

Algoritmo Adaptativo para Linearização de Amplificadores de RF com Alta eficiência

André Antônio dos Anjos e Rausley Adriano Amaral de Souza

Resumo—Amplificadores de potência em RF são a principal causa de inserção de distorções não lineares nos sistemas de comunicação digital. Arquiteturas de amplificadores mais eficientes, tal como a Doherty, tendem a introduzir ainda mais distorções no sinal a ser transmitido. Para mitigar esse problema de forma eficiente, torna-se necessário utilizar técnicas de pré-correção digital. Neste trabalho será proposta a aplicação do algoritmo adaptativo *damped Newton* (DN), tradicionalmente utilizado para treinamento em redes neurais, na pré-correção digital para cenários de distorções bem severas. Comparando-se o desempenho do algoritmo proposto com outros algoritmos adaptativos já consolidados na literatura utilizando um modelo de amplificador do tipo Doherty, foi possível comprovar a superioridade do algoritmo DN em todas as métricas avaliadas.

Palavras-Chave—Modelos não lineares, linearização, pré-correção Digital, algoritmos adaptativos.

Abstract—RF power amplifiers are the main cause of the insertion of non-linear distortions in digital communication systems. More efficient amplifier architectures, such as Doherty, tend to introduce even more distortions into the signal being transmitted. To efficiently mitigate this problem, it is necessary to use digital pre-correction techniques. In this paper, we proposed the application of the adaptive algorithm *damped Newton* (DN), traditionally used for training in neural networks, in digital pre-correction for very severe distortion scenarios. Comparing the performance of the proposed algorithm with other adaptive algorithms already consolidated in the literature using a Doherty amplifier model, it was possible to prove the superiority of the DN algorithm in all evaluated metrics.

Keywords—Non-linear models, linearization, digital pre-correction, adaptive algorithms.

I. INTRODUÇÃO

A utilização de amplificadores de potência (PA, *power amplifiers*) de RF em sistemas de comunicação sem fio é indispensável, pois viabiliza que o sinal a ser transmitido atinja uma ampla área de cobertura. Entretanto, esses dispositivos são os principais responsáveis por introduzirem degradações não lineares no sinal de transmissão, gerando intermodulações dentro da banda de transmissão e em canais adjacentes. A intermodulação dentro da banda degrada a qualidade do sinal emitido pelo transmissor, por exemplo, reduzindo a sua taxa de erro de modulação (MER, *modulation error ratio*)

André A. dos Anjos, Universidade Federal de Uberlândia (UFU), Patos de Minas, e-mail: andre.anjos@ufu.br; Rausley A. A. de Souza, Instituto Nacional de Telecomunicações (INATEL), Santa Rita do Sapucaí, e-mail: rausley@inatel.br. Este trabalho foi parcialmente financiado pelo CNPq (contrato: 311470/2021-1), pela FAPEMIG (contrato: APQ 00966-17), pela FAPESP (contrato: 2021/06946-0), pela CAPES (contrato: 88887.353680/2019-00) e pela RNP, com recursos do MCTIC, processo No 01245.010604/2020-14, sob o projeto Sistemas de Comunicações Móveis de 6ª Geração (6G) do Centro de Referência em Radiocomunicações (CRR) do Instituto Nacional de Telecomunicações – Inatel, Brasil.

e, conseqüentemente, aumentando a taxa de erro de bit na recepção. Por outro lado, a intermodulação fora da banda poderá interferir em outros serviços que estejam tentando realizar suas transmissões em canais adjacentes ao do transmissor de interesse. Essas degradações tornam-se ainda mais críticas em sinais com alta PAPR (*peak-to-average power ratio*), que é o caso dos sinais OFDM (*orthogonal frequency division multiplexing*), amplamente empregados nos sistemas de comunicação mais modernos, dentre os quais podemos destacar os sistemas de TV digital ISDB-T e ATSC 3.0 ou mesmo os sistemas móveis celulares de quarta (4G) e quinta (5G) gerações. Sendo assim, para eliminar ou pelo menos minimizar as distorções inseridas pelos PAs nesses sistemas, é essencial o uso de alguma técnica de linearização.

