tabela apontam que o sistema linearizado com redes neurais aplicando aprendizagem direta tem capacidade de gerar resultados melhores do que a aprendizagem indireta. Em particular, reduções de 0,02 p.p. e 0,27 p.p. para a métrica de EVM são obtidas pela aprendizagem direta com cenário 1 em relação à aprendizagem indireta. Por outro lado, a dependência de um modelo de acurácia elevada torna-se significativa, o aumento do EVM para os cenários 2 e 4 demonstram essa necessidade. Já o uso de um modelo de PA extraído usando sinais não pré-distorcidos, indicado pelo cenário 3, apesar de ser significativo devido ao aumento do EVM, não é tanto quanto a

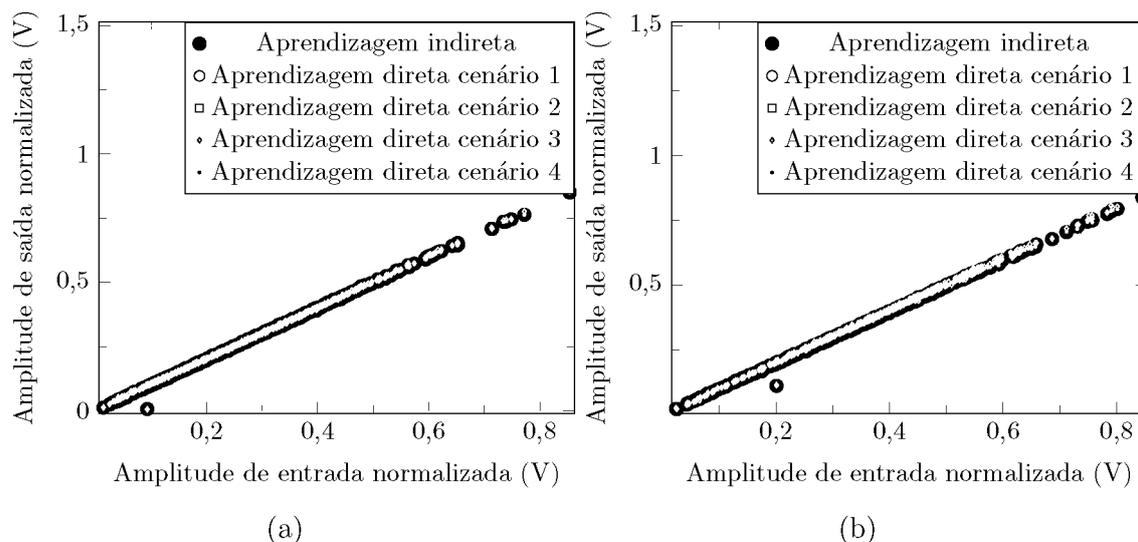


Figura 5.2: Resposta em amplitude do sistema de banda dupla concorrente linearizado com 2D-IMP utilizando as aprendizagens indireta e direta nos cenários 1 ao 4 para (a) o canal 1; (b) o canal 2.

Fonte – O autor, 2021.

acurácia exigida. As figuras 5.4a, 5.4b, 5.5a e 5.5b apresentam as respostas de amplitude dos canais 1 e 2 e as PSDs de saída do sistema dos canais 1 e 2 do sistema de banda dupla concorrente linearizado com redes neurais.

Pelas respostas de amplitude das figuras 5.4a e 5.4b, apenas para o cenário 4 do canal 1 fica mais evidente um comprometimento da linearidade. Os demais cenários apresentam linearidade considerável indicando compensação efetiva de não linearidade e memória. Por outro lado, observando as PSDs apresentadas pelas figuras 5.5a e 5.5b, a diferença entre os cenários torna-se perceptível. Novamente o melhor resultado, com menor potência nos canais adjacentes, é obtido pela aprendizagem direta no cenário 1, seguido da aprendizagem indireta. Já nos cenários 2 e 4, onde há a degradação da acurácia do modelo do PA, o desempenho da linearização é pior que para o cenário 3, onde a acurácia é elevada, mas o modelo do PA é extraído usando sinais não pré-distorcidos.

Em resumo, aplicando modelo 2D-IMP para o DPD, a aprendizagem indireta apresentou melhor desempenho e isso é consequência do modelo do PA ser extraído usando sinais pré-distorcidos. Por outro lado, aplicando redes neurais, a aprendizagem direta apresentou o melhor resultado. Entretanto, a dependência de um modelo com acurácia elevada e modelo de PA extraído usando sinais pré-distorcidos é o principal fator limitante nessas situações.

### 5.1.2 Desempenho da aprendizagem indireta modificada

No que se refere à aprendizagem indireta modificada, as duas iterações de aprendizagem indireta tradicional são mantidas e, da terceira em diante, a modificação da

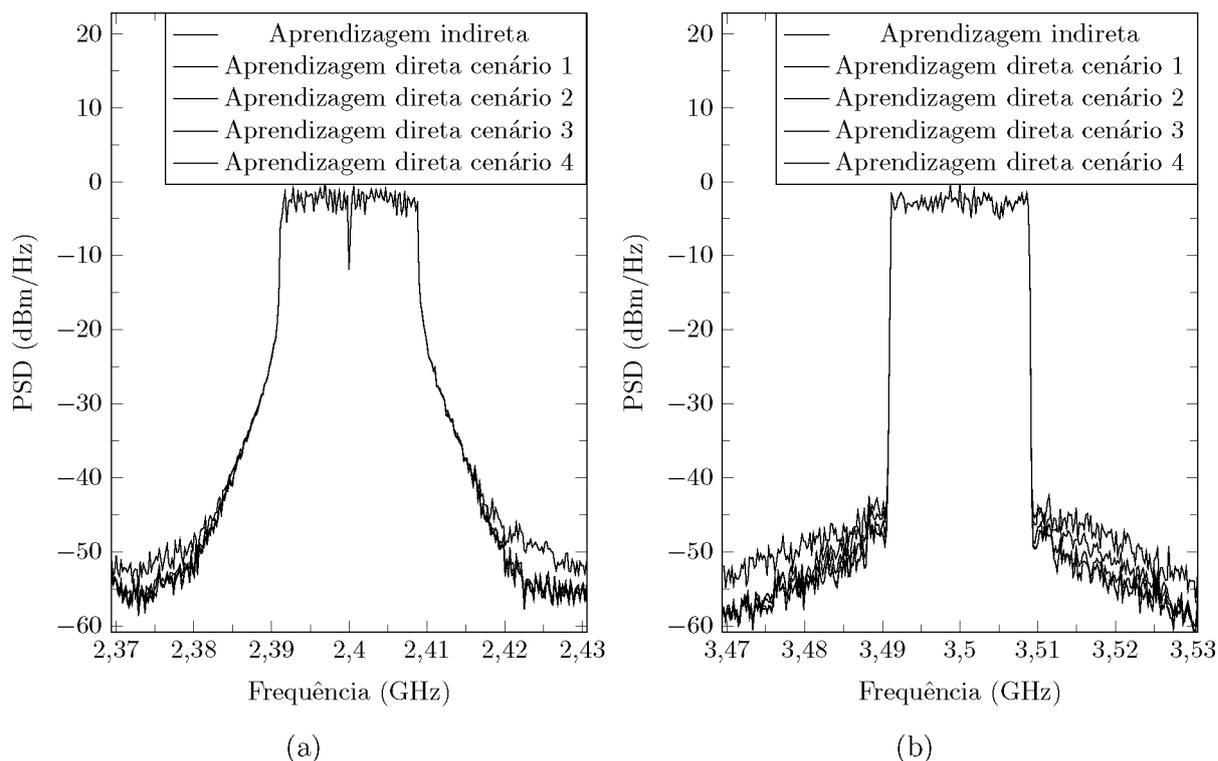


Figura 5.3: PSD obtida do sinal de saída do sistema de banda dupla concorrente linearizado com 2D-IMP utilizando as aprendizagens indireta e direta nos cenários 1 ao 4 para (a) o canal 1; (b) o canal 2.

Fonte – O autor, 2021.

figura 3.3 é aplicada. A aprendizagem indireta modificada busca melhorar o desempenho da linearização sem a necessidade de avaliar o comportamento do PA várias vezes ou depender de um modelo adequado do PA. A cada iteração adicionada, uma simulação de transitório do circuito do PA é efetuada. Apesar da necessidade de novas simulações do PA, a quantidade de iterações é significativamente menor do que aquela exigida pela aprendizagem direta.

Em uma primeira avaliação da abordagem proposta, a métrica NMSE é utilizada para verificar o comportamento da extração. As figuras 5.6a e 5.6b apresentam estes resultados para a aprendizagem indireta modificada aplicando modelo polinomial 2D-IMP e redes neurais, respectivamente.

As iterações 1 e 2 de ambas as figuras indicam os desempenhos de linearidade atingidos após a primeira e segunda iterações da aprendizagem indireta tradicional avaliados pelo NMSE, respectivamente. Os erros diminuem consideravelmente entre a primeira e segunda iterações. Isso é consequência da mudança de comportamento do PA entre a primeira e segunda iterações. Novas iterações da aprendizagem tradicional não modificam o comportamento do PA da segunda iteração. Por outro lado, a modificação sugerida a partir da terceira iteração permite que o DPD implemente uma inversa mais exata do PA. De fato as figuras 5.6a e 5.6b apresentam aumento de linearidade reduzindo o NMSE

Tabela 5.3: Resultados de desempenho do PA em banda dupla concorrente linearizado com redes neurais e aprendizagens indireta e direta.

|                               | $P_{CC}$<br>(mW) | $P_{out}$<br>(dBm) | PAE<br>(%) | EVM<br>Wi-Fi<br>(%) | EVM<br>LTE<br>(%) |
|-------------------------------|------------------|--------------------|------------|---------------------|-------------------|
| Aprendizagem indireta         | 827,87           | 17,82              | 7,29       | 1,07                | 1,76              |
| Aprendizagem direta cenário 1 | 827,86           | 17,82              | 7,29       | 1,05                | 1,49              |
| Aprendizagem direta cenário 2 | 827,86           | 17,81              | 7,28       | 2,81                | 3,47              |
| Aprendizagem direta cenário 3 | 823,58           | 18,03              | 7,69       | 1,63                | 1,91              |
| Aprendizagem direta cenário 4 | 827,76           | 17,81              | 7,29       | 9,59                | 6,90              |

Fonte – O autor, 2021.

em até 1,92 dB e 1,49 dB para os canais 1 e 2 utilizando modelo polinomial e 5,26 dB e 4,95 dB para os canais 1 e 2 utilizando redes neurais, respectivamente. Para redes neurais a redução foi mais significativa, de forma que o mínimo atingido pelo modelo polinomial e redes neurais teve diferença menor de 0,15 dB, enquanto essa mesma diferença aplicando a aprendizagem indireta tradicional é maior que 3,22 dB. Não existe uma garantia em obter o melhor resultado com 16 iterações, entretanto existe uma tendência de mínimo para o canal Wi-Fi o que indica possivelmente uma degradação contínua a partir desse ponto.

Para validar o desempenho da linearização aplicando a aprendizagem proposta, novas simulações para os parâmetros obtidos nas iterações 2, 6, 11 e 16 são realizadas. As tabelas 5.4 e 5.5 apresentam os resultados para modelo polinomial 2D-IMP e redes neurais, respectivamente. As figuras 5.7a e 5.7b mostram as PSDs do PA linearizado para as iterações 2, 6, 11 e 16 e sem linearização aplicando 2D-IMP na modelagem indireta modificada para os canais 1 e 2, e as figuras 5.8a e 5.8b mostram as PSDs do PA linearizado para as iterações 2, 6, 11 e 16 e sem linearização aplicando redes neurais na modelagem indireta modificada para os canais 1 e 2, respectivamente.

A modificação proposta no sistema linearizado com 2D-IMP possibilitou um leve aumento de linearidade mensurada pelo EVM, atingindo reduções de até 0,08 p.p. e 0,07 p.p. para os canais 1 e 2 em comparação com a aprendizagem indireta tradicional (2 iterações). Por outro lado, implementando redes neurais, reduções de até 0,20 p.p. e 0,63 p.p. foram obtidas sem a necessidade de impor quantidades severas de iterações com o PA e sem a necessidade de um modelo do PA durante a extração para os canais

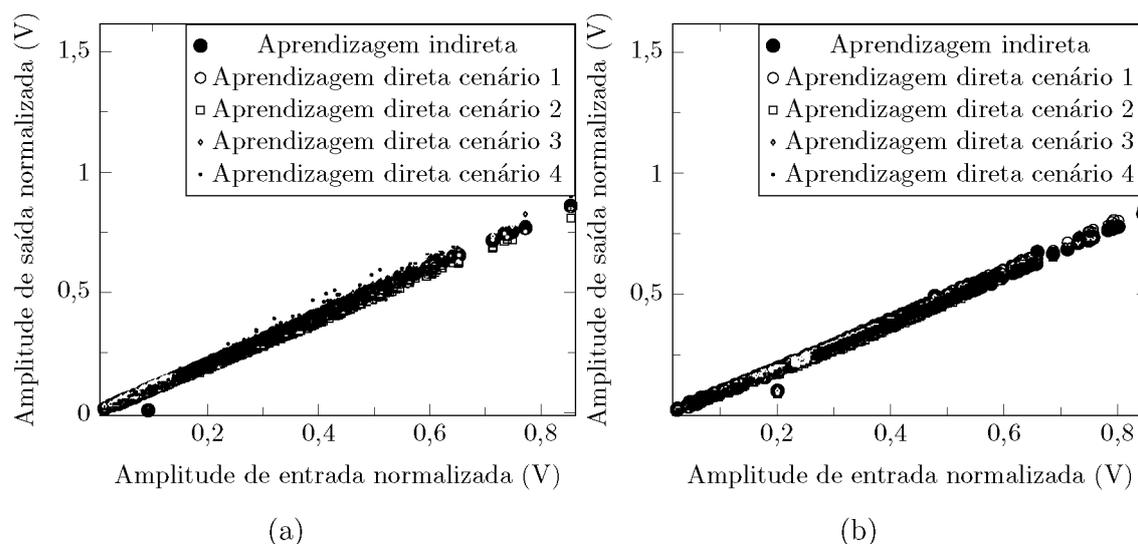


Figura 5.4: Resposta em amplitude do sistema de banda dupla concorrente linearizado com redes neurais utilizando as aprendizagens indireta e direta nos cenários 1 ao 4 para (a) o canal 1; (b) o canal 2.

Fonte – O autor, 2021.

1 e 2, respectivamente. As figuras de PSD ajudam a evidenciar este resultado. Para modelo polinomial o resultado se manteve com as iterações, por outro lado, para redes neurais a melhora foi evidente principalmente para o canal LTE, inclusive os resultados foram melhores que a aprendizagem direta, reduzindo o EVM em 0,18 p.p. e 0,36 p.p. Em termos de porcentagem, a modificação proposta permitiu reduzir o EVM em até 9% (de 0,87% para 0,79%) e 36% (de 1,79% para 1,13%) para 2D-IMP e redes neurais em relação ao melhor resultado dos métodos tradicionais, respectivamente. Os resultados sem linearização foram incluídos nas tabelas 5.4 e 5.5 para evidenciar o quanto a inclusão de um sistema de linearização é efetivo para compensar a não linearidade, o efeito de memória e a intermodulação cruzada.

## 5.2 Resultados em relação aos modelos propostos

Os resultados sobre os modelos propostos e o algoritmo AscFat são apresentados como segue. A Seção 5.2.1 apresenta os resultados comparativos entre o modelo 2D proposto comparado com os modelos da literatura, a busca exaustiva também é comparada com o algoritmo AscFat proposto; a Seção 5.2.2 apresenta os resultados em cenários de modelagem e linearização 3D com escolha de fatores por busca exaustiva e algoritmo AscFat; e a Seção 5.2.3 apresenta os resultados para um cenário 3D de portadoras múltiplas. O algoritmo AscFat é comparado apenas com a busca exaustiva porque não é conhecida uma metodologia na literatura específica para essa finalidade.

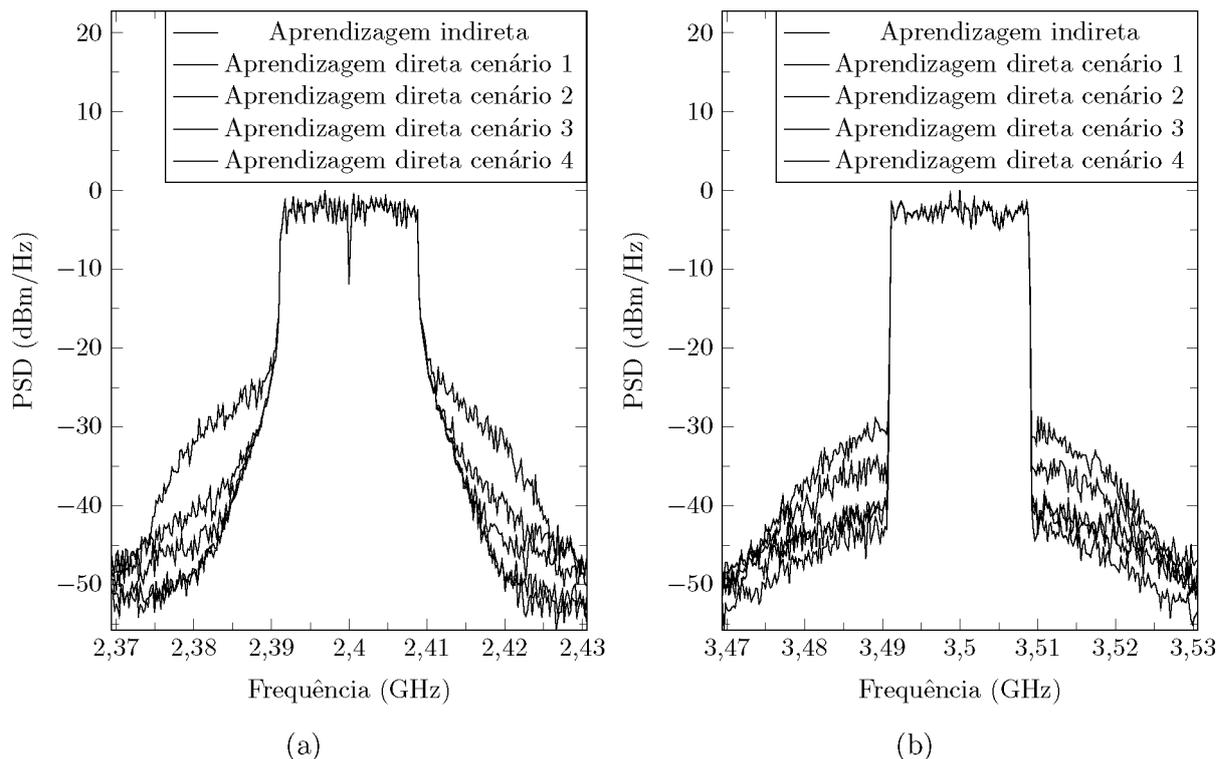


Figura 5.5: PSD obtida do sinal de saída do sistema de banda dupla concorrente linearizado com redes neurais utilizando as aprendizagens indireta e direta nos cenários 1 ao 4 para (a) o canal 1; (b) o canal 2.

