

基于深度学习的广义频分复用系统时频双选择信道估计

王莹¹, 任军¹, 史可¹, 林彬^{1,2}

(1. 大连海事大学信息科学技术学院, 辽宁 大连 116026; 2. 鹏程实验室网络通信研究中心, 广东 深圳 518052)

摘 要: 广义频分复用 (GFDM) 系统存在固有的子载波间干扰和子符号间干扰, 在时频双选择信道下, 会产生严重的导频污染现象, 使基于导频的信道估计性能显著下降。为此, 提出一种基于深度学习的 GFDM 系统信道估计框架, 将离散导频位置处最小二乘信道估计值构成低分辨率图像作为网络输入, 利用深度残差网络恢复信道时频响应的高分辨率图像, 实现 GFDM 系统的信道估计。设计了基于深度残差网络的 GFDM 时频双选择信道估计算法的仿真系统, 通过离线训练获得深度残差网络的最优参数。仿真结果表明, 所提算法能够得到接近于最小均方误差信道估计的精度和误码率性能, 并具有稳健的多普勒频移泛化能力。

关键词: 广义频分复用; 深度学习; 双选择信道; 信道估计; 残差网络

中图分类号: TN92

文献标识码: A

DOI: 10.11959/j.issn.1000-436x.2021188

Doubly-selective channel estimation for generalized frequency division multiplexing systems based on deep learning

WANG Ying¹, REN Jun¹, SHI Ke¹, LIN Bin^{1,2}

1. College of Information Science and Technology, Dalian Maritime University, Dalian 116026, China

2. Research Center of Network Communications, Peng Cheng Laboratory, Shenzhen 518052, China

Abstract: There exist intrinsic inter-carrier interference and inter-subsymbol interference in generalized frequency division multiplexing (GFDM) systems. Under condition of time-frequency doubly selective channels, severe effects of pilot contamination would occur and lead to significant performance degradation for the pilot-based channel estimations. To this end, a channel estimation framework for GFDM systems based on deep learning was proposed, which took the low-resolution image constructed with the least squares estimated channel gains of the pilot symbols as input. Consequently, a high-resolution image about the channel time-frequency response was recovered through a deep residual network, and the channel estimation was achieved for GFDM systems. A simulation system for the proposed GFDM time-frequency doubly selective channel estimation algorithm based on deep residual network was developed, and the optimal parameters of the deep residual network were determined through an offline training process. Simulation results show that the proposed algorithm can achieve better performance near to minimum mean square error (MMSE) estimation in terms of estimation error and bit error rate (BER), and has robust Doppler frequency shift generalization capability.

Keywords: generalized frequency division multiplexing (GFDM), deep learning, doubly-selective channel, channel estimation, residual network

收稿日期: 2021-05-18; 修回日期: 2021-09-06

通信作者: 林彬, binlin@dlnu.edu.cn

基金项目: 国家重点研发计划基金资助项目 (No.2019YFE0111600); 国家自然科学基金资助项目 (No.61971083, No.51939001); 大连市科技创新基金资助项目 (No.2019J11CY015)

Foundation Items: The National Key Research and Development Program of China (No.2019YFE0111600), The National Natural Science Foundation of China (No.61971083, No.51939001), The Dalian Science and Technology Innovation Fund (No.2019J11CY015)

1 引言

正交频分复用 (OFDM, orthogonal frequency division multiplexing) 能够有效抵抗频率选择性衰落信道, 而且其基于快速傅里叶变换的调制、解调方案具有很低的计算复杂度, 因而被广泛应用于现代通信系统, 如蜂窝移动通信网、无线局域网等。然而, OFDM 通信为每一个 OFDM 符号添加一个循环前缀, 以消除符号间干扰, 但会降低 OFDM 系统的频谱效率。另外, OFDM 系统使用矩形脉冲成型函数, 使 OFDM 信号具有较高的带外辐射, 不利于频谱资源的高效利用; 并且要求严格的频率同步以保证子载波间的正交条件。OFDM 系统的这些不足使其难以满足海量机器类通信 (mMTC, massive machine-type communications) [1]、超低时延数据传输 [2] 等新型应用的要求。为了克服 OFDM 系统的缺点, 广义频分复用 (GFDM, generalized frequency division multiplexing) 这一新型多载波通信技术受到了研究人员的广泛关注 [3-4]。每个 GFDM 符号包含多个子符号, 在时频平面上呈矩形网格结构。GFDM 的主要特点包括: 1) 采用具有时频局部化特征的循环移位脉冲成型滤波器对每一个子载波单独进行滤波处理, 从而显著降低了系统的带外辐射; 2) GFDM 符号的所有子符号共用一个循环前缀, 使系统的频谱效率得到了提高; 3) GFDM 支持灵活的时频数据块结构配置方式, 可以满足超低时延数据传输的需求 [5]。

在无线通信中, 接收信号受无线信道传播特性的影响会产生衰落现象。为了准确恢复出发送的数据符号, 获取准确的信道状态信息 (CSI, channel state information) 至关重要, 导频辅助的信道估计是 GFDM 系统最常用的信道估计方法。然而, GFDM 是一种非正交的多载波通信系统, 其循环移位脉冲成型过程会破坏子载波间的正交, 产生固有的子载波间干扰 (ICI, inter-carrier interference) 和子符号间干扰 (ISI, inter-subsymbol interference)。所以在信道估计过程中会存在导频污染, 严重影响 GFDM 系统的信道估计质量。文献 [6] 在近似平坦衰落信道的假设条件下, 提出了 2 种 GFDM 固有干扰消除方法, 能够保证导频符号免受其他数据符号的干扰; 采用匹配滤波得到时频 2 维平面上导频符号位置处的接收信号, 通过最小二乘 (LS, least square) 方法估计导频符号处的信道频率响应。然

而该方法不适用于宽带 GFDM 系统, 而且干扰消除会造成 GFDM 发射功率损失。文献 [7] 提出了一种 GFDM 波形频域实现方案, 能够为导频符号预留与数据符号相互正交的子载波, 从而提高信道估计的质量。然而, 该方案对 GFDM 系统存在的频偏非常敏感, 频偏的存在将破坏导频符号与数据符号间的正交, 造成信道估计精度下降。文献 [8] 针对频率选择性衰落信道, 分别设计了 LS 和线性最小均方误差 (LMMSE, linear minimum mean square error) 信道估计算法。文献 [8] 没有采取导频保护措施, 而是将其他数据符号对导频符号的干扰视为噪声, 使其提出的 LS 和 LMMSE 这 2 种信道估计算法在高信噪比 (SNR, signal to noise ratio) 情况下存在较大的误差平台, 而且 LMMSE 信道估计算法需要信道的统计状态信息并进行矩阵求逆运算, 这些因素制约上述 2 种信道估计算法的实际应用。文献 [9] 和文献 [10] 分别通过双滤波器结构和特征值分解技术消除传统 GFDM 系统固有的 ICI 和 ISI, 使导频符号得到保护, 在频率选择性信道下能够得到良好的信道估计效果; 但是这 2 种 GFDM 固有干扰消除技术均破坏了脉冲成型滤波器的时频局部化特征, 不利于其在时频双选择信道下的数据传输。

