

引用格式: 邹峰, 常宗煜, 胡欣, 等. 面向行波管放大器的多状态行为模型表征方法研究 [J]. 电子科技大学学报, 2025, 54(2): 197-202.
ZOU F, CHANG Z Y, HU X, et al. Research on multi-state behavior model characterization method for traveling wave tube amplifiers[J]. Journal of University of Electronic Science and Technology of China, 2025, 54(2): 197-202.

面向行波管放大器的多状态行为模型表征方法研究



邹峰^{1,2*}, 常宗煜³, 胡欣³, 王刚^{1,2}

(1. 中国科学院空天信息创新研究院, 北京 100190; 2. 中国科学院大学电子电气与通信工程学院, 北京 100049;
3. 北京邮电大学电子工程学院, 北京 100876)

摘要: 近年来, 以深度神经网络为代表的人工智能技术被应用于功率放大器的行为模型构建中, 高精度的非线性拟合度可以满足功率放大器行为模型表征的要求, 但仅适用于单一工作状态。随着对行波管放大器输入输出特性的深入研究, 输出信号受到输入端激励信号的频率和温度变化等多因素的影响, 如何基于深度神经网络构建面向行波管放大器的多状态行为模型亟需研究。该文提出一种面向行波管放大器的多状态神经网络建模方法, 引入嵌入编码向量表征行波管放大器的多种工作状态, 通过增加跳跃连接构造多状态行为模型以避免梯度消失的问题。实验结果表明, 与传统方法相比, 该方法能够构建表征行波管放大器的多种工作状态, 且不会随着模型规模的增加而损失模型精度。

关键词: 行为模型; 行波管放大器; 跳跃连接; 嵌入向量

中图分类号: TN92

文献标志码: A

DOI: 10.12178/1001-0548.2023328

Research on multi-state behavior model characterization method for traveling wave tube amplifiers

ZOU Feng^{1,2*}, CHANG Zongyu³, HU Xin³, and WANG Gang^{1,2}

(1. Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100190, China;

2. School of Electronic, Electrical and Communication Engineering, University of Chinese Academy of Sciences, Beijing 100049, China;

3. School of Electronic Engineering, Beijing University of Posts and Telecommunications, Beijing 100876, China)

Abstract: In recent years, artificial intelligence technologies represented by deep neural networks have been applied in the construction of behavioral models for power amplifiers. High precision nonlinear fitting can meet the requirements of characterizing the behavioral models of power amplifiers, but it is still only applicable to a single working state. With the in-depth study of the input-output characteristics of traveling-wave tube amplifier (TWTA), the output signal is affected by multiple factors such as the frequency of the input excitation signal and temperature changes. Therefore, it is urgent to study how to construct a multi-state behavior model for TWTA based on deep neural networks. This article proposes a multi-state neural network modeling method for TWTA. This method introduces embedded encoding vectors to characterize the various working states of TWTA, and innovatively constructs a multi-state behavior model by adding skip connections to avoid the problem of gradient vanishing. The experimental results show that compared with traditional methods, this method can construct multiple operating states that characterize TWTA without losing model accuracy as the model size increases.

Key words: behavioral model; traveling-wave tube amplifier (TWTA); skip connection; embedding vector

数字预失真 (digital pre-distortion, DPD) 方法是通信系统中常用的功率放大器线性化技术^[1], 对功率放大器行为进行建模是实现预失真的关键步骤

之一^[2]。基于 Volterra 级数及其简化形式的多项式模型已广泛用于功率放大器行为建模中^[3-4], 这一类行为模型主要应用在特定工作条件和特定输入信号

收稿日期: 2023-07-21

作者简介: 邹峰, 高级工程师, 主要从事行波管放大器线性化技术方面的研究。

*通信作者 E-mail: zoufeng@aircas.ac.cn

下的功率放大器建模和预失真中。

文献 [5] 研究发现, 当输入信号 (频率、幅度、带宽)、工作环境温度发生变化时, 行波管放大器 (TWTA) 的非线性失真特性也会发生变化, TWTA 的行为模型需要重新校准。为应对输入功率变化引起的特性变化, 在模型中嵌入输入功率变化信息可以实现自适应标定^[6]。随着表征状态的增多, 传统的多项式模型面临模型复杂度急剧增长的问题。近年来, 神经网络因可以精确拟合非线性特性, 已被应用于功率放大器的低复杂度建模中, 并取得了良好的效果^[7-8]。为了解决深度神经网络构建的功率放大器模型只能适应单一状态的特定场景的问题, 文献 [9] 尝试改造深度神经网络的输入并构建了多状态模型, 只需训练一次即可适应多种状态, 但仅适用于少量状态的场景, 不能直接应用于 TWTA 这类对表征状态数量需求更多的场景, 原因是状态表征数量的增多需要神经网络规模增长, 而神经网络规模的增长存在梯度消失的问题^[10]。在训练中, 反向传播或随机梯度算法中梯度逐渐变得非常小, 甚至趋近于零, 从而导致网络的参数难以得到有效更新, 尤其是在深层网络中更为显著。