Fonte – O autor, 2021.

### 5.2.1 Desempenho do modelo 2D proposto e validação em 2D do algoritmo AscFat proposto

Os testes para os modelos 2D e validação do algoritmo AscFat são efetuados com dados obtidos do PA CMOS simulados no Cadence Virtuoso estimulado com dados de entrada Wi-Fi IEEE 802.11n de 20 MHz de largura de banda centrado em 2,4 GHz (canal 1) e LTE de 20 MHz de largura de banda centrado em 3,5 GHz (canal 2) sem aplicar pré-distorção.

Em uma primeira abordagem os modelos da literatura são comparados aplicando a modelagem inversa variando os fatores de truncamento com a busca exaustiva. O 2D-MP (2.6) e (2.7) é avaliado com  $P$  limitado em 5 e  $M$  limitado em 3, armazenando os resultados das combinações relevantes, onde o NMSE é menor que aqueles com menos parâmetros. O 2D-IMP (2.8) e (2.9) é avaliado com busca exaustiva variando os fatores de truncamento limitados em  $Q = P = 6$  e  $M = 3$ , na primeira situação a condição  $q + p < P$  não está incluída e na segunda situação a condição está incluída. Em uma segunda abordagem, o modelo proposto 2D-MIMP (3.1) é avaliado com busca exaustiva e com algoritmo AscFat. A busca exaustiva possui quantidade limitada de coeficientes devido à demanda computacional. Para ambos os casos, os fatores de truncamento de

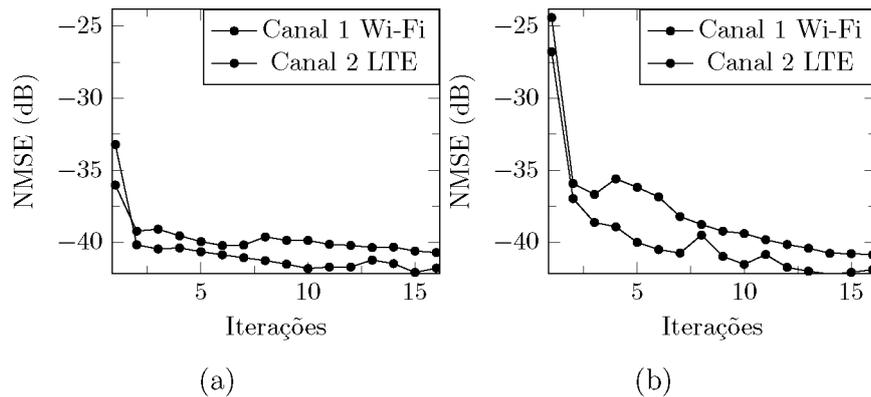


Figura 5.6: NMSE de extração *vs.* as iterações de aprendizagem indireta modificada para o sistema de banda dupla concorrente aplicando (a) modelo 2D-IMP; (b) redes neurais.

Fonte – O autor, 2021.

Tabela 5.4: Resultados de desempenho do PA em banda dupla concorrente linearizado com 2D-IMP e aprendizagem indireta modificada.

|              | $P_{CC}$<br>(mW) | $P_{out}$<br>(dBm) | PAE<br>(%) | EVM<br>Wi-Fi<br>(%) | EVM<br>LTE<br>(%) |
|--------------|------------------|--------------------|------------|---------------------|-------------------|
| Iteração 2 * | 827,98           | 17,81              | 7,28       | 0,87                | 1,05              |
| Iteração 6   | 828,46           | 17,77              | 7,22       | 0,81                | 1,02              |
| Iteração 11  | 829,01           | 17,73              | 7,14       | 0,79                | 1,00              |
| Iteração 16  | 829,48           | 17,69              | 7,07       | 0,79                | 0,98              |
| Sem DPD      | 827,00           | 17,81              | 7,29       | 8,26                | 9,93              |

\* Aprendizagem indireta tradicional conforme a literatura.

Fonte – O autor, 2021.

não linearidade são todos limitados em 6, enquanto os comprimentos de memória estão limitados em 3. Por fim, na terceira abordagem o modelo 2D-MIMP aplicando algoritmo AscFat é comparado ao modelo 2D-IMP impondo a mesma condição de restrições de fatores de truncamento. As figuras 5.9a e 5.9b apresentam os resultados para os canais 1 e 2, respectivamente.

Na primeira abordagem, são encontradas diferenças ao aplicar 2D-IMP com ou sem a condição  $p + q < P$ . Em particular, quando a condição é aplicada o desempenho do modelo fica melhor em função do número de coeficientes. Isso acontece porque a condição evita que vários parâmetros não significativos sejam incluídos no modelo de tal forma que, sem essa condição, o modelo 2D-IMP apresenta desempenho pior do que o próprio 2D-MP que é um caso particular do 2D-IMP. Por outro lado, os desempenhos do 2D-IMP com a condição e do 2D-MP estão próximos para este estudo de caso. Em geral os pontos apresentados pelo 2D-MP se sobrepõem com os do 2D-IMP, entretanto o 2D-IMP permite mais combinações do que aqueles pontos sobrepostos. Por exemplo, ambos os modelos

Tabela 5.5: Resultados de desempenho do PA em banda dupla concorrente linearizado com redes neurais e aprendizagem indireta modificada.

|              | $P_{CC}$<br>(mW) | $P_{out}$<br>(dBm) | PAE<br>(%) | EVM<br>Wi-Fi<br>(%) | EVM<br>LTE<br>(%) |
|--------------|------------------|--------------------|------------|---------------------|-------------------|
| Iteração 2 * | 827,87           | 17,82              | 7,29       | 1,07                | 1,76              |
| Iteração 6   | 828,37           | 17,78              | 7,22       | 0,89                | 1,56              |
| Iteração 11  | 829,16           | 17,72              | 7,11       | 0,88                | 1,21              |
| Iteração 16  | 829,83           | 17,66              | 7,02       | 0,87                | 1,13              |
| Sem DPD      | 827,00           | 17,81              | 7,29       | 8,26                | 9,93              |

\* Aprendizagem indireta tradicional conforme a literatura.

Fonte – O autor, 2021.

apresentam resultados iguais em 20 e 30 coeficientes nos dois canais, mas o 2D-IMP com a condição permite uma combinação com 28 coeficientes melhor do que com 20 e o 2D-MP não permite. Dessa forma o 2D-IMP com a condição será utilizado como modelo da literatura a ser comparado.

Na segunda abordagem o modelo proposto 2D-MIMP apresenta a redução do NMSE em função do número de coeficientes de forma muito similar quando é aplicada a busca exaustiva ou o algoritmo AscFat. Diversos pontos azuis se sobrepõem aos vermelhos, e isso indica que o AscFat possibilitou obter mesmas configurações do que a busca exaustiva, em contra partida o AscFat negligencia algumas combinações possíveis. A maior vantagem do AscFat é o montante de avaliações do modelo, teoricamente seriam necessárias 90 avaliações por canal do modelo para obter até 6 parâmetros. Entretanto com as restrições foram necessárias 36 e 28 avaliações para os canais 1 e 2, respectivamente, enquanto a busca exaustiva exigiu 986 avaliações só para 6 coeficientes por canal e 1489 para obter de 1 a 6 coeficientes por canal.

Na terceira abordagem, para o canal 1 torna-se nítida uma diferença de convergência do modelo proposto em relação ao 2D-IMP. Para o canal 2, a diferença torna-se significativa acima de 20 coeficientes. A maior diferença de NMSE entre o 2D-MIMP com o algoritmo AscFat e 2D-IMP com a condição e aplicando a busca exaustiva para os canais 1 e 2 foi de 3,76 dB e 2,76 dB, respectivamente.

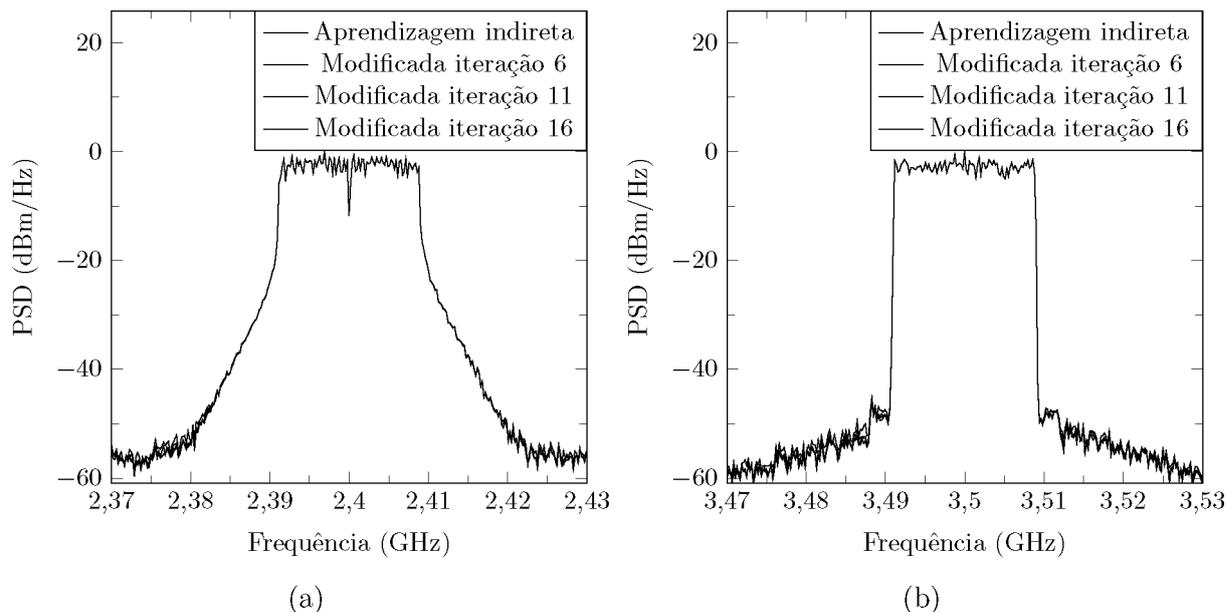


Figura 5.7: PSDs extraídos do sinal de saída do sistema de banda dupla concorrente linearizado com a aprendizagem indireta modificada aplicando modelo 2D-IMP nas iterações 2, 6, 11, e 16 para (a) cana 1; (b) canal 2.

Fonte – O autor, 2021.

### 5.2.2 Comparação entre os modelos 3D da literatura, desempenho do modelo 3D proposto e validação em 3D do algoritmo AscFat proposto em cenários de portadoras não múltiplas

Esta seção aborda resultados comparativos entre os modelos da literatura mencionados na Seção 2.2.3, entre os modelos da literatura 3D-MP, 3D-MB e o modelo proposto 3D-IMP, validação do algoritmo AscFat e desempenho de linearização do modelo proposto com algoritmo AscFat em transmissão de banda tripla concorrente com portadoras não múltiplas.

Para as validações de modelagem, os dados são extraídos do PA em teste estimulado com sinais Wi-Fi IEEE 802.11n de modulação 64-QAM de banda de 20 MHz centrado em 2,4 GHz (canal 1), LTE com modulação 64-QAM de banda 20 MHz e centrado em 3,5 GHz (canal 2), e Wi-Fi IEEE 802.11ac de modulação 256-QAM de banda 20 MHz e centrado em 5,0 GHz (canal 3). O PA é avaliado com simulações de transitório em RF. Os resultados de entrada e saída são demodulados para as envoltórias dos sinais em banda base com frequência de amostragem de 120 MHz. Os três canais possuem a mesma amplitude de entrada de forma que o PA gera  $P_{out}$  de 18,3 dBm, consome 815 mW de potência contínua e apresenta PAE de 8,33%. As envoltórias coletadas são divididas em dados de extração e validação.

Os modelos mencionados da literatura são comparados em um mesmo cenário de

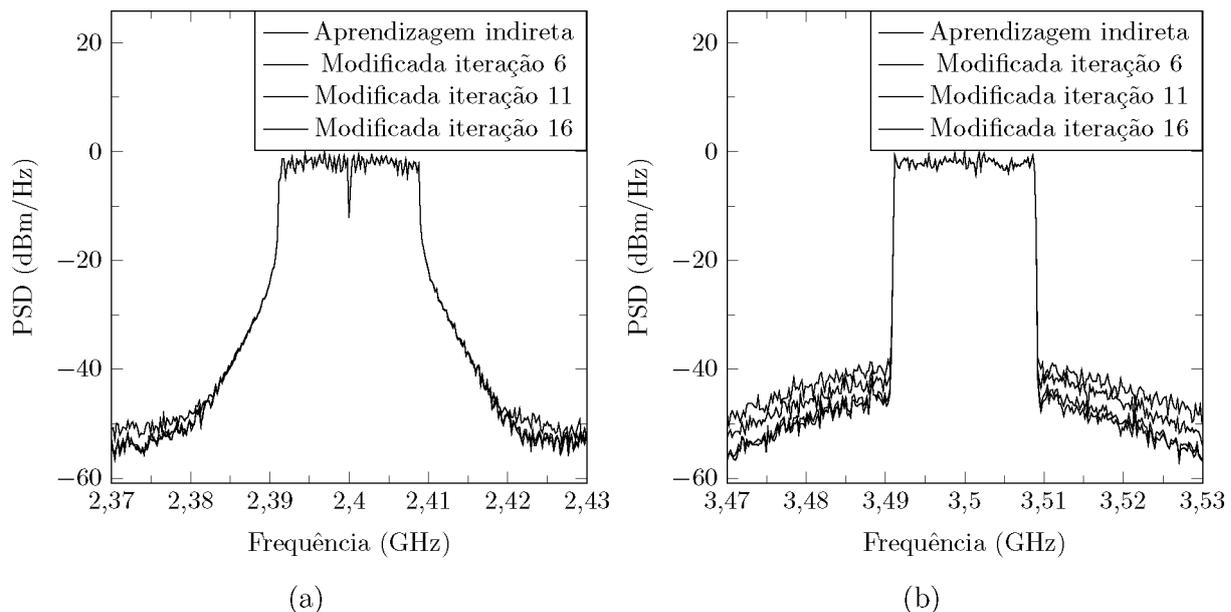


Figura 5.8: PSDs extraídos do sinal de saída do sistema de banda dupla concorrente linearizado com a aprendizagem indireta modificada aplicando redes neurais nas iterações 2, 6, 11, e 16 para (a) cana 1; (b) canal 2.

Fonte – O autor, 2021.

modelagem inversa. As figuras 5.10a, 5.10b e 5.10c apresentam os melhores resultados de NMSE em função do número de parâmetros para os canais 1, 2 e 3, respectivamente. Os resultados são obtidos com a busca exaustiva variando os fatores de truncamento do valor mínimo ao 3 para comprimento de memória e ao 6 para não linearidade.

Os melhores resultados das figuras apresentam desempenho superior do 3D-MB em relação aos demais, enquanto que os outros modelos ficaram próximos ao 3D-MP. Na sequência, o modelo proposto é comparado ao 3D-MB e ao 3D-MP. As figuras 5.11a, 5.11b e 5.11c apresentam as melhores configurações de NMSE possíveis em função do número de parâmetros para os canais 1, 2 e 3, respectivamente. Para os modelos da literatura, apenas a busca exaustiva é aplicada, e para o modelo proposto, o algoritmo AscFat e a busca exaustiva, limitada a poucos parâmetros, são aplicados. Os fatores de truncamento são variados e limitados em 3 para comprimento de memória e em 6 para não linearidade. Para 3D-MP, dois fatores são avaliados ( $M$  e  $P$ ), para 3D-MB cinco fatores distintos são avaliados ( $P_1$ ,  $P_2$ ,  $P_3$ ,  $M_1$ , e  $M_2$ ) e para 3D-IMP, 20 fatores distintos são avaliados ( $P_1$ ,  $P_2$ ,  $P_3$ ,  $P_4$ ,  $P_5$ ,  $P_6$ ,  $P_7$ ,  $P_8$ ,  $Q_1$ ,  $Q_2$ ,  $Q_3$ ,  $Q_4$ ,  $R_1$ ,  $R_2$ ,  $R_3$ ,  $R_4$ ,  $M_1$ ,  $M_2$ ,  $M_3$  e  $M_4$ ).