Existem vários métodos disponíveis para efetuar a linearização, tais como redução de potência (*back-off*), *feedforward*, realimentação negativa e pré-correção analógica [1]. Entretanto, essas soluções podem levar a circuitos complexos, com problemas de estabilidade e que muitas vezes não atingem um resultado tão satisfatório [1]. Um outro método para linearização de amplificadores que vem sendo amplamente adotado em sistemas mais modernos é o de pré-correção digital em banda base [2], que utilizam um dispositivo gerador de distorções não lineares, denominado de DPD (*digital pre-distorter*), que tem a função de compensar aquelas distorções geradas pelo amplificador, permitindo que o sistema completo (DPD + PA) seja linearizado e opere mais próximo da saturação do amplificador, aumentando a sua eficiência energética.

Nos últimos anos, o desenvolvimento de sistemas e algoritmos de pré-correção digital tem atraído grande interesse de pesquisadores em todo o mundo [2]–[4]. Por exemplo, em [2] é proposto um novo algoritmo adaptativo para linearização de amplificadores baseado no conhecido modelo estático LS (*least squares*) com SVD (*singular value decomposition*). A nova proposta reduz as dimensões das matrizes processadas e, conseqüentemente, a sua complexidade computacional, além de prover maior estabilidade a cada nova iteração. Já em [3], os autores apresentaram um tipo de arquitetura de DPD para amplificadores banda larga com limitação de banda no sinal de retorno a ser processado, permitindo a redução da frequência de amostragem desses sinais sem que haja uma degradação de desempenho significativa no sistema de linearização. E, muito recentemente, os autores de [4] apresentaram várias abordagens de baixa complexidade para estimação do modelo inverso do amplificador com a utilização de novos algoritmos adaptativos de aprendizagem, que encontram aplicações em sistemas nos quais as não linearidades do PA são variantes com o tempo e necessitam de constantes atualizações no DPD.

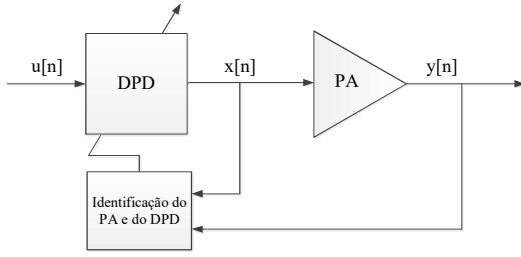


Fig. 1. Arquitetura discretizada simplificada de aprendizagem direta.

Neste artigo é proposta a utilização do algoritmo DN (*damped Newton*), que vem sendo amplamente empregado para treinamento e otimização em redes neurais [5], em sistemas de pré-distorção digital para linearização de amplificadores com arquitetura Doherty, conhecidos por sua alta eficiência energética, mas que degradam muito a qualidade do sinal amplificado [6]. Para comprovar a superioridade do algoritmo proposto, três outros algoritmos disponíveis na literatura também são comparados, a saber (i) NLMS (*normalized mean square error*) [7], (ii) RLS (*recursive least squares*) [8] e (iii) RPEM (*recursive prediction error method*) [9].

II. PRÉ-DISTORÇÃO DIGITAL EM BANDA BASE

As características não lineares do PA podem ser representadas por curvas de conversão denominadas AM/AM (*amplitude modulation to amplitude modulation*) e AM/PM (*amplitude modulation to phase modulation*), que basicamente informam como a amplitude e a fase de saída, respectivamente, são moduladas de acordo com a amplitude de entrada do dispositivo. A essência da pré-correção digital consiste em pré-processar o sinal de entrada de modo a compensar as distorções AM/AM e AM/PM do PA [10], fazendo com que a cascata (DPD + PA) se torne um sistema que seja o mais linear possível. As arquiteturas dos sistemas de pré-distorção são divididas basicamente em dois tipos, denominadas de arquitetura de aprendizagem direta e indireta [1].

A. Arquitetura Estática de Aprendizagem Direta

A arquitetura de aprendizagem direta tem o seu diagrama simplificado apresentado na Fig. 1, em que $u[n]$ representa o sinal de entrada digital, em banda base, do módulo DPD, $x[n]$ é o sinal pré-distorcido pelo DPD e $y[n]$ é o sinal de saída do PA. Nessa arquitetura, inicialmente, deve-se modelar as não linearidades do PA e, na sequência, de posse desse modelo, encontra-se o modelo do DPD que melhor inverte as distorções introduzidas pelo PA. Existem várias equações disponíveis na literatura para a modelagem do PA [11]. Neste trabalho será considerada a equação polinomial com memória MP (*memory polynomial*), que é um dos modelos mais efetivos e amplamente empregados nos sistemas de linearização digital [12]. O modelo MP é expresso em banda base como

$$y[n] = \sum_{m=0}^{M-1} \sum_{k=0}^{\frac{K-1}{2}} h_{m,k} x[n-m] |x[n-m]|^{2k}, \quad (1)$$