在宽带 GFDM 通信系统中, 用户的运动将带来多普勒效应, 使无线信道同时具有频率选择性和时间选择性, 即时频双选择信道。在双选择信道的作用下, 一方面 GFDM 系统的 ICI 和 ISI 会增强, 产生严重的导频污染; 另一方面需要估计的信道参数数量也会显著增加。这使 GFDM 系统时频双选择信道估计具有很高的挑战性。GFDM 系统双选择信道估计的文献非常有限, 而上述介绍的导频辅助的 GFDM 信道估计技术也无法直接应用于双选择信道应用场景。

随着计算机硬件性能飞速发展和梯度传播算法逐渐完善, 基于深度学习 (DL, deep learning) 的智能无线通信系统已成为当前的研究焦点 [11-12]。在基于深度学习的信道估计研究中, 文献 [13] 利用深度神经网络 (DNN, deep neural network) 实现了 OFDM 接收机端到端的信道估计与符号检测功能, 验证了 DNN 应用于 OFDM 物理层设计的可行性。但是, 该 DNN 无法直接提供信道的时频响应, 因此无法应用于需要完整信道响应信息的场景。文献 [14] 将信道的时频响应视为一幅包含噪声的低分辨率 2 维图像, 结合使用超分辨卷积神经网络 (CNN,

convolution neural network) 和去噪神经网络进行 OFDM 系统信道估计。文献[14]构建的深度学习网络支持灵活的导频布置方案,但是相应的网络结构并未针对信道估计问题进行优化,计算复杂度和信道估计误差性能均需进一步提高。文献[15]采用与文献[14]相似的思路,即将信道的时频响应当作 2 维图像进行处理,提出了一种 OFDM 深度残差信道估计网络,利用残差块结构中的跳层连接^[16]克服网络训练过程中的梯度消失和梯度爆炸问题,提高学习效率。

综上所述,GFDM 系统的时频双选择信道估计问题还没有得到很好的研究。为了保障 GFDM 系统在时频双选择信道下具有良好的误码率性能,本文提出了一种用于 GFDM 系统的深度神经网络,即信道估计残差网络(CE-ResNet, channel estimation residual network),实现对 GFDM 系统时频双选择性信道的估计。针对 GFDM 符号的块状符号结构,插入时频 2 维分布的离散导频符号。以导频符号位置处信道增益的最小二乘估计值构成低分辨率信道时频增益图像,作为 CE-ResNet 的输入,由 CE-ResNet 学习低分辨率信道时频增益图像与高分辨率信道时频增益图像间的映射关系。利用经过具有不同多普勒频移的多径衰落信道传输,且包含加性白高斯噪声的 GFDM 系统接收信号产生训练与测试数据,完成 CE-ResNet 的训练与测试。仿真结果表明,本文提出的 CE-ResNet 能够获得接近于最小均方误差(MMSE, minimum mean square error)信道估计的精度和误码率性能,并且针对多普勒频移具有很好的泛化性能。

2 GFDM 系统模型及其时变信道估计

2.1 GFDM 系统模型

考虑一个具有 K 个子载波和 M 个子符号的 GFDM 系统,记 $N = KM$ 。发射机端将数据源提供的 μN 个二进制数据比特通过正交幅度调制(QAM, quadrature amplitude modulation)映射为 N 个复数据符号,其中, μ 为调制阶数。将这 N 个复数据符号记为符号向量 $\mathbf{d} = [d_{0,0}, \dots, d_{K-1,0}, d_{0,1}, \dots, d_{K-1,M-1}]^T$,其中, $d_{k,m}$ 表示 GFDM 数据块中第 m 个子符号的第 k 个子载波上传输的数据符号。GFDM 通过对一个具有时频局部化特征的原型脉冲成型滤波器进行时域循环移位和频域调制,从而得到每一个数据符号所需的成型脉冲。将经过脉冲成型处理的 N 个数据符号叠加在一起便可产生 GFDM 基带信号,即

$$\mathbf{x}[n] = \sum_{k=0}^{K-1} \sum_{m=0}^{M-1} d_{k,m} \mathbf{g}_{k,m}[n], \quad n = 0, \dots, N-1 \quad (1)$$

其中, $\mathbf{g}_{k,m}[n]$ 为与数据符号 $d_{k,m}$ 相对应的脉冲成形函数。对于 $k \in \{0, \dots, K-1\}$, $m \in \{0, \dots, M-1\}$, $\mathbf{g}_{k,m}[n]$ 可以表示为

$$\mathbf{g}_{k,m}[n] = \mathbf{g}[\langle n - mK \rangle_N] e^{j \frac{2\pi}{K} kn} \quad (2)$$

其中, $\langle \cdot \rangle_N$ 表示模- N 运算。 $\mathbf{g}[n]$ 代表原型脉冲成型滤波器,通常采用升余弦函数、根升余弦函数等作为原型脉冲成型滤波器^[5]。进一步地,式(1)还可以改写为矩阵形式,即

$$\mathbf{x} = \mathbf{A} \mathbf{d} \quad (3)$$

其中, $\mathbf{x} = [x[0], \dots, x[N-1]]^T$, \mathbf{A} 为 GFDM 系统的调制矩阵,可以表示为

$$\mathbf{A} = [\mathbf{g}_{0,0}, \dots, \mathbf{g}_{K-1,0}, \mathbf{g}_{0,1}, \dots, \mathbf{g}_{K-1,M-1}] \quad (4)$$