O algoritmo AscFat proposto para a escolha dos fatores de truncamento apresentou desempenho muito próximo à busca exaustiva, mesmo apresentando uma leve diferença em algumas regiões, o resultado ainda assim é próximo à escolha ideal. Os resultados de 3D-MP e 3D-MB foram mantidos para compará-los ao modelo proposto com algoritmo AscFat. Para até 40 parâmetros, os maiores ganhos de NMSE do 3D-IMP em relação ao 3D-MP foram de 6,8 dB, 6,7 dB e 8,2 dB para os canais 1, 2 e 3, respecti-

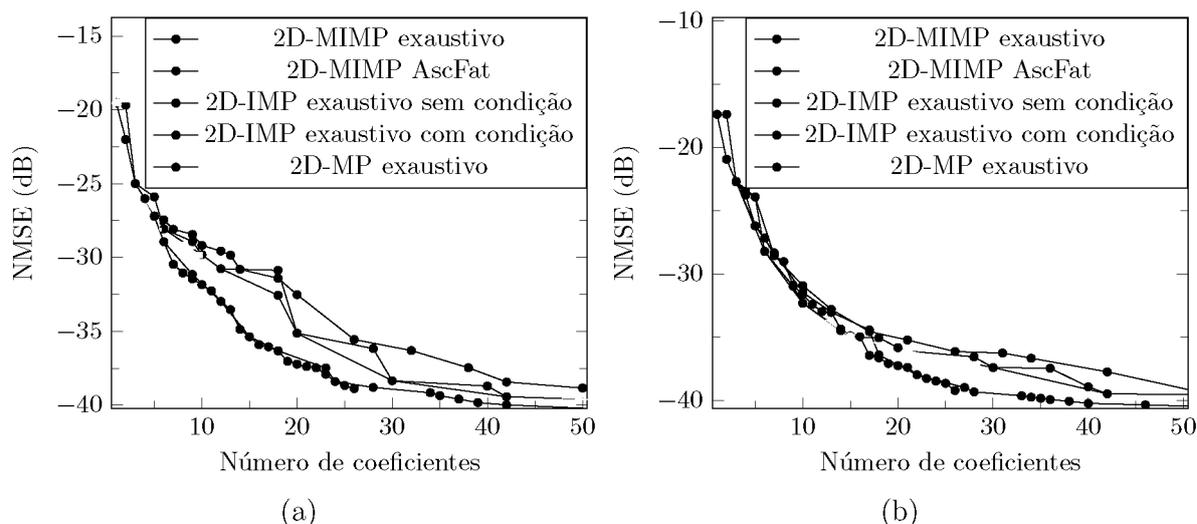


Figura 5.9: Melhor combinação do NMSE *vs.* o número de coeficientes comparando os modelos 2D-IMP com restrição e sem restrição, 2D-MP da literatura aplicando busca exaustiva e 2D-MIMP proposto com busca exaustiva e com algoritmo AscFat na modelagem inversa de banda dupla concorrente para o (a) canal 1; (b) canal 2.

Fonte – O autor, 2021.

vamente, e do 3D-IMP em relação ao 3D-MB foram de 5,9 dB, 6,1 dB e 8,3 dB para os canais 1, 2 e 3, respectivamente. Como o 3D-MB apresenta a curva de NMSE em função do número de parâmetros abaixo da curva do 3D-MP, apenas o 3D-MB será aplicado como o modelo da literatura.

Os melhores fatores de truncamento, que geram até 20 parâmetros para cada canal com 3D-MB utilizando busca exaustiva e 3D-IMP adotando AscFat, são aplicados como modelos para o DPD. Os parâmetros do DPD são extraídos com a aprendizagem indireta tradicional de duas iterações e extração com LS. Os resultados de validação comparativos de desempenho do sistema linearizado com 3D-MB, 3D-IMP e sem linearização estão apresentados na tabela 5.6.

Tabela 5.6: Resultados de desempenho do sistema em banda tripla concorrente com portadoras não múltiplas, linearizado com 3D-MB e 3D-IMP limitados a 20 coeficientes.

|         | $P_{CC}$<br>(mW) | $P_{out}$<br>(mW) | PAE<br>(%) | EVM<br>Canal 1<br>(%) | EVM<br>Canal 2<br>(%) | EVM<br>Canal 3<br>(%) |
|---------|------------------|-------------------|------------|-----------------------|-----------------------|-----------------------|
| 3D-MB   | 830,18           | 17,62             | 6,95       | 0,90                  | 1,07                  | 1,38                  |
| 3D-IMP  | 830,25           | 17,61             | 6,93       | 0,66                  | 0,96                  | 0,99                  |
| Sem DPD | 829,52           | 17,62             | 6,96       | 6,75                  | 7,26                  | 8,49                  |

Fonte – O autor, 2021.

Para  $P_{out}$  próximas, ambos os modelos apresentam ganho significativo de linearidade indicados pelo EVM, onde as reduções ficaram acima de 5,85 p.p. e 6,09 p.p. para

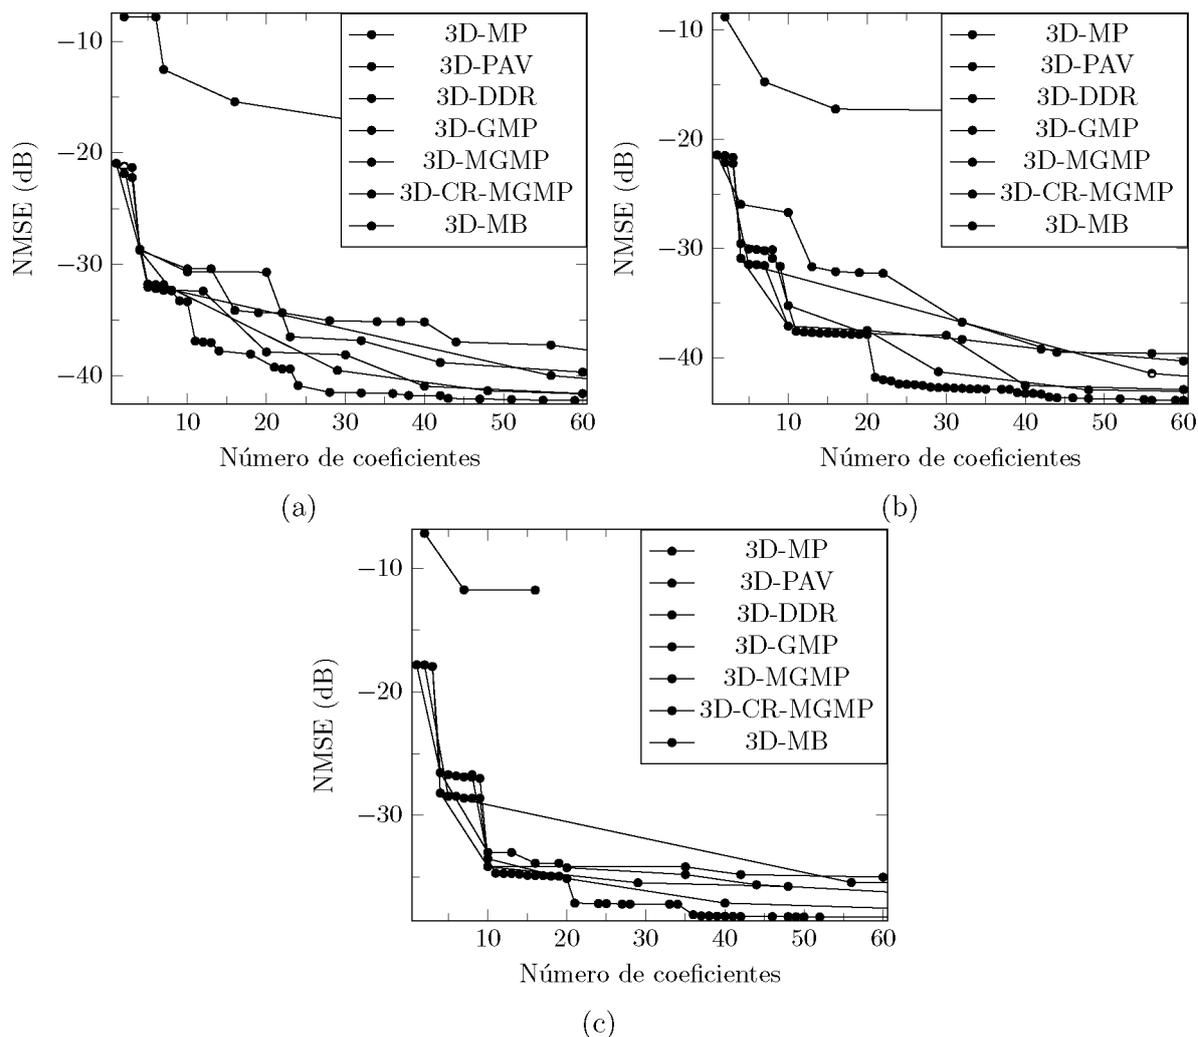


Figura 5.10: NMSE *vs.* o número de coeficientes comparando os modelos da literatura na modelagem banda tripla concorrente com portadoras não múltiplas para o (a) canal 1; (b) canal 2; (c) canal 3.

Fonte – O autor, 2021.

3D-MB e 3D-IMP comparados ao sistema não linearizado, respectivamente. Entretanto, ganhos adicionais de 0,24 p.p., 0,11 p.p. e 0,39 p.p. são obtidos pelo modelo proposto 3D-IMP em relação ao modelo da literatura 3D-MB para o montante de coeficientes limitado em 20. Os desempenhos dos modelos também são comparados pelas PSDs obtidas do sinal de saída do PA, representadas nas figuras 5.12a, 5.12b e 5.12c para os canais 1, 2 e 3, respectivamente, e pela magnitude do erro entre entrada e saída do sistema em função do tempo dos canais 1, 2 e 3 apresentado pelas figuras 5.13a, 5.13b e 5.13c, respectivamente.

As figuras de PSD apresentam redução significativa de potência nos canais adjacentes com o uso da linearização, entretanto uma redução levemente maior, principalmente para os canais 1 e 3, é obtida ao se aplicar o modelo proposto, devido à maior acurácia para mesma quantidade de coeficientes. As figuras de erro confirmam o resultado de linearidade, onde o 3D-MB mostrou resultado mais significativo apenas no canal 2 e o modelo

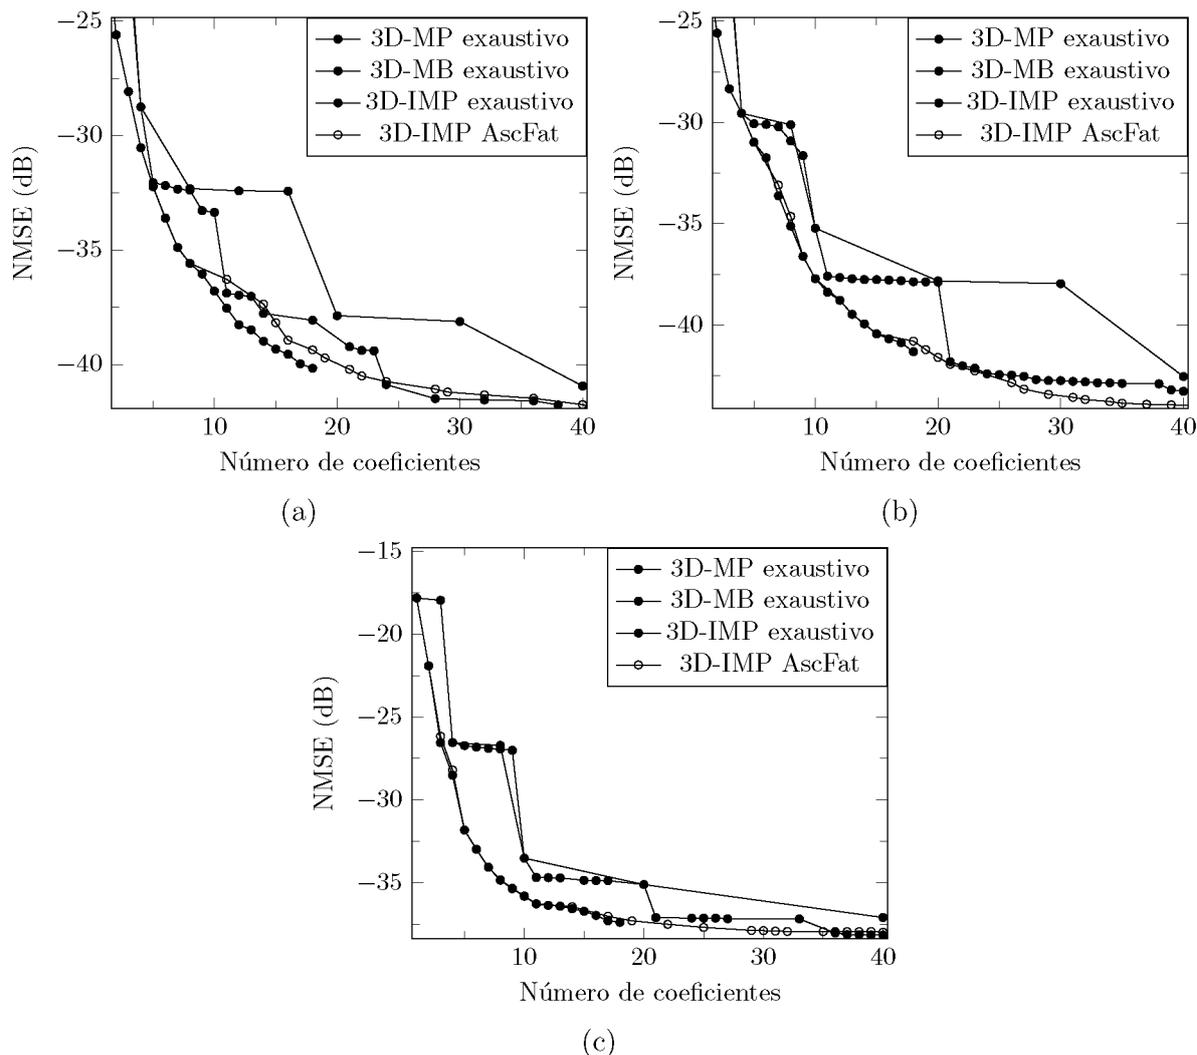


Figura 5.11: NMSE *vs.* o número de coeficientes comparando o modelo proposto com os modelos da literatura na modelagem banda tripla concorrente com portadoras não múltiplas para o (a) canal 1; (b) canal 2; (c) canal 3.

Fonte – O autor, 2021.

proposto apresentou melhor linearidade para os canais 1 e 3.

Exceto pelo canal 2, onde o modelo da literatura obteve ganho de linearidade igual ao modelo proposto, os demais resultados apontam que o 3D-IMP obteve desempenho melhor. Dessa forma, as figuras 5.14a, 5.14b, 5.14c, 5.15a, 5.15b e 5.15c apresentam o desempenho do sistema linearizado apenas com 3D-IMP. As figuras 5.14a, 5.14b e 5.14c apresentam a resposta em amplitude do sistema com e sem a linearização para os canais 1, 2 e 3, respectivamente, e as figuras 5.15a, 5.15b e 5.15c apresentam a constelação obtida com o sinal de saída do PA para os canais 1, 2 e 3, respectivamente.

As características apresentadas pelos resultados demonstram que o modelo proposto possui capacidade excelente de compensar as distorções dentro da banda e nas bandas adjacentes.

### 5.2.3 Comparação entre o modelo 3D proposto aplicando o algoritmo AscFat com modelo da literatura e resultados da linearização com portadoras múltiplas

Esta seção apresenta resultados comparativos entre o modelo proposto, 3D-HIMP, para comunicação de banda tripla concorrente para portadoras múltiplas aplicando algoritmo AscFat e o modelo da literatura, 3D-HMP, com busca exaustiva.

Os dados de extração utilizados para a modelagem são obtidos do PA estimulado com sinais de portadoras múltiplas conforme segue: o canal 1 é estimulado com sinal Wi-Fi IEEE 802.11n de 20 MHz de banda, modulação 64-QAM e centrado em 1,8 GHz; o canal 2 é estimulado com sinal LTE de 20 MHz de banda, modulação 64-QAM e centrado em 3,6 GHz; e o canal 3 estimulado com sinal Wi-Fi IEEE 802.11ac de 20 MHz de banda, modulação 256-QAM e centrado em 5,4 GHz. As amplitudes dos três sinais de entrada são iguais e ajustadas de forma que o PA apresenta consumo de 830 mW de potência contínua,  $P_{out}$  de 17,6 dBm e PAE de 6,99%. Os dados obtidos são separados em conjuntos de extração e validação.

Os modelos são comparados com base no melhor desempenho, avaliado pelo NMSE, em função do número de coeficientes de cada canal. Para 3D-HMP é aplicada a busca exaustiva variando os dois fatores de truncamento  $M$  e  $P$ , enquanto para o modelo proposto 3D-HIMP é aplicado o algoritmo AscFat avaliando os 140 fatores de truncamento distintos. Os fatores de truncamento de memória são limitados em 3 e as ordens de não linearidade em 6.

As figuras 5.16a, 5.16b e 5.16c apresentam os NMSE de validação da modelagem inversa para os canais 1, 2 e 3 respectivamente. Os modelos apropriados para portadoras múltiplas 3D-HMP e 3D-HIMP são comparados. Para reforçar a necessidade de um modelo apropriado em cenários de portadoras múltiplas, o modelo 3D-IMP, desenvolvido para aplicações de portadoras não múltiplas, também está incluído cuja varredura é realizada com algoritmo AscFat.

