

Problema Inverso Aplicado na Validação de Pré-distorcedores Digitais para Amplificadores de Potência

Caio Phillipe Mizerkowski e Eduardo Gonçalves de Lima

Resumo—Para utilizar o amplificador de potência (PA) em sua operação de maior eficiência sem comprometer a linearidade, uma alternativa atraente é a inclusão de um pré-distorcedor digital (DPD) em comunicação sem fio. O projeto do DPD demanda medidas do PA para treinar e validar os coeficientes ajustáveis providos pelo modelo de DPD escolhido. Na literatura, a validação do DPD requer uma medição adicional do PA após o treinamento do DPD. Esse trabalho oferece uma abordagem alternativa para a validação do DPD baseada na solução de um problema inverso, que emprega somente as medidas do PA coletadas antes do treinamento do DPD. Quatro estudos de caso foram realizados para ilustrar a eficiência da abordagem. Medidas realizadas em um PA Si LDMOS classe AB, um PA GaN HEMT classe AB, um PA GaN HEMT classe AB estimulado por duas portadoras e um PA GaN HEMT Doherty foram exploradas para desenvolver seus respectivos modelos de DPD. Para este trabalho os modelos de DPD escolhidos foram do tipo *perceptrons* de três camadas (TLPs), que constituem um subgrupo das redes neurais artificiais, e nos quais foi utilizada a função sigmóide como função de ativação, entretanto, existem outros métodos capazes de modelar o inverso de um PA. Os resultados das simulações no Matlab mostram ajustes ótimos entre as entradas dos DPDs conseguidas como uma solução do problema inverso e as medidas dos sinais de saída dos PAs, quantificados pelos erros quadráticos médios normalizados (NMSEs) de -41 dB, -39,3 dB, -39,7 dB e -36,9 dB, para os respectivos PAs. Para a comparação entre a abordagem tradicional e a proposta foi realizado um estudo de caso adicional, utilizando dois conjuntos de medidas experimentais em um PA GaN classe AB, obtidos antes e depois da identificação de um modelo polinomial de DPD. Na comparação foram analisados os valores dos NMSEs, que foram de -44,6 dB para a abordagem tradicional e -38,9 dB para a abordagem proposta.

Palavras-chaves — DPD, rede neural, PA, TLP, validação

I. INTRODUÇÃO

Em um sistema de comunicação sem fio, a comunicação entre o transmissor e o receptor é realizada com perdas pelo ar [1] e necessita de um sinal com alto nível de potência. O amplificador de potência (PA) é o elemento responsável por entregar o alto nível de potência que será irradiado pela antena transmissora. O PA é em razão disso um componente que consome uma grande quantidade de potência em sistemas de comunicação sem fio, sendo portanto necessário que sua

operação se dê em uma região de alta eficiência. Entretanto, a eficiência do PA tem uma relação inversa com respeito à linearidade do PA [2]. A linearidade é necessária para evitar a interferência no sinal entre os usuários alocados em canais adjacentes [3]. A eficiência é importante para reduzir o consumo de energia e aumentar a autonomia da bateria [3].

Para lidar com esse problema, uma abordagem atraente é a linearização do PA por meio de uma conexão em cascata de um pré-distorcedor digital (DPD) seguido pelo PA [4]. O DPD é projetado para exibir uma característica de transferência inversa com respeito ao PA. Uma equação matemática com coeficientes ajustáveis é primeiramente escolhida como modelo comportamental do DPD. Então, um primeiro conjunto de entradas e saídas medidas do PA é empregado para a identificação dos parâmetros do DPD. Finalmente, um segundo conjunto de entradas e saídas medidas do PA é usado para a validação do projeto do DPD, comparando os sinais de saída e de entrada da cascata.

Uma prática comum na literatura é que a segunda medição do PA é realizada após o conhecimento do modelo do DPD [5]. Neste caso, um sinal de entrada conhecido é primeiro passado através do modelo de DPD já treinado para somente então alimentar a entrada do PA. Consequentemente, a validação tradicional do DPD compara o sinal de entrada conhecido do DPD com uma nova medição do sinal de saída do PA. O maior problema deste procedimento é que a nova medição do PA precisa ser realizada para cada caso particular do DPD.

A contribuição deste trabalho é a proposta de um procedimento para comparar o sinal de entrada do DPD e o sinal de saída do PA, colocados em cascata, baseado somente nas medidas do PA coletadas experimentalmente antes do conhecimento de qualquer modelo de DPD. Por meio da estratégia proposta neste trabalho, é contornada a necessidade da realização de uma nova medição do PA para a validação do modelo do DPD treinado.

A estratégia introduzida aqui resolve um problema inverso para cada caso particular do treinamento do DPD. Em outras palavras, é um processo iterativo no qual o conjunto de variáveis conhecidas é composto pela saída esperada do modelo do DPD e por uma quantidade M de soluções passadas do problema inverso. Neste processo, o sinal de saída conhecido é igual ao sinal já anteriormente aplicado como entrada do PA e o sinal de entrada, cujos valores são as soluções do problema inverso, é uma réplica do sinal medido como saída

Caio Phillipe Mizerkowski é graduando em Engenharia Elétrica pela Universidade Federal do Paraná (UFPR), Centro Politécnico, Curitiba. (caiomizerkowski@gmail.com)

Eduardo Gonçalves de Lima é doutor em Dispositivos Eletrônicos pelo Politécnico di Torino e docente na Universidade Federal do Paraná (UFPR), Centro Politécnico, Curitiba. (elima@eletrica.ufpr.br)

do PA. Consequentemente, o procedimento de validação do DPD primeiro calcula um novo sinal de entrada do DPD e então compara ele com a medição do sinal de saída do PA já conhecido.

A organização deste trabalho é a seguinte: a Seção II sumariza os conceitos básicos da modelagem comportamental. A Seção III apresenta a pré-distorção digital. A Seção IV apresenta o método proposto de validação baseado no problema inverso, que é aplicado para quatro estudos de caso reportados na Seção V. A Seção VI apresenta uma comparação entre o método proposto e o tradicional. A conclusão é dada na Seção VII.

II. CONCEITOS BÁSICOS EM MODELAGEM COMPORTAMENTAL

A modelagem comportamental pode ser dividida em quatro partes [6]: seleção do modelo, medidas, treinamento e validação.

Uma equação matemática com coeficientes ajustáveis que formula o sinal de saída como uma função do sinal de entrada deve ser primeiro escolhida como modelo comportamental. Para o propósito da linearização, um modelo dinâmico não-linear sem realimentação é requerido para compensar a não-linearidade do PA relacionada aos seus componentes ativos e os efeitos de memória associados aos seus circuitos passivos [6].