受人工智能大模型的启发^[11], 如何将文献 [9] 中的多状态模型进行进一步优化设计, 在单次训练后广泛适应多种工作状态是本文的研究重点。本文提出了一种新的面向 TWTA 的多状态行为表征方法, 该方法在隐藏层之间增加了跳跃连接, 使得当神经网络的深度较大时, 网络的精度不会降低。此外, 通过对 TWTA 的不同状态进行向量编码, 只需一次训练即可构建具有出色泛化能力的广义行为模型。

1 TWTA 多状态分析

TWTA 应用于星载平台, 承担中继、数传、通信等系统的微波功率放大作用, 其输出信号受到输入端激励信号的频率带宽及幅度、电源供电和温度变化等因素的影响, 输出信号的幅度、相位、非线性特性等都随之变化。表 1 为一款 K 频段 TWTA 的典型参数, 在接近饱和区域的非线性特性恶化较快, 饱和和工作点 AM/PM 达到 4.5°/dB。

TWTA 的工作温度对行波管及行波管电源均有影响。温度的变化影响行波管高频慢波系统的结构状态、永磁聚焦系统的磁场强度, 导致行波管饱和和工作点、输出信号功率、相位、群时延等参数发生变化。同时, 行波管电源中的元器件受温度影

响, 造成电源输出的高压电压发生偏离, 电源纹波变大, 其作用于行波管后带来输出信号幅度和相位的变化。星载平台关注的 TWTA 工作温度范围为 $-20^{\circ}\text{C} \sim +60^{\circ}\text{C}$, AM/AM、AM/PM 曲线如图 1、图 2 所示。环境温度变化带来 TWTA 的饱和和工作点发生 ± 1 dB 平移, AM/AM 曲线在饱和区变化约 0.25 dB、线性区 (输入功率相对饱和和工作点回退 6 dB 以上) 变化超过 0.7 dB, AM/PM 曲线变化约 17° 。

表 1 K 频段 TWTA 典型参数

性能参数	参数值
频带范围/GHz	19~21
饱和输出功率/W	≥ 65
饱和增益/dB	≥ 50
三阶交调/dBc	≥ 9.5
相移/ $^{\circ}$	≤ 48
幅相转换系数/ $(^{\circ}\cdot\text{dB}^{-1})$	≤ 4.5




图 1 TWTA 在不同温度条件下的 AM/AM 曲线




图 2 TWTA 在不同温度条件下的 AM/PM 曲线

为满足星载链路线性度要求, 通常设置 TWTA 工作在输出功率回退 2~3 dB 状态, 此时输入功率相对饱和和激励回退 6 dB 左右, TWTA 处于近似线性增益状态。从图 3 可以看出, 随着激励信号频率变化, 相同输入激励条件下 TWTA 输出功

率在工作频带范围内均变化约 1.2 dB (约 13 W), 信号频率对 TWTA 输出状态影响明显。

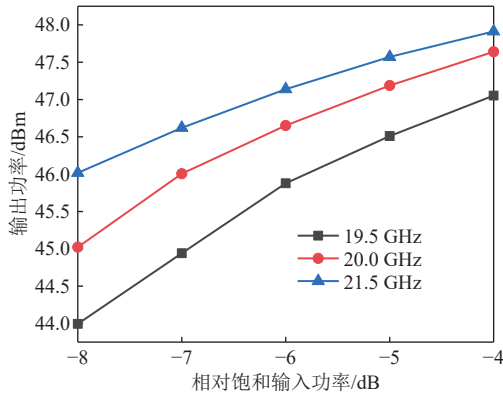


图 3 TWTA 在不同输入频率激励时的 AM/AM 曲线

将 TWTA 的输入信号幅度、工作温度环境作为数字预失真状态参数, 开展多状态行为模型的建模。输入信号带宽为 60 MHz, 信号频率选取 19.5~20.5 GHz, 状态步进为 0.5 GHz; 工作温度设置为 -20℃~+60℃, 考察星载条件的温度区