Comparando 3D-HMP e 3D-HIMP, o modelo proposto apresenta combinações de maior acurácia para mesma quantidade de parâmetros. Este resultado é consequência da inclusão dos 18 termos possíveis ao invés de 12 e do uso de uma quantidade maior de fatores distintos. Comparando em um mesmo número de parâmetros, o modelo proposto reduz o NMSE em até 11,9 dB, 16,6 dB e 12,3 dB nos canais 1, 2 e 3, respectivamente. Para atingir a mesma acurácia que o 3D-HMP com 40 parâmetros, são necessários menos de 10 parâmetros do modelo proposto, redução de mais de 75%. Analisando o modelo 3D-IMP, cujos valores mínimos de NMSE foram de  $-5,4$  dB,  $-28,1$  dB, e  $-18,7$  dB para os canais 1, 2 e 3, respectivamente, confirma-se a necessidade da inclusão de termos de intermodulação harmônica para cenários de portadoras múltiplas. No cenário de portadoras não múltiplas, o mesmo modelo atingiu NMSE inferior a  $-38$  dB.

As melhores combinações com até 40 coeficientes aplicando 3D-HMP e 3D-HIMP, ilustradas nas figuras 5.16a, 5.16b e 5.16c são utilizadas para linearizar o PA. O DPD é treinado com aprendizagem indireta de duas iterações e extração de parâmetros com LS. A tabela 5.7 apresenta os resultados de desempenho do PA linearizado com 3D-HMP aplicando busca exaustiva limitada a 40 coeficientes, 3D-HIMP aplicando AscFat limitado a 40 coeficientes e sem linearização com potência média de saída próxima.

Tabela 5.7: Resultados de desempenho do sistema em banda tripla concorrente com portadoras múltiplas, linearizado com 3D-HMP e 3D-HIMP limitados a 40 coeficientes.

|         | $P_{CC}$<br>(mW) | $P_{out}$<br>(mW) | PAE<br>(%) | EVM<br>Canal 1<br>(%) | EVM<br>Canal 2<br>(%) | EVM<br>Canal 3<br>(%) |
|---------|------------------|-------------------|------------|-----------------------|-----------------------|-----------------------|
| 3D-HMP  | 832,38           | 17,43             | 6,65       | 1,87                  | 1,43                  | 2,84                  |
| 3D-HIMP | 832,47           | 17,42             | 6,63       | 1,35                  | 1,02                  | 1,61                  |
| Sem DPD | 832,22           | 17,43             | 6,63       | 75,88                 | 5,29                  | 10,85                 |

Fonte – O autor, 2021.

Os resultados comparativos da tabela 5.7 apresentam redução significativa no EVM aplicando a linearização, principalmente para o canal 1. Redução adicional é obtida com 3D-HIMP em 0,52 p.p., 0,41 p.p. e 1,23 p.p. para os canais 1, 2 e 3 quando comparados à linearização aplicando o modelo 3D-HMP da literatura, respectivamente. Se comparar os casos sem DPD das tabelas 5.6 e 5.7, há degradação significativa nos EVMs, principalmente do primeiro canal, causada pela multiplicidade de portadoras na tabela 5.7 indicando o quanto as interferências harmônicas atrapalham os canais concorrentes.

A melhor capacidade de linearização do modelo proposto para mesma quantidade de parâmetros também está ilustrada pelas figuras 5.17a, 5.17b e 5.17c contendo as curvas de PSD obtidas da saída do PA para os canais 1, 2 e 3, respectivamente, e as figuras 5.18a, 5.18b e 5.18c contendo a magnitude de erro entre entrada do sistema e saída do PA aplicando linearização com 3D-HMP, 3D-HIMP e sem linearização para os canais 1, 2 e 3, respectivamente.

Pelas ilustrações, o melhor resultado de linearização foi obtido com 3D-HIMP. Dessa forma, as figuras 5.19a, 5.19b e 5.19c apresentam as respostas em amplitude para os canais 1, 2 e 3 do sistema linearizado com 3D-HIMP e sem linearização, respectivamente, e as figuras 5.20a, 5.20b e 5.20c apresentam as constelações dos canais 1, 2 e 3 obtidas do sinal de saída do PA aplicando linearização com 3D-HIMP e sem linearização, respectivamente.

### 5.3 Resultados aplicando saturação do DPD em banda dupla

O algoritmo descrito na Seção 3.3 agora é aplicado na linearização do cenário de banda dupla concorrente com entradas Wi-Fi (802.11n) em 2,4 GHz e LTE em 3,5 GHz. A Subseção 5.3.1 apresenta uma análise da implementação da saturação e suas características; a Subseção 5.3.2 descreve a configuração aplicada nos testes; e a Subseção 5.3.3 apresenta os resultados e a análise.

#### 5.3.1 Os efeitos da saturação de banda dupla

Sejam os sinais de entrada Wi-Fi e LTE representados por  $x_1(n)$  e  $x_2(n)$ , respectivamente, ambos em banda base e amostrados a 120 MHz. São armazenadas 100 amostras de  $x_1(n)$  e  $x_2(n)$ , ambas normalizadas para que a amplitude máxima seja igual a 1 V, conseqüentemente a envoltória  $x(n)$  pode ultrapassar 1 V. Tomando como base o desenvolvimento da Seção 3.3, neste cenário  $\omega_1 = 2\pi 2,4$  Grad/s e  $\omega_2 = 2\pi 3,5$  Grad/s. Logo,  $\omega = 2\pi 2,95$  Grad/s e  $\Delta\omega = 2\pi 550$  Mrad/s, a envoltória complexa em  $\omega$  é bem maior que a frequência de amostragem de cada canal, o que exige a proposição de que cada sinal em banda base está sendo apenas deslocado para  $\Delta\omega$ . Forçando o limiar  $L = 1$  V, as figuras 5.21a e 5.21b apresentam as envoltórias complexas  $x(n)$  e  $x_c(n)$  aplicando as abordagens da soma e da divisão, respectivamente.

As envoltórias apresentadas nas figuras 5.21a e 5.21b demonstram que o procedimento de saturação possui coerência com o que se deseja em ambas as abordagens aplicadas. Entretanto, no caso da divisão o resultado apresenta maior confiabilidade em relação ao limitar  $L$ . A aplicação da saturação acontece de fato em  $x_1(n)$  e  $x_2(n)$ , mas a relação com  $L$  não é direta. Para exemplificar o que acontece com as envoltórias ceifadas  $x_{1c}(n)$  e  $x_{2c}(n)$ , as figuras 5.22a e 5.22b apresentam os canais Wi-Fi e LTE para o caso da soma (figura 5.21a). A envoltória possui variação muito abrupta na amplitude sempre que  $x(n)$  ultrapassa  $L$ . Entretanto o aspecto das curvas  $x_{1c}(n)$  e  $x_{2c}(n)$  com  $x_1(n)$  e  $x_2(n)$  ainda pode ser verificado. Para os casos apresentados, sendo  $L = 1$  V, houve extrapolação de até 1,75 vezes, o que é um valor bem elevado. As configurações conhecidas de outros testes são valores de no máximo 1,5 vezes o limiar (SCHUARTZ *et al.*, 2018b, 2019a), logo a fidelidade de cada curva de amplitude da informação saturada com a amplitude original tende a ser maior.

O ponto mais crítico desse desenvolvimento está no fato das envoltórias  $x_{1c}$  e  $x_{2c}$  não estarem concentradas dentro da expectativa do modelo. Se por um lado, controlar a envoltória resultante não garante que para cada canal a envoltória não extrapole o modelo, por outro lado, em um modelo multidimensional e com memória, limitar a amplitude do canal principal também não traz garantia alguma sobre a extrapolação. A principal consequência desse efeito é a possibilidade de existirem amostras com valores

inesperados. Contudo, se as ocorrências forem eventuais e o benefício principal (aumentar a potência/eficiência aos limites da norma) então a abordagem é válida.

### 5.3.2 Configuração para os testes de linearização

O objetivo do teste é avaliar se a abordagem de saturação proposta permite aumentar a potência de saída do PA, e conseqüentemente a eficiência, comprometendo a linearidade aos limites das normas mas garantindo desempenho melhor com a saturação do que sem a linearização. Por essa razão, o modelo para DPD aplicado é o 2D-IMP retirado da literatura e detalhado na Seção 2.2.2 e o método de aprendizado é a aprendizagem indireta detalhada na Seção 2.4.5.

Os dados aplicados nos testes são Wi-Fi IEEE 802.11n em 2,4 GHz e LTE em 3,5 GHz, ambos possuem largura de banda de 20 MHz e estão amostrados a 120 MHz. A extrapolação é aplicada somente na segunda iteração de aprendizado. A escolha dos fatores de truncamento é distinta para cada iteração e para cada canal. O algoritmo proposto AscFat descrito na Seção 3.2.4 é utilizado para obter os melhores ajustes dos fatores de truncamento. Os mesmos fatores de truncamento são aplicados para as abordagens da soma e da divisão.

O valor de limiar  $L$  é escolhido igual ao valor máximo dos dados de entrada do DPD da segunda iteração de aprendizagem de parâmetros. Os níveis de saturação são sempre iguais entre os canais e obtidos conforme descritos nas Seções 3.3.2.1 e 3.3.2.2 para as abordagens da soma e da divisão, respectivamente.

### 5.3.3 Resultados de linearização de banda dupla com saturação

Os resultados apresentados seguem a descrição da Seção 5.3.2 elevando a amplitude dos dados até um valor controlado de sobre-sinal máximo. O sobre-sinal com 00% indica a situação onde a saturação não é aplicada, ou seja,  $|x_3(n)| \leq L$ , e para os casos onde a saturação foi aplicada, o sobre-sinal foi idêntico para ambos os canais e variados de 10 a 50%. O sobre-sinal aplicado é controlado separadamente em  $x_1(n)$  e  $x_2(n)$  e não em  $x_3(n)$ . Logo, o sobre-sinal em  $x_3(n)$  não necessariamente possui a mesma relação que as indicações. A razão de controlar o sobre-sinal em cada banda é a possibilidade de controlar a potência de cada canal de forma independente. Nessas configurações as tabelas 5.8 e 5.9 apresentam os resultados aplicando as abordagens da soma e da divisão, respectivamente.

A característica mais esperada dos resultados é o aumento considerável de potência. As tabelas apresentam ganho de potência de saída menor que 1 dB, o que indicaria que aplicar essa abordagem poderia não ser interessante. Mas por outro lado, o ganho de eficiência foi mais efetivo. Em específico os resultados apresentaram aumento máximo de

Tabela 5.8: Resultados de desempenho da linearização de banda dupla concorrente aplicando saturação com a abordagem da soma.

| Sobre-sinal | $P_{out}$<br>(dBm) | PAE<br>(%) | EVM<br>Canal 1<br>(%) | EVM<br>Canal 2<br>(%) |
|-------------|--------------------|------------|-----------------------|-----------------------|
| 00%         | 20,86              | 14,7       | 1,17                  | 1,23                  |
| 10%         | 20,99              | 15,2       | 1,07                  | 1,39                  |
| 20%         | 21,13              | 15,7       | 1,49                  | 2,08                  |
| 30%         | 21,27              | 16,3       | 2,61                  | 2,51                  |
| 40%         | 21,42              | 16,9       | 5,03                  | 4,02                  |
| 50%         | 21,58              | 17,3       | 8,46                  | 6,81                  |

Fonte – O autor, 2021.

Tabela 5.9: Resultados de desempenho da linearização de banda dupla concorrente aplicando saturação com a abordagem da divisão.

| Sobre-sinal | $P_{out}$<br>(dBm) | PAE<br>(%) | EVM<br>Canal 1<br>(%) | EVM<br>Canal 2<br>(%) |
|-------------|--------------------|------------|-----------------------|-----------------------|
| 00%         | 20,86              | 14,7       | 1,17                  | 1,23                  |
| 10%         | 20,99              | 15,2       | 1,07                  | 1,39                  |
| 20%         | 21,13              | 15,7       | 1,49                  | 2,08                  |
| 30%         | 21,27              | 16,3       | 2,64                  | 2,53                  |
| 40%         | 21,42              | 17,0       | 5,00                  | 4,06                  |
| 50%         | 21,58              | 17,3       | 8,24                  | 6,78                  |

Fonte – O autor, 2021.

14,7% para 17,3% na PAE sem deteriorar o EVM significativamente.

Diferentemente dos resultados de saturação aplicados para banda única (SCHU-ARTZ *et al.*, 2019a) onde a deterioração do EVM foi bem mais significativa do que o aumento da PSD nos canais adjacentes, para banda dupla concorrente as restrições espectrais dos canais Wi-Fi e LTE foram mais significativas. Encontrar um ponto de limite ótimo de saturação para cada canal é um trabalho oneroso considerando a necessidade de simulações de transitório em RF. Entretanto, mantendo a proporção fixa entre ambos, o sobre-sinal ceifado que cumpre as restrições de ambas as normas é de 25% em ambas as abordagens. Resultados comparando os casos de pré-distorção tradicional, pré-distorção com saturação de 25% com abordagens de soma e divisão e sem linearização estão dispostos na tabela 5.10 e figuras 5.23a e 5.23b.

Na tabela 5.10 o confronto de potência média foi feito para os casos sem linearização e com linearização aplicando a saturação. Em mesma situação de potência média

Tabela 5.10: Confronto de mesma potência média aplicando a linearização de banda dupla concorrente sem saturação, com saturação de 25% nas abordagens de soma e divisão e sem linearização.

|                          | $P_{out}$<br>(dBm) | PAE<br>(%) | EVM<br>Canal 1<br>(%) | EVM<br>Canal 2<br>(%) |
|--------------------------|--------------------|------------|-----------------------|-----------------------|
| Sem linearização         | 21,21              | 16,1       | 9,83                  | 11,68                 |
| Soma 25%                 | 21,20              | 16,0       | 1,89                  | 2,13                  |
| Divisão 25%              | 21,20              | 16,0       | 1,89                  | 2,14                  |
| Linearização tradicional | 20,86              | 14,7       | 1,17                  | 1,23                  |

Fonte – O autor, 2021.

o desempenho em eficiência foi igual, enquanto que o EVM foi reduzido significativamente para os dois canais. Em específico, houve ganho de EVM em 7,9 p.p. e 9,5 p.p. para os canais Wi-Fi e LTE, respectivamente. Comparando o caso linearizado com saturação e tradicional, houve ganho de 8,8% (de 14,7% para 16,0%) em rendimento com degradação de EVM abaixo de 1 p.p. Se por um lado a deterioração de EVM foi mínima, por outro lado, nas PSDs apresentadas pelas figuras 5.23a e 5.23b a potência espectral fora da banda aumentou consideravelmente. Para o canal Wi-Fi (figura 5.23a) o limite foi atingido em 2,37 GHz e 2,43 GHz. Apesar da PSD ser o ponto limitante para esse caso (a restrição de EVM está acima de 5%), a característica de espalhamento nas adjacências do canal de comunicação foi reduzida consideravelmente. Por fim, comparando as abordagens da soma e divisão, ambas apresentaram desempenho muito próximo, houve apenas desempenho minimamente melhor da abordagem da soma.

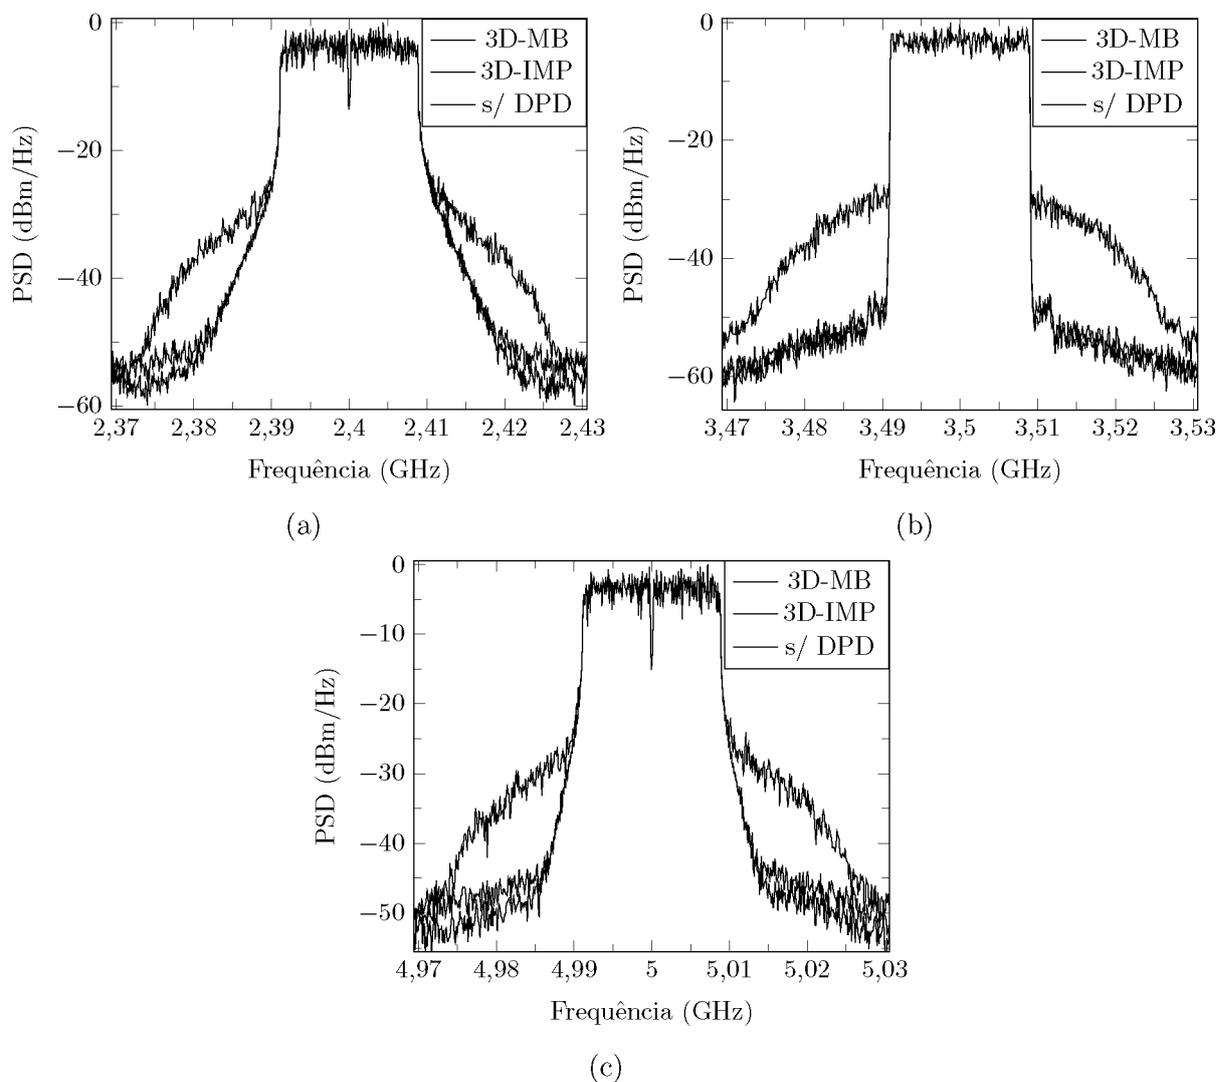


Figura 5.12: PSD do sinal de saída do sistema de banda tripla concorrente com portadoras não múltiplas linearizado com 3D-MB e 3D-IMP, limitados a 20 coeficientes, e sem linearização para mesma potência média de saída para (a) o canal 1; (b) o canal 2; (c) o canal 3.

