

一种基于改进 ResNet 的发射天线智能选择算法

李玉芳,陈 哲,徐凌伟

(青岛科技大学 信息科学技术学院,山东 青岛 266061)

摘 要 为满足移动用户数据传输的需求,大规模多输入多输出在 5G 通信系统中得到了广泛应用,在 N -Nakagami 衰落信道下,建立了移动多天线协作通信系统。为提高发射天线的选择准确率,提出一种基于改进 ResNet 的发射天线智能选择算法,可以获得更大的信道容量。改进的 ResNet 网络以残差结构为网络主体,利用 VGG 神经网络代替原始的卷积层。VGG 神经网络提取信道状态数据的信息特征,大大减少了浅层计算参数;丢弃池化机制以保护信息特征;重新构建三个残差模块结构以增强特征信息提取,提高发射天线的选择准确率,获得信道容量更佳的天线。与传统的天线选择算法相比,所提出的发射天线智能选择算法的准确率提升至 94.0%,具有较好的系统容量性能,且可以有效降低设备成本。

关键词 移动通信;协作通信;发射天线选择;改进的 ResNet 网络;

中图分类号 TN919.3

文献标识码 A

开放科学(资源服务)标识码 OSID)



Transmit Antenna Intelligent Selection Algorithm Based on Improved ResNet

LI Yufang, CHEN Zhe, XU Lingwei

(School of Information Science & Technology, Qingdao University of Science & Technology, Qingdao 266061, China)

Abstract In order to meet the needs of data transmission for mobile users, massive multi-input multi-output system has been widely used in 5th generation mobile communication technology systems. In this paper, a mobile multi-antenna cooperative communication system is established based on the N -Nakagami fading channel. To improve the transmit antenna selection accuracy, a transmit antenna intelligent selection algorithm based on improved ResNet is proposed, which can obtain the greater channel capacity. The improved ResNet network employs the residual structures as the main part and the VGG neural network to replace the original convolutional layers. Firstly, the VGG neural network is added to extract the information feature of channel state data, which greatly reduces the shallow computing parameters. Secondly, discarding pooling mechanism is to protect information characteristics. Thirdly, three residual module structures are reconstructed to enhance the extraction of information features, improve the accuracy of the selection, and obtain antennas with better channel capacity. Compared with the traditional antenna selection algorithms, the accuracy of the proposed intelligent transmit antenna selection algorithm is increased to 94.0%, which has better system capacity performance and can reduce equipment cost in an effective manner.

收稿日期: 2022-08-08

基金项目: 国家自然科学基金项目(61702295), 数字化学习技术集成与应用教育部工程研究中心创新基金项目(1221042)资助

通讯作者: 徐凌伟,男,汉族,博士,副教授,研究方向:智能信息与通信, E-mail: gaomilaojia2009@163.com。

Key words mobile communications; cooperative communication; transmitting antenna selection; improved ResNet network;

1 引言

作为新兴趋势之一的第五代移动通信技术迅猛崛起,影响着人类的生产与生活^[1]。作为通信行业的关键驱动者,可满足医疗、交通、物流、教育等多种服务需求^[2,3]。为提高通信质量,多输入多输出(Multiple input-multiple output, MIMO)系统凭借高频谱和高能量的优势,成为移动系统的关键技术,并且被纳入 5G 通信技术标准中^[4-7]。但是,用户天线数目的增加,多输入多输出系统需求大量的射频链路,计算复杂度与成本也随之提高^[8]。

发射天线选择技术(Transmitting antenna selection, TAS)可以保证通信系统性能的情况下,有效减少射频器的数量,得到一个良好的天线子集,降低 MIMO 通信系统的硬件费用和计算复杂度^[9,10]。传统天线选择方案计算复杂度较高,且通信系统的容量性能相对较低。文献[11]采用量子化学反应,提出了一种智能天线选择方法,解决了非线性、多约束的混合优化难题。文献[12]针对大规模 MIMO 发射天线选择算法,利用凸函数有效降低了系统的误码率。文献[13]所提出的天线选择算法不仅降低了计算复杂度还提升了安全容量。文献[14]提出了一种基于强化学习的天线选择算法,大大降低了系统的复杂度。文献[15]提出了低复杂度天线选择算法规避了传统天线选择算法的缺点。文献[16]用支持向量机(Support Vector Machine, SVM)和朴素贝叶斯(Naive Bayesian Model, NBM)两种方案进行天线选择,有效降低了反馈开销。文献[17]在窃听信道系统中分别采用 K 最邻近(K-NearestNeighbor, KNN)算法和逻辑回归算法(Logistic Regression, LR)选择具有最大保密性的天线,降低了训练时间。