Para a modelagem comportamental requerida, vários conjuntos de modelos matemáticos são possíveis, enquanto apresentem as características necessárias para a reprodução do comportamento esperado. As séries de Volterra são uma destas técnicas utilizadas, que se caracterizam como modelos matemáticos formados por séries de potência de coeficientes ajustáveis relacionados às entradas atuais e passadas do sistema a ser reproduzido [7]. Outra abordagem envolve a utilização de redes neurais artificiais, utilizadas neste trabalho na forma dos *perceptrons* de três camadas (TLPs), e cujo desenvolvimento foi baseado no funcionamento dos neurônios biológicos [8].

As medições das entradas e saídas do sistema a ser modelado precisam então ser coletadas. Em modelos discretos no tempo, as amostras são então organizadas em função do tempo com um intervalo de amostragem constante.

No treinamento, correções são feitas para aproximar as estimativas do modelo das medições. Um chute inicial para os coeficientes ajustáveis é feito. Um conjunto de saídas estimadas pelo modelo é gerado e comparado com um conjunto de saídas medidas para as mesmas entradas. Correções nos valores dos parâmetros são feitas com o propósito de minimizar a diferença entre as amostras medidas e as do modelo. O processo é repetido até que um critério de parada seja atingido.

Para modelos lineares nos coeficientes, como é o caso dos modelos baseados em séries de Volterra, algoritmos não recursivos são uma alternativa viável para a determinação de um conjunto de coeficientes. Um exemplo largamente utilizado

são os mínimos quadrados, aonde um vetor de coeficientes é determinado por meio de operações que podem ser descritas matricialmente, como descrito em [7]:

$$\mathbf{H} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}, \quad (1)$$

sendo \mathbf{H} o vetor de coeficientes, \mathbf{X} a matriz de entradas e \mathbf{Y} o vetor de saídas. Havendo a necessidade da utilização de coeficientes complexos, a operação de transposição $(\cdot)^T$ é substituída pela operação que gera o complexo conjugado da matriz transposta $(\cdot)^H$, conhecida como matriz Hermitiana.

Já para as redes neurais artificiais, que são modelos não lineares em seus coeficientes, o algoritmo de treinamento mais difundido é a *backpropagation*, em que o ajuste dos coeficientes é realizado partindo-se da camada de saída e propagando-se no sentido oposto ao da geração do sinal através das camadas ocultas [8].

O modelo treinado tem que ser validado com um outro conjunto de entradas para assegurar a generalização do modelo, ou seja, a habilidade para prever de forma acurada as saídas fora do conjunto de treinamento.

III. PRÉ-DISTORÇÃO DIGITAL

A distorção digital é um modo de conciliar a eficiência e a linearidade do PA. A distorção digital aplica uma característica de transferência inversa antes ou depois do PA. O pré-distorcedor (DPD) é um sistema pré-inverso, distorcendo o sinal antes do PA, como mostrado na Fig. 1a. O pós-distorcedor (PoD) é uma pós-inversa, que distorce o sinal depois do PA, como mostrado na Fig. 1b.

Para os projetos do DPD e PoD, dois conjuntos de entradas e saídas medidas precisam estar disponíveis: um para o treinamento e outro para a validação. O projeto do PoD é uma modelagem comportamental clássica na qual todas as informações do PoD são conhecidas. As informações para o PoD são obtidas pela troca de papéis da entrada e da saída do PA. Entretanto, por causa de sua saída desconhecida, projetar um DPD requer uma maior complexidade em relação ao PoD.

Na prática, devido aos altos níveis de potência manipulados pela saída do PA, um uso efetivo do PoD é inviável. Por essa razão, o DPD é usado ao invés do PoD.

No que concerne ao treinamento do DPD, para contornar o treinamento direto mais pesado do DPD, uma arquitetura para um aprendizado indireto (ILA) é usualmente adotada. Na ILA, os parâmetros do modelo de PoD são primeiro identificados para um cenário mais clássico, no qual ambos os sinais de entrada e saída são conhecidos, e então os parâmetros são copiados para um modelo de DPD com a mesma topologia [9].

No entanto, uma validação de DPD mais confiável exige o seu uso como um modelo pré-inverso. Isso deriva do fato de que o modelo inverso obtido não é exato e apresenta somente uma aproximação do comportamento requerido, embora possa apresentar uma baixíssima diferença em relação ao modelo inverso exato. No entanto, isso já é o suficiente para fazer com que, quando exista uma troca de posição entre os blocos

da cascata, se perca a garantia de que o erro gerado na cascata permaneça igual, criando a necessidade desta nova validação.

Por esta razão, na literatura é usualmente requerida uma nova medição do PA após o treinamento, como visto em [5]. Neste método, uma sequência pré-distorcida é aplicada como a entrada do PA para a medição da saída do PA. A saída do PA é então comparada com o sinal de entrada do DPD e o erro entre a entrada da cascata e o sinal de saída é calculado.

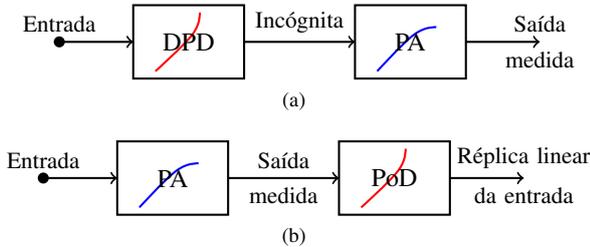


Figura 1: Diagrama de blocos das conexões em cascata: a) DPD seguido pelo PA; b) PA seguido pelo PoD.

IV. ESTRATÉGIA PROPOSTA DE VALIDAÇÃO DO DPD BASEADA NO PROBLEMA INVERSO

O método estabelecido na literatura para a validação da pré-inversa requer uma medição adicional do PA após o treinamento do DPD. Esse trabalho tem o objetivo de oferecer uma alternativa que emprega somente as medições do PA coletadas antes do treinamento do DPD.