Fonte – O autor, 2021.

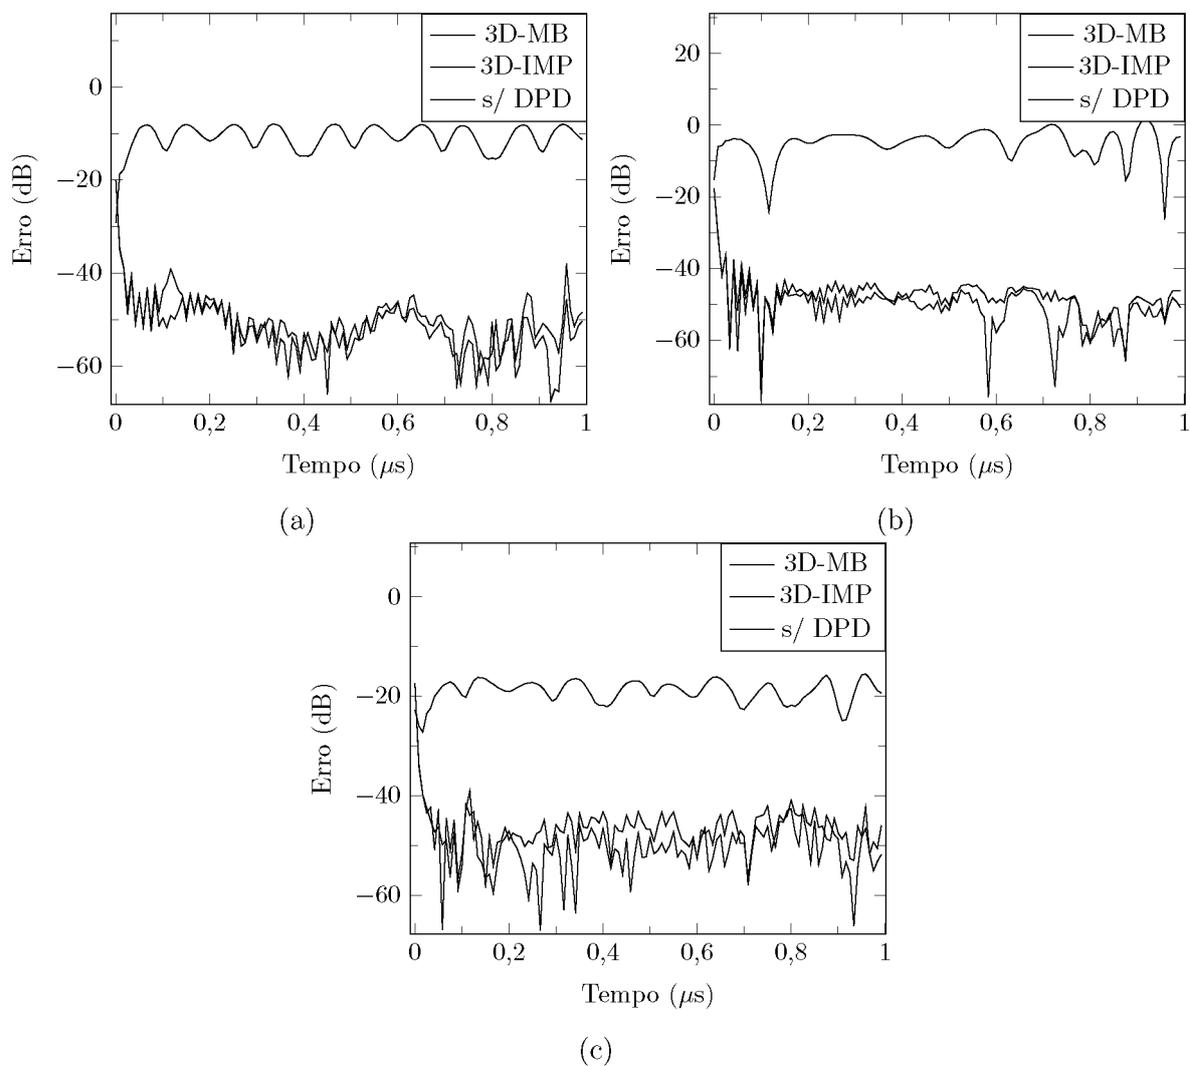


Figura 5.13: Magnitude do erro entre os sinais de entrada e de saída do sistema de banda tripla concorrente com portadoras não múltiplas linearizado com 3D-MB e 3D-IMP, limitados a 20 coeficientes, e sem linearização para mesma potência média de saída para (a) o canal 1; (b) o canal 2; (c) o canal 3.

Fonte – O autor, 2021.

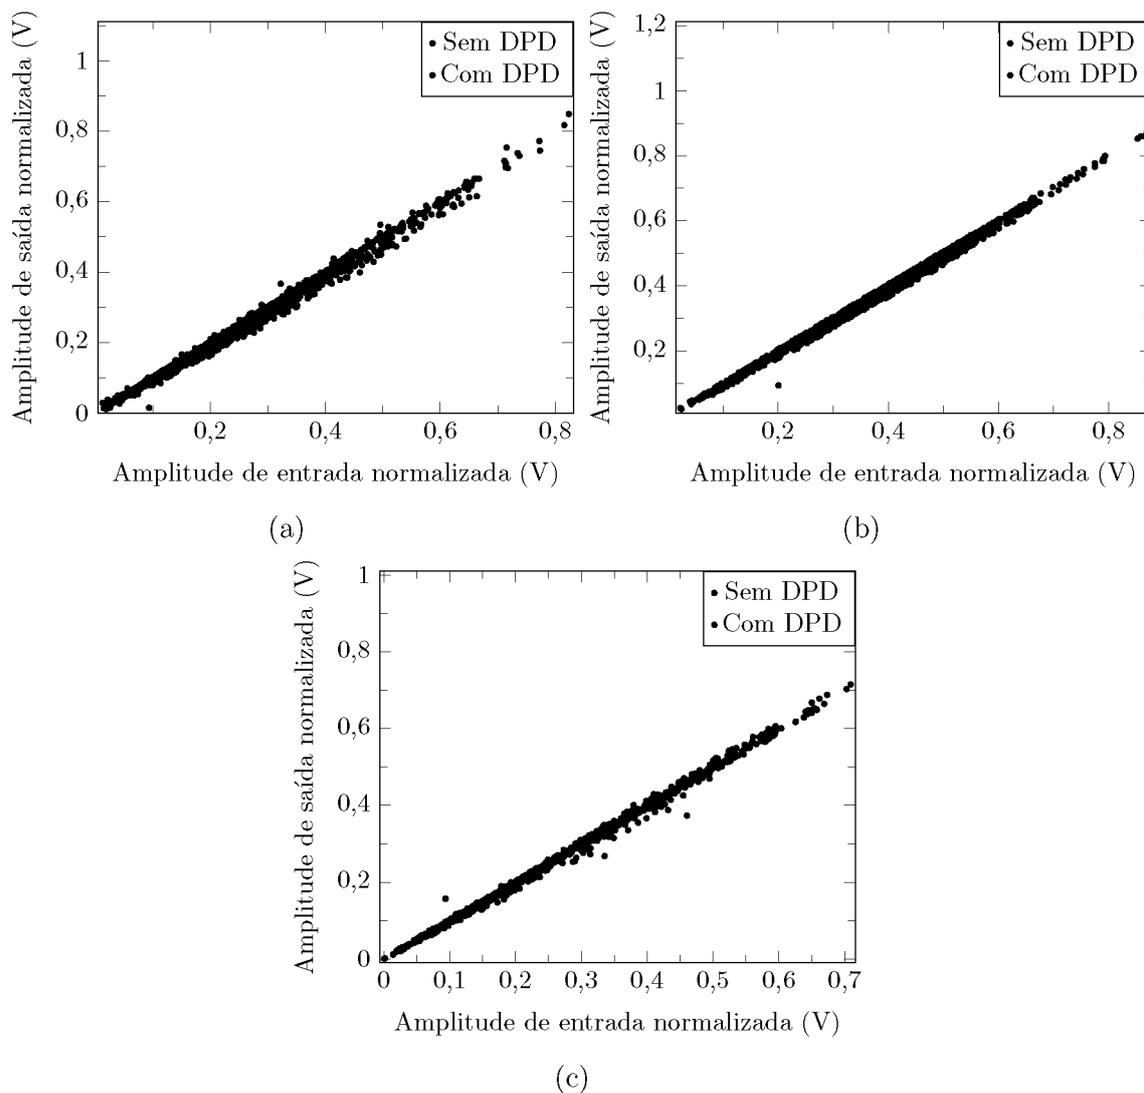


Figura 5.14: Resposta em amplitude do sistema de banda tripla concorrente com portadoras não múltiplas linearizado com 3D-IMP limitado a 20 coeficientes e sem linearização para mesma potência média de saída para (a) o canal 1; (b) o canal 2; (c) o canal 3.

Fonte – O autor, 2021.

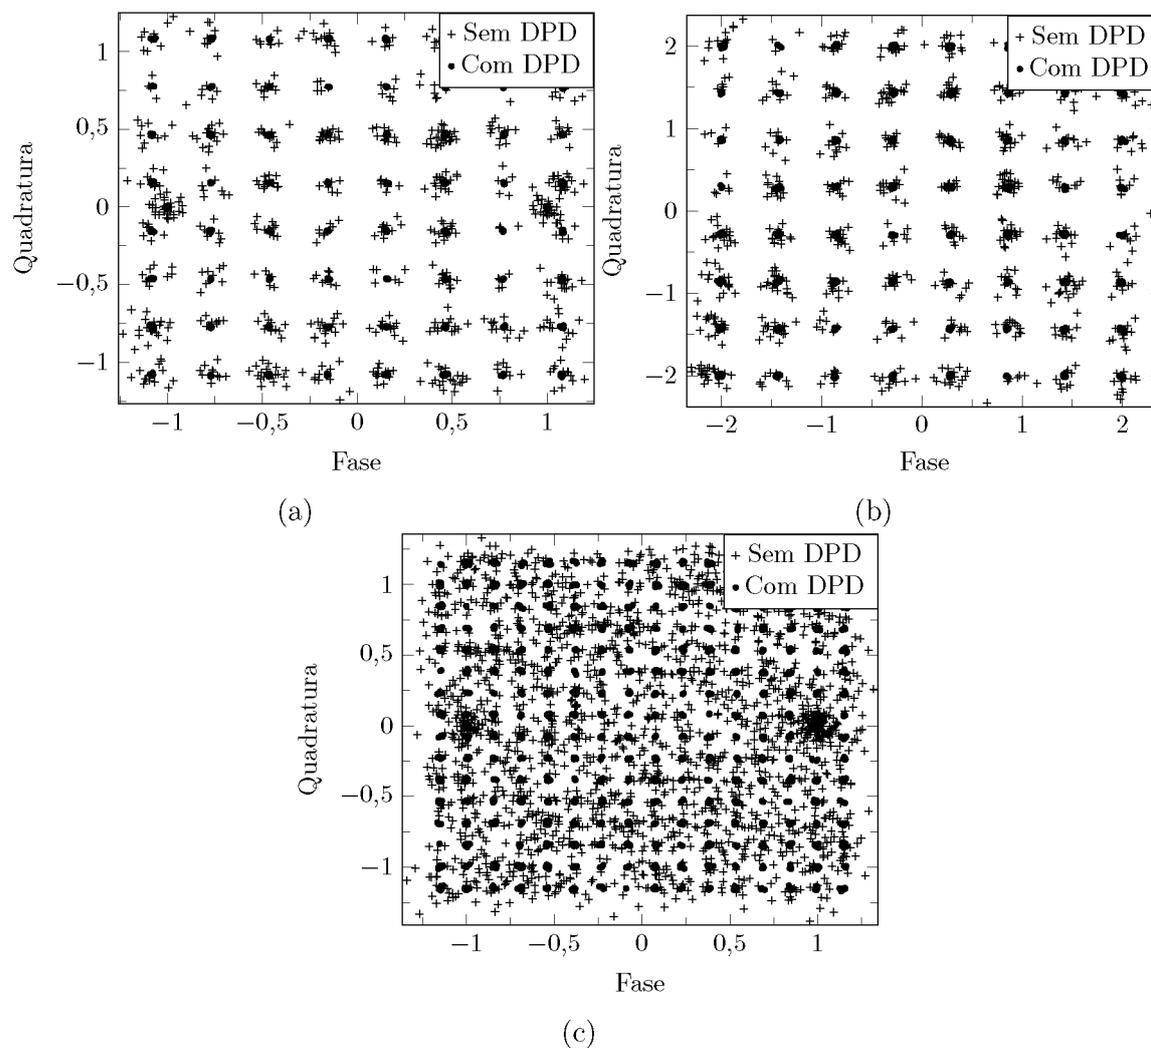


Figura 5.15: Constelação do sinal de saída do sistema de banda tripla concorrente com portadoras não múltiplas linearizado com 3D-IMP limitado a 20 coeficientes e sem linearização para mesma potência média de saída para (a) o canal 1; (b) o canal 2; (c) o canal 3.

Fonte – O autor, 2021.

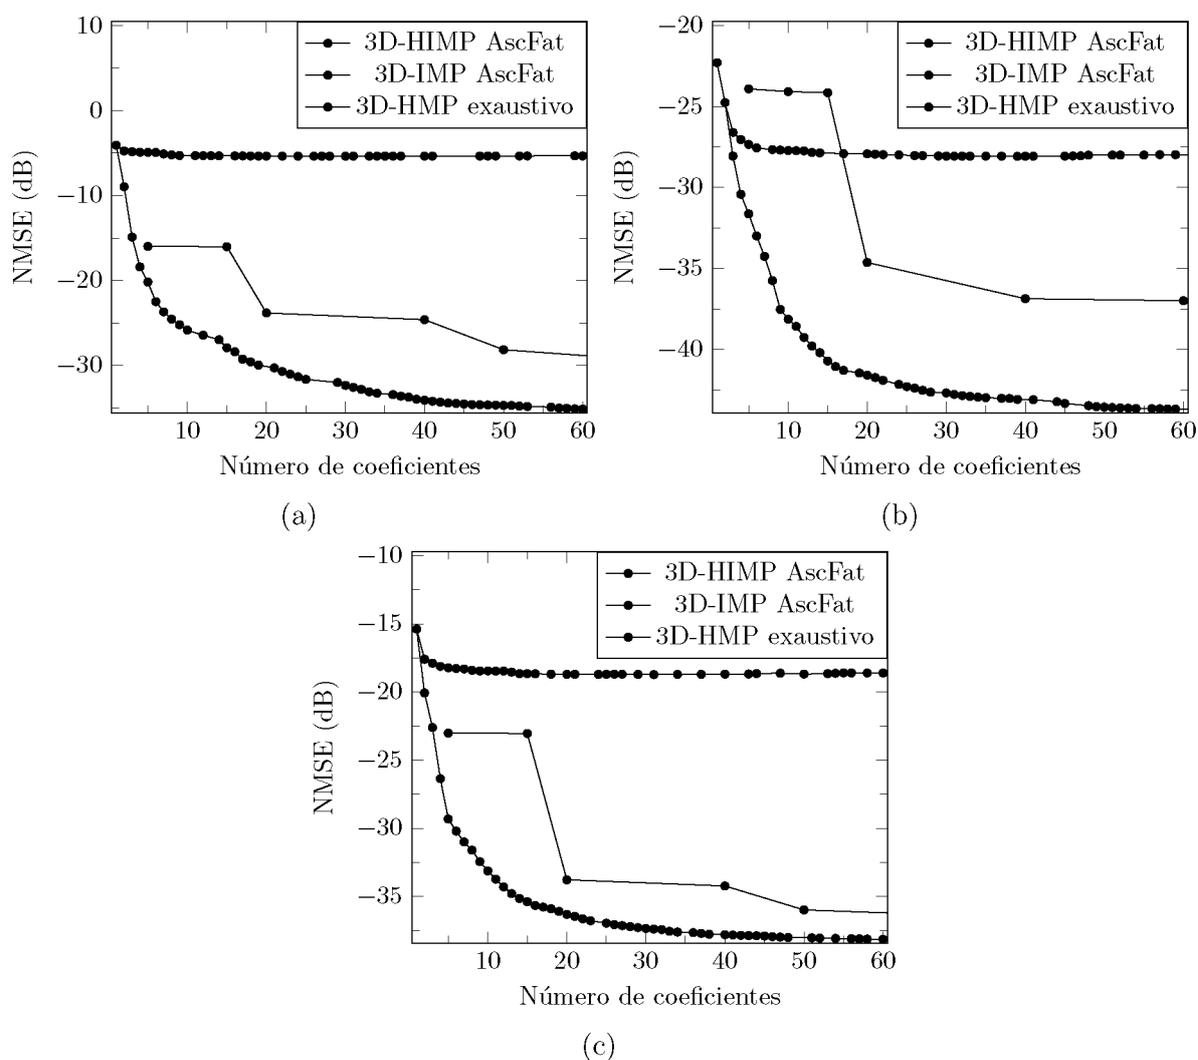


Figura 5.16: NMSE *vs.* o número de coeficientes comparando o modelo proposto com o modelo da literatura na modelagem banda tripla concorrente com portadoras múltiplas para o (a) canal 1; (b) canal 2; (c) canal 3.

