

移动场景下的智能信道预测方法

何世文^{1,2,3} 黄凤青¹ 安振宇³ 王良鹏³ 熊绍文¹

(1. 中南大学计算机学院, 湖南长沙 410083; 2. 东南大学移动通信国家重点实验室, 江苏南京 210096;
3. 网络通信与安全紫金山实验室, 江苏南京 210096)

摘要: 针对无线通信信道估计老化问题, 本文提出了一种基于卷积神经网络信道预测方法, 该方法通过联合轨迹预测和信道重构实现。首先, 采用卷积神经网络学习从规划路线和移动终端所在位置到移动方向映射, 进而预测出轨迹上多个目标位置; 其次, 采用卷积神经网络学习从目标位置附近 K 个位置项的信道, 到目标位置信道间映射, 用于实现预测轨迹的信道估计。本文利用 Wireless InSite 为移动方向预测和信道重构模型的训练及测试生成充足的样本, 包括规划路线和通过射线跟踪方法获取的信道等。仿真结果表明, 本文所提出的方法能有效地估计目标位置的信道特性, 与 K 值较小的 K -近邻插值方法和基于全连接神经网络信道预测方法相比, 其信道估计总相对误差更低且鲁棒性较好。

关键词: 信道预测; 移动方向预测; 信道重构; 卷积神经网络

中图分类号: TN929.5 **文献标识码:** A **DOI:** 10.16798/j.issn.1003-0530.2022.08.003

引用格式: 何世文, 黄凤青, 安振宇, 等. 移动场景下的智能信道预测方法[J]. 信号处理, 2022, 38(8): 1579-1591. DOI: 10.16798/j.issn.1003-0530.2022.08.003.

Reference format: HE Shiwen, HUANG Fengqing, AN Zhenyu, et al. An intelligent channel prediction method in mobile scenarios[J]. Journal of Signal Processing, 2022, 38(8): 1579-1591. DOI: 10.16798/j.issn.1003-0530.2022.08.003.

An Intelligent Channel Prediction Method in Mobile Scenarios

HE Shiwen^{1,2,3} HUANG Fengqing¹ AN Zhenyu³ WANG Liangpeng³ XIONG Shaowen¹

(1. School of Computer Science and Engineering, Central South University, Changsha, Hunan 410083, China;
2. National Mobile Communications Research Laboratory, Southeast University, Nanjing, Jiangsu 210096, China;
3. Purple Mountain Laboratories, Nanjing, Jiangsu 210096, China)

Abstract: Aiming at the channel aging problem in wireless communication channel estimation, a convolutional neural network (CNN)-based channel prediction method was proposed. It was implemented by joint trajectory prediction and channel reconstruction. The trajectory prediction was implemented by a CNN-based mobile direction prediction model, and the channel reconstruction was implemented by a CNN-based channel reconstruction model. Specifically, first, the prediction problem of the two elements of the direction vector, i. e., the unit vector in the moving direction, was regarded as a multi-task learning problem. Then, we adopted two CNNs to learn the mapping from the planned route and the current location of the mobile terminal, to the two elements of the moving direction, respectively. Next, based on the predicted direction vectors, the predicted position was calculated using kinematic principle. Then, the movement trajectory was predicted. Second, a CNN was adopted to learn the mapping from the channel characteristic matrices of the K closest position terms in the channel path map, to the channel characteristic matrix of target location. The channel estimation of the predicted trajectory was achieved, by predicting the channel characteristic matrix of each target location on the

收稿日期: 2022-04-12; 修回日期: 2022-06-01

基金项目: 国家自然科学基金资助项目(62171474, 61720106003); 东南大学移动通信国家重点实验室开放研究基金资助课题(2022D03); OPPO 广东移动通信有限公司研究基金项目(CN05202112160224)

predicted trajectory. We utilized Wireless InSite software to generate sufficient samples for the training and testing of the mobile direction prediction and channel reconstruction models, and to construct the channel path maps. The collected data set included the planned routes, current locations and moving trajectories of the mobile terminal, as well as the multi-input multi-output (MIMO) channel characteristics (e. g., the powers, arrival angles in vertical and horizontal directions of effective paths, etc.), which was generated by the ray-tracing algorithm of Wireless InSite. Numerical simulation results showed that, the proposed channel reconstruction model could effectively estimate the MIMO channel characteristics, outperformed the fully connected neural network (FCN)-based channel reconstruction model, and was very close to the error performance of the K-nearest neighbor interpolation method, in terms of error. In addition, the proposed CNN-based channel prediction method had lower sum of relative error and better robustness in channel estimation than the K-nearest-neighbor interpolation method with smaller K values, and the FCN-based channel prediction method.

