•通信与信息工程•



多尺度残差注意力的高速铁路 OFDM 信道估计

陈 永*,蒋丰源,詹芝贤

(兰州交通大学电子与信息工程学院 兰州 730070)

【摘要】针对高速铁路正交频分复用 (OFDM) 通信系统在高速移动场景下,难以准确对快时变信道状态信息进行估计的 问题,提出了一种基于多尺度残差注意力网络的高速铁路 OFDM 信道估计方法。首先,设计多尺度信道特征提取结构,对 低分辨率信道矩阵采用多尺度多维特征提取,增强了信道不同尺度信息的提取能力。然后,构建残差注意力级联深度网络进 行信道特征重构映射,将局部残差反馈结合注意力机制促进深层特征的融合和利用,提升 OFDM 信道矩阵的重构映射能 力。最后,使用子像素卷积重构生成高分辨率信道矩阵,完成信道估计。通过频域和时域信道估计测试分析表明:在低速及 高速铁路场景下,该方法与其他方法相比,信道估计的精度和复杂度等客观性评价指标均优于比较算法,能够满足 OFDM 信道估计的要求。

关 键 词 信道估计; 深度残差注意力; 多尺度卷积神经网络; 正交频分复用系统; 超分辨率重构 中图分类号 TN911.72; TP391.9 **文献标志码** A doi:10.12178/1001-0548.2022205

Channel Estimation of OFDM in High-Speed Railway Based on Multi-Scale Residual Attention Network

CHEN Yong*, JIANG Fengyuan, and ZHAN Zhixian

(School of Electronic and Information Engineering, Lanzhou Jiaotong University Lanzhou 730070)

Abstract In order to solve the problem that it is difficult to accurately estimate the fast time-varying channel state information in orthogonal frequency division multiplexing (OFDM) communication system of high-speed railway in high-speed mobile scene, an OFDM channel estimation method based on multi-scale residual attention network was proposed. Firstly, we design the multi-scale channel feature extraction structure. For the low-quality channel matrix, we apply the multi-scale convolution kernel to extracting the shallow multi-dimensional feature information, which can improve the extraction performance of channel feature information with different scales. Then, a multi-scale residual attention cascade depth network is constructed for channel feature reconstruction and mapping. The local residual feedback is combined with CBAM (convolutional block attention module) attention mechanism to promote the fusion and utilization of deep features and improve the reconstruction and mapping ability of OFDM channel matrix. Finally, the sub-pixel convolution reconstruction is used to generate a high-resolution channel matrix to complete the channel estimation. The analysis in both frequency domain and time domain show that the proposed channel estimation method is better than other methods in terms of accuracy and complexity of channel estimation and can satisfy the needs of OFDM channel estimation.

Key words channel estimation; depth residual attention; multi-scale convolutional neural network; orthogonal frequency division multiplexing (OFDM) system; super resolution reconstruction

铁路无线通信系统的可靠性和稳定性,对于保 障高速铁路的安全运行至关重要。由于高速铁路运 营环境的复杂性和列车的高速移动性,极易受多径 和多普勒频移的影响,无线信道呈现出快时变性和 非平稳性的特点^[1]。当发射信号进入快时变信道传 播时,信道质量会变差,导致接收端难以准确获取 信道信息,严重破坏了高速铁路的无线通信环境^[2]。此时,接收端必须采取一定的信道估计补偿方法才能 准确恢复出发送端信号。信道估计是高速铁路正交 频分复用 (orthogonal frequency division multiplexing, OFDM) 系统关键技术,也是铁路无线通信系统进 行信道检测和均衡等操作的基础,其准确性和快速

收稿日期: 2022-06-24; 修回日期: 2022-10-26

基金项目: 国家自然科学基金 (61963023, 61841303)

作者简介: 陈永 (1979-), 男, 博士, 教授, 主要从事高可信无线通信方面的研究.

^{*}通信作者: 陈永, E-mail: edukeylab@126.com

性对提升铁路无线通信系统性能有着重要意义[3]。

传统信道估计算法分为盲估计和导频辅助估计 两种。其中, 盲估计算法根据接收信号统计先验特 征进行估计,该类方法因未插入额外导频信号,具 有较高的频谱利用率及负荷较小的优点。但盲估计 算法往往需要接收大量的发射信号来提取它们的统 计特性,导致其复杂度很高^[4]。而基于导频辅助的 估计算法需要在发射信号中提前插入辅助导频符 号,然后通过线性最小均方误差⁵³、离散傅里叶变 换法^[6]等算法恢复导频位置的信道状态信息 (channel state information, CSI),再通过插值算法恢复出所 需位置的 CSI。该类方法估计精度较高,假设信道 响应在一个 OFDM 周期内不发生变化^[7]。然而在列 车高速运行场景下,多径效应和多普勒频移引起信 道频率响应不断发生变化,导致传统信道估计性能 大幅度降低,难以满足高速运行场景下无线信道估 计的需求。

近年来,随着深度学习理论的快速发展,其被 广泛应用到诸多领域。在铁路无线通信系统中,深 度学习也被应用在信号检测图、信号编码图和信道 状态信息反馈^[10]等领域。由于信道矩阵与图像存 在一定的相似性,近几年出现了一些以图像重建和 恢复技术为基础的信道估计的深度学习算法。文 献 [11] 提出将信道矩阵看作二维自然图像,将信 道估计问题转化为图像处理问题,对其使用图像重 建技术进行信道估计。文献 [12] 提出了一种采用 近似消息传递去噪网络的信道估计方法,但该模型 存在特征提取尺度单一以及列车高速移动性条件下 噪声呈现较大差异性的特点,使得该方法难以有效 剔除噪声干扰。文献 [13] 提出了采用条件生成对 抗网络的信道估计方法,通过学习信道矩阵与导频 位置的信道矩阵之间的映射函数进行信道估计, 但 CGAN 模型存在模式崩塌的问题,导致难以获 得稳定解。文献 [14] 提出了 ChannelNet 模型对信 道进行估计,将导频处的信道频率响应视为低分辨 图像,通过超分辨率 (super resolution, SR) 重建网 络来恢复出完整信道,但该方法使用浅层神经网 络,存在信道特征提取不充分的问题。

