

# GFDM 中基于高阶长短时记忆神经网络的自适应均衡器 \*

牛安东<sup>1,2</sup>,苗硕<sup>1,2</sup>,刘佳宁<sup>1,2</sup>,李英善<sup>1,2</sup>

(1.南开大学 电子信息与光学工程学院,天津 300350;2.南开大学 光电传感器与传感网络技术重点实验室,天津 300350)

**摘要:**在广义频分复用系统(GFDM)中,为解决5G网络下车载移动通信在Sub-6 GHz频段信道中信号严重失真的问题,提出一种基于高阶长短时记忆神经网络(HO-LSTM)结构的自适应均衡器。HO-LSTM自适应均衡器在传统高阶前馈神经网络(HO-FNN)的基础上,采用复杂度更低的广义记忆多项式模型(GMP)代替Volterra模型,并引入LSTM神经网络使其更适用于复杂非线性模型的预测。结果表明,相比于传统HO-FNN均衡器和LSTM均衡器,所提出的HO-LSTM均衡器的均衡效果显著提升,系统性能也得到进一步改善。

**关键词:**广义频分复用技术;长短时记忆神经网络;高阶神经网络;广义记忆多项式

中图分类号: TN911.7

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.212382

中文引用格式:牛安东,苗硕,刘佳宁,等. GFDM 中基于高阶长短时记忆神经网络的自适应均衡器[J]. 电子技术应用, 2022, 48(8): 95–100.

英文引用格式: Niu Andong, Miao Shuo, Liu Jianing, et al. An adaptive equalizer based on high order LSTM in GFDM[J]. Application of Electronic Technique, 2022, 48(8): 95–100.

## An adaptive equalizer based on high order LSTM in GFDM

Niu Andong<sup>1,2</sup>, Miao Shuo<sup>1,2</sup>, Liu Jianing<sup>1,2</sup>, Li Yingshan<sup>1,2</sup>

(1. College of Electronic Information and Optical Engineering, Nankai University, Tianjin 300350, China;

2. Tianjin Key Laboratory of Optoelectronic Sensor and Sensing Network Technology, Nankai University, Tianjin 300350, China)

**Abstract:** In the generalized frequency division multiplexing system (GFDM), in order to solve the problem of severe signal distortion in the sub-6 GHz frequency band channel of the vehicle-mounted mobile communication under the 5G network, an adaptive equalizer based on high order long short-term memory (HO-LSTM) neural network structure is proposed. Based on the traditional high-order feedforward neural network (HO-FNN), HO-LSTM adaptive equalizer uses the generalized memory polynomial model (GMP) with lower complexity instead of Volterra model, and introduces LSTM neural network to make it more suitable for the prediction of complex nonlinear models. The results show that, compared with the traditional HO-FNN equalizer and LSTM equalizer, the equalization effect of the proposed HO-LSTM equalizer is significantly improved, and the system performance is further improved.

**Key words:** generalized frequency division multiplexing(GFDM); long short-term memory(LSTM); high order neural network; generalized memory polynomial(GMP)

## 0 引言

近年来,第五代移动通信技术(5th Generation Mobile Communication Technology, 5G)受到了极大的关注。广义频分复用技术(Generalized Frequency Division Multiplexing, GFDM)作为5G候选波形,由于其能够有效地克服码间干扰,让依赖于超可靠低时延通信的车联网等业务从中受益<sup>[1]</sup>。在中国工信部出台的针对5G通信规划中,将Sub-6 GHz频段作为商用频段。相比于第四代移动通信(4th Generation Mobile Communication Technology, 4G)中1.8 GHz~2.7 GHz的低频段信道,Sub-6 GHz的高频段信