O método proposto precisa da geração de um sinal de saída do pré-distorcedor que seja igual às entradas previamente medidas no PA. Uma vez que, na estratégia proposta todas as medidas do PA são feitas antes do treinamento do DPD, o sinal de entrada do PA nunca será uma sequência pré-distorcida, sendo sempre um sinal não distorcido. Na estratégia proposta, busca-se obter uma entrada do DPD que idealmente seja uma réplica da saída medida no PA que, por sua vez, é um sinal distorcido. Como mostrado na Fig. 2, o DPD e suas saídas são conhecidos, mas as entradas do DPD necessárias para gerar o sinal de saída do pré-distorcedor que é igual às entradas do PA previamente medidas são desconhecidas. Achar estas entradas descreve um problema inverso, representado pelo bloco DPD^{-1} na Fig. 2, que precisa de uma solução numérica para cada instante de tempo.

Para finalizar a validação, o erro entre as entradas estimadas, por meio da solução do problema inverso, do DPD e as saídas previamente medidas do PA é computado. Isso é equivalente a medir o erro entre a entrada da cascata e o sinal de saída, como mostrado na Fig. 2. Visto que a saída da cascata deve apresentar uma relação linear com a entrada da mesma, o erro computado é uma medida da capacidade de linearização do sinal pelo DPD.

V. ESTUDOS DE CASO

A técnica de validação do DPD proposta neste trabalho pode ser aplicada para qualquer modelo de DPD. Nesta seção,

como uma prova de conceito, tal técnica é aplicada para a validação de DPDs para quatro PAs, sendo todos os quatro DPDs simulados por redes neurais de valores reais, porém cada um deles é treinado para um PA específico, possuindo um número diferente de entradas e de *perceptrons* na camada oculta, o que altera drasticamente o número de coeficientes de cada um deles, conforme descreve a Seção V.A. Os detalhes do problema inverso, que é utilizado nesse trabalho, são discutidos na Seção V.B. Os resultados são reportados na Seção V.C.

A. Modelagem do DPD

O *perceptron* trabalha como um separador linear com a capacidade de separar um espaço n -dimensional em dois por meio de um hiperplano. O uso de mais de uma camada de *perceptrons* na forma de uma rede neural é necessário para o caso da inversa do PA. O *perceptron* de três camadas (TLP) é a rede neural escolhida para esse trabalho, por causa de sua capacidade de aproximar o comportamento de funções não lineares e sua fácil implementação [8].

A arquitetura do TLP usa uma função sigmóide como função de ativação e é constituída de três camadas: entrada, oculta e saída. A função sigmóide usada é a função tangente hiperbólica, que adiciona a não-linearidade para a função. A Fig. 3 mostra as três camadas da rede usada neste trabalho, mas os *bias* são omitidos e os pesos são representados pelas linhas. A única função da camada de entrada é transferir as entradas para a camada oculta. A camada oculta, que é feita de *perceptrons*, tem o propósito de multiplicar as entradas pelos pesos e aplicar a função sigmóide.

Os *perceptrons* da camada oculta são representados na Fig. 4, na qual são indicadas as entradas in_i e os coeficientes a serem treinados, w_i e b , que são, respectivamente, os pesos e o *bias* do *perceptron*. Para este caso, o subíndice i varia entre 1 e P , que é o total de entradas do TLP. A soma ponderada das entradas por seus respectivos coeficientes e a aplicação da função de ativação são realizadas no *perceptron*. Todo este processo é análogo ao funcionamento dos neurônios biológicos, inspiração para o desenvolvimento dos *perceptrons*, cujo funcionamento é melhor detalhado em [10].

A camada de saída recebe o resultado da camada oculta e repete o processo de multiplicação matricial. O resultado pode ser transferido para outras camadas, mas somente duas

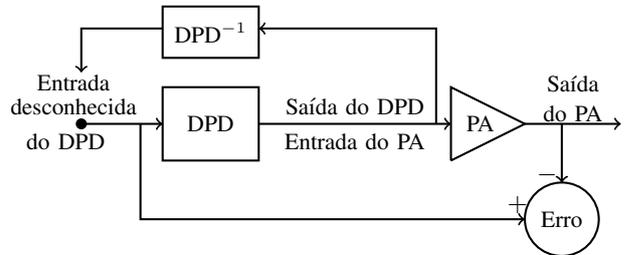


Figura 2: Problema inverso para ser solucionado pela validação do DPD proposta.

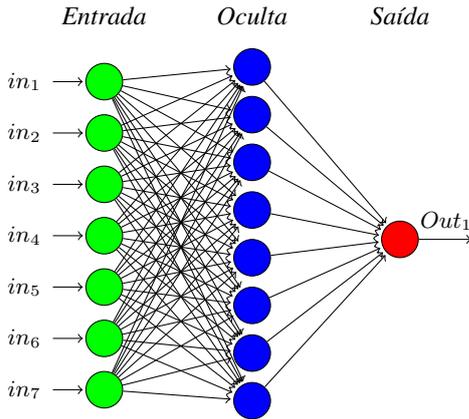


Figura 3: Diagrama de blocos de um *perceptron* de três camadas.

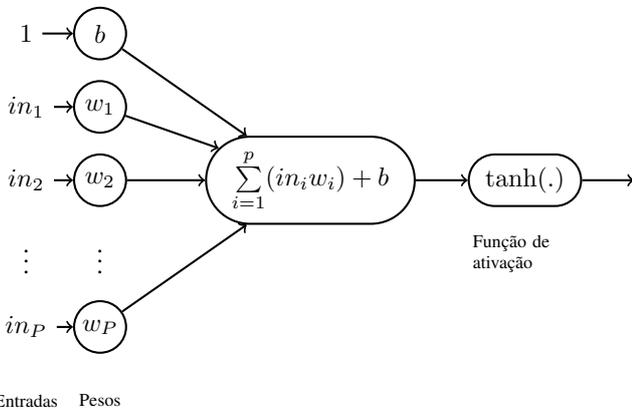


Figura 4: Diagrama da estrutura do perceptron genérico

camadas de *perceptrons* são suficientes para oferecer a não-linearidade requerida [11].

O TLP de valores reais da Fig. 3 não pode lidar com os valores complexos usados na modelagem do DPD. Aqui, para a modelagem do DPD, o diagrama de blocos proposto em [12] e mostrado na Fig. 5 é usado. Essa arquitetura divide a entrada em valor absoluto e variação de fase, a última na forma de seno e cosseno. Para estimar a saída instantânea, não somente as entradas atuais como também as passadas são usadas, o que caracteriza uma memória controlada por um fator M . Em particular, as entradas das redes são compostas por $(M+1)$ amplitudes, correspondentes a todas as amostras contidas no intervalo $n-m$, com m variando de 0 a M , e M senos, juntamente com M cossenos, da diferença entre duas amostras consecutivas $(n-m)-(n-m-1)$, com m variando de 0 a $M-1$. Duas redes de saída única foram empregadas.

