

高速移动环境下基于深度学习的信道估计方法

廖 勇,花远肖,姚海梅,杨馨怡

(重庆大学通信与测控中心,重庆 400044)

摘 要: 针对高速移动环境下信道快时变、非平稳特性导致下行链路信道估计性能受限的问题,本文提出一种基于深度学习的信道估计网络,即 ChanEstNet. ChanEstNet 使用卷积神经网络(Convolutional Neural Network, CNN)提取信道响应特征矢量和循环神经网络(Recurrent Neural Network, RNN)进行信道估计. 我们利用标准的高速信道数据对学习网络进行离线训练,充分挖掘训练样本中的信道信息,使其学习到高速移动环境下信道快时变和非平稳的特点,更好的跟踪高速环境下信道的变化特征. 仿真结果表明,在高速移动环境下,与传统方法相比,所提信道估计方法计算复杂度低,性能提升明显.

关键词: OFDM; 信道估计; 高速信道; 深度学习; 快时变信道; 非平稳信道

中图分类号: TN911.72 **文献标识码:** A **文章编号:** 0372-2112 (2019)08-1701-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2019.08.013

Channel Estimation Method Based on Deep Learning in High-Speed Mobile Environments

LIAO Yong, HUA Yuan-xiao, YAO Hai-mei, YANG Xin-yi

(Center of Communication and TT&C, Chongqing University, Chongqing 400044, China)

Abstract: Aiming at the problem that the downlink channel estimation performance is limited due to the fast time-varying and non-stationary characteristics in the high-speed mobile environment, this paper proposes a channel estimation network based on deep learning, called ChanEstNet. ChanEstNet uses the convolutional neural network (CNN) to extract channel response feature vectors and recurrent neural network (RNN) for channel estimation. We use the standard high-speed channel data to conduct offline training for the learning network, fully excavate the channel information in the training sample, make it learn the characteristics of fast time-varying and non-stationary channels in high-speed mobile environments, and better track the characteristics of channel changing in high-speed environment. The simulation results show that in the high-speed mobile environment, compared with the traditional methods, the proposed channel estimation method has low computational complexity and significant performance improvement.

Key words: OFDM; channel estimation; high-speed channel; deep learning; fast time-varying channel; non-stationary channel

1 引言

随着高铁建设与运营的快速发展,用于高速环境的移动通信系统已成为研究的热点. 其中,对于正交频分复用(Orthogonal Frequency Division Multiplexing, OFDM)系统,其下行链路信道估计已受到广泛关注^[1-3]. 在高速环境中,由于多径效应和多普勒效应的共同影响,其信道响应具有时/频域选择性衰落(双选

衰落)和非平稳的特性^[4],在这种环境下,传统的信道估计技术已不再适合.

传统的信道估计主要分为时域信道估计和频域信道估计. 对于频域信道估计,该类方法假设导频处的信道频域响应(Channel Frequency Response, CFR)与数据处的 CFR 的变化是线性的,但在高速环境下,线性变化的这一假设不成立,使得传统频域信道估计方法的估计性能较低. 对于时域信道估计方法,由于该类方法可

收稿日期:2018-09-17;修回日期:2019-01-21;责任编辑:覃怀银

基金项目:国家自然科学基金(No. 61501066);重庆市基础与前沿研究计划项目(No. cstc2015jcyjA40003);重庆市研究生科研创新项目(No. CYS18061);中央高校基本科研业务费重点基金(No. 106112017CDJXY500001)

以直接估计出信道冲激响应 (Channel Impulse Response, CIR), 因此可以消除子载波间干扰 (Inter Carrier Interference, ICI)^[5], 但是由于其需要估计出每个路径的 CIR, 导致该类方法的待估计参数数量将远远高于频域估计方法, 因此需要寻找有效的方法减少时域信道估计方法中的待估计参数数量^[6]. 针对待估计参数过多问题, 文献[7]提出基于基扩展模型 (Basis Expansion Model, BEM) 的最小二乘 (Least Squares, LS) 算法, 降低了待估计参数数量, 但估计性能较低. 文献[8]提出应用于高速环境的基于 BEM 的扩展卡尔曼滤波器 (Extended Kalman Filter, EKF) 信道估计算法和基于 BEM 的 EKF-RTSS (Rauch-Tung-Striebel Smoother) 信道估计算法, 虽然此类方法较传统的方法有一定的估计性能提升, 但是其估计复杂度太高. 因此高速移动环境下的信道估计仍然面临技术挑战.