Key words: channel prediction; moving direction prediction; channel reconstruction; convolutional neural network

1 引言

无线信号在无线环境中传播时,可能受到如多径效应、阴影衰减和大气衰减等不同因素的影响,使其信号质量变差。因此,如何克服信号传输过程中的衰减和损耗,进而提升系统容量成为毫米波通信技术需解决的关键问题之一^[1]。一个可行的解决方案是通过在基站端部署大规模阵列,降低不同终端用户间的干扰,显著提升系统的容量^[2]。然而,大规模多输入多输出(Multi-input Multi-output, MIMO)系统中的预编码、波束成形及接收机设计等都依赖于对信道状态信息的有效获取。因此,有必要对移动终端和基站之间的无线信道进行精确的估计。

目前,大规模 MIMO 信道状态信息的获取大多通过周期性发送正交导频、利用传统信道估计方法,即最小二乘法(Least Squares, LS)和最小均方误差(Minimum Mean Squared Error, MMSE)获得。LS 估计虽然不要求先验的信道统计信息,但其性能可能不好。MMSE 估计通常通过利用信道的二阶统计来获得更好的检测性能。然而,对于基于导频的信道估计方法,相应的导频开销将随着天线数目线性增长。在中高速移动环境下,导频开销将消耗掉大量的时频资源,构成系统瓶颈。移动终端与基站间的相对运动导致当前信道与信道状态信息检测时的信道发生了较大的变化,出现了信道老化问题,同样对用户速率产生了较大的负面影响。

随着神经网络在计算机视觉^[3]和自然语言处理^[4]中的成功应用,促使研究人员探索神经网络,特别是基于深度学习(Deep Learning, DL)的信道估计方法^[5]。与寻求解析解的传统方法不同,基于神经网络的方法是一种数据驱动模型。YE Hao 等人^[5]利用深度神经网络(Deep Neural Network, DNN)学

习从导频块和数据块的接收数据,到无线信道之间的映射,以端到端的方式估计无线信道。其仿真结果显示,当无线信道因严重失真和干扰而变得复杂时,深度学习方法比 MMSE 方法具有优势,证明了 DNN 具有记忆和分析无线信道的复杂特征的能力。然而,作者提出的方法类似于基于导频的信道估计方法,只是采用神经网络替代传统的信道估计方法,以提高信道估计性能,没有解决导频开销大的问题。

由于信道状态信息与移动终端的位置密切相关,可以通过构建信道知识地图(Channel Knowledge Map, CKM)^[6]实现无导频信道估计。例如,可以将 CKM 用于实现信道状态信息建立信道知识和接收机位置之间的准确映射。当信道知识可用时,CKM 可用于辅助无线传输方案的设计^[7-8]。CKM 的构建方法主要分为两种,一种是数值模拟,即利用射线跟踪和可用物理环境生成接收机位置的信道知识,这种方法实施起来经济有效,但产生的数据质量很大程度上取决于物理环境知识的准确性;另一种是基于测量,可调度专用测量设备(例如地面和空中飞行器)专门进行数据收集,或者在实际通信发生时在线收集数据。基于测量的方法能够提供更准确的数据、更好地反映无线电传播环境的真实情况,但实施成本较高、设备分布不均匀,因此,通常无法全部覆盖 CKM 的所有位置项。CKM 使能的环境感知通信面临的基本问题就是如何基于有限的用户位置上有限的测量数据,有效地构建 CKM。最简单的 CKM 重构方法是基于插值的方法,例如 K-近邻(K-Nearest Neighbors, KNN)方法。然而,这种纯数据驱动的方法忽略了近几十年发展起来的基于随机或几何的信道模型,且需要大量的测量数据才能准确地重构 CKM,因此,通常需要巨大的存

