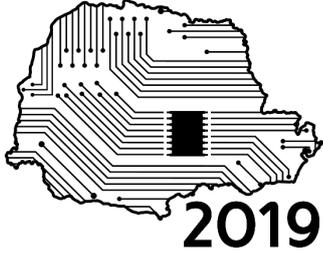


SeMicro-PR



MODELAGEM COMPORTAMENTAL DE AMPLIFICADORES DE POTÊNCIA USANDO APROXIMAÇÕES POLINOMIAIS ORTOGONAIS

Rodrigo Campos Serra Domingues, Eduardo Gonçalves de
Lima

Universidade Federal do Paraná, Curitiba, Paraná
rodricsdomingues@gmail.com,eduardo.goncalves.lima@gmail.com

Resumo - Este trabalho tem como objetivo a modelagem comportamental de amplificadores de potência de rádio frequência utilizando aproximações por polinômios ortogonais através da implementação de uma rede neural de ligação funcional (FLNN), a qual tem a vantagem de ser linear nos seus coeficientes. Foram utilizados três modelos comportamentais para a rede neural usando os polinômios de Chebyshev, de Legendre e de Laguerre, para fins de testar qual modelo oferece uma melhor aproximação para a resposta do amplificador. A implementação dos modelos da rede neural foi feita através do Octave, assim, também, como o treinamento desta rede utilizando diferentes valores para o número de coeficientes e diferentes ordens polinomiais. Após essas duas etapas, foi feita a comparação entre os dados de saída obtidos da rede neural, com os dados de saída medidos no amplificador utilizados como referência, e então foi analisado qual dos modelos implementados obtiveram a menor diferença entre os dados obtidos e os valores de referência, ou seja, quais obtiveram o menor erro na saída. Foi percebido, então, que a exatidão dos resultados aumentava com o aumento de coeficientes, mas o modelo com o polinômio de Laguerre obteve o maior erro, enquanto os modelos com os polinômios de Chebyshev e de Legendre tiveram resultados semelhantes.

Palavras-chave – polinômios ortogonais, rede neural de ligação funcional, modelagem comportamental.

I. INTRODUÇÃO

Nas últimas décadas, foi notório o crescente número de dispositivos conectados à internet, em especial o número de dispositivos wireless, número que vem crescendo cada vez mais desde o surgimento da internet das coisas (IoT), o que leva, também, ao crescente número de dados transferidos nos últimos tempos, e isto leva a uma preocupação com a eficiência energética para sistemas de comunicação wireless [1]. Para os aparelhos de comunicação sem fio, esta eficiência energética representa uma maior duração de suas baterias, enquanto que, para as estações de rádio base, isto representa um menor custo com a dissipação de energia.

Porém, para transmissores com amplificadores a base de transistores de estado sólido, o aumento da eficiência representa a perda de linearidade [2], o que leva à distorção do sinal a ser transmitido levando à perda de informação.

Uma abordagem para resolver este problema é adicionar, em cascata, um bloco que contenha um modelo matemático inverso ao modelo do amplificador, que tenha baixa complexidade e alta exatidão. Tal modelo pode ser obtido por meio de redes neurais como uma FLNN (*Functional Link Neural Network*) com polinômios de Chebyshev [3], que foi utilizada na dissertação de mestrado de Silva [4] no qual este trabalho foi baseado.

II. DESENVOLVIMENTO DO MODELO

Amplificadores são dispositivos que apresentam uma relação de ganho linear entre um sinal de saída e um sinal de entrada. Esta relação pode ser expressa como: $G = P_o / P_i$, onde P_o e P_i são, respectivamente, as potências de saída e de entrada.

