DOI:10.20079/j.issn.1001-893x.220817001

基于宽深超分辨率网络的信道估计方法*

谢 朋,钱蓉蓉,任文平

(云南大学 信息学院,昆明 650500)

摘 要:在正交频分复用(Orthogonal Frequency Division Multiplexing, OFDM)系统中由于快衰落导致 信道特征不连续,常规的信道插值方法无法准确反应导频与整个信道之间的关联性。针对这一问 题,提出了一种基于宽深超分辨率(Wide Deep Super-resolution, WDSR)网络的信道估计方法,把导频 值通过最小二乘估计(Least Squares, LS)初步插值,再通过 WDSR 网络再次放大重构整个信道的响 应。将信道估计插值上采样替换成初步插值和图像超分辨率上采样两步。仿真结果表明,与超分辨 率卷积神经网络(Super-resolution Convolutional Neural Network, SRCNN)信道估计算法相比,在不同 种类的信道以及导频数下 WDSR 信道估计方法均方误差性能提升约4.6 dB。

关键词:OFDM 系统:信道估计:宽深超分辨率(WDSR)网络;超分辨率卷积神经网络(SRCNN)

开放科学(资源服务)标识码(OSID);



中图分类号:TN911.72 文献标志码:A 文章编号:1001-893X(2024)01-0132-07

Channel Estimation Based on Wide Deep Super-resolution(WDSR) Network

XIE Peng, QIAN Rongrong, REN Wenping

(School of Information Science and Engineering, Yunnan University, Kunming 650500, China)

Abstract: In an orthogonal frequency division multiplexing(OFDM) system, the channel characteristics are discontinuous due to fast fading, and the conventional channel interpolation method cannot accurately reflect the correlation between the pilot and the entire channel. To solve this problem, a channel estimation method based on Wide Deep Super-resolution(WDSR) network is proposed. The pilot value is preliminarily interpolated through Least Squares(LS) estimation, and then the response of the whole channel is amplified and reconstructed again through WDSR network. The channel estimation interpolation upsampling is replaced by two steps of preliminary interpolation and image super-resolution upsampling. The simulation results show that compared with the Super-resolution Convolutional Neural Network (SRCNN) channel estimation algorithm, the mean square error performance of WDSR channel estimation method is improved by about 4.6 dB under different types of channels and pilot frequencies.

Key words: OFDM system; channel estimation; wide deep super-resolution (WDSR) network; super-resolution convolutional neural network(SRCNN)

0 引 言

正交频分复用(Orthogonal Frequency Division Multiplexing, OFDM)作为通信中一种重要的抗多径 技术也是 5G 的关键技术之一,成为了目前重要的

研究对象。在 OFDM 传输的过程中, 阴影衰落、传输路径中的损耗, 以及多径影响, 都有可能造成信号的畸变, 影响通信系统的性能, 这就要求要获得准确的信道状态信息(Channel State Information, CSI)^[1],

· 132 ·

 ^{*} 收稿日期:2022-08-17;修回日期:2022-09-11
 基金项目:国家自然科学基金青年科学基金项目(61701433);云南省科技厅面上项目(2018FB099)
 通信作者:线蓉蓉 Email:r. qiang@ ynu. edu. cn