其中, $\mathbf{g}_{k,m} = [g_{k,m}[0], \dots, g_{k,m}[N-1]]^T$ 。

考虑时频双选择信道,其时变信道脉冲响应函数可以表示为

$$h(t, \tau) = \sum_{l=0}^{L-1} h_l(t) \delta(\tau - \tau_l) \quad (5)$$

其中, L 是信道的径数, $h_l(t)$ 是第 l 径的时变幅值增益, τ_l 是第 l 径的路径时延。对式(5)中连续时间脉冲响应函数进行采样后,便可得到离散时间信道脉冲响应,即 $h_{n,l} \triangleq h(nT_s, lT_s)$, 这里 T_s 为采样间隔。假设 GFDM 符号的循环前缀长度 $N_{\text{CP}} \geq L$, 则接收端实现完美符号同步并去除循环前缀后的接收信号可以表示为

$$\mathbf{y} = \mathbf{H}' \mathbf{A} \mathbf{d} + \mathbf{w} \quad (6)$$

其中, $\mathbf{y} = [y[0], \dots, y[N-1]]^T$ 为接收信号矢量; $\mathbf{w} = [w[0], \dots, w[N-1]]^T$ 表示均值为 0、方差为 $\sigma_w^2 \mathbf{I}_N$ 的加性白高斯噪声矢量, \mathbf{I}_N 为 $N \times N$ 的单位矩阵; $\mathbf{H}' \in \mathcal{C}^{N \times N}$ 为信道矩阵, \mathcal{C} 表示复数集合。 \mathbf{H}' 的第 n_1 行第 n_2 列的元素 $[\mathbf{H}']_{n_1, n_2} = h_{n_1, \langle n_1 - n_2 \rangle_N}$, 当 $\langle n_1 - n_2 \rangle_N \geq L$ 时, 有 $[\mathbf{H}']_{n_1, n_2} = 0$, 其中, $n_1, n_2 \in \{0, 1, \dots, N-1\}$ 。

假设 GFDM 接收端获得了信道状态信息,则对式(6)的接收信号进行迫零均衡,有^[5]

$$\mathbf{y}' = (\mathbf{H}')^{-1} \mathbf{H}' \mathbf{A} \mathbf{d} + (\mathbf{H}')^{-1} \mathbf{w} \quad (7)$$

对于均衡后的信号 \mathbf{y}' , 可以通过以下处理方式

得到发送数据符号的检测结果, 即

$$\hat{\mathbf{d}} = \mathbf{B}\mathbf{y}' \quad (8)$$

其中, $\mathbf{B} \in \mathbb{C}^{N \times N}$ 是 GFDM 系统的符号检测矩阵。当 $\mathbf{B} = \mathbf{A}^H$ 时, 表示匹配滤波接收机; 当 $\mathbf{B} = \mathbf{A}^{-1}$ 时, 表示迫零接收机; 当 $\mathbf{B} = (\mathbf{A}^H \mathbf{A} + \sigma_w^2 \mathbf{I}_N)^{-1} \mathbf{A}^H$ 时, 表示 MMSE 接收机。

2.2 时变信道估计

对于非时变信道, 信道矩阵 \mathbf{H}' 是一个循环矩阵, 通过傅里叶变换矩阵 \mathbf{F} 能够将其对角化, 从而显著降低信道估计的复杂度。这里, 傅里叶变换矩阵 \mathbf{F} 的第 n_1 行第 n_2 列的元素定义为 $[\mathbf{F}]_{n_1, n_2} = e^{-j\frac{2\pi}{N}n_1 n_2}$ 。然而, 在时变信道条件下, 信道矩阵 \mathbf{H}' 将失去循环矩阵的特征, 并包含 NL 个未知的信道脉冲响应抽头系数。为了对时变信道进行估计, 发射端在 GFDM 符号中插入离散导频, 具体结构如图 1 所示。图 1 中 Δk 和 Δm 分别为导频在频域与时域的布置间隔, 通常二者分别与待估计信道的时延扩展和多普勒频移的大小成反比, 以使导频的数目满足采样定理要求。记导频符号集合为 $\mathbf{P} \subseteq \{0, \dots, K-1\} \times \{0, \dots, M-1\}$, 导频符号的数目为 $|\mathbf{P}|$ 。进一步定义导频符号矢量为 $\mathbf{d}_p \in \mathbb{C}^{N \times 1}$, 数据符号矢量为 $\mathbf{d}_d \in \mathbb{C}^{N \times 1}$ 。 \mathbf{d}_p 在非导频符号位置处为 0 元素, 而 \mathbf{d}_d 在非数据符号位置处为 0 元素; 且 $\mathbf{d}_p \odot \mathbf{d}_d = \mathbf{0}$, $\mathbf{d}_p + \mathbf{d}_d = \mathbf{d}$ 。其中, \odot 表示 Hadamard 积。




图 1 GFDM 符号数据块中导频符号的布置

接收端对式(6)接收信号进行匹配滤波, 对于第 m 个子符号的第 k 个子载波上的信号, 匹配滤波的结果可以表示为

$$z_{k,m} = \sum_{n=0}^{N-1} y[n] g_{k,m}^*[n] = \sum_{n=0}^{N-1} \sum_{l=0}^{L-1} h_{n,l} \sum_{k'=0}^{K-1} \sum_{m'=0}^{M-1} d_{k',m'} \cdot g_{k',m'}^*[(n-l)_N] g_{k,m}^*[n] + \sum_{n=0}^{N-1} w[n] g_{k,m}^*[n] \quad (9)$$

对式(9)进行整理, 可以得到

$$z_{k,m} = d_{k,m} H_{k,m}^{0,0} + \sum_{(\alpha,\beta) \in \mathbf{S}_{k,m}} d_{k-\alpha, m-\beta} H_{k,m}^{\alpha,\beta} + w'_{k,m}[n] \quad (10)$$

其中, $w'_{k,m}[n]$ 为加性白高斯噪声经过匹配滤波器后的输出。集合 $\mathbf{S}_{k,m} = \{k, \langle k-1 \rangle_K, \dots, \langle k-K+1 \rangle_K\} \cdot \{m, \langle m-1 \rangle_M, \dots, \langle m-M+1 \rangle_M\} \setminus (0,0)$, 即 $\alpha = k - k'$, $\beta = m - m'$ 。这里, “ \setminus ” 表示集合减法操作。 $H_{k,m}^{\alpha,\beta}$ 定义为

$$H_{k,m}^{\alpha,\beta} = \sum_{n=0}^{N-1} \sum_{l=0}^{L-1} h_{n,l} g_{m-\beta}[(n-l)_N] g_m^*[n] e^{-j\frac{2\pi}{K}(an+kl-al)} \quad (\alpha,\beta) \in \mathbf{S}_{k,m} \cup (0,0) \quad (11)$$