综上所述,现有的信道估计方法在对 OFDM 系统信道估计时,存在尺度单一及特征提取不充 分,导致难以准确信道估计的问题。为此提出了一 种基于多尺度残差注意力网络的高速铁路 OFDM 信道估计方法。本文主要工作如下:1)将低质信道 矩阵采用多尺度卷积核,提取信道矩阵的浅层多维 特征信息,增强不同尺度信道特征信息的提取能力,克服了现在深度学习信道模型尺度提取单一的问题。2)提出残差注意力级联深度网络对信道特征进行重构映射,将局部残差反馈结合注意力机制(convolutional block attention module, CBAM)来促进信道图像深层特征的融合和利用,达到充分提取信道特征的目的,提升OFDM信道矩阵的重构映射能力。3)特征映射学习后,使用子像素卷积重构恢复生成高分辨率信道矩阵,从而完成信道估计。通过频域和时域信道估计实验表明:所提算法对OFDM 无线信道恢复的精确度和时间复杂度等客观性评价指标均优于对比算法,能够满足高速场景下正交频分复用 OFDM 通信系统的信道估计需求。

1 系统模型

1.1 OFDM 模型

OFDM 系统由发射机与接收机两部分组成, 在系统的发射端,对输入数据进行调制与串并转换 后,插入导频信息并进行子载波加扰与反向傅里叶 变换,然后加入循环前缀形成 OFDM 符号通过无 线信道进行传输。OFDM 系统的接收端为发射端 的逆过程,在对经过无线信道的数据去除循环前缀 后进行快速傅里叶变换,经过信道估计环节对其进 行均衡、解调等操作来对发送的数据进行恢复。

当列车高速运行时,接收端信号将会在一个 OFDM 符号内发生快速的周期性变化,OFDM 子载 波间正交性被破坏,出现子载波间干扰 (intercarrier interference, ICI) 现象,较长的 OFDM 符号周期会严 重影响信道估计的准确性^[15]。在时变信道中,一个 OFDM 发射符号在时域上表示为^[16]:

$$x[n] = \sum_{k=0}^{N-1} X[k] e^{j2\pi kn/N} \qquad n = 0, 1, \cdots, N-1 \quad (1)$$

为了防止 ICI 的发生,对发射符号加入循环前缀,OFDM 发射符号经过 *L* 条路径的无线信道之后接收信号可表示为:

$$y[n] = \sum_{i=0}^{L-1} h_i[n]x[n-\tau_i] + w[n]$$
(2)

式中, *h_i*[*n*]为第*i*条路径的信道脉冲响应; *τ_i*为第 *i*条路径的时延; *w*[*n*]为一个加性高斯白噪声。最 后,接收端移除循环前缀,得到接收信号 *y*[*n*]。为 了得到频域的接收信号,需要对式 (2)得到的 *y*[*n*] 继续进行傅里叶 FFT 操作:

$$Y[k] = \frac{1}{N} \sum_{n=0}^{N-1} y[n] e^{-j2\pi kn/N} =$$

$$\sum_{m=0}^{L-1} \sum_{i=0}^{N-1} X[m] H_i[k-m] e^{-j2\pi kn/N} + W[k]$$

$$k = 0, 1, \dots, N-1$$
(3)

式中, *W*[*k*] 为 *w*[*n*] 的傅里叶变换; *H_i*[*k*] 为脉冲响 应{*h_i*[*n*]}的傅里叶变换,为:

$$H_{i}[k] = \frac{1}{N} \sum_{n=0}^{N-1} h_{i}[n] e^{-j2\pi kn/N}$$
(4)

在高速移动场景下,信道频率响应在 OFDM 符 号周期内不断发生变化,此时信道矩阵 H 不再是一 个对角矩阵,变得难以求解^[17]。因此,需要采用信道 估计方法在接收端尽可能地还原发送端发送的原信 号,从而提高铁路无线通信系统的安全性和可靠性。

1.2 信道模型

无线信道是评估铁路无线通信系统的基础。 Jakes 信道能够很好地模拟出信号接收端以一定速 度运行时,发射信号经过运行环境反射效应后沿各 个方向到达接收端的过程。综合考虑高速铁路运行 环境的复杂性,本文利用 Jakes 信道模型来模拟无 线信道。Jakes 信道生成后,其实部和虚部分别为^[18]:

$$h_{\rm I}(t) = 2\sum_{n=1}^{N_0} (\cos \emptyset_n \cos \omega_n t) + \sqrt{2} \cos \emptyset_N \cos \omega_d t \qquad (5)$$

$$h_{\rm Q}(t) = 2\sum_{n=1}^{N_6} (\sin \emptyset_n \cos \omega_n t) + \sqrt{2} \sin \emptyset_N \cos \omega_d t \qquad (6)$$

式中, o_n 为初始相位; ω_d 为最大多普勒正弦信号的初始相位; N_0 为正弦波数量。Jakes 信道的复输出为:

$$h(t) = \frac{E_0}{\sqrt{2N_0 + 1}} \{ h_{\rm I}(t) + j h_{\rm Q}(t) \}$$
(7)

式中, *E*₀ 为衰落信道的平均幅度。随着信号接收 站的高速移动, *E*₀ 位置不断发生变化,信号的接收 角度也会发生改变,高速移动场景下的无线信道具 有非平稳性的状态特征。

2 本文算法

在高速铁路场景下,信号在一定周期内的相关 性将会发生变化,这时传统的信道估计算法对信道 估计的插值性能较差,信道估计结果的精度大大降 低^[11-12]。针对这一问题,本文提出一种基于多尺度 深度残差注意力网络的高速铁路 OFDM 信道估计 方法来提高信道估计性能。将导频位置处的信道状 态信息 CSI 等同于低分辨率图像上的像素点,然后 将提取后的导频位置的信道矩阵视为低分辨率 图像,然后通过提出的多尺度深度残差注意力信 道估计网络 (multi-scale residual attention channel estimation network, MSRACEN)对无线信道特征进 行端到端学习映射后重构生成高分辨率信道图像, 从而完成信道估计恢复任务。