间。TWTA 多状态配置如表 2 所示。

表 2 TWTA 多状态配置

f/GHz	工作温度/℃					
	-20	-10	0	10	30	60
19.5	S1	S2	S3	S4	S5	S6
20.0	S7	S8	S9	S10	S11	S12
20.5	S13	S14	S15	S16	S17	S18

2 TWTA 多状态神经网络模型

为了解决增加网络层数后出现的退化问题, 本文引入跳跃连接的深度神经网络模型来构建 TWTA 模型。同时, 为了使模型能够适应大量复杂的状态, 如输入信号幅度、信号功率电平、工作温度, 本文将提取不同状态类别的特征并对特征值进行预处理, 将其添加到输入数据中, 然后加深模型的层数, 并最终构建一个能够适应多状态的模型。图 4 显示了 TWTA 多状态模型的各个实现模块, 下面将对每个模块进行详细描述。

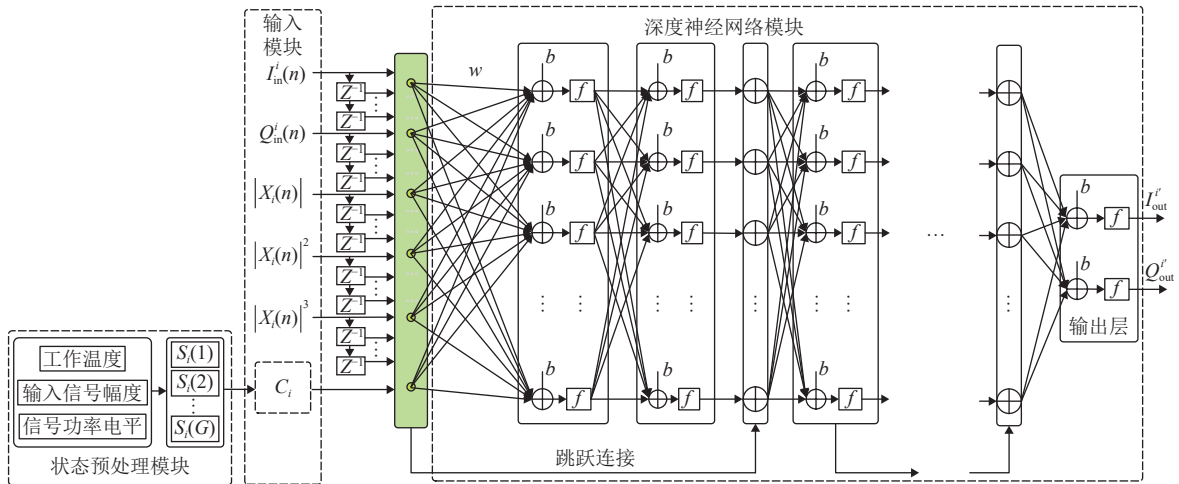


图 4 TWTA 多状态神经网络框图

2.1 状态预处理模块

为了识别 TWTA 的多种工作状态, 提取了不同 TWTA 状态的不同特征。首先, 对特征值的量级进行归一化, 使其与输入项处于同一数量级, 提高了 TWTA 模型的识别精度, 同时归一化可以提高“状态值的密度”, 增强模型的泛化能力。然后将预处理后的状态值拼接成状态向量, 以表征 TWTA 的不同状态, 状态预处理模块得到的状态向量为:

$$C_i = [S_i(1), S_i(2), \dots, S_i(G)] \quad i = 1, 2, \dots, N_s \quad (1)$$

式中, S_i 为表征状态特征的预处理值向量; N_s 为状

态总数; G 为状态要素的类别总数。

2.2 输入模块

输入数据由两部分组成: 1) TWTA 输入信号 X_i 的 I/Q 分量、当前时刻的包络项和 I/Q 分量以及最后时刻的包络项; 2) 状态预处理模块得到的表示该 TWTA 状态的状态向量。输入数据为:

$$X_i^{\text{input}} = [X_i^{\text{PA}}, C_i] \quad i = 1, 2, \dots, N_s \quad (2)$$

$$X_i^{\text{PA}}(n) = [I_{\text{in}}^i(n), Q_{\text{in}}^i(n), |X_i(n)|, |X_i(n)|^2, |X_i(n)|^3, I_{\text{in}}^i(n-1), Q_{\text{in}}^i(n-1), \dots, |X_i(n-M)|^3] \quad n = 1, 2, \dots, N_t \quad (3)$$

