



研究与开发

5G 高速移动系统中基于 BP 神经网络的多普勒频偏估计方法

王增浩, 杨丽花, 程露, 张捷, 梁彦

(南京邮电大学江苏省无线通信重点实验室, 江苏 南京 210003)

摘要: 提出了一种基于反向传播 (back propagation, BP) 算法训练的神经网络的多普勒频偏估计方法。所提方法主要分成线下训练与线上估计两个阶段, 首先利用随机多普勒频偏与接收的导频符号构建训练样本, 然后利用训练样本对 BP 神经网络进行线下训练, 完成输入与输出数据之间的映射关系, 最后基于训练后的网络利用接收导频符号数据, 进行线上多普勒频偏估计。仿真结果表明, 所提方法的估计性能远远优于现有方法, 且具有较低的计算复杂度。

关键词: 5G-NR; 毫米波; 高速铁路; BP 神经网络; 多普勒频偏估计

中图分类号: TN929.5

文献标识码: A

doi: 10.11959/j.issn.1000-0801.2020124

BP neural network based Doppler frequency offset estimation method for 5G high-speed mobile system

WANG Zenghao, YANG Lihua, CHENG Lu, ZHANG Jie, LIANG Yan

Jiangsu Key Laboratory of Wireless Communication, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

Abstract: A BP neural network based Doppler frequency offset estimation method was proposed. The proposed method was mainly divided into two stages: offline training and online estimation. Firstly, the training samples were constructed by using random Doppler frequency offset and received pilot signals, and then the training samples were used to train the BP neural network offline, which could complete the mapping relationship between input and output data. Then, based on the trained network, the received pilot signal was used to estimate the Doppler frequency offset online. Simulation results show that the performance of the proposed method is far superior to the existing method, and it has low computational complexity.

Key words: 5G-NR, millimeter wave, high speed railway, BP neural network, Doppler frequency offset estimation

收稿日期: 2019-11-01; 修回日期: 2020-04-02

通信作者: 杨丽花, yanglh@njupt.edu.cn

基金项目: 江苏省科技厅自然科学基金资助项目 (No.BK20191378); 江苏省高等学校自然科学研究面上项目 (No.18KJ13510034); 第 11 批中国博士后科学基金特别资助项目 (No.2018T110530); 国家自然科学基金资助项目 (No.61401232, No.61671251, No.61771255)

Foundation Items: The National Science Foundation Program of Jiangsu Province (No.BK20191378), The National Science Research Project of Jiangsu Higher Education Institutions (No.18KJ13510034), The 11th Batch of China Postdoctoral Science Fund Special Funding Project (No.2018T110530), The National Natural Science Foundation of China (No.61401232, No.61671251, No.61771255)



1 引言

近年来,科学技术和经济的快速发展,激发了高速铁路(high speed railway, HSR)的快速和广泛发展。随着 HSR 的大规模部署,HSR 环境下的无线通信已在全球引起了越来越多的关注^[1-2],并且 HSR 已被作为第五代新无线电(5G-NR)通信网络的重要使用场景之一,预计 5G-NR 系统可以实现高达 500 km/h 的移动速度。然而,当前大多数无线通信系统被设计来服务具有低等或中等移动性的用户,并且高移动性显著地限制了覆盖区域和传输速率。因此,需要设计可靠高效的、面向 5G-NR HSR (≥ 500 km/h) 场景的通信系统^[3]。

由于高速列车上的乘客通常很多,这要求 HSR 通信不仅要能处理关键信令应用,还要能提供各种宽带应用,如高清(high definition, HD)视频监控、车载宽带互联网接入、实时列车调度高清视频以及铁路物联网^[4-5]等,这些应用需要更多的频谱资源来支持。为了满足对 HSR 用户体验不断增长的需求,目前国内外一些文献和 3GPP 标准提出将 5G-NR 毫米波(mmWave)频带应用于 HSR 通信,并给出了相应的实验证明。然而,在使用 5G-NR 毫米波的高速移动环境中,多普勒频移的影响将变得更加显著、路径损耗更为严重,这将不利于 HSR 场景中的车地通信。因此,为了实现 5G-NR 毫米波段未来列车在时速高达 500 km/h 场景下的 10 Gbit/s 连接,还需要开展很多工作。