2.1 网络整体模型

因为信道矩阵具有稀疏性,其中的元素均具有 高度相关性,所以可以将信道矩阵 H 视为二维的自 然图像且使用图像重建恢复技术对其进行处理^[11]。 在信道估计时,从时域和频域两个维度周期性的插 入导频,能够提高信道估计精度。因此,二维导频的 插入采用分散导频 (Scattered Pilot)的形式,如图 1 所示^[19]。



图 1 中, Δm为时域插入间隔,Δn为频域插入 间隔。对于插入二维导频后的矩阵,使用最小二乘 (least square, LS)信道估计算法获取导频位置处的 信道状态信息H_{LS},再将导频矩阵中的每一个元素 视为像素点,组合成一个大小为M×N的低分辨率 的二维图像H_{LR},经过上述处理,即可以得到本文 多尺度深度残差注意力 MSRACEN 重建网络模型 的低分辨率输入图像。

针对现有信道估计算法特征提取尺度单一和重 构精度差的问题,本文提出了多尺度深度残差注意 力信道估计 MSRACEN 网络,其深度学习模型结 构如图 2 所示。该模型主要由多尺度浅层特征提 取、深度残差注意力级联深层特征映射和子像素卷 积重构 3 部分组成。MSRACEN 模型工作时,首先 通过多尺度特征提取模块完成对导频位置处信道矩 阵的浅层特征的提取;然后提出残差注意力级联深 度网络对信道特征进行重构映射学习,完成对信道 矩阵的超分辨率重建;最后通过子像素卷积模块完 成了对信道矩阵的恢复,重构生成高分辨率信道图 像矩阵,从而完成对低质信道的估计。



2.2 多尺度浅层特征提取

本文 MSRACEN 网络模型中首先采用多尺度 浅层特征提取的方法来提取信道图像的多维特征信 息。现有信道估计算法中,大多数算法只采用单一 感受野在一个维度上进行信道浅层特征提取,但信 道矩阵图像特征信道往往具有不同尺度的特点。单 尺度卷积特征提取操作难以恢复出低质图像的高频 纹理数据^[20]。因此,为了充分提取低质信道图像特 征信息,本文模型中首先设计多尺度特征提取模块 对待恢复低质信道图像进行浅层特征提取,如图 3 所示。



图 3 中,对于待恢复的低分辨率信道图像分别 采用 1×1、3×3 和 5×5 这 3 种不同感受野尺度大小 的卷积核进行处理。卷积核可以将低分辨率信道图 像中一个小区域中的像素加权平均后,输出为对应 的像素。本文采用多尺度卷积核来提取不同分辨率 的信道特征信息,以克服现有信道估计模型特征提 取能力不足的问题。在多尺度卷积操作时,并采用 激活函数 (parametric rectified linear unit, PReLU)将 线性输入信号转换为非线性输出信号,以便神经网 络可以近似任何非线性函数将输入端的信道特征信 息映射到输出端,计算公式为:

$$\begin{cases} U_{11} = \sigma(W_{1\times 1}^{11} * M_{n-1} + b_{1\times 1}^{11}) \\ U_{12} = \sigma(W_{3\times 3}^{12} * M_{n-1} + b_{3\times 3}^{12}) \\ U_{13} = \sigma(W_{5\times 5}^{13} * M_{n-1} + b_{5\times 5}^{13}) \end{cases}$$
(8)

式中,*代表卷积算子; W和b代表每个神经元的权 值和偏重,其下角标代表卷积核的大小,上角标代表 不同层的位置; M_{n-1}代表多尺度残差连接模块的输 入; U代表每个分支的输出结果; σ代表 PReLU 激 活函数。在完成多尺度不同感受野特征提取后,然 后使用式 (9)的 Concat 融合和 1×1 卷积降维后,从 而得到信道低分辨率图像H_{LR}的浅层特征图 S,融 合和降维公式分别如下:

$$C_1 = [U_{11}, U_{12}, U_{13}] \tag{9}$$

$$\mathbf{S} = W_{1 \times 1}^4 * C_1 + b_{1 \times 1}^4 \tag{10}$$

式中, C₁代表 Concat 融合操作的特征; S 表示得到 的信道浅层特征图。随后,将浅层信道特征图 S 输 入到残差注意力级联深度网络中进行映射学习。

2.3 残差注意力级联特征映射

在信道估计网络中,随着网络的不断加深,特 征信息在传递过程中会被网络层逐渐忽略甚至遗 漏,以至于重建质量较差,蕴含在低分辨率图像中 丰富的特征信息没有得到很好的传递和充分利用, 限制了模型的性能。传统的深度残差网络是一种特 征提取网络,其内部采用残差映射模块来构建,如 图 4 所示^[21],其中跳跃连接用来缓解较深网络训练 时出现的梯度消失问题。



图 4 中, 传统残差网络模块中的每一层网络结构为卷积层+批归一化层 (batch normalization, BN) +PReLU+卷积层+BN 层。每个卷积操作完成后, 先通过 BN 层和激活函数实现对数据的归一化处理 与下一卷积核的输入映射,再使用 3×3 的卷积核对

H°再次进行信道特征矩阵的提取,最后通过跳跃 连接将输入数据直接传递到输出端将误差降低。残 差网络中每一层的映射公式为:

$$\boldsymbol{H}^* = F(\boldsymbol{X}) + \boldsymbol{H}^c \tag{11}$$

式中, H^c表示残差网络模型的输入数据; F(X)为深 度残差网络预测的差值: H*为输出的信道矩阵。

然而,在图4中的传统的残差网络在特征提取 时,仅使用 3×3 卷积核进行特征提取,单一的卷积 核尺寸无法获取全局和局部更细粒度的信道图像特 征信息。此外,在每个卷积操作后均使用 BN 层处 理,批归一化可以增加网络的容纳能力,然而在超 分辨率重构网络中使用归一化处理会破坏信道图像 的空间信息,导致重构效果较差^[22]。因此本文模型 在特征映射学习时,去除掉 BN 层,增加了多尺度 特征和注意力机制的提取,注意力机制可以让深度 学习网络更加充分地对信道有效信息的特征进行提 取,避免其他因素的干扰。为了降低快时变信道中 子载波间干扰和噪声等干扰因素对信道估计精度的 影响^[23],本文提出了一种残差注意力级联结构组, 由多粒度特征提取残差级联模块 (Res2Net)^[24] 与注 意力增强模块共同构成,如图5所示,用以改善噪 声等因素对信道估计精度的影响。