As saídas das redes estimam as partes reais e imaginárias de um número complexo. Estes valores são então combinados em um valor complexo que é então multiplicado pela fase da entrada instantânea.

Para aproximar o comportamento de uma função, a rede

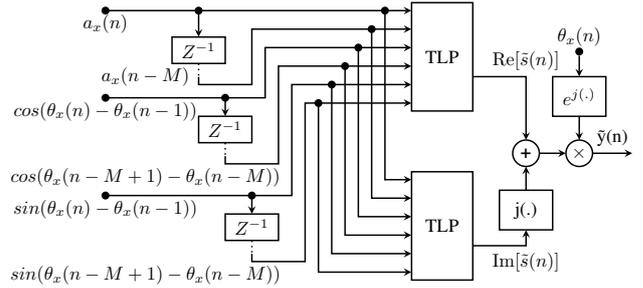


Figura 5: Diagrama de blocos de um modelo de DPD baseado no TLP.

neural precisa de um treinamento. O treinamento do DPD precisa de um conjunto de entradas e saídas e o uso de uma função para minimizar o erro quadrático médio (MSE) dado por:

$$MSE = \frac{1}{N_t} \sum_{i=1}^{N_t} (O_i - \hat{O}_i)^2, \quad (2)$$

onde O é a saída desejada, \hat{O} é o valor estimado da saída da rede neural e N_t é o total de amostras. No treinamento do PoD, a função que é minimizada é o MSE entre a saída de cada rede neural e as respectivas partes reais e imaginárias da entrada do PA.

A função escolhida para minimizar o MSE é a *lsqnonlin* que é parte do *software* Matlab. O *lsqnonlin* é usado para resolver problemas de ajuste de curvas pelos mínimos quadrados não-lineares. Para isso, a função recebe um vetor de erro e de ajustes e os coeficientes do TLP (pesos e *bias*) para minimizar o MSE [13].

B. Problema Inverso

Na técnica tradicional de validação, uma entrada conhecida do DPD é processada através de um modelo conhecido de DPD para conseguir uma saída do DPD. Em tal problema direto, a incógnita é a amostra instantânea de saída do DPD $out_{DPD}(n)$, que é uma função explícita das amostras presentes e passadas da entrada do DPD, de acordo com:

$$out_{DPD}(n) = f[in_{DPD}(n), \dots, in_{DPD}(n-M)]. \quad (3)$$

Na técnica proposta de validação, uma entrada do DPD desconhecida precisa ser encontrada para fornecer uma saída conhecida do DPD quando sujeita à ação de um modelo de DPD conhecido. Em tal problema inverso, a incógnita é a amostra de entrada instantânea do DPD $in_{DPD}(n)$, que só pode ser escrita como uma função das amostras de saída instantâneas do DPD e das amostras de entradas passadas na sua forma implícita, de acordo com:

$$g[in_{DPD}(n), \dots, in_{DPD}(n-M), out_{DPD}(n)] = 0. \quad (4)$$

Para resolver o problema inverso em sua forma implícita, os zeros da equação algébrica não-linear de (4) precisam ser encontrados. Pelo motivo de (4) manipular sinais de amostras passadas, para cada instante de tempo uma equação não-linear

distinta é obtida. Consequentemente, (4) precisa ser resolvida para cada instante de tempo em uma ordem sequencial. A solução de (4) é um número de valor complexo que pode ser separado em parte real e imaginária. Além disso, a equação de valores complexos (4) é equivalente a impor que as partes reais e imaginárias do operador g são simultaneamente zero. A função *fsolve* do Matlab, que encontra os zeros de sistemas não-lineares de valores reais, é usada aqui para resolver o problema inverso.

C. Resultados

Foram realizados quatro estudos de caso de forma a confirmar a viabilidade da abordagem utilizada, por meio do uso de sinais originados em diferentes PAs. Os PAs testados foram um Si LDMOS classe AB modulado por um sinal 3GPP WCDMA e com as medições realizadas por um analisador vetorial de sinais (VSA) Agilent MXA N9020A enquanto o PA operava com uma potência média de saída de 31,5 dBm (na sequência, este PA será designado de LDMOS_AB) [14], um GaN HEMT classe AB modulado por um sinal 3GPP WCDMA e com as medições realizadas por um VSA Rohde & Schwarz FSQ (na sequência, este PA será designado de GaN_AB_1) [15], um GaN HEMT classe AB estimulado por duas portadoras moduladas por sinais 3GPP WCDMA e medido com um VSA Rohde & Schwarz FSQ durante sua operação com uma potência média de saída de 26 dBm (na sequência, este PA será designado de GaN_AB_2) [14] e um GaN HEMT Doherty modulado por sinal LTE OFDMA com as medidas de entrada-saída conseguidas por meio de uma simulação do circuito operando com uma potência média de saída de 30,5 dBm (na sequência, este PA será designado de GaN_Doherty) [14].

Na Tabela I são apresentadas a frequência central (f_c) de operação do sinal, a largura de banda (BW) e a diferença entre a frequência central da faixa central e as frequências centrais das faixas adjacentes (Δf_{cen}).

Tabela I: Detalhes sobre os sinais aplicados nas entradas dos PAs.

PA	f_c (GHz)	BW (MHz)	Δf_{cen} (MHz)
LDMOS_AB	2	3,84	5
GaN_AB_1	0,9	3,84	5
GaN_AB_2	0,9	8,84	10
GaN_Doherty	2,14	7,68	10

A Tabela II, relativa a medição e obtenção do sinal, aponta a frequência de amostragem (f_s) utilizada, o número de amostras para o conjunto de dados de extração e o número de amostras para o conjunto de dados da validação.

Tabela II: Informações sobre os dados coletados dos PAs.

PA	f_s (MHz)	Treinamento	Validação
LDMOS_AB	30,72	26180	8501
GaN_AB_1	30,72	3221	2001
GaN_AB_2	61,44	24180	9600
GaN_Doherty	61,44	20290	4500

A arquitetura baseada em TLP da Fig. 5 foi selecionada para todos os casos como modelo de DPD. Os dois parâmetros de ajuste da arquitetura foram a profundidade de memória M e o número de neurônios N presentes na camada oculta do TLP. A Tabela III apresenta os pares de parâmetros utilizados para cada um dos casos analisados.

Tabela III: Parâmetros utilizados nas redes neurais que modelam os DPDs.