近年来,深度学习已经广泛应用到移动通信系统中,解决了诸多通信难题。文献[18]利用深度学习的方法降低 MMO 系统中的训练开销。文献[19]为了有效减小误码率,实现了一种改进的卷积神经网络(Convolutional Neural Network, CNN)端到端自编码器通信系统。文献[20]所提出的复数卷积神经网络(Complex-Valued Convolutional Neural Network, CVCNN)有效降低了传统算法的信息损失。文献[21]结合双向长短期记忆神经网络和 CNN,有效提高了短波频率的预测精度。文献[22]利用卷积神经网络解决频谱资源紧缺的难题。文献[23]基于深度学习提出的方案达到近似最优算法的最佳安全能效的 96%。文献[24]基于神经网络建立了故障诊断算法,检测准确率达 97.5%。文献[25]将深度学习应用于信道估计,为无线通信开辟了新的研究方向。文献[26]将深度学习应用于通信系统中,利用递归神经网络研究了用户的传输功率,优于常规功率控制技术。

因此,本文提出了将卷积神经网络引入到发射天线选择领域中的方案,不仅可以降低 MIMO 系统的复杂度和成本,同时还可以提升系统的通信性能。主要工作:在 N -Nakagami 衰落信道下,利用 MIMO 和协作通信技术,建立了移动多天线协作通信系统模型。改进了 ResNet 网络模型,提出了一种基于改进 ResNet 的发射天线智能选择算法。改进的 ResNet 网络以残差结构为网络主体,利用 VGG 神经网络代替原始的卷积层,不仅有利于提取更丰富的特征信息,还减少了计算参数;丢弃了池化层,保护了信道状态数据的信息特征;设计了三个残差模块,有效增强了特征信息的提取,获得了信道容量更优的天线。最后,分别与 KNN、LR、VGG16 进行了仿真对比,所提出算法的准确率提升至 94.0%,具有较好的系统容量性能,且可以有效降低设备成本。

2 系统模型

2.1 N -Nakagami 衰落信道

服从 N -Nakagami 分布的信道状态 h 为^[27]

$$h = \prod_{i=1}^N a_i, \quad (1)$$

式中 N 为衰弱因子, a_t 符合 Nakagami 分布。

a_t 的概率密度函数表示为^[27]

$$f(a) = \frac{2m^m}{\Omega^m \Gamma(m)} a^{2m-1} \exp\left(-\frac{m}{\Omega} a^2\right), \quad (2)$$

式中 $\Gamma(\cdot)$ 是伽玛函数, m 是衰弱系数, $\Omega = E(|a|^2)$, $E(\cdot)$ 是求均值。

h 的概率密度函数表示为^[27]

$$f(h) = \frac{2^m}{h \prod_{t=1}^N \Gamma(m_t)} G_{0,N}^{N,0} \left[h^2 \prod_{t=1}^N \frac{m_t}{\Omega_t} \middle| \begin{matrix} - \\ m_1, \dots, m_N \end{matrix} \right]. \quad (3)$$

2.2 移动多天线协作通信系统模

本文基于 N -Nakagami 衰落信道, 建立了移动多天线协作通信系统模型。如图 1 所示, 该移动多天线协作通信系统包括一个 MS, L 个 MR, 一个 MD。MS 为发送端, MR 为中继, MD 为接收端。系统工作在半双工模式下, MS 使用 N_t 根天线, MD 使用 N_r 根天线, MR 使用单天线。

假设 $MS \rightarrow MD$ 链路增益为 $G_{SD} = 1$, $MS \rightarrow MR_l$ 和 $MR_l \rightarrow MD$ 链路相对于 G_{SD} 的归一化增益分别为 G_{SRl} , G_{RDl} 。

第一个时隙, 在 MD 和 MR_l 接收到的信号 r_{SDij} 、 r_{SRil} 分别表示为 $r_{SDij} = \sqrt{KE}h_{SDij}x + n_{SDij}$, $r_{SRil} = \sqrt{G_{SRil}KE}h_{SRil}x + n_{SRil}$, 式中 n_{SDij} , n_{SRil} 为零均值高斯白噪声。

