

UNIVERSIDADE FEDERAL DO PARANÁ

JOÃO CARLOS DA SILVA

Modelagem comportamental de amplificadores de potência de RF utilizando redes neurais de ligação funcional com polinômio de Chebyshev

CURITIBA

2014

JOÃO CARLOS DA SILVA

Modelagem comportamental de amplificadores de potência de RF utilizando redes neurais de ligação funcional com polinômio de Chebyshev

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

Orientador: Prof. Dr. Eduardo Gonçalves de Lima

CURITIBA

2014

S586m

Silva, João Carlos da

Modelagem comportamental de amplificadores de potencia de RF utilizando redes neurais de ligação funcional com polinômio de Chebyshev / João Carlos da Silva. – Curitiba, 2014..

60f. : il. [algumas color.] ; 30 cm.

Dissertação (mestrado) - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-graduação em Engenharia Elétrica, 2014.

Orientador: Eduardo Gonçalves de Lima.

Bibliografia: p. 55-58.

1. Amplificadores de potência. 2. Chebyshev, polinomio de. I. Universidade Federal do Paraná. II. Lima, Eduardo Gonçalves de. III. Título.

CDD: 621.381



UNIVERSIDADE FEDERAL DO PARANÁ
Programa de Pós-Graduação em Engenharia Elétrica
PPGEE
Setor de Tecnologia

ATA DE DEFESA DE MESTRADO

Aos trinta e um dias do mês de outubro de 2014, na Sala PK 07 do Departamento de Engenharia Elétrica, foi instalada pela Prof^a. Dr^a. Thelma Solange Piazza Fernandes, Coordenadora do Programa de Pós-Graduação em Engenharia Elétrica, a Banca Examinadora para a centésima sexagésima Dissertação de Mestrado do PPGEE, na Área de Concentração em **TELECOMUNICAÇÕES**. Estiveram presentes no ato, além da Coordenadora do Curso de Pós-Graduação, professores, alunos e visitantes.

A Banca Examinadora, atendendo determinação do Colegiado do Programa de Pós-Graduação em Engenharia Elétrica, ficou constituída pelos professores doutores **Eduardo Gonçalves de Lima (Orientador - UFPR)**; **Paulo Henrique Siqueira (UFPR)**; **André Augusto Mariano (UFPR)** e **Luis Henrique de Assumpção Lolis (UFPR)**.


Às 14:00 horas, a banca iniciou os trabalhos, convidando o candidato **JOÃO CARLOS DA SILVA** a fazer a apresentação da dissertação intitulada "**MODELAGEM COMPORTAMENTAL DE AMPLIFICADORES DE POTÊNCIA DE RF UTILIZANDO REDES NEURAIS DE LIGAÇÃO FUNCIONAL COM POLINÔMIO DE CHEBYSHEV**". Encerrada a apresentação, iniciou-se a fase de arguição pelos membros participantes.

Tendo em vista a dissertação e a arguição, a banca decidiu pela:

APROVAÇÃO

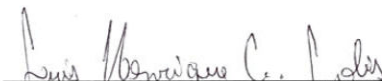
NÃO APROVAÇÃO do candidato, (de acordo com a determinação da Resolução 63/03-CEPE).

Curitiba, 31 de outubro 2014.


Prof. Dr. **Eduardo Gonçalves de Lima**


Prof. Dr. **Paulo Henrique Siqueira**


Prof. Dr. **André Augusto Mariano**


Prof. Dr. **Luis Henrique de Assumpção Lolis**

AGRADECIMENTOS

A Deus, pela sua misericórdia e sabedoria dada a mim.

A Jesus, por ter me dado uma nova vida.

A minha amada esposa Patrícia e meu filho amado Gustavo, pela paciência, pela motivação e pelo auxílio na caminhada do mestrado.

Ao Prof. Dr. Eduardo Gonçalves de Lima, meu orientador, pela grande confiança, pela compreensão e pela dedicação e prontidão no desenvolvimento desta dissertação.

Aos amigos e colegas do Departamento de Engenharia Elétrica da Universidade Federal do Paraná, pela companhia.

Não me escolhestes vós a mim, mas eu vos escolhi a vós, e vos nomeei, para que vades e deis fruto, e o vosso fruto permaneça; a fim de que tudo quanto em meu nome pedirdes ao Pai ele vo-lo conceda.

João 15:16.

RESUMO

Este trabalho aborda a modelagem comportamental de amplificadores de potência de RF (PAs RF) utilizando a Rede Neural de Ligação Funcional (FLNN) com polinômio de Chebyshev (CFLNN). De um ponto de vista matemático, um PA RF pode ser visto como um sistema passa-banda não linear com memória. Neste trabalho, diferentemente das abordagens anteriores, a natureza passa-banda do PA RF é imposta ao CFLNN a fim de melhorar o compromisso entre a precisão do modelo e a complexidade computacional. Duas estratégias diferentes para incorporar as restrições de passa-banda são investigadas: a primeira estratégia é mudar apenas o processamento dentro do CFLNN e a segunda mudar os sinais de entrada e saída do CFLNN. Os modelos comportamentais baseados em CFLNN propostos são validados usando dados experimentais medidos em um PA classe AB baseado em transistor GaN (Nitreto de Gálio). Verifica-se que, em comparação com a abordagem caixa-preta anterior, em um cenário de número similar de parâmetros, o CFLNN proposto que impõe a restrição de passa-banda modificando seus sinais de entrada e saída reduz o erro quadrático médio normalizado (NMSE) em até 2 dB e a razão entre a potência do sinal de erro no canal adjacente e a potência do sinal de saída na banda passante (ACEPR) em até 3 dB. Alternativamente, observa-se que, para obter um NMSE inferior a -45 dB, o modelo proposto que impõe a restrição de passa-banda modificando seus sinais de entrada e saída utiliza 80% menos coeficientes que a abordagem anterior (56 parâmetros ao invés de 281 parâmetros).

Palavras-chave—Amplificador de potência; modelagem; polinômio de Chebyshev; rádio-frequência; rede neural de ligação funcional; sistema passa-banda.

ABSTRACT

This work addresses the behavioral modeling of RF power amplifiers (PAs) using the Chebyshev Functional Link Neural Network (CFLNN). From a mathematical point of view, an RF PA can be seen as a nonlinear bandpass system with memory. In here, differently from previous approaches, the bandpass nature of RF PAs is imposed on the CFLNN in order to improve the trade-off between model accuracy and computational complexity. Two different strategies for incorporating the bandpass constraints are investigated: changing the processing through the CFLNN or changing the CFLNN input and output signals. The proposed CFLNN behavioral models are validated using experimental data measured on a GaN-based class AB PA. It is verified that, in comparison with the previous black-box approach in a scenario of similar number of parameters, the proposed CFLNN that imposes the bandpass constraint by modifying its input and output signals reduces the normalized mean square error (NMSE) up to 2 dB and the adjacent channel error power ratio (ACEPR) up to 3 dB.

Keywords—Bandpass system; Chebyshev polynomial; functional link neural network; modeling; power amplifier; radio-frequency.

LISTA DE FIGURAS

FIGURA 1	- DIAGRAMA DE BALANCEAMENTO DE POTÊNCIAS DE UM AMPLIFICADOR.....	15
FIGURA 2	- GRÁFICOS TÍPICOS DE UM PA RF: RENDIMENTO E GANHO DE POTÊNCIA EM FUNÇÃO DA POTÊNCIA RF DE ENTRADA.....	17
FIGURA 3	- ESPECTROS DE FREQUÊNCIA NA SAÍDA DE UM TÍPICO PA RF OPERANDO EM COMPRESSÃO E EXCITADO POR UM SINAL DE DOIS TONS (NAS FREQUÊNCIAS ω_1 e ω_2).....	19
FIGURA 4	- GRÁFICO DA INTERPRETAÇÃO DO PONTO DE COMPRESSÃO DE 1 dB: POTÊNCIA DE SAÍDA EM FUNÇÃO DA POTÊNCIA DE ENTRADA DE UM AMPLIFICADOR DE POTÊNCIA GENÉRICO E PONTO DE COMPRESSÃO DE 1dB.....	20
FIGURA 5	- BANDAS DE INTEGRAÇÃO USADAS NA CARACTERIZAÇÃO DA ACPR.....	21
FIGURA 6	- FORMA DE ONDA DE UM SINAL DE RF MODULADO EM AMPLITUDE E FASE.....	23
FIGURA 7	- MODELAGEM COMPORTAMENTAL DE PA RF.....	25
FIGURA 8	- PROPRIEDADE E CLASSIFICAÇÃO DE MODELAGEM COMPORTAMENTAL DE PA RF.....	26
FIGURA 9	- ESPECTRO DO SINAL REAL $x(t)$, DO ANALÍTICO $\tilde{x}(t)e^{j\omega_0 t}$ E DO SINAL DE ENVOLTÓRIA-COMPLEXA $\tilde{x}(t)$	28
FIGURA 10	- ESPECTRO DO SINAL DE ENTRADA DE RF $ \tilde{x}(t) \cos(\omega_c t + \theta_t)$ E DO SINAL DE SAÍDA DE RF $ \tilde{y}(t) \cos(\omega_c t + \varphi_t + \theta_t)$ DE UM TÍPICO PA RF.....	29
FIGURA 11	- SINAIS MANIPULADOS PELOS MODELOS PASSA-BANDA E EQUIVALENTE PASSA-BAIXAS.....	31
FIGURA 12	- DIAGRAMA DE BLOCO DA REDE NEURAL DE LIGAÇÃO FUNCIONAL (FLNN).....	33
FIGURA 13	- DIAGRAMA DE BLOCO DO CFLNN PROPOSTO COM DIFERENTES ENTRADAS E SAÍDA.....	44

FIGURA 14	- PROCEDIMENTO DE IDENTIFICAÇÃO DO SISTEMA.....	47
FIGURA 15	- PROCEDIMENTO DE IDENTIFICAÇÃO DO MODELO COMPORTAMENTAL DE PA RF BASEADO EM CFLNN.....	48
FIGURA 16	- RESULTADOS DE NMSE EM FUNÇÃO DO NÚMERO DE PARÂMETROS.....	50
FIGURA 17	- RESULTADOS DE ACEPR EM FUNÇÃO DO NÚMERO DE PARÂMETROS.....	51
FIGURA 18	- PSD DOS SINAIS DE ERRO: CFLNN MOD_IN / OUT TEM 251 PARÂMETROS; CFLNN PREVIOUS TEM 281 PARÂMETROS; CFLNN MOD_PROCES TEM 280 PARÂMETROS.....	52

LISTA DE TABELAS

TABELA 1	- CONTRIBUIÇÕES DE 2ª ORDEM.....	35
TABELA 2	- EXEMPLO PARA O CASO ONDE $E=3$, $P=3$ E $S=1$	37
TABELA 3	- EXEMPLO DE CONJUGAÇÃO ADEQUADA PARA O CASO ONDE $E=3$, $P=3$ E $S=1$	40
TABELA 4	- EXEMPLO DE REMOVER AS CONSTANTES PARA O CASO ONDE $E=3$, $P=3$ E $S=1$	43

LISTA DE SIGLAS

3GPP	<i>3th Generation Partnership Project</i>
ACP	<i>Adjacent-Channel Power</i>
ACPR	<i>Adjacent-Channel Power Ratio</i>
ACEPR	<i>Adjacent Channel Error Power Ratio</i>
ANN	<i>Artificial Neural Network</i>
BW	<i>Bandwidth</i>
CC	Corrente Contínua
CFLNN	<i>Chebyshev Functional Link Neural Network</i>
dB	Decibel
FLNN	<i>Functional Link Neural Network</i>
GaN	Nitreto de Gálio
IMR	<i>Intermodulation Ratio</i>
MATLAB	<i>MATrix LABoratory</i>
MIMO	<i>Multiple-input Multiple-output</i>
NMSE	<i>Normalized Mean Square Error</i>
P1dB	Ponto de Compressão a 1 dB
PA	Amplificador de Potência
PAPR	<i>Peak-to-Average Power Ratio</i>
P_{DC}	Potência Fornecida pela Fonte de Alimentação
P_{DISS}	Potência Dissipada
P_{in}	Potência de Entrada
P_{out}	Potência de Saída
RBF	<i>Radial Basis Function</i>
RF	Rádio-Frequência
RNA	Rede Neural Artificial
SISO	<i>Single-input Single-output</i>
PAE	<i>Power Added Efficiency</i>
PSD	<i>Power Spectral Density</i>
TLP	<i>Three-Layer Perceptron</i>
WCDMA	<i>Wideband Code-Division Multiple Access</i>

SUMÁRIO

1 INTRODUÇÃO	12
1.1 MOTIVAÇÃO.....	12
1.2 OBJETIVO GERAL.....	14
1.3 ORGANIZAÇÃO DA DISSERTAÇÃO.....	14
2 CONCEITOS BÁSICOS SOBRE AMPLIFICADORES DE POTÊNCIA DE RÁDIO-FREQUÊNCIA	15
2.1 EFICIÊNCIA.....	16
2.2 LINEARIDADE.....	18
2.3 COMPROMISSO ENTRE LINEARIDADE E EFICIÊNCIA.....	22
2.4 MODELAGEM COMPORTAMENTAL DE PA RF.....	23
2.5 MODELO COMPORTAMENTAL EQUIVALENTE PASSA-BAIXAS PARA PA RF.....	27
3 REDE NEURAL DE LIGAÇÃO FUNCIONAL (FLNN)	32
3.1 REDE NEURAL DE LIGAÇÃO FUNCIONAL (FLNN).....	32
3.2 TREINAMENTO DA REDE FLNN.....	37
3.3 MODELAGEM COMPORTAMENTAL EQUIVALENTE PASSA-BAIXAS DO PA RF UTILIZANDO CHEBYSHEV FLNN.....	38
3.4 PROPOSTA PARA NOVOS MODELOS COMPORTAMENTAIS EQUIVALENTE PASSA-BAIXAS DE PA RF UTILIZANDO CHEBYSHEV FLNNS.....	41
4 VALIDAÇÃO DOS MODELOS PROPOSTOS	46
4.1 RESULTADOS.....	49
5 CONCLUSÃO	54
5.1 CONCLUSÃO.....	54
5.2 SUGESTÃO DE TRABALHO FUTURO.....	54
BIBLIOGRAFIA	55

CAPÍTULO 1

INTRODUÇÃO

1.1 Motivação

A eficiência energética tem sido sempre um assunto de grande importância em sistemas de comunicação *wireless* (sem fio) [1]. Para os aparelhos portáteis, a grande preocupação é aumentar o tempo de autonomia da bateria, enquanto que para as estações de rádio-base, o interesse principal é a redução dos custos associados com a dissipação de calor e consumo de energia. Transmissores *wireless* tradicionais que proporcionam amplificação baseados em transistores de estado sólido só podem fornecer uma alta eficiência em um nível de potência única. Isto é devido ao fato de que os transistores de estado sólido, independente da classe de funcionamento, apresentam um compromisso entre linearidade e eficiência [2]. Como consequência, uma eficiência elevada apenas pode ser atingida se o sinal de portadora de RF é modulado por um sinal com amplitude constante, o que implica em taxas de dados baixas adequadas apenas para serviços de voz.