式中, X_i^{input} 表示输入数据; X_i^{PA} 包含输入数据的前两部分; C_i 表示状态向量; $I_{\text{in}}^i(n)$ 和 $Q_{\text{in}}^i(n)$ 表示时刻 n 的输入信号 I/Q 分量; $|X_i(n)|$ 表示输入信号的复包络 $X_i(n)$ 的幅度; $I_{\text{in}}^i(n-m)$ 、 $Q_{\text{in}}^i(n-m)$ 和 $|X_i(n-m)|$ 表示 $n-m$ ($m=1,2,\dots,M$) 时刻输入信号的 I/Q 分量和包络幅度; M 为记忆深度; X_i^{PA} 的数据项为 $5M+5$; N_i 为样本数。模型的输出数据表示为:

$$Y_i = [I_{\text{out}}^i, Q_{\text{out}}^i] \quad (4)$$

式中, Y_i 为功放输出信号; I_{out}^i 和 Q_{out}^i 输出信号的 I/Q 分量。

2.3 深度神经网络模块

使用引入跳跃连接的深度神经网络来构建 TWTA 模型, 如图 4 所示, 该模型由 $2(L-1)$ 层隐藏层和输出层组成, 对每一个全连接块, 即每经过两层全连接层, 就将第一层的输入和第二层的输出相加, 即跳跃连接, 从而作为这两层的输出进入下一层。因此, 第 k 层引入跳跃连接的全连接块的输出可以表示为:

$$a_k = \tanh(w_{2k}^T \tanh(w_{1k}^T \cdot a_{k-1} + b_{1k}) + b_{2k}) + a_{k-1} \quad (5)$$

$$k = 1, 2, \dots, L-1$$

式中, w_{1k}^T 、 w_{2k}^T 和 b_{1k} 、 b_{2k} 为 k 阶全连接块中两层全连接层的权重和偏置; a_{k-1} 和 a_k 为全连接模块的输入和输出; a_0 为 $k=0$ 时的输入数据 X_i^{input} 。通过跳跃连接, 网络更容易学习到恒能映射, 即将输入的信息直接传递到输出, 从而避免梯度减小的问题, 同时, 在反向传播过程中, 由于存在跳跃连接, 梯度可以更直接地流向较早的层, 避免了在传播过程中梯度过小而导致的梯度消失问题。这样, 即使网络非常深, 也能更有效地进行训练。由于全连接层的输出需要叠加至输入, 输入和输出的维度应保持一致, 即 $k=1, 2, \dots, L-1$, a_k 与 X_i^{input} 的维度相同。每一层隐藏层中的全连接层的神经元数量与 X_i^{input} 的行数相同, 即 $5M+5+G$ 个。全连接层的激活函数为“tanh”。由于该模型的目标是预测所获得的 TWTA 输出信号的 I/Q 分量, 因此输出层由两个神经元组成, 输出可以表示为:

$$Y_i^{\text{pred}} = f_o(w_o^T \cdot a_{L-1} + b_o) = [I_{\text{out}}^i, Q_{\text{out}}^i] \quad (6)$$

式中, w_o^T 和 b_o 为输出层的权重和偏置; $f_o(\cdot)$ 为输出层的激活函数; Y_i^{pred} 为模型预测的输出; I_{out}^i 和 Q_{out}^i 为响应的 I/Q 分量。

综上所述, 通过状态预处理模块和输入数据模块, 可以将包含大量 TWTA 状态的数据, 在具有非常深层的全连接模块中进行训练, 使用均方误差 MSE (mean square error) 作为代价函数, 使用 Adam (adaptive moment estimation) 算法作为参数更新算法。Adam 是一种常用的优化算法, 用于训练神经网络和深度学习模型。它结合了动量法和自适应学习率的思想, 旨在提高梯度下降的效率, 并对学习率进行自适应调整。Adam 算法的优点在于它能自适应地调整学习率, 并结合了动量的思想, 使得在不同方向上的梯度更新更加平稳, 有助于加速收敛。因此, 最终可以得到一个足以适应大量 TWTA 状态、精度更高的 TWTA 多状态深度神经网络模型。该模型的建模算法如下。

算法: 多种状态的 TWTA 建模

- 1) 确定每个模块的参数和结构;
- 2) 确定要表征的 TWTA 状态, 并获得与每种状态相对应的 TWTA 输入 X_i 和预期输出 Y_i ;
- 3) 确定 MSE 作为成本函数, 将 Adam 确定为优化算法。