在众多需要开展的工作中,克服大多普勒频移的影响至关重要,这是因为在基于 5G-NR 毫米波的 HSR 环境中,多普勒频移的影响将变得尤为显著,如考虑 3GPP 建议的典型频段(30 GHz)和车载速度 500 km/h,对应的下行传输系统的多普勒频移约为 14 kHz,其是 4G-LTE HSR 中上行系统的 20 多倍^[6-7]。如此大的多普勒频移将会引起更为严重的载波间干扰/用户间干扰和信道的快速随机变化,从而使得 HSR 通信系统的性能严

重下降。因此,需要开展对 5G-NR 毫米波在 HSR 环境中抗大多普勒频移技术的研究,其中多普勒频偏估计和补偿技术是基础。

近年来,国内外已经开展了大量针对高速移动场景下多普勒频偏估计与补偿方法的研究,但是这些研究大多是关于 4G-LTE 系统下 HSR 场景中多普勒频偏估计与补偿的^[8-11],如参考文献[9]给出了一种基于环境地图的多普勒频偏估计方法,其主要通过将信道各径的多普勒频移按照权重进行累加来获取多普勒频偏估计,其中信道的相关参数从地图中获取,该方法简单易行,但是该方法的估计精度依赖于地图中保存的与信道相关参数的估计精度;参考文献[11]给出了一种基于导频的多普勒频偏估计方法,该方法仅通过对两个块导频符号进行相关处理获取频偏估计,且该方法的估计范围较小。因此,这些现有的基于 4G-LTE 系统 HSR 场景中的多普勒频偏估计方法或由于精度不高或由于估计范围不大或由于计算复杂度太高,不能直接用于 5G-NR 毫米波 HSR 场景下的多普勒频偏估计。

目前,有关 5G-NR 毫米波 HSR 场景中多普勒频偏估计与补偿的研究鲜少,尚处于起步阶段。参考文献[6]针对毫米波 HSR 场景给出了一种基于位置和预补偿的多普勒频偏估计与补偿算法,该方法根据列车的位置与速度计算得到多普勒频移,并在信号发送前进行预补偿,但是该方法需要依赖于高精度的定位与列车速度信息,而在实际中无法避免的定位误差与速度测量误差严重限制了该方法的性能。参考文献[12]给出了一种毫米波 HSR 移动通信系统中的多普勒频偏消除方法,该方法主要是基于假设列车顶部首尾两中继接收信号具有数值相同的反向频偏进行的,通过将首尾中继的接收信号进行简单的相乘处理来消除多普勒频偏的影响。然而,当列车经过基站时,多普勒频偏会迅速降低,并且车顶首尾中继经过基站的时间不同,因此在列车越区切换时该方法的

性能将会恶化。参考文献[13]给出了一种基于导频的最大似然多普勒频偏估计方法,该方法通过对导频进行分段和求解极大似然函数来估计多普勒频偏,但是该方法需要付出大的计算复杂度才能具有较好的估计精度,并且为了满足导频特殊分段的要求,该方法对导频符号的长度有严格的限制,使其不适用于导频结构已确定的通信系统。

近年来,人工智能特别是机器学习在计算机视觉、自然语言处理、语音识别等领域获得了巨大成功^[14],无线通信领域的研究者们期望将其应用于通信系统的各个层面,进而满足人们对数据传输速率及质量的需求。前期的研究成果多集中于应用层和网络层,主要思想是将神经网络学习的思想引入无线资源管理和分配等领域。目前,该方向的研究正在向 MAC 层和物理层推进,并且在信道估计、信号检测和信道解码等方面取得了一定的成果。结合目前神经网络学习在物理层的应用,本文提出了一种基于 BP 神经网络的多普勒频偏估计方法,该方法引入神经网络对多普勒频偏进行估计,利用神经网络通过非线性处理单元抽取原始数据特征的特性,使该网络实现输入与输出数据间的映射关系,然后基于该网络利用接收信号中的导频符号数据估计对应的多普勒频偏。

2 系统模型

在 5G-NR 毫米波 HSR 下行传输系统中,假设时域发送信号为:

$$s_i(m, n) = \frac{1}{\sqrt{N}} \sum_{k=0}^{N-1} S_i(m, k) e^{\frac{j2\pi nk}{N}} \quad (1)$$