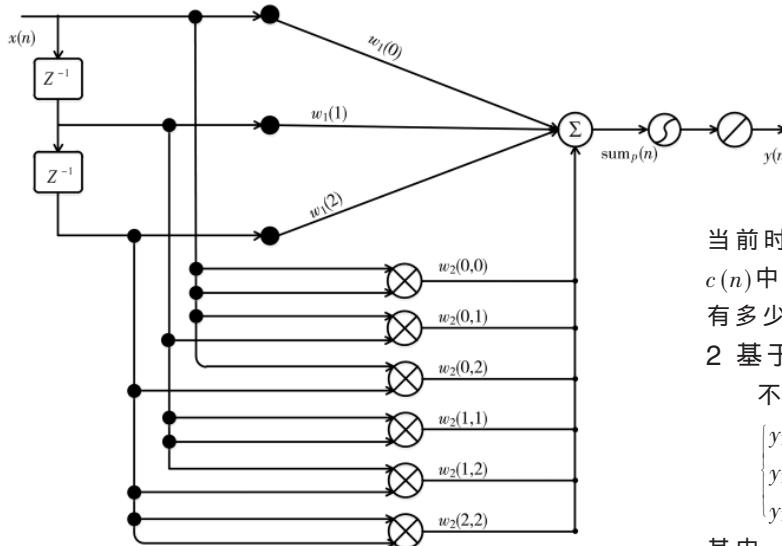
道导致的信号失真会更加严重<sup>[2]</sup>。

目前接收端均衡技术是提高通信质量的有效方法之一,传统的均衡器分为线性均衡器和非线性均衡器两种类型。其中非线性均衡器通常有两种常用的设计方式:基于Volterra滤波器的方法<sup>[3-4]</sup>和基于神经网络的方法<sup>[5-7]</sup>。

其中神经网络由于其极强的非线性拟合能力在信道均衡领域吸引了很多关注<sup>[6]</sup>。传统的前馈神经网络在均衡器设计中已经广泛应用。Marmarelis和Zhao提出了基于Volterra级数的高阶前馈神经网络模型,将Volterra多项式与前馈神经网络结合起来<sup>[8]</sup>,高阶前馈神经网络相较于传统的前馈神经网络提高了建模精度。最近的研

\* 基金项目:国家自然科学基金项目(62171239)



图 3  $M=2, P=2$  的 HONN 均衡器模型

其中,  $\phi$  为 Sigmoid 函数, 是最常见的隐藏层激活函数之一, 它被定义为:

$$\phi(x) = \frac{1}{1+e^{-x}} \quad (10)$$

该神经网络的权重训练过程采用广义 delta 规则<sup>[16]</sup>。

基于 Volterra 模型的高阶前馈神经网络的缺点之一是随着记忆深度和阶数的增加, 计算复杂度呈指数级增大, 同时, 由于高阶前馈神经网络不能利用输出的历史信息, 而其更倾向于记住训练数据, 从而不能从给定的训练数据中学习规则。

### 1.3.2 循环神经网络均衡器

循环神经网络是一种将神经元定向连接成环的反馈式神经网络, 其内部状态可以展示动态时序行为。长短时记忆神经网络(Long Short-Term Memory, LSTM)是循环神经网络的一种特殊类型, 也是目前最常用的实现循环神经网络的网络结构。LSTM 网络结构如图 4 所示<sup>[17]</sup>。

图 4 中,  $c$  表示单元状态, 用来存储长期记忆;  $h$  表示当前输出状态, 用来输出瞬时记忆。LSTM 网络用两个门函数来控制单元状态  $c$  的内容, 一个是遗忘门, 用来决定上一个时刻的单元状态  $c(n-1)$  有多少可以保留到当前的单元状态  $c(n)$ ; 另一个是输入门, 它决定了当前时刻网络的输入  $x(n)$  有多少可以存储到单元状态  $c(n)$  中。最后 LSTM 网络用输出门来控制单元状态  $c(n)$  有多少可以输出到 LSTM 网络的当前输出值  $h(n)$ 。

### 2 基于高阶长短时记忆神经网络的均衡器设计

不同神经网络结构下的输出如式(11)所示:

$$\begin{cases} y_{\text{FNN}}[n] = \varphi_{\text{FNN}}(\omega_F x[n]) \\ y_{\text{LSTM}}[n] = \varphi_{\text{LSTM}}(\omega_R x[n] + \omega_O y[n-1]) \\ y_{\text{HO-FNN}}[n] = \varphi_{\text{HO-FNN}}(\text{sum}_p(n)) \end{cases} \quad (11)$$

其中,  $\varphi_{\text{FNN}}(\cdot)$ 、 $\varphi_{\text{LSTM}}(\cdot)$  和  $\varphi_{\text{HO-FNN}}(\cdot)$  表示隐藏层的激活函数,  $x(n)$  表示神经网络的输入,  $\omega_F$ 、 $\omega_R$ 、 $\omega_O$  分别表示相应的权重,  $\text{sum}_p(n)$  表示经过 Volterra 多项式变换后的信号。