Hoje em dia, com o uso generalizado de telefones inteligentes (*smartphones*) e a crescente demanda por novos serviços, tais como serviços *internet* e chamadas de vídeo, a taxa de dados exigida por sistemas sem fio aumentou de forma drástica [3]. Considerando a largura reduzida de banda disponível para os sistemas celulares, as altas taxas de dados necessárias só podem ser alcançadas por meio de esquemas de modulação tanto em amplitude quanto em fase. Do ponto de vista do transistor, significa que é requerida a amplificação linear de uma portadora de rádio-frequência (RF) modulada por um sinal de envoltória com uma amplitude variável e com uma alta razão entre a amplitude de pico e a amplitude média. Portanto, os padrões *wireless* modernos impõem rigorosas exigências para o projeto do amplificador de potência (PA, do inglês *Power Amplifier*). Como consequência, para alcançar simultaneamente a alta

linearidade e a alta eficiência, transmissores sem fio devem incluir um esquema de linearização dentro da cadeia de transmissão [4].

Para fins de linearização utilizando pré-distorção digital em banda base (DPD, do inglês *Digital Baseband Predistortion*), um modelo de PA de baixa complexidade e de alta precisão é obrigatório. Modelos comportamentais ou matemáticos que descrevem o PA com pouco ou nenhum conhecimento *a priori* de suas características físicas internas são a escolha mais adequada para linearização [5]. Além disso, o modelo comportamental tem que ser capaz de levar em conta o comportamento não linear observado em PAs em forte compressão, bem como estimar os efeitos de memória de baixa frequência (atribuídos às redes de polarização do transistor e ao seu auto-aquecimento) e de alta frequência, devido à resposta não plana das redes de casamento de impedâncias [5].

As redes neurais artificiais (RNAs) podem ser utilizadas para fornecer o modelo de PA adequado para fins de linearização. Alguns exemplos de arquiteturas de RNA incluem o *perceptron* de três camadas (TLP, do inglês *Three-Layer Perceptron*) [6], a função de base radial (RBF, do inglês *Radial Basis Function*) [7] e a rede neural de ligação funcional (FLNN, do inglês *Functional Link Neural Network*) [8] - [9]. Comparado com as redes TLP e RBF, a rede FLNN tem a vantagem de ser linear em seus parâmetros, facilitando muito a modelagem comportamental. Então, a FLNN é escolhida como modelo comportamental de PA neste trabalho.

Recentemente, uma rede FLNN, utilizando polinômios de Chebyshev para realizar o bloco de expansão funcional, foi usada para modelar um PA RF [9]. O FLNN proposto em [9] pode ser classificado como uma abordagem caixa-preta pura, uma vez que não leva em consideração nenhum conhecimento físico sobre o PA RF. No entanto, um PA RF é de fato um sistema dinâmico não linear passa-banda e a natureza passa-banda de PAs RF impõe algumas restrições sobre os comportamentos observados na saída do PA [10].

1.2 Objetivo Geral

O objetivo deste trabalho é investigar os benefícios de incluir, na modelagem comportamental de PAs através de redes neurais FLNNs, o conhecimento físico prévio da natureza passa-banda de PAs RF. Para tal fim, as restrições impostas sobre os comportamentos observados na saída do PA serão incorporadas nas redes FLNNs que utilizam polinômios de Chebyshev (CFLNN, do inglês *Chebyshev Functional Link Neural Network*), por meio de duas estratégias diferentes: modificar o bloco de expansão funcional presente na CFLNN ou alterar os sinais de entrada e saída da CFLNN.

Portanto, serão propostos aqui dois novos modelos comportamentais de PAs RF baseados em redes neurais CFLNN. A precisão dos modelos propostos será investigada em função do número de parâmetros necessários para a implementação do CFLNN e comparada com modelos previamente propostos na literatura. A comparação utiliza dados medidos em um laboratório de RF e os modelos são implementados em ambiente Matlab.

1.3 Organização da Dissertação

Esta dissertação está organizada da seguinte forma. No Capítulo 1 estão descritas as motivações e os objetivos deste trabalho. O Capítulo 2 é dedicado à apresentação de conceitos básicos em amplificadores de potência para sistemas de comunicações sem fio, destacando o compromisso entre linearidade e eficiência, a sua modelagem comportamental e a sua natureza banda passante. No Capítulo 3, é discutido o uso de redes neurais para a modelagem de sistemas não lineares dinâmicos, com atenção especial às CFLNNs, inicialmente revisando a abordagem anterior que utilizou CFLNN para a modelagem comportamental de PAs RF e, na sequência, apresentando os dois modelos propostos nesta dissertação. O Capítulo 4 apresenta a validação dos modelos CFLNN propostos. O Capítulo 5 relata as conclusões e sugestões para trabalhos futuros.

CAPÍTULO 2

CONCEITOS BÁSICOS SOBRE AMPLIFICADORES DE POTÊNCIA DE RÁDIO-FREQUÊNCIA

Para iniciar os estudos, temos que compreender o funcionamento básico de um amplificador de potência de rádio-frequência utilizado em sistemas de comunicações sem fio. O PA RF tem a função de amplificar um sinal RF injetado em sua entrada. Esta amplificação consiste em que o sinal de saída possua mais potência (energia) do que o sinal RF de entrada. Porém, temos que levar em conta o princípio da conservação da energia que diz que a energia de um sistema isolado é sempre constante. Portanto, um amplificador é um dispositivo que tem a finalidade de converter energia de uma fonte de potência (fonte de alimentação) contínua (CC) em energia de sinal RF. Este processo está representado na Figura 1.

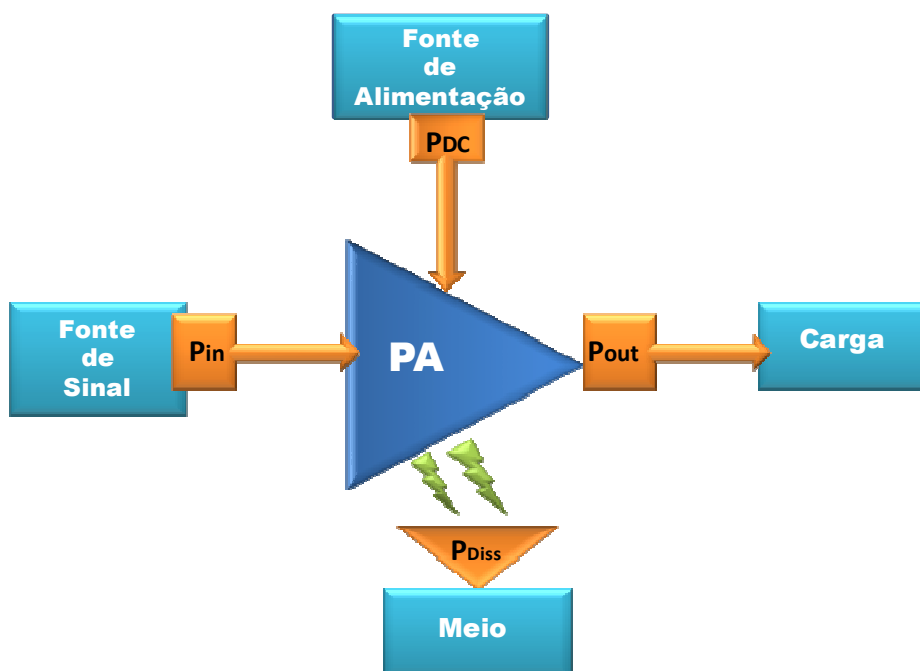


Figura 1. Diagrama de balanceamento de potências de um amplificador, retirado de [11].

O balanceamento das potências em um amplificador obedece a:

$$P_{DC} + P_{in} = P_{out} + P_{Diss} \quad (2.1)$$

onde P_{in} representa a potência do sinal RF de entrada, P_{out} é a potência RF entregue à carga, P_{DC} é a potência consumida da fonte CC e P_{Diss} é a potência dissipada pelo circuito amplificador.

Quando é analisado o funcionamento de um PA RF para aplicação em sistemas de comunicações sem fio, temos que entender dois aspectos importantes, linearidade e eficiência, pois o maior desafio é conseguir simultaneamente uma boa eficiência e uma boa linearidade.

Este capítulo está organizado da seguinte maneira. Na Seção 2.1, é discutida a eficiência de PAs RF, enquanto que na Seção 2.2 é definida a linearidade. O compromisso entre eficiência e linearidade é abordado na Seção 2.3, evidenciando a importância da modelagem comportamental de PAs RF, assunto a ser apresentado na Seção 2.4. Na Seção 2.5, é discutida a natureza banda passante de PAs RF e a sua importância no contexto de modelagem comportamental de PAs RF.

2.1 Eficiência

Um dos grandes desafios no projeto de um PA RF é obter uma alta eficiência. Portanto, primeiro devemos definir o que se entende por eficiência. Duas definições que são usadas com mais frequência são a eficiência de dreno (ou eficiência de coletor, ou ainda rendimento η) e eficiência de potência adicionada (PAE).

A eficiência de dreno (ou eficiência de coletor, ou ainda rendimento η) identifica a porcentagem da potência CC que é convertida em potência RF de saída. Dessa forma, o rendimento é definido como [11]:

$$\eta = \frac{P_{out}}{P_{DC}} \quad (2.2)$$

Porém, existem casos, sobretudo em RF, em que o ganho de potência do PA é tão baixo que a potência RF de entrada - P_{in} - representa uma parte substancial da potência de saída - P_{out} . Nesta situação, o rendimento é substituído pela eficiência de potência adicionada (PAE). Então, define-se a PAE como a relação entre a diferença da potência RF de saída do amplificador (P_{out}) e a potência RF de entrada (P_{in}), sobre a potência fornecida pela fonte de alimentação CC (P_{DC}) [11], de acordo com:

$$PAE = \frac{P_{out} - P_{in}}{P_{DC}} \quad (2.3)$$

Para o projeto de PAs RF são utilizados transistores semicondutores. Embora haja um grande leque de topologias de circuitos para PAs, uma característica comum a praticamente todas as arquiteturas é um aumento no rendimento em função de um aumento na potência do sinal de RF de entrada. A Figura 2 contém um gráfico típico de um PA RF onde se observa a redução do rendimento com a diminuição da potência RF de entrada.

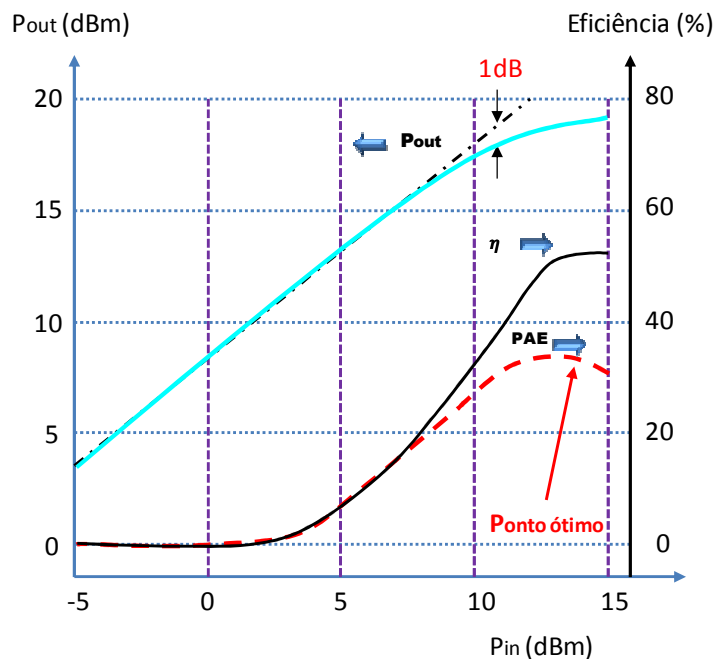


Figura 2. Gráficos típicos de um PA RF: rendimento e ganho de potência em função da potência RF de entrada, retirado de [12].

2.2 Linearidade

Para entender como se estabelece a linearidade em um PA RF, existe a necessidade de definir o que é um sistema linear. Para tanto, considere um sistema que tem uma função característica (F) que relaciona o sinal na sua entrada $x(t)$ com um sinal na sua saída $y(t)$ através de:

$$y(t) = F[x(t)] \quad (2.4)$$

Um sistema linear é aquele que respeita o princípio da homogeneidade e sobreposição, ou seja, se considerarmos como entrada,

$$x(t) = c_1 \cdot x_1(t) + c_2 \cdot x_2(t) \quad (2.5)$$

onde c_1 e c_2 são constantes arbitrárias, então, o sistema é linear se e somente se:

$$y(t) = F[x(t)] = c_1 \cdot y_1(t) + c_2 \cdot y_2(t) \quad (2.6)$$

onde

$$y_1(t) = F[x_1(t)] \quad (2.7)$$

e

$$y_2(t) = F[x_2(t)] \quad (2.8)$$

Caso o sistema não respeite esta condição é chamado de não linear.

Independente da arquitetura do circuito do PA RF, em amplificadores de potência de RF observam-se não linearidades devido à compressão e saturação do ganho de potência. Em outras palavras, à medida que a potência RF de entrada aumenta, o ganho de potência diminui, ou seja, o ganho comprime-se. Se continuarmos a aumentar a potência RF de entrada, a partir de um certo nível é impossível fornecer mais potência de saída, pois a fonte de alimentação possui uma

potência finita, e diz-se que o PA está saturado. A Figura. 2 ilustra um caso típico de PA RF onde o ganho é linear somente para baixas potências RF de entrada, tornando-se não linear com o aumento da potência RF de entrada, primeiro devido à compressão do ganho de potência e depois devido à saturação da potência RF de saída.

Como consequência destes efeitos não lineares, no sinal de saída do PA RF aparecem componentes espectrais não presentes no sinal RF de entrada. Cada componente recebe um nome específico associado a sua localização no espectro de frequências:

- nos arredores da frequência zero (CC) – componentes de banda base;
- nos arredores das harmônicas – componentes de distorção harmônica;
- nos arredores da frequência fundamental – produto de intermodulação na banda-passante.

As componentes localizadas perto da frequência fundamental são as mais problemáticas, pois se encontram dentro da banda passante do PA. As demais são facilmente eliminadas com a utilização de filtros apropriados.

Para melhor compreender os conceitos, vamos utilizar os diagramas mostrados na Figura 3 que representam os espectros de frequências do sinal na saída de um típico PA RF excitado por um sinal de dois tons (nas frequências ω_1 e ω_2) [14] e operando em regime não linear.