其中, $S_i(m, k)$ 为第 i 个子帧、第 m 个 OFDMA 符号、第 k 个子载波上的信号, N 为傅里叶变换的长度。

在 HSR 通信环境中,由于基站均是沿铁轨附近建立的,这将存在一个很强的直射径(line-of-sight, LOS)分量,因此在 HSR 环境中通常采用莱斯信道作为信道模型^[15-17],故在下行

传输链路中,第 i 个子帧、第 m 个符号的传输信道可以表示为^[18]:

$$h_i(m, n) = c_i \exp[j2\pi \varepsilon_{i,m} (mN_D - N + n)/N] + \sum_{l_p=0}^{L_p-1} \alpha_{i,l_p}(m, n) \delta(m, n - \tau_{l_p}) \quad (2)$$

其中, c_i 为信道的 LOS 分量; $\alpha_{i,l_p}(m, n), l_p = 0, \dots, L_p - 1$ 代表散射分量且服从瑞利分布; L_p 是多径莱斯信道的径数; $\varepsilon_{i,m}$ 是归一化多普勒频偏; τ_{l_p} 是第 l_p 径的归一化时延; $N_D = N + N_{cp}$, 其中 N_{cp} 是循环前缀的长度; 该莱斯信道的莱斯因子定义为 $K = |c_i|^2 / \sum_{l_p=0}^{L_p-1} \text{var}[\alpha_{i,l_p}]$ 。

假设循环前缀的长度大于无线传输信道的最大时延,且接收端理想定时同步,则接收到的时域信号可以表示为:

$$r_i(m, n) = c_i s_i(m, n) \exp[j2\pi \varepsilon_{i,m} (mN_D - N + n)/N] + \sum_{l_p=0}^{L_p-1} \alpha_{i,l_p}(m, n) s_i(m, n - \tau_{l_p}) + w_i(m, n) \quad (3)$$

其中,传输符号的功率为 σ_s^2 , $w_i(m, n)$ 是方差为 σ_w^2 的加性高斯白噪声(AWGN)。

由于子帧上每个 OFDMA 符号的多普勒频偏变化比较小,因此每个子帧上的多普勒频偏可以近似为一个常数,即 $\varepsilon_{i,m} \approx \varepsilon_i$ 。由于每一个子帧的多普勒频偏估计方法相同,因此,为了便于介绍本文所提方法,将省略 OFDMA 符号与子帧标号 m 和 i 。

3 基于 BP 神经网络的多普勒频偏估计方法

为了满足 5G-NR 毫米波 HSR 场景中大多普勒频偏估计的要求,本文给出了一种基于 BP 神经网络的多普勒频偏估计方法。下面将对本文所提方法中采用的 BP 神经网络与原理进行详细介绍。

3.1 BP 神经网络

BP 神经网络是一种按照误差逆向传播算法训练的多层前馈神经网络,属于多层神经网络中



的一种,而深度学习则是为了让多层神经网络更好地训练工作而演化出来的一系列的新结构和方法。传统意义上的多层神经网络含有输入层、隐藏层、输出层。其中隐藏层根据需要而定,并没有明确的理论依据。而深度学习中最著名的卷积神经网络(convolutional neural network, CNN)在原来多层神经网络的基础上,加入了特征学习部分,该部分模拟了人脑对信号的处理。具体操作是在原来的全连接层前面加入部分连接的卷积层和降维层,其网络层数较BP神经网络更多。循环神经网络(recurrent neural network, RNN)在多层神经网络的基础上引入了定向循环,传统的神经网络模型每层之间的节点是无连接的,而RNN会对前面的信息进行记忆并应用于当前输出的计算中,即隐藏层节点之间出现连接,隐藏层的输入不仅包括输入层的输出,还包括上一时刻隐藏层的输出。理论上,RNN能够对任何长度的序列数据进行处理。

BP神经网络采用迭代的算法来训练网络,随机设定初值,计算网络输出,然后根据当前输出与目标之间的差值改变前面各层的参数直至收敛,并且它需要人为提取原始数据的特征作为输入,深度学习网络则通过学习原始数据结构自动提取特征值以及网络初值,减少了人工的工作量。BP神经网络具有很强的非线性映射能力,且应用范围广泛。考虑到高速移动场景下数据具有复杂的相关性,BP神经网络与深度学习网络相比,具有较低的计算复杂度。因此,本文所提方法采用BP神经网络来进行多普勒频偏估计。