图 5 残差注意力级联结构组

在图 5 残差注意力级联结构模块中,本文采 用 Res2net 多粒度模块来替代图 4 中传统残差模块 中的 3×3 普通卷积操作,采用 Res2net 模块可以将 特征图以分组层级残差的形式进行连接,达到对特 征图不同粒度特征提取的目的。Res2net 特征提取 时,对于输入的浅层信道特征图S,先采用1×1卷 积操作得到 k 个特征子图, 然后将其划分为 i 个分 组,如图6所示。



Res2Net 多粒度特征提取模块 图 6

图 6 中每一组 x_i均使用 3×3 的卷积核得到相 应的输出y_i,获得y_i的过程如下:

$$y_i = \begin{cases} x_i & i = 1 \\ K_i(x_i) & i = 2 \\ K_i(x_i + y_{i-1}) & 2 < i \le s \end{cases}$$
(12)

式中, K_i代表每组 x_i通过大小为 3×3 卷积核的输 出。Res2Net 模块特征提取时,采用 3×3 卷积对分 组 x2进行特征提取,得到对应的特征提取结果 v₂,并将该结果输入到下层 x₃,再进行 3×3 卷积操 作,2次3×3卷积相当于初始的感受野从3×3变成 了 5×5,从而扩大了感受野的特征提取范围;然后 再依次输入到 x₄ 中,此时相当于通过 3 次 3×3 卷积, 感受野变成 7×7,再次以更大的感受野对低质信道 图像进行特征提取。上述采用 Res2Net 进行特征提 取操作克服了图 4 中传统 Resnet 残差模块仅采用 3×3卷积特征提取不足的问题。Res2net模块的实 现公式为:

$$\boldsymbol{Y} = f(\boldsymbol{S}, \boldsymbol{W}) \tag{13}$$

式中,**S**代表输入的浅层特征图;W代表模块中卷 积核的权值参数; Y 代表 Res2net 模块输出的信道 特征图像。

在信道估计过程中,由于环境的复杂性和信号 接收端的高速移动性,无线信道易受到噪声和其他 干扰的影响,导致在复杂环境或者低信噪比下误差 较大。深度学习中,通过注意力机制,可以将不同权 重分配给感兴趣目标,达到聚焦感兴趣目标的目 的。在本文所提模型中,为了在信道估计时将注意 力主要集中在信道矩阵中的有效数据部分,在残差 级联的基础上采用通道注意力和空间注意力模块 (convolutional block attention module, CBAM)^[25] 进 行有效特征的提取。在 CBAM 模块中,首先进行 通道注意力特征增强,如图7所示。对Res2Net输 出特征图 Y, 采用全局和平均双池化操作对数据进 行降维,然后经过双层 MLP 感知机特征提取相加 激活后,得到通道权重Mc,最后将权重与输入特征 图相乘,从而得到通道增强注意力特征图。



上述过程,采用式(14)计算:

$$M_{c}(\mathbf{Y}) =$$

$$\sigma(\text{MLP}(\text{AvgPool}(\mathbf{Y})) + \text{MLP}(\text{MaxPool}(\mathbf{Y}))) =$$

$$\sigma(W_{1}(W_{0}(Y_{\text{avg}}^{c})) + W_{1}(W_{0}(y_{\text{max}}^{c})))$$
(14)

式中, Y 代表 Res2Net 残差特征图输入; M_c为通道 权重系数; Y^c_{avg}和y^c_{max}为平均和最大池化操作; W₁ 和 W₀分别表示双层 MLP 感知机的权值。在通道 注意力的基础上,紧接着进行空间注意力增强,如 图 8 所示。将大小为 H×W×C 的特征图Y',先采用 最大和平均池化得到大小为 H×W×1 特征图,拼接 后再经过 7×7 的卷积层激活后得到空间注意力权重 系数M_s, 然后将该权重系数与通过增加后特征图 进行点乘,得到空间注意力增加的特征图。



上述空间注意力机制为:

$$M_s(\boldsymbol{Y}) = \sigma(f^{7*7}([Y_{\text{avg}}^s; y_{\text{max}}^s]))$$
(15)

式中, M_s 为空间注意力输出; $Y_{avg}^s \pi y_{max}^s$ 分别代表 平均和最大池化操作;f()表示 7×7 卷积操作; σ 为 sigmoid 激活函数。

上述 CBAM 注意力机制的处理过程分别为:

$$Y' = M_c(Y) \otimes Y \tag{16}$$

$$\mathbf{Y}^{\prime\prime} = M_s(\mathbf{Y}^\prime) \otimes \mathbf{Y}^\prime \tag{17}$$

式中,Y代表 CBAM 注意力机制的输入;M_c(Y)代 表一维的通道注意力图像;⊗代表逐元素相乘; Y'代表经过通道注意力机制处理后的信道特征图; M_s(Y')代表二维的空间注意力图;Y''代表 CBAM 注 意力输出特征图。

最后,再由Res2net模块对Y"进行卷积操作:

$$\boldsymbol{H}' = f(\boldsymbol{Y}'', \boldsymbol{W}') \tag{18}$$

式中, H'表示一个残差模块的输出; W'表示权值 参数。本文设计采用级联的方式构成残差模块,每 一层的残差块映射得到的特征都会与最开始的特征 进行级联,并传递到下一层:

$$X_n = C(H_{AB,n}(X_{n-1}), X_0)$$
(19)

式中, X_n表示第 n 个级联残差注意力模块的输出; C()表示级联操作; H_{AB,n}()表示第 n 个级联残差模块 中注意力机制的函数; X₀表示级联残差模块的输入。采用上述级联结构,能够充分实现低质信道图像到高分辨率信道图像的端到端映射学习。