近几年, 深度学习已经成功应用于无线通信系统, 例如毫米波信道估计^[9], 信道状态信息 (Channel State Information, CSI) 反馈^[10] 与信号检测^[11] 等. 对于信道估计, 深度学习方法尚未得到全面的研究, 特别是对于高速环境下的信道估计. 因此, 针对传统信道估计方法在高速移动场景下估计性能的不足, 本文提出一种基于卷积神经网络 (Convolutional Neural Network, CNN) 和循环神经网络 (Recurrent Neural Network, RNN) 的信道估计算法, 即 ChanEstNet. ChanEstNet 利用 CNN 提取数据特征矢量和 RNN 网络对序列数据处理的强大能力进行信道估计, 通过导频处的 CSI 预测出数据符号处的 CSI; 同时, 针对时域信道估计中待估计参数数量过多的问题, 本文使用最大池化网络 (MaxPooling) 对待估计参数降维, 在保证能够在信道估计环节消除 ICI 影响的同时有效降低信道估计算法的复杂度.

2 系统模型

信道估计根据是否使用导频信息和插入导频符号的不同, 主要分为盲估计、半盲估计和导频辅助信道估计 (非盲估计). 由于盲估计和半盲估计都是假设信道的 CIR 为广义平稳过程^[12], 对于非平稳双选信道, 导频辅助信道估计方法更加合适^[6]. 而对于适用于 OFDM 系统的基于导频辅助的信道估计方法而言, 导频图样的选择是开展后续研究的基础. 目前研究及应用比较广泛的导频图样包括梳状导频图样、块状导频图样、格状导频图样等^[13]. 其中块状导频图样由于导频符号插入到了 OFDM 所有的子载波中, 因此适用于具有双选衰落的场景^[6], 因而被 IEEE 802. 11p 以及 LTE 等通信协议^[14, 15] 采用作为其导频图样用于辅助信道估计, 本文采用块状导频图样及 LTE^[15] 导频插入模式.

考虑具有 N 个子载波的 OFDM 系统, 一个子帧总

共包含 T 个 OFDM 符号, 设第 t 个 OFDM 符号上第 n 个子载波上传输符号的符号用 $s_t(n)$ 表示, 因此第 t 个 OFDM 符号上传输的符号矢量为 $s_t = [s_t(1), \dots, s_t(N)]^T$. 将频域符号经过傅里叶逆变换 (Inverse Discrete Fourier Transform, IDFT) 变换进行 OFDM 调制后, 有

$$\tilde{s}_t = \mathbf{F}^H s_t \quad (1)$$

其中, $\tilde{s}_t = [\tilde{s}_t(1), \dots, \tilde{s}_t(N)]^T$ 表示发送的时域序列,

$[\mathbf{F}]_{n,k} = \frac{1}{\sqrt{N}} \exp\left(-j \frac{2\pi}{N} kn\right)$ 表示傅里叶变换矩阵. 进一步可以构造 OFDM 传输模型如下:

$$\mathbf{y}_t = \mathbf{H}_t \mathbf{s}_t + \mathbf{z}_t \quad (2)$$

其中, 第 t 个 OFDM 符号块上接收到的频域符号向量为 $\mathbf{y}_t = [y_t(1), \dots, y_t(N)]^T$, \mathbf{z}_t 为信道的加性复高斯白噪声, 协方差矩阵为 $\mathbf{Q}_z = \sigma_z^2 \mathbf{I}_N$, $\mathbf{H}_t \in \mathbb{C}^{N \times N}$ 表示第 t 个 OFDM 符号上信道的频域响应矩阵, 有

$$\mathbf{H}_t = \mathbf{F} \mathbf{G}_t \mathbf{F}^H \quad (3)$$

其中矩阵 $\mathbf{G}_t \in \mathbb{C}^{N \times N}$ 表示第 t 个符号时间信道的冲激响应矩阵, 有

$$\mathbf{G}_t = \begin{bmatrix} h_t(0,0) & 0 & \dots & h_t(0,L-1) & \dots & h_t(0,1) \\ h_t(1,1) & h_t(1,0) & 0 & \dots & \dots & h_t(1,2) \\ \vdots & \ddots & \ddots & \ddots & \ddots & \vdots \\ 0 & \dots & 0 & h_t(N-1,L-1) & \dots & h_t(N-1,0) \end{bmatrix} \quad (4)$$

其中, L 为多径数, $h_t(k,l)$ 表示第 t 个符号时间上, 信道冲激响应第 l 个抽头的第 k 个采样点.

3 ChanEstNet 信道估计

针对高速移动信道环境下传统信道估计方法性能受限的问题, 本文提出一种基于深度学习的高速信道估计方法, 利用卷积神经网络提取数据特征矢量和循环神经网络对序列数据处理强大的能力跟踪信道的变化, 以此进行信道估计. 首先通过 LS 方法初始导频处的 CSI, 然后通过 ChanEstNet 网络的获取所有资源网格处的 CSI.