BP神经网络主要由输入层、隐藏层、输出层3部分组成,作为一种多层前馈网络,BP神经网络学习由样本信息的正向传播和误差的反向传播两个过程组成,使用梯度下降学习算法,通过反向传播来不断调整网络的权值和阈值,使网络的误差最小。图1给出了一个 L 层的BP神经网络结构,其中第 l 层、第 b 个节点的输入可以表示为:

$$u_b^{(l)} = \mathbf{w}_{ba}^{(l)\top} \mathbf{I}_a \quad (4)$$

其中, $\mathbf{a}$ 表示与节点 b 相连的前一层节点的集合, $\mathbf{w}_{ba}^{(l)}$ 表示节点 b 与节点集合 $\mathbf{a}$ 中节点之间的权值组成的列向量, $\mathbf{I}_a$ 为前一层节点的输入组成的列向量。由于节点的输出就是所有输入的加权和经过传递函数处理得到的值,则第 l 层相应的输出为:

$$y_b^{(l)} = f^{(l)}(u_b^{(l)}) = f^{(l)}(\mathbf{w}_{ba}^{(l)\top} \mathbf{I}_a) \quad (5)$$

其中, $f^{(l)}(\cdot)$ 表示该节点的传递函数,根据具体应用可以选择不同的传递函数。在此,本文所提方法在隐藏层采用tansig传递函数,在输出层采用purelin传递函数,其表达式分别为:

$$f_{\text{tansig}}(x) = \frac{2}{1 + e^{-2x}} - 1, \quad f_{\text{purelin}}(x) = x \quad (6)$$




图1 L 层BP神经网络结构

3.2 基于BP神经网络的多普勒频偏估计方法原理

本文所提方法将BP神经网络看作一个映射函数,利用给定的神经网络学习算法实现接收端导频符号与多普勒频偏之间的映射关系,然后对多普勒频偏进行估计。图2给出了本文所提方法的原理,该方法主要分为线下训练与线上估计两个阶段,线下训练阶段主要是为了建立神经网络输入与输出数据之间的映射关系,其中输入为随机生成的多普勒频偏以及基于给定的HSR信道模型时接收端收到的不同多普勒频偏情况下的导频信号,利用该信号组成的训练样本集对神经网络进行训练,得到最优的权值与阈值;线上估计阶




图 2 基于 BP 神经网络的多普勒频偏估计方法的原理

段直接将接收到的导频信号送入神经网络，从而得到估计的多普勒频偏。下面将对该方法进行详细介绍。

(1) 线下训练阶段

假设在给定的 HSR 信道模型下，可以得到的样本集为：

$$\mathbf{Z} = \left\{ \left(\mathbf{R}_{\text{pilot}}^{(1)}, f_d^{(1)} \right), \left(\mathbf{R}_{\text{pilot}}^{(2)}, f_d^{(2)} \right), \dots, \left(\mathbf{R}_{\text{pilot}}^{(M)}, f_d^{(M)} \right) \right\}, \quad (7)$$

$$\mathbf{R}_{\text{pilot}}^{(k)} \in \mathbb{R}^{D \times 1}$$

其中， $f_d^{(k)}$ 代表第 k 个多普勒频偏值， $\mathbf{R}_{\text{pilot}}^{(k)}$ 代表第 k 个多普勒频移为 $f_d^{(k)}$ 时接收到的频域导频信号， D 代表输入样本集中向量的长度， M 为样本个数。

研究表明，在不限限制隐藏层节点数的情况下，较少层的网络即可实现任意非线性映射^[19]。因此，本文所提方法在训练时将选用一个三层 BP 神经网络，包含两层隐藏层和一层输出层，其中两个隐藏层的节点个数分别为 50 和 20，隐藏层选用的传递函数为 tansig 函数，输出层的传递函数为 purelin 函数，训练目标最小误差设为 0，最大训练次数设为 1 000，学习速率设为 0.01。基于 BP 神经网络的多普勒频偏估计线下训练具体执行步骤如下所示。

初始化 给定神经网络的误差允许值 $\varepsilon_{\text{goal}}$ 、常数 μ_0 和 β ($\beta > 1$)，并对权值阈值向量 $\mathbf{w}^{(0)}$ 参数进行初始化，令 $k = 0$ ， $\mu = \mu_0$ 。