在第二个时隙, $MS_i \rightarrow MD_j$ 链路的接收信噪比 γ_{SDij} 表示为 $\gamma_{SDij} = K |h_{SDij}|^2 \bar{\gamma}$, 如

果 $\gamma_{SDij} > \gamma_p$, MS_i 将会转发下一个信息, MR 没有转发信号。MD_j 的接收信噪比表示为 $\gamma_{0ij} = \gamma_{SDij}$, 如果 $\gamma_{SDij} < \gamma_p$, 最佳中继 MR 根据信噪比门限 γ_T 来决定是否译码转发收到的信号到 MD_j。最佳中继的选择过程表示为 $\gamma_{SRi} = \max_{1 \leq l \leq L} (\gamma_{SRil})$, 式中 γ_{SRil} 表示 $MS_i \rightarrow MR_l$ 链路的信噪比, $\gamma_{SRil} = K G_{SRil} |h_{SRil}|^2 \bar{\gamma}$, 如果 $\gamma_{SRi} < \gamma_T$, MS_i 将会传输下一个信息, 最佳中继 MR 没有转发信号。MD_j 的接收信噪比可以表示为 $\gamma_{1ij} = \gamma_{SDij}$, 如果 $\gamma_{SRi} > \gamma_T$, 最佳中继 MR 将会译码转发信号到 MD_j。MD_j 使用选择合并, 接收信噪比表示为 $\gamma_{SCij} = \max(\gamma_{SDij}, \gamma_{RDj})$, 式中 γ_{RDj} 表示最佳中继 $MR \rightarrow MD_j$ 链路的信噪比。

第 j 根接收天线的信噪比为

$$\gamma_{ij} = \begin{cases} \gamma_{0ij}, & \gamma_{SDij} > \gamma_p, \\ \gamma_{1ij}, & \gamma_{SDij} < \gamma_p, \gamma_{SRi} < \gamma_T, \\ \gamma_{SCij}, & \gamma_{SDij} < \gamma_p, \gamma_{SRi} > \gamma_T. \end{cases} \quad (4)$$

第 i 根发射天线的接收信噪比表示为 $\gamma_{SCi} = \max_{1 \leq j \leq N_r} (\gamma_{ij})$ 。

最佳选择发射天线表示为 $w = \arg \max_{1 \leq i \leq N_t} (\gamma_{SCi}) = \arg \max_{1 \leq i \leq N_t, 1 \leq j \leq N_r} (\gamma_{ij})$ 。

2.3 信道容量计算

通信系统的容量性能是非常重要的性能参数, 也是衡量系统传输可靠性的重要依据。信道容量表示为 $C = B \log_2(1 + S/N)$, 式中 B 为信道带宽, S 表示信号平均功率, N 表示噪声功率。

由此得出: 当信道带宽 B 越大且信噪比 S/N 越大, 可以得到更大的信道容量。




图 1 移动多天线协作系统模型

3 基于改进 ResNet 的发射天线智能选择算法

本文提出了基于改进 ResNet 的发射天线智能选择算法。为选择出更佳的天线,以残差结构为主干模块,利用 VGG 网络优化特征提取,不仅减少了参数的计算,而且获得了最佳的信道状态数据信息。

3.1 数据集构建

数据集是基于移动多天线协作通信系统模型而产生,并以信道容量最大为准则,确定以信道状态数据 h 为特征值。详细的数据集构建算法如算法 1 所示。

算法 1 数据集构建算法

第 1 步 在 N -Nakagami 信道下,建立移动多天线协作通信系统模型;

第 2 步 研究通信系统容量性能,确定以信道状态数据为特征值;

第 3 步 对产生信道状态数据进行标签,完成数据集的构建。

3.2 改进 ResNet 神经网络模型

为解决传统构建深层网络方案所产生的梯度不稳定问题,ResNet 结构被提出,观测值减去估计值即可得残差。同时,利用捷径分支等映射,不会产生额外的计算参数,计算复杂度由此也客观。

改进 ResNet 神经网络的模型结构如图 2 所示,针对本文的数据集,以残差结构为主干,加入了 VGG 神经网络进行信道状态数据的信息特征提取。其中,VGG 模块的使用有效减少了浅层计算参数,获取优秀特征子集,去除无关特征冗余,同时为避免数据信息再次压缩,放弃池化机制;残差结构可增强信道状态信息特征提取,由多个并行子网络构成,采用加和操作并不会给网络增加额外的计算参数,而且捷径分支这一结构可很好的解决梯度消失问题,同时这种残差结构和 VGG 融合的信道状态信息特征提取方法,在解决天线选择任务时有优良表现。