储容量来维护 CKM。

通过将信道建模为仅在不同导频或终端位置上已知的二维图像,运用超分辨率图像重构技术^[9]可以恢复其他位置上的信道。例如, SOLTANI M 等人^[10]将信道响应的时频网格建模为仅在导频位置已知的二维图像,并将其看成一个低分辨率图像,而估计的信道被视为高分辨率图像,利用基于 (Convolutional neural network, CNN) 的图像超分辨率算法来提高分辨率,然后,利用基于 CNN 的图像恢复方法去除噪声影响。仿真结果表明,与 MMSE 算法相比,作者提出的基于 DL 的信道估计算法, ChannelNet 在估计误差方面具有很强的竞争力。SHI Qi 等人^[11]同样利用超分辨率图像重构技术对非线性插值机制建模,从有限的导频信号观察结果中重构整个资源块的信道状态信息,获得了比传统信道估计方法更好的性能。类似地, DENG Ruichen 等人^[12]分析了模型驱动的传统信道估计方法的性能限制问题,提出了一种数据驱动的两步插值方法,将大尺度信道参数建模为仅在部分接收位置项上已知的二维图像,采用 KNN 插值方法对缺失位置项的路径损失参数进行插值,构建一个粗糙的 CKM,再通过图像恢复技术对粗糙的信道进行平滑。结果显示,与 MMSE 方法相比,该方法的插值误差降低了 50% 以上。上述方法的共同点是先对信道重构模型进行离线训练,再将训练好的模型用于恢复缺失导频位置项或位置坐标上的信道或大尺度信道参数。然而,这些方法不适用于移动场景,因为它们无法估计出移动终端移动轨迹上的信道特性,且仍没有解决移动场景下的信道估计老化问题。

胡逸文等人^[13]提出了一种基于联邦学习的无线信道预测方法,通过估计移动终端在未来一段时间间隔后的信道,来解决信道老化问题。该方法采用训练后的模型进行在线推断,计算复杂度低。然而,该模型离线训练所需的时间较长,且尽管对预测模型进行了几千倍压缩,其所需的上行数据集仍高于集中式学习,大大影响了通信效率。然而,在移动场景下,需要一个更有效的信道估计方法,这对无线传输方案的设计具有现实意义。

针对信道估计导频开销大和信道老化等问题,本文提出一种基于卷积神经网络信道预测方法。

首先,利用规划路线、移动终端所在的位置和移动速度大小等易获取的信息,预测移动终端在未来一段时间内的移动轨迹,其中,预测移动轨迹由若干个目标位置组成。其次,利用距离目标位置最近的 K 个位置项的信道特性矩阵,估计目标位置的信道特性矩阵,从而实现对预测轨迹的信道估计。本文采用一个卷积神经网络进行信道重构,并将所提出的基于卷积神经网络信道预测方法,与基于插值和其他基于神经网络信道预测方法进行比较。最后,通过采用射线跟踪方法收集的信道数据集进行仿真,结果表明,所提方法能有效地估计 MIMO 信道特性,与基于插值和其他基于神经网络信道预测方法相比,具有一定的优势,能够实现无导频信道估计及可以节省反馈估计信道开销等。

2 系统模型

本文所考虑的移动通信系统由一个基站和一个移动终端组成¹,基站和移动终端都安装大小为 $N_{\text{UPA}} = N_E N_Z$ 的均匀面板天线阵列 (Uniform Planar Array, UPA),其中, N_E 和 N_Z 分别表示垂直和水平方向的天线数。采用常见的毫米波多径信道 $\mathbf{H} \in \mathbf{C}^{N_{\text{UPA}} \times N_{\text{UPA}}}$ ^[14-15],表示为:

$$\mathbf{H} = \sum_{l=1}^{N_L} \alpha_l \mathbf{a}_{\text{rx}}(\theta_l, \phi_l) \mathbf{a}_{\text{tx}}^H(\vartheta_l, \varphi_l) \quad (1)$$