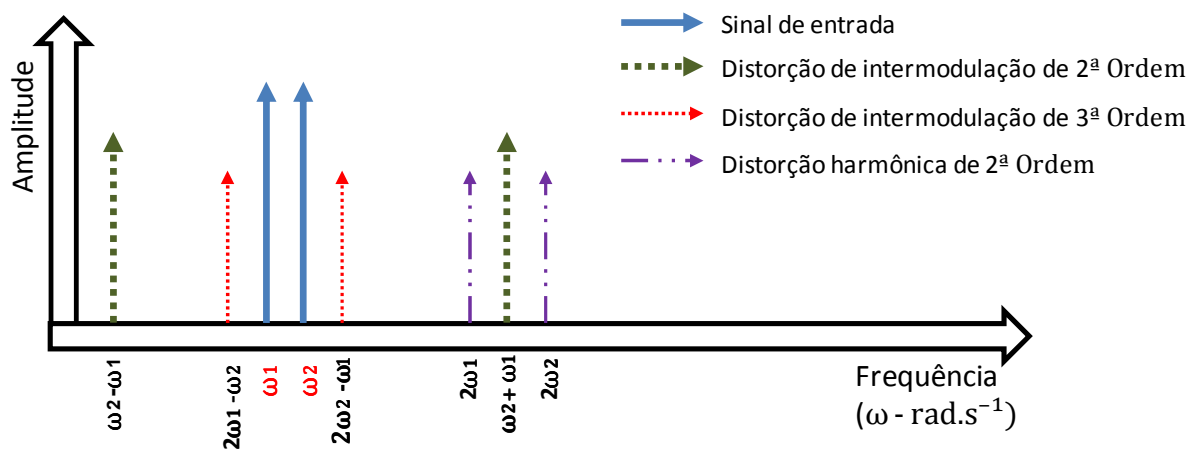


Figura 3. Espectros de frequência na saída de um típico PA RF operando em compressão e excitado por um sinal de dois tons (nas frequências ω_1 e ω_2), retirado de [14].

As não linearidades influenciam na resposta do PA e podem ser caracterizadas através de figuras de mérito, que dependem da modulação do sinal e da aplicação.

Seguem algumas métricas que são mais utilizadas:

- Ponto de compressão de 1 dB;
- *Intermodulation Distortion Ratio* (IMR);
- Ponto de intersecção de terceira ordem (IP3);
- *Adjacent-channel Power Ratio* (ACPR).

O ponto de compressão de 1 dB (P1dB) é definido como o valor da potência de saída no qual o sinal de saída já sofreu uma compressão de 1 dB relativo à potência do sinal de saída que seria obtida se fosse extrapolada a curva de resposta do seu valor na região linear [11], conforme mostra a Figura 4.

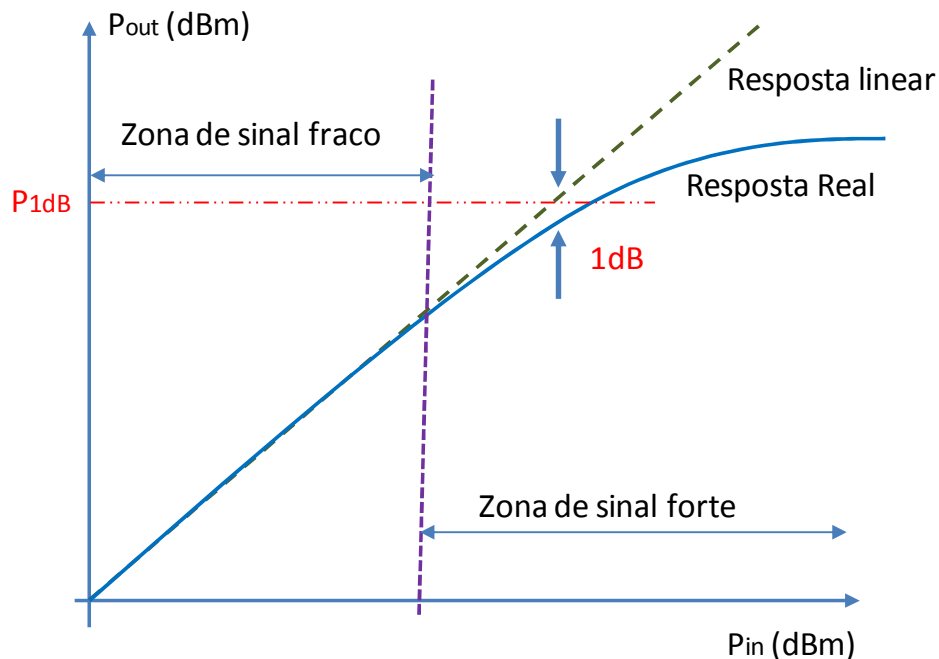


Figura 4. Gráfico da interpretação do ponto de compressão de 1 dB: Potência de saída em função da potência de entrada de um amplificador de potência genérico e ponto de compressão de 1 dB, retirado de [11].

Esta relação é demonstrada pela seguinte expressão:

$$P_{\text{out},1\text{dB}}(\text{dBm}) = P_{\text{in},1\text{dB}}(\text{dBm}) + G_{1\text{dB}}(\text{dB}) \quad (2.9)$$

onde G_{1dB} (dB) é o ganho no ponto de compressão de 1dB.

A *Adjacent-Channel Power Ratio* (ACPR) é a caracterização da distorção de intermodulação, também conhecida como espalhamento espectral (do inglês, *spectral regrowth*). A ACPR consiste na composição de todas as componentes de distorção do sinal que se localizam dentro da banda, com ocupação de canais adjacentes a banda passante. Esta forma de distorção acontece devido aos efeitos não lineares do PA [11] - [15].

A ACPR de um sinal é definida pela relação entre a potência de saída total medida na banda passante, e a potência total integrada nas bandas adjacentes, superior e inferior (ACP).

$$ACPR_T = \frac{P_O}{P_{AI} + P_{AS}} = \frac{\int_{\omega_{L2}}^{\omega_{S1}} S_O(\omega) \cdot d\omega}{\int_{\omega_{L1}}^{\omega_{L2}} S_O(\omega) \cdot d\omega + \int_{\omega_{S1}}^{\omega_{S2}} S_O(\omega) \cdot d\omega} \quad (2.10)$$

onde, P_{AI} é a potência integrada na banda adjacente inferior, P_{AS} é a potência integrada na banda adjacente superior, P_O é a potência integrada na banda passante e $S_O(\omega)$ é a função da densidade espectral de potência do sinal de saída. Graficamente pode-se verificar esta relação na Figura 5.

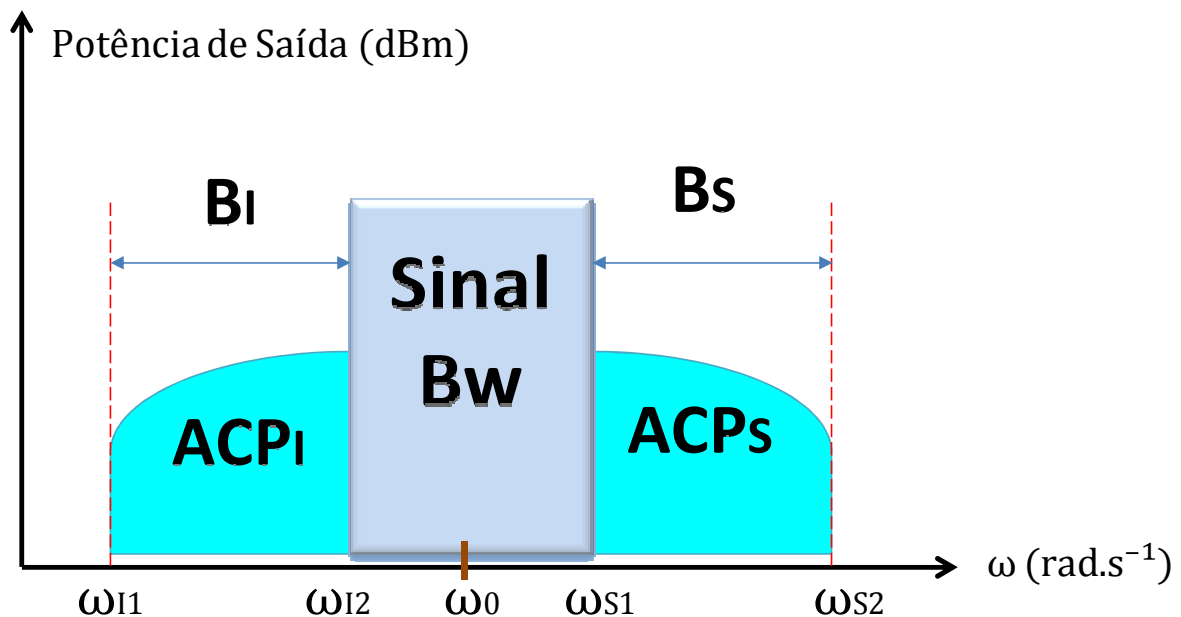


Figura 5. Bandas de integração usadas na caracterização da ACPR, retirado de [11].

2.3 Compromisso entre linearidade e eficiência

De acordo com a Seção 2.1, a eficiência em PAs RF aumenta em função da potência RF de entrada. Contudo, de acordo com a Seção 2.2, a linearidade de PAs RF diminui em função do aumento da potência RF de entrada. Há, portanto, um compromisso entre linearidade e eficiência em PAs RF. Ou seja, para ser linear, um PA RF deve operar em baixos níveis de potência, o que por sua vez acarreta em baixa eficiência. Ou vice versa, para ser eficiente, um PA RF deve operar em altos níveis de potência, o que por sua vez implica em comportamento não linear. A legislação que governa as comunicações sem fio exige que o transmissor cumpra rigorosas exigências de linearidade para evitar a presença de produtos de intermodulação (ou seja, o espalhamento espectral) que causam interferências entre usuários de canais adjacentes.

Em sistemas modernos de comunicações sem fio, a situação agrava-se ainda mais. Isso é devido à necessidade de adoção de técnicas que aumentem a eficiência espectral, definida pela razão entre taxa de transferência de dados e banda ocupada.

Em particular, técnicas de alta eficiência espectral devem transmitir a informação desejada através da modulação tanto em amplitude quanto em fase de uma portadora em RF. Uma vez que a amplitude do sinal a ser transmitido (e amplificado pelo PA) é variável, define-se o PAPR como a relação entre o valor de pico e o valor médio da potência de um sinal, ou seja:

$$PAPR(\tilde{s}t\tilde{g}) = \frac{Max[|\tilde{s}t\tilde{g}|]}{Mean[|\tilde{s}t\tilde{g}|]} \quad (2.11)$$

onde $\tilde{s}t\tilde{g}$ é o sinal de envoltória complexa no domínio do tempo, $Mean$ fornece o valor médio e Max fornece o valor máximo.

Portanto, uma codificação espectralmente eficiente terá um valor de PAPR superior a dois [13]. A Figura 6 ilustra um típico sinal de comunicação sem fio a ser transmitido por um PA RF. Além disso, é possível aumentar ainda mais a taxa de

transmissão de dados na reduzida largura de banda disponível se o sinal a ser transmitido representar múltiplas subportadoras, o que por sua vez implica em elevar ainda mais o PAPR de um sinal.

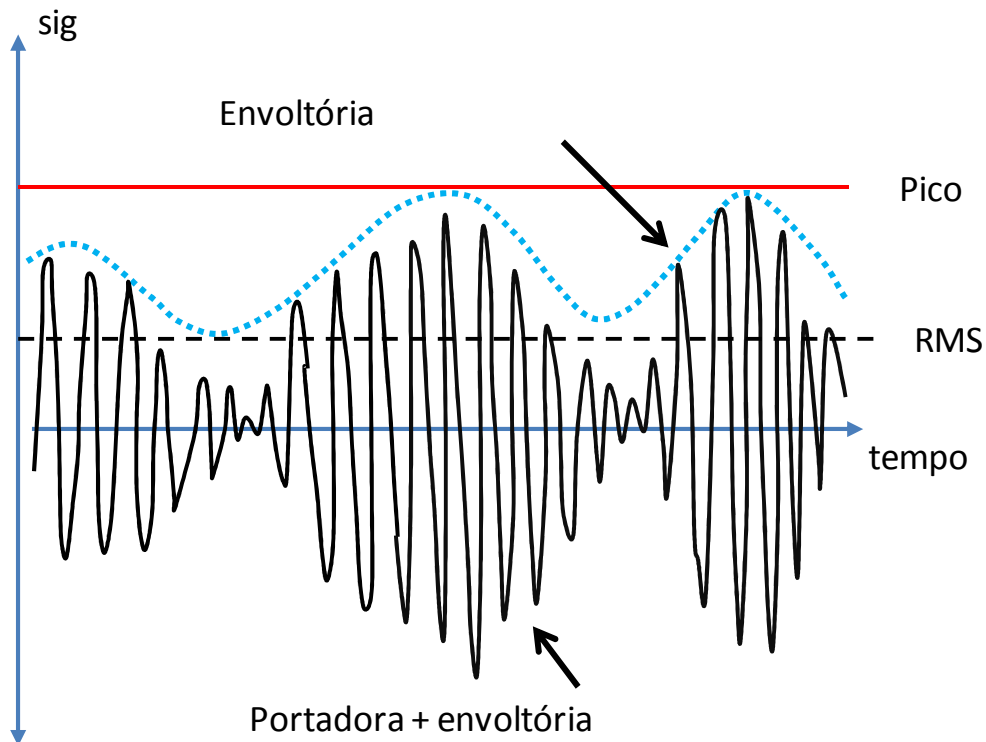


Figura 6. Forma de onda de um sinal de RF modulado em amplitude e fase, retirado de [13].

2.4 Modelagem comportamental de PA RF

Para aumentar a eficiência de PAs RF para sistemas de comunicações sem fio, sem comprometer a linearidade, uma alternativa que tem sido muito utilizada recentemente é a chamada linearização. Uma das exigências para implementar a linearização é a utilização de um modelo preciso e de baixa demanda computacional para o PA RF. Estes modelos têm sido o foco de vários estudos, artigos e pesquisas. Nesta seção, ênfase é dada no estudo de modelos de PAs RF que representem de maneira precisa a relação entrada-saída, e empreguem uma baixa complexidade computacional.

Os modelos para PA podem ser classificados em [16]: modelos físicos, modelos baseados em circuitos equivalentes e modelos comportamentais.

Modelos físicos requerem o conhecimento dos materiais e elementos que fazem parte do PA, suas relações, suas interações e regras teóricas. São, portanto, os modelos que descrevem o PA com a maior quantidade de detalhes e, por essa razão, apresentam a maior complexidade computacional entre todos os modelos de PA. Em específico, envolvem o uso de equações diferenciais parciais e buscam relacionar os campos eletromagnéticos ao longo do PA.

Para reduzir a complexidade computacional e simplificar o detalhamento do PA, modelos baseados no uso de circuitos equivalentes do PA são disponíveis. Baseiam-se no uso de equações diferenciais ordinárias e buscam relacionar as tensões e correntes dentro do circuito do PA. Podem fornecer resultados bastante precisos, porém esta precisão ainda tem um alto custo computacional, pois implica na necessidade de uma descrição detalhada interna do PA ao nível de circuito.

Quando o circuito equivalente do PA não está disponível, ou sempre que uma simulação completa no nível de sistema é desejada, são preferidos os modelos comportamentais de PA. São modelos baseados em medições realizadas na entrada e na saída do PA, que descrevem o comportamento do PA por meio de equações matemáticas usando pouco ou nenhum conhecimento da estrutura interna do PA. Os modelos comportamentais apresentam, portanto, a menor complexidade computacional entre todos os modelos de PAs. Contudo, sua precisão é altamente sensível a estrutura do modelo adotado e o procedimento para extração de parâmetros, em particular a estatística do sinal de excitação do PA.