用于均衡和补偿信道的衰落。因此信道估计在此过 程中显得尤为重要,信道估计的精度直接影响到了 整个通信系统的性能。

信号传输过程十分复杂,干扰严重,导致信号失 真^[2],给信道估计过程带来了挑战。随着计算机性 能的提升,神经网络在数据处理方面体现出了强大 的优势,目前已有研究将神经网络算法应用在无线 通信领域,如信道估计^[3-10]、信号检测。文献[3]将 无线信道视作黑盒,利用深度神经网络(Deep Neural Network, DNN) 以端到端的方式模拟信道传 输特征。文献[4]对文献[3]的工作做了进一步改 进,使用 DNN 加长短期记忆人工神经网络(Long Short-Term Memory,LSTM)代替原本的全连接 DNN 网络,端到端地恢复出原始符号。这种设计使网络 参数大幅缩减,收敛速度进一步加快。文献[5]提 出基于反向传播(Back Propagation, BP)神经网络的 信道估计算法,通过离线的信道数据训练拟合信道 特征。文献[6]提出使用集成神经网络将信道估计 过程映射为含噪导频信号与原始导频信号之间的非 线性关系构建,并结合差异度对其进行集成。文献 [7]提出将系统的通道响应作为二维图像处理,把 信道估计问题转换为二维图像处理问题。文献[8] 同样将信道矩阵当作二维矩阵,通过对信道矩阵进 行插值,再通过超分辨率卷积神经网络[9]重构信道 矩阵,但是其网络结构简单,得出的效果并不令人满 意。文献[10]针对时变信号提出了基于超分辨率 生成对抗网络 (Super-resolution Generative Adversarial Network, SRGAN)的信道估计方法,代替 了信道估计中的插值处理。但是该方法需要的导频 过多降低了频带的利用率,并且对数据的规格有一 定的限制,不适用于标准 OFDM 信号。

针对 OFDM 系统中的快速衰落信道,本文提出 了一种基于宽深超分辨率(Wide Deep Superresolution,WDSR)网络^[11]的信道估计算法,把传统 信道估计插值方法与深度学习超分辨率方法结合, 将上采样分为插值和深度学习超分辨率两步替代以 往的一步插值上采样方法,将 LS 信道估计算法初步 上采样得到的估计值作为低分辨率图像,通过离线 训练的方式来训练网络调整参数,利用图像超分辨 率的方法再次放大重构出高分辨率图像,即整个信 道的高精度信道矩阵。算法通过 LS 信道估计初步 上采样的预处理方法,解决了文献[10]在快衰落中 对导频估计值直接通过网络放大带来的导频开销过 大以及数据规格限制问题,并且 WDSR 网络相比之 前提出的 SRCNN 方法对信道特征的提取能力更 强,采用了残差网络能够更加准确地学习到导频与 真实值之间的映射关系,更准确地重构信道。实验 结果表明,所提算法相比常用的传统算法以及 SRCNN 算法提高了信道估计的精确度。

1 系统模型

考虑如图 1 所示的 OFDM 系统,发送端发送的 数据由一系列随机生成的二进制序列组成,在传输 过程中由于通信过程中的干扰和噪声导致发送端和 接收端之间的信道响应失真,通常会在 OFDM 信号 中插入导频,导频的位置以及数值完全已知。插入 导频后对数据进行符号调制把数据分割到不同频率 的载波上(OFDM 子帧中有 N_s 个子载波以及 N_p 个 OFDM 符号),然后对数据进行快速傅里叶逆变换 (Inverse Fast Fourier Transformation, IFFT)变换。由 于通信中存在符号间干扰(Inter-symbol Interference, ISI)以及子载波干扰(Inter-carrier Interference, ICI), 需要在 OFDM 符号中加入循环前缀(Cyclic Prefix, CP),得到发送端数据 X_o



Fig. 1 OFDM system architecture

对于 OFDM 信号第 k 个时隙上的第 i 个子载波 发送端信号 $X_{i,k}$,其与接收端信号 $Y_{i,k}$ 之间的关系 可以由式(1)表达:

$$\boldsymbol{Y}_{i,k} = \boldsymbol{H}_{i,k} \boldsymbol{X}_{i,k} + \boldsymbol{Z}_{i,k} \tag{1}$$

式中:OFDM 子帧的结构为 (N_s, N_p) 时间索引 k 的 取值范围是 $(0, N_p-1)$;子载波索引 i 的取值范围是 $(0, N_s-1)$; $X_{i,k}$ 代表传输信号; $Y_{i,k}$ 代表接收信号; $Z_{i,k}$ 代表高斯白噪声; $H_{i,k}$ 代表对应时隙和子载波 的信道响应; $H \in \mathbb{C}^{N_s \times N_p}$ 是整个信道的信道响应。 在得到接收信号 Y 后去除 CP,并且进行快速傅里叶 变换(Fast Fourier Transform, FFT),再利用信道估计 得到的估计信道响应 \hat{H} 求得发送信号的估计值,最 后通过解调可以得到相应的数据二进制序列。信道 估计就是要利用已知的导频值求解 \hat{H} ,使其尽量接 .133. 近于真实的信道响应H。