3.1 ChanEstNet 结构

ChanEstNet 结构主要分为离线训练和在线预测两个部分, 其结构图如下图 1(a) 所示. 本文所使用的信道估计网络主要分为两个步骤, 对于离线训练, 我们利用收集到的大量信道数据对学习网络进行训练, 使学习网络学习到信道的变化特征. 对于在线预测, 学习网络的输入为 OFDM 无线通信系统反馈的一个子帧大小的信道矩阵. 学习网络主要包括一维 (One Dimension, 1D) CNN 网络, 1D MaxPooling 网络, 双向长短期记忆 (Bidirectional Long Short-Term Memory, BiLSTM) 网络和全连接神经网络, 其结构图如图 1(b) 所示.

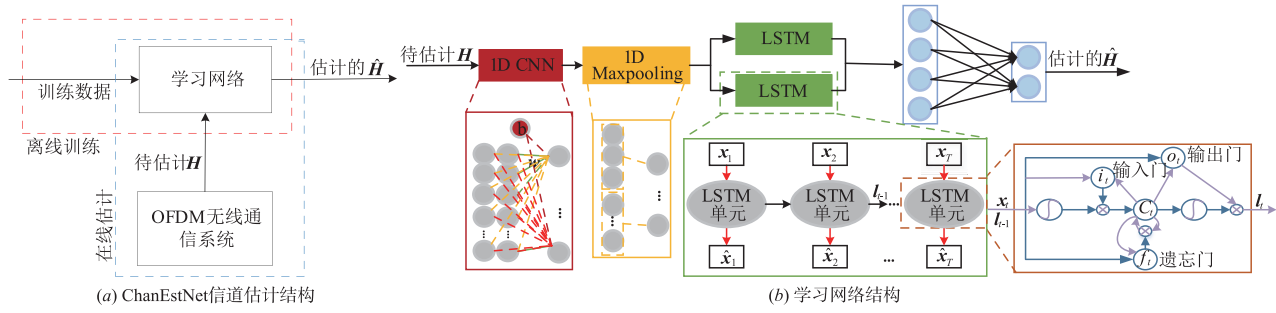


图1 ChanEstnet结构

1D CNN 网络主要用于提取导频序列特征值,主要由若干个并行的滤波器组成,这些滤波器通过一组权重重连接到 CSI 图像,沿着水平方向(时间轴)跨越图像并计算卷积结果.通常,一个 CNN 网络由多个卷积滤波器组成,每个滤波器处理不同通道上的数据,通过滑动窗口对数据进行卷积求和.设 \mathbf{W} 为卷积滤波器,则 CNN 的变换公式为:

$$\mathbf{x}' = f(\mathbf{W} * \mathbf{x} + \mathbf{b}) \quad (5)$$

其中, \mathbf{b} 为偏置, f 为激活函数, $*$ 表示卷积操作. 本文使用双正切激活函数 (\tanh), 其表达式为:

$$\tanh(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (6)$$

1D Maxpooling 网络主要用于降维待估计参数,通过一个池化窗口来寻找滤波器输出结果之间的最大值.对于频域信道估计,由于其待估计参数较少,因此这层可以省略.针对时域信道估计,其变化表达式为 $x' = \max(\mathbf{x}')$.

BiLSTM 网络主要用于 CSI 预测,为两个单向 LSTM 网络的组合,其中一个 LSTM 网络进行数据的正向预测,另一个 LSTM 网络进行反向预测. LSTM 网络主要由若干个 LSTM 单元组成.每个 LSTM 单元由输入门,遗忘门,输出门和记忆单元组成,并且每个 LSTM 单元参数共享,即每个时间步上神经网络的参数都一样. LSTM 网络具有内在的存储器单元,能够长时间保持先前提取的信息以用于下一个时刻的预测.单个 LSTM 结构的数学描述如下:

$$\mathbf{i}_t = \sigma(\mathbf{b}_i + \mathbf{U}_i \mathbf{x}_t + \mathbf{W}_i \mathbf{l}_{t-1}) \quad (7)$$

$$\mathbf{f}_t = \sigma(\mathbf{b}_f + \mathbf{U}_f \mathbf{x}_t + \mathbf{W}_f \mathbf{l}_{t-1}) \quad (8)$$

$$\mathbf{c}_t = \mathbf{f}_t \odot \mathbf{c}_{t-1} + \mathbf{i}_t \odot \sigma(\mathbf{b}_c + \mathbf{U}_c \mathbf{x}_t + \mathbf{W}_c \mathbf{l}_{t-1}) \quad (9)$$

$$\mathbf{o}_t = \sigma(\mathbf{b}_o + \mathbf{U}_o \mathbf{x}_t + \mathbf{W}_o \mathbf{l}_{t-1}) \quad (10)$$

$$\mathbf{l}_t = \mathbf{o}_t \odot \tanh(\mathbf{c}_t) \quad (11)$$

其中 $\mathbf{i}_t, \mathbf{f}_t, \mathbf{o}_t, \mathbf{c}_t, \mathbf{l}_t$ 分别为 LSTM 网络每个时间步的输入门,遗忘门,输出门,记忆单元和隐藏层矢量, $\mathbf{U}_i, \mathbf{W}_i, \mathbf{U}_f, \mathbf{W}_f, \mathbf{U}_c, \mathbf{W}_c, \mathbf{U}_o, \mathbf{W}_o \in \mathbb{R}^{d \times d}$ 为 LSTM 网络的权重矩阵, $\mathbf{b}_i, \mathbf{b}_f, \mathbf{b}_c, \mathbf{b}_o \in \mathbb{R}^d$ 为 LSTM 网络的偏置,权重和偏置都是通过训练学习得到, \odot 表示元素乘法, σ 为 sigmoid 函数, d 表示输入序列维度,在本文中即为 OFDM 子载波