A Figura 7 ilustra a filosofia da modelagem comportamental. Para uma mesma entrada *in* aplicada à um PA físico e à um modelo comportamental, deseja-se que a saída do modelo seja a mais próxima possível da saída medida do PA físico. Ou seja, deseja-se minimizar o erro definido pela diferença entre a saída do PA físico e a saída do modelo ($ERRO = out1 - out2$). O modelo comportamental possui parâmetros ajustáveis de tal maneira a minimizar o erro.

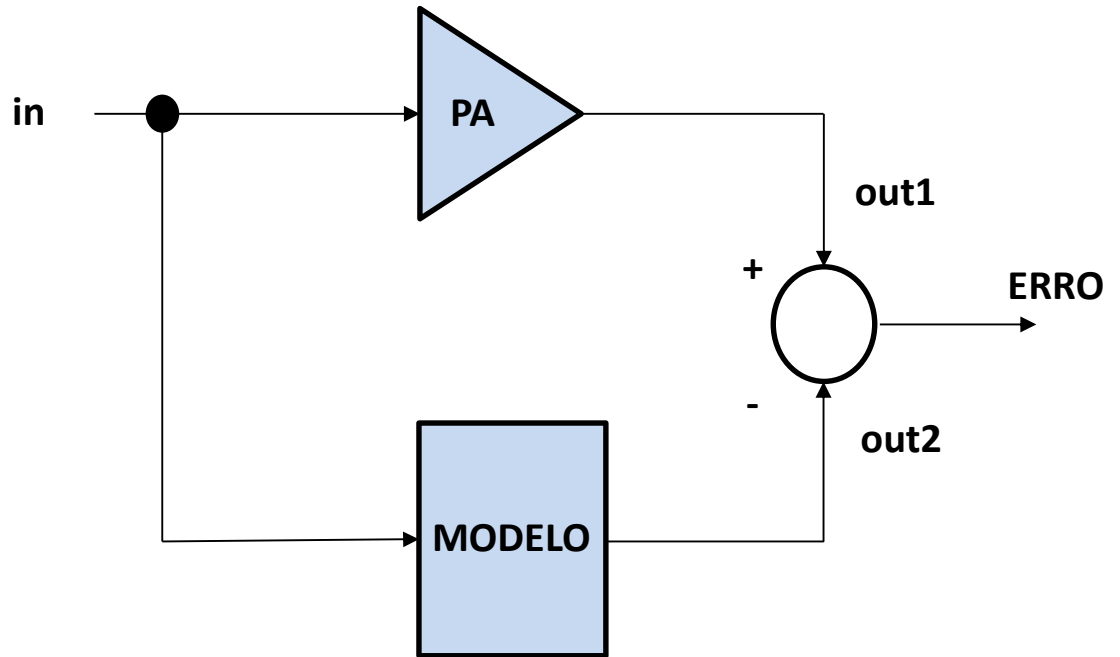


Figura 7. Modelagem comportamental de PA RF.

Para fins de linearização, os modelos comportamentais são os mais adequados e, portanto, nos capítulos seguintes, apenas a modelagem comportamental será discutida.

Na literatura, há uma grande variedade de modelos comportamentais para PAs RF. Para permitir uma comparação entre os diferentes modelos comportamentais, são identificadas uma vasta lista de propriedades. Em [17], as propriedades de modelos comportamentais de PAs (Figura 8) são definidas para três classes de modelos de PA de acordo com sua fonte de origem, ou seja, modelo de PAs:



Figura 8. Propriedade e classificação de modelagem comportamental de PA RF, retirado de [17].

a) Baseado na Aplicação

Para os modelos comportamentais baseados em aplicação, definem-se as seguintes propriedades: modelos no nível de circuito equivalente e em nível de sistema; modelos passa-banda ou modelos equivalentes passa-baixas.

b) Baseado na Estrutura da Modelagem

As propriedades dos modelos comportamentais com base na estrutura estão relacionadas com a descrição matemática específica do mapeamento entre entrada e saída. Existem muitas possibilidades para descrever a relação entre saída e entrada de um sistema. Para os modelos comportamentais baseados na estrutura,

definem-se as seguintes propriedades: modelos paramétricos e não paramétricos, modelos discretos ou contínuos no tempo, modelos variantes ou invariantes no tempo, modelos sem memória ou com memória, resposta impulsiva finita ou infinita, modelos com uma entrada e uma saída (SISO) ou modelos com múltiplas entradas e múltiplas saídas (MIMO), modelos determinísticos ou estocásticos.

c) Baseado no Amplificador

Para os modelos comportamentais baseados no amplificador, definem-se as seguintes propriedades: efeitos de memória de curta ou longa duração, modelos quase sem memória, modelos lineares, fracamente ou fortemente não lineares.

Baseado nestas propriedades, nesta dissertação será escolhido um modelo comportamental de PA de alta precisão, que pode ser classificado como: modelo equivalente passa-baixas ao nível de sistema, modelo não linear dinâmico, discreto e invariante no tempo e modelo fortemente não linear capaz de estimar efeitos de memória de curta e longa duração. Em específico, o modelo de PA que obedece a estes requisitos escolhido neste trabalho é chamado de rede neural de ligação funcional (FLNN), cuja descrição será apresentada no próximo capítulo.

2.5 Modelo comportamental equivalente passa-baixas para PA RF

Nesta seção, é analisada a natureza passa-banda do amplificador de potência de RF e o seu impacto na modelagem comportamental de PAs RF.

Os PAs RF são sistemas passa-banda, pois relacionam um sinal passa-banda de entrada e um sinal passa-banda de saída. Um sinal passa-banda é definido como um sinal de banda estreita onde a largura de banda é muito menor do que a frequência central. Em sistemas de comunicação sem fio, o sinal de entrada do PA RF $x(t)$ é um sinal de portadora na frequência (ω_c), modulado por uma envoltória de valor-complexo $\tilde{x}(t)$, como o exemplo abaixo:

$$x(t) = \text{Re}[\tilde{x}(t) \cdot e^{j\omega_c t}] = a_t \cos(\omega_c t + \theta_t) \quad (2.12)$$

e o sinal de saída do PA RF $y(t)$ é também um sinal de portadora na mesma frequência (ω_c), modulado por um envoltória de valor-complexo $\tilde{y}(t)$, como o exemplo abaixo:

$$y(t) = \text{Re}[\tilde{y}(t) \cdot e^{j\omega_c t}] = b_t \cos(\omega_c t + \varphi_t + \theta_t) \quad (2.13)$$

A Figura 9 ilustra um caso típico de espectro dos diferentes sinais RF e de envoltória.




Figura 9. Espectro do sinal real $x(t)$, do analítico $\tilde{x}(t)e^{j\omega_0 t}$ e do sinal de envoltória-complexa $\tilde{x}(t)$, retirado de [17].

Um modelo de tempo discreto de PA RF que estima o sinal de saída passa-banda $y(t)$ como função do sinal de entrada passa-banda $x(t)$, apresenta uma enorme complexidade computacional. A Figura 10 mostra o PA como um bloco de uma entrada e uma saída, assim como os espectros de frequência dos sinais na entrada e na saída de um típico PA RF. Observe que, na saída, há componentes espectrais não presentes na entrada, o que indica a presença de não linearidade.




Figura 10. Espectro do sinal de entrada de RF $|\tilde{x}(t)| \cos(\omega_c t + \theta_t)$ e do sinal de saída de RF $|\tilde{y}(t)| \cos(\omega_c t + \varphi_t + \theta_t)$ de um típico PA RF.

Na verdade, quando se trata de sinais passa-banda, para cumprir o critério de Nyquist, a frequência de amostragem deve ser pelo menos duas vezes a frequência da portadora (da ordem de GHz). Além disso, o modelo do PA RF deve ser capaz de levar em conta os efeitos de memória de baixa frequência da ordem da largura de banda da envoltória. Como consequência deste fato, para obter um modelo de PA RF passa-banda em tempo discreto de alta precisão, deve-se estimar a saída instantânea do PA como função da entrada instantânea do PA, assim como de um conjunto muito grande de entradas passadas (da ordem de 1000 amostras passadas), o que é inaceitável para aplicações de linearização.

Um modelo de PA RF muito mais compacto é alcançado se são utilizados apenas os sinais de envoltória-complexa $\tilde{x}(t)$ e $\tilde{y}(t)$. Neste caso, a frequência máxima que o modelo do PA deve tratar é reduzida para poucas harmônicas da largura de banda da envoltória. Assim, uma frequência de amostragem na faixa de MHz é suficiente para satisfazer o critério de Nyquist e, portanto, a saída instantânea do PA pode ser modelada com precisão em função da entrada instantânea do PA, junto com apenas algumas amostras passadas da envoltória-complexa de entrada. Estes modelos chamados de modelos comportamentais equivalente passa-baixas são, portanto, insensíveis à frequência da portadora e, como consequência, eles

permitem uma redução considerável no número de entradas, sem comprometer a precisão da modelagem. A Figura 11 ilustra os sinais manipulados pelos modelos passa-banda e equivalente passa-baixas. Observe que a máxima frequência dos sinais manipulados pelo modelo passa-banda é da ordem de GHz, enquanto que a máxima frequência dos sinais manipulados pelo modelo equivalente passa-baixa é da ordem de MHz. Portanto, para fins de linearização, o modelo adotado deve ser o equivalente passa-baixas. Observe que a redução computacional permitida pelo uso do modelo equivalente passa-baixas é devido à sobreposição de todas as bandas (fundamental e harmônicas) em torno da frequência zero (ou seja, banda base). Como consequência, torna-se difícil (não se tem mais o recurso visual) identificar se uma determinada contribuição está localizada na banda passante ou em harmônicas da mesma. Uma adicional e significativa redução na complexidade computacional de modelos comportamentais equivalente passa-baixas pode ser alcançada se for garantido que apenas contribuições dentro da banda passante do PA RF são geradas. Uma vez que o modelo equivalente comportamental passa-baixas não mantém qualquer ligação com ω_c , ele pode gerar contribuições fora da banda (ou seja, em frequências harmônicas de ω_c), contribuições essas que, na prática, têm valores muito pequenos e, portanto, não impactam de maneira significativa no desempenho esperado para o PA. Além disso, as medições das envoltórias-complexas são realizadas através de analisadores de sinais vetoriais (VSAs) que não são capazes de medir as contribuições fora da banda passante.

Para garantir que um modelo equivalente passa-baixas gere somente contribuições dentro da banda passante, como mostrado em [10], o modelo do PA deve garantir que o valor escalar unitário multiplicado por ω_c seja preservado, ou seja, a expressão $1(\omega_c t)$ deve ser mantida.

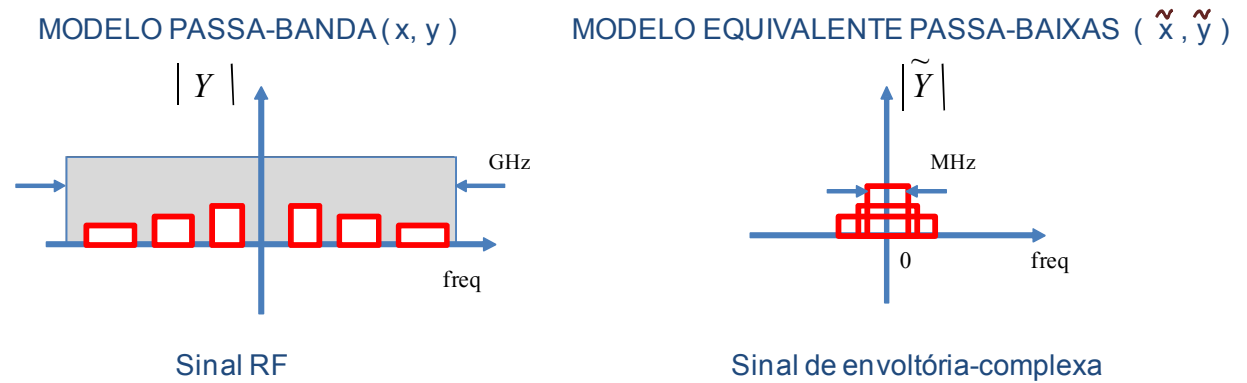


Figura 11. Sinais manipulados pelos modelos passa-banda e equivalente passa-baixas.

Entender a natureza de passa-banda de PAs RF e garantir que as restrições impostas pela mesma sobre a modelagem comportamental equivalente passa-baixas são satisfeitas é altamente valioso, pois permite reduzir a complexidade computacional dos modelos, sem comprometer a precisão, simplesmente por evitar a geração de respostas que não podem ser observadas e, portanto, não são físicas.

CAPÍTULO 3

REDE NEURAL DE LIGAÇÃO FUNCIONAL (FLNN)

Este capítulo discute RNAs (Redes Neurais Artificiais), que são técnicas computacionais que permitem aproximar de maneira muito precisa o comportamento de sistemas dinâmicos não lineares, por exemplo, o PA RF. O uso destas redes é motivado principalmente pela sua capacidade de aprendizagem, eficiência computacional e versatilidade. Nas RNAs, a partir de um conjunto de treinamento consistindo de entradas e correspondentes saídas desejadas e através de aprendizagem supervisionada, é feito o mapeamento entre entrada e saída. Os pesos (ou coeficientes da RNA) utilizados são adaptados de acordo com a aprendizagem estipulada.

Exemplos de arquiteturas de RNA incluem o *perceptron* de três camadas (TLP), a função de base radial (RBF) e a rede neural de ligação funcional (FLNN). A FLNN tem como principal característica ser linear nos seus parâmetros e, por este motivo, é escolhida como modelo comportamental de PA RF neste trabalho.

3.1 Rede neural de ligação funcional (FLNN)

A rede neural de ligação funcional (FLNN) foi originalmente proposta por Pao [8], [18], e tem sido utilizada com sucesso em muitas aplicações tais como:

- A. Identificação de sistema [19] – [24];
- B. Equalização de canal [25];
- C. Classificação [26] – [29];
- D. Reconhecimento de padrões [30] – [31];
- E. Previsão [32] – [33];
- F. Estrutura para modelar os PAs RF [34].

O diagrama de blocos de uma FLNN é mostrado na Figura 12. Observe que:

a) A FLNN tem E entradas e S saídas como é ilustrado na Figura 12. Podemos verificar que a camada de entrada é ligada diretamente à camada de saída, sem qualquer camada escondida.

b) Os sinais de entrada E aplicados à FLNN são sujeitos à ação de um bloco chamado de expansão funcional (*Functional Expansion*), cujo objetivo é mapear o conjunto de E sinais de entrada em um conjunto maior de Q sinais. Polinômios ortogonais, como Chebyshev, Hermite ou Legendre, são normalmente utilizados para executar esta tarefa de aumentar o conjunto de sinais de entrada.

c) O conjunto expandido de Q sinais é linearmente combinado, para então ser modificado pela ação de funções de ativação g , para finalmente produzir as saídas da FLNN.