与前馈神经网络(FNN)相比, 长短时记忆神经网络(LSTM)和高阶前馈神经网络(HO-FNN)都适合于动态系统识别或时间序列预测。LSTM 仅使用线性输入和一阶反馈项, 因此不能利用输入的高阶项。而 HO-FNN 则不能利用输出的历史时刻。因此, 为了弥补以上 3 种神经网络结构的缺点, 本文提出基于 GMP 的高阶长短时记忆神经网络(HO-LSTM)均衡器。

为了降低 Volterra 多项式的复杂度, 研究人员提出了记忆多项式(Memory Polynomial, MP)模型, 该模型只保留了 Volterra 多项式的对角项, 极大地减少了模型系数, 因此记忆多项式更适用于构建非线性行为较弱的模型。但由于其缺少交叉项, MP 模型无法对引起码间干扰的多径信道进行建模, 因此研究人员在记忆多项式的基础上增加了交叉项, 提出了 GMP 模型, 可以有效解决码间干扰问题, 并且在提高建模精度的同时计算量不会随着

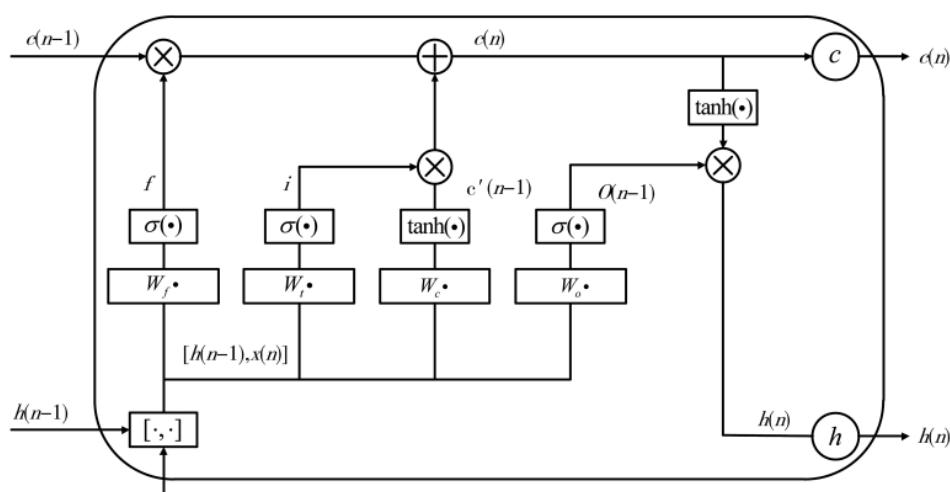


图 4 LSTM 网络结构

记忆深度和阶数的增加而急速上升。

因此本文采用 GMP 模型进行建模。GMP 模型如下所示<sup>[18]</sup>:

$$\begin{aligned} y_{\text{GMP}}(n) = & \sum_{p=0}^{P-1} \sum_{m=0}^{M-1} a_{pm} x(n-m) |x(n-m)|^p \\ & + \sum_{p=1}^{P-1} \sum_{m=0}^{M-1} \sum_{l=1}^L b_{pml} x(n-m) |x(n-m-l)|^p \end{aligned} \quad (12)$$

其中,  $P$ 、 $M$  分别是记忆多项式的阶数和前向记忆深度,  $L$  是滞后记忆深度。

图 5 为 HO-LSTM 自适应均衡器结构及其训练算法原理。GMP 中网络模型的记忆深度为  $M_1$ , 滞后记忆深度为  $L_1$ , 阶数为  $P$ 。其中  $x(n)$  表示神经网络的输入, 令  $z_h(n)$  为第  $h$  个隐藏层神经元的输出, 则输入  $x(n)$  与隐藏层输出  $z_h(n)$  的关系由下式给出:

$$\begin{aligned} \text{sum}_{p,\text{HO-LSTM}}(n) = & \sum_{m=0}^{M-1} A_m x(n-m) + \\ & \sum_{p=1}^{P-1} \sum_{m=0}^{M-1} \sum_{l=0}^L B_{pml} x(n-m) |x(n-m-l)|^p + \sum_{j=1}^{M_1-1} C_j z_h(n-j) \end{aligned} \quad (13)$$

$$z_h(n) = \varphi \left( \sum_{p=0}^P \text{sum}_{p,\text{HO-LSTM}}(n) \right) \quad (14)$$