2 基于 WDSR 的信道估计算法

在先前的研究中, Soltani 等人^[8]将 SRCNN 应 用于信道估计问题中, 然而并不是所有的超分辨率 网络都适用于信道估计问题, 例如增强可变形卷积 网络(Enhanced Deformable Convolutional Networks, EDVR)^[12]过于注重视频图像细节而无法用于信道 估计。本文选用 WDSR 网络处理信道估计问题。

2.1 WDSR 网络架构

WDSR 利用残差网络的跳跃式连接,相比于 SRCNN 它的特征提取能力更强,并且很好地解决了 梯度消失以及梯度爆炸问题。同时 WDSR 采用了 亚像素卷积^[13]的上采样方法降低了上采样的人为 干扰因素,其过程如图 2 所示。首先通过 CNN 提取 特征图,之后就是彩色部分所示的 Pix 过程。如果 需要将目标图像放大 r 倍就需要生成 r² 张特征图, 然后再将 r² 张特征图拼接成一个×r 倍的放大图像, 运用的是抽样的逆思想。与 SRCNN 相比,WDSR 能 够取得更好的训练效果,其结构如图 3 所示。



图 2 亚像素卷积过程 Fig. 2 Sub-pixel convolution



图 3 WDSR 网络结构 Fig. 3 WDSR network architecture

网络整体上采用了类似于残差块的结构,在上 半部分网络首先采用卷积核大小为 3×3、通道数为 3 的卷积层,对输入的低分辨率图像进行卷积操作 实现对低分辨率图像的特征提取。假设 w₁ 为第一 个卷积层的权重,b₁ 为偏置项,H_h 为输入的低分辨 率图像,对应的输出 H¹_c 可以表示为

$$\boldsymbol{H}_{\mathrm{C}}^{1} = \boldsymbol{H}_{\mathrm{lr}} \boldsymbol{w}_{1} + \boldsymbol{b}_{1}$$
 (2)

为了更好地提取低分辨率图像和高分辨率图像 •134 •

电讯技术

之间的映射关系,WDSR 采用了更深的网络来进行 特征提取。对于网络加深所带来的梯度消失以及梯 度爆炸产生的性能下降问题,WDSR 网络通过引入 残差块来解决,残差块由卷积层、Relu 层、卷积层、 卷积层构成。其中采用的归一化方式为权重归一化 (Weight Normalization,WN)^[14],将权重进行如式 (3)所示的标准化计算。通过实验发现,相较于批 量归一化(Batch Normalization,BN),在图像超分辨 率问题中WN 的响应速度更快并且能取得更高的准 确率,是一种更加适应于图像超分辨率问题的标准 化方法。

$$\boldsymbol{w} = \boldsymbol{g} \, \frac{\boldsymbol{g}}{\|\boldsymbol{v}\|} \tag{3}$$

式中:w 为权值向量;v 是 w 在欧氏范数上解耦得出的参数标量,v 的物理意义为 w 的权值大小;g 是 w 在欧氏范数上解耦得出的参数向量,g 的物理意义为 w 的权值方向。根据 v,g 重新参数化网络中的每个权重向量 w 后,再对其进行随机梯度下降从而加快收敛的速度。

若经过第 k 个残差块的输出结果为H^k_b则第 k+1 个残差块的输出结果可表示为

 $\boldsymbol{H}_{\mathrm{b}}^{K+1} = f_2(f_1(\max(f(\boldsymbol{H}_{\mathrm{b}}^k\boldsymbol{\theta}_1 + \boldsymbol{u}_1), \boldsymbol{0})\boldsymbol{\theta}_2 + \boldsymbol{u}_2)\boldsymbol{\theta}_3 + \boldsymbol{u}_3) + \boldsymbol{H}_{\mathrm{b}}^k, K \ge 2$ (4)