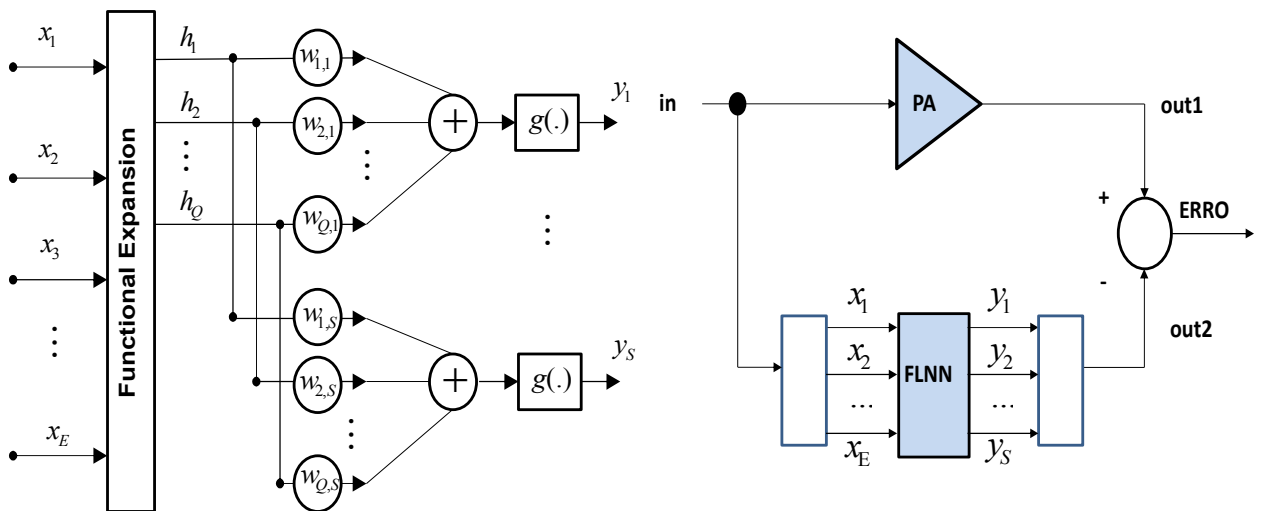


Figura 12. Diagrama de bloco da rede neural de ligação funcional (FLNN).

Neste trabalho, assim como em [9], polinômios de Chebyshev são utilizados dentro do bloco de expansão funcional e, na camada de saída, são usadas funções de ativação g lineares.

Os polinômios de Chebyshev unidimensionais de ordem zero e de primeira ordem tem os seguintes valores $T_0(x) = 1$ e $T_1(x) = x$, respectivamente. Observe que a notação $T_i(x)$ indica o polinômio de ordem i na variável x .

Polinômios de Chebyshev unidimensionais para ordens superiores são gerados pela equação recursiva:

$$T_{n+1}(x) = 2xT_n(x) - T_{n-1}(x) \quad (3.1)$$

Conhecendo a equação recursiva, seguem os próximos três polinômios de Chebyshev:

$$T_2(x) = 2xT_1(x) - T_0(x) = 2x^2 - 1 \quad (3.2)$$

$$T_3(x) = 2xT_2(x) - T_1(x) = 4x^3 - 3x \quad (3.3)$$

$$T_4(x) = 2xT_3(x) - T_2(x) = 8x^4 - 8x^2 + 1 \quad (3.4)$$

Para uma FLNN tendo E entradas, são necessários polinômios de Chebyshev multidimensionais. Em polinômios de Chebyshev multidimensionais, a quantidade de contribuições aumenta significativamente, pois devem ser incluídos os produtos entre termos inteiros. A Tabela 1, ilustra as diferentes contribuições de 2ª ordem, para os casos bidimensionais [$E=2$] e tridimensionais [$E=3$].

Tabela 1: Contribuições de 2ª ordem.

E=2	E=3
$T_2(x_1)$	$T_2(x_1)$
$T_2(x_2)$	$T_2(x_2)$
$T_1(x_1) T_1(x_2)$	$T_2(x_3)$
	$T_1(x_1) T_1(x_2)$
	$T_1(x_1) T_1(x_3)$
	$T_1(x_2) T_1(x_3)$

Com o objetivo de ilustrar a generalização dos polinômios de Chebyshev para o caso multidimensional, utiliza-se o processamento mostrado na Figura 12, entre uma saída qualquer (y_m) em função de todas as E entradas, considerando $g(\cdot)$ uma função linear de ganho unitário (ou seja, $g(r) = r$).

De acordo com [35], e explorando a simetria, sem qualquer perda de generalidade, pode-se mostrar que o m -ésimo sinal de saída y_m está relacionado com os E sinais de entrada $[x_1, x_2, \dots, x_E]$ de acordo com:

$$\begin{aligned}
y_m &= W^T T = \\
&w_m(0)T_0 + \sum_{p=1}^P \sum_{r=1}^p \sum_{q_1=1}^p \cdots \sum_{q_r=q_{r-1}+1}^p \sum_{l_1=1}^{f_1} \cdots \sum_{l_r=1}^{f_r} \\
&\quad \underbrace{\hspace{15em}}_{\text{if}(p=l_1q_1+\dots+l_rq_r)} \\
&\sum_{e_1=1}^E \cdots \sum_{e_{l_1}=e_{l_1-1}+1}^E \cdots \sum_{e_{l_1+l_2+\dots+l_{r-1}+1}=1}^E \cdots \sum_{e_{l_1+\dots+l_r}=e_{l_1+\dots+l_{r-1}+1}}^E \\
&\quad \underbrace{\hspace{15em}}_{\text{if}(e_1 \neq e_2 \neq \dots \neq e_{l_1+l_2+\dots+l_r})} \quad (3.5) \\
&w_m(p, r, q_1, q_2, \dots, q_r, l_1, l_2, \dots, l_r, e_1, e_2, \dots, e_{l_1+l_2+\dots+l_r}) \\
&\prod_{j_1=1}^{l_1} T_{q_1}(x_{e_{j_1}}) \cdots \prod_{j_r=l_1+l_2+\dots+l_{r-1}+1}^{l_1+l_2+\dots+l_r} T_{q_r}(x_{e_{j_r}})
\end{aligned}$$

onde w são os coeficientes a determinar (ou pesos) da FLNN, $T_q(\cdot)$ é a q -ésima ordem do polinômio Chebyshev dada por (3.1), P é o truncamento na ordem de Chebyshev e:

$$f_1 = \text{floor} \left(\frac{p}{q_1} \right), \quad (3.6)$$

$$f_2 = \text{floor} \left[\frac{p - l_1 q_1}{q_2} \right], \quad (3.7)$$

.....

$$f_r = \left[\frac{p - l_1 q_1 - \dots - l_{r-1} q_{r-1}}{q_r} \right] \quad (3.8)$$

onde $\text{floor}(\cdot)$ é o operador que arredonda o número para o inteiro mais próximo de menos infinito ($-\infty$).

A Tabela 2 apresenta um exemplo para o caso onde $E=3$, $P=3$ e $S=1$.

Tabela 2: Exemplo para o caso onde $E=3$, $P=3$ e $S=1$.

Termos	p	r	q ₁	q ₂	l ₁	l ₂	e ₁	e ₂	e ₃	Coefficiente (elemento de w_m)	Regressor (elemento de T)
1°	-	-	-	-	-	-	-	-	-	$w_m(0)$	T_0
2°	1	1	1	-	1	-	1	-	-	$w_m(1,1,1,1,1)$	$T_1(x_1)$
3°	1	1	1	-	1	-	2	-	-	$w_m(1,1,1,1,2)$	$T_1(x_2)$
4°	1	1	1	-	1	-	3	-	-	$w_m(1,1,1,1,3)$	$T_1(x_3)$
5°	2	1	1	-	2	-	1	2	-	$w_m(2,1,1,2,1,2)$	$T_1(x_1) T_1(x_2)$
6°	2	1	1	-	2	-	1	3	-	$w_m(2,1,1,2,1,3)$	$T_1(x_1) T_1(x_3)$
7°	2	1	1	-	2	-	2	3	-	$w_m(2,1,1,2,2,3)$	$T_1(x_2) T_1(x_3)$
8°	2	1	2	-	1	-	1	-	-	$w_m(2,1,2,1,1)$	$T_2(x_1)$
9°	2	1	2	-	1	-	2	-	-	$w_m(2,1,2,1,2)$	$T_2(x_2)$
10°	2	1	2	-	1	-	3	-	-	$w_m(2,1,2,1,3)$	$T_2(x_3)$
11°	3	1	1	-	3	-	1	2	3	$w_m(3,1,1,3,1,2,3)$	$T_1(x_1) T_1(x_2) T_1(x_3)$
12°	3	1	3	-	1	-	1	-	-	$w_m(3,1,3,1,1)$	$T_3(x_1)$
13°	3	1	3	-	1	-	2	-	-	$w_m(3,1,3,1,2)$	$T_3(x_2)$
14°	3	1	3	-	1	-	3	-	-	$w_m(3,1,3,1,3)$	$T_3(x_3)$
15°	3	2	1	2	1	1	1	2	-	$w_m(3,2,1,2,1,1,1,2)$	$T_1(x_1) T_2(x_2)$
16°	3	2	1	2	1	1	1	3	-	$w_m(3,2,1,2,1,1,1,3)$	$T_1(x_1) T_2(x_3)$
17°	3	2	1	2	1	1	2	3	-	$w_m(3,2,1,2,1,1,2,3)$	$T_1(x_2) T_2(x_3)$
18°	3	2	1	2	1	1	2	1	-	$w_m(3,2,1,2,1,1,2,1)$	$T_1(x_2) T_2(x_1)$
19°	3	2	1	2	1	1	3	1	-	$w_m(3,2,1,2,1,1,3,1)$	$T_1(x_3) T_2(x_1)$
20°	3	2	1	2	1	1	3	2	-	$w_m(3,2,1,2,1,1,3,2)$	$T_1(x_3) T_2(x_2)$

3.2 Treinamento da rede FLNN

O treinamento de uma rede FLNN consiste em encontrar o conjunto de valores para os coeficientes w que minimizem o erro entre a saída desejada ou medida (y_{med}) e a saída calculada y_{cal} para a FLNN. Considerando que a FLNN é linear nos seus parâmetros w , para o treinamento será utilizado o método dos mínimos quadrados. No Matlab, dado um sistema $Ax=b$, onde A é uma matriz $m \times n$, onde $m > n$, x é o vetor de incógnitas de dimensão $n \times 1$ e b é o vetor solução de dimensão $m \times 1$, o comando $A \backslash b$ fornece como resultado o vetor de incógnitas que minimiza o erro quadrático médio. Para a validação da rede, deve-se utilizar um conjunto de dados de entrada-saída distinto daquele utilizado para o treinamento da rede.

3.3 Modelagem comportamental equivalente passa-baixas do PA RF utilizando Chebyshev FLNN

Foi relatado em [9] o uso de FLNN com polinômio de Chebyshev (CFLNN) para a modelagem comportamental equivalente passa-baixas de PAs RF. Em [9], para empregar o CFLNN na modelagem comportamental de PAs, as entradas do CFLNN $(x_1, x_2, x_3, \dots, x_E)$ são os sinais de envoltória de valores-complexos \tilde{x} aplicados na entrada do PA RF no instante atual e também em amostras passadas até o comprimento de memória M . Neste mesmo trabalho, a única saída do CFLNN (y_1) , é a amostra instantânea do sinal de envoltória de valor-complexo (\tilde{y}) medido na saída do PA RF. Caso a (3.5) seja utilizada diretamente, assumindo que os sinais x são complexos, uma grande quantidade de contribuições fora da banda seriam geradas. Por exemplo a contribuição $T_2(x_1) = 2x_1^2 - 1$ gera contribuições na 2ª harmônica (devido a $2x_1^2$) e na banda base (devido a -1). Explicando melhor: dado $x_1 = |x_1|e^{j\theta_1}$, $x_1^2 \Rightarrow |x_1|^2 e^{j2\theta_1}$, portanto, $2x_1^2 = 2|x_1|^2 e^{j2\theta_1}$. Uma vez que θ_1 aparece sempre juntamente com $\omega_c t$ na forma $(\omega_c t + \theta_1)$, então a expressão $2\theta_1$ implica em $2(\omega_c t + \theta_1)$, o que prova então que esta é uma contribuição de 2ª harmônica.

Considerando que as entradas e a saída do CFLNN são números complexos, em [9] uma conjugação adequada foi aplicada em (3.5). A aplicação da conjugação adequada é feita da seguinte maneira: para cada sinal de valor-complexo na saída do bloco de expansão funcional (sinais h na Figura 12), composto por produtos de entradas do CFLNN, todas menos uma entrada de valor-complexo devem ser substituídas pelos seus respectivos valores absolutos. Portanto, para cada sinal h que contém o produto de diferentes entradas do CFLNN, digamos v diferentes entradas, a aplicação do conceito de conjugação adequada irá originar v novos sinais a partir de um único sinal. Por exemplo:

a) O sinal $(2 \cdot x_1^2 - 1)$ depende apenas de x_1 e, por isso, é substituído apenas pelo novo sinal $2 \cdot |x_1| \cdot x_1 - 1$;

b) O sinal $(x_1 \cdot x_2 \cdot x_3)$ depende de três entradas diferentes (x_1, x_2 e x_3) e, portanto, é substituído por três novos sinais:

$$(x_1 \cdot |x_2| \cdot |x_3|), (|x_1| \cdot x_2 \cdot |x_3|) \text{ e } (|x_1| \cdot |x_2| \cdot x_3);$$

c) O sinal $(x_1 \cdot x_2 \cdot x_3 \cdot x_4 \cdot x_5)$ depende de cinco entradas diferentes $(x_1, x_2, x_3, x_4 \text{ e } x_5)$ e, portanto, é substituído por cinco novos sinais:

$$\begin{aligned} &(x_1 \cdot |x_2| \cdot |x_3| \cdot |x_4| \cdot |x_5|), (|x_1| \cdot x_2 \cdot |x_3| \cdot |x_4| \cdot |x_5|), \\ &(|x_1| \cdot |x_2| \cdot x_3 \cdot |x_4| \cdot |x_5|), (|x_1| \cdot |x_2| \cdot |x_3| \cdot x_4 \cdot |x_5|) \text{ e} \\ &(|x_1| \cdot |x_2| \cdot |x_3| \cdot |x_4| \cdot x_5). \end{aligned}$$

O CFLNN apresentado em [9] não garante que apenas as contribuições físicas são geradas. Por contribuição física entende-se contribuições localizadas na banda passante. Dessa forma, contribuições não físicas são aquelas localizadas fora da banda passante. Esta denominação é baseada na natureza banda passante do PA RF, ou seja, na sua saída são mensuráveis apenas sinais com energia exclusivamente na banda passante. Na verdade, pode ser visto que em (3.5), o sinal de saída do PA estimado pelo modelo CFLNN pode conter termos constantes que não têm relação com as entradas. Uma vez que termos constantes (valores médios) são equivalentes, no domínio da frequência, à frequência zero, eles não podem ser observados em sistemas passa-banda. A Tabela 3 apresenta a aplicação do conceito de conjugação adequada proposta em [9] para o mesmo exemplo da Tabela 2, onde $E=3$, $P=3$ e $S=1$. Observe que de 20 contribuições, passou-se para 31 contribuições.