式中,  $\varphi(\cdot)$  表示隐藏层的激活函数,  $A_m$  表示前馈部分的权重系数,  $B_{pml}$  表示 GMP 模型每个展开项的权重系数,  $M_1$  表示反馈部分的记忆深度,  $C_j$  表示反馈部分的权重系数。神经网络的输出  $y(n)$  可表示为:

$$y(n) = v \left( \sum_{h=1}^H O_h z_h(n) \right) \quad (15)$$

式中,  $v(\cdot)$  表示从隐藏层到输出层的传递函数,  $O_h$  表示输出层的权重系数。

本文采用反向传播算法<sup>[17]</sup>训练神经网络, 其中  $d(n)$  是训练数据的参考输出。

表 1 列出了不同多项式的实值乘法计算量, 其中

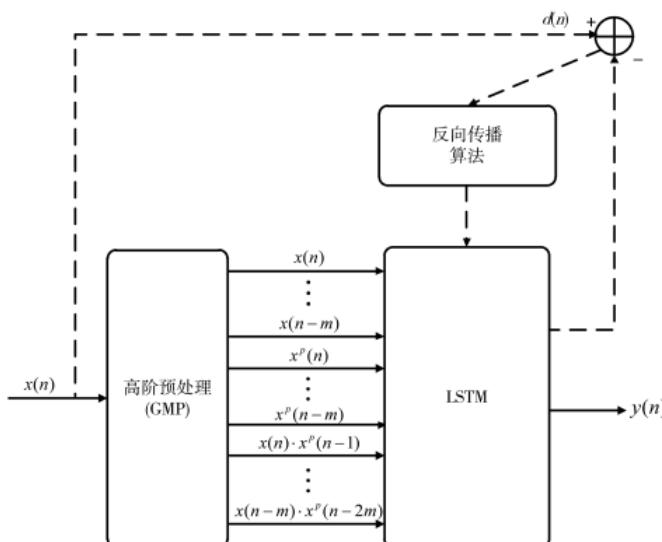


图 5 HO-LSTM 自适应均衡器结构及其训练算法原理

表 1 模型复杂度对比

模型	乘法计算量	系数数量 ( $M=5, P=3$ )
Volterra	$\sum_{p=1}^{P+1/2} M^{2p-1} \cdot (4P-1)$	190
MP	$P(M+1)$	18
GMP	$(M+1)(P+2MP-2M)$	138

$M=M_1+L_1$ 。可以看出 GMP 模型的计算复杂度相比于 Volterra 模型有所下降。

### 3 实验结果与分析

为证明所提出的 HO-LSTM 自适应均衡器在 GFDM 系统环境下对复杂多径莱斯信道的均衡效果, 本文进行大量的仿真实验。GFDM 信号的仿真参数如下: 载波数  $K=64$ , 每个子载波符号数为 15, 每个字符的样本数  $K_{\text{on}}=64$ , 调制方式为 16QAM。

为模拟 Sub-6 GHz 频段中车联网在乡村视距(Rural Line of Sight, RLOS)无线传输环境下的信道环境, 莱斯信道的仿真参数为: 散射路径数目  $L=2$ , 直射路径的多普勒频移  $f_d=800$  Hz, 莱斯因子  $K_r=10$ , 两条散射路径时延  $\tau_l$  分别为 83 ns、183 ns, 直射路径的功率为 1 dBm, 两条散射路径平均功率  $P_l$  分别为 -14 dBm、-10 dBm, 两条散射路径多普勒频偏  $f_{dl}$  分别为 492 Hz、-295 Hz。

实验中, GFDM 系统随机生成 2 928 个发射数据用来训练均衡器的参数, 另外产生 1 464 000 个数据用于测试该均衡器的性能。表 2 列出了不同神经网络均衡方案的仿真参数。