其中, $g_m[n] \triangleq g[\langle n - mK \rangle_N]$ 。注意, 当 $(\alpha, \beta) \in \mathbf{S}_{k,m}$ 时, $H_{k,m}^{\alpha,\beta}$ 表示符号 $d_{k-\alpha, m-\beta}$ 对符号 $d_{k,m}$ 的干扰增益, 而 $H_{k,m}^{0,0}$ 表示符号 $d_{k,m}$ 自身的增益。因此, 本文称 $H_{k,m}^{0,0}$ 为广义信道时频增益, 其中, $k \in \{0, \dots, K-1\}$, $m \in \{0, \dots, M-1\}$ 。则待估计的矩阵形式的广义信道时频增益可以表示为

$$\mathbf{H} = \begin{bmatrix} H_{0,0}^{0,0} & \cdots & H_{0,M-1}^{0,0} \\ \vdots & \ddots & \vdots \\ H_{K-1,0}^{0,0} & \cdots & H_{K-1,M-1}^{0,0} \end{bmatrix} \quad (12)$$

式(10)等号右侧第一项为期望的符号数据, 第二项为 GFDM 的非正交特性及时变多径衰落信道所引起的 ICI 与 ISI 信号, 第三项为经过匹配滤波器后的噪声信号。将式(10)改写为矩阵形式, 有

$$\mathbf{Z} = \mathbf{H} \odot \mathbf{D} + \mathbf{W} \quad (13)$$

其中, $\mathbf{Z} \in \mathbb{C}^{K \times M}$ 为匹配滤波器输出信号矩阵, 其第 k 行第 m 列的元素为 $z_{k,m}$; $\mathbf{D} \in \mathbb{C}^{K \times M}$ 的第 k 行第 m 列元素为 $d_{k,m}$; $\mathbf{W} \in \mathbb{C}^{K \times M}$ 的第 k 行第 m 列元素为

$$\sum_{(\alpha,\beta) \in \mathbf{S}_{k,m}} d_{k-\alpha, m-\beta} H_{k,m}^{\alpha,\beta} + w'_{k,m}[n]$$

利用基于广义信道增益的信号模型式(13), 便可以进行导频辅助的双选择信道估计。具体而言, 从式(13)匹配滤波器的输出信号矩阵 \mathbf{Z} 提取出导频符号处的元素 $z_{k,m}$, 其中, $(k, m) \in \mathbf{P}$ 。此时, 采用 LS 算法估计导频位置处的信道时频增益, 即

$$\left(\tilde{H}_{k,m}^{0,0} \right)^{\text{LS}} = \frac{z_{k,m}}{d_{k,m}} \quad (14)$$

记 $\tilde{\mathbf{H}}_p^{\text{LS}} = \left[\left(\tilde{H}_{k_1, m_1}^{0,0} \right)^{\text{LS}}, \dots, \left(\tilde{H}_{k_{p_1}, m_{p_1}}^{0,0} \right)^{\text{LS}} \right]^T \in \mathbb{C}^{|\mathbf{P}| \times 1}$ 为

所有导频位置处信道时频增益估计值矢量，基于 $\tilde{\mathbf{H}}_p^{\text{LS}}$ 便可以采用插值算法估计所有数据符号位置处的信道时频增益。

利用 MMSE 算法能够进一步提高信道估计的精度。基于式(14)给出的导频符号位置处信道时频响应增益的最小二乘估计，对于数据符号矢量 \mathbf{d}_d 的元素 $d_{k',m'}$ ， $k' \in \{0, \dots, K-1\}$ ， $m' \in \{0, \dots, M-1\}$ ，其广义信道时频增益的 MMSE 估计值可以表示为

$$\left(H_{k',m'}^{0,0}\right)^{\text{MMSE}} = \mathbf{R}_{H_{k',m'}^{0,0}, \tilde{\mathbf{H}}_p^{\text{LS}}} \mathbf{R}_{\tilde{\mathbf{H}}_p^{\text{LS}}, \tilde{\mathbf{H}}_p^{\text{LS}}}^{-1} \tilde{\mathbf{H}}_p^{\text{LS}} \quad (15)$$

其中， $\mathbf{R}_{H_{k',m'}^{0,0}, \tilde{\mathbf{H}}_p^{\text{LS}}} \in \mathcal{C}^{1 \times |P|}$ 为数据符号 $d_{k',m'}$ 位置处信道时频增益 $H_{k',m'}^{0,0}$ 与 $\tilde{\mathbf{H}}_p^{\text{LS}}$ 之间的互相关系数矢量， $\mathbf{R}_{\tilde{\mathbf{H}}_p^{\text{LS}}, \tilde{\mathbf{H}}_p^{\text{LS}}} \in \mathcal{C}^{|P| \times |P|}$ 为导频位置处信道时频增益矢量的互相关系数矩阵。虽然 MMSE 信道估计方法提高了信道估计精度，但是需要已知信道的统计特征参数，并存在矩阵求逆运算，这些因素限制了其在实际中的应用。

在得到广义信道矩阵的估计值 $\tilde{\mathbf{H}}$ 后，GFDM 接收信号的均衡处理可以表示为

$$\hat{\mathbf{D}} = \overline{\mathbf{H}} \odot \mathbf{Z} \quad (16)$$

其中， $\overline{\mathbf{H}} \in \mathcal{C}^{K \times M}$ 的第 k 行第 m 列元素定义为

$$\overline{H}_{k,m}^{0,0} = \frac{1}{\tilde{H}_{k,m}^{0,0}}, k \in \{0, \dots, K-1\}, m \in \{0, \dots, M-1\} \quad (17)$$

其中， $\tilde{H}_{k,m}^{0,0}$ 是广义信道估计矩阵 $\tilde{\mathbf{H}}$ 的第 k 行第 m 列元素。

3 基于残差学习的信道估计网络

3.1 残差网络的结构

在深度学习的应用中，通常认为随着深度神经网络的层数增加，可以提取更多的特征，从而达到更好的分类效果。然而，人们在实践中发现在网络深度逐渐增加的过程中，分类精度会首先达到饱和，并随后出现性能迅速下降的现象^[17]。文献[16]针对深度神经网络的性能退化问题，提出了深度残差学习框架。深度残差学习的核心思想是通过层叠的网络层来学习残差映射，而不是直接学习所期望的潜在映射。残差学习基本单元如图 2 所示。由图 2 可知，残差学习基本单元块在层叠网络中引入了输入信号的跳跃传输机制。记 $H(x)$ 为期望的潜在映射，在残差学习框架下层叠的非线性网络用于拟合残差 $F(x) = H(x) - x$ ，这样原始的潜在映射便可以