PA	M	N
LDMOS_AB	2	8
GaN_AB_1	8	3
GaN_AB_2	3	7
GaN_Doherty	1	8

As rotinas de treinamento e validação não apresentam entre si diferenças em suas estruturas de processamento e nem em relação aos parâmetros das funções de otimização presentes no Matlab. Alteram-se somente as dimensões das matrizes usadas para representar as entradas e os coeficientes das redes neurais utilizadas, ajustes que são realizados com a simples alteração dos valores M e N durante o processo de chamada da função.

Para o treinamento, os pesos iniciais das redes neurais foram valores aleatórios entre zero e um. A função *lsqnonlin* do Matlab foi configurada com poucas modificações em relação aos seus valores padrões. O algoritmo escolhido foi o Levenberg-Marquardt [16], com um máximo de 10.000 iterações e resoluções das funções, e o valor de 10^{-12} para as tolerâncias de passo e de função.

O erro quadrático médio normalizado (NMSE), introduzido em [17] e calculado por:

$$NMSE = 10 \log_{10} \left(\frac{\sum_{i=1}^{N_t} |O_i - \hat{O}_i|^2}{\sum_{i=1}^{N_t} |O_i|^2} \right), \quad (5)$$

foi empregado na validação dos modelos de PoD e DPD. No que concerne a validação do PoD, O é a medição da entrada do PA e \hat{O} é a saída estimada do PoD. No que concerne a validação do DPD, O é a medição da saída do PA e \hat{O} é a estimativa da entrada do DPD. A Tabela IV mostra o resultado do NMSE para a validação dos modelos PoD.

Tabela IV: NMSE para os conjuntos de validação e de extração para a modelagem comportamental do PoD.

NMSE (dB)	LDMOS_AB	GaN_AB_1	GaN_AB_2	GaN_Doherty
Extração	-40,8	-37,1	-38,0	-34,5
Validação	-40,7	-37,5	-37,3	-34,4

A função *fsolve* do Matlab, com o algoritmo Levenberg-Marquardt, é usada para resolver o problema inverso. Os valores padrões são usados, exceto pelas tolerâncias de passo e função, que recebem os valores de 10^{-12} . O chute inicial para o instante n é o valor estimado para o instante $n-1$.

Além de utilizar-se o NMSE como métrica para avaliação da fidelidade do sinal estimado para a entrada do DPD em relação

ao sinal de saída do PA, calculou-se a razão de potência de canal adjacente (ACPR) para o sinal estimado, conforme a seguinte definição de ACPR:

$$ACPR = 10 \log_{10} \frac{\int_{adj} |f(\omega)|^2}{\int_{cen} |f(\omega)|^2}. \quad (6)$$

Com a discretização do sinal necessária para o processamento do mesmo digitalmente, tem-se a operação de integração transformada em um somatório:

$$ACPR = 10 \log_{10} \frac{\sum_{adj} |f(\omega)|^2}{\sum_{cen} |f(\omega)|^2}, \quad (7)$$

onde $f(\omega)$ é o sinal no domínio da frequência e adj e cen referem-se, respectivamente, as faixas de frequências adjacentes, superior e inferior, e a faixa de frequências centrais do sinal. Têm-se, portanto, dois diferentes valores de ACPR para o sinal analisado, o primeiro referenciando-se a faixa adjacente superior e o segundo a inferior.

Os resultados em NMSE e ACPR obtidos para os casos analisados são apresentados na Tabela V.

Tabela V: Valores de NMSE e ACPR obtidos para os casos analisados.

PA	NMSE (dB)	ACPR _{sup} (dB)	ACPR _{inf} (dB)
LDMOS_AB	-41,0	-35,1	-37,5
GaN_AB_1	-39,3	-29,2	-27,5
GaN_AB_2	-39,7	-29,7	-26,6
GaN_Doherty	-36,9	-24,6	-24,6

Para oferecer um referencial aos valores de ACPR obtidos para os sinais estimados para a entrada das cascatas, na Tabela VI são mostrados os valores de ACPR calculados para os sinais conhecidos das saídas das cascatas.

Tabela VI: Valores de ACPR calculados para os sinais de saída das cascatas.

PA	ACPR _{sup} (dB)	ACPR _{inf} (dB)
LDMOS_AB	-35,0	-37,5
GaN_AB_1	-29,2	-27,3
GaN_AB_2	-29,6	-26,4
GaN_Doherty	-24,5	-24,6

A Fig. 6 mostra, para cada um dos casos analisados, a amplitude da saída do PA e a diferença de fase (entre os sinais de entrada e de saída da cascata) como funções da amplitude de entrada do DPD.

A Fig. 7 mostra as densidades espectrais de potência (PSDs) medidas nas saídas dos PAs (em cor preta) e estimadas nas entradas dos DPDs como soluções dos problemas inversos (as faixas centrais de frequências estão indicadas na cor azul e as faixas adjacentes na cor vermelha).

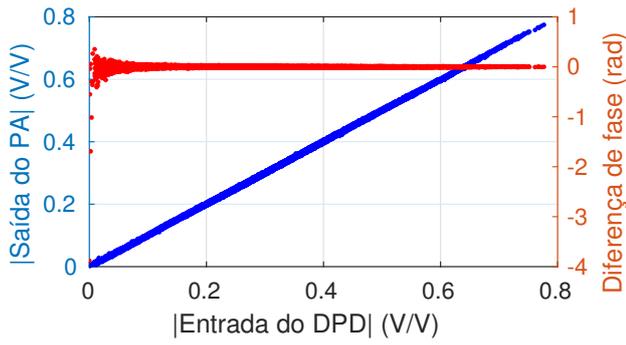
Uma avaliação mais criteriosa entre a abordagem tradicional e a proposta, especificamente para o conjunto de casos analisados nesta seção, se vê impossibilitada pela falta de medições experimentais realizadas nos PAs após a identificação dos