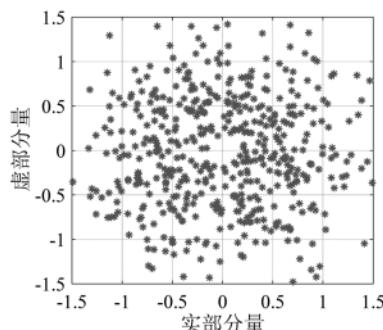
表 2 各均衡器参数说明

均衡器	前向抽头数量	阶数	隐藏层神经元个数	输出层神经元个数	学习率
HONN	6	2	50	2	0.005
LSTM	6	0	40	2	0.005
HO-LSTM	6	2	40	2	0.005

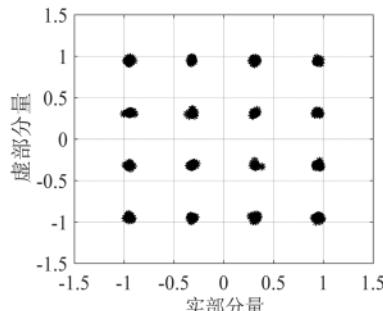
图 6 为 GFDM 系统发射信号在不同信道环境影响下的 16QAM 星座图。从图 6(a)中可以看出, 发射信号在经过 RLOS 信道后星座点扩散十分严重。

图 7 展示了不同神经网络自适应均衡器方案对信道均衡之后的星座图。可以看出, 文献[15]提出的高阶前馈神经网络均衡器在 GFDM 系统里对 RLOS 信道的均衡效果很差, 文献[17]提出的 LSTM 自适应均衡器对 RLOS 信道有一定的均衡效果, 而本文提出的 HO-LSTM 均衡方案与文献[15]和[17]里的均衡器相比均衡效果显著提高。

为进一步研究各均衡方案对系统的传输可靠性, 通过测试 1 464 000 个数据得到了每个方案的误比特率(Bit Error Rate, BER)性能曲线, 结果如图 8 所示。从图中可以观察到,  $\text{SNR}=15$  dB 时, HO-LSTM 均衡方案的 BER 在  $10^{-4}$  以下, LSTM 均衡方案、HO-FNN 均衡方案<sup>[15]</sup>以及 ZF 均衡方案<sup>[19]</sup>的 BER 均高于  $10^{-2}$ 。



(a) RLOS+AWGN 信道



(b) 只有 AWGN 信道

图 6 SNR=25 dB 时 16QAM 星座图

此外,本实验还研究了 LSTM 和 HO-LSTM 均衡器方案的学习曲线。均方误差(Mean Square Error, MSE)是描述神经网络的学习能力随迭代次数而变化的重要指标,MSE 定义为:

$$MSE = \frac{1}{I} \sum_{i=1}^I (y_i - \hat{y}_i)^2 \quad (16)$$

图 9 绘制了 SNR=25 dB 时随均衡算法迭代次数的 MSE 曲线,可以看出 HO-LSTM 的收敛速度比 LSTM 均衡方案更快。

#### 4 结论

为解决 GFDM 系统中车载无线通信在 Sub-6 GHz 频段信道中的失真问题,本文提出一种基于高阶长短时记忆神经网络(HO-LSTM)的自适应均衡器设计方案。该均衡方案使用长短时记忆神经网络(LSTM)来预测复杂