个数, t 为输入序列长度,即为 OFDM 符号数,也即为 LSTM 单元数量.每个时间步 LSTM 网络的输出和隐藏层更新变换公式可以简化为式(12)和(13):

$$\mathbf{l}_t = \text{LSTM}(\mathbf{l}_{t-1}, \mathbf{x}_t, \Theta) \quad (12)$$

$$\hat{\mathbf{x}}_t = \tanh(\mathbf{W}_{l_0} \mathbf{l}_t + \mathbf{b}_{l_0}) \quad (13)$$

其中 $\text{LSTM}(\cdot)$ 为式(7)~(11)的组合, Θ 表示 LSTM 网络中的所有参数, \mathbf{W}_{l_0} 和 \mathbf{b}_{l_0} 表示隐藏层到输出的权重和偏置. BiLSTM 为两个单向 LSTM 的结合,因此 BiLSTM 网络的输出变换式为:

$$\mathbf{p}_t = \text{Concat}(\hat{\mathbf{x}}_t, \hat{\mathbf{x}}_t^\dagger) \quad (14)$$

其中 $\hat{\mathbf{x}}_t^\dagger$ 为 t 时刻 BiLSTM 网络的反向输出, \mathbf{p}_t 为 t 时刻 BiLSTM 网络的输出, $\text{Concat}(\cdot)$ 函数将两个矢量按指定维度结合起来.将 BiLSTM 网络每个时间步的输出变换简写成下式:

$$\mathbf{p}_t = \text{BiLSTM}(\mathbf{l}_{t-1}, \mathbf{l}_{t-1}^\dagger, \mathbf{x}_t, \mathbf{x}_t^\dagger, \Theta_{\text{bi}}) \quad (15)$$

其中 \mathbf{l}_{t-1}^\dagger 为 $t-1$ 时刻 BiLSTM 网络的反向隐藏层矢量, \mathbf{x}_t^\dagger 为 t 时刻 BiLSTM 网络的反向输入. Θ_{bi} 和 $\text{BiLSTM}(\cdot)$ 分别表示 BiLSTM 网络中的所有参数和变换函数.学习网络最后一层使用全连接网络对 BiLSTM 网络每个时间步的输出进行维度变换,相较于卷积神经网络,全连接神经网络输入每个元素都连接到一个不同的权重,输出为输入所有的元素加权和.

3.2 ChanEstNet 网络中的数据流

输入数据通过所提出的学习网络获得估计的 CSI,其数据流如图 2 所示.下面分别对输入数据、频率代表向量提取和信道估计进行了详细的描述.

(1) 输入数据:所提学习网络的输入数据为一个子帧大小的 CSI 矩阵 $\mathbf{H} \in \mathbb{C}^{T \times N_L}$,对于频域信道估计, L 被设为 1. 导频符号处的 CSI 数值通过 LS 方法估计得到,数据符号处的 CSI 初始化数值设为 0. LSTM 网络需要时间序列数据作为输入,因此将 CSI 变换成序列的形式,其输入数据表达形式为:

$$\mathbf{H} = [\mathbf{h}_1, \dots, \mathbf{h}_t, \dots, \mathbf{h}_T]^T \quad (16)$$

其中 $\mathbf{h}_t \in \mathbb{C}^{N_L}$ 为第 t 个 OFDM 符号处的 CSI.因为信道数据为复数信号,因此在对所提的学习网络进行输入之前需要对数据进行预处理,把输入数据的实部和虚部

提取出来然后将实部和虚部结合成一个维度,于是输入数据变成 $\mathbf{H}' \in \mathbb{R}^{T \times 2NL}$, $\mathbf{h}'_i \in \mathbb{R}^{2NL}$, 即学习网络的输入