图 2 网络预测模型原理图




图 3 VGG 模块原理图

VGG 模块原理框架如图 3 所示,将信道状态数据压缩为三维的特征信道状态矩阵作为输入,通过 VGG 神经网络进行了特征提取,利用增补改变信道状态数据矩阵的大小,最终得到 $14 \times 14 \times 64$ 的特征矩阵。为了获得系统容量更加的天线,以便得到更优的神经网络模型,对输入的特征值进行如下处理:将三维的特征信道状态矩阵输入到 VGG 神经网络结构中,堆叠多个 3×3 的卷积核代替大尺度卷积核,卷积后进行数据特征信息提取,不仅可获得高质量的特征信息子集,而且控制了浅层计算参数,由此提高了网络学习效果。同时,为了避免特征信息的丢失不再采用池化层。

改进 ResNet 神经网络结构中共使用了三个残差模块,以增强特征信息提取。第一个残差模块,堆叠了两个相同的残差结构。第二个和第三个残差模块仅采用一个残差结构,加强了学习能力;两者均使用虚线残差模块,以采用捷径分支来直接改变通道数。三个残差模块内部结构均包含卷积层、BN 层和 ReLU 层,对其中的卷积层、步距和填充均作了相应的优化。

图 4 表示改进 ResNet 神经网络结构中的残差模块。第一个残差模块采用两个残差结构。残差结构一首先经过两层 3×3 的卷积,得到 $14 \times 14 \times 64$ 的矩阵。残差结构二的输入输出以及卷积层与残差结构一的

相同。

第二个残差模块仅采用一个残差结构,首先经过 3×3 的卷积核进行卷积,步距为 2,增补一侧,输出 $7 \times 7 \times 128$ 的矩阵;再经过 3×3 的卷积核进行卷积,输出 $7 \times 7 \times 128$ 的矩阵。

第三个残差模块也仅采用一个残差结构,首先经过 3×3 的卷积核进行卷积,步距为 2,输出 $4 \times 4 \times 256$ 的矩阵;再经过 3×3 的卷积核进行卷积,输出 $4 \times 4 \times 256$ 的矩阵。




图4 残差模块示意图

3.3 发射天线智能选择算法

发射天线智能选择算法如算法2所示。

算法2 基于改进 ResNet 的发射天线智能选择算法

第1步 构建改进 ResNet 神经网络预测模型;

第2步 数据输入并进行预处理;

第3步 划分 10 000 个数据集,9 000 个为训练集,1 000 个进行预测;

第4步 设置超参数,学习率 0.01,批次 50,迭代次数 30 轮;

第5步 训练网络,

for $i = 1 : \text{epoch}$

前向传播计算实际输出值,对比真实值并计算损失;

反向传播更新模型参数;

end

第6步 模型收敛后,保存权重;

第7步 进行天线的智能预测;

第8步 与其他方案进行信道容量仿真并对比分析。

具体算法流程图如图5所示。

4 仿真结果

4.1 ResNet 层数确定

在确定残差网络的层数时,分别对传统 18 层,34 层,50 层的残差网络进行了仿真,并对其结果进行了统

计,如表 1 所示。结果显示随着 ResNet 神经网络层数的增加准确率反而逐渐降低,训练的时间也逐渐延长。而且可以发现当 ResNet 的深度达到 50 层时,准确率竟降到 2%。由此仿真结果,我们可以猜测针对本数据集,深层的神经网络反而不利于实现发射天线的选择,而且减少残差模块的使用可以有效降低训练代价。于是我们结合 VGG 神经网络结构和残差结构搭建网络模型,最终确定了含有四个残差结构的模型,不仅简化了网络结构,降低了训练代价,而且准确率也大大提升。




图 5 算法流程图

表 1 确定 ResNet 层数仿真数据

层数	训练时间/s	准确率
18 层	48.78	86%
34 层	108.04	56%
50 层	186.69	2%

表 2 各算法仿真结果对比数据

算法	训练时间/ms	准确率
KNN	156.27	31.0%
LR	93.76	61.0%
VGG16	197 995.38	87.0%
改进 ResNet	51 926.22	94.0%