其中, N_L 为路径总数目, α_l 表示第 l 条路径的功率, θ_l 和 ϕ_l 分别表示第 l 条路径在垂直和水平方向的到达角, ϑ_l 和 φ_l 分别表示第 l 条路径在垂直和水平方向的偏离角, $\mathbf{a}_{\text{rx}}(\theta_l, \phi_l) \in \mathbf{C}^{N_{\text{UPA}} \times 1}$ 和 $\mathbf{a}_{\text{tx}}(\vartheta_l, \varphi_l) \in \mathbf{C}^{N_{\text{UPA}} \times 1}$ 分别表示接收和发射天线向量, $l \in \{1, 2, \dots, N_L\}$, $(\cdot)^H$ 表示共轭转置操作。假设发射机和接收机装备的 UPA 天线中沿着垂直和水平方向的天线元间的间隔均为半个波长,则接收和发射天线向量分别为:

$$\mathbf{a}_{\text{rx}}(\theta_l, \phi_l) = \mathbf{c}_{N_E} \left(\frac{1}{2} \sin(\theta_l) \cos(\phi_l) \right) \otimes \mathbf{c}_{N_Z} \left(\frac{1}{2} \cos(\theta_l) \right) \quad (2)$$

$$\mathbf{a}_{\text{tx}}(\vartheta_l, \varphi_l) = \mathbf{c}_{N_E} \left(\frac{1}{2} \sin(\vartheta_l) \cos(\varphi_l) \right) \otimes \mathbf{c}_{N_Z} \left(\frac{1}{2} \cos(\vartheta_l) \right) \quad (3)$$

其中, \otimes 表示 Kronecker 积, $\mathbf{c}_N(\nu)$ 为天线阵列响应,表示为:

¹ 本文提出的智能信道预测方法也可用于多用户场景,为每个移动终端分别调用一次所提方法,即可实现其信道的预测。

$$\mathbf{c}_N(\nu) = \frac{1}{\sqrt{N}} [1, e^{j2\pi\nu}, \dots, e^{j2\pi(N-1)\nu}]^T \in \mathbf{C}^{N \times 1},$$

$$\nu \in \left[-\frac{1}{2}, \frac{1}{2}\right] \quad (4)$$

ν 为频率, N 表示天线数, $(\cdot)^T$ 表示转置操作。将基站与移动终端间各有效路径的功率、到达角和离开角等信道特性写成一个矩阵,即信道特性矩阵 $\mathbf{B} \in \mathbf{R}^{5 \times N_L}$,表示为

$$\mathbf{B} = [\boldsymbol{\alpha}, \boldsymbol{\theta}, \boldsymbol{\phi}, \boldsymbol{\vartheta}, \boldsymbol{\varphi}]^T \quad (5)$$

其中, $\boldsymbol{\alpha} = [\alpha_1, \dots, \alpha_{N_L}]^T \in \mathbf{R}^{N_L \times 1}$ 表示路径功率向量, $\boldsymbol{\theta} = [\theta_1, \dots, \theta_{N_L}]^T \in \mathbf{R}^{N_L \times 1}$ 和 $\boldsymbol{\phi} = [\phi_1, \dots, \phi_{N_L}]^T \in \mathbf{R}^{N_L \times 1}$ 分别表示垂直和水平方向的到达角向量, $\boldsymbol{\vartheta} = [\vartheta_1, \dots, \vartheta_{N_L}]^T \in \mathbf{R}^{N_L \times 1}$ 和 $\boldsymbol{\varphi} = [\varphi_1, \dots, \varphi_{N_L}]^T \in \mathbf{R}^{N_L \times 1}$ 分别表示垂直和水平方向的偏离角。

假设基站处构建了一个如图1所示的信道路径地图(Channel Path Map, CPM)(CKM的应用实例之一),用于实现信道特性矩阵与相应的接收位置项之间的准确映射,其中,相邻位置项之间的间隔均为 d m。由于CPM的构建成本较高,通常只能覆盖区域内的部分位置项。然而,如图1所示,移动终端进入该区域之后,其移动轨迹与被覆盖的位置项之间有一定的距离。因此,仍需要估计移动轨迹上各目标位置的信道。此外,为了实现移动终端的信道预测,需要通过轨迹预测方法预测移动终端在未来一段时间内的移动轨迹。