输入处理:

- 1) 对 TWTA 多种状态的差异特性进行预处理, 得到状态向量 C_i ;
- 2) 从每个状态的 X_i^{PA} 和 C_i 获取模型输入项 X_i^{input} 。

TWTA 建模:

- 1) 使用引入跳跃连接的深度神经网络作为 TWTA 模型;
- 2) 使用输入项 X_i^{input} 训练模型:
 1. 获得模型输出;
 2. 评估成本函数;
 3. 如果满足性能要求, 则退出循环, 否则继续;
 4. 更新模型系数。

3 实验结果

为了验证该方法的有效性, 本文搭建了一个测试平台, 如图 5 所示。该平台包括 1 台 PC、1 个信号发生器、1 个直流电源、1 个 TWTA、1 个定向耦合器和 1 个频谱分析仪, 其中 TWTA 工作参数如表 1 所示。为了获得指示 TWTA 不同状态的数据, 激励信号 PAPR 为 9.09 dB, 频率为 19.5 GHz、20.0 GHz 和 20.5 GHz, 温度为 -20°C 、 -10°C 、 0°C 、 $+10^\circ\text{C}$ 、 $+30^\circ\text{C}$ 和 $+60^\circ\text{C}$ 。因此, 考虑

信号功率电平和温度带来不同的 TWTA 状态, 状态数 N 为 18 ($3 \times 6 = 18$), 类别数 G 为 2。在实验中, 本文提出的 TWTA 多状态模型的参数设置如下, 记忆深度为 3, 则输入项数量为 22, 因此隐藏层中的神经元数量也为 22。作为对照, 使用相同的数据训练具有相同参数的嵌入式单向量的普通多态深度神经网络模型^[9], 且这两个模型都只预训练一次。

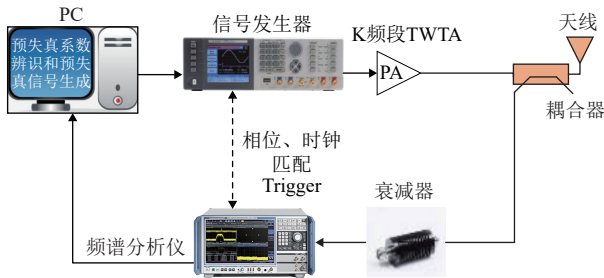


图 5 K 频段 TWTA 数字预失真测试平台

图 6 从 18 个状态中取出 1 个状态 S16[20.5 GHz, 10 °C], 并测试了 TWTA 多状态模型和普通多状态模型在该状态下每增加 10 层隐藏层数的性能。可以看出, 普通多状态模型的归一化均方误差 NMSE (normalized mean square error) 性能随着隐藏层数的增加而逐渐变差, 层数为 30 时 NMSE 仅为 -34.7 dB, 但当层数增加到 40 层后, NMSE 变异为接近 0 dB, 出现梯度消失现象, 使得普通多状态模型在需要更深层次建模的情况下无法满足 TWTA 建模的要求。相反, 当 TWTA 多状态模型的隐藏层层数从 10 层增加到 40 层时, NMSE 从 -38.3 dB 变为 -38.6 dB, 并且没有性能下降和梯度

消失, 这表明该模型在深度建模中仍然取得了优异的建模性能。同时, 当层数相同时, TWTA 多状态模型的 NMSE 性能优于普通多状态模型的 NMSE 性能。




图 6 不同隐藏层数的模型性能

在需要对大量状态进行深度建模的情况下, 对相同层数的 30 层 TWTA 多状态模型和普通多状态模型进行预训练, 表 3、表 4 比较了预训练完成后两个模型对每种状态的 NMSE 性能。可以看出, 此时普通多状态模型对多种状态的适应能力不好, 18 种训练状态中没有有一个状态优于 -35 dB, 相比之下, TWTA 多状态模型在 18 种状态下均优于 -35 dB, 实现了出色的多状态广义建模。同时, 30 层下 TWTA 多状态模型在状态 [20.5 GHz, 10 °C] 下的 DPD 补偿效果如图 7 所示, 将失真的 PA 输出的邻道功率比 ACPR (adjacent channel power ratio) 从 [-34.42, -33.04] 优化至 [-46.72, -46.76], 表明了 DPD 性能表现良好。

表 3 TWTA 多状态模型的 NMSE 性能

f/GHz	工作温度/°C					
	-20	-10	0	10	30	60
19.5	-35.6	-35.7	-35.6	-37.2	-37.8	-35.3
20.0	-36.3	-37.1	-37.6	-38.3	-38.5	-37.8
20.5	-36.1	-35.6	-35.2	-38.2	-36.1	-36.5