式中: f_i 代表包含归一化处理的卷积层映射关系; θ_i 与 u_i 对应每个卷积层的权重项和偏置项。通过残差块特征提取后,接着通过一个卷积层和WN处理,卷积核大小为 3×3,通道数为 $r^2 × c_o$ 该操作为 Pix 提供对应数目的特征图,r 为图像放大倍数,c 为图像颜色通道数。然后对特征图进行 Pix 操作,将图像放大到目标尺寸。若输入的低分辨率图像为灰度图像(c=1),则网络上半部分输出为

$$\boldsymbol{H}_{1}^{\text{HR}} = \text{PS}(\boldsymbol{H}_{b}^{\text{L}}\boldsymbol{w}_{c} + \boldsymbol{b}_{c})$$
(5)

式中:**H**^L为残差模块的输出w_c;**b**。表示卷积网络的 权重与偏置项;PS表示亚像素卷积排列操作。

网络的下半部分与上半部分结构类似,只在上 半部分的基础上去除了残差模块,其输出为**H**^{HR}₂。 网络的最终输出**H**_h可以表示为

$$\boldsymbol{H}_{\rm hr} = \boldsymbol{H}_1^{\rm HR} + \boldsymbol{H}_2^{\rm HR} \tag{6}$$

这样完成了由低分辨率图像**H**_{LR} 到高分辨率图像**H**_{HB} 之间的重构。

2.2 WDSR 信道估计算法

WDSR 网络的处理对象通常是是图片,因此原始 WDSR 网络的输入层接收的是三通道(RBG 图

像)的训练数据,而在信道估计方法中需要把通过 导频得到的信道响应矩阵作为低分辨率图像输入, 得到整个信道的高分辨率信道响应矩阵,信道矩阵 每个对应位置只有单一的值,因此要把输入层从 (*N*_s,*N*_p,3)改变成(*N*_s,*N*_p,1)。信道响应的取值并 没有一个固定为范围,所以要去除 WDSR 网络中的 归一化层。由于标准的 OFDM 子帧对应的时网格 包含 N_s =72 个子载波 N_p =14 个时隙,因此对于标 准 OFDM 子帧采用的是×2 WDSR 模型。训练流程 如图 4 所示。



图 4 WDSR 信道估计算法训练流程 Fig. 4 Training process of WDSR channel estimation algorithm

首先将发送端和接收端的导频值 X_{p}, Y_{p} 通过式 (7)得到 \hat{H}_{p}^{LS} :

$$\hat{H}_{\rm P}^{\rm LS} = \frac{Y_{\rm P}}{X_{\rm P}} \tag{7}$$

对 H_{P}^{LS} 进行插值将其放大至信道响应 $H_{N_{S}\times N_{D}}$ 大小的一半得到 $\hat{H}_{\frac{N_{S}}{2}\times \frac{N_{D}}{2}}^{LS}$ 。由于信道响应矩阵中的值为 复数而神经网络无法处理复数数据,因此将信道响 应矩阵表示为两幅二维的图像,将 $\hat{H}_{\frac{N_{S}}{2}\times \frac{N_{D}}{2}}^{LS}$ 实部、虚部 拆分为二维图像,分别为 Re($\hat{H}_{\frac{N_{S}}{2}\times \frac{N_{D}}{2}}^{LS}$)和 Im($\hat{H}_{\frac{N_{S}}{2}\times \frac{N_{D}}{2}}^{LS}$), 作为×2 WDSR 网络模型的输入图像 $Z_{1,2}$ 。为了得 到精准的信道估计值,将不含噪声的理想信道响应 $H_{perfect}$ 作为训练标签。模型的训练相当于将信道模 型中导频处响应和信道响应之间复杂的映射关系转 换成模型参数 θ 上的简单分布,并不断地通过训练 来调整 θ 使得其能更准确地反映导频响应与信道响 应之间的映射关系。在训练过程中使用的损失函数 为均方误差,网络模型在损失函数的基础上进行优 化,如下式:

$$E_{\rm MS} = \frac{1}{n} \sum_{1}^{n} \left\{ \mathbf{E} \left[\| \boldsymbol{H}_{\rm perfect} - \boldsymbol{F}_{\theta}(\boldsymbol{Z}_{1}) \|^{2} \right] \right\}$$
(8)

$$\boldsymbol{\Theta}^* = \operatorname{argmin}_{\boldsymbol{\Theta}} E_{\mathrm{MS}} \tag{9}$$