Fonte – O autor, 2021.

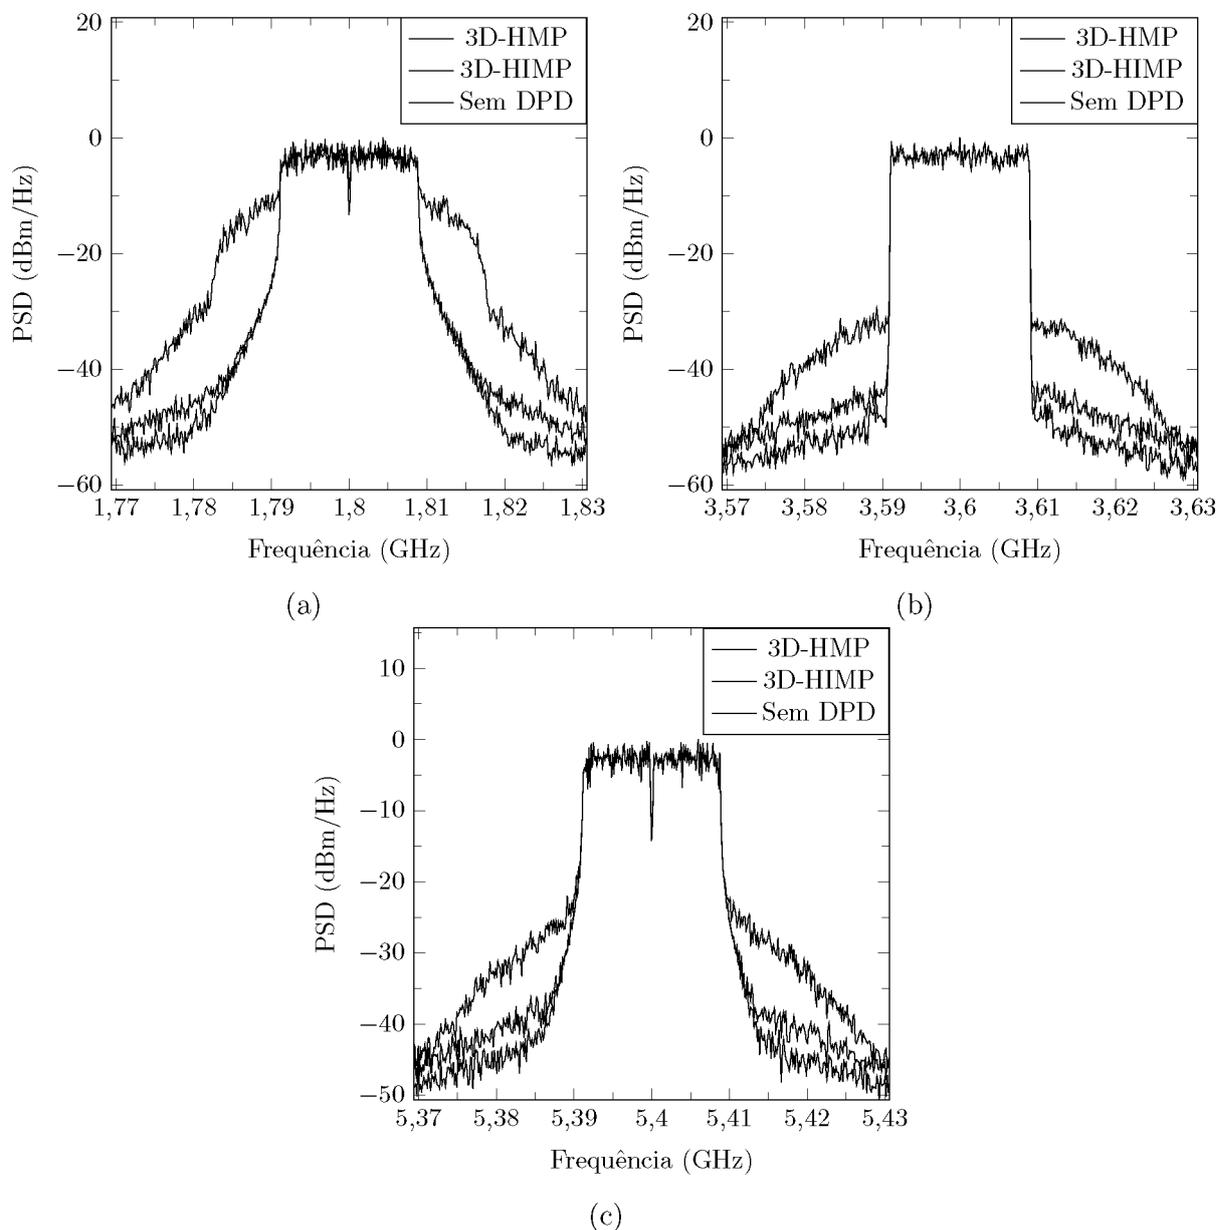


Figura 5.17: PSD do sinal de saída do sistema de banda tripla concorrente com portadoras múltiplas linearizado com 3D-HMP e 3D-HIMP, limitados a 40 coeficientes, e sem linearização para mesma potência média de saída para (a) o canal 1; (b) o canal 2; (c) o canal 3.

Fonte – O autor, 2021.

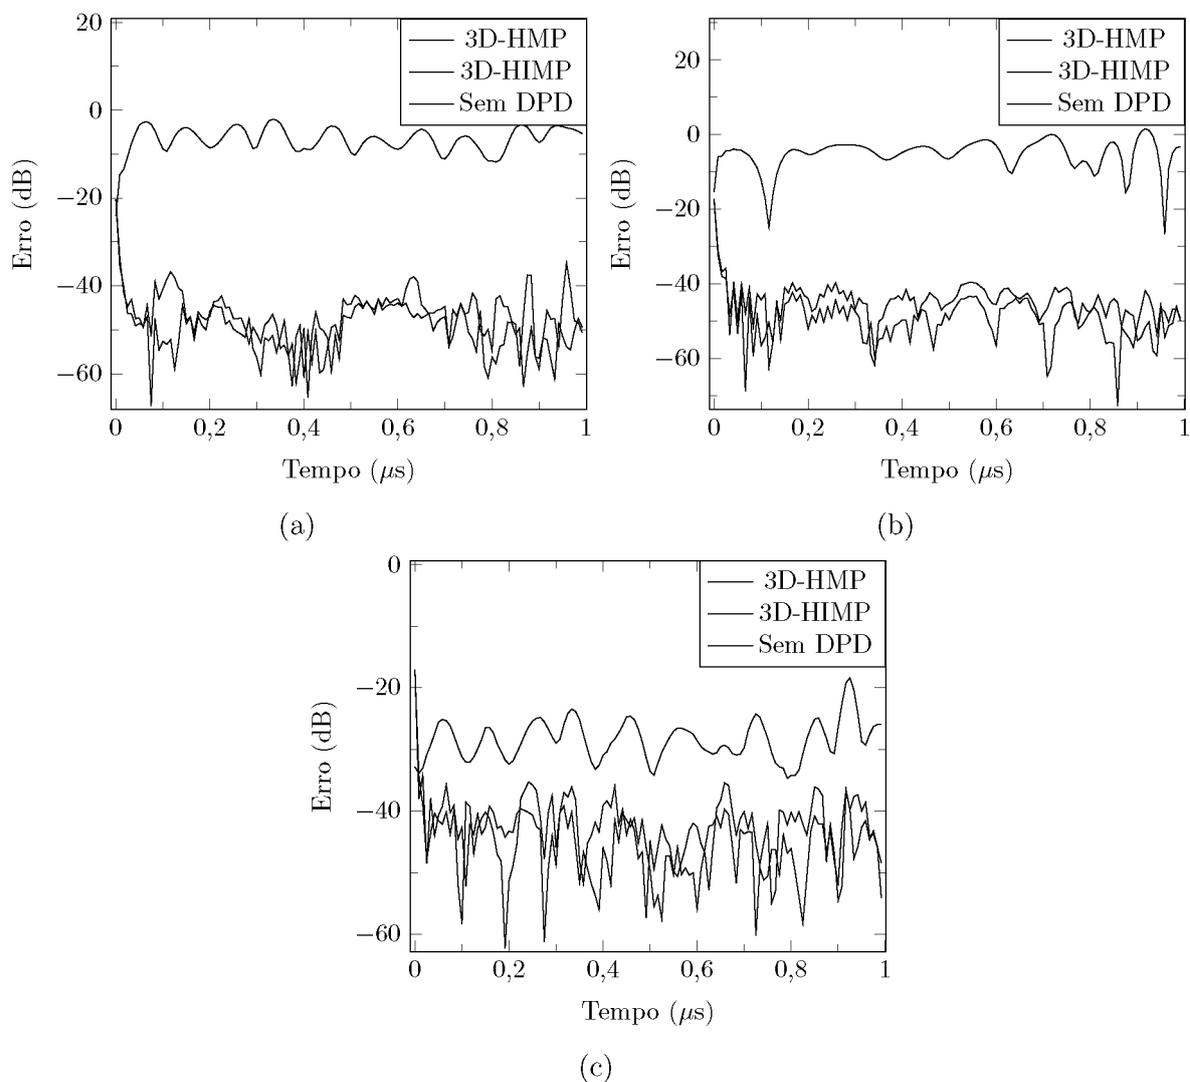


Figura 5.18: Magnitude do erro entre os sinais de entrada e de saída do sistema de banda tripla concorrente com portadoras múltiplas linearizado com 3D-HMP e 3D-HIMP, limitados a 40 coeficientes, e sem linearização para mesma potência média de saída para (a) o canal 1; (b) o canal 2; (c) o canal 3.

Fonte – O autor, 2021.

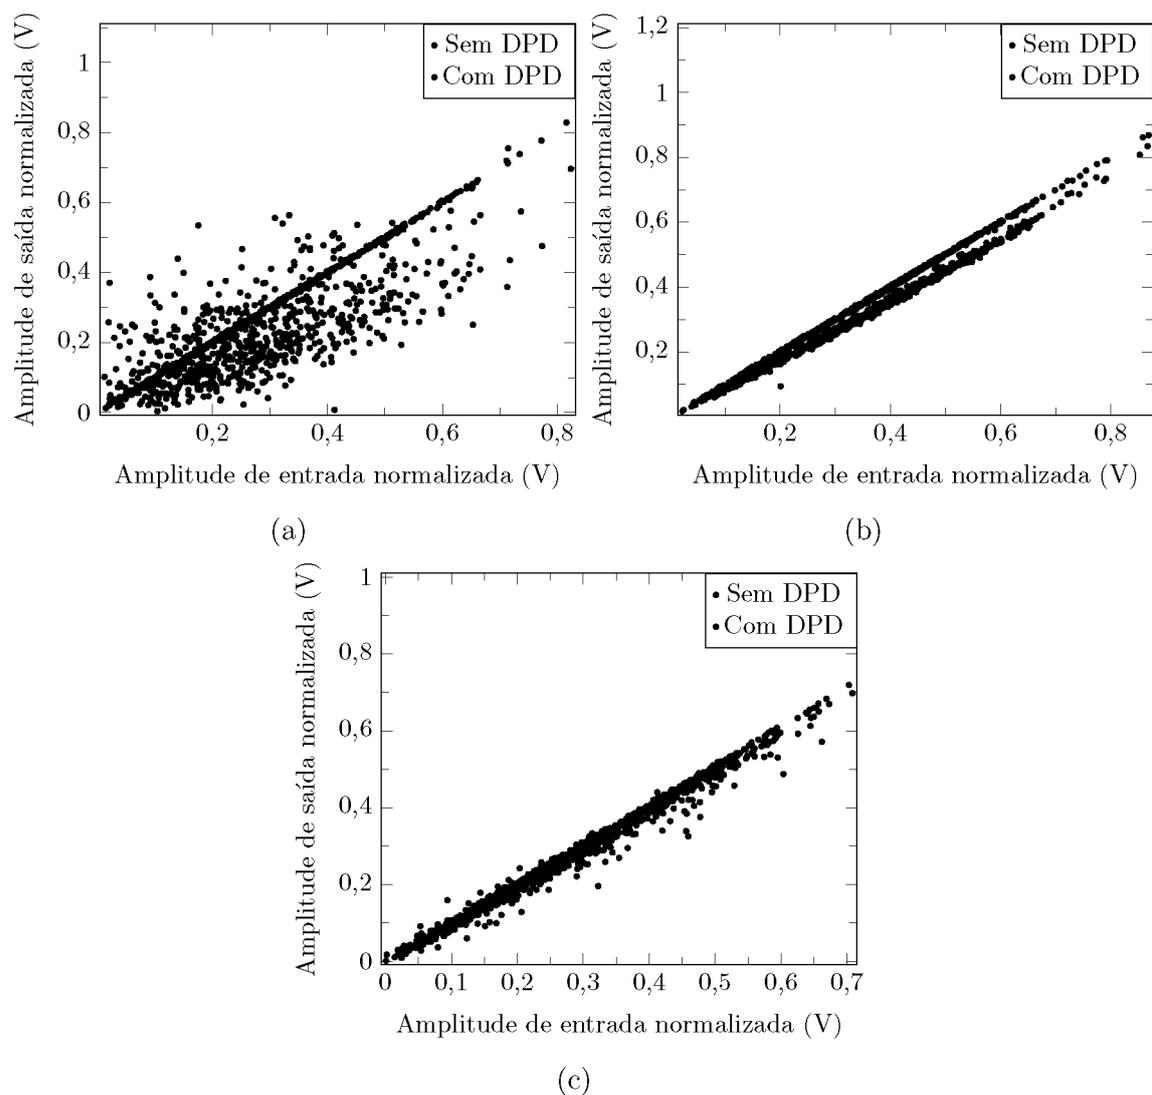


Figura 5.19: Resposta em amplitude do sistema de banda tripla concorrente com portadoras múltiplas linearizado com 3D-HIMP limitado a 40 coeficientes e sem linearização para mesma potência média de saída para (a) o canal 1; (b) o canal 2; (c) o canal 3.

Fonte – O autor, 2021.

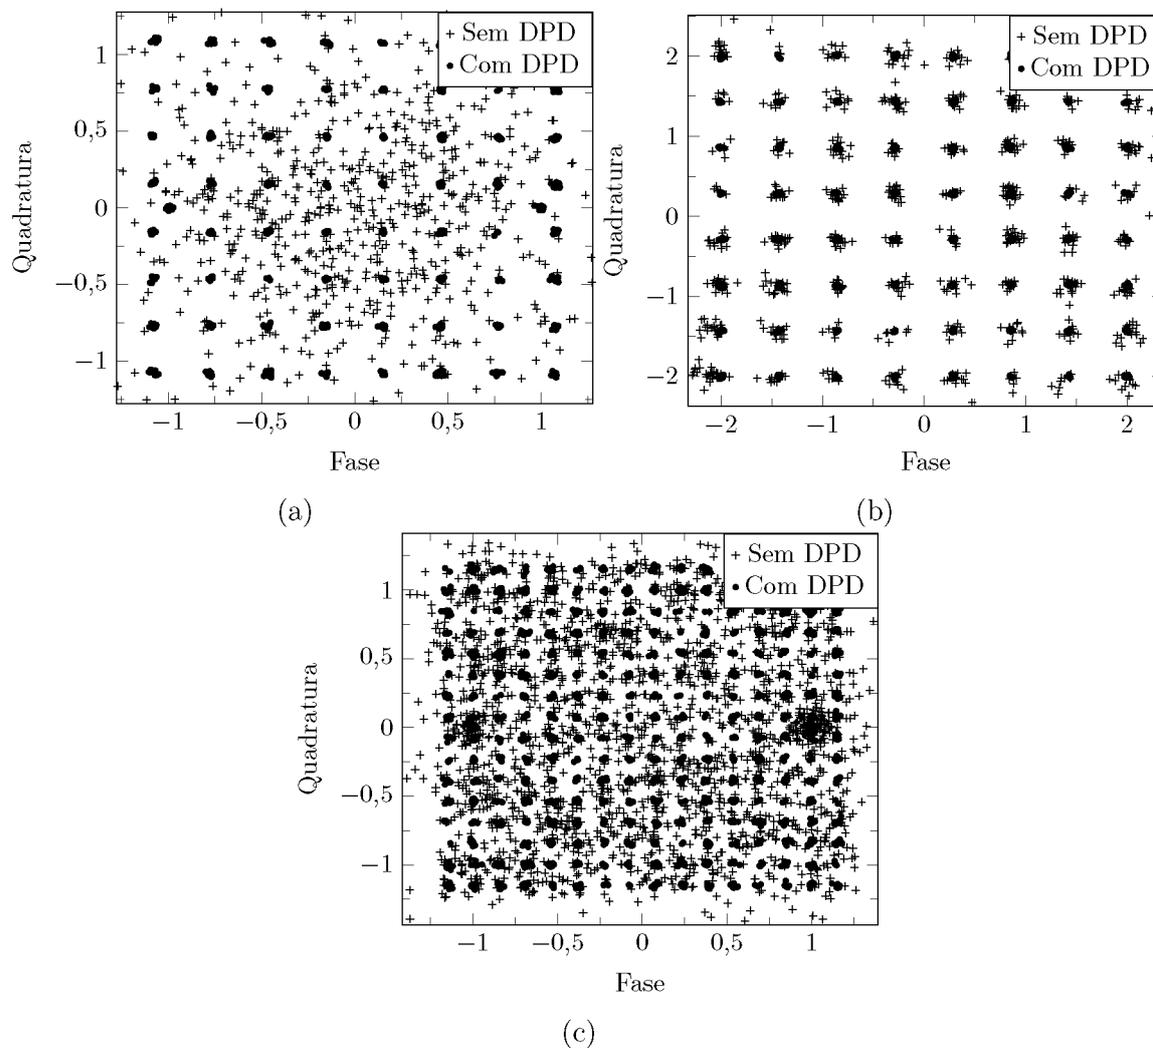


Figura 5.20: Constelação do sinal de saída do sistema de banda tripla concorrente com portadoras múltiplas linearizado com 3D-HIMP limitado a 40 coeficientes e sem linearização para mesma potência média de saída para (a) o canal 1; (b) o canal 2; (c) o canal 3.