No entanto, uma propriedade de amplificadores a base de transistores de estado sólido é que o aumento da eficiência do amplificador implica em uma perda de sua linearidade, o que, por sua vez, implica na distorção do sinal amplificado e portanto apareçam produtos de intermodulação. Para evitar isto, é considerado passar o amplificador por um processo de linearização [5]. Para tal, é necessário um modelo computacional de alta exatidão e baixa complexidade computacional do amplificador, o qual será na forma de um modelo comportamental, pois este requer apenas os dados de entrada e de saída, com os quais criam modelos matemáticos para descrever o comportamento do amplificador. Porém, a exatidão destes modelos depende muito da estrutura adotada, estes são preferidos quando não se tem nenhuma informação do amplificador.

A. Redes Neurais e Polinômios Ortogonais

Como os dados para modelagem do amplificador são amostras no tempo, obtidas da medição de sinais na entrada e na saída do amplificador, o modelo comportamental será encontrado através da interpolação polinomial dos dados, tendo como modelo a *FLNN* utilizada por Silva [4], cujos dados de entrada serão as amostras obtidas do sinal de entrada do amplificador expandidos por polinômios ortogonais.

Os polinômios utilizados pertencem a três categorias de polinômios ortogonais: os polinômios de Chebyshev, os polinômios de Legendre e os polinômios de Laguerre. Os dois primeiros tem os primeiros termos como sendo $T_0(x)=1$ e $T_1(x)=x$, enquanto o terceiro difere apenas em $T_1(x)=1-x$ e os termos de ordem superior podem ser encontrados usando as seguintes equações de recorrência:

- Polinômios de Chebyshev:

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

- Polinômios de Legendre:

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

- Polinômios de Laguerre:

$$(n+1)T_{n+1}(x) = (2n+1-x)T_n(x) - nT_{n-1}(x). \quad (3)$$

A rede neural que foi utilizada foi originalmente proposta por [6] e esta rede tem sido aplicada com sucesso em diversas aplicações como: identificação de sistemas, equalização de canais, reconhecimento de padrões e estruturas para modelar amplificadores de potência de rádio frequência (PARFs) [6].

Esta rede tem a vantagem de ser linear nos seus coeficientes e liga diretamente a entrada com a saída sem a necessidade de camadas ocultas. A figura 1 mostra o funcionamento desta rede. É importante notar que para os casos onde existem mais de uma entrada ($E > 1$), ou seja, para polinômios multidimensionais, surgem maiores contribuições.

A figura 1 mostra o diagrama de blocos da *FLNN*. As saídas y_s são obtidas do resultado de uma função de ativação, cujo valor de entrada é o resultado de uma função somadora da ponderação das constantes $w_{Q,S}$, com os elementos h_Q , os quais são obtidos pela expansão, através das equações de recorrência dadas acima, dos valores de entrada x_E , medidos na entrada do amplificador.

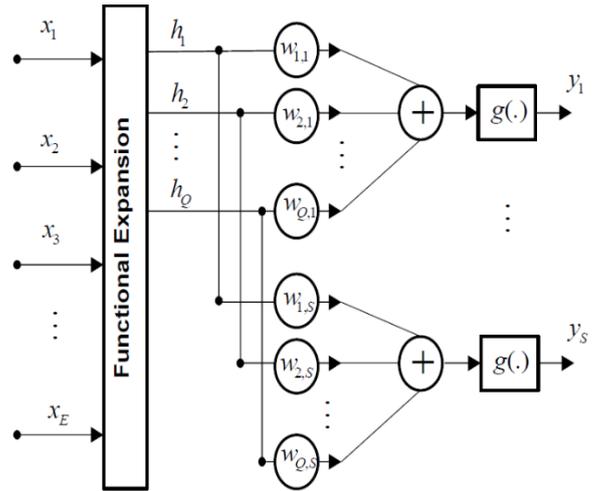


Figura 1: Diagrama de blocos da *FLNN*. Fonte Silva [4].