modelos de DPD apresentados nesta seção. Nestas medições não disponíveis, sequências pré-distorcidas, geradas por meio da passagem de sinais pelos DPDs correspondentes, seriam aplicadas como entradas a cada PA de maneira a se conseguir um conjunto de dados de entrada e de saída para cada uma das cascatas analisadas. A disponibilidade destes dados é uma condição necessária para a realização de uma comparação entre os resultados da validação dos modelos pelo método tradicional e pelo método apresentado nesse trabalho. No entanto, é possível afirmar o sucesso do método de validação proposto por causa dos comportamentos lineares, apresentados na Fig. 6, entre a entrada e a saída das cascatas em função da amplitude de entrada. Para todas as cascatas reportadas na Fig. 6, verificam-se ganhos unitários entre a amplitude de saída e a amplitude de entrada, ilustrados pelas retas de inclinações unitárias em azul. Pela Fig. 6 observa-se também que os sinais de entrada e saída de todas as cascatas possuem praticamente a mesma fase, o que é evidenciado pelas retas horizontais em vermelho. De fato, qualquer PA construído fisicamente vai induzir algum atraso e, uma vez que o DPD é um sistema causal, a saída do PA é sempre uma versão atrasada do sinal de entrada do DPD. Contudo, todas as medições de sinais de entrada e saída dos PAs utilizadas neste trabalho foram realizadas com VSAs de um único canal. Dessa forma, as medições do sinal de entrada e saída foram sempre realizadas em diferentes instantes de tempo. Como consequência, não é possível estimar o atraso absoluto do PA. Diante disso, os dados medidos foram pré-processados através do uso de algoritmos de correlação de tal forma a eliminar o atraso entre as sequências de entrada e saída do PA. Somente após a realização deste procedimento é que os sinais foram aplicados para a identificação e validação dos DPDs, o que justifica a ausência de atraso entre os sinais de saída e entrada das cascatas reportadas na Fig. 6. Corroborando ao resultado gráfico, os valores de NMSE apresentados na Tabela IV são próximos dos valores mostrados na Tabela V, o que é um indicativo adicional de que os modelos inversos desenvolvidos comportam-se de maneira similar antes ou após os PAs nas cascatas.

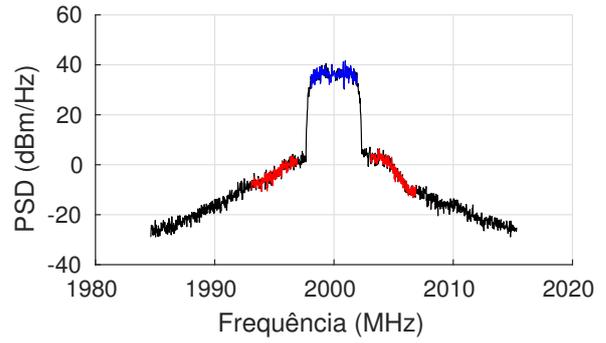
Além disso, a exatidão do método de validação proposto pode ser verificada pela Fig. 7 onde observa-se que, em todos os quatro estudos de caso investigados, as distorções presentes nos canais adjacentes das entradas estimadas dos DPDs através das soluções dos problemas inversos são visivelmente muito próximas das distorções medidas nos canais adjacentes das saídas dos PAs. Especificamente, analisando os resultados de ACPR reportados nas Tabelas V e VI, observa-se que a diferença entre os valores de ACPR nas entradas e saídas das cascatas são sempre iguais ou inferiores a 0,2 dB.

VI. COMPARAÇÃO COM A ABORDAGEM TRADICIONAL

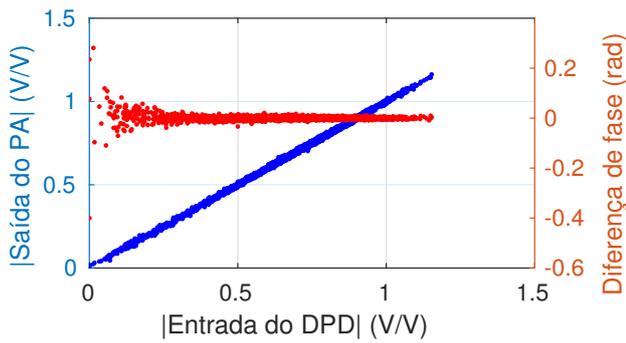
Existindo a necessidade da comparação entre a metodologia tradicional e aquela proposta neste trabalho, um novo estudo de caso deve ser realizado. Este estudo de caso adicional utiliza os dados medidos experimentalmente em um PA linearizado por um DPD já validado pela abordagem tradicional e compara