表示为 $F(x) + x$ 。文献[16]指出通过残差学习技术，解决了神经网络中由于层数增加而带来的网络退化问题，并能够有效提高网络的性能。




图 2 残差学习基本单元块

3.2 GFDM 时变信道估计网络的建立

本节将 GFDM 系统导频位置处的时频信道响应视为低分辨率图像，利用深度残差网络进行 GFDM 系统的信道估计。基于深度学习技术的无线信道估计与其他应用领域的分类问题相似，均是通过有监督的学习算法对网络进行训练，待训练过程收敛后得到网络参数，再通过测试数据对网络性能进行测试。本文采用如图 1 所示的 GFDM 导频插入方式，得到 $K_p \times M_p$ 个导频符号。其中， $K_p = \lceil K/\Delta k \rceil$ ， $M_p = \lceil M/\Delta m \rceil$ ， $\lceil \cdot \rceil$ 表示向上取整数。接下来，首先通过式(13)给出的 LS 信道估计算法得到导频符号位置处的广义信道时频增益 $\tilde{\mathbf{H}}_p^{\text{LS}}$ ，再将 $\tilde{\mathbf{H}}_p^{\text{LS}}$ 的 $|P|$ 个元素组织成 $K_p \times M_p$ 的 2 维低分辨率图像。这里的低分辨率图像包括 2 个通道，记为 $\tilde{\mathbf{H}}_{p,1}^{\text{LS}} \in \mathcal{R}^{K_p \times M_p}$ 和 $\tilde{\mathbf{H}}_{p,2}^{\text{LS}} \in \mathcal{R}^{K_p \times M_p}$ ，分别对应于 $\tilde{\mathbf{H}}_p^{\text{LS}}$ 的实部数据和虚部数据。其中， \mathcal{R} 表示实数集合。经过上述处理便得到了 GFDM 时变信道估计网络的输入信号。

本节设计的深度学习辅助的 GFDM 系统时变信道估计网络 CE-ResNet 是基于残差学习的深度神经网络，其网络模型如图 3 所示。CE-ResNet 开始是一个 2 维卷积层，其滤波器个数为 16，核的大小为 3×3 ，步长为 1。为了使该卷积层的输出具有与原始输入相同的形状，在输入的低分辨率图像周围填充一圈 0 元素。考虑到 GFDM 系统的非正交及时频双选择信道所引起的严重的导频污染现象，本节在第一个卷积层之后采用了 6 个依次串联的残差学习单元，通过较深的结构来提高网络的特征学习能力。这些残差学习单元具有相同的网络结构，分别由 2 维卷积层、归一化层、ReLU 激活层和 2 维卷

积层串联构成。残差学习单元中的批量归一化层可以避免梯度消失，提高网络学习效率。本节设置残差学习单元中的 2 维卷积层与网络开始位置处的 2 维卷积层具有相同的结构。在 6 个残差学习单元的后面仍然是一个与网络开始位置处的 2 维卷积层具有相同结构的 2 维卷积层，随后配置一个 2 维反卷积层^[18]，其滤波器个数为 16，作用是对网络输入数据进行上采样，使输出数据与待估计的信道时频响应具有相同的维度。因此，该 2 维反卷积层卷积核的大小 $C_1 \times C_2$ 和步长 (S_1, S_2) 均需要根据 GFDM 系统的参数 K, M, K_p, M_p 来确定，具体关系为

$$\begin{cases} K = (K_p - 1)S_1 + C_1 \\ M = (M_p - 1)S_2 + C_2 \end{cases} \quad (18)$$

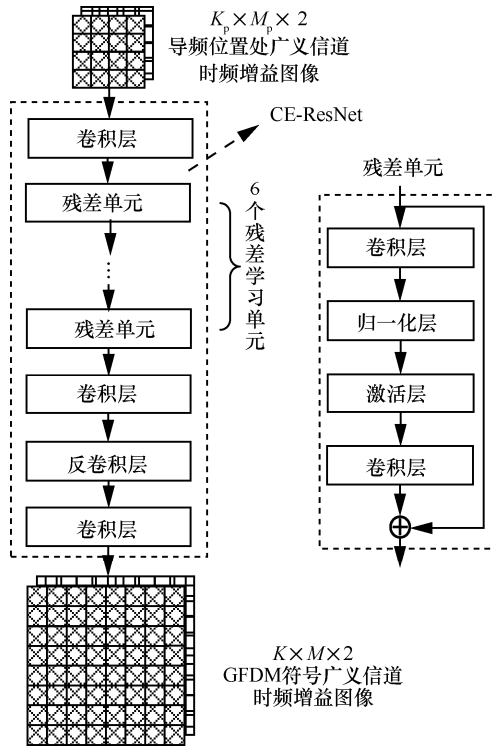


图 3 CE-ResNet 的网络模型

经过 2 维反卷积层的处理，便可以将特征图由 16 通道的 $K_p \times M_p$ 图像扩展成 16 通道的 $K \times M$ 图像。反卷积插值在通过若干样值计算一个插值点时，其网络权重是可以被学习的，从而获得优于常规插值算法的性能。最后一层仍是 2 维卷积层，但该层的滤波器个数为 2，以将反卷积网络输出的 16 通道特征图像数据转换为 2 通道的信道时频响应估计值，分别对应于信道时频响应的实部数据和虚部数据，这样便得到 GFDM 系统的广义信道时频增益

的估计值 $\tilde{\mathbf{H}}^{\text{ResNet}} \in \mathcal{C}^{K \times M}$ 。 $\tilde{\mathbf{H}}^{\text{ResNet}}$ 可以表示为

$$\tilde{\mathbf{H}}^{\text{ResNet}} = \begin{bmatrix} (\tilde{H}_{0,0}^{0,0})^{\text{ResNet}} & \cdots & (\tilde{H}_{0,M-1}^{0,0})^{\text{ResNet}} \\ \vdots & \ddots & \vdots \\ (\tilde{H}_{K-1,0}^{0,0})^{\text{ResNet}} & \cdots & (\tilde{H}_{K-1,M-1}^{0,0})^{\text{ResNet}} \end{bmatrix} \quad (19)$$

CE-ResNet 的训练与测试过程如图 4 所示。首先利用信道模型随机产生时变信道脉冲响应函数，并随机产生 GFDM 符号。在此基础上根据式(6)得到 GFDM 接收机的接收信号，训练过程中接收信号的信噪比设定为 20 dB。然后，根据式(14)计算导频位置处的广义信道时频增益 $\tilde{\mathbf{H}}_{p,1}^{\text{LS}}$ 和 $\tilde{\mathbf{H}}_{p,2}^{\text{LS}}$ ，并结合相应的 GFDM 符号广义信道时频增益 \mathbf{H} 的实部和虚部数据 $\mathbf{H}_1 \in \mathcal{R}^{K \times M}$ 、 $\mathbf{H}_2 \in \mathcal{R}^{K \times M}$ 作为标签，便组成了 CE-ResNet 的训练数据。记 CE-ResNet 的参数集合为 Θ ，则其 GFDM 符号信道估计值可以表示为

$$(\tilde{\mathbf{H}}_1, \tilde{\mathbf{H}}_2) = f_{\Theta}(\tilde{\mathbf{H}}_{p,1}^{\text{LS}}, \tilde{\mathbf{H}}_{p,2}^{\text{LS}}) \quad (20)$$