em que M representa a máxima profundidade de memória considerada, K é a máxima ordem de não linearidade do polinômio considerado e $h_{m,k}$ representa o coeficiente de ordem k e profundidade m , com $0 \leq k \leq (K-1)/2$ e $0 \leq m \leq M-1$ e K ímpar. Utilizando conceitos de cálculos matriciais e denotando $x[n, m, k] \triangleq x[n-m] |x[n-m]|^{2k}$, o modelo apresentado em (1) pode ser escrito como $y[n] = \mathbf{x}_n \mathbf{h}$, em que $\mathbf{x}_n = [x[n, 0, 0], \dots, x[n, k, m], \dots, x[n, \frac{(K-1)}{2}, M-1]] \in \mathbb{C}^{1 \times \frac{M(K+1)}{2}}$, $\mathbf{h} = [h_{0,0}, h_{0,1}, \dots, h_{M-1, \frac{(K-1)}{2}}]^T \in \mathbb{C}^{\frac{M(K+1)}{2} \times 1}$ e \mathbf{T} indica a operação de transposição de uma matriz. Avaliando N amostras, o modelo MP em (1) pode ser reescrito na forma matricial como $\mathbf{y} = \mathbf{X} \mathbf{h}$, na qual $\mathbf{y} = [y[0], y[1], y[2], \dots, y[N-1]]^T \in \mathbb{C}^{N \times 1}$ e $\mathbf{X} = [\mathbf{x}_0; \mathbf{x}_1; \mathbf{x}_2; \dots; \mathbf{x}_{N-1}] \in \mathbb{C}^{N \times \frac{M(K+1)}{2}}$.

Desta forma, de posse das N amostras de $x[n]$ e $y[n]$ capturadas, para solução de $\mathbf{y} = \mathbf{X} \mathbf{h}$, ou em outras palavras, para estimação do conjunto de coeficientes de \mathbf{h} , que melhor modelam o PA, pode-se aplicar o algoritmo de minimização do erro quadrático LS [13], de acordo com

$$\hat{\mathbf{h}} = (\mathbf{X}^\dagger \mathbf{X})^{-1} \mathbf{X}^\dagger \mathbf{y}, \quad (2)$$

em que \dagger representa o transposto conjugado.

Para verificar a qualidade do modelo obtido, pode-se calcular um vetor de saída estimado, $\mathbf{y}' = \mathbf{X} \hat{\mathbf{h}} \in \mathbb{C}^{N \times 1}$, visando compará-lo com o conjunto de amostras capturado, \mathbf{y} , o que pode ser feito, por exemplo, utilizando a métrica de erro NMSE (*normalized mean square error*). Quanto menor for o valor do erro NMSE calculado, melhor a qualidade da modelagem realizada.

A modelagem do DPD utiliza a mesma equação (1) e, sendo assim, para encontrar os seus coeficientes, basta seguir o mesmo procedimento descrito anteriormente para modelagem do PA, apenas tomando o cuidado de considerar as amostras de entrada da equação do modelo DPD como sendo as de saída estimada do PA, i.e. $x[n] = y'[n]$, e as amostras de saída ficam sendo aquelas capturadas na entrada do PA, i.e. $y[n] = x[n]$. Após a estimação dos coeficientes do DPD, eles são enviados ao dispositivo que, de fato, realizará a operação de pré-distorção do sinal $u[n]$, normalmente implementado em FPGA. Caso a modelagem tenha sido realizada com sucesso, a saída de toda a cascata do sistema, $y[n]$, será um sinal com uma redução significativa de distorções não lineares dentro e fora da banda de transmissão.

A arquitetura estática de aprendizagem direta tem vantagens em termos de simplicidade de implementação e de estabilidade de modelagem. Entretanto, a supressão de distorções alcançadas por esse tipo de DPD pode perder desempenho drasticamente com pequenas alterações nas características do PA, que podem ocorrer devido a vários fatores, tais como: envelhecimento dos transistores utilizados, mudança na potência de operação do equipamento e alteração no canal de transmissão. Portanto, nesses casos, uma arquitetura mais elaborada e adaptativa, que será vista na próxima subseção, torna-se indispensável.