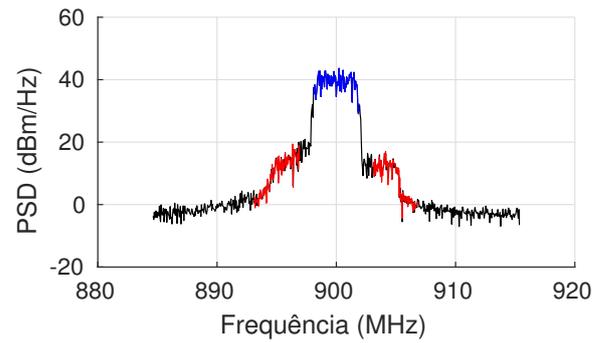
(a) LDMOS_AB



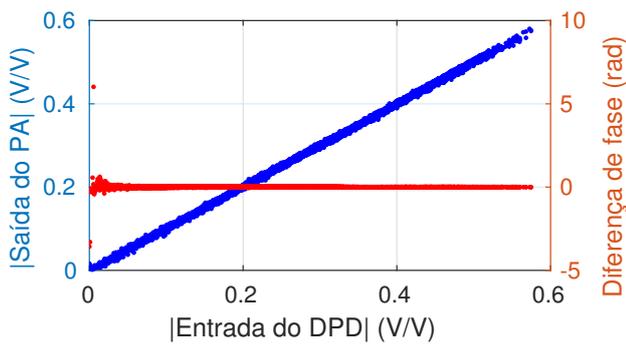
(a) LDMOS_AB



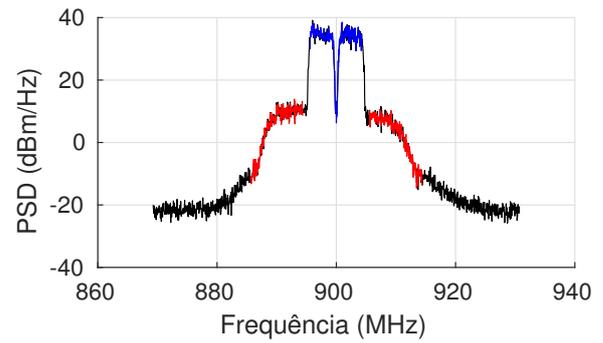
(b) GaN_AB_1



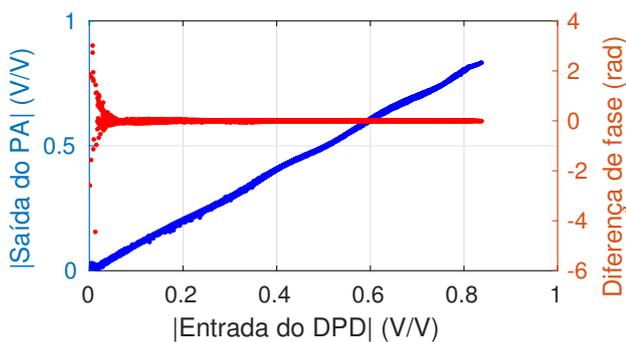
(b) GaN_AB_1



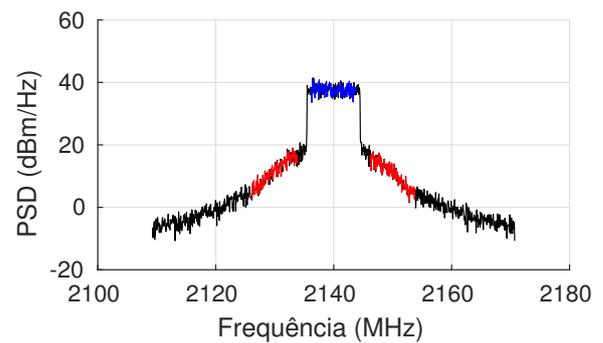
(c) GaN_AB_2



(c) GaN_AB_2



(d) GaN_Doherty



(d) GaN_Doherty

Figura 6: Amplitude de saída do PA e diferença de fase na cascata em função da amplitude de entrada do DPD para os diferentes PAs.

Figura 7: PSD para as entradas estimadas dos DPDs e as saídas medidas dos PAs, considerando-se os conjuntos de dados de treinamento.

estes resultados com os obtidos por meio da abordagem proposta. Espera-se da abordagem proposta um resultado mais conservador, de modo com que haja a garantia de um rigor na validação do modelo inverso em sua função de DPD.

O PA selecionado para o estudo de caso adicional foi um PA GaN classe AB, estimulado por uma portadora em 900 MHz modulada por um sinal WCDMA 3GPP com uma largura de banda de 3,84 MHz e cuja potência média de saída foi de 26 dBm para a extração dos dados. Foram utilizadas 28.800 amostras para o treinamento do modelo e 8.700 amostras para a validação, sendo a frequência de amostragem de 61,44 MHz e as medições realizadas por meio de um VSA Rohde & Schwarz FSQ [18].

O modelo de DPD correspondente ao PA foi projetado utilizando-se o modelo polinomial descrito pela seguinte equação:

$$\tilde{y}(n) = \sum_{p=1}^{P_0} \sum_{m=0}^M \tilde{b}_{p,m} |\tilde{x}(n-m)|^{p-1} \tilde{x}(n-m), \quad (8)$$

na qual $\tilde{y}(n)$ representa a enésima saída do DPD, $\tilde{x}(n)$ a enésima entrada do DPD, P_0 a ordem do polinômio resultante, M a profundidade de memória requerida pelo polinômio e $\tilde{b}_{p,m}$ é o conjunto de coeficientes que serão ajustados pelo método dos mínimos quadrados de forma a modelar a pré-inversa do PA, sendo definida a ordem do polinômio resultante P_0 como 7 e a profundidade de memória M como 3.

Dois conjuntos de dados diferentes foram utilizados para esta comparação. O primeiro deles é formado pelos valores de entrada e saída da cascata e foi utilizado para a obtenção dos valores de NMSE e ACPR referentes a validação tradicional, assim como para a obtenção da Fig. 8a. Em outras palavras, para a obtenção deste primeiro conjunto de dados, uma nova medição do PA foi realizada após o treinamento do DPD, no qual um sinal conhecido foi primeiramente aplicado na entrada do DPD e a sequência pré-distorcida gerada pelo DPD foi então aplicada na entrada do PA. O segundo conjunto de dados é formado pelos valores de entrada e saída do PA medidos antes da identificação do DPD e foi utilizado para a obtenção dos valores de NMSE e ACPR referentes ao método proposto de validação e também para a obtenção da Fig. 8b.

O cálculo do ACPR foi realizado para os sinais de entrada e saída das cascatas. Foi utilizada uma diferença entre a frequência central da faixa central e as frequências centrais das faixas adjacentes de 5 MHz.

Na Tabela VII são comparados os valores de NMSE e ACPR. Verifica-se através da análise do NMSE que o resultado da metodologia proposta apresenta uma estimativa mais conservadora em relação à realidade, uma consequência do erro adicional ao sistema pela resolução do problema inverso. Pela Tabela VII, verifica-se que os valores de ACPR obtidos na entrada e saída da cascata que valida o DPD usando a estratégia proposta são mais próximos entre si do que os respectivos valores para a cascata que valida o DPD usando a estratégia tradicional. Em específico, na cascata que valida o

DPD por meio da estratégia proposta, as diferenças de ACPR de entrada e saída são de no máximo 4,0 dB, enquanto que na cascata que valida o DPD por meio da estratégia tradicional, as diferenças de ACPR de entrada e saída são de até 21,5 dB. Cumpre ressaltar que, na estratégia tradicional, busca-se estimar valores extremamente baixos de ACPR, o que de fato configura-se em uma tarefa muito difícil de ser cumprida. Dessa forma, pode-se concluir que, em ambas as estratégias tradicional e proposta, o objetivo de obter um sinal de saída da cascata que é uma réplica do sinal de entrada da cascata é cumprido de maneira bastante satisfatória.

Tabela VII: Valores de NMSE e ACPR para a comparação entre as duas abordagens.

Abordagem	Tradicional	Proposta
NMSE (dB)	-44,6	-38,9
$ACPR_{sup}$ de Entrada (dB)	-77,2	-36,0
$ACPR_{inf}$ de Entrada (dB)	-77,8	-33,6
$ACPR_{sup}$ de Saída (dB)	-57,9	-39,1
$ACPR_{inf}$ de Saída (dB)	-56,3	-37,6

Na Fig. 8 são observados tanto o comportamento linear necessário como a pequena diferença de fase, condições necessárias para o bom funcionamento do DPD.