Tabela 3: Exemplo de conjugação adequada para o caso onde $E=3$, $P=3$ e $S=1$.

Termos	Regressor	Antes da aplicação da conjugação adequada	Após a aplicação da conjugação adequada
1°	T_0	1	1
2°	$T_1(x_1)$	x_1	x_1
3°	$T_1(x_2)$	x_2	x_2
4°	$T_1(x_3)$	x_3	x_3
5°	$T_1(x_1) T_1(x_2)$	$(x_1) (x_2)$	$(x_1) (x_2)$
			$(x_1) (x_2)$
6°	$T_1(x_1) T_1(x_3)$	$(x_1) (x_3)$	$(x_1) (x_3)$
			$(x_1) (x_3)$
7°	$T_1(x_2) T_1(x_3)$	$(x_2) (x_3)$	$(x_2) (x_3)$
			$(x_2) (x_3)$
8°	$T_2(x_1)$	$2(x_1)^2-1$	$2(x_1)(x_1)-1$
9°	$T_2(x_2)$	$2(x_2)^2-1$	$2(x_2)(x_2)-1$
10°	$T_2(x_3)$	$2(x_3)^2-1$	$2(x_3)(x_3)-1$
11°	$T_1(x_1) T_1(x_2) T_1(x_3)$	$(x_1) (x_2) (x_3)$	$(x_1) (x_2) (x_3)$
			$(x_1) (x_2) (x_3)$
			$(x_1) (x_2) (x_3)$
12°	$T_3(x_1)$	$4(x_1)^3-3(x_1)$	$4(x_1)(x_1)(x_1)-3(x_1)$
13°	$T_3(x_2)$	$4(x_2)^3-3(x_2)$	$4(x_2)(x_2)(x_2)-3(x_2)$
14°	$T_3(x_3)$	$4(x_3)^3-3(x_3)$	$4(x_3)(x_3)(x_3)-3(x_3)$
15°	$T_1(x_1) T_2(x_2)$	$(x_1) (2(x_2)^2-1)$	$(x_1) (2(x_2)(x_2)-1)$
			$(x_1) (2(x_2)(x_2)) -1 (x_1)$
16°	$T_1(x_1) T_2(x_3)$	$(x_1) (2(x_3)^2-1)$	$(x_1) (2(x_3)(x_3)-1)$
			$(x_1) (2(x_3)(x_3)) -1 (x_1)$
17°	$T_1(x_2) T_2(x_3)$	$(x_2) (2(x_3)^2-1)$	$(x_2) (2(x_3)(x_3)-1)$
			$(x_2) (2(x_3)(x_3)) -1 (x_2)$
18°	$T_1(x_2) T_2(x_1)$	$(x_2) (2(x_1)^2-1)$	$(x_2) (2(x_1)(x_1)-1)$
			$(x_2) (2(x_1)(x_1)) -1 (x_2)$
19°	$T_1(x_3) T_2(x_1)$	$(x_3) (2(x_1)^2-1)$	$(x_3) (2(x_1)(x_1)-1)$
			$(x_3) (2(x_1)(x_1)) -1 (x_3)$
20°	$T_1(x_3) T_2(x_2)$	$(x_3) (2(x_2)^2-1)$	$(x_3) (2(x_2)(x_2)-1)$
			$(x_3) (2(x_2)(x_2)) -1 (x_3)$

Com exceção dos termos constantes todas as demais contribuições (após a aplicação da conjugação adequada) são de fato contribuições banda base. De fato, observe que o módulo de um número complexo não tem relação com ω_c . Dessa forma, a conjugação adequada faz com que o tratamento da fase do número complexo seja linear. Portanto, nenhuma operação não linear é realizada sobre a fase, o que mantém o $1(\omega_c t)$ inalterado.

3.4 Proposta para novos modelos comportamentais equivalente passa-baixas de PA RF utilizando Chebyshev FLNNs

Nesta seção, apresentam-se dois novos modelos comportamentais para PAs RF baseados em CFLNN que, ao contrário do CFLNN proposto em [9], garantem que o valor unitário do escalar que é multiplicado por ω_c é preservado e, dessa forma, somente são geradas contribuições físicas (ou seja, contribuições dentro da banda passante).

Os dois modelos propostos diferem entre si pela estratégia adotada para cumprir as restrições impostas pela natureza passa-banda de PAs RF. Mais especificamente, em comparação com a abordagem do estudo anterior [9], um dos modelos propostos faz mudanças apenas dentro do CFLNN e o outro modelo realiza alterações nas entradas e saídas da rede CFLNN. Seguem as denominações dos três modelos que serão comparados neste estudo:

- a) **Modelo 1** – Modelo descrito anteriormente em [9] – *mod_previous*;
- b) **Modelo 2** – Modelo proposto nesta dissertação com alterações somente na arquitetura interna da rede CFLNN – *mod_proces*;
- c) **Modelo 3** – Modelo proposto nesta dissertação com alterações somente nas entradas e saídas da CFLNN – *mod_in/out*.

Para obter o primeiro modelo baseado em CFLNN proposto aqui (*mod_proces*), a mesma técnica de conjugação adequada apresentada em [9] é aplicada a (3.5) e a única modificação necessária é a remoção de todos os termos constantes.

Seguem exemplos de retirada de constante:

$$T_0(x_1) = 1, \text{ retirar a constante } +1.$$

$$T_1(x_1) = x_1, \text{ não tem constante e, portanto, não necessita de alteração.}$$

$$T_2(x_1) = 2x_1^2 - 1, \text{ retirar a constante } -1.$$

$T_3(x_1) = 4x_1^3 - 3x_1$, não tem constante e, portanto, não necessita de alteração.

$$T_4(x_1) = 8x_1^4 - 8x_1^2 + 1, \text{ retirar a constante } +1.$$

Neste primeiro modelo proposto, aplicam-se nas entradas da CFLNN os mesmos sinais de valores-complexos usados em [9] e o sinal de saída de valor-complexo a ser estimado pela CFLNN também é idêntico ao utilizado em [9]. A Tabela 4 ilustra a remoção das constantes, também para o caso $E=3$, $P=3$ e $S=1$, relatado anteriormente nas Tabelas 2 e 3.

Tabela 4: Exemplo remover as constantes para o caso onde $E=3$, $P=3$ e $S=1$.

Termos	Regressor	Antes da aplicação da conjugação adequada	Após a aplicação da conjugação adequada	Após remover as constantes
1º	T_0	1	1	$1-1=0$
2º	$T_1(x_1)$	x_1	x_1	x_1
3º	$T_1(x_2)$	x_2	x_2	x_2
4º	$T_1(x_3)$	x_3	x_3	x_3
5º	$T_1(x_1) T_1(x_2)$	$(x_1) (x_2)$	$(x_1) (x_2)$	$(x_1) (x_2)$
			$(x_1) (x_2)$	$(x_1) (x_2)$
6º	$T_1(x_1) T_1(x_3)$	$(x_1) (x_3)$	$(x_1) (x_3)$	$(x_1) (x_3)$
			$(x_1) (x_3)$	$(x_1) (x_3)$
7º	$T_1(x_2) T_1(x_3)$	$(x_2) (x_3)$	$(x_2) (x_3)$	$(x_2) (x_3)$
			$(x_2) (x_3)$	$(x_2) (x_3)$
8º	$T_2(x_1)$	$2(x_1)^2-1$	$2(x_1)(x_1)-1$	$2(x_1)(x_1)-1+1$
9º	$T_2(x_2)$	$2(x_2)^2-1$	$2(x_2)(x_2)-1$	$2(x_2)(x_2)-1+1$
10º	$T_2(x_3)$	$2(x_3)^2-1$	$2(x_3)(x_3)-1$	$2(x_3)(x_3)-1+1$
11º	$T_1(x_1) T_1(x_2) T_1(x_3)$	$(x_1) (x_2) (x_3)$	$(x_1) (x_2) (x_3)$	$(x_1) (x_2) (x_3)$
			$(x_1) (x_2) (x_3)$	$(x_1) (x_2) (x_3)$
			$(x_1) (x_2) (x_3)$	$(x_1) (x_2) (x_3)$
12º	$T_3(x_1)$	$4(x_1)^3-3(x_1)$	$4(x_1)(x_1)(x_1)-3(x_1)$	$4(x_1)(x_1)(x_1)-3(x_1)$
13º	$T_3(x_2)$	$4(x_2)^3-3(x_2)$	$4(x_2)(x_2)(x_2)-3(x_2)$	$4(x_2)(x_2)(x_2)-3(x_2)$
14º	$T_3(x_3)$	$4(x_3)^3-3(x_3)$	$4(x_3)(x_3)(x_3)-3(x_3)$	$4(x_3)(x_3)(x_3)-3(x_3)$
15º	$T_1(x_1) T_2(x_2)$	$(x_1) (2(x_2)^2-1)$	$(x_1) (2(x_2)(x_2)-1)$	$(x_1) (2(x_2)(x_2)-1+1)$
			$(x_1) (2(x_2)(x_2)-1)$	$(x_1) (2(x_2)(x_2)-1+1)$
16º	$T_1(x_1) T_2(x_3)$	$(x_1) (2(x_3)^2-1)$	$(x_1) (2(x_3)(x_3)-1)$	$(x_1) (2(x_3)(x_3)-1+1)$
			$(x_1) (2(x_3)(x_3)-1)$	$(x_1) (2(x_3)(x_3)-1+1)$
17º	$T_1(x_2) T_2(x_3)$	$(x_2) (2(x_3)^2-1)$	$(x_2) (2(x_3)(x_3)-1)$	$(x_2) (2(x_3)(x_3)-1+1)$
			$(x_2) (2(x_3)(x_3)-1)$	$(x_2) (2(x_3)(x_3)-1+1)$
18º	$T_1(x_2) T_2(x_1)$	$(x_2) (2(x_1)^2-1)$	$(x_2) (2(x_1)(x_1)-1)$	$(x_2) (2(x_1)(x_1)-1+1)$
			$(x_2) (2(x_1)(x_1)-1)$	$(x_2) (2(x_1)(x_1)-1+1)$
19º	$T_1(x_3) T_2(x_1)$	$(x_3) (2(x_1)^2-1)$	$(x_3) (2(x_1)(x_1)-1)$	$(x_3) (2(x_1)(x_1)-1+1)$
			$(x_3) (2(x_1)(x_1)-1)$	$(x_3) (2(x_1)(x_1)-1+1)$
20º	$T_1(x_3) T_2(x_2)$	$(x_3) (2(x_2)^2-1)$	$(x_3) (2(x_2)(x_2)-1)$	$(x_3) (2(x_2)(x_2)-1+1)$
			$(x_3) (2(x_2)(x_2)-1)$	$(x_3) (2(x_2)(x_2)-1+1)$

No que diz respeito ao segundo modelo proposto baseado em CFLNN (*mod_in/out*), para garantir que o valor unitário do escalar multiplicando ω_c é preservado, os sinais aplicados nas entradas do CFLNN são modificados de acordo com a Figura 13.




Figura 13. Diagrama de bloco do CFLNN proposto com diferentes entradas e saída.

Como entradas do segundo modelo proposto CFLNN, temos a amplitude (a) e a diferença de fases do sinal de valor-complexo de entrada (\tilde{x}). O índice M indica o comprimento de memória. As entradas deste modelo são definidas da seguinte forma:

- a) As amplitudes, no instante atual (a_n) e nos instantes passados (a_{n-M});
- b) As diferenças de fase da envoltória de valor-complexo de entrada no instante atual, $\exp j(\theta_n - \theta_{n-1})$, e nos instantes passados, $\exp j(\theta_{n-M+1} - \theta_{n-M})$.

Todas as entradas aplicadas ao CFLNN na Figura 13 são de fato sinais banda-base, pois nenhum deles mantém relação direta com a portadora (ω_c). A amplitude de um número complexo, por definição, não possui relação com a frequência da portadora. Lembrando de que a fase de um número complexo está relacionada com a $\omega_c t$ por uma somatória $\omega_c t + \theta_n$, o modelo proposto de CFLNN mostrado na Figura 13 retira a dependência da portadora simplesmente por utilizar como entradas sempre a diferença entre duas fases. Dessa forma, o modelo proposto e mostrado na Figura 13 retira completamente a possibilidade de gerar múltiplos inteiros de ω_c , uma vez que se pode observar que:

$$(\omega_c t + \theta_1) - (\omega_c t + \theta_2) = (\theta_1 - \theta_2) \quad (3.9)$$

Com relação à saída do CFLNN, observe pela Figura 13 que o CFLNN estima na sua saída um sinal banda-base que não tem relação com a frequência da portadora. Deve-se, portanto, realizar as operações adicionais mostradas na Figura 13. De fato, a única operação a ser realizada é a multiplicação do sinal de banda-base estimado pela CFLNN, ou seja, $b_n \exp j(\varphi_n)$ por $\exp j(\theta_n)$, o que restitui o valor escalar unitário que multiplica $(\omega_c t + \theta_n)$. Isto conclui a prova que o modelo comportamental equivalente passa-baixas, mostrado na Figura 13, satisfaz as restrições fundamentais impostas pela natureza passa-banda dos PAs RF e só gera contribuições que podem ser observadas fisicamente.

CAPÍTULO 4

VALIDAÇÃO DOS MODELOS PROPOSTOS

Neste capítulo se fará uma comparação da precisão em função do número de parâmetros, utilizando o software Matlab, entre os três modelos apresentados no Capítulo 3. Será utilizado um cenário de número similar de parâmetros para avaliar qual dos modelos comportamentais CFLNN propostos apresenta os melhores resultados de precisão. As métricas a serem utilizadas aqui são o erro quadrático médio normalizado (NMSE) e a relação entre a potência do sinal de erro no canal adjacente e a potência do sinal de saída na banda passante (ACEPR).

Como informado no Capítulo 3, o modelo CFLNN em [9] é designado como CFLNN *mod_previous*. O CFLNN proposto que satisfaz a restrição de passa-banda alterando o processamento através do CFLNN (remover as constantes) é denominado como CFLNN *mod_proces*. O CFLNN proposto em que a natureza de passa-banda é garantida modificando os sinais de entrada e saída do CFLNN de acordo com a Figura 13 é chamado CFLNN *mod_in/out*.

Como já visto nos capítulos anteriores o conhecimento *a priori* do PA RF é muito importante para melhorar o desempenho da modelagem comportamental e sua precisão é altamente sensível à estrutura do modelo adotado, às medições dos sinais de entrada e saída do RF PA e o procedimento correto para extração de parâmetros. As Figuras 14 e 15 apresentam o procedimento adotado neste trabalho.