O sistema representado pela Figura 1, de acordo com [7] e explorando a simetria sem qualquer perda de generalidade, pode ser representado como:

$$y_m = w(0) + \sum_{p=1}^P \sum_{r=1}^P \sum_{q_1}^P \cdots \sum_{q_r=q_{r-1}+1}^P \sum_{l_1}^{f_1} \cdots \sum_{l_r}^{f_r} \sum_{e_1=1}^E \sum_{e_1=e_{l_1-1}+1}^E \cdots \sum_{e_{\sum_{j=1}^{r-1} l_j}}^{E} \sum_{e_{\sum_{i=1}^r l_i} = e_{\sum_{i=1}^{r-1} l_i} + 1}^E w(p, r, q_1, \dots, q_r, l_1, \dots, l_r, e_1, \dots, e_{\sum_{i=1}^r l_i}) \cdot \prod_{q_1}^{q_r} \prod_{j=1+\sum_{i=1}^{r-1} l_i}^{\sum_{i=1}^r l_i} T_q(x_{e_j}) \quad (4)$$

$$\text{se } \left\{ \begin{array}{l} p = \sum_{i=1}^{r-1} l_i q_i \\ e_1 \neq e_2 \neq \cdots \neq e_{\sum_{i=1}^r l_i} \end{array} \right.$$

Onde w_m são os coeficientes da *FLNN* a serem determinados e T_q são os polinômios ortogonais de q -ésima ordem, E e S se referem, respectivamente, ao número de entradas e saídas, P é o truncamento na ordem do polinômio, f, p, r, q e l são índices que determinam as contribuições de cada polinômio ortogonal T_q nos fatores do polinômio final, o qual será a saída y_m e f é obtido por:

$$f = \text{floor} \left[\frac{p + \sum_{i=1}^{r-1} l_i}{q_r} \right] \quad (5)$$

A função floor, aproxima o resultado da expressão para o inteiro mais próximo e menor do que o resultado.

B. Validação do Modelo

Para a validação dos modelos, foram utilizados dados divididos em dois conjuntos, um de extração contendo 29550 amostras e outro de validação contendo 8700 amostras, ambos foram implementados usando a ferramenta Octave, tendo a ordem polinomial e a duração da memória variadas. Estes dados foram obtidos previamente da medição da entrada e da saída de um PARF, sendo este fabricado com tecnologia de nitreto de gálio (GaN) operando em classe AB, excitado por uma portadora na frequência de 900 MHz e modulado por um sinal 3GPP WCDMA contendo 3,84 MHz de largura de banda. Estes dados foram medidos utilizando um analisador vetorial de sinais Rohde & Schwarz FSQ VSA com uma frequência de amostragem de 61,44 MHz.

Para a identificação do modelo, é feita a minimização do erro quadrático médio (MSE), que é feita através dos mínimos quadrados. Foi utilizado o erro quadrático médio normalizado (NMSE), que é uma métrica bastante utilizada como relatado em [8], sendo definido por:

$$NMSE = 10 \log_{10} \left[\frac{\sum_{n=1}^N |y_{ref}(n) - y_{est}(n)|^2}{\sum_{n=1}^N |y_{ref}(n)|^2} \right]. \quad (6)$$

III. RESULTADOS

Os modelos foram testados variando o número de coeficientes através da variação da ordem polinomial indo de 3 a 5, e da variação do tamanho da memória indo de 2 a 4. Os resultados obtidos em termos do NMSE e do número de coeficientes estão na tabela 1. Cada coluna representa, respectivamente, a duração de memória (M), ordem polinomial (P), NMSE de validação, e o número de coeficientes (c).

Tabela 1: Resultados obtidos para os polinômios de Chebyshev, Legendre e Laguerre com M indo de 2 a 4 e P indo de 3 a 5.