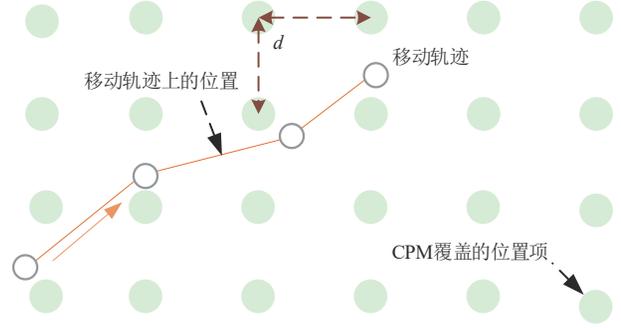


图1 CPM的位置项与移动轨迹

Fig. 1 The location entries of the channel path map and the moving trajectory

3 智能信道预测方法

本文提出一种智能信道预测方法,用于预测移动终端从其所在的位置 $\mathbf{p}_{\text{src}} = (x_{\text{src}}, y_{\text{src}})$ 出发之后一段时间内的信道。如图2所示,该方法由轨迹预测和信道重构两个部分组成。首先,本文将移动终端规划的路线表示为 $\zeta = \{\mathbf{p}_1, \dots, \mathbf{p}_i, \dots, \mathbf{p}_{N_\zeta}\}$,其中, $\mathbf{p}_i = (x_i, y_i)$ 表示规划路线中第 i 个拐点的位置信息, $i \in \{1, 2, \dots, N_\zeta\}$, N_ζ 为规划路线中的拐点个数。特别地, \mathbf{p}_1 和 \mathbf{p}_{N_ζ} 分别表示规划路线的起点和终点。如图3所示,为具有6个拐点的规划路线。根据规划路线矩阵 $\mathbf{U} \in \mathbf{R}^{2 \times N_\zeta}$ 和标记矩阵 $\mathbf{M} \in \mathbf{R}^{2 \times N_\zeta}$,通过移动方向预测模型预测移动终端当前移动方向上的单位向量,获得预测方向向量 $\hat{\mathbf{v}}$ 。规划路线矩阵 \mathbf{U} 可以表示为:

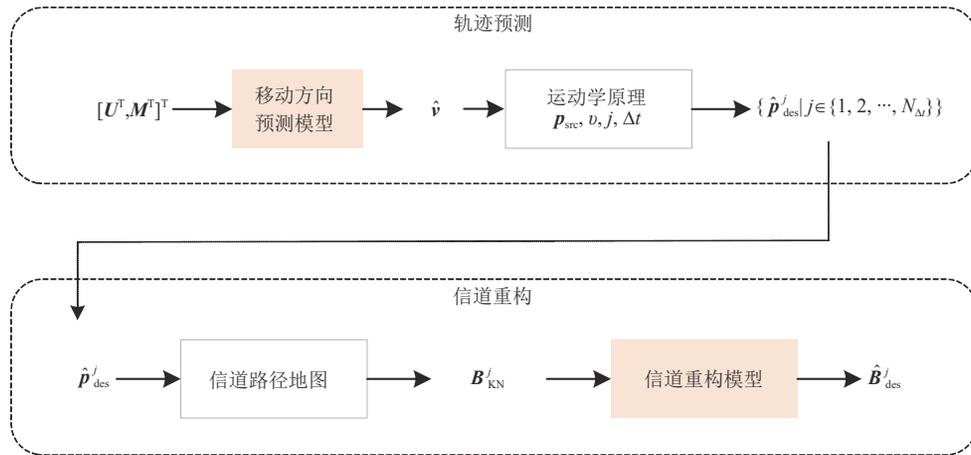


图2 智能信道预测方法

Fig. 2 Intelligent channel prediction method

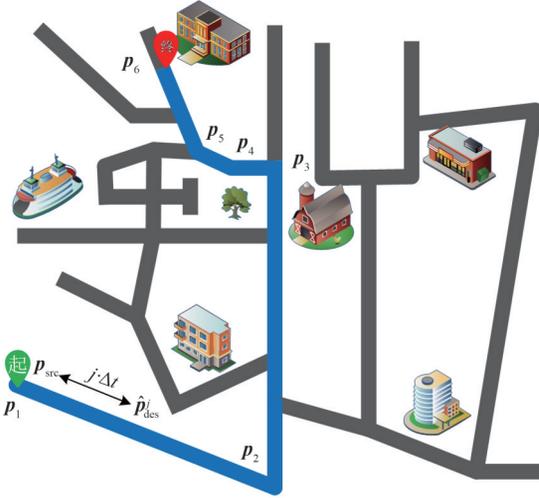


图 3 具有 6 个拐弯点的规划路线, 移动终端所在的位置和目标位置

Fig. 3 Planned route with 6 turning points, the current position and target position of mobile terminal

$$U = \begin{bmatrix} x_1, & \cdots, & x_{N_c} \\ y_1, & \cdots, & y_{N_c} \end{bmatrix} \quad (6)$$