图 6 所提出算法的 Loss 曲线图

4.2 预测仿真结果

分析所提出算法的 Loss 曲线图 6,没有出现曲线震荡现象,已经基本达到收敛效果。在进行超参数设置时,学习率对该模型的收敛效果影响较大。

本文与 KNN、LR^[17]和 VGG16 等方法进行了对比。所提出算法的超参数设置:批次为 100,迭代次数为 30,学习率为 0.01,且采用 SGD 优化器。

本文首先在 1 000 组数据中随机抽取 900 组样本集作为训练集,分别训练 KNN、LR、VGG16 和改进的 ResNet 模型,然后分别用训练好的模型预测 100 组天线,分别得到如图 7 中的(a)、(b)、(c)、(d)四种仿真结果。基于 KNN 和 LR 的天线选择准确率均比 CNN 方案低,深度学习在解决天线选择准确率问题上优势较大;同时,可以明显看出本文所提出改进 ResNet 的发射天线智能选择算法的对比值重合度最高,所以相比于其他三种算法,本文所提出算法的准确率最优越。

为全面分析所提出算法在发射天线选择上的亮点,基于上述四种算法,统计实验过程中的训练时间和准确率得到如表 2 所示的结果,记录时间均保留小数点后两位。首先,对比四种算法的选择准确率,所提算法

的选择准确率较 KNN、LR、VGG16 分别提高了 63%、33%、7%，所提出算法的选择准确率最高。其次，对于 900 组数据训练代价而言，LR 模型结构简单所消耗时间最短，VGG16 模型结构较复杂所消耗时间最长；其中，VGG16 的迭代次数为 50，所提算法的迭代次数为 30，VGG16 算法训练时间约是所提出算法的 4 倍。所提出算法与单纯堆叠卷积层相比，准确率更高且时间复杂度更低；与 KNN、LR 算法相比，准确率高达 94.0%，可以获得系统容量更佳的天线。




图7 各算法真实值与预测值对比

计算平均信道容量时，为保证数据的随机性与多样性，分别利用 KNN、LR、VGG16 和所提出的预测模型对在移动多天线协作通信系统模型下产生的数据进行智能预测，得到不同算法所选出发射天线的平均信道容量如图 8 所示。随着信道质量的提高，天线的平均信道容量逐渐增大，基于改进 ResNet 算法所选择出的发射天线具有更大的平均信道容量，可以验证所提出的发射天线智能选择算法的有效性。

5 结论

本文在 N -Nakagami 衰落信道下建立了移动多天线协作通信系统模型。以信道状态数据为特征值，研究了通信系统的容量性能，并以信道容量最佳为准则产生了通信数据集。将 VGG 模型融合于 ResNet 神经网络中，改善残差模块的卷积层、池化层和全连接




图8 不同算法的系统平均容量

层,并改进了残差结构的构建,建立了改进 ResNet 神经网络预测模型,提出了一种基于改进 ResNet 的发射天线智能选择算法。通过和 KNN、LR、VGG16 算法相比较,所提出算法的天线选择准确率高,具有更佳的系统容量性能,还降低了设备的复杂度及其成本。