M	P	NMSE Validação (dB)			c
		Chebyshev	Legendre	Laguerre	
2	3	-44,154	-44,154	-44,154	30
3	3	-44,337	-44,337	-44,337	60
4	3	-44,472	-44,472	-44,472	105
2	4	-46,219	-46,219	-46,219	51
3	4	-46,574	-46,574	-46,574	100
4	4	-46,790	-46,790	-46,790	170
2	5	-47,657	-47,657	-47,657	78
3	5	-48,122	-48,122	-48,122	152
4	5	-48,386	-48,386	-48,386	255

Desta tabela, percebe-se que a ordem polinomial tem uma influência mais significativa no NMSE, enquanto que o aumento de coeficientes tem uma influência menos significativa no NMSE. Isto fica evidente quando se observa que um polinômio de grau 5 e duração de memória 2 (78 coeficientes) tem um NMSE menor do que um polinômio de grau 4 e de memória 4 (170 coeficientes), porém dois polinômios de mesmo grau, um com duração de memória maior (mais coeficientes) tem NMSE menor do que outro com duração de memória menor (menos coeficientes). A relação com o NMSE e o número de coeficientes está mostrada na figura 2.

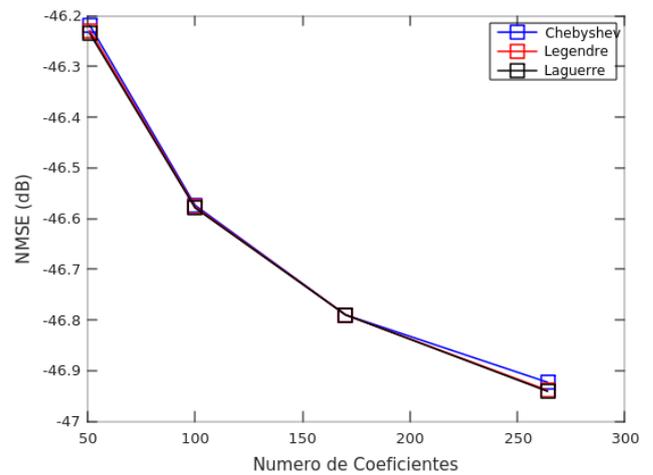


Figura 2: Gráfico da variação do NMSE de validação variando M com P=4 para os três polinômios. Fonte: O Autor (2019).

IV. CONCLUSÃO

Este trabalho teve como objetivo estudar a aplicação de polinômios de Legendre e Laguerre no lugar dos polinômios de Chebyshev na rede neural utilizada por [4] para a modelagem comportamental de um PARF. Com base nos resultados obtidos, os três modelos feitos com aproximações de polinômios de Chebyshev, Legendre e de Laguerre apresentaram desempenhos parecidos. Este resultado provavelmente está relacionado com o modelo utilizado, sendo este o primeiro modelo proposto por [4]. Pode-se utilizar o segundo modelo proposto por Silva, para averiguar se os resultados obtidos pelas três aproximações continuam parecidos. Como sugestão para trabalhos futuros, pode ser feita a mesma análise aumentando a ordem polinomial e a duração da memória, ou utilizar outra classe de polinômios ortogonais como os polinômios Hermite.

V. REFERÊNCIAS

- [1] F. H. RAAB, P. ASBECK, S. CRIPPS, P. B. KENINGTON, Z. B. POPOVIC, N. POTHECARY, 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] 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.
- [4] J. C. SILVA, "Modelagem comportamental de amplificadores de potência de RF utilizando a Rede Neural de Ligação Funcional com polinômio de Chebyshev". 2014.
- [5] P. B. KENINGTON, "High Linearity RF Amplifier Design". Norwood, MA: Artech House, 2000.
- [6] Y. H. Pao, *Adaptive Pattern Recognition and Neural Networks*. Reading, MA: Addison-Wesley, 1989.
- [7] 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.
- [8] MUHA, M. S.; CLARK, C. J.; MOULTHROP, A.; SILVA, C. P. Validation of power amplifier nonlinear block models. In: *IEEE MTT-S Int. Microwave Symp. Dig.*, Anaheim, CA, Jun. 1999, pp. 759–762.