标记矩阵 M 是根据移动终端所在的位置 p_{src} 与规划路线矩阵 U 计算得到的矩阵, 即:

$$M = \begin{bmatrix} \text{sgn}(x_{src} - x_1), & \cdots, & \text{sgn}(x_{src} - x_{N_c}) \\ \text{sgn}(y_{src} - y_1), & \cdots, & \text{sgn}(y_{src} - y_{N_c}) \end{bmatrix} \quad (7)$$

其中, $\text{sgn}(\cdot)$ 为符号函数, 有助于模型学习到移动终端所在的位置与规划路线之间的关系。

进一步地, 假设可预测的轨迹长度为 $N_{\Delta t}$, 并且在未来 $N_{\Delta t}$ 个单位时间间隔 Δt 内, 移动终端处于两个拐点之间, 即 $N_{\Delta t} \cdot \Delta t < t_{i+1} - t_i$, 其中, t_i 和 t_{i+1} 分别为移动终端驶过的最后一个拐点和即将经过的第一个拐点的时刻, $i \in \{1, 2, \dots, N_c - 1\}$ 。若移动速度大小为 v , 则 j 个单位时间间隔 Δt 之后, 预测的移动终端目标位置为

$$\hat{p}_{des}^j = p_{src} + v \cdot j \cdot \Delta t \cdot \hat{v} \quad (8)$$

其中, $j \in \{1, 2, \dots, N_{\Delta t}\}$ 为单位时间间隔 Δt 的数目, 采用 $\{\hat{p}_{des}^j | j \in \{1, 2, \dots, N_{\Delta t}\}\}$ 表示所预测的移动轨迹。

其次, 本文通过分别估计预测轨迹上各目标位置 \hat{p}_{des}^j 的信道, 实现对预测轨迹信道的估计。具体地, 首先, 从 CPM 中读取距离 \hat{p}_{des}^j 最近的 K 个位置项的信道特性矩阵。第 k 个位置项的信道特性矩阵表示为 $B_k^j = [\alpha_k^j, \theta_k^j, \phi_k^j, \vartheta_k^j, \varphi_k^j]^T \in \mathbf{R}^{5 \times N_c}$, 其中, $\alpha_k^j \in \mathbf{R}^{N_c \times 1}$ 为第 k 个位置项的路径功率向量, $\theta_k^j \in \mathbf{R}^{N_c \times 1}$ 和

$\phi_k^j \in \mathbf{R}^{N_c \times 1}$ 分别为第 k 个位置项垂直和水平方向的到达角向量, $\vartheta_k^j \in \mathbf{R}^{N_c \times 1}$ 和 $\varphi_k^j \in \mathbf{R}^{N_c \times 1}$ 分别为第 k 个位置项垂直和水平方向的偏离角, $k \in \{1, 2, \dots, K\}$ 。为了方便起见, 将这 K 个位置项的级联信道特性矩阵写成 $B_{KN}^j \in \mathbf{R}^{5 \times N_c \times K}$, 即

$$B_{KN}^j = [B_k^j] \quad (9)$$

并通过信道重构模型预测 \hat{p}_{des}^j 的信道特性矩阵。最后, 采用 $\{\hat{B}_{des}^j | j \in \{1, 2, \dots, N_{\Delta t}\}\}$ 表示所估计的预测轨迹信道。

接下来的两个小节将分别介绍移动方向预测模型和信道重构模型的组成结构, 其中, 移动方向预测模型采用两个结构相同的 CNN 进行设计, 信道重构模型采用 CNN 进行设计。

3.1 移动方向预测模型

移动方向预测模型用于将规划路线矩阵 U 和标记矩阵 M 映射到方向向量 $v = (\lambda, \gamma)$, 其中, 方向向量

中的两个元素分别为 $\lambda = \frac{x_{i+1} - x_i}{\sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2}}$ 和