表 4 普通多状态模型的 NMSE 性能

f/GHz	工作温度/°C					
	-20	-10	0	10	30	60
19.5	-31.6	-30.6	-30.2	-33.8	-34.3	-34.0
20.0	-33.5	-33.0	-34.9	-34.5	-30.7	-34.8
20.5	-33.3	-34.6	-34.2	-34.7	-33.1	-34.5

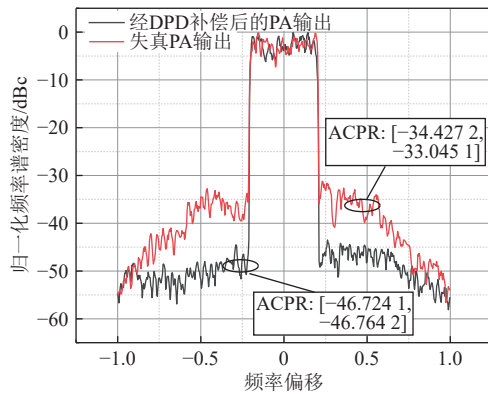


图 7 [20.5 GHz, 10 °C] 时 DPD 技术性能

4 结束语

本文提出了一种新的面向 TWTA 放大器的建模方法, 根据状态特征对状态向量进行预处理, 在训练数据中引入嵌入向量, 在深度神经网络中引入跳跃连接, 最终构建面向 TWTA 的深度多状态 TWTA 模型。此模型明显优于普通多状态 DNN 模型, 可以提供出色的建模性能。

参考文献

- [1] 杨瑜, 曾辉, 朱维, 等. 数字预失真技术对行波管发射机信号质量的影响研究[J]. 电子科技大学学报, 2021, 50(5): 697-702.
YANG Y, ZENG H, ZHU W, et al. Study on the effect of digital predistortion on signal quality of travelling-wave tube transmitter[J]. Journal of University of Electronic Science and Technology of China, 2021, 50(5): 697-702.
- [2] GHANNOUCHI F M, HAMMI O. Behavioral modeling and predistortion[J]. IEEE Microwave Magazine, 2009, 10(7): 52-64.
- [3] HU X, LIU T, LIU Z J, et al. A novel single feedback architecture with time-interleaved sampling for multi-band DPD[J]. IEEE Communications Letters, 2019, 23(6): 1033-1036.
- [4] 刘昕, 陈文华, 吴汇波, 等. 功放数字预失真线性化技术发展趋势与挑战[J]. 中国科学(信息科学), 2022, 52(4): 569-595.
LIU X, CHEN W H, WU H B, et al. Digital predistortion: Development trends and key techniques[J]. Scientia Sinica (Informationis), 2022, 52(4): 569-595.
- [5] 辜文婷, 熊洁, 刘钊, 等. 预失真技术在 Ka 频段行波管上的应用[J]. 真空电子技术, 2019(2): 40-42.
GU W T, XIONG J, LIU Z, et al. Application of predistortion technology in ka-band TWTs[J]. Vacuum Electronics, 2019(2): 40-42.
- [6] GUO Y, YU C, ZHU A D. Power adaptive digital predistortion for RF power amplifiers[C]//Proceedings of the IEEE MTT-S International Microwave Symposium. New York: IEEE, 2014: 1-3.
- [7] 刘发林, 张牵牵, 王俊森, 等. 基于机器学习的数字预失真进展[J]. 微波学报, 2023, 39(5): 62-69.
LIU F L, ZHANG Q Q, WANG J S, et al. Recent progresses in digital predistortion based on machine learning[J]. Journal of Microwaves, 2023, 39(5): 62-69.
- [8] HU X, LIU Z J, YU X F, et al. Convolutional neural network for behavioral modeling and predistortion of wideband power amplifiers[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(8): 3923-3937.
- [9] HU X, XIE S B, JI X, et al. Behavioral model with multiple states based on deep neural network for power amplifiers[J]. IEEE Microwave and Wireless Components Letters, 2022, 32(11): 1363-1366.
- [10] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2016: 770-778.
- [11] DONG X F, ZHANG X Q, ZHANG D, et al. A survey of research progress and theory foundation in large model[C]//Proceedings of the IEEE 8th International Conference on Cloud Computing and Intelligent Systems. New York: IEEE, 2022: 451-455.

编辑 叶芳