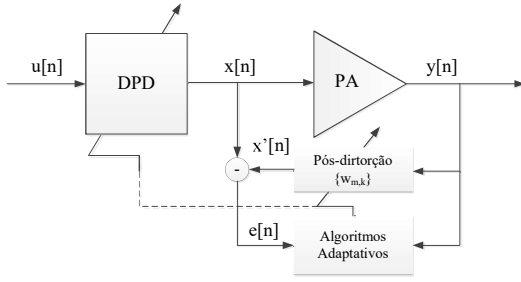


Fig. 2. Arquitetura discretizada simplificada de aprendizagem indireta.

B. Arquitetura Adaptativa de Aprendizagem Indireta

A arquitetura adaptativa de aprendizagem indireta (ILA, *indirect learning architecture*) tem o seu diagrama em blocos apresentado na Fig. 2. Nessa arquitetura é inserido na saída do PA um elemento de pós-distorção (PD, *post-distorter*), que tem a função de reverter as distorções provocadas pelo amplificador, gerando o sinal pós-distorcido, $x'[n]$. Como pode ser visualizado na Fig. 2, o dispositivo de pós-distorção tem seus elementos atualizados por meio de um algoritmo adaptativo, que irá receber em sua entrada um sinal de erro, $e[n] = x[n] - x'[n]$, e as amostras de saída do PA $y[n]$. O algoritmo adaptativo irá atualizar o conjunto de coeficientes, $\{w_{m,k}\}$, do elemento PD a cada nova iteração, coeficientes que também serão replicados no DPD. As iterações irão ocorrer até que se atinja o menor valor de erro possível, que idealmente deveria ser $e[n] = 0$. Nessas condições, o sistema se encontrará em uma condição de estabilidade e o sinal de saída do PA já estará com as distorções não lineares praticamente eliminadas. Neste trabalho utilizaremos exatamente essa arquitetura ILA para comparação do desempenho entre os algoritmos adaptativos, detalhados na Seção III, usados para atualização dos coeficientes do PD e do DPD.

III. ALGORITMOS ADAPTATIVOS E FIGURAS DE MÉRITO

A. Algoritmos de Referência

O NLMS é um algoritmo estocástico baseado no gradiente descendente, no qual os coeficientes de um determinado sistema são adaptados apenas baseando-se no erro atual $e[n]$. Ele é uma variante do algoritmo LMS que resolve o problema de sensibilidade à escala das amostras de entrada normalizando sua amplitude. A atualização dos coeficientes para a n -ésima amostra processada, $n = 1, 2, \dots, N$, é obtida por

$$\mathbf{w}_n = \mathbf{w}_{n-1} + \mu e[n] \frac{\mathbf{y}_n^T}{\mathbf{y}_n \mathbf{y}_n^\dagger}, \quad (3)$$

em que $\mathbf{w}_n \in \mathbb{C}^{\frac{M(K+1)}{2} \times 1}$ é um vetor contendo o conjunto de coeficientes estimados, $\{w_{m,k}\}$, para a n -ésima iteração do algoritmo, μ é o passo de adaptação ($0 < \mu \leq 1$), $*$ indica o conjugado de um número complexo e $\mathbf{y}_n \in \mathbb{C}^{1 \times \frac{M(K+1)}{2}}$ é um vetor de regressão linear de entrada do algoritmo, construído com base na n -ésima amostra processada e na equação MP (1) utilizada para a adaptação, com construção similar a \mathbf{x}_n ,

entretanto, considerando como entrada as amostras de saída do amplificador.

Outro algoritmo considerado nas análises é o RLS [8], que é uma evolução do NLMS, no qual a atualização dos coeficientes para a n -ésima iteração é dada por $S_n = \mathbf{y}_n \mathbf{P}_{n-1} \mathbf{y}_n^T + \lambda$, $\mathbf{P}_n = \frac{\mathbf{P}_{n-1} - \mathbf{P}_{n-1} \frac{\mathbf{y}_n^T \mathbf{y}_n \mathbf{P}_{n-1}}{S_n}}{\lambda}$ e $\mathbf{w}_n = \mathbf{w}_{n-1} + \mathbf{P}_n \mathbf{y}_n^T e[n]$, em que λ é um fator de esquecimento, tal que quanto menor o seu valor, mais rápido a informação dos dados já processados será esquecida pelo algoritmo. $\mathbf{P}_n \in \mathbb{C}^{\frac{M(K+1)}{2} \times \frac{M(K+1)}{2}}$ é uma matriz com valor inicial definido por $\mathbf{P}_0 = \rho \mathbf{I}$, em que \mathbf{I} é uma matriz identidade e ρ é uma constante que reflete a confiança no vetor inicial de coeficientes \mathbf{w}_0 .