图 4 CE-ResNet 的训练与测试过程

本节选择 Frobenius 范数作为网络的损失函数，利用 Adam 优化器对网络参数集合 Θ 进行优化，以得到最佳网络参数集合，即

$$\Theta^* = \arg \min_{\Theta} \left\{ \|\mathbf{H}_1 - \tilde{\mathbf{H}}_1\|_F^2 + \|\mathbf{H}_2 - \tilde{\mathbf{H}}_2\|_F^2 \right\} \quad (21)$$

其中， $\|\cdot\|_F$ 表示 Frobenius 范数。在网络训练结束后，还需要对其性能进行测试。采用与网络训练数据相同的准备方法，得到测试数据 $\tilde{\mathbf{H}}_{p,1}^{\text{LS}}$ 和 $\tilde{\mathbf{H}}_{p,2}^{\text{LS}}$ ，对 CE-ResNet 进行测试。

4 仿真与分析

为了验证设计的深度学习辅助的 GFDM 系统时频双选择信道估计网络 CE-ResNet 的性能，首先，在 Keras 框架下利用 Python 语言实现如图 3 所示的 CE-ResNet 模型。然后，在 Matlab 软件环境下生成 GFDM 符号波形、时变多径衰落信道参数 \mathbf{H}_1 和 \mathbf{H}_2 ，以及经过时变多径衰落信道后的接收信号。

相应的 GFDM 通信系统仿真参数如表 1 所示。接下来，利用 LS 算法得到导频位置处的广义信道增益的估计值 $\tilde{\mathbf{H}}_{p,1}^{LS}$ 和 $\tilde{\mathbf{H}}_{p,2}^{LS}$ 。此时，将产生的数据集 $(\tilde{\mathbf{H}}_{p,1}^{LS}, \tilde{\mathbf{H}}_{p,2}^{LS}, \mathbf{H}_1, \mathbf{H}_2)$ 组织成 CE-ResNet 的训练数据文件和验证数据文件。数据集 $(\tilde{\mathbf{H}}_{p,1}^{LS}, \tilde{\mathbf{H}}_{p,2}^{LS}, \mathbf{H}_1, \mathbf{H}_2)$ 的具体内容包括归一化多普勒频移 $f_D = 0.01$ 时的数据 20 000 组、 $f_D = 0.03$ 时的数据 10 000 组、 $f_D = 0.05$ 时的数据 7 000 组和 $f_D = 0.07$ 时的数据 3 000 组。将这 40 000 组数据进行随机排列后堆叠在一起，取出其中 80% 的数据集作为训练数据，而其余 20% 的数据作为验证数据。在 CE-ResNet 的训练与验证数据的产生过程中，由于随着多普勒频移的增加，GFDM 符号内的 ICI 和 ISI 将显著增强，不利于符号的估计检测。因此，随着多普勒频移的增加相应的数据量也随之下落。初始学习速率设置为 0.001，考虑到固定的学习速率可能导致网络模型在经过一定数目的迭代训练后效果不再提升，在网络的训练过程中采用了学习速率自动调整技术，即当训练损失停留在每个平台不再下降时，将主动减小学习速率，从而加速网络模型的训练过程。

表 1 GFDM 通信系统仿真参数设定

参数名称	参数取值
系统带宽/MHz	10
子载波数	$K=64$
子符号数	$M=13$
导频符号数目	$K_p \times M_p = 22 \times 4$
原型滤波器	根升余弦函数
滚降因子 α	0.1
调制方式	4-QAM
时变信道模型	Jakes
多径时延/ns	[0, 300, 500, 600, 800]
路径功率/dB	[0, -8, -17, -21, -25]

图 5 是 CE-ResNet 训练与验证的收敛曲线。可以看到，网络的 Frobenius 范数损失随着训练轮次的增加迅速下降，并在训练轮次为 130 次后达到一个相对稳定数值。这表明本文所设计的 GFDM 系统双选择信道估计网络 CE-ResNet 可以通过训练快速收敛。

为了验证 CE-ResNet 的信道估计性能，本文将其与 MMSE 信道估计算法在信道估计均方误差、BER 性能和计算复杂度等方面进行比较。除此之外，本文还设计了一个基于全连接层（FCL, full

connection layer）结构的信道估计深度神经网络（CE-DNN, channel estimation deep neural network）作为性能对比对象。CE-DNN 的深度为 4 层，各层神经元的个数分别为 176、2 500、2 000 和 1 664，隐藏层的激活函数为 Tanh，而且训练数据与 CE-ResNet 相同。为了避免 CE-DNN 出现过拟合现象，本节对每个隐藏层均设置了 0.1 的丢弃概率。图 6 和图 7 分别是 CE-ResNet、CE-DNN 和 MMSE 这 3 种信道估计方法针对 GFDM 系统双选择信道估计的均方误差和 BER 性能曲线。从图 6 和图 7 中可以看出，在双选择信道环境下，随着归一化多普勒频移的增加，信道估计的均方误差均随之增大，而且带信道估计的系统误码率性能也会逐渐变差。此外，基于 CE-DNN 的双选择信道估计性能最差，基于 MMSE 算法的双选择信道估计性能最好。而基于 CE-ResNet 进行 GFDM 系统双选择信道估计的性能与 MMSE 算法的信道估计性能相近，且优于基于 CE-DNN 的双选择信道估计。