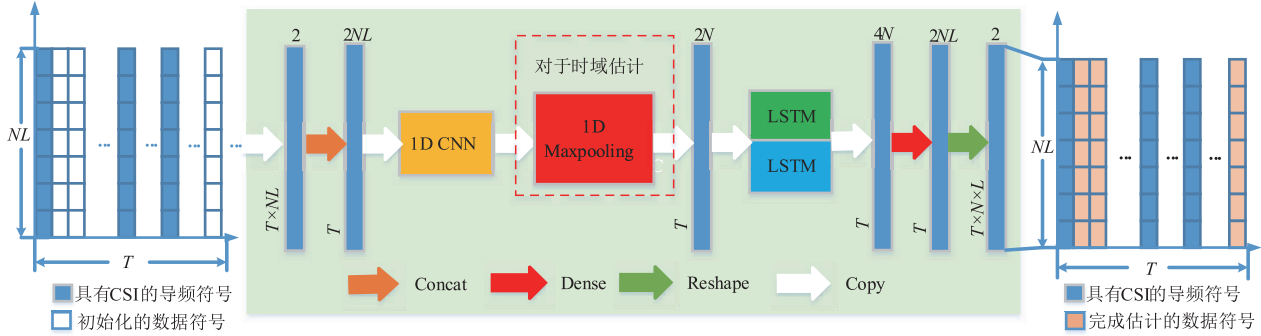


图2 ChanEstNet网络中的数据流

(2) 频率特征矢量提取:输入数据经过预处理之后就送入 1D CNN 网络,1D CNN 的主要任务是进行数据特征矢量的提取和选择,与传统手动进行特征提取和选择的机器算法不同,CNN 能够自动的从数据中进行特征值的提取和选择,以从输入数据中获得代表性矢量. 1D CNN 网络通过 T 维对 \mathbf{H}' 进行卷积运算,卷积滤波器个数为 $2NL$,因此 CNN 网络的输出为:

$$\mathbf{H}'' = f(\mathbf{W} * \mathbf{H}' + \mathbf{b}) \quad (17)$$

通过卷积网络后,输出维度不变,即 $\mathbf{H}'' \in \mathbb{R}^{T \times 2NL}$. 特别的,对于时域信道估计,由于直接估计 CIR,因此原始数据相对于频域信道估计多了一个时延维,与频域信道估计不同就是多了一个 1D Maxpooling 层,用于压缩待估计参数. 1D CNN 网络的输出将通过 1D Maxpooling 网络压缩待估计参数. 设 1D Maxpooling 网络的池化窗口大小为 $1 \times L$,因此池化后的数据维度为 $\mathbf{H}''' \in \mathbb{R}^{T \times 2N}$, $\mathbf{h}'''_i \in \mathbb{R}^{2N}$.

(3) 信道估计:所提的学习网络旨在利用过去、当前的反馈和未来的数据预测出当前的 CSI. 考虑到 LSTM 网络在序列任务学习中表现优异,因此本文采用 LSTM 网络进行 CSI 预测,对于正向预测,后一时刻的 CSI 通过前一时刻的 CSI 预测得到,对于反向预测,前一时刻的 CSI 通过后一时刻预测得到,充分利用前向和后向的导频信息,以进一步的提升信道估计的精度. 对于信道估计, BiLSTM 网络的每个时间步都有输出,基于式(16),可以得到每个时间步 CSI 预测序列如下:

$$\mathbf{h}'''_i = \text{BiLSTM}(I_{i-1}, I_{i-1}^*, \mathbf{h}'''_i, \mathbf{h}'''_i, \Theta_{\text{bi}}) \quad (18)$$

BiLSTM 网络的输出维度为输入的两倍,即 $\mathbf{h}'''_i \in \mathbb{R}^{4N}$. 最后通过全连接网络将双向 LSTM 网络每个时序的输出进行维度变换,使得最终的输出维度与输入维度一致,即全连接神经元个数为 $2NL$ 个. 其变换表达式为:

$$\hat{\mathbf{h}}_i = \sigma(\mathbf{W}_{i,i} \mathbf{h}'''_i + \mathbf{b}_{i,i}) \quad (19)$$

其中 $\mathbf{W}_{i,i}$ 和 $\mathbf{b}_{i,i}$ 分别为每个时间步上全连接层的权重和偏置. 然后将最终的输出重新整形的两个 $T \times L$ 大小的矩阵作为最终估计的实部和虚部,再将实部和虚部加

为 T 个 $2NL$ 维的序列.

在一起得到最终输出的:

$$\hat{\mathbf{H}} = [\hat{\mathbf{h}}_1, \dots, \hat{\mathbf{h}}_i, \dots, \hat{\mathbf{h}}_T]^T \quad (20)$$

3.3 模型训练

为了训练 ChanEstNet 网络,我们使用端到端的方式获取 ChanEstNet 网络中的所有权重和偏置. 设整个 ChanEstNet 网络的变换式和所有参数分别为 $f_{\text{est}}(\cdot)$ 和 Θ_{est} ,因此 ChanEstNet 网络估计得到的 CSI 可以表示为 $\hat{\mathbf{H}} = f_{\text{est}}(\mathbf{H}, \Theta_{\text{est}})$. 我们使用自适应矩估计 (ADaptive Moment estimation, ADAM) 算法更新 ChanEstNet 网络的参数集, ADAM 算法与传统采用固定学习率的梯度下降算法不同,它能够通过训练自适应的更新学习率. 网络的损失函数为均方误差 (Mean Squared Error, MSE), 因此,我们模型的预测损失为:

$$L(\Theta_{\text{est}}) = \frac{1}{M} \sum_{i=1}^M (f_{\text{est}}(\mathbf{H}_i, \Theta_{\text{est}}) - \mathbf{H}_i^*)^2 \quad (21)$$

其中, \mathbf{H}_i^* 为监督数据, M 为训练样本集中总的样本数.