2.4 子像素卷积信道重构恢复

经过残差注意力级联深度网络信道特征映射学 习后,在本文 MSRACEN 网络模型末端采用子像 素卷积操作进行高分辨率信道图像重构,即将得到 的残差级联低分辨率信道特征图输入到子像素卷积 模块中进行恢复。重构过程主要对非线性映射层获 得的特征图进行上采样和聚合,使用子像素卷积来 代替反卷积对特征图片进行上采样。使用子像素卷积来 代替反卷积对特征图片进行上采样。使用子像素卷积来 代替反卷积对特征图片进行上采样。使用子像素卷积模型对图像进行超分辨扩大时不同于传统的超分 辨扩大尺度的方法,传统方法通常使用反卷积操作 对图像进行扩大操作,这种操作方法由于引入过多 的人工因素,易使放大后的图像产生明显误差,而 子像素卷积模型中的卷积参数通过样本学习获得, 使模型的放大性能更加精确,可以更好地拟合图像 中像素与像素之间的关系。子像素卷积是一种基于 学习的超分辨扩大图像尺度的方法,如图9所示^[26]。



图 9 中,子像素卷积模块由一个大小为 3×3 的 卷积核及子像素卷层组成。首先通过 3×3 卷积核对 深度残差级联注意力特征图扩大通道数。在子像素 卷积扩大恢复时,若恢复图像放大因子为r,则对 应卷积核数为 r²,将低质信道特征图中每个像素 的 r² 个通道映射为高分辨率图像中 r×r 大小的图 像块。迭代通过上述操作,从而将大小为 r²×H×W 的低分辨率信道特征图像,被重构生成大小为 1×rH×rW的高分辨率图像,从而完成超分辨率信 道估计目的。恢复过程为:

$$\boldsymbol{H}^{\prime\prime} = f(\boldsymbol{W}^{\prime\prime}, \boldsymbol{H}^{\prime}) \tag{20}$$

式中, H"代表估计的信道矩阵图像; H′代表通过 浅层特征提取模块和残差模块所获得的信道特征图 像; f()代表子像素卷积模型对H′进行的各种处 理; W″代表子像素卷积模型中的权值参数。通过 式 (20) 得到最终的高分辨率重构信道矩阵图像, 从而完成低质信道矩阵的重构估计恢复。

2.5 损失函数

本文所提方法选取 MSE 作为目标函数,计算 估计出的信道高分辨率矩阵与最优估计 *H* 的均方 误差为:

$$L(\theta) = \frac{1}{S} \sum_{I=1}^{S} \left(\boldsymbol{H}^{L} - \boldsymbol{H} \right)^{2}$$
(21)

式中, S为对模型进行训练所输入的总样本数; H^L为高分辨率信道估计输出矩阵。

3 实验结果与分析

3.1 评价指标

为收集对本文 MSRACEN 网络模型进行离线 训练所需要的数据集,通过 MATLAB 模拟随机地 生成数据序列作为传输符号并在传输符号中添加固 定的导频符号,使用 LS 算法收集导频位置处的信 道矩阵作为训练数据,对模型进行训练减少误差。 随机生成的二进制比特流由 Jakes 信道模型产生并 且采用 16OAM 的星座调制^[17]。为训练本文算法网 络,首先经过 Jakes 无线信道模拟生成随机数据序 列作为传输符号,并在传输符号中添加导频符号形 成相应的 OFDM 帧,二维导频的插入采用分散导 频的形式,将导频处的信道估计值 H_{IS}和最 优估计 H 收集为训练数据,当初始训练学习率为 0.000 1, Batchsize 为 300 时, 训练时间为 570 s。 为了综合评估本文网络模型对信道的估计性能,对 本文方法与 LS 算法[27]、线性最小均方误差 (linear minimum mean squared error, LMMSE) 算法^[5]、 ChannelNet^[14] 算法进行仿真对比。此外,为了综合 评估本文方法的信道估计性能,将分别收集通过频 域与时域两种类型的信道估计算法获得的导频处 的 CSI。不同方法定量客观评价时,使用归一化均 方误差 (normalized mean-square error, NMSE) 作为 信道估计性能评价指标,公式为:

$$\text{NMSE} = \text{E}\left\{\frac{\left\|\boldsymbol{H}^{L} - \boldsymbol{H}\right\|_{2}^{2}}{\left\|\boldsymbol{H}\right\|_{2}^{2}}\right\}$$
(22)

3.2 分析对比

好的信道估计算法就是使估计误差较小,同时 保持较低的复杂度^[3,7]。信道估计分为时域和频域估 计两种,其中频域方法从幅度和能量分布角度对信 道状态进行分析;而时域方法主要实现衰落信道中 衰落系数的分析。为了对本文算法进行全面地分析 对比,分别对时域和频域进行不同信道估计方法的 比较。首先使用在频域方案下进行信道估计的 LS 算法获取无线信道导频位置的信道频率响应作 为数据集,对本文算法和 ChannelNet 进行训练, 将它们的测试结果与 LS 算法和 LMMSE 算法进行 对比。在频域对比完成后,再收集在时域方案下进 行的信道估计的 BEM-LS 算法^[28]获取的导频位置 信道冲激响应作为数据集进行训练,将测试结果 与 BEM-LS 算法和 BEM-UKF算法^[29]进行对比。

3.2.1 频域分析对比

首先进行不同车速下信道频域估计的比较,选择的对比速度均为低速 50 km/h 和高速 300 km/h,对 LS 算法、LMMSE 算法、ChannelNet 算法和本 文算法进行仿真分析,各个算法在不同速度下的归 一化均方误差如图 10 和图 11 所示。