式中: $F_{\theta}(\cdot)$ 代表 WDSR 信道估计网络的映射关系; Θ 为网络中的参数包含权重与偏置项。

将参数 Θ 初始化,使用自适应矩估计(Adaptive Moment Estimation, ADAM)算法来优化网络参数,利 用每次迭代生成的信道估计矩阵 $F(Z_1)$ 联合式(8) 和式(9)来更新参数 Θ ,参数更新后产生新的信道 估计矩阵 \hat{H} ,如式(10):

$$\hat{\boldsymbol{H}} = \boldsymbol{F}_{\theta}(\boldsymbol{Z}_{1}) \tag{10}$$

重复上述的参数优化过程最终得到最优的信道 估计矩阵,具体流程如下(Epoch 为训练批次; $H_{\rm P}$, $\hat{H}_{\rm LS}$ 分别代表导频处响应和插值后的信道响应; α 为学习率 g_t 为t时刻的累积梯度; Θ 为网络参数; m_t 为梯度累积的一阶矩估计; v_t 为梯度累积的二阶 矩估计; β_1 和 β_2 为衰减因子; ε 为稳定数值的常数, 其取值默认设置为 10⁻⁸);

输入:导频接收端以及发送端 $X_{p}, Y_{p},$ 不含噪声的理想 信道响应 $H_{perfect}$

输出:信道 CSI 矩阵的估计值 \hat{H} $H_{p} \leftarrow \frac{Y_{p}}{X_{p}}$ (计算导频处响应) $\hat{H}_{LS} \leftarrow interpolate. Rbf(H_{p}, \frac{N_{s}}{2}, \frac{N_{p}}{2})(对 H_{p}$ 进行插值) $Z_{1,2} \leftarrow Re(\hat{H}_{LS}), Im(\hat{H}_{LS})(提取实部虚部)$ 初始化:随机初始化参数 $\Theta, t \leftarrow 0, m_{t} \leftarrow 0, v_{t} \leftarrow 0;$ while 训练次数<Epoch do $t \leftarrow t+1(i)$ 小族次数更新)

$$L(\boldsymbol{\Theta}) \leftarrow \frac{1}{n} \sum_{1}^{n} \{ \mathbb{E} [\| \boldsymbol{H}_{\text{perfect}} - F_{\boldsymbol{\theta}}(\boldsymbol{Z}_{1,2}) \|^{2}] \} (计算损失函)$$

数)

$$g_{\iota} \leftarrow \nabla_{\theta} L(\boldsymbol{\Theta}_{t-1}) (\ddagger \hat{\beta} \hat{\boldsymbol{\beta}} \boldsymbol{\beta})$$

$$m_{\iota} \leftarrow \beta_{1} * m_{\iota-1} + (1-\beta_{1}) * g_{\iota} (\, \boldsymbol{\mathbb{R}} \boldsymbol{\mathcal{R}} \hat{\boldsymbol{\beta}} \boldsymbol{\beta})$$

$$v_{\iota} \leftarrow \beta_{2} * v_{\iota-1} + (1-\beta_{2}) * g_{\iota}^{2} (\, \boldsymbol{\mathbb{R}} \boldsymbol{\mathcal{H}} \hat{\boldsymbol{\beta}} \boldsymbol{\beta} \boldsymbol{\beta} \boldsymbol{\gamma})$$

$$\hat{\boldsymbol{m}}_{\iota} \leftarrow m_{\iota} / (1-\beta_{1}^{\iota}) (\, \boldsymbol{\widehat{\boldsymbol{m}}} \hat{\boldsymbol{\varepsilon}} \boldsymbol{\beta} \boldsymbol{\Sigma} \boldsymbol{m}_{\iota})$$

$$\hat{\boldsymbol{v}}_{\iota} \leftarrow v_{\iota} / (1-\beta_{2}^{\iota}) (\, \boldsymbol{\widehat{\boldsymbol{m}}} \hat{\boldsymbol{\varepsilon}} \boldsymbol{\beta} \boldsymbol{\Sigma} \boldsymbol{v}_{\iota})$$

$$\boldsymbol{\Theta}_{\iota} \leftarrow \boldsymbol{\Theta}_{\iota-1} - \alpha * \frac{\hat{\boldsymbol{m}}_{\iota}}{\sqrt{\hat{\boldsymbol{v}}_{\iota}} + \varepsilon} (\, \boldsymbol{\mathfrak{P}} \hat{\boldsymbol{\beta}} \boldsymbol{\delta} \boldsymbol{\Sigma})$$