O último algoritmo adaptativo com atualização de coeficientes a cada amostra processada considerado é o RPEM [9], que é uma generalização do RLS, no qual o fator de esquecimento se altera à medida que as iterações ocorrem. Neste caso, os coeficientes para a n -ésima amostra processada são calculados como $\lambda_n = \lambda_0 \lambda_{n-1} + 1 - \lambda_0$, $S_n = \mathbf{y}_n \mathbf{P}_{n-1} \mathbf{y}_n^T + \lambda_n$, $\mathbf{P}_n = \frac{\mathbf{P}_{n-1} - \mathbf{P}_{n-1} \frac{\mathbf{y}_n^T \mathbf{y}_n \mathbf{P}_{n-1}}{S_n}}{\lambda_n}$ e $\mathbf{w}_n = \mathbf{w}_{n-1} + \mathbf{P}_n \mathbf{y}_n^T e[n]$, na qual λ_n é um fator de esquecimento que cresce exponencialmente para 1. E, neste caso, além do fator ρ que aparece em $\mathbf{P}_0 = \rho \mathbf{I}$, já definido para o RLS, pode-se configurar também a taxa λ_0 e um valor inicial para λ_n .

B. Algoritmo Damped Newton

O principal algoritmo considerado neste trabalho para estimação dos coeficientes do PD e do DPD é denominado de DN (*Damped Newton*) [5], [14], que foi inicialmente previsto para treinamento, otimização e adaptação em redes neurais. Neste caso, diferentemente dos demais algoritmos já apresentados, nos quais a atualização dos coeficientes ocorre a cada amostra processada, aqui ela ocorrerá a cada processamento de um conjunto ou bloco de N amostras. Os coeficientes estimados para o i -ésimo processamento de um bloco de N amostras no DN são obtidos por

$$\begin{aligned} \mathbf{x}'_i &= \mathbf{Y}_i \mathbf{w}_{i-1} \\ \mathbf{e}_i &= \mathbf{x}_i - \mathbf{x}'_i \\ \mathbf{w}_i &= \mathbf{w}_{i-1} + \alpha (\mathbf{Y}_i^T \mathbf{Y}_i)^{-1} \mathbf{Y}_i^T \mathbf{e}_i \end{aligned} \quad (4)$$

em que $\mathbf{x}'_i \in \mathbb{C}^{N \times 1}$ é um vetor estimado para a entrada do PA na i -ésima iteração, considerando uma matriz de regressão linear $\mathbf{Y}_i \in \mathbb{C}^{N \times \frac{M(K+1)}{2}}$, construída com base na equação MP (1) e em um conjunto de N amostras $y[n]$, capturadas na saída do PA. O erro, \mathbf{e}_i , neste caso, é um vetor $\in \mathbb{C}^{N \times 1}$. O fator α é um fator de relaxamento ($0 < \alpha \leq 1$), tal que quanto menor o seu valor, menor será a contribuição do novo bloco de amostras processadas na estimação do i -ésimo conjunto de coeficientes.

Para avaliar o desempenho dos algoritmos, as seguintes figuras de mérito foram consideradas: (i) o conhecido erro NMSE para medir a dissimilaridade entre as amostras estimadas e as capturadas, (ii) a taxa de erro de modulação (MER) para medir a degradação dentro da banda e (iii) a rejeição do vazamento do canal adjacente (ACLR) para mensurar a degradação fora da banda. A MER pode ser obtida por $\text{MER} =$

TABELA I
PARÂMETROS DE TRANSMISSÃO DO SISTEMA OFDM

Parâmetros	Valor
Número de portadoras totais	8192
Número de portadoras não nulas	5617
Intervalo de Guarda	1/4
Modulação empregada nas portadoras de dados	64-QAM
Modulação empregada nas pilotos	BPSK
Duração do símbolo OFDM	1.26 ms
Distância entre subportadoras	0.992 kHz
Distância entre pilotos	11.9 kHz
Clock da IFFT	512/63 MHz
BW	5.572 MHz
Frequência de amostragem da simulação	65.015 MHz
Número de bits do DAC considerado	12 bits

$\sum_{n=0}^{N-1} [I_n^2 + Q_n^2] / \sum_{n=0}^{N-1} [(I'_n - I_n)^2 + (Q'_n - Q_n)^2]$, em que I_n , Q_n , I'_n e Q'_n representam as componentes em fase e em quadratura dos símbolos ideais e estimados, respectivamente. A ACLR pode ser calculada como $ACLR = \int_{f \in FB} S(f)df / \int_{f \in DB} S(f)df$, na qual os termos do numerador e do denominador representam as integrais realizadas na densidade espectral de potência (DEP) do sinal sob análise, $S(f)$, fora e dentro da banda, respectivamente.