图 10 中,在低速 50 km/h 环境下,从信噪比 增益的角度对比上述算法,LMMSE 算法信噪比 (signal-noise ratio, SNR) 增益比 LS 算法高大约 7 dB, 这是因为 LS 算法在信道估计时,算法过于理想 化,忽略了噪声对信道产生的影响,由于缺少对先 验信道特性的考虑导致其精度较低,而LMMSE 算 法能够充分利用先验统计信息来提高估计的精度。 ChannelNet 网络的信噪比增益比 LMMSE 算法高 约11 dB。而本文方法又比 ChannelNet 方法提高了 约10 dB, 其原因为较LMMSE 算法, ChannelNet 使用深度学习特征提取功能,可以更好地跟踪信道 的频率响应,但由于 ChannelNet 只使用了单尺度 卷积核来对信道矩阵进行特征提取,存在感受域较 小的问题,对信道矩阵的特征捕捉能力有较大的局 限性。而本文方法采用多尺度特征、局部残差反馈 结合 CBAM 注意力机制促进深层特征的融合和利 用,提升了 OFDM 信道矩阵的重构映射能力,能 够有效降低对无线信道进行估计产生的误差,其估 计精度在4种方法中最高,估计结果更接近于克拉 美罗界 (Cramér-Rao bound, CRB), 距离 CRB 约有 4 dB 的差距。

高速环境下,不同方法频域性能估计比较如 图 11 所示。可以看出,LS 算法和 LMMSE 算法在 高速 300 km/h 环境下,随着 SNR 的增加,其归一化均 方误差 NMSE 下降不明显,说明在高速环境下上 述两种方法估计性能变差,误差增加,继而说明上 述两种信道估计算法并不适用于高速场景。而本文 算法在高速环境下,较其他 3 种方法同样具有较好 的性能,距离 CRB 约有 5 dB,更加逼近于 CRB。 与低速环境下相同,本文 NMSE 均呈现出下降趋 势,说明本文算法对于高速铁路在不同场景中的适 应性更好。

此外,综合图 10 和图 11 在低速和高速频域信 道估计可以看出:随着 SNR 的增大,在低速环境 下,4种算法都呈现出下降的趋势,这是因为 SNR 为信号与噪声的功率比值, SNR 值越大说明信道 质量越好,即受到噪声污染的程度越低,因此4种 算法 NMSE 均呈现出下降的趋势,而预测的精度 相反会逐渐提高。但在高速环境,随着 SNR 的增 大,LS和LMMSE等方法下降趋势较慢,即高速 环境下 LS 和 LMMSE 方法无法完成对于信道的准 确估计,这是因为列车在高速行车条件下,受多普 勒频移影响,信道出现严重的载波间干扰问题, 而 LS 算法未考虑噪声影响,所以其估计精度有 限。LMMSE 属于线性估计算法,其利用频域上各 个子载波之间的信道有相关性这一特点来提高信道 估计精度,然而在高速环境下,无线信道的质量急 剧恶化,在这种快衰落信道情况下,各个子载波之 间的信道相关性被破坏,LMMSE 很难实现信道的

预测^[30]。而本文方法无论是在低速或者高速环境 下,采用多尺度残差注意力信道估计以及子像素卷 积去噪,其信道估计精度均优于其他方法,本文方 法估计精度更高。

3.2.2 时域分析对比

在完成频域信道估计性能比较后,为了进一步 验证本文方法的有效性,进行时域方案不同方法的 比较分析,对比结果如图 12 和图 13 所示。





在图 12 中,低速 50 km/h环境下,BEM-LS 算法和 BEM-UKF 算法对信道进行估计的 NMSE 性能相差并不大,其中 BEM-UKF 算法的信噪比增 益比 BEM-LS 算法高大约 5 dB,本文算法较 CRB 高约 6 dB。这是因为在低速场景下,BEM-LS 算法 与 BEM-UKF 算法均以基扩展模型为基础进行信道 估计,在低速环境下受多普勒频移影响较小,采用 基扩展 BEM 估计方法,均能得到导频符号周期内 的 BEM 系数,两种算法均具有较好的估计精度。 而 ChannelNet 算法在低信噪比时性能较差,这是 由于在低信噪比 SNR 条件下,此时信道中噪声较多, 而 ChannelNet 采用浅层网络进行特征提取,在特征提取时采用三层卷积层进行特征提取,较浅的网络层数在噪声较多干扰环境下难以有效提取到信道特征,导致估计结果较差。所提方法与 ChannelNet 浅层模型相对比,本文深度残差网络模型可以更加 有效地对信道特征进行挖掘和提取,采用残差级联 结构能够较好的解决网络中梯度弥散和精度下降的 问题。此外从图 12 整体趋势来看,本文算法在低 速时域环境下,无论在低信噪比还是高信噪比的情 况下,其信道估计的精度和性能均优异于其他 3 种 比较方法。

从图 13 可以看出,在高速场景 300 km/h 时, BEM-UKF 算法的估计精度下降不大,而 BEM-LS 算法的信道估计精度大大降低,其原因为同样在高 速环境下,子载波间干扰问题导致 BEM-LS 估计 方法无法在信道估计环节有效消除信道干扰。而采 用无迹卡尔曼滤波器的 BEM-UKF 算法比 BEM-LS 有更高的估计精度,这是因为无迹卡尔曼滤波器 BEM-UKF 模型通过无迹变换的方法,能够对信道 冲激响应的实时变化进行跟踪,因此在高速场景下 也具有一定的精度。高速环境下, ChannelNet 较低 速估计性能有所降低,而本文方法在高速移动场景 下进行的时域信道估计,与 CRB 更加逼近,较其 他算法相比有更高的估计性能,因为本文采用多尺 度特征提取,以及残差注意力级联结构更容易学习 到导频估计值与理想信道之间的复杂映射关系,可 以更好地拟合信道中不同导频之间的关系。

3.2.3 导频位置对 NMSE 的影响

综上时域和频域分析,可以得出所提方法在频 域和时域上均取得了较好的信道估计能力。为了进 一步体现本文算法在不同的导频位置下的信道插值 性能,分别在导频间隔为3和导频间隔为6的情况 下,使用不同的插值算法进行信道插值,得到的结 果如图 14 所示。