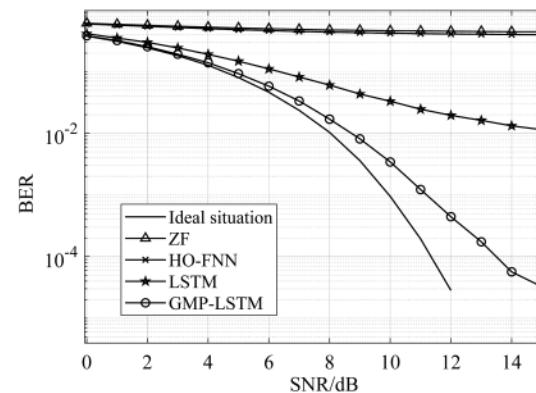


图 8 各均衡器方案 BER 率性能对比

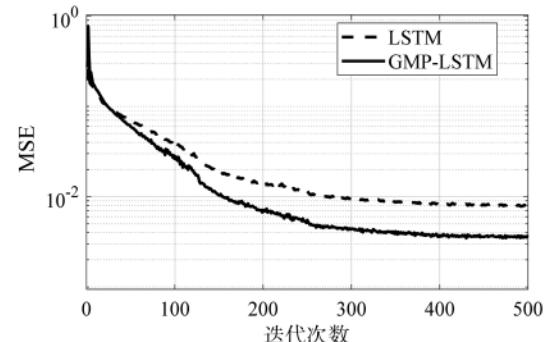
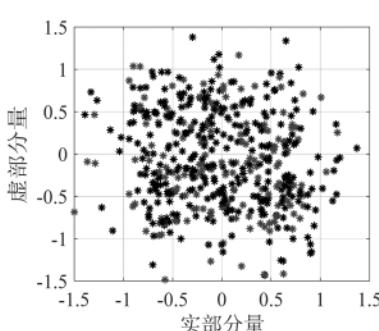


图 9 各均衡方案的 MSE 学习曲线 (SNR=25 dB)

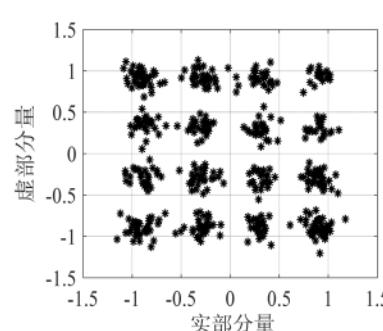
非线性模型,并引用 GMP 模型设计 LSTM 神经网络的输入项,使均衡器能够更好地适应 5G 系统中复杂信道环境的变化。本文通过大量实验将 HO-LSTM 均衡方案、LSTM 均衡方案以及 HO-FNN 均衡方案进行比较。结果表明,HO-LSTM 自适应均衡器面对复杂信道的均衡效果与 HONN 和 LSTM 模型相比有显著提升。虽然,HO-LSTM 模型相比于 LSTM 模型复杂度有所提升,但是从实验结果来看,牺牲一定的复杂度来提升系统性能是可取的。

#### 参考文献

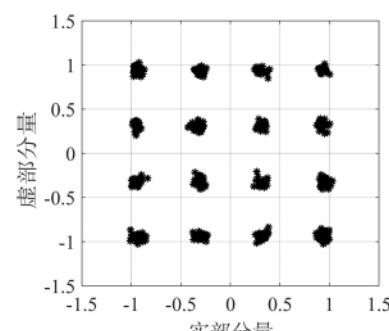
- [1] BANDARI S K, MANI V V, DROSOPoulos A. GFDM/OQAM implementation under Rician fading channel[C]//International