4 仿真分析

在本节中,我们将通过与其他同类信道估计方法以及经典的信道估计与插值方法进行比较评估所提时域信道估计方法和频域信道估计方法在不同环境下的估计性能. 信道模型我们采用的是具有快时变和非平稳特征的高速信道模型 WINNER-II D2a^[16]. 对于离线训练过程,我们使用的训练集、校验集和测试集的样本数分别为 10000, 3000 和 1000. 仿真系统的主要参数如表 2 所示.

表 2 仿真系统参数

参数	数值
载波频率	2.8GHz
系统带宽	5MHz
子载波数	300
FFT 长度	512
CP 长度	36
调制方式	QPSK
非平稳信道模型	WINNER-II D2a ^[16]

4.1 归一化均方误差

图 3 和图 4 分别比较了频域类估计方法 LS^[17]方法, LMMSE^[6]方法和本文所提的频域估计 F-ChanEstNet 方法, 与时域类估计方法 BEM-based LS^[7]方法, BEM-

based EKF^[8]方法, BEM-based EKF-RTSS^[8]方法和本文所提的时域估计 T-ChanEstNet 方法在不同速度环境下的归一化均方误差 (Normalized MSE, NMSE) 性能.




图3 频域估计方法的NMSE比较

从仿真结果上看, 无论频域信道估计还是时域信道估计, LS 配合线性插值方法表现出比较差的 NMSE 性能, 其估计精度受限的主要原因在于, 非平稳的信道环境其时域相关系数是一个时变的参数, 其信道变化的规律不满足线性假设. 对于频域信道估计, LMMSE 配合线性插值方法能够利用信道的先验统计信息提升估计精度, 在速度为 50km/h 时, LMMSE 的信噪比 (Signal-to-Noise Ratio, SNR) 增益高于 LS 16dB 左右, 而此时本文所提的频域信道估计方法 F-ChanEstNet 比 LMMSE 高 9dB 左右, 这是因为 LS 缺乏先验的信道统计信息, 忽略噪声引起的估计误差较大, LMMSE 利用信道统计信息提高估计精度. 而本文所提的估计方法性能提升明显, 主要原因是我们所提的学习网络能够通过训练学习到信道的变化特征, 因此能够更好的适应信道的变化.

在速度为 300km/h 时, 三种方法的 NMSE 较 50km/h 均呈上升趋势, 此时 LS 方法的 NMSE 性能曲线与速度为 50km/h 时差距不大, 这表明 LS 配合线性插值方法无论是在高速还低速下都具有较差的估计性能. 此时 LMMSE 的 NMSE 性能曲线较移动速度为 50km/h 有明显的上升趋势, 表明在高速环境下传统的线性插值方法不再合适. 而对于 F-ChanEstNet 方法, 虽然相对于移动速度为 50km/h 时 NMSE 性能曲线呈一定的上升趋势, 但相对于传统的频域类信道估计方法表现出较好的 SNR 增益, 表现出更好的 NMSE 性能. 特别的, 对于时域估计, 各种方法的 NMSE 性能在不同速度下十分接近, 无论是传统基于 BEM 的降维方法或本文所提




图4 时域估计方法的NMSE比较

的池化降维方法, 由于对待估计参数降维带来了一定的误差. 并且由图 4 可以看出, BEM-based EKF 和 BEM-based EKF-RTSS 的 NMSE 十分接近, 其 SNR 增益比 BEM-based LS 高约 3.5dB, 而此时本文所提的 T-ChanEstNet 方法比 BEM-based EKF 方法和 BEM-based EKF-RTSS 方法高约 4.5dB.

综上所述, 本文所提的信道估计方法, 不管是在时域估计还是频域估计都表现出较好的 NMSE 性能, 表明我们的信道估计网络能够很好的学习到高速信道的变化特点, 并且在不同速度环境下所提方法都表现出优异的 NMSE 性能.

4.2 误码率

误码率 (Bit Error Ratio, BER) 性能是衡量信道估计方法对系统整体性能影响的宏观指标. 图 5 和图 6 分别比较了频域类估计方法 LS 方法, LMMSE 方法和本文所提的频域估计 F-ChanEstNet 方法, 与时域类估计方法 BEM-based LS 方法, BEM-based EKF 方法, BEM-based EKF-RTSS 方法和本文所提的时域估计 T-ChanEstNet 方法在不同速度环境下的 BER 性能.