 $\hat{H} \leftarrow F_{\theta}(\mathbf{Z}_{1,2})$ (参数更新之后,估计信道矩阵) end while

仿真分析 3

本节通过仿真验证 WDSR 信道估计方法在不 同场景的表现,并将结果与现行的几种算法进行 对比。

3.1 仿直参数

在信道建模方面,使用较为常用的维也纳大学 LTE 模拟器^[15]生成与文献[9]中同类型的车载小尺 度衰落信道(Vehicular A channel, VehA)(载波频率 为2.5 GHz,带宽1.4 MHz),以及行人小尺度衰落 信道(Pedestrian A channel, PedA)(其多径时延和信 道增益与 VehA 区别较大且应用场景不同: VehA 作 用区域较大,后者 PedA 作用区域较小但环境相对 复杂)。将导频发送数据和接收数据通过计算得到 含噪声的信道矩阵Hnoise,之后借助 LTE 模拟器自带 的理想信道估计功能进行单通道的理想信道估计, 重复5500次后对所得的矩阵进行拼接生成不含噪 声的理想信道矩阵H_{perfect}。仿真中 OFDM 子帧由 14 个时隙和72个子载波组成,调制方式为 BPSK,信道 为快衰落信道,其他参数如表1所示。

表1 仿真参数	
---------	--

Tab. 1	Simulation parameter
参数	数值
子帧导频数	16,24,36,48
带宽/MHz	1.4
载波频率/GHz	2.5
CP 长度	18
多径时延/ns	[0,310,710,1090,1730,2510] [0,50,110,170,290,310]
信道增益/dB	[0,-1,-9,-10,-15,-20] [0,-3,-10,-18-26,-32]

仿真采用 pytorch 框架利用 GPU 加速训练来实 现所提出的算法。为了使训练尽量收敛,将最大迭 代次数设置为50次,训练集和测试集分别为5000 和 500。训练参数如表 2 所示。

	表 2 训练参数	
	Tab. 2 Training param	eter
	参数	数值
批次十小	WDSR	64
加沃入小	SRCNN	128
迷伴炉粉	WDSR	50
达代认知	SRCNN	300
训练集		5 000
验证集		500
巴口南	WDSR	0.001
子勺平	SRCNN	0.001

在仿真过程中采用均方误差 (Mean Square Error MSE)以及误码率(Bit Error Rate, BER)作为性 能指标来评估理想信道矩阵 H 与估计矩阵 \hat{H} 之间 的误差。

3.2 仿真结果

在 3.1 节的仿真条件下对 WDSR 方法、传统信 道估计方法以及 SRCNN 信道估计方法进行对比, 图5展示了在 VehA 信道中不同信道估计算法的 MSE 和 BER 性能。



(b)BER 性能

SNR/dB

2.5 5.0 7.5

0.0

VehA 信道模型中不同 SNR 和 图 5 导频数下不同算法的 MSE 和 BER 性能

Fig. 5 MSE and BER performance of different algorithms under different SNR and pilot numbers in the VehA channel model

由图 5(a)可以看出,随着 SNR 的下降,四种信 道估计方法的误差均有所下降,在假设信道先验信 息已知的情况下 MMSE 算法具有最好的性能,但是 在实际信道估计中难以实现:两种基于深度学习的 信道估计算法效果均优于传统的 LS 信道估计方法: 在给定的 SNR 范围内 WDSR 算法的效果均优于 SRCNN 算法。在不同导频情况下, SRCNN 算法对 导频数量的少量变化并不敏感:随着导频数的增加, MSE 只有微量的降低,这是因为信道特征不连续而 SRCNN 方法采用对导频一步插值的上采样方式来 进行数据预处理。WDSR 算法随着导频的增多,估 计的效果也随之提升:在导频数从 16 增加到 36 时 MSE 逐渐降低,在导频数从 36 增加到 48 时 MSE 的 降低较为微小。WDSR 网络在不同的导频数下相较 于 LS 算法以及 SRCNN 信道估计算法仍然取得了 较好的效果,因此可以在一定程度上节省导频的开销,提高频带的利用率。对比 SRCNN 算法,WDSR 网络算法的 MSE 性能至少提高 1.5 dB,最高可达 到 6.5 dB。