Fonte – O autor, 2021.

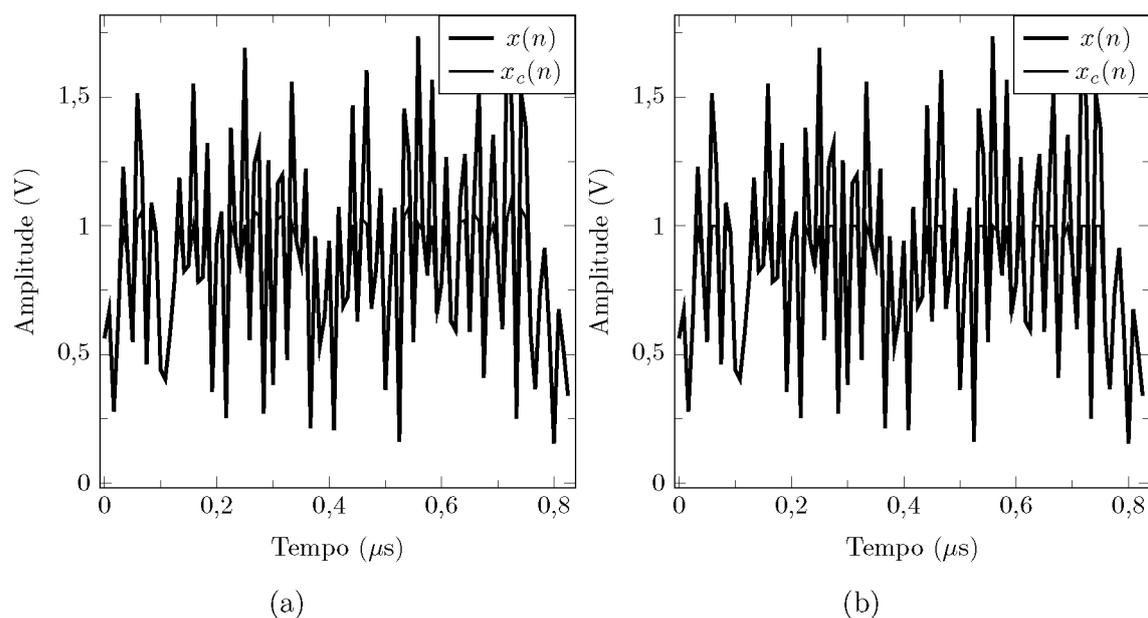


Figura 5.21: Amplitude de  $x(n)$  e  $x_c(n)$  aplicando saturação com limiar  $L = 1$  V e abordagem (a) da soma; (b) da divisão.

Fonte – O autor, 2021.

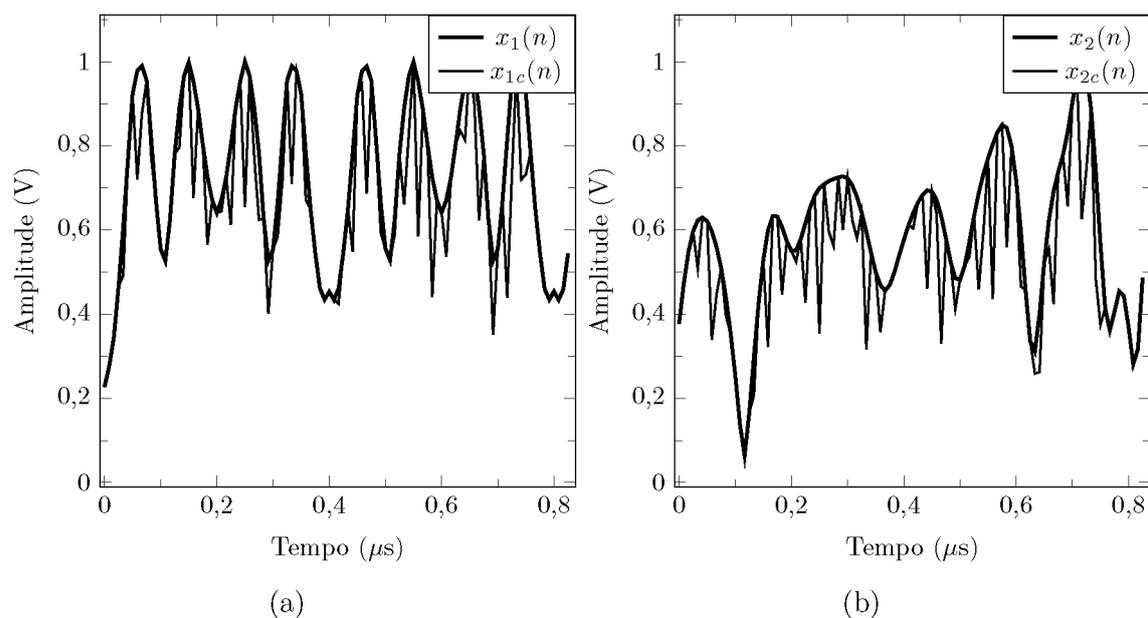


Figura 5.22: Amplitudes de cada canal aplicando a saturação com abordagem da soma e limiar  $L = 1$  V. Amplitudes (a) do canal 1; e (b) do canal 2.

Fonte – O autor, 2021.

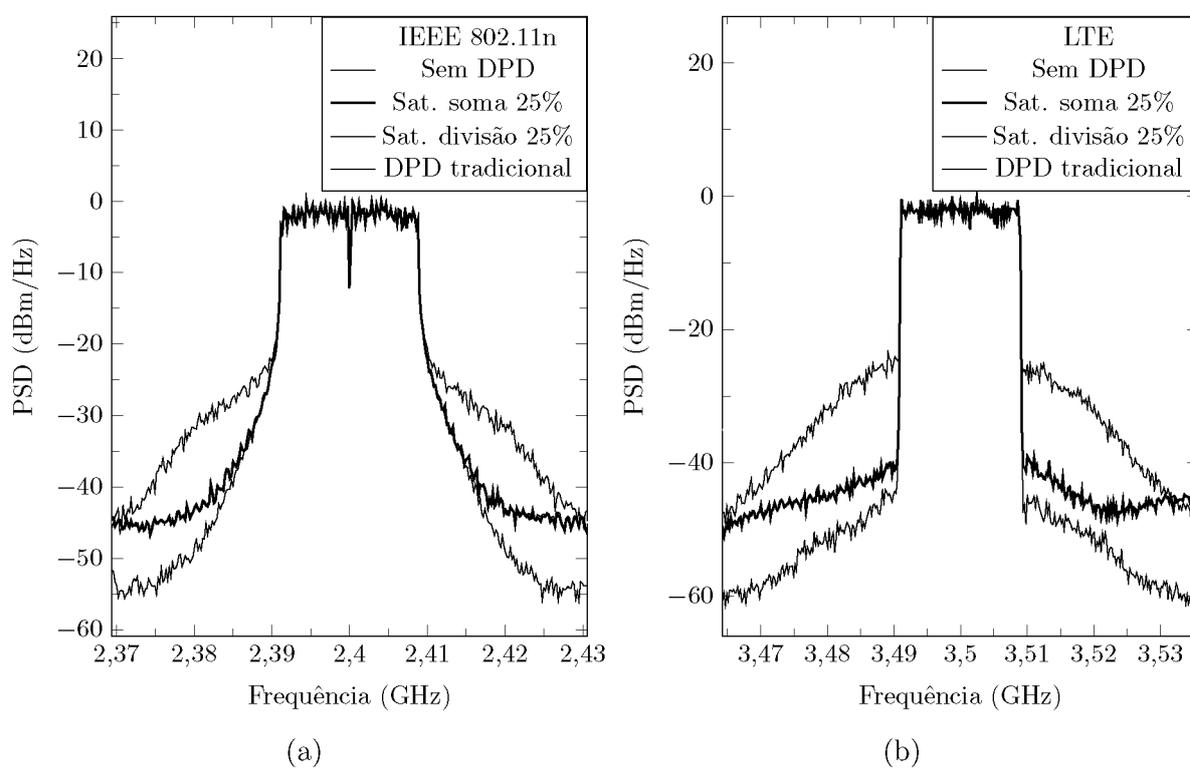


Figura 5.23: PSDs comparando resultados sem linearização, com linearização tradicional e com as abordagens de saturação para (a) do canal 1; e (b) do canal 2.

Fonte – O autor, 2021.

## CAPÍTULO 6

### CONCLUSÕES E PROPOSTAS DE TRABALHOS FUTUROS

#### 6.1 Conclusões

Em relação ao método de aprendizagem, comparações entre as aprendizagens direta e indireta para transmissão de banda dupla concorrente utilizando modelo polinomial 2D-IMP e redes neurais para o DPD foram apresentadas. Na aprendizagem direta o PA foi substituído por um modelo polinomial em 4 cenários distintos de modelos de PA. Resultados apontaram que a aprendizagem direta possui potencialidade de apresentar melhor desempenho, principalmente para redes neurais, mas a forte dependência de um modelo de PA amplificando sinais pré-distorcidos e de acurácia elevada do PA é o principal fator limitante. Para resolver este problema, uma modificação na aprendizagem indireta é proposta de forma que uma melhora na extração de parâmetros do PA pode ser executada sem a necessidade de quantidades severas de iterações com o PA ou a necessidade de um modelo para o PA. Resultados apontam que a modificação sugerida permitiu obter uma inversa de maior acurácia do PA, cujo ganho de NMSE foi de aproximadamente 2 dB e 5 dB para modelo polinomial e redes neurais, respectivamente. Em relação ao desempenho do sistema linearizado, a modificação proposta permitiu reduzir o EVM em até 9% (de 0,87% para 0,79%) e 36% (de 1,79% para 1,13%) para modelo polinomial e redes neurais em relação ao melhor caso dos métodos tradicionais.

Em banda dupla concorrente, o modelo 2D-MIMP acrescenta uma série de fatores de truncamento distintos e termos multidimensionais em comparação aos modelos prévios 2D-IMP e 2D-MP. Comparações entre os modelos da literatura mostram que o 2D-IMP, mesmo sendo um modelo genérico em relação ao 2D-MP, somente apresenta desempenho superior se for aplicada uma condição de limite das ordens de não linearidade. O algoritmo proposto AscFat apresenta desempenho praticamente igual à busca exaustiva em relação ao erro e convergência, mas negligencia diversas combinações que a busca exaustiva encontra, entretanto o grande desempenho com poucas avaliações justifica sua utilização. Não há comparação entre outros algoritmos de busca porque não é conhecido um algoritmo para esta finalidade, um dos motivos é a ausência de necessidade de um algoritmo específico de buscas para modelos com poucos fatores de truncamento. Comparando o modelo proposto 2D-MIMP com o 2D-IMP impondo a condição de não linearidade, o modelo proposto apresenta desempenho superior para ambos os canais, atingindo ganho de NMSE de até 3,76 dB e 2,76 dB para modelagem inversa para os canais 1 e 2, respectivamente.

Em relação à modelagem de banda tripla concorrente com portadoras não múltiplas,

os modelos da literatura citados na fundamentação teórica são comparados verificando o NMSE em função do número de parâmetros exigidos pelo modelo variando os parâmetros e utilizando busca exaustiva para obter o melhor resultado. Os resultados mostram que entre os modelos da literatura o 3D-MB apresenta resultado superior e isso acontece por conta do modelo incluir fatores distintos. Dessa forma, o modelo proposto 3D-IMP inclui um montante de 20 fatores de truncamento distintos para garantir acurácia com poucos parâmetros. Por conta do montante de fatores, a busca exaustiva torna-se inviável e, então, o algoritmo de escolha dos fatores de truncamento proposto AscFat faz a busca com pouca quantidade de testes. Resultados apontam que o 3D-IMP aplicando algoritmo AscFat apresenta desempenho de modelagem superior ao 3D-MB, em particular, diferenças de até 5,9 dB, 6,1 dB e 8,3 dB para os canais 1, 2 e 3 foram obtidas para mesma quantidade de parâmetros. E para quantidade pequena de coeficientes, o algoritmo AscFat possui resultado quase ótimo, validando o algoritmo em banda tripla. Aplicando a melhor combinação do 3D-MB com busca exaustiva e 3D-IMP com AscFat para até 20 parâmetros na linearização do PA, resultados de EVM apontam ganho de até 0,39 p.p., reforçado pelas curvas de PSD e magnitude de erro que indicam desempenho melhor do modelo proposto.

Em relação à linearização do PA em banda tripla concorrente de portadoras múltiplas, o modelo proposto 3D-HIMP é comparado com o modelo da literatura 3D-HMP. Além de incluir todos os termos de intermodulação harmônica com produto de até 4 termos, o modelo proposto segue a ideia de incluir quantidades significativas de fatores de truncamento, totalizando em 140 fatores. Na modelagem inversa, avaliando o NMSE em função do número de parâmetros para as melhores combinações dos fatores de truncamento, o modelo proposto 3D-HIMP com algoritmo AscFat reduz o NMSE em até 11,9 dB, 16,6 dB e 12,3 dB em relação ao modelo da literatura 3D-HMP aplicando busca exaustiva para mesmo número de parâmetros. Implementando o DPD com até 40 coeficientes por canal em ambos os modelos, reduções de até 1,23 p.p. no EVM e nas curvas de PSD demonstram a efetividade do modelo proposto em conjunto com o algoritmo AscFat.

Em relação à saturação de bandas múltiplas, duas abordagens, da soma e da divisão, foram apresentadas para banda dupla concorrente onde as envoltórias não são múltiplas entre si. A saturação é aplicada com base na envoltória equivalente produzida em torno de uma portadora média e o sobre-sinal é distribuído para ambos os canais através da soma ou da divisão. As metodologias para ceifar as envoltórias restringiram corretamente a amplitude em torno da portadora média mas não necessariamente garantem que o modelo não seja extrapolado. A saturação para banda dupla foi aplicada na linearização do PA com dados Wi-Fi em 2,4 GHz e LTE em 3,5 GHz. Foi possível elevar a potência de saída aos limites das normas garantindo melhor desempenho aplicando a linearização com saturação do que sem linearização. Em específico, a saturação permitiu

ganho de 8,8% (de 14,7% para 16,0%) em PAE com degradação de EVM abaixo de 1 p.p se comparada à linearização tradicional e redução de até 9,5 p.p. em EVM se comparado ao caso sem linearização para mesma potência média de saída.

## 6.2 Publicações relacionadas com essa pesquisa

Os seguintes trabalhos foram publicados até a data da defesa:

1. O artigo intitulado *Comparison between direct and indirect learnings for the digital pre-distortion of concurrent dual-band power amplifiers* apresentado no *Symposium on Integrated Circuits and Systems Design* em 2019 apresenta uma prévia e um estudo de caso comparando a aprendizagem indireta com a aprendizagem direta para cenários de comunicação de banda dupla concorrente aplicando modelos polinomiais (SCHUARTZ *et al.*, 2019b);
2. O artigo intitulado *Modified indirect learning applied to neural network-based pre-distortion of a concurrent dual-band CMOS power amplifier* publicado no periódico *Analog Integrated Circuits and Signal Processing* em 2021 contém uma versão estendida do artigo acima apresentando um comparativo entre as aprendizagens direta e indireta e inclui a aprendizagem indireta modificada fruto dessa pesquisa (SCHUARTZ *et al.*, 2021);
3. O artigo intitulado *Concurrent Tri-band CMOS Power Amplifier Linearized by 3D Improved Memory Polynomial Digital Predistorter* publicado no periódico *Circuits, Systems, and Signal Processing* em 2021 contém as contribuições referentes aos modelos para transmissão em banda tripla concorrentes e o algoritmo de escolha dos fatores de truncamento AscFat (SCHUARTZ *et al.*, 2021).