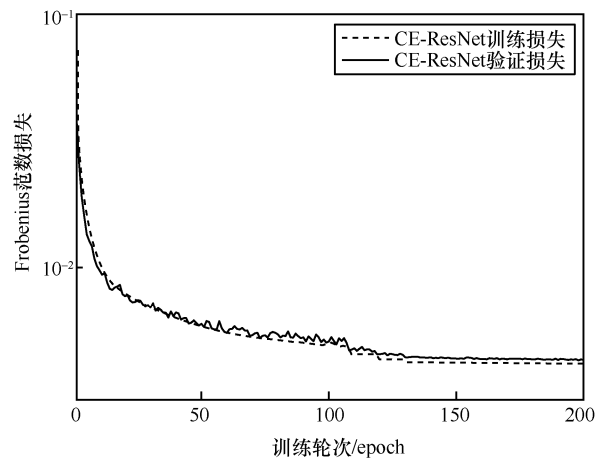


图 5 CE-ResNet 训练与验证的收敛曲线




图 6 3 种信道估计方法的信道估计均方误差曲线




图 7 3 种信道估计方法的 BER 对比

下面对上述 3 种信道估计算法以实数乘法次数为单位的计算复杂度进行分析。对于 MMSE 信道估计算法，不考虑信道相关矩阵计算及矩阵求逆运算，则由式 (13) 可知，其实数乘法次数为 $4KM(|\mathbf{P}|^2 + |\mathbf{P}|)$ 。记 L 为全连层或卷积层的总层数。在 CE-DNN 中，设第 l 个全连层的神经元个数为 N_l ，则在考虑偏置的情况下，其第 l 层需要训练的参数数量为 $(N_l + 1)N_{l+1}$ ，故 CE-DNN 整体的网络参数数量为 $\sum_{l=1}^{L-1} (N_l + 1)N_{l+1}$ 。在利用 CE-DNN 对 GFDM 相同信道时频响应进行预测时，实数乘法次数为 $\sum_{l=1}^{L-1} N_l N_{l+1}$ 。对于 CE-ResNet，记 $k_{l,h}$ 、 $k_{l,w}$ 和 $k_{l,c}$ 分别代表第 l 个卷积层中卷积核的长度、宽度和通道数，并记 H_l 、 W_l 、 C_l 分别代表第 l 个卷积层输入图像的长度、宽度和通道数。则第 l 个卷积层的参数数量为 $(k_{l,h}k_{l,w}k_{l,c} + 1)C_{l+1}$ ，网络总参数数量为 $\sum_{l=1}^{L-1} (k_{l,h}k_{l,w}k_{l,c} + 1)C_{l+1}$ 。在利用 CE-ResNet 对 GFDM 系统信道时频响应增益进行预测时，实数乘法次数为 $\sum_{l=1}^{L-1} k_{l,h}k_{l,w}k_{l,c}H_{l+1}W_{l+1}C_{l+1}$ 。表 2 给出了上述 3 种不同信道估计算法的计算复杂度。基于本文的设计参数，3 种算法具体的实例化计算复杂度数值如表 3 所示。由表 3 可知，MMSE 信道估计算法的计算复杂度最高，CE-DNN 的计算复杂度次之，而 CE-ResNet 具有最低的计算复杂度。此外，CE-ResNet 的网络参数数量远低于 CE-DNN，这表明 CE-ResNet 较 CE-DNN 在训练过程中存在显著的计算量下降。

图 8 给出了采用 1/2 码率 LDPC 编码的 GFDM

系统与非编码 GFDM 系统，在利用 CE-ResNet 的双选择信道估计值进行符号检测时的 BER 对比曲线。由图 8 可以看出，LDPC 编码可以显著改善系统的 BER 性能。然而，对于归一化多普勒频率 $f_D = 0.03$ ，当 SNR 大于 15 dB 之后，对于 $f_D = 0.005$ ，当 SNR 大于 25 dB 之后，LDPC 编码带来的 BER 改善效果变得不明显。这是由于 GFDM 系统在多普勒频移条件下会产生严重的 ICI 与 ISI，当加性白高斯噪声的功率降低到一定程度后，影响 BER 性能的主要因素是 ICI 与 ISI。而当 $f_D = 0.03$ 时，多普勒频移产生的 ICI 与 ISI 大于 $f_D = 0.005$ 时相应的 ICI 与 ISI，所以 $f_D = 0.03$ 时的 LDPC 编码的 BER 出现平台现象所对应的 SNR 小于 $f_D = 0.005$ 时相应的 SNR。

表 2 3 种信道估计算法的计算复杂度

方法	参数数量	实数乘法次数
CE-DNN	$\sum_{l=1}^{L-1} (N_l + 1)N_{l+1}$	$\sum_{l=1}^{L-1} N_l N_{l+1}$
MMSE	$KM \mathbf{P} + \mathbf{P} ^2$	$4KM(\mathbf{P} ^2 + \mathbf{P})$
CE-ResNet	$\sum_{l=1}^{L-1} (k_{l,h}k_{l,w}k_{l,c} + 1)C_{l+1}$	$\sum_{l=1}^{L-1} k_{l,h}k_{l,w}k_{l,c}H_{l+1}W_{l+1}C_{l+1}$

表 3 3 种信道估计算法实例化的计算复杂度

方法	参数数量	实数乘法次数
MMSE	80 960	26 064 896
CE-DNN	8 774 164	8 768 000
CE-ResNet	53 298	4 883 200

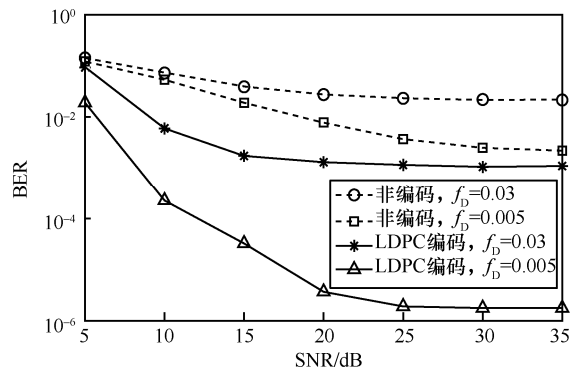


图 8 LDPC 编码与非编码 GFDM 系统基于 CE-ResNet 信道估计的 BER 性能对比

为了验证所设计的 GFDM 系统双选择信道估计网络 CE-ResNet 针对多普勒频移的泛化能力，本文采用 CE-ResNet 对归一化多普勒频移分别为 0.02、0.04 和 0.06 的双选择信道进行估计，相应的

BER 性能曲线如图 9 所示。由图 9 可知，虽然训练数据中不包含 $f_D = 0.02$ 、 $f_D = 0.04$ 和 $f_D = 0.06$ 这三种情况下的数据，CE-ResNet 仍能够获得与 MMSE 信道估计算法非常接近的 BER 性能。这表明本文所设计的 GFDM 系统双选择信道估计网络 CE-ResNet 针对多普勒频移具有很好的泛化能力。




图 9 f_D 分别为 0.02、0.04 和 0.06 时 CE-ResNet 的 BER 性能

图 10 给出了 CE-ResNet 信道估计算法中不同导频符号数目对 GFDM 系统误码率性能的影响。从图 10 可以看出，随着导频符号数目的减少，系统的误码率性能会随之下降，而且性能下降的程度与多普勒频移的大小有关。在归一化多普勒频移 $f_D = 0.01$ 时的低信噪比情况下，3 种不同导频符号数目具有十分相近的误码率性能；随着信噪比的改善，高导频符号密度带来的系统性能提升变得更加明显。此外，随着归一化多普勒频移从 0.01 增加到 0.03 和 0.07，高导频符号密度较低导频符号密度带来的误码率性能提升现象更明显。但是，总体而言，CE-ResNet 对导频符号密度的变化不十分敏感，在实际应用中能够通过适当降低导频符号数目，以较低的误码率性能损失换取系统频谱效率的提高。