$\gamma = \frac{y_{i+1} - y_i}{\sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2}}$, (x_i, y_i) 和 (x_{i+1}, y_{i+1}) 分别

为规划的路线 ζ 中移动终端驶过的最后一个拐点 p_i 和即将经过的第一个拐点 p_{i+1} , $i \in \{1, 2, \dots, N_c - 1\}$ 。由于方向向量 $v = (\lambda, \gamma)$ 中的两个元素分别与 p_i 和 p_{i+1} 在 x 轴和 y 轴方向上的位移差以及与 p_i 和 p_{i+1} 之间的距离有关, 可以将这两个元素的预测问题看成一个多任务学习问题, 即 x 轴和 y 轴向方向向量的预测问题, 该任务的目标是从训练数据中学习到的映射函数 $\mathcal{N}_\lambda(p_{src}, \zeta)$ 和 $\mathcal{N}_\gamma(p_{src}, \zeta)$, 分别预测方向向量 \hat{v} 的 x 轴分量 $\hat{\lambda}$ 和 y 轴分量 $\hat{\gamma}$, 进而实现对方向向量 $\hat{v} = (\hat{\lambda}, \hat{\gamma})$ 的预测。

本文采用两个结构相同的 CNN 来设计移动方向预测模型。如图 4 所示, 每个 CNN 由一个输入层、三个卷积层 (Convolutional Layer, CL)、三个激活层 (Activation Layer, AL)、一个展平层、一个全连接层 (Fully connected Layer, FL)、一个激活层和一个输出层组成。为了加快移动方向预测模型的收敛速度, 将规划路线矩阵 U 和标记矩阵 M 作为输入, 预测移动终端移动方向上的单位向量。在所设计的预测模型中, 卷积层的作用是从输入数据中提取特征, 其中, 卷积层中 N_{conv} 个卷积核的大小均为

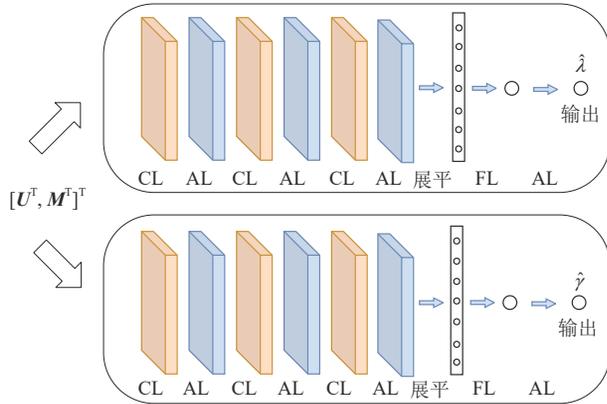


图4 移动方向预测模型

Fig. 4 The moving direction prediction model

$N_k \times N_k$ 。激活层的作用是为CNN引入非线性。展平层将其前一层输出特征一维化并输入至一个全连接层,对提取的局部信息进行融合汇聚。最后一个全连接层的输出被输入一个激活层,将学到的特征映射到 $(-1, 1)$ 的取值范围之内,实现对方向向量的预测。为了引入非线性特征、保证最后一个激活层的输出与二维空间中单位向量元素在取值范围上的一致性,激活层采用了Tanh函数。

本文采用监督学习的方式对预测模型进行训练。前文中本文已经将方向预测问题转化为 x 轴和 y 轴向方向向量两个任务的学习问题,而多任务学习问题常常将所有的损失进行联合优化,典型的损失函数 \mathcal{L}_{MTL} 为

$$\mathcal{L}_{\text{MTL}} = \sum_i w_i \mathcal{L}_i \quad (10)$$

其中, w_i 和 \mathcal{L}_i 分别为第 i 个任务的权重大小和损失函数, $i \in \{1, 2\}$ 。然而,这种方式通常需要手动调节 w_i ,模型最终的学习效果对权重十分敏感,因此往往很难同时收获对于多个任务都较优的模型,且费时费力。为了解决该问题,本文采用优化后的损失函数^[16],同时应用指数损失函数使得损失值恒为非负数。因此,移动方向预测模型的损失函数为:

$$\mathcal{L}(\mathbf{W}, \sigma_1, \sigma_2) = e^{\frac{1}{2\sigma_1^2} \mathcal{L}_1(\mathbf{W}) + \frac{1}{2\sigma_2^2} \mathcal{L}_2(\mathbf{W}) + \log \sigma_1 \sigma_2} \quad (11)$$