对于频域信道估计, 从图 5 可以看出, 不同速度环境下本文所提的 F-ChanEstNet 方法相对于 LS 配合线性插值的方法其 SNR 增益有较大差距, 在 50km/h 时, 本文所提的 F-ChanEstNet 方法 SNR 性能增益较大, 峰值能够达到 6dB; 在 300km/h 时, 其峰值 SNR 增益为 5.5dB. 在低信噪比 (SNR \leq 10dB) 下, F-ChanEstNet 算法与 LMMSE 算法的 BER 性能相当, 在 50km/h 时, 峰值增益为 1.5dB; 在 300km/h 时, 其峰值增益仅为

0.7dB. 而在高信噪比 (SNR > 10dB) 情况下, F-ChanEstNet 方法的 BER 急速下降, BER 性能明显优于 LMMSE 算法. 虽然从其 NMSE 性能来看, 本文所提的信道估计方法相当于传统的方法性能提升明显, 但频域信道估




图5 频域估计不同方法的BER比较

对于时域估计, 从图6可以看出, 各种方法的 BER 性能相对于频域类信道估计方法都有明显的性能提升, 主要原因是时域类估计方法能够直接估计出 CIR, 在信道估计环节消除 ICI 的影响. 在各种环境下, 本文所提的 T-ChanEstNet 方法的 BER 性能都远优于 BEM-based LS 方法, 这是由于传统的 LS 方法无法考虑信道的非平稳因素. 在 50km/h 时, T-ChanEstNet 与 BEM-based EKF 和 BEM-based EKF-RTSS 的 BER 性能相当, 主要原因是在低速环境下, CIR 变化趋于平稳, BEM-based EKF 和 BEM-based EKF-RTSS 算法也能很好的适跟踪信道的变化. 但在 300km/h 时, 受信道环境的影响, 各种信道估计方法的 BER 性能都随着 SNR 的增加而趋于收敛. BEM-based EKF 和 BEM-based EKF-RTSS 算法几乎重合, 其 SNR 增益相对于 BEM-based LS 为 6.5dB 左右, 而此时 T-ChanEstNet 算法相对于 BEM-based EKF 和 BEM-based EKF-RTSS 算法有一定的性能提升, 其峰值 SNR 增益为 3dB 左右.

由以上仿真结果可知, 在不同的环境下, 本文所提的信道估计方法能够获得较好的估计精度性能, 虽然较 BEM-based EKF 算法和 BEM-based EKF-RTSS 算法没有太大的性能提升. 但总体而言, 在保证本文所提方法的计算复杂度与 LS 等传统方法在同一数量级的前提下, 在不同速度场景下, 本文所提方法都保持着较高的 BER 性能增益.

5 结论

本文基于块状频图样, 针对传统估计方法在高

速环境下信道估计的不足, 提出一种基于深度学习的信道估计方法, 通过离线训练和深度学习的非线性映射特性更好地适应高速信道的变化特点, 有效地利用了训练样本中的信道信息提升信道估计的准确度; 针对时域信道估计待估计参数数量过多的情况, 我们利用最大池化网络降低待估计参数, 在保证能够在信道估计环节消除 ICI 影响的同时有效降低了信道估计算法的复杂度. 通过时域估计和频域估计的仿真对比, 分析了 ChanEstNet 方法在高速环境下的性能表现. 从仿真结果可以看出, 本文所提方法在保证复杂度与传统经典方法复杂度在同一量级的前提下, 具有更优的估计精度, 更强的鲁棒性, 以及更佳接收机整体性能.

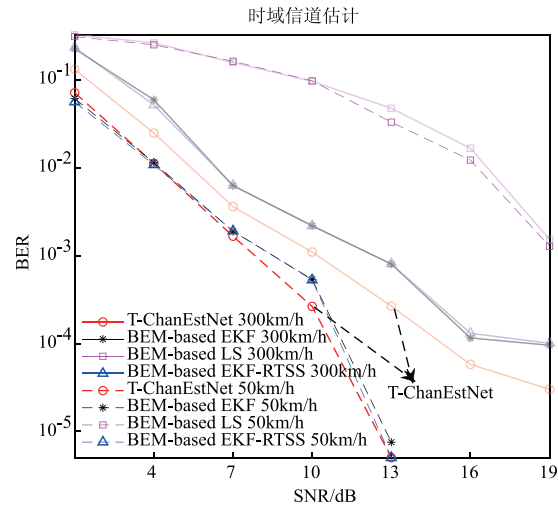


图6 时域估计不同方法的BER比较

速环境下信道估计的不足, 提出一种基于深度学习的信道估计方法, 通过离线训练和深度学习的非线性映射特性更好地适应高速信道的变化特点, 有效地利用了训练样本中的信道信息提升信道估计的准确度; 针对时域信道估计待估计参数数量过多的情况, 我们利用最大池化网络降低待估计参数, 在保证能够在信道估计环节消除 ICI 影响的同时有效降低了信道估计算法的复杂度. 通过时域估计和频域估计的仿真对比, 分析了 ChanEstNet 方法在高速环境下的性能表现. 从仿真结果可以看出, 本文所提方法在保证复杂度与传统经典方法复杂度在同一量级的前提下, 具有更优的估计精度, 更强的鲁棒性, 以及更佳接收机整体性能.