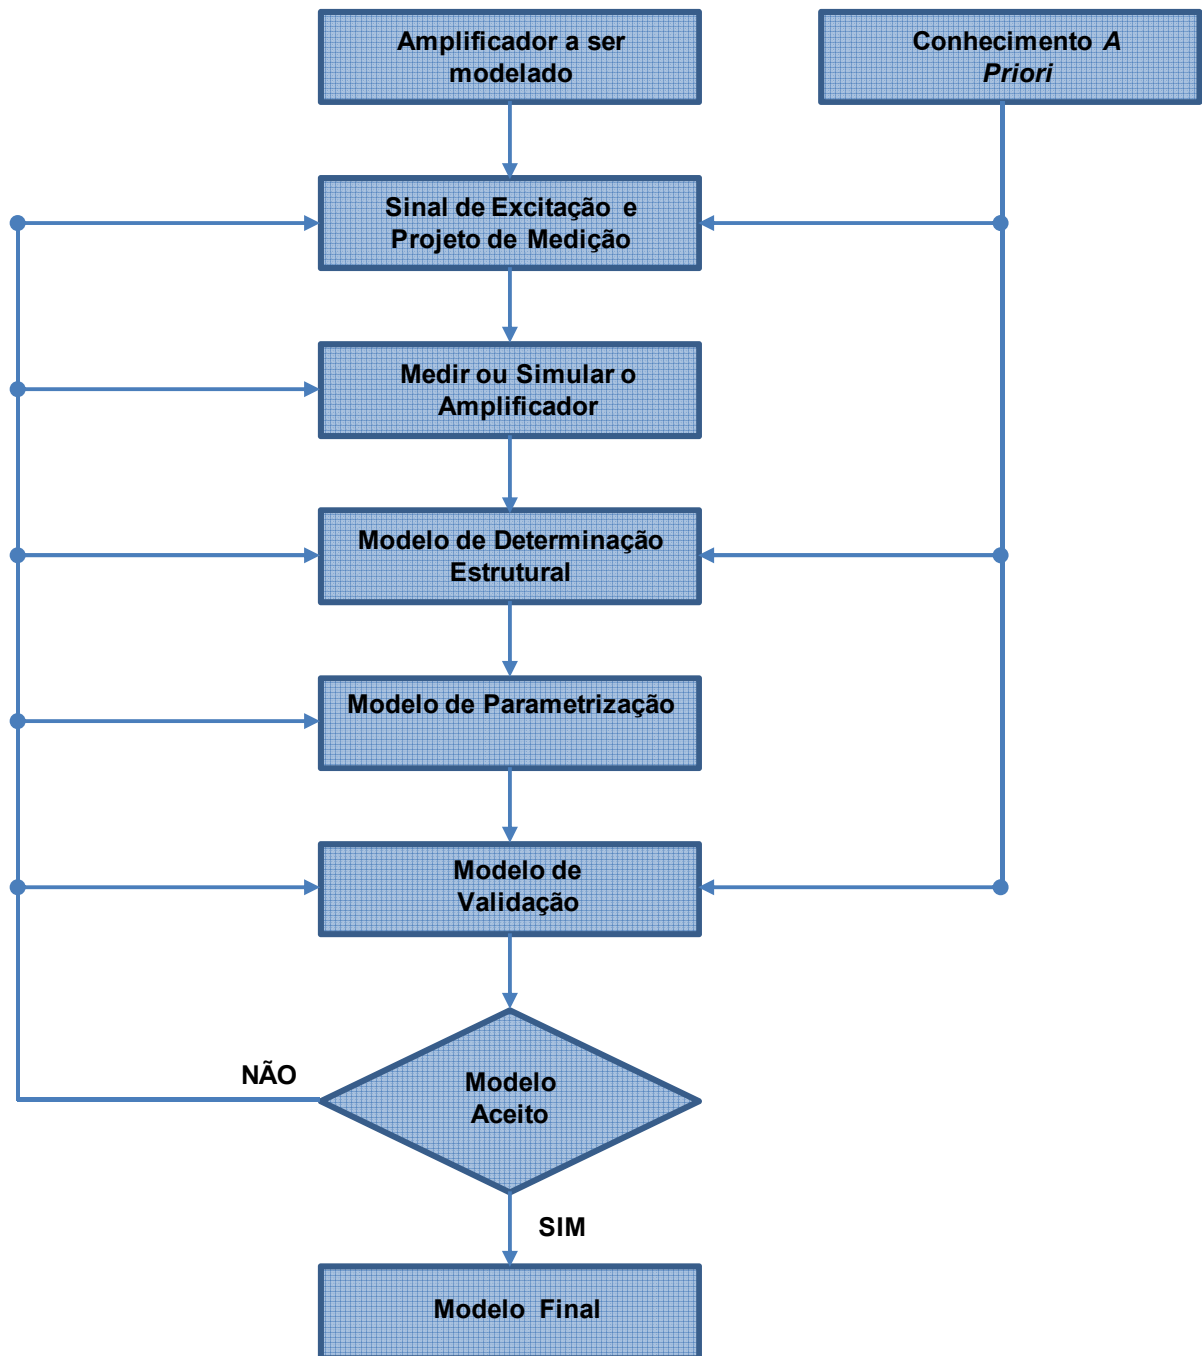


Figura 14. Procedimento de identificação do sistema, modificado de [36].

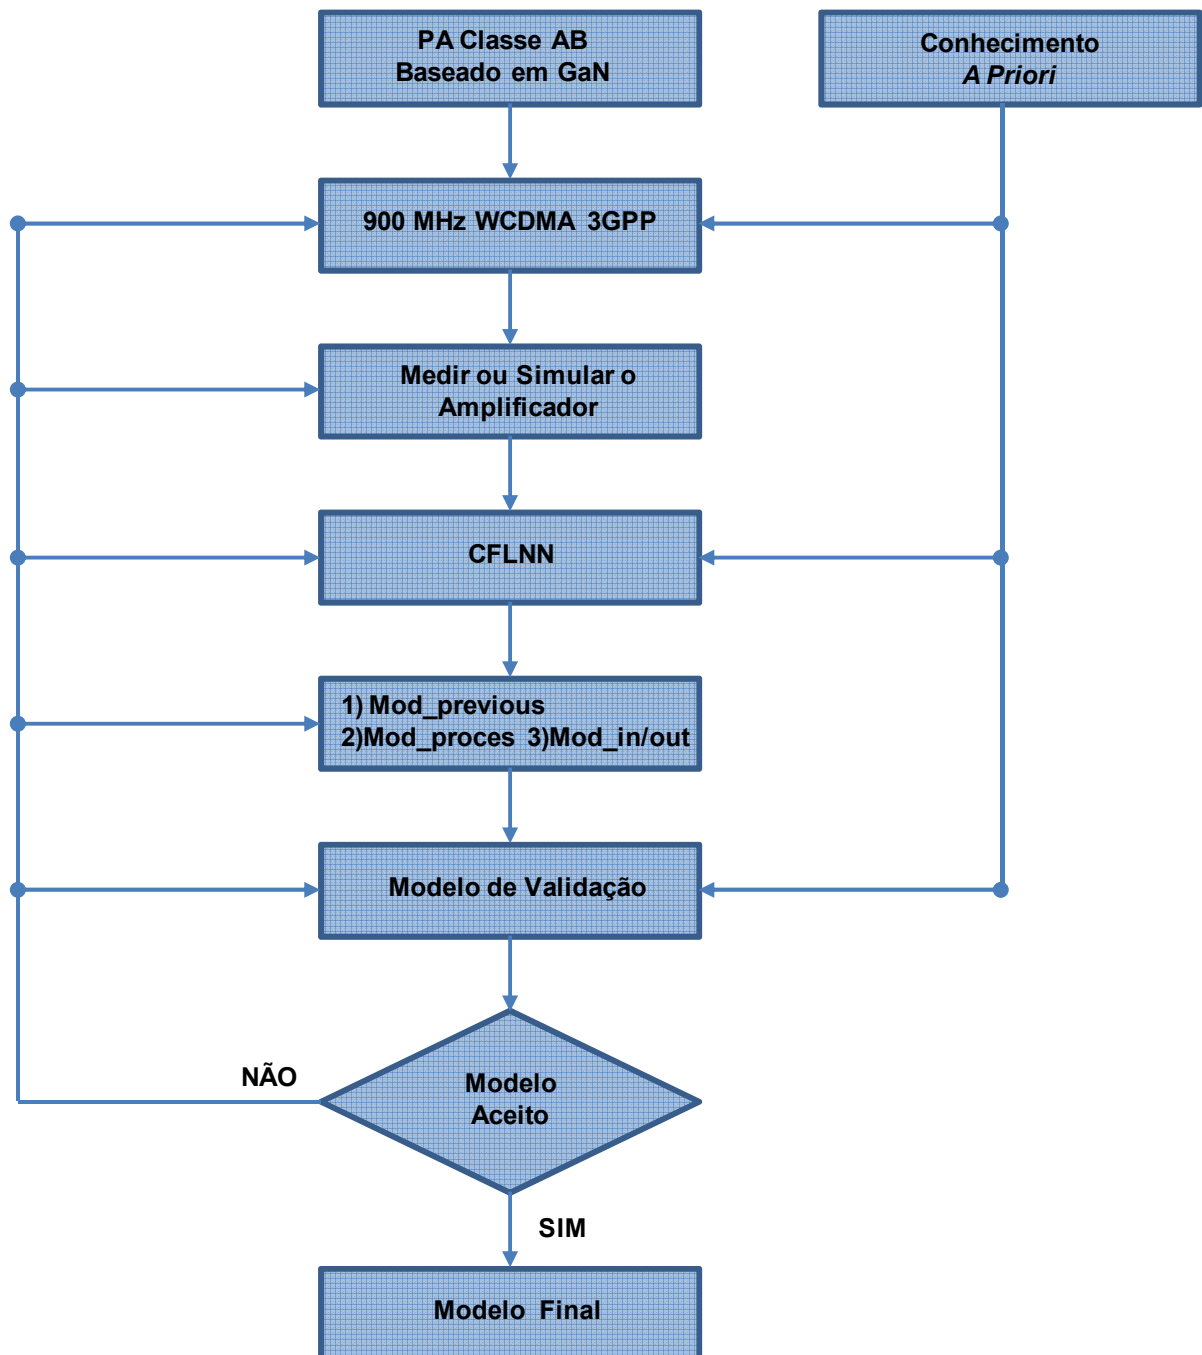


Figura 15. Procedimento de identificação do modelo comportamental de PA RF baseado em CFLNN, modificado de [36].

Os dados de entrada e de saída do PA aqui relatados para composição do modelo foram medidos em um PA de classe AB baseado em transistor GaN (Nitreto de Gálio), com as seguintes especificações técnicas:

- a) Frequência central de 900 MHz;
- b) Excitado por um sinal WCDMA 3GPP;
- c) Largura de banda do sinal de envoltória de 3,84 MHz;
- d) Potência média de saída de 26 dBm.

Os dados de entrada e saída foram medidos utilizando-se um analisador de sinal vetorial (VSA), com frequência de amostragem de 61,44 MHz. Foram coletados 38250 pontos, que serviram para parametrizar os modelos e posteriormente validar os três modelos. Os modelos serão parametrizados com o número fixo de entradas (neste caso vamos usar cinco entradas). Para validar adequadamente os modelos, os dados de entrada-saída usados para a validação são diferentes dos que são utilizados para a identificação do modelo. A validação utilizou 8096 pontos.

Foram extraídos vários modelos. Todos os modelos extraídos apresentam o número de entradas fixo em cinco. Porém, o número de parâmetros é variado alterando-se o truncamento da ordem polinomial. Todos os modelos foram extraídos utilizando-se o algoritmo de mínimos quadrados.

4.1 Resultados

Com a finalidade de avaliar a precisão dos modelos comportamentais CFLNN, são utilizadas duas métricas (figuras de mérito) bem conhecidas. Elas são calculadas sobre os sinais de erro definidos como a diferença entre os sinais de saída medido e simulado pelo modelo de amplificador de potência.

A primeira métrica é conhecida como o erro quadrático médio normalizado (NMSE), relatado em [37] e calculada por:

$$NMSE = 10 \log_{10} \left[\frac{\sum_{i=1}^N |y_{med}(i) - y_{est}(i)|^2}{\sum_{i=1}^N |y_{med}(i)|^2} \right] \quad (4.1)$$

onde i especifica uma amostra e N é o número total de amostras. O sinal $y_{med}(i)$ é o sinal de saída (envoltória de valor-complexo) medido no instante de tempo i . O sinal $y_{est}(i)$ é o sinal de saída (envoltória de valor-complexo) estimado pelo modelo de PA RF no instante de tempo i . Tem-se, portanto, o erro do sinal no instante de tempo i definido como a diferença entre os sinais de saída medido e estimado pelo modelo, ou seja, $y_{med}(i) - y_{est}(i)$.

Para visualizar os resultados da métrica do NMSE (eixo vertical) como uma função do número de parâmetros de valores-complexos (eixo horizontal) utilizados por cada modelo, verificar a Figura 16. Observe que o número de parâmetros foi variado alterando-se o truncamento da ordem polinomial. Observe também que o CFLNN *mod_in/out* proposto obteve um melhor desempenho em comparação com a abordagem anterior, proposta em [9]. Isso é observado por uma melhoria de até 2 dB na figura de mérito NMSE, em caso de ambos os modelos possuírem a mesma quantidade de parâmetros.

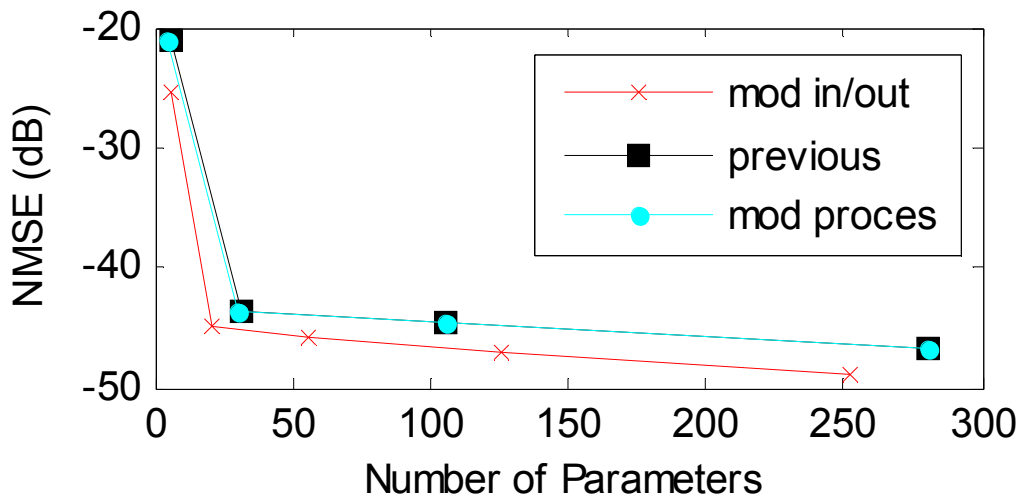


Figura 16. Resultados de NMSE em função do número de parâmetros.