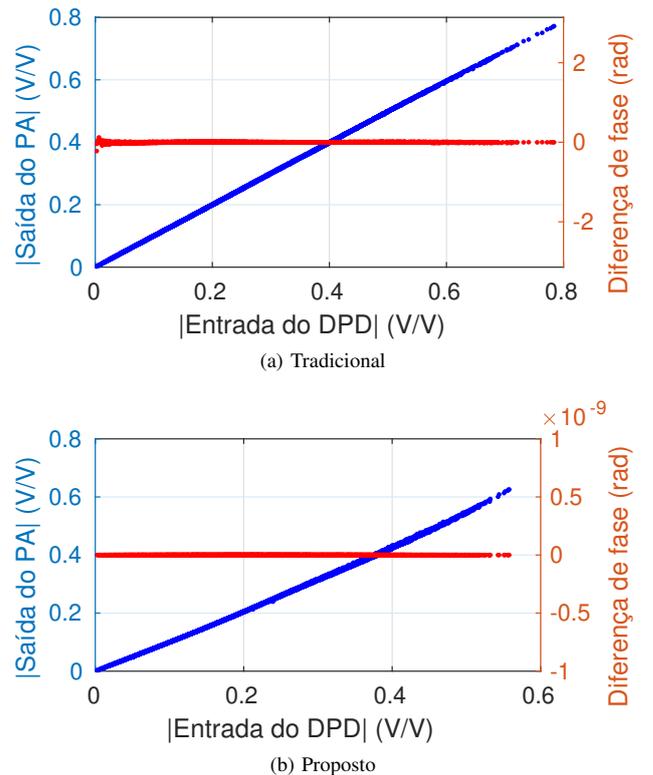


Figura 8: Amplitude de saída do PA e diferença de fase na cascata em função da amplitude de entrada do DPD para: a) Método tradicional de validação; b) Método proposto de validação

VII. CONCLUSÃO

Para evitar a necessidade de realizar uma nova medição do PA toda vez que um modelo diferente de DPD é treinado, esse trabalho propôs a solução de um problema inverso para modificar a entrada do DPD. Os estudos de caso analisados neste trabalho, que adotam um modelo de DPD baseado no TLP para linearizar quatro diferentes PAs, cada qual com características próprias de memória e de não-linearidade, mostraram um NMSE entre a medição da saída do PA e a entrada gerada do DPD de -41 dB para um PA Si LDMOS classe AB, de -39,3 dB para um PA GaN HEMT classe AB, de -39,7 dB para um PA GaN HEMT classe AB estimulado por duas portadoras e um de -36,9 dB para um PA GaN HEMT Doherty. Uma comparação complementar, a qual utilizou um modelo polinomial de DPD, apontou, por meio do NMSE de -44,6 dB para a validação tradicional e de -38,9 dB para a validação proposta, que a metodologia proposta apresenta um resultado conservador em relação ao tradicional. O conjunto de resultados indicou que o uso da metodologia proposta, usando somente as medições do PA coletadas antes do treinamento do DPD, pode ser uma alternativa para a validação de diferentes modelos de DPD, cujas características apresentem diferentes necessidades de memória e não-linearidades.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro provido pela Fundação Araucária de Apoio ao Desenvolvimento Científico e Tecnológico do Estado do Paraná.

REFERÊNCIAS

- [1] 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.
- [2] S. C. Cripps, *RF power amplifiers for wireless communications*, 2nd ed., ser. Artech House microwave library. Boston: Artech House, 2006.
- [3] F. Raab, P. Asbeck, S. Cripps, P. Kenington, Z. Popovic, N. Potheary, J. Sevic, and N. Sokal, "Power amplifiers and transmitters for RF and microwave," *IEEE Transactions on Microwave Theory and Techniques*, vol. 50, no. 3, pp. 814–826, Mar. 2002.
- [4] P. B. Kenington, *High-linearity RF amplifier design*, ser. Artech House microwave library. Boston, MA: Artech House, 2000.
- [5] H. Wang, G. Li, C. Zhou, W. Tao, F. Liu, and A. Zhu, "1-bit Observation for Direct-Learning-Based Digital Predistortion of RF Power Amplifiers," *IEEE Transactions on Microwave Theory and Techniques*, vol. 65, no. 7, pp. 2465–2475, Jul. 2017.
- [6] J. Pedro and S. Maas, "A comparative overview of microwave and wireless power-amplifier behavioral modeling approaches," *IEEE Transactions on Microwave Theory and Techniques*, vol. 53, no. 4, pp. 1150–1163, Apr. 2005.
- [7] V. J. Mathews and G. L. Sicuranza, *Polynomial Signal Processing*. Wiley-Interscience, 2000.
- [8] S. Haykin and P. M. Engel, *Redes neurais: princípios e prática*. Porto Alegre: Bookman, 2001, oCLC: 55921641.
- [9] C. Eun and E. Powers, "A new Volterra predistorter based on the indirect learning architecture," *IEEE Transactions on Signal Processing*, vol. 45, no. 1, pp. 223–227, Jan. 1997.
- [10] J. E. J. E. Hall and A. C. Guyton, *Tratado de fisiologia medica*. Rio de Janeiro (RJ): ELSEVIER, 2011, oCLC: 817254591.
- [11] K. Hornik, "Approximation capabilities of multilayer feedforward networks," *Neural Networks*, vol. 4, no. 2, pp. 251–257, 1991.
- [12] L. B. Chipansky Freire, C. De Franca, and E. G. de Lima, "A Modified Real-Valued Feed-Forward Neural Network Low-Pass Equivalent Behavioral Model for RF Power Amplifiers," *Progress In Electromagnetics Research*, vol. 57, pp. 43–52, 2015.
- [13] J. Nocedal and S. Wright, *Numerical Optimization (Springer Series in Operations Research and Financial Engineering)*. Springer, 2006.
- [14] C. França, L. B. C. Freire, and E. G. Lima, "Three-Layer Perceptron versus Radial Basis Function for the Low-pass Equivalent Behavioral Modeling of Wireless Transmitters," *Journal of Microwaves, Optoelectronics and Electromagnetic Applications (JMoe)*, vol. 14, pp. 136–149, 2015.
- [15] E. J. Bonfim and E. G. de Lima, "A modified two dimensional volterra-based series for the low-pass equivalent behavioral modeling of rf power amplifiers," *Progress In Electromagnetics Research M*, vol. 47, pp. 27–35, 2016.
- [16] D. W. Marquardt, "An algorithm for least-squares estimation of nonlinear parameters," *Journal of the Society for Industrial and Applied Mathematics*, vol. 11, no. 2, pp. 431–441, jun 1963.
- [17] M. S. Muha, C. J. Clark, A. A. Moulthrop, and C. P. Silva, "Validation of power amplifier nonlinear block models," in *Microwave Symposium Digest, 1999 IEEE MTT-S International*, vol. 2. IEEE, 1999, pp. 759–762.
- [18] E. G. Lima, "Behavioral modeling and digital base-band predistortion of rf power amplifiers," Ph.D. thesis, Politecnico di Torino, 2009.