从图 14 可以看出,在相同的信噪比下,不同方 法导频间隔越小,其归一化均方误差 NMSE 值越 低。如图 14 中导频间隔为 3 的信号 NMSE 小于导频 间隔为 6 的信号,其原因为当导频间隔较大时,对 信道状态信息的采样密度将会减小,导频间信道状 态信息的相关性变弱,使估计误差增大^[31]。将本文 算法与基于深度残差超分辨重建网络^[32]的插值算 法进行对比,可以看出本文算法的估计精度更高, 这是因为本文算法采用多尺度特征提取与注意力机 制对信道状态信息进行处理,可以提取更充分的信 道特征,并采用注意力机制能够更有效的抑制无关 信息的干扰,因此其估计精度更高。

3.2.4 复杂度比较

高速移动场景下,对信道估计算法的时间复杂 度提出了更高的要求。表1给出了不同信道估计算 法的时间复杂度值,其中基扩展模型进行信道估计 的复杂度表达式中,Q为用来拟合信道的基函数的个数, L为多径数,N为子载波个数。对于基于深度学习模 型的算法复杂度分析,通常以深度学习网络前馈运 行的乘法与加法次数作为复杂度分析度量^[18]。

表1 不同算法复杂度

| 名称 | 乘法计算次数 | 复杂度 |
|------------|------------------------|--------------|
| LS | Ν | O(N) |
| LMMSE | $3N^3 + N^2$ | $O(N^3)$ |
| BEM-LS | $4(QL)^2N+QLN$ | $O((QL)^2N)$ |
| BEM-UKF | $3N^2QL+25(QL)^2N$ | $O(N^2 QL)$ |
| ChannelNet | $107N^2 + 23N$ | $O(N^2)$ |
| 本文方法 | 545N ² +26N | $O(N^2)$ |

从表1可以看出,LS估计算法因仅在各导频子载波上进行一次除法运算,其时间复杂度最低,总计算次数为子载波数量 N,算法复杂度大小为O(N), 但通过频域和时域性能分析,该方法的信道估计性能最低。LMMSE 的复杂度最高,因为该方法在信 道估计时,需要求解大量自相关矩阵求逆运算,导 致其计算量较大,计算次数为 3N³+N²,算法复杂 度为O(N³)。基扩展 BEM-LS 方法采用基扩展模型 中基函数与多径数和 LS 算法完成信道估计,计算 次数为 4(*QL*)²N+*QLN*,其算法复杂度为O((*QL*)²N)。 而基扩展 BEM-UKF 方法采用正交基函数的线性组 合和卡尔曼滤波算法来降低运算复杂度,计算次数 为 3N²*QL*+25(*QL*)²N,其算法复杂度为O(N²*QL*), 但因为基扩展模型的阶数远小于信道的长度,降低 了其复杂度,其复杂度低于 LMMSE算法。 ChannelNet 网络和本文算法复杂度均低于 LMMSE 算法和 BEM-UKF 算法, ChannelNet 网络 的计算次数与复杂度分别为 107N²+23N和 O(N²), 而本文所提算法计算次数为 545N²+26N,算法复杂 度为O(N²)。虽然 ChannelNet 网络和本文 MSRACEN 网络的复杂度接近,但本文模型使用深度残差级联 网络来对低质信道进行超分辨重构,并采用子像素 卷积进行恢复,既保证了精度又保证了速度。综合 性能分析和复杂度比较,本文所提方法具有更好的 性能和更高的信道估计精度。

4 结束语

针对高速铁路正交频分复用 OFDM 通信系统,使用现有的信道估计算法时,存在信道估计误差较大及特征提取不充分的问题,提出一种基于多尺度深度残差网络的高速铁路 OFDM 信道估计方法。结果表明,本文方法对低质信道矩阵采用多尺度残差注意力级联深度网络进行信道特征重构映射,将局部残差反馈结合 CBAM 注意力机制促进深层特征的融合和利用,增强了不同尺度信道特征信息的提取能力,克服了现有信道估计方法特征提取尺度单一和特征提取不足的问题。并在时域和频域测试下,其信道估计精度均优于比较方法。而且,其时间复杂度较低,能够更好地满足信道估计的要求。研究结果对于 OFDM 系统的信道估计器的设计提供了一定的参考依据。

本文研究工作得到兰州交通大学天佑创新团队项目 (TY202003)、兰州交通大学基础研究拔尖人 才项目 (2022JC36) 的资助,在此表示感谢。

参考文献

- TRIPATHI P, SHUKLA S K, BHATT A. Performance of channel estimating approach in mobile OFDM system [C]//2021 International Conference on Advances in Electrical, Computing, Communication and Sustainable Technologies (ICAECT). Bhilai, India: IEEE, 2021: 1-4.
- [2] 徐岩, 丁峰. LTE 高铁环境下 OFDM 载波间干扰消除优 化研究[J]. 铁道学报, 2020, 42(10): 87-91.
 XU Y, DING F. Research on improved of OFDM intercarrier interference elimination in high-speed railway LTE environment[J]. Journal of the China Railway Society, 2020, 42(10): 87-91.
- [3] 李倩, 王公仆, 李清勇, 等. 适应高速铁路场景的新型基扩展信道估计模型[J]. 铁道学报, 2017, 39(9): 81-88.
 LI Q, WANG G P, LI Q Y, et al. A new basis expansion model for channel estimation in high-speed railway scenario[J]. Journal of the China Railway Society, 2017,

39(9): 81-88.