IV. SIMULAÇÃO E RESULTADOS

A simulação desenvolvida no software MATLAB para a comparação dos 4 algoritmos, descritos na Seção III, foi baseada na arquitetura ILA, ilustrada na Fig. 2. Para geração do sinal de transmissão de referência, $u[n]$, um modulador OFDM prático, com características descritas na Tabela I, foi desenvolvido.

O PA foi modelado utilizando amostras reais de um sinal OFDM, similar àquele descrito na Tabela I, capturadas na entrada e na saída convertida para banda base de um amplificador de alta eficiência energética com topologia Doherty, construído com o dispositivo Ampleon BLF888E, operando com 100 watts de potência média RMS na frequência de 473 MHz (Canal 14 UHF). Por meio das amostras capturadas, foi possível levantar a função de transferência do PA, que tem o seu módulo normalizado apresentado na Fig. 3(a). Analisando a dispersão do módulo da função de transferência, mostrada na Fig.3(a), é possível concluir que o amplificador em questão apresenta o efeito memória [11] e a sua modelagem foi realizada considerando a equação (1) para $M = 2$ e $K = 7$, chegando-se em um conjunto de coeficientes estimados para o amplificador dado por $\hat{\mathbf{h}} = [0.79 - 0.36i, 0.11 - 1.7i, -1.9 + 3.6i, 1.4 - 1.6i, 0.04 - 0.08i, 0.39 - 0.65i, -0.85 + 0.81i, 0.48 - 0.36i]^T$. Os blocos de DPD e PD, da Fig. 2, foram implementados também utilizando a equação MP (1), para $M = 3$, $K = 9$, tomando o cuidado de substituir no lugar de $x[n]$ a entrada do respectivo bloco e no lugar do conjunto de coeficientes $h_{m,k}$ aqueles estimados a cada iteração pelo algoritmo de adaptação $w_{m,k}$.

Com todos os blocos da arquitetura ILA implementados, o sistema de pré-correção digital foi avaliado considerando o processamento de 1024 amostras para cada um dos quatro algoritmos. A parametrização considerada para os algoritmos NLMS, RLS e RPEM foi baseada em valores típicos utilizados

TABELA II
RESULTADOS DAS FIGURAS DE MÉRITO

-	NMSE [dB]	ACLR [dB]	MER [dB]
sem DPD	-20.65	-24.65	19.94
NLMS	-6.73	-18.06	9.16
RLS	-27.13	-33.75	26.05
RPEM	-26.81	-34.74	24.89
DN	-33.45	-38.79	39.91

em outras referências sobre o assunto [15]–[17]. Já a parametrização do DN foi obtida de forma experimental, visando obter um bom resultado de eliminação de distorções do PA. Os valores utilizados na parametrização de cada algoritmo são: $\mu = 0.7$ (NLMS), $\lambda = 1$ e $\rho = 10^4$ (RLS), $\lambda_0 = 0.99$, $\lambda = 0.9$ e $\rho = 10^4$ (RPEM) e $\alpha = 0.98$ (DN).

O sistema desenvolvido foi avaliado, inicialmente, sem DPD e, posteriormente, com cada algoritmo considerado no trabalho. O resultado alcançado nas métricas avaliadas para cada cenário considerado está sintetizado na Tabela II. Analisando os resultados da Tabela II é possível concluir que o sistema está em uma condição bem severa de distorção na ausência do DPD, o que pode ser constatado por meio da alta dissimilaridade entre as amostras ideais de entrada e as de saída (NMSE = -20.65 dB), da alta quantidade de intermodulação fora da banda de transmissão (ACLR = -24.65 dB) e da baixa qualidade do sinal de saída dentro da banda (MER = 19.94 dB).