参考文献

- [1] Yang L, Ren G, Yang B, et al. Fast time-varying channel estimation technique for LTE uplink in HST environment [J]. IEEE Transactions on Vehicular Technology, 2012, 61(9): 4009 - 4019.
- [2] 廖勇, 沈轩帆, 代学武, 周昕, 王丹. 基于扩展卡尔曼滤波器的联合迭代检测译码信道估计方法 [J]. 电子学报, 2018, 46(3): 554 - 561.
LIAO Yong, SHEN Xuan-fan, DAI Xue-wu, ZHOU Xin, WANG Dan. Joint iterative detector and decoder channel estimation based on extended Kalman filter [J]. Acta Electronica Sinica, 2018, 46(3): 554 - 561. (in Chinese)
- [3] Shen X F, Liao Y, Dai X, et al. Joint channel estimation and decoding design for 5G-enabled V2V channel [J]. China Communications, 2018, 15(7): 49 - 56.

- [4] Ghazal A, Yuan Y, Wang C X, et al. A non-stationary IMT-advanced MIMO channel model for high-mobility wireless communication systems[J]. IEEE Transactions on Wireless Communications, 2017, 16(4): 2057 – 2068.
- [5] Hlawatsch F, Matz G. Wireless Communications over Rapidly Time-Varying Channels[M]. US: Academic Press, 2011.
- [6] Yong S C, Kim J, Yang W Y, et al. MIMO-OFDM Wireless Communications with MATLAB [M]. USA: Wiley Publishing, 2010.
- [7] Zhang J, Wen H, Song H, et al. Using basis expansion model for physical layer authentication in time-variant system [A]. Communications and Network Security [C]. Philadelphia, PA: IEEE, 2017. 348 – 349.
- [8] Shen X F, Liao Y, Dai X W, et al. BEM-based EKF-RTSS channel estimation for non-stationary double-selective channel [A]. IEEE/CIC International Conference on Communications in China [C]. Beijing, China: IEEE, 2018. 1 – 6.
- [9] He H, Wen C K, Jin S, et al. Deep learning-based channel estimation for beamspace mm Wave massive MIMO systems [J]. IEEE Wireless Communications Letters, 2018, 7(5): 852 – 1855.
- [10] Wen C K, Shih W T, Jin S. Deep learning for massive MIMO CSI feedback [J]. IEEE Wireless Communications Letters, 2017, 7(5): 748 – 751.
- [11] 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.
- [12] Liu Y, Tan Z, Hu H, et al. Channel estimation for OFDM [J]. IEEE Communications Surveys and Tutorials, 2014, 16(4): 1891 – 1908.
- [13] Coleri S, Ergen M, Puri A, et al. Channel estimation techniques based on pilot arrangement in OFDM systems [J]. IEEE Transactions on Broadcasting, 2002, 48(3): 223 – 229.
- [14] Gozalvez J, Sepulcre M, Bauza R. IEEE 802. 11p vehicle to infrastructure communications in urban environments [J]. IEEE Communications Magazine, 2012, 50(5): 176 – 183.
- [15] Sesia S, Toufik I, Baker M. LTE, The UMTS Long Term Evolution: From Theory to Practice [M]. USA: Wiley Publishing, 2009.
- [16] Meinilä J, Kyösti P, Jämsä T, et al. WINNER II Channel Models [M]. New Jersey: Wiley Publishing, 2008. 39 – 92.
- [17] Zarrinkoub D H. Understanding LTE with MATLAB: From Mathematical Modeling to Simulation and Prototyping [M]. Hoboken: Wiley Publishing, 2014.

作者简介



廖 勇 (通信作者) 男, 1982 年出生于四川省自贡市。现为重庆大学副研究员, 博士生导师, 主要研究方向为下一代无线通信与网络, 人工智能、区块链及其在无线通信中的应用等。
E-mail: liaoy@cqu.edu.cn



花远肖 男, 1994 年出生于四川省阆中市。现为重庆大学微电子与通信工程学院研究生, 主要研究方向为人工智能算法及其在无线通信中的应用。
E-mail: huayx@cqu.edu.cn



姚海梅 女, 1992 年出生于江西省吉安市。现为重庆大学微电子与通信工程学院研究生, 主要研究方向为人工智能算法及其在无线通信中的应用。
E-mail: meimei@cqu.edu.cn



杨馨怡 女, 1996 年出生于四川省绵阳市。现为重庆大学微电子与通信工程学院研究生, 主要研究方向为高速移动通信中的预编码研究。
E-mail: yangxinyi@cqu.edu.cn