参 考 文 献

- [1] SHAFIQUE K, KHAWAJA B A, SABIR F, et al. Internet of things (IoT) for next-generation smart systems: A review of current challenges, future trends and prospects for emerging 5G-IoT scenarios[J]. IEEE Access, 2020, 8: 23022-23040.
- [2] MOROCHO-CAYAMCELA M E, LEE H, LIM W. Machine learning for 5G/B5G mobile and wireless communications: Potential, limitations, and future directions[J]. IEEE Access, 2019, 7: 137184-137206.
- [3] LARSSON E G, EDFORS O, TUFVESSON F, et al. Massive MIMO for next generation wireless systems.[J]. IEEE Communications Magazine, 2014, 52(2): 186-195.
- [4] NISHIMORI K, et al. Novel technologies using massive MIMO transmission toward 5G and its beyond systems[R]. 2018 International Symposium on Antennas and Propagation (ISAP), Busan, Korea (South), 2018.
- [5] SIVAKRISHNA S, YARRABOTHU R S. Design and simulation of 5G massive MIMO kernel algorithm on SIMD vector processor[C]. // 2018 Conference on Signal Processing And Communication Engineering Systems. IEEE, 2018.
- [6] 刘刚, 姜增进, 林勤华, 等. 大规模 MIMO 系统中的改进 CG 迭代算法[J]. 西安电子科技大学学报, 2022, 49(4): 8-15.
- [7] LU L, LI G Y, A. LEE S, et al. An Overview of Massive MIMO: Benefits and Challenges[J]. J Sel Topics Signal Processing, 2014, 8(5): 742-758.
- [8] VISHWANATH S, JINDAL N, GOLDSMITH A. Duality, achievable rates, and sum-rate capacity of Gaussian MIMO broadcast channels. [J]. IEEE Trans. Information Theory, 2003, 49(10): 2658-2668.
- [9] GAO Y, HAN V, THOMAS K. Massive MIMO antenna selection: switching architectures, capacity bounds, and optimal antenna selection algorithms[J]. IEEE Transactions on Signal Processing, 2018, 66(5): 1346-1360.
- [10] KIM S. Performance analysis of precoding-aided differential spatial modulation systems with transmit antenna selection[J]. Electronics and Telecommunications Research Institute Journal, 2022, 44(1): 117-124.
- [11] 高洪元, 苏雨萌, 张世铂. 大规模 MIMO 系统的智能天线选择与功率分配方法研究[J]. 系统工程与电子技术, 2020, 42(12): 2669-2675.
- [12] 李国民, 李亚如, 李新民, 等. 一种改进的大规模 MIMO 发射天线选择算法[J]. 电讯技术, 2019, 59(4): 395-400.
- [13] 丁青峰, 奚韬, 连义舫, 等. 基于物理层安全的空间调制系统天线选择算法[J]. 计算机科学, 2020, 47(7): 322-327.
- [14] 柴新新, 刘建. 基于强化学习的大规模天线阵列天线选择算法[J]. 舰船电子对抗, 2022, 45(1): 85-90.
- [15] 刘燕, 贾东升, 李玉河, 等. 基于空间调制系统的低复杂度天线选择算法[J]. 广东通信技术, 2018, 38(2): 69-73.
- [16] H E D, LIU C, QUEK T Q S, et al. Transmit antenna selection in MIMO wiretap channels: a machine learning approach[J]. IEEE Wireless Communications Letters, 2018, 7(4): 634-637.
- [17] 王博, 钱蓉蓉, 任文平. 一种利用机器学习优化 MIMO 窃听信道天线选择的方法[J]. 电讯技术, 2020, 60(5): 579-584.
- [18] LIN B, GAO F, ZHANG S, et al. Deep Learning-Based Antenna Selection and CSI Extrapolation in Massive MIMO Systems[J]. IEEE Transactions on Wireless Communications, 2021, 20(11): 634-637.
- [19] 王旭东, 林彬, 张凯尧, 等. 一种改进的 CNN 端到端自编码器通信系统[J]. 电讯技术, 2020, 60(2): 147-152.
- [20] 华敏好, 张逸彬, 孙金龙, 等. 基于深度学习的 FDD 大规模 MIMO 系统下行 CSI 反馈技术[J]. 移动通信, 2022, 46(7): 23-28.
- [21] 夏吉业, 张海勇, 徐池, 等. 基于 CNN-BiLSTM 的短波通信频率预测研究[J]. 通信技术, 2020, 53(6): 1311-1318.
- [22] 朱政宇, 侯庚旺, 黄崇文, 等. 基于并行 CNN 的 RIS 辅助 D2D 保密通信系统资源分配算法[J]. 通信学报, 2022, 43(3): 172-179.
- [23] 邹翔宇, 黄崇文, 徐勇军, 等. 基于深度学习的通信系统中安全能效的控制[J]. 电子与信息学报, 2022, 44(7): 2245-2252.
- [24] 巢玮斌, 邹明莉, 任联合, 等. 基于神经网络的光通信故障诊断系统设计[J]. 信息通信, 2020(4): 169-171.
- [25] 张兴, 周兰花, 王帅, 等. 深度学习在无线通信系统信道估计中的应用[J]. 信息通信, 2020(6): 9-11+14.
- [26] SAUD K, YOUNG S S. Deep learning aided transmit power estimation in mobile communication system[J]. IEEE Communications Letters, 2019, 23(8): 1405-1408.
- [27] 徐凌伟, 张浩, GULLIVER T A. TAS/SEC 系统在 N-Nakagami 信道下的性能分析[J]. 山东大学学报(工学版), 2015, 45(4): 84-90.

(责任编辑:刘庆松)