- [4] PARK M C, HAN D S. Deep learning-based automatic modulation classification with blind OFDM parameter estimation[J]. IEEE Access, 2021, 9: 108305-108317.
- [5] WU H. LMMSE Channel estimation in OFDM systems: A vector quantization approach[J]. IEEE Communications Letters, 2021, 25(6): 1994-1998.
- [6] MA L, LI T, LIU S, et al. Efficient interpolation based OMP for sparse channel estimation in underwater acoustic OFDM[J]. Applied Acoustics, 2021, 172(1): 107606.
- [7] LIU Y, TAN Z, HU H, et al. Channel estimation for OFDM[J]. Communications Surveys & Tutorials IEEE, 2014, 16(4): 1891-1908.
- [8] EMIR A, KARA F, KAYA H, et al. Deep learning-based flexible joint channel estimation and signal detection of multi-user OFDM-NOMA[J]. Physical Communication, 2021, 48: 101443.
- [9] HUSAIN B, MOHAMED H, HAERING L, et al. Deep learning-based multi-tone interference suppression for short polar codes[C]//2021 IEEE 93rd Vehicular Technology Conference (VTC2021- Spring). [S.I.]: IEEE, 2021: 1-5.
- [10] DEHMOLLAIAN E, ETZLINGER B, TORRES N B, et al. Using channel state information for physical tamper attack detection in OFDM systems: A deep learning approach[J]. IEEE Wireless Communications Letters, 2021, 10(7): 1503-1507.
- [11] YANG J, WEN C K, JIB S, et al. Beamspace channel estimation in mmWave systems via cosparse image reconstruction technique[J]. IEEE Transactions on Communications, 2018, 66(10): 4767-4782.
- [12] HEH T, WEN CK, JIN S, et al. Deep learning-based channel estimation for beamspace mmWave massive MIMO systems[J]. IEEE Wireless Communication Letters, 2018, 7(5): 852-855.
- [13] LI X F, ALKHATEEB A, TEPEDELENLIOGLU C. Generative adversarial estimation of channel covariance in vehicular millimeter wave systems[C]//Proceedings of the 2018 52nd Asilomar Conference on Signals, Systems, and Computers. Pacific Grove, CA: [s.n.], 2018: 1572-1576.
- [14] SOLTANI M, POURAHMADI V, MIRZAEI A, et al. Deep learning-based channel estimation[J]. IEEE Communications Letters, 2019, 23(4): 652-655.
- [15] 王妮娜, 桂冠, 苏泳涛, 等. 基于压缩感知的 MIMO-OFDM 系统稀疏信道估计方法[J]. 电子科技大学学报, 2013, 42(1): 58-62.
 WANG N N, GUI G, SU Y T, et al. Compressive sensing-based sparse channel estimation method for MIMO-OFDM systems[J]. Journal of University of Electronic Science and Technology of China, 2013, 42(1): 58-62.
- [16] 季策,张晓.基于 GSA-BP 神经网络的 OFDM 系统信道 估计算法[J]. 东北大学学报 (自然科学版), 2022, 43(6): 769-775.
 JI C, ZHANG X. Channel estimation algorithm of OFDM system based on GSABP neural network[J]. Journal of Northeastern University (Natural Science), 2022, 43(6): 769-775.
- [17] CHO H, NGUYEN T H, NGUYEN H N, et al. A robust

ICI suppression based on an adaptive equalizer for very fast time-varying channels in LTE-R systems[J]. EURASIP Journal on Wireless Communications and Networking, 2018(1): 1-7.

- [18] 邵凯, 陈连成, 刘胤. 高移动性 Jakes 信道的学习与估 计[J]. 系统工程与电子技术, 2021, 43(4): 1119-1125. SHAO K, CHEN L C, LIU Y. Learning and estimation of high mobility jakes channel[J]. Systems Engineering and Electronics, 2021, 43(4): 1119-1125.
- [19] 王熙宇. 高速无线通信系统的快时变信道估计[D]. 北京: 北京交通大学, 2018.
 WANG X Y. Fast time-varying channel estimation for wireless communication systems on high speed railways[D]. Beijing: Beijing Jiaotong University, 2018.
- [20] HU Y, GAO X, LI J, et al. Single image super-resolution with multi-scale information cross-fusion network[J]. Signal Processing, 2021, 179: 107831.
- [21] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. [S. 1.]: IEEE, 2016: 770-778.
- [22] XIE S, YANG T. Artifact removal in sparse-angle CT based on feature fusion residual network[J]. IEEE Transactions on Radiation and Plasma Medical Sciences, 2020, 5(2): 261-271.
- [23] LIU S, GAO Z, ZHANG J, et al. Deep denoising neural network assisted compressive channel estimation for mmWave intelligent reflecting surfaces[J]. IEEE Transactions on Vehicular Technology, 2020, 69(8): 9223-9228.
- [24] GAO S H, CHENG M M, ZHAO K, et al. Res2net: A new multi-scale backbone architecture[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 43(2): 652-662.
- [25] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision (ECCV). Munich: [s.n.], 2018: 3-19.
- [26] SHARMA P K, BASAVARAJU S, SUR A. High-

Resolution image de-raining using conditional GAN with sub-pixel upscaling[J]. Multimedia Tools and Applications, 2021, 80(1): 1075-1094.

- [27] ASTAWA I G P, PERTIWI B. LS and MMSE estimation channel techniques for DVB-T2 system based on MIMO-OFDM[C]//2021 IEEE 5th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE). [S.I.]: IEEE, 2021: 257-261.
- [28] WANG G, GAO F, CHEN W, et al. Channel estimation and training design for two-way relay networks in timeselective fading environments[J]. IEEE Transactions on Wireless Communications, 2011, 10(8): 2681-2691.
- [29] 卢娜,高丽,沈轩帆.基于无迹卡尔曼滤波的双选信道估 计算法[J].山东大学学报(工学版), 2019, 49(4): 130-136.

LU N, GAO L, SHEN X F. Double-Selection channel estimation method based on unscented kalman filter[J]. Journal of Shandong University (Engineering Edition), 2019, 49(4): 130-136.

- [30] KUNDU N K, MCKAY M R. Channel estimation for reconfigurable intelligent surface aided MISO communications: From LMMSE to deep learning solutions[J]. IEEE Open Journal of the Communications Society, 2021, 2: 471-487.
- [31] 刘紫燕, 马珊珊, 梁静, 等. 注意力机制 CNN 的毫米波大规模 MIMO 系统信道估计算法[J]. 系统工程与电子技术, 2022, 44(1): 307-312.
 LIU Z Y, MA S S, LIANG J, et al. Attention mechanism based CNN channel estimation algorithm in millimeter-wave massive MIMO System[J]. Systems Engineering and Electronics, 2022, 44(1): 307-312.
- [32] LEDIG C, THEIS L, HUSZAR F, et al. Photo-Realistic single image super-resolution using a generative adversarial network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. [S.1.]: IEEE, 2017: 4681-4690.

编辑税红