图 10 不同导频符号数目情况下 CE-ResNet 的 BER 性能

在利用 4-QAM 符号对提出的 CE-ResNet 进行训练与性能验证的基础上，本文还采用 4-QAM 与 16-QAM 符号联合构成网络训练数据，对 CE-ResNet 进行训练。图 11 给出了基于 CE-ResNet 的双选择信道估计值，采用 16-QAM 调制时 GFDM 系统的 BER 性能。从图 11 可以看出，对于 16-QAM 调制，CE-ResNet 仍能够获得接近于 MMSE 信道估计时的 BER 性能。




图 11 16-QAM 调制情况下 CE-ResNet 的 BER 性能

5 结束语

本文对基于深度学习的 GFDM 系统时频双选择信道的估计进行研究，建立了基于残差学习的深度神经网络 CE-ResNet 进行 GFDM 系统信道估计。利用导频位置处信道时频响应的 LS 估计值构成低分辨率图像作为 CE-ResNet 的输入，由 CE-ResNet 恢复出相应的高分辨率图像，实现对 GFDM 系统时频双选择信道的估计；通过训练确定了 CE-ResNet 的最佳网络参数。仿真结果表明，CE-ResNet 能够获得接近于 MMSE 信道估计的精度与误码率性能，并且对多普勒频移具有很好的泛化性能。下一阶段的工作将主要集中在利用深度学习估计 GFDM 系统在双选择信道下的 ICI 和 ISI，从而进行有效的干扰消除。

参考文献：

[1] SHARMA S K, WANG X B. Toward massive machine type communications in ultra-dense cellular IoT networks: current issues and machine learning-assisted solutions[J]. IEEE Communications Surveys & Tutorials, 2020, 22(1): 426-471.
 [2] YANG H J, ZHANG K, ZHENG K, et al. Joint frame design and resource allocation for ultra-reliable and low-latency vehicular networks[J]. IEEE Transactions on Wireless Communications, 2020,

- 19(5): 3607-3622.
- [3] 吴虹, 刘兵, 赵迎新, 等. 广义频分复用通信系统抑制干扰技术[J]. 上海交通大学学报, 2017, 51(9): 1117-1123.
WU H, LIU B, ZHAO Y X, et al. Research on interference suppression in generalized frequency division multiplex system[J]. Journal of Shanghai Jiao Tong University, 2017, 51(9): 1117-1123.
- [4] 黄翔东, 王惠杰, 黎鸣诗, 等. GFDM 系统低复杂度最小均方误差接收机解调算法[J]. 北京邮电大学学报, 2019, 42(3): 7-13.
HUANG X D, WANG H J, LI M S, et al. Low-complexity MMSE demodulation algorithm for GFDM[J]. Journal of Beijing University of Posts and Telecommunications, 2019, 42(3): 7-13.
- [5] MICHAÏLOW N, MATTHÉ M, GASPAR I S, et al. Generalized frequency division multiplexing for 5th generation cellular networks[J]. IEEE Transactions on Communications, 2014, 62(9): 3045-3061.
- [6] VILAIORNISAWAI U, JIA M. Scattered-pilot channel estimation for GFDM[C]//Proceedings of 2014 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2014: 1053-1058.
- [7] EHSANFAR S, MATTHE M, ZHANG D, et al. Interference-free pilots insertion for MIMO-GFDM channel estimation[C]//Proceedings of 2017 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2017: 1-6.
- [8] EHSANFAR S, MATTHE M, ZHANG D, et al. Theoretical analysis and CRLB evaluation for pilot-aided channel estimation in GFDM[C]//Proceedings of 2016 IEEE Global Communications Conference (GLOBECOM). Piscataway: IEEE Press, 2016: 1-7.
- [9] LI F, ZHENG K, ZHAO L, et al. Design and performance of a novel interference-free GFDM transceiver with dual filter[J]. IEEE Transactions on Vehicular Technology, 2019, 68(5): 4695-4706.
- [10] JEONG J, PARK Y, WEON S, et al. Eigendecomposition-based GFDM for interference-free data transmission and pilot insertion for channel estimation[J]. IEEE Transactions on Wireless Communications, 2018, 17(10): 6931-6943.
- [11] 桂冠, 王禹, 黄浩. 基于深度学习的物理层无线通信技术: 机遇与挑战[J]. 通信学报, 2019, 40(2): 19-23.
GUI G, WANG Y, HUANG H. Deep learning based physical layer wireless communication techniques: opportunities and challenges[J]. Journal on Communications, 2019, 40(2): 19-23.
- [12] 梁应敞, 谭俊杰, NIYATO D. 智能无线通信技术研究概况[J]. 通信学报, 2020, 41(7): 1-17.
LIANG Y C, TAN J J, NIYATO D. Overview on intelligent wireless communication technology[J]. Journal on Communications, 2020, 41(7): 1-17.
- [13] YE H, LI G Y, JUANG B H. Power of deep learning for channel estimation and signal detection in OFDM systems[J]. IEEE Wireless Communications Letters, 2018, 7(1): 114-117.
- [14] SOLTANI M, POURAHMADI V, MIRZAEI A, et al. Deep learning-based channel estimation[J]. IEEE Communications Letters, 2019, 23(4): 652-655.
- [15] LI L J, CHEN H, CHANG H H, et al. Deep residual learning meets OFDM channel estimation[J]. IEEE Wireless Communications Letters, 2020, 9(5): 615-618.
- [16] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2016: 770-778.
- [17] HE K M, SUN J. Convolutional neural networks at constrained time cost[C]//Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2015: 5353-5360.
- [18] ZEILER M D, KRISHNAN D, TAYLOR G W, et al. Deconvolutional networks[C]//Proceedings of 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2010: 2528-2535.

[作者简介]



王莹(1968-), 男, 河北保定人, 博士, 大连海事大学教授, 主要研究方向为移动通信理论、无线自组网等。



任军(1997-), 男, 安徽淮北人, 大连海事大学硕士生, 主要研究方向为多载波通信技术。



史可(1998-), 女, 吉林榆树人, 大连海事大学硕士生, 主要研究方向为多载波通信技术。



林彬(1977-), 女, 辽宁大连人, 博士, 大连海事大学教授, 主要研究方向为无线网络优化理论。