## 6.3 Propostas para trabalhos futuros

1. Desenvolver modelo capaz de prever distorções de todo o conteúdo espectral (interferência dentro da banda, intermodulação cruzada e harmônica) dentro e fora da banda de interesse com a ausência de informações fora das bandas de interesse;
2. Permitir a remoção de conteúdo espectral fora das bandas de interesse causado por distorções harmônicas e de modulação cruzada com a ausência de informações dessas bandas;
3. Estimar com precisão a redução de potência que pode ser atingida com os modelos propostos;

4. Unir os desenvolvimentos dessa tese em uma única linearização e avaliar os ganhos em acurácia em relação às abordagens tradicionais;
5. Melhorar as abordagens de saturação restringindo com confiabilidade maior a extrapolação dos modelos ou tratando as extrapolações de forma controlada;
6. Avaliar o comportamento da saturação de bandas múltiplas ao aplicar níveis de potência distintos para cada um dos canais possibilitando que um canal atinja pontos de saturação mais rapidamente, e dessa forma, modificando separadamente os níveis de distorção de cada canal;
7. Fazer uma análise do desempenho em circuitos físicos dos desenvolvimentos dessa tese.

## BIBLIOGRAFIA

ACKERMANN, T. *et al.* A robust digital predistortion algorithm for 5g mimo: Modeling a mimo scenario with two nonlinear mimo transmitters including a cross-coupling effect. **IEEE Microwave Magazine**, IEEE, v. 21, n. 7, p. 54–62, 2020.

BASSAM, S. A.; HELAOUI, M.; GHANNOUCHI, F. M. 2-d digital predistortion (2-d-dpd) architecture for concurrent dual-band transmitters. **IEEE Transactions on Microwave Theory and Techniques**, IEEE, v. 59, n. 10, p. 2547–2553, 2011.

BAUDOIN, G.; JARDIN, P. Adaptive polynomial pre-distortion for linearization of power amplifiers in wireless communications and wlan. In: IEEE. **EUROCON'2001. International Conference on Trends in Communications. Technical Program, Proceedings (Cat. No. 01EX439)**. [S.l.], 2001. v. 1, p. 157–160.

BONFIM, E. J.; LIMA, E. G. Um novo modelo com memória baseado em aproximações polinomiais bidimensionais para transmissores de sistemas de comunicações sem fio. **XXXIII simpósio Brasileiro de Telecomunicações SBrT2015**, SBrT2015, 2015.

BROYDEN, C. G. The convergence of a class of double-rank minimization algorithms 1. general considerations. **IMA Journal of Applied Mathematics**, Oxford University Press, v. 6, n. 1, p. 76–90, 1970.

CHAVEZ, J. H. *et al.* Optimal parameter identification for look-up table based band-limited memory polynomial model using direct and indirect learnings. **Journal of Integrated Circuits and Systems**, v. 13, n. 2, p. 1–6, 2018.

CHEN, S.; COWAN, C. F.; GRANT, P. M. Orthogonal least squares learning algorithm for radial basis function networks. **IEEE Transactions on neural networks**, IEEE, v. 2, n. 2, p. 302–309, 1991.

COLEMAN, T. F.; LI, Y. On the convergence of interior-reflective newton methods for nonlinear minimization subject to bounds. **Mathematical programming**, Springer, v. 67, n. 1-3, p. 189–224, 1994.

COLEMAN, T. F.; LI, Y. An interior trust region approach for nonlinear minimization subject to bounds. **SIAM Journal on optimization**, SIAM, v. 6, n. 2, p. 418–445, 1996.

CRIPPS, S. C. **RF power amplifiers for wireless communications**. 2nd. ed. Norwood, MA: Artech House, 2006.

DARDAILLON, M.; JABBOUR, C.; SRINI, V. P. Adaptive digital pre-distortion for future wireless transmitters. In: IEEE. **Electronics, Circuits, and Systems (ICECS), 2015 IEEE International Conference on**. [S.l.], 2015. p. 332–335.

DESGREYS, P. *et al.* Wideband power amplifier predistortion: Trends, challenges and solutions. In: IEEE. **ASIC (ASICON), 2017 IEEE 12th International Conference on**. [S.l.], 2017. p. 100–103.

ESMAEL, M. M.; ABDALLA, M. A.; ESHRAH, I. A. A 19-43 ghz linear power amplifier in 28nm bulk cmos for 5g phased array. In: IEEE. **2019 IEEE Topical Conference on RF/Microwave Power Amplifiers for Radio and Wireless Applications (PAWR)**. [S.l.], 2019. p. 1–3.

EUN, C.; POWERS, E. J. A new volterra predistorter based on the indirect learning architecture. **IEEE transactions on signal processing**, IEEE, v. 45, n. 1, p. 223–227, 1997.

FIORELLI, R. *et al.* Normalized nonlinear semiempirical most model used in monolithic rf class a-to-c pas. **Circuits, Systems, and Signal Processing**, Springer, p. 1–26, 2019.

FLETCHER, R. A new approach to variable metric algorithms. **The computer journal**, Oxford University Press, v. 13, n. 3, p. 317–322, 1970.

FREIRE, L. B. C. *et al.* Behavioral modeling of power amplifiers using perceptrons with complex activation functions. **35<sup>o</sup> Simpósio Sul de Microeletrônica, 35<sup>o</sup> SIM**, Ijuí e São Miguel das Missões, RS, p. 1–4, 2020.

FREIRE, L. B. C. *et al.* Behavioral modeling of a multimode power amplifier using perceptrons with am-am and am-pm complex-valued activation function. **Journal of Integrated Circuits and Systems**, v. 16, n. 1, p. 1–11, 2021.

GILABERT, P. L. *et al.* Order reduction of wideband digital predistorters using principal component analysis. In: IEEE. **Microwave Symposium Digest (IMS), 2013 IEEE MTT-S International**. [S.l.], 2013. p. 1–7.

GILABERT, P. L. *et al.* Digital predistorters go multidimensional: Dpd for concurrent multiband envelope tracking and outphasing power amplifiers. **IEEE Microwave Magazine**, IEEE, v. 20, n. 5, p. 50–61, 2019.

GUAN, L.; ZHU, A. Green communications: Digital predistortion for wideband rf power amplifiers. IEEE, 2014.

HASIN, M. R.; KITCHEN, J. A compact watt-level gan-on-si class ab power amplifier for handset applications. In: IEEE. **Wireless and Microwave Circuits and Systems (WMCS), 2017 Texas Symposium on**. [S.l.], 2017. p. 1–4.

HAYKIN, S. **Sistemas de comunicação**. [S.l.]: Bookman, 2004.

HAYKIN, S. **Communication Systems**. 5th. ed. [S.l.: s.n.], 2009.

JARAUT, P.; RAWAT, M.; GHANNOUCHI, F. M. Harmonically related concurrent tri-band behavioral modeling and digital predistortion. **IEEE Transactions on Circuits and Systems II: Express Briefs**, IEEE, v. 66, n. 6, p. 1073–1077, 2018.

JORDAO, M. *et al.* Mixed-signal soc characterization for future 5g dpd applications [application notes]. **IEEE Microwave Magazine**, IEEE, v. 21, n. 2, p. 14–23, 2020.

KELLY, N.; CAO, W.; ZHU, A. Preparing linearity and efficiency for 5g: Digital predistortion for dual-band doherty power amplifiers with mixed-mode carrier aggregation. **IEEE microwave magazine**, IEEE, v. 18, n. 1, p. 76–84, 2016.

KHAWAM, Y.; ALBASHA, L.; MIR, H. Accurate and low complexity polynomial and neural network models for pa digital pre-distortion. In: IEEE. **Microwave Symposium (MMS), 2016 16th Mediterranean**. [S.l.], 2016. p. 1–4.

KIM, J.; KONSTANTINOU, K. Digital predistortion of wideband signals based on power amplifier model with memory. **Electronics Letters**, IET, v. 37, n. 23, p. 1417–1418, 2001.

KWAN, A. K. *et al.* Selective intermodulation compensation in a multi-stage digital predistorter for nonlinear multi-band power amplifiers. **IEEE Journal on Emerging and Selected Topics in Circuits and Systems**, IEEE, v. 7, n. 4, p. 534–546, 2017.

LI, T.-W.; HUANG, M.-Y.; WANG, H. Millimeter-wave continuous-mode power amplifier for 5g mimo applications. **IEEE Transactions on Microwave Theory and Techniques**, IEEE, v. 67, n. 7, p. 3088–3098, 2019.

LIU, Y. *et al.* A new digital predistortion using indirect learning with constrained feedback bandwidth for wideband power amplifiers. In: IEEE. **2014 IEEE MTT-S International Microwave Symposium (IMS2014)**. [S.l.], 2014. p. 1–3.

MANYAM, V. N. *et al.* A low-power high-performance digital predistorter for wideband power amplifiers. **Analog Integrated Circuits and Signal Processing**, Springer, v. 97, n. 3, p. 483–492, 2018.

MATHEWS, V. J.; SICURANZA, G. L. **Polynomial signal processing**. [S.l.]: Wiley-Interscience, 2000.

MATLAB, D. **Optimization toolbox user’s guide**. [S.l.]: Version, 2020.

MAYEDA, J.; LIE, D.; LOPEZ, J. A highly efficient and linear 15 ghz gan power amplifier design for 5g communications. In: IEEE. **Wireless and Microwave Circuits and Systems (WMCS), 2017 Texas Symposium on**. [S.l.], 2017. p. 1–4.

MCKINLEY, M. D. *et al.* Evm calculation for broadband modulated signals. In: **64th ARFTG Conf. Dig.** [S.l.: s.n.], 2004. p. 45–52.

MKADEM, F.; ISLAM, A.; BOUMAIZA, S. Multi-band complexity-reduced generalized-memory-polynomial power-amplifier digital predistortion. **IEEE Transactions on Microwave Theory and Techniques**, IEEE, v. 64, n. 6, p. 1763–1774, 2016.

MORGAN, D. R. *et al.* A generalized memory polynomial model for digital predistortion of rf power amplifiers. **IEEE Transactions on signal processing**, IEEE, v. 54, n. 10, p. 3852–3860, 2006.

MUHA, M. *et al.* Validation of power amplifier nonlinear block models. In: IEEE. **Microwave Symposium Digest, 1999 IEEE MTT-S International**. [S.l.], 1999. v. 2, p. 759–762.

NAIK, G.; LIU, J.; PARK, J. M. Coexistence of wireless technologies in the 5 ghz bands: A survey of existing solutions and a roadmap for future research. **IEEE Communications Surveys Tutorials**, p. 1–1, 2018.

NARAHARISETTI, N. *et al.* Quasi-exact inverse pa model for digital predistorter linearization. In: IEEE. **82nd ARFTG microwave measurement conference**. [S.l.], 2013. p. 1–4.

NIELSEN, J. J.; LIU, R.; POPOVSKI, P. Optimized interface diversity for ultra-reliable low latency communication (urllc). In: IEEE. **GLOBECOM 2017-2017 IEEE Global Communications Conference**. [S.l.], 2017. p. 1–6.

OJHA, V. K.; ABRAHAM, A.; SNÁŠEL, V. Metaheuristic design of feedforward neural networks: A review of two decades of research. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 60, p. 97–116, 2017.

PEDRO, J. C.; MAAS, S. A. 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, April 2005. ISSN 0018-9480.

PENG, X.; QIU, X.; MU, F. Digital harmonic canceling algorithm for power amplifiers based on nonlinear adaptive filter. **Progress In Electromagnetics Research**, EMW Publishing, v. 65, p. 151–164, 2018.

PRATT, P.; KEARNEY, F. Ultrawideband digital predistortion (dpd): The rewards (power and performance) and challenges of implementation in cable distribution systems. **10 Massive MIMO and Beamforming: The Signal Processing Behind the 5G Buzzwords**, p. 22, 2017.

RAWAT, M. *et al.* Concurrent dual-band modeling and digital predistortion in the presence of unfilterable harmonic signal interference. **IEEE Transactions on Microwave Theory and Techniques**, IEEE, v. 63, n. 2, p. 625–637, 2015.

RAZAVI, B.; BEHZAD, R. **RF microelectronics**. [S.l.]: Prentice Hall New Jersey, 1998.

REYNAERT, P.; STEYAERT, M. **RF power amplifiers for mobile communications**. [S.l.]: Springer Science & Business Media, 2006.

RIBA, O.; LIMA, E. G. Improved 2d memory polynomial model for the digital baseband predistortion of dual-band rf pas. **31<sup>o</sup> Simpósio Sul de Microeletrônica, 31<sup>o</sup> SIM**, Porto Alegre, RS, p. 1–4, 2016.

SCHUARTZ, L. *et al.* Modified indirect learning applied to neural network-based pre-distortion of a concurrent dual-band cmos power amplifier. **Analog Integrated Circuits and Signal Processing**, Springer, v. 106, n. 1, p. 277–292, 2021.

SCHUARTZ, L. *et al.* Saturated predistorter for efficiency improvement of a cmos pa for 3.5 ghz lte and wi-fi in 2.4 and 5 ghz. **34<sup>o</sup> Simpósio Sul de Microeletrônica, 34<sup>o</sup> SIM**, Pelotas, RS, p. 139–142, 2019.

SCHUARTZ, L. *et al.* Comparison between direct and indirect learnings for the digital pre-distortion of concurrent dual-band power amplifiers. In: IEEE. **2019 32nd Symposium on Integrated Circuits and Systems Design (SBCCI)**. [S.l.], 2019. p. 1–5.

- SCHUARTZ, L.; LIMA, E. G. Comparison among algorithms for the identification of adaptive memory polynomial predistorter models. **30<sup>o</sup> Simpósio Sul de Microeletrônica**, 30<sup>o</sup> SIM, Santa Maria, RS, p. 1–4, 2015.
- SCHUARTZ, L.; LIMA, E. G. Aproximações polinomiais com memória de complexidade reduzida baseada em mínimos quadrados ortogonais. **Revista Jr de Iniciação Científica em Ciências Exatas e Engenharia**, ICCEEg, p. 11–16, 2016.
- SCHUARTZ, L. *et al.* Incremental and decremental approaches to reduce the number of parameters in polynomial models. **33<sup>o</sup> Simpósio Sul de Microeletrônica**, 33<sup>o</sup> SIM, Curitiba, PR, p. 49–52, 2018.
- SCHUARTZ, L. *et al.* Traditional and saturated digital baseband predistorters for wireless transmitters. **33<sup>o</sup> Simpósio Sul de Microeletrônica**, 33<sup>o</sup> SIM, Curitiba, PR, p. 93–96, 2018.
- SCHUARTZ, L. *et al.* Reduced-complexity polynomials with memory applied to the linearization of power amplifiers with real-time discrete gain control. **Circuits, Systems, and Signal Processing**, Springer, v. 38, n. 9, p. 3901–3930, 2019.
- SCHUARTZ, L. *et al.* Concurrent tri-band cmos power amplifier linearized by 3d improved memory polynomial digital predistorter. **Circuits, Systems, and Signal Processing**, Springer, v. 40, n. 5, p. 2176–2208, 2021.
- SHANNO, D. F. Conditioning of quasi-newton methods for function minimization. **Mathematics of computation**, v. 24, n. 111, p. 647–656, 1970.
- SHOKAIR, A. *et al.* Wide band digital predistortion using iterative feedback decomposition. **Analog Integrated Circuits and Signal Processing**, Springer, v. 100, n. 1, p. 93–108, 2019.
- TEHRANI, A. S. *et al.* A comparative analysis of the complexity/accuracy tradeoff in power amplifier behavioral models. **IEEE Transactions on Microwave Theory and Techniques**, IEEE, v. 58, n. 6, p. 1510–1520, 2010.
- TIAN, T. *et al.* A novel concurrent tri-band digital predistortion for broadband signals. In: IEEE. **2015 10th European Microwave Integrated Circuits Conference (EuMIC)**. [S.l.], 2015. p. 285–288.
- VARAHRAM, P. *et al.* A digital pre-distortion based on nonlinear autoregressive with exogenous inputs. **IEEE Microwave and Wireless Components Letters**, IEEE, v. 26, n. 5, p. 364–366, 2016.
- WANG, Y.; WU, R.; OKADA, K. A compact 39-ghz 17.2-dbm power amplifier for 5g communication in 65-nm cmos. In: IEEE. **2018 IEEE International Symposium on Radio-Frequency Integration Technology (RFIT)**. [S.l.], 2018. p. 1–3.
- WANG, Z.; CHEN, W.; SU, G. Low computational complexity digital pre-distortion for broadband power amplifiers. In: **2015 Asia-Pacific Microwave Conference (APMC)**. [S.l.: s.n.], 2015. v. 1, p. 1–3.

WOOD, J. Digital pre-distortion of rf power amplifiers: progress to date and future challenges. In: IEEE. **Microwave Symposium (IMS), 2015 IEEE MTT-S International**. [S.l.], 2015. p. 1–3.

YOUNES, M. *et al.* Linearization of concurrent tri-band transmitters using 3-d phase-aligned pruned volterra model. **IEEE transactions on microwave theory and techniques**, IEEE, v. 61, n. 12, p. 4569–4578, 2013.

YOUNES, M. *et al.* Three-dimensional digital predistorter for concurrent tri-band power amplifier linearization. In: IEEE. **2013 IEEE MTT-S International Microwave Symposium Digest (MTT)**. [S.l.], 2013. p. 1–4.

YU, C. *et al.* Linear-decomposition digital predistortion of power amplifiers for 5g ultrabroadband applications. **IEEE Transactions on Microwave Theory and Techniques**, IEEE, 2020.

ZUREK, P.; CAPPELLO, T.; POPOVIĆ, Z. A concurrent 2.2/3.9-ghz dual-band gan power amplifier. In: IEEE. **2019 IEEE Topical Conference on RF/Microwave Power Amplifiers for Radio and Wireless Applications (PAWR)**. [S.l.], 2019. p. 1–4.