Avaliando o sistema com DPD e algoritmo NLMS, interessante, verifica-se uma piora em todas as três métricas de desempenho, indicando que esse tipo de algoritmo não é adequado para a pré-correção de sistemas não lineares, o que pode ser explicado devido ao mau condicionamento das matrizes de covariância nesse tipo de sistema. Considerando o DPD com RLS, é possível constatar uma melhora em todas as métricas consideradas. Por exemplo, a MER passou de 19.94 dB para 26.05 dB e o ACLR de -24.65 dB para -33,75 dB. Analisando os resultados do DPD com RPEM verifica-se que as métricas ficaram bem próximas daquelas obtidas com RLS, havendo uma pequena melhora de cerca 1 dB na ACLR e uma piora de 1.16 dB na MER. Por último, o DPD com DN obteve um desempenho muito superior ao dos demais algoritmos, proporcionando uma melhora de cerca de 20 dB na MER e de cerca de 14 dB na ACLR, indicando que o algoritmo, inicialmente proposto para utilização em redes neurais, tem um enorme potencial em sistemas de pré-correção de amplificadores de RF, principalmente em cenários de alta degradação. A Fig. 3(b) mostra a DEP do sinal de entrada (ideal) e de saída para cada cenário avaliado, por meio da qual é possível constatar que a técnica de DPD com DN é a que mais elimina distorções fora da banda de transmissão, confirmando as conclusões alcançadas anteriormente com a análise da métrica ACLR.

Com o objetivo de ilustrar também a grande melhoria na qualidade do sinal dentro da banda de transmissão, proporcionada pela utilização do DPD com DN, a Fig. 3(c) apresenta as constelações dos símbolos transmitidos sem DPD (MER = 19.94 dB) e com DPD DN (MER = 39.91 dB), na qual fica evidente a eficiência do algoritmo em reduzir as distorções não

lineares do PA, revelando-se muito promissor para cenários com distorções bem severas.

Uma análise preliminar sobre a complexidade computacional dos algoritmos adaptativos também foi realizada. Na ocasião, efetuou-se a medição do tempo de processamento gasto por cada um deles. Por meio dos resultados, foi possível constatar que o DN é o que possui menor custo computacional, gastando 7 ms para execução, seguido do NLMS (80 ms), RLS (120 ms) e, por último, o RPEM (133 ms). Conjectura-se que esse melhor resultado do DN seja devido ao fato dele processar, de forma matricial, as N amostras em uma única iteração para estimação dos seus coeficientes.

Por fim, vale ressaltar que o algoritmo proposto (DN) e os algoritmos de referência (NLMS, RLS e RPEM) considerados neste trabalho também foram avaliados em outros cenários ao considerar outras condições de distorção e o processamento de um número de amostras diferente de $N = 1024$. Para todos os casos, o sistema com DPD DN obteve o melhor desempenho em todas as métricas avaliadas.

V. CONCLUSÕES

Neste trabalho foi proposta a utilização do algoritmo DN, que vem sendo amplamente empregado em treinamento de redes neurais, em um sistema de pré-correção digital com arquitetura ILA, para linearização de um modelo de PA com arquitetura Doherty, em condições bem severas de distorção. Com este algoritmo alcançou-se um desempenho muito superior ao dos demais algoritmos avaliados (NLMS, RLS e RPEM), em todas as métricas consideradas, proporcionando, por exemplo, uma melhoria de cerca de 20 dB na MER do sinal de transmissão, comprovando sua grande utilidade para linearização de amplificadores de potência em cenários de alta distorção como aqueles encontrados em PAs que utilizam a arquitetura Doherty.