训练：

步骤 1 计算网络输出及误差指标函数 $E(\mathbf{w}^{(k)})$ ：

$$E(\mathbf{w}^{(k)}) = \frac{1}{2} \left\| \hat{f}_d(\mathbf{w}^{(k)}) - f_d \right\|^2 = \frac{1}{2} e^2(\mathbf{w}^{(k)}) \quad (8)$$

其中， $\mathbf{w}^{(k)}$ 表示第 k 次迭代的权值阈值向量， $\hat{f}_d(\mathbf{w}^{(k)})$ 是权值阈值为 $\mathbf{w}^{(k)}$ 时神经网络输出的多普勒频偏估计值， f_d 为实际的多普勒频偏值， $e(\mathbf{w}^{(k)})$ 是误差。

步骤 2 计算 Jacobian 矩阵 $\mathbf{J}_{\mathbf{w}^{(k)}}$ 。

步骤 3 计算权值增量 $\Delta \mathbf{w}^{(k)}$ ：

$$\Delta \mathbf{w}^{(k)} = \left[\mathbf{J}_{\mathbf{w}^{(k)}}^T \mathbf{J}_{\mathbf{w}^{(k)}} + \mu \mathbf{I} \right]^{-1} \mathbf{J}_{\mathbf{w}^{(k)}}^T e(\mathbf{w}^{(k)}) \quad (9)$$

其中， $\mathbf{I}$ 代表单位矩阵， μ 是用户定义的学习率。

步骤 4 若 $E(\mathbf{w}^{(k)}) > \varepsilon_{\text{goal}}$ ，则 $\mathbf{w}^{(k+1)} = \mathbf{w}^{(k)} - \Delta \mathbf{w}^{(k)}$ 为新的权值阈值向量，计算误差指标函数 $E(\mathbf{w}^{(k+1)})$ ；否则，转到步骤 6。

步骤 5 若 $E(\mathbf{w}^{(k+1)}) < E(\mathbf{w}^{(k)})$ ，则令 $k = k + 1$ ， $\mu = \mu / \beta$ ，转到步骤 1；否则 $\mu = \mu \beta$ ，转到步骤 3。



步骤6 算法结束。

(2) 线上估计阶段

线上估计阶段采用线下训练好的 BP 神经网络, 只需要在网络中输入接收到的导频信号, 即可获取多普勒频偏估计。

4 仿真与分析

为验证本文所提方法的性能, 本节将对该方法进行仿真与分析。根据参考文献[20]给出的 5G-NR 毫米波 HSR 场景下无线帧的定义, 在此以 1 子帧为单位进行仿真, 即 1 子帧的长度为 250 μ s, 每子帧包含 14 个 OFDMA 符号。在此帧结构下, 表 1 给出了本文具体的仿真参数^[21-22]。为了比较本文所提方法的性能, 仿真中还给出了参考文献[11,13]中方法的性能, 其中参考文献[11]为基于导频分段的多普勒频偏估计方法, 参考文献[13]为基于导频序列的最大似然频偏估计方法。

表 1 仿真参数

参数	取值
OFDMA 符号长度	1 024
循环前缀长度	128
载波频率	30 GHz
子载波间隔	60 kHz
列车速度	500 km/h
信道模型	单径莱斯信道
莱斯因子	5 和 10

4.1 仿真结果与分析

图 3 给出了本文所提方法采用不同数目的导频信号作为样本训练网络后获取的多普勒频偏估计的 MSE 性能。仿真中, 样本集数目 M 为 4 000。从图 3 中可以看出, 训练神经网络的导频数目越多, 基于该网络获取的多普勒频偏估计性能越好, 且导频数目为 32 时, 本文所提方法的 MSE 性能可以达到 10^{-4} 左右, 这表明本文所提方法可以减

少导频的开销, 即利用较少的导频即可获取较高的估计精度。




图 3 本文所提方法采用不同数目导频训练网络后获取的多普勒频偏估计的 MSE 性能

图 4 给出了本文所提方法采用不同数目的训练样本集训练网络后获取的多普勒频偏估计的 MSE 性能。仿真中每个样本集中导频数目 D 相同, 且 $D=16$ 。从图 4 中可以看出, 随着样本集个数 M 的增加, 用其训练的网络获取的多普勒频偏估计越精确, 这也说明足够多的训练样本集可以提高神经网络的学习效率, 更好地发挥本文所提方法的优势, 但是也会引起线下训练复杂度的增加。综合图 3 与图 4 的仿真结果可以得出: 本文所提方法在线下训练时需要付出较高的计算复杂度, 但是线上估计只需要很少的导频信号与很低的计算复杂度即可获取较高的估计性能。