(a) HO-FNN



(b) LSTM



(c) HO-LSTM

图 7 SNR=25 dB 时均衡后的 16QAM 星座图

- Conference on Advances in Computing.Jaipur, India : IEEE , 2016 : 256–260.
- [2] 齐航, 刘玮, 任治冰, 等. Sub 6GHz 频段无线传播特性研究[J]. 移动通信, 2019, 43(2): 19–24, 32.
- [3] GUTIERREZ A, RYAN W E. Performance of adaptive volterra equalizers on nonlinear satellite channels[C]//IEEE International Conference on Communications.Seattle, WA, USA : IEEE , 1995 : 488–492.
- [4] 赵知劲, 郑晓华, 沈雷. 一种基于格型滤波的二阶 Volterra 自适应均衡算法[J]. 电路与系统学报, 2010, 15(6): 11–15.
- [5] MOUSTAFA M, EL-RAMLY S. Channel estimation and equalization using backpropagation neural networks in OFDM systems[C]//2009 IFIP International Conference on Wireless and Optical Communications Networks, Cairo, Egypt : IEEE , 2009 : 1–4.
- [6] BURSE K, YADAV R N, SHRIVASTAVA S C. Channel equalization using neural networks: a review[J]. IEEE Transactions on Systems Man & Cybernetics Part C Applications & Reviews, 2010, 40(3): 352–357.
- [7] 蒋浩然. 基于神经网络的并行均衡技术研究与实现[D]. 成都: 电子科技大学, 2019.
- [8] MARMARELIS V Z, ZHAO X, et al. Volterra models and three-layer perceptrons[J]. IEEE Transactions on Neural Networks, 1997, 8(6): 1421–1433.
- [9] DASH S, DAS S R. Analysis of BER and MSE performance in nonlinear equalization using modified recurrent network[C]// IET Chennai Fourth International Conference on Sustainable Energy & Intelligent Systems.Chennai : IET , 2013 : 292–296.
- [10] LAVANIA S, KUMAM B, MATEY P S, et al. Adaptive channel equalization using recurrent neural network under SUI channel model[C]//2015 International Conference on Innovations in Information, Embedded and Communication Systems(ICIECS).Coimbatore, India : IEEE , 2015 : 1–6.
- [11] 张钟文. GFDM 通信系统信道估计技术的研究[D]. 大连: 大连海事大学, 2020.
- [12] PERMANA A K, HA MID E Y. DFT-based channel estimation for GFDM on multipath channels[C]//2018 10th International Conference on Information Technology and Electrical Engineering(ICITEE).Bali, Indonesia : IEEE , 2018 : 31–35.
- [13] 孙婷婷. 莱斯信道下大规模 MIMO 自适应传输及用户调度[D]. 南京: 东南大学, 2019.
- [14] 左凤丽. 高速移动环境下 OFDM 系统关键技术研究[D]. 西安: 西安电子科技大学, 2014.
- [15] REID M B, SPIRKOVSKA L, OCHOA E. Rapid training of higher-order neural networks for invariant pattern recognition[C]//International 1989 Joint Conference on Neural Networks.Washington, DC, USA : IEEE , 1994 : 689–692.
- [16] KIM P. MATLAB deep learning: with machine learning, neural networks and artificial intelligence[M]. Apress, 2017.
- [17] 朱亮亮. 高速移动无线信道建模与基于学习的自适应均衡[D]. 杭州: 浙江大学, 2019.
- [18] MORGAN D R, MA Z, KIM J, et al. A generalized memory polynomial model for digital predistortion of RF power amplifiers[J]. IEEE Transactions on Signal Processing, 2006, 54(10): 3852–3860.
- [19] 李戈. 60GHz 通信系统关键技术仿真[D]. 成都: 电子科技大学, 2013.

(收稿日期: 2021-11-26)

## 作者简介:

牛安东(1996-), 女, 硕士研究生, 主要研究方向: 无线通信。

苗硕(1996-), 男, 硕士研究生, 主要研究方向: 无线通信。

李英善(1972-), 通信作者, 女, 博士, 副教授, 主要研究方向: 宽带无线通信、通信信号处理, E-mail: yingsl1122@nankai.edu.cn。



扫码下载电子文档

(上接第 94 页)

- [4] 高嵩, 胥剑涛. 基于 FPGA 的相控阵天线波束控制算法优化研究[J]. 电子技术应用, 2021, 47(3): 82–85, 95.
- [5] 李鹏, 席虹标, 陈国帅. 基于 PLL 技术低相噪时钟信号光纤传输系统[J]. 大众科技, 2020, 22(5): 8–10, 13.
- [6] 邹波. 一种针对数字阵列雷达的光传输系统设计与实现[D]. 成都: 电子科技大学, 2014.
- [7] 王天亮. 毫米波信号光纤传输关键技术的研究[D]. 北京: 清华大学, 2010.
- [8] 张安旭, 孙亨利, 戴一堂, 等. 光纤时频传输及其在航天探测中的应用[J]. 无线电工程, 2016, 46(9): 15–19.
- [9] 石雄. 时间和频率信号的光纤稳定传输技术研究[D]. 上

海: 上海交通大学, 2007.

- [10] 郑学杰, 陈俊宇, 兰才伦, 等. 基于高精度光纤长度测试建立的高效 DWDM 光纤配相方法[J]. 中国新通信, 2021, 32(2): 63–64.
- [11] 吕菲, 韦文生, 雷敏, 等. 基于波分复用光纤传输的通信系统实验[J]. 实验室研究与探索, 2016, 35(3): 41–45.
- [12] 余浩国. 波光纤分复用系统的实验及其性能研究[J]. 电子世界, 2014(18): 203.

(收稿日期: 2022-05-18)

## 作者简介:

陈凌(1975-), 通信作者, 女, 硕士, 工程师, 主要研究方向: 航天测控系统, E-mail: 13568832652@163.com。



扫码下载电子文档

## 版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所