从图 5(b)来看,LS 信道估计方法误码率较高, 因为 LS 算法没有考虑噪声对信道的影响所以精度 较低。在信噪比较低的情况下(SNR ≤ 5 dB), WDSR 信道估计算法相较于 SRCNN 算法误码率性 能指标提升较小;随着 SNR 的逐渐增大,WDSR 网 络算法的 BER 下降速度增快,在信噪比较高 (SNR≥10 dB)时性能明显优于 SRCNN 算法。

图 6 对不同算法在 PedA 信道中的效果进行了 对比。在 SNR = 5 dB 时,对比 VehA 信道模型, WDSR 算法相较于 SRCNN 算法的 MSE 性能提升明 显。值得关注的是,在 SNR = 15 dB 时,SRCNN 算法 以及 WDSR 算法的 MSE 性能出现了衰退,但是 WDSR 算法能够提取更多的底层信息,得到相对能 接受的 MSE,并且在信噪比和导频取值范围内性能 指标均优于其他两种算法。





Fig. 6 MSE and BER performance of different algorithms under different SNR pilot numbers in the PedA channel model

在 WDSR 信道估计算法中残差块的数量影响 着网络的深度和信道估计的性能。为了探究残差块 对信道估计性能的影响,对不同残差块下的训练效 果进行了对比,如图 7 所示。从图中可以看出,残差 块数量 RES=1 时 MSE 指标较差,RES=2 时效果有 明显提升,当 RES 数量提升至 3 和 4 时训练效果的 提升逐渐减弱。考虑到网络的深度以及训练的效 果,可以根据应用需求选择 RES=2 或者 RES=3。



图 7 不同残差块下 WDSR 信道估计算法的 MSE 性能 Fig. 7 MSE performance of WDSR channel estimation algorithm under different residual blocks

为了研究 WDSR 算法的收敛性,在 SNR 为 0~20 dB 范围内进行收敛性实验,观察迭代次数以及 MSE 性能。为了减少残差块数量对实验的影响,残 差块数量设置为 3。如图 8 所示, MSE 性能随着 SNR 的增大而不断提升,并且在不同的信噪比情况 下网络都能在 25 次迭代内达到收敛。



图 8 WDSR 信道估计算法的收敛性 Fig. 8 Convergence of WDSR channel estimation algorithm

3.3 算法复杂度分析

表 3 给出了 LS 信道估计算法、MMSE 信道估计 算法、SRCNN 以及 WDSR 信道估计算法的计算复杂 度。WDSR 信道估计算法的复杂度主要来自于卷积 层特征提取所需要的乘法数,其中 *M_n* 和 *K_n* 分别表 示各层的输出特征图边长以及卷积核边长,*Cⁱⁿ* 和 *C*^{out} 分别代表各层的输入和输出通道数,*q* 为残差块 个数。由于 WDSR 网络结构相对复杂,其计算复杂 度大于 LS 以及 SRCNN 信道估计方法,但是小于 MMSE 信道估计。

表 3 计算复杂度比较

Tab. 3	Comparison of computational complexity
算法	计算复杂度
LS	O(k)
MMSE	$O(k^3)$
SRCNN	$O\left(\sum_{n=1}^{3} M_n^2 K_n^2 C_n^{\text{in}} C_n^{\text{out}}\right)$
WDSR	$O(\sum_{n=1}^{3q+9} M_n^2 K_n^2 C_n^{\text{in}} C_n^{\text{out}})$