图 5 给出了不同莱斯因子时各种多普勒频偏估计方法的 MSE 性能曲线。仿真中, 本文所提方法考虑导频信号样本集 $M=4\ 000$ 和导频长度 $D=32$, 参考文献[11]与参考文献[13]方法中考虑导频数目均为 1 024, 且均考虑导频符号分段数为 2。由图 5 可以看出, 无论莱斯因子为 5 还是 10 时, 本文所提方法均只需较少的导频信号与低的计算复杂度就可以获取优于现有方法的估计性能。另外, 参考文献[11]中方法的用于估计频偏的信号中




图4 本文所提方法采用不同数目的样本集训练网络后获取的多普勒频偏估计的MSE性能

存在大量的干扰,故其性能在 $\text{SNR} > 10 \text{ dB}$ 时出现误差基底,而参考文献[13]方法受导频分段数的限制,所以该方法在 $\text{SNR} > 20 \text{ dB}$ 时也出现误差基底。然而,本文所提方法利用神经网络对原始数据进行特征提取,因此在进行多普勒频偏估计时可以保持较好的估计性能。




图5 不同莱斯因子时各种多普勒频偏估计方法的MSE性能

4.2 复杂度分析

在高速铁路运行的某一场景下,由于本文所提方法只需要一次线下训练好网络,线上即可利用该网络实时地获取多普勒频偏估计,因此,对于本文所提方法而言,线下训练网络引入的复杂度是一次性的,而实际多普勒频偏估计引入的计

算复杂度只是线上估计阶段。为此,本文所提方法的复杂度仅考虑线上估计阶段的计算复杂度。表2给出了本文所提方法与不同多普勒频偏估计方法的复杂度比较, T 为搜索次数, L 代表BP神经网络的层数, Q_l 表示第 l 层神经网络所包含的神经元节点的个数。参考文献[13]采用的搜索次数 $T=100$ 。在这种情况下,从表2可以看出:本文所提方法与参考文献[11,13]两种方法的复杂度接近,但是本文所提方法的估计性能优于参考文献[11,13]两种方法(从第4.1节的仿真可以看出)。

表2 复杂度分析

方法	复数乘法	复数加法
参考文献[11]方法	$3N+3$	$N-1$
参考文献[13]方法	$N/2+2N_{cp}+8T$	$N/2+2N_{cp}+3T$
本文方法	$\sum_{l=1}^{L-1} Q_{l-1} Q_l$	$\sum_{l=1}^{L-1} (Q_{l-1}-1) Q_l$

5 结束语

本文提出了一种基于神经网络学习的适用于5G-NR毫米波HSR场景的多普勒频偏估计方法,其主要利用BP神经网络进行多普勒频偏估计。该方法在线下完成网络训练后,在线上只需要输入少量的导频信号即可获得高精度的多普勒频偏估计,具有较低的计算复杂度。本文所提方法不仅适用于5G-NR毫米波HSR场景,也适用于现有及未来高速移动通信场景中的多普勒频偏估计。

参考文献:

- [1] HU Y, LI H, CHANG Z, et al. Scheduling strategy for multimedia heterogeneous high-speed train networks[J]. IEEE Transactions on Vehicular Technology, 2017, 66(4): 3265-3279.
- [2] SUN N, ZHAO Y, SUN L, et al. Distributed and dynamic resource management for wireless service delivery to high-speed trains[J]. IEEE Access, 2017(5): 620-632.
- [3] GHAZZAI H, BOUCHOUCHA T, ALSHAROA A, et al. Transmit power minimization and base station planning for high-speed trains with multiple moving relays in OFDMA systems[J]. IEEE Transactions on Vehicular Technology, 2017,