A segunda métrica a ser calculada aqui é conhecida como a relação entre a potência do sinal de erro no canal adjacente e a potência do sinal de saída na banda passante (ACEPR), indicado em [38] e calculado por:

$$ACEPR = 10 \log_{10} \left[\frac{\int_{adj} |Y_{med}(f) - Y_{est}(f)|^2 df}{\int_{chan} |Y_{med}(f)|^2 df} \right] \quad (4.2)$$

onde $Y(f)$ é a transformada discreta de Fourier do sinal correspondente, $Y_{med}(f)$ é a transformada discreta de Fourier do sinal de saída medido e o $Y_{est}(f)$ é a transformada discreta de Fourier do sinal de saída estimado pelo modelo. A integral do denominador *chan* é aplicada sobre o canal principal e a integral do numerador *adj* é aplicada sobre o canal adjacente (superior ou inferior) com a mesma largura de banda do canal principal.

A Figura 17 mostra os resultados da métrica ACEPR (para canais com uma largura de banda igual a 3,84 MHz e uma separação de 5 MHz entre o canal central e os canais adjacentes), também como uma função do número de parâmetros. Observe que o CFLNN *mod_in/out* proposto obteve um melhor desempenho em comparação com a abordagem anterior, proposta em [9]. Isso é observado por uma melhoria de até 3 dB na figura de mérito ACEPR, em caso de ambos os modelos possuírem a mesma quantidade de parâmetros.




Figura 17. Resultados de ACEPR em função do número de parâmetros.

Para visualizar ainda melhor o compromisso entre precisão e complexidade computacional fornecida pelos modelos, será utilizada a densidade espectral de

potência (PSD) dos sinais de erro, para as diferentes CFLNNs estudadas, como mostra a Figura 18. Por erro, entende-se a diferença entre o sinal de saída medido (desejado) e o sinal de saída identificado pelos modelos CFLNNs.

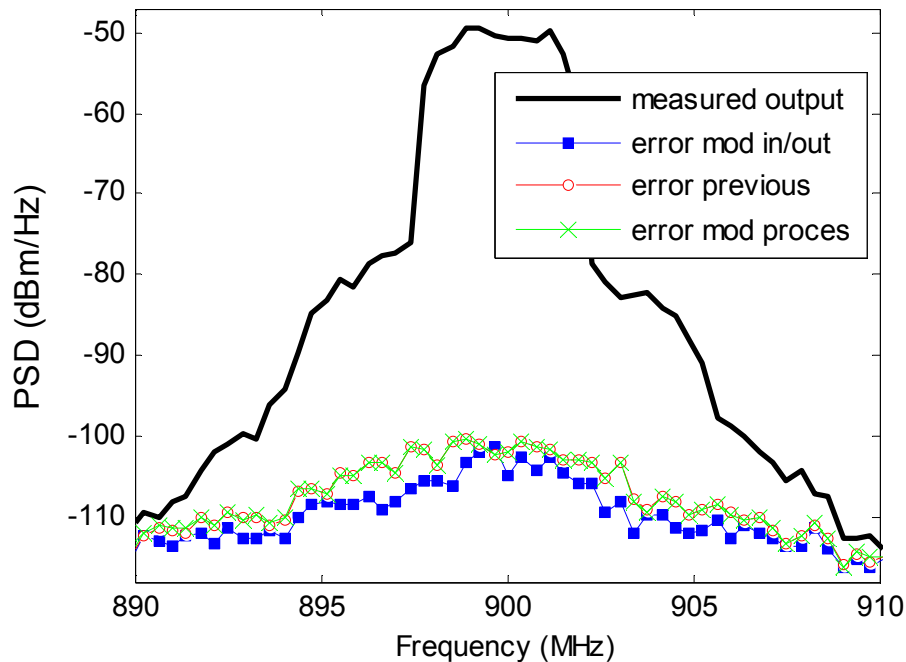


Figura 18. PSD dos sinais de erro: CFLNN *mod_in / out* tem 251 parâmetros; CFLNN *previous* tem 281 parâmetros; CFLNN *mod_proces* tem 280 parâmetros.

Como se pode verificar, a Figura 18 apresenta a PSD do sinal de saída medido e também as PSDs dos sinais de erros utilizando os diferentes modelos CFLNNs. Observa-se que o erro para o modelo CFLNN *mod_in/out* proposto apresenta a menor PSD em todo o espectro ilustrado na Figura 18, mesmo quando utiliza um número de parâmetros menor que os outros modelos.

Como se pode verificar pelas Figuras 16, 17 e 18, um modelo obteve melhor resultado. Seguem algumas considerações sobre estes resultados:

a) Pode-se observar que o modelo CFLNN *mod_in/out* tem um desempenho melhor que os demais modelos CFLNN apresentados. O modelo CFLNN *mod_in/out* é mais econômico no número de parâmetros em comparação com os outros modelos (na Figura 18, por exemplo, o modelo CFLNN *mod_in/out* utilizou 251 parâmetros; o modelo CFLNN *mod_previous* utilizou 281 parâmetros; o

modelo CFLNN *mod_proces* utilizou 280 parâmetros). Isso acontece porque o modelo CFLNN *mod_in/out* não necessita da aplicação do conceito de conjugação adequada, e esse conceito de conjugação adequada aumenta significativamente o número de parâmetros.

b) Pode-se observar que o modelo CFLNN *mod_previous* e o modelo CFLNN *mod_proces* possuem resultados muito semelhantes em termos das métricas NMSE e ACEPR. Na verdade, o modelo CFLNN *mod_previous* em geral não cumpre a restrição de sistema passa-banda. Entretanto, no CFLNN *mod_previous*, as contribuições não físicas são restritas à números complexos de valores constantes. Uma vez que o polinômio de Chebyshev de ordem zero (T_0) (uma constante por definição) também está incluída no subespaço do CFLNN, seu coeficiente multiplicativo $w(0)$ pode ser ajustado a fim de remover as contribuições não físicas (todas elas constantes) geradas pelas ordens pares do polinômio de Chebyshev.

CAPÍTULO 5

CONCLUSÃO

Neste capítulo são apresentadas as conclusões deste trabalho, bem como identificadas algumas linhas possíveis para melhoria e continuidade do mesmo.

5.1 Conclusão

Este trabalho abordou os benefícios da inferência do conhecimento físico para melhorar o compromisso entre precisão e complexidade computacional na modelagem comportamental de PAs RF. Foi proposto um modelo comportamental CFLNN para PA, com diferentes sinais de entrada e de saída, que garante o cumprimento das restrições impostas pela natureza passa-banda de PAs RF, independentemente do comportamento particular dos polinômios de Chebyshev dentro do bloco de expansão funcional.

Desta forma, o CFLNN proposto (CFLNN *mod_in/out*) não exige a aplicação do conceito de conjugação adequada, obrigatório para a abordagem anterior (CFLNN *mod_previous*) e, por conseguinte, o CFLNN proposto pode reduzir significativamente o número de parâmetros. Com base em dados experimentais medidos em um PA classe AB baseado em transistor GaN (Nitreto de Gálio), o CFLNN proposto obteve um melhor desempenho em comparação com uma abordagem anterior. Isso é observado por uma melhoria de até 2 dB na figura de mérito NMSE e uma melhoria superior a 3 dB na figura de mérito ACEPR.

5.2 Sugestão de Trabalho Futuro

Uma sugestão de trabalho futuro seria repetir a análise utilizando outros polinômios ortogonais, como por exemplo, o polinômio de Hermite, o polinômio de Legendre e o polinômio de Laguerre.

BIBLIOGRAFIA

- [1] F. H. Raab, P. Asbeck, S. Cripps, P. B. Kenington, Z. B. Popovic, N. Potheary, J. F. Sevic, and N. O. Sokal, "Power amplifiers and transmitters for RF and microwave," *IEEE Trans. Microw. Theory Tech.*, vol.50, no.3, pp.814–826, Mar. 2002.
- [2] S. Cripps, *RF Power Amplifiers for Wireless Communications*, 2nd edition. Norwood, MA: Artech House, 2006.
- [3] D. Raychaudhuri and N. B. Mandayam, "Frontiers of Wireless and Mobile Communications," *Proceedings of the IEEE* , vol.100, no.4, pp.824-840, Apr. 2012.
- [4] P. B. Kenington, *High Linearity RF Amplifier Design*. Norwood, MA: Artech House, 2000.
- [5] J. C. Pedro and S. A. Maas, "A comparative overview of microwave and wireless power-amplifier behavioral modeling approaches," *IEEE Trans. Microw. Theory Tech.*, vol. 53, no. 4, pp. 1150–1163, Apr. 2005.
- [6] T. Liu, S. Boumaiza, and F. M. Ghannouchi, "Dynamic behavioral modeling of 3G power amplifiers using real-valued time-delay neural networks," *IEEE Trans. Microw. Theory Tech.*, vol. 52, no. 3, pp. 1025–1033, Mar. 2004.
- [7] M. Isaksson, D. Wisell, and D. Ronnow, "Wide-band dynamic modeling of power amplifiers using radial-basis function neural networks," *IEEE Trans. Microw. Theory Tech.*, vol. 53, no. 11, pp. 3422–3428, Nov. 2005.
- [8] Y. H. Pao, *Adaptive Pattern Recognition and Neural Networks*. Reading, MA: Addison-Wesley, 1989.
- [9] M. Li, J. Liu, Y. Jiang, and W. Feng, "Complex-Chebyshev Functional Link Neural Network Behavioral Model for Broadband Wireless Power Amplifiers", *IEEE Trans. Microw. Theory Tech.*, vol. 60, no. 6, pp. 1979–1989, June 2012.
- [10] E. G. Lima, T. R. Cunha, and J. C. Pedro, "A Physically Meaningful Neural Network Behavioral Model for Wireless Transmitters Exhibiting PM–AM/PM–PM Distortions", *IEEE Trans. Microw. Theory Tech.*, vol. 59, no. 12, pp. 3512–3521, Dec. 2011.
- [11] J. C. Pedro and N. B. Carvalho, *Intermodulation Distortion in Microwave and Wireless Circuits*, 1st Edition. Norwood, MA: Artech House, Inc., 2003.

- [12] D. M. Pozar, *Microwave Engineering*. John Wiley & Sons, Third Edition, 2005.
- [13] J. T. Stauth and S. R. Sanders, *Dynamic power supply design for high-efficiency wireless transmitters*. Berkeley, CA: Master's thesis, EECS Department, University of California, May 2006.
- [14] S. A. Maas, *Nonlinear Microwave and RF circuits*, 2nd edition. Norwood, MA: Artech House, January 2003.
- [15] J. C. Pedro and N. B. Carvalho, "On the use of multitone techniques for assessing RF components intermodulation distortion," *IEEE Transactions on Microwave Theory and Techniques*, vol. 47, pp. 2393-2402, 1999.
- [16] S. Benedetto and E. Biglieri, *Principles of Digital Transmission with Wireless Applications*. Kluwer/Plenum, 1999.
- [17] M. Gadringer, D. Silveira, D. Schreurs, M. Myslinski, M. O'Droma, J. A. Garcia and A. Mediavilla, "Properties of behavioural models, " in *RF Power Amplifier Behavioral Modeling*, D. Schreurs, M. O'Droma, A. A. Goacher and M. Gadringer, Eds. Cambridge, MA: The M.I.T. Press, 2009, ch. 2, pp. 27–85.
- [18] Y. H. Pao and Y. Takefuji, "Functional-link net computing: theory, system architecture, and functionalities," *Computer*, vol. 25, pp. 76-79, 1992.
- [19] J. C. Patra and C. Bornand, "Nonlinear dynamic system identification using Legendre neural network," in *International Joint Conference on Neural Networks*, 2010, pp. 1-7.
- [20] J. C. Patra and A. C. Kot, "Nonlinear dynamic system identification using Chebyshev functional link artificial neural networks," *IEEE Trans. Systems, Man, and Cybernetics, Part B: Cybernetics*, vol. 32, pp. 505-511, 2002.
- [21] H. M. Abbas, "System Identification Using Optimally Designed Functional Link Networks via a Fast Orthogonal Search Technique," *Journal of Computers*, vol. 4, pp. 147-153, February 2009.
- [22] S. Emrani, et al., "Individual particle optimized functional link neural network for real time identification of nonlinear dynamic systems," in the *5th IEEE Conference Industrial Electronics and Applications (ICIEA)*, 2010, pp. 35-40.

- [23] S. J. Nanda, et al., "Improved Identification of Nonlinear MIMO Plants using New Hybrid FLANN-AIS Model," in IEEE International Advance Computing Conference, 2009, pp. 141-146.
- [24] J. Teeter and C. Mo-Yuen, "Application of functional link neural network to HVAC thermal dynamic system identification," IEEE Trans. Industrial Electronics, vol. 45, pp. 170-176, 1998.
- [25] J. C. Patra and R. N. Pal, "A functional link artificial neural network for adaptive channel equalization," Signal Processing, vol. 43, pp. 181- 195, 1995.
- [26] P. P. Raghu, et al., "A combined neural network approach for texture classification," Neural Networks, vol. 8, pp. 975-987, 1995.
- [27] I. A. Abu-Mahfouz, "A comparative study of three artificial neural networks for the detection and classification of gear faults, " International Journal of General Systems, vol. 34, pp. 261-277, 2005.
- [28] L. M. Liu, et al., "Image classification in remote sensing using functional link neural networks," in Proceedings of the IEEE Southwest Symposium on Image Analysis and Interpretation, 1994, pp. 54-58.
- [29] S. Dehuri and S.-B. Cho, "Evolutionarily optimized features in functional link neural network for classification," Expert Systems with Applications, vol. 37, pp. 4379-4391, 2010.
- [30] M. Klaseen and Y. H. Pao, "The functional link net in structural pattern recognition," in Conference on Computer and Communication Systems, 1990, pp. 567-571, vol.2.
- [31] G. H. Park and Y. H. Pao, "Unconstrained word-based approach for off-line script recognition using density-based random-vector functional-link net," Neurocomputing, vol. 31, pp. 45-65, 2000.
- [32] R. Majhi, et al., "Development and performance evaluation of FLANN based model for forecasting of stock markets," Expert Systems with Applications, vol. 36, pp. 6800-6808, 2009.
- [33] R. Ghazali, et al., "Dynamic Ridge Polynomial Neural Network: Forecasting the univariate non-stationary and stationary trading signals," Expert Systems with Applications, vol. 38, pp. 3765-3776, 2011.
- [34] B. B. Misra and S. Dehuri, "Functional Link Artificial Neural Network for Classification Task in Data Mining," Journal of Computer Science, vol. 3, pp. 948-955, 2007.

[35] T. T. Lee and J. T. Jeng, "The chebyshev polynomial based unified model neural networks for function approximations," *IEEE Trans. Syst., Man Cybern.*, vol. 28, no. 6, pt. B, pp. 925–935, Jun. 1998.

[36] T.Soderstrom and P.Stoica, *System Identification*. London, United Kingdom: Prentice-Hall International, 1989.

[37] M. S. Muha, C. J. Clark, A. Moulthrop, and C. P. Silva, "Validation of power amplifier nonlinear block models," in *IEEE MTT-S Int. Microwave Symp. Dig.*, Anaheim, CA, Jun. 1999, pp. 759–762.

[38] M. Isaksson, D. Wisell, and D. Ronnow, "A comparative analysis of behavioral models for RF power amplifiers," *IEEE Trans. Microw. Theory Tech.*, vol. 54, no. 1, pp. 348–359, Jan. 2006.