4 结束语

本文针对快衰落信道估计中精度不够高、导频 开销过大的问题,提出了一种基于 WDSR 网络的信 道估计方法,将导频处的估计值通过 LS 插值初步上 采样放大后的信道矩阵拆分为实部和虚部两幅低分 辨率二维图像,再利用 WDSR 网络再次放大重建高 精度的图像,在输出端对输出的实部、虚部高分辨率 图像进行重新组合得到信道估计的最终结果。将信 道插值与 WDSR 网络结合替换了以往的信道插值, 把快衰落信道估计问题转换为图像超分辨率问题, 解决了信道特征不连续导致信道估计精度低、导频 开销大的问题。在不同导频数和不同类型的信道 中,该方法不仅信道估计的性能有所提高而且在达 到相同 MSE 以及误码率的情况下占用的导频数更 少,提高了通信的有效性。但是其缺点在于网络较 深,因此未来需要对算法优化,进一步减少算法的计 算量,同时需要考虑更多时变特性带来的影响。

参考文献:

- [1] WEN C K, SHIH W T, JIN S. Deep learning for massive MIMO CSI feedback [J]. IEEE Wireless Communications Letters, 2018, 7(5):748-751.
- [2] 吕新荣,李有明,国强. MIMO-OFDM 系统的信道与脉 冲噪声联合估计方法[J]. 通信学报,2021,42(12): 54-64.
- [3] YE H,LI G Y,JUANG B H. Power of deep learning for channel estimation and signal detectionin OFDM systems
 [J]. IEEE Wireless Communications Letters, 2018, 7 (1):114-117.
- GAO X,JIN S,WEN C, et al. Comnet:combination of deep learning and expert knowledge in OFDM receivers [J].
 IEEE Communications Letters,2018,22(12):2627-2630.

电讯技术

- [5] 纪勤文,朱春华. 基于 BP 神经网络的 OFDM 系统信 道估计[J],电讯技术,2021,61(7):793-799.
- [6] 罗菊,方照东,袁泉.基于集成神经网络的信道估计方法研究[J].重庆邮电大学学报(自然科学版), 2020,32(6):969-975.
- [7] YANG J, WEN C K, JIN S, et al. Beamspace channel estimation in mmWave systems via cosparse image reconstruction technique [J]. IEEE Transactions on Communications, 2018, 66(10):4767-4782.
- [8] SOLTANI M, POURAHMADI V, MIRZAEI A, et al. Deep learning-based channel estimation [J]. IEEE Communications Letters, 2019, 23(4):652-655.
- [9] DONG C, LOY C C, HE K, et al. Image super-resolution using deep convolutional networks [J]. IEEE Transactions on Pattern Analysis and Machine Inteligence, 2015, 38(2): 295–307.
- [10] 金龙,吴游,张泳翔. 基于改进 SRGAN 的 OFDM 信道 估计方法[J]. 计算机与现代化,2021(10):112-118.
- [11] YU J, FAN Y, YANG J, et al. Wide activation for efficient and accurate image super-resolution [EB/OL].
 (2018-12-21) [2022-05-11]. https://arxiv.org/abs/1808.08718.
- [12] WANG X, CHAN K C K, Yu K, et al. EDVR: video restoration with enhanced deformable convolutional networks [C]//Proceedings of the IEEE/ CVF Conference on Computer Vision and Pattern Recognition Workshops. Long Beach: IEEE, 2019:1954-1963.
- [13] SHI W, CABALLERO J, HUSZAR F, et al. Real-time single image and video super-resolution using an efficient subpixel convolutional neural network [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas:IEEE, 2016:1874–1883.
- [14] SALIMANS T, KINGMA D P. Weight normalization: a simple reparameterization to accelerate training of deep neural networks [EB/OL]. (2016-02-26) [2022-05-11]. https://arxiv.org/abs/1602.07868.
- [15] MEHLFÜHRER C, IKUNO J C, ŠIMKO M, et al. The Vienna LTE simulators-enabling reproducibility in wireless communications research [J]. EURASIP Journal on Advances in Signal Processing, 2011(1):1–14.

作者简介:

谢 朋 男,1997 年生于湖南湘潭,2019 年获学士学 位,现为硕士研究生,主要研究方向为深度学习与信道估计 技术。

钱蓉蓉 女,1985 年生于云南德宏,2015 年获博士学位,现为讲师、硕士生导师,主要研究方向为通信技术与信号处理技术。

任文平 女,1967 年生于甘肃天水,2001 年获硕士学位,现为副教授、硕士生导师,主要研究方向为 FPGA 在无线通信领域的应用。

· 138 ·