REFERÊNCIAS

- [1] J. Tao, "Behavioral modeling and FPGA implementation of digital predistortion for RF and microwave power amplifiers," Ph.D. dissertation, University Politecnico di Torino, 2016.
- [2] Q. Zhang and Z. Zeng, "A new adaptive algorithm for digital predistortion using LS with singular value decomposition," in *Proceedings of the 2013 International Conference on Information Science and Technology Applications (ICISTA-2013)*. Atlantis Press, 2013/06, pp. 169–172.
- [3] Y. Liu, W. Pan, S. Shao, and Y. Tang, "A general digital predistortion architecture using constrained feedback bandwidth for wideband power amplifiers," *IEEE Trans. Microw. Theory Tech.*, vol. 63, no. 5, pp. 1544–1555, 2015.
- [4] P. P. Campo, L. Anttila, V. Lampu, M. Allén, Y. Guo, N. Wang, and M. Valkama, "Inverse covariance matrix estimation for low-complexity closed-loop DPD systems: Methods and performance," *IEEE Trans. Microw. Theory Tech.*, vol. 70, no. 3, pp. 1474–1489, 2022.
- [5] L. Wang, "The damped Newton method - an ANN learning algorithm," Master's thesis, Northern Arizona University, Arizona, US, 1993.
- [6] M. Naseri Ali Abadi, H. Golestaneh, H. Sarbishaei, and S. Boumaiza, "Doherty power amplifier with extended bandwidth and improved linearizability under carrier-aggregated signal stimuli," *IEEE Microw. Wireless Compon. Lett.*, vol. 26, no. 5, pp. 358–360, 2016.
- [7] M. T.-H. Alouane, "A square root normalized lms algorithm for adaptive identification with non-stationary inputs," *Journal of Communications and Networks*, vol. 9, no. 1, pp. 18–27, 2007.
- [8] L. Ljung and T. Soderstrom, *Theory and Practice of Recursive Identification*, 1st ed. Cambridge, M.I.T. Press, 1983.
- [9] H. G. Natke, "System identification: Torsten söderström and petre stoica." vol. 28, no. 5, pp. 1069–1071, 1992.
- [10] L. Lamport, *High Linearity RF Amplifier Design*. Artech House, 2000.
- [11] E. G. Lima, T. R. Cunha, H. M. Teixeira, M. Pirola, and J. C. Pedro, "Base-band derived volterra series for power amplifier modeling," in *2009 IEEE MTT-S Int. Microwave Symp. Digest*, 2009, pp. 1361–1364.
- [12] W. Pan, Y. Liu, and Y. Tang, "A predistortion algorithm based on accurately solving the reverse function of memory polynomial model," *IEEE Wireless Commun. Lett.*, vol. 1, no. 4, pp. 384–387, 2012.
- [13] L. Guan and A. Zhu, "Optimized low-complexity implementation of least squares based model extraction for digital predistortion of RF power amplifiers," *IEEE Trans. Microw. Theory Tech.*, vol. 60, no. 3, pp. 594–603, 2012.
- [14] J. Zhou, W. Wei, and Z. Zheng, "Research of damped Newton stochastic gradient descent method for neural network training," *CoRR*, vol. abs/2103.16764, 2021.
- [15] E. Abd-Elrady, L. Gan, and G. Kubin, "A nonlinear filtered-x prediction error method algorithm for digital predistortion in digital subscriber line systems," *Int. Journal of Communication Systems*, vol. 26, 05 2013.
- [16] H. D. Rodrigues, "Linearização de amplificadores de potência de rf com pré-distorção digital ortogonal e realimentação escalar," Ph.D. dissertation, Universidade Federal de Itajubá, 2017, tese de doutorado.
- [17] L. Gan, "Adaptive digital predistortion of nonlinear systems," Ph.D. dissertation, Graz University of Technology, 2009.

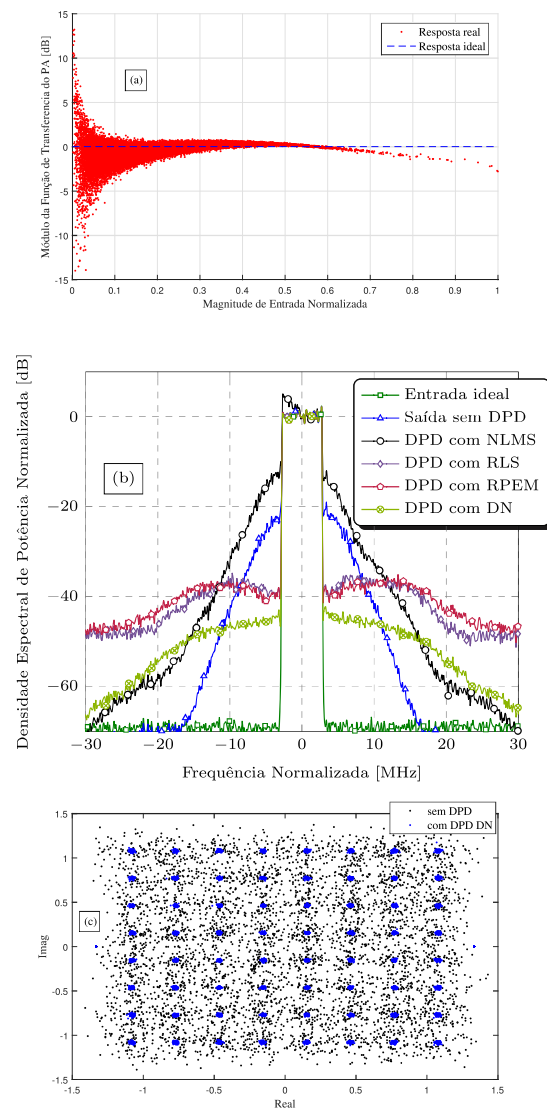


Fig. 3. (a) Função de transferência normalizada, (b) DEP do sinal de saída em várias situações com e sem DPD, (c) constelação de símbolos transmitidos.