- 66(1): 175-187.
- [4] GUAN K, LI G, HUI B, et al. On millimeter wave and THz mobile radio channel for smart rail mobility[J]. IEEE Transactions on Vehicular Technology, 2017, 66(7): 5658-5674.
 - [5] AI B, GUAN K, KURNER T, et al. Future railway services-oriented mobile communications network[J]. IEEE Communications Magazine, 2015, 53(10): 78-85.
 - [6] LEVANEN T, TALVITIE J, WICHMAN R, et al. Location-aware 5G communications and Doppler compensation for high-speed train networks[C]//Proceedings of 2017 European Conference on Networks and Communications. Piscataway: IEEE Press, 2017: 1-6.
 - [7] CHOI S N, KIM I. Performance improvement of MHN-enhanced uplink with frequency offset compensation[C]//Proceedings of 2017 Ninth International Conference on Ubiquitous and Future Networks. Piscataway: IEEE Press, 2017: 788-790.
 - [8] FAN D, ZHONG Z, WANG G, et al. Doppler shift estimation for high-speed railway wireless communication systems with large scale linear antennas[C]//Proceedings of 2015 International Workshop on High Mobility Wireless Communications. Piscataway: IEEE Press, 2015: 96-100.
 - [9] LI J, ZHAO Y. Radio environment map-based cognitive Doppler spread compensation algorithms for high-speed rail broadband mobile communications[J]. EURASIP Journal on Wireless Communications and Network, 2012: 1-18.
 - [10] HOU Z, ZHOU Y, TIAN L, et al. Radio environment map-aided Doppler shift estimation in LTE railway[J]. IEEE Transactions on Vehicular Technology, 2017, 66(5): 4462-4467.
 - [11] 闪硕. 多径快时变环境下的同步算法研究与实现[D]. 西安: 西安电子科技大学, 2017.
SHAN S. Research and implementation of synchronization algorithm in multipath fast time varying environment[D]. Xi'an: Xidian University, 2017.
 - [12] HUI B, KIM J, CHUNG H, et al. Efficient Doppler mitigation for high-speed rail communications[C]//Proceedings of 2016 18th International Conference on Advanced Communication Technology. Piscataway: IEEE Press, 2016: 1-2.
 - [13] ZHANG C, WANG G, HE R, et al. A Doppler shift estimator for millimeter-wave communication systems on high-speed railways[C]//Proceedings of 2018 IEEE/CIC International Conference on communications in China. Piscataway: IEEE Press, 2018: 227-231.
 - [14] MAO Q, HU F, HAO Q. Deep learning for intelligent wireless networks: a comprehensive survey[J]. IEEE Communications Surveys & Tutorials, 2018(99): 1.
 - [15] ABRISHAMKAR F, IRVINE J. Comparison of current solutions for the provision of voice services to passengers on high speed trains[C]//Proceedings of Vehicular Technology Conference Fall. [S.l.:s.n.], 2000: 2068-2075.
 - [16] GOLLER M. Application of GSM in high speed trains: measurements and simulations[J]. IEEE Colloquium on Radio Communications in Transportation, 1995(5): 1-7.
 - [17] 3GPP. Initial ideal simulation results for different high speed propagation scenarios: TSG-RAN4-37 (R4-051274) [S]. 2005.
 - [18] YANG L H, REN G L, QIU Z L. A novel Doppler frequency offset estimation method for DVB-T system in HST environment[J]. IEEE Transactions on Broadcasting, 2012, 58(1): 139-143.
 - [19] HORNIK K, STINCHOMBE M, WHITE H. Multilayer feed-forward networks are universal approximators[J]. Neural Networks, 1989(5): 359-366.
 - [20] SONG H, FANG X, FANG Y. Millimeter-wave network architectures for future high-speed railway communications: challenges and solutions[J]. IEEE Wireless Communications, 2016, 23(6): 114-122.
 - [21] 童辉. 5G新空口设计: 如何从LTE拓展与创新[J]. 电信科学, 2019, 35(7): 17-26.
TONG H. 5G new radio design: why/how to extend/innovate from LTE[J]. Telecommunications Science, 2019, 35(7): 17-26.
 - [22] 3GPP. 3rd generation partnership project; technical specification group radio access network; study on channel model for frequency spectrum above 6 GHz (Release 14): TR38.900 v14.3.1[S]. 2017.

[作者简介]



王增浩 (1994—), 男, 南京邮电大学硕士生, 主要研究方向为高速移动通信。



杨丽花 (1984—), 女, 南京邮电大学副教授, 主要研究方向为移动无线通信、通信信号处理、多载波通信系统等。

程露 (1995—), 女, 南京邮电大学硕士生, 主要研究方向为移动通信。

张捷 (1996—), 女, 南京邮电大学硕士生, 主要研究方向为宽带移动通信。

梁彦 (1979—), 女, 南京邮电大学副教授, 主要研究方向为宽带无线通信、通信信号处理等。