其中, \mathbf{W} 为权重参数, σ_1, σ_2 分别为 x 轴和 y 轴向方向向量预测任务的噪声参数, $\mathcal{L}_1(\mathbf{W}) = \|\lambda - \mathcal{N}_\lambda^{\mathbf{W}}(\mathbf{p}_{\text{src}}, \zeta)\|^2$ 和 $\mathcal{L}_2(\mathbf{W}) = \|\gamma - \mathcal{N}_\gamma^{\mathbf{W}}(\mathbf{p}_{\text{src}}, \zeta)\|^2$ 分别为 x 轴和 y 轴向方向向量预测任务的均方误差(Mean Squared Error, MSE)损失函数。在模型的训练阶段,通过最小化损失函数,噪声参数 σ_1 和 σ_2 能够根

据数据自适应地学习损失 $\mathcal{L}_1(\mathbf{W})$ 和 $\mathcal{L}_2(\mathbf{W})$ 的相对权重。例如,随着 x 轴向方向向量预测任务的噪声参数 σ_1 的增加, $\mathcal{L}_1(\mathbf{W})$ 的权重就会下降。另一方面,随着噪声的减少,各项损失的权重增加。最后一项则充当了噪声项的正则化器,噪声参数设置得越大,则正则化惩罚越大。噪声参数 σ_1, σ_2 以及模型的权重参数 \mathbf{W} 均通过梯度下降(Gradient Descent, GD)算法进行更新。

3.2 信道重构模型

信道重构模型用于实现从距离目标位置 $\hat{\mathbf{p}}_{\text{des}}^j$ 最近的 K 个位置项的级联信道特性矩阵 $\mathbf{B}_{\text{KN}}^j \in \mathbf{R}^{5 \times N_L \times K}$ 到 $\hat{\mathbf{p}}_{\text{des}}^j$ 的信道特性矩阵 $\hat{\mathbf{B}}_{\text{des}}^j \in \mathbf{R}^{5 \times N_L}$ 之间的映射。该模型利用了相邻位置信道特性的空间相关性^[17],即相邻位置的功率和角度等信道特性是空间一致的,在相邻位置上是缓慢变化的,因此,本文利用目标位置附近位置的信道特性矩阵,预测目标位置的信道特性矩阵。

如图5所示,模型由一个输入层、一个卷积层和一个输出层组成,其中,输入层以级联信道特性矩阵 \mathbf{B}_{KN}^j 作为输入,预测目标位置的信道特性矩阵。卷积层使用 $N_{\text{conv}} = 5$ 个大小为 $3 \times K$ 的卷积核,对输入的级联信道特性矩阵进行卷积运算。卷积核的移动步幅为1,并在输入的第二个维度上进行大小为1的零填充。根据卷积前后二维矩阵的尺度大小变化与卷积核大小、移动步幅和零填充之间的关系可以推出,卷积层的输出大小为 $5 \times N_L$,将其作为目标位置的信道特性矩阵预测结果 $\hat{\mathbf{B}}_{\text{des}}^j$ 。模型以监督学习的方式进行训练,采用MSE函数作为损失函数,即:

$$\text{Loss} = \|\mathbf{B}_{\text{des}}^j - \hat{\mathbf{B}}_{\text{des}}^j\|_{\text{F}}^2 \quad (12)$$

其中, F 为Frobenius范数, $\mathbf{B}_{\text{des}}^j$ 为目标位置 $\hat{\mathbf{p}}_{\text{des}}^j$ 的信道特性矩阵。

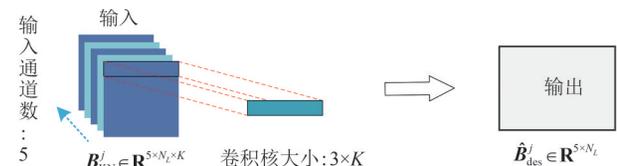


图5 基于CNN的信道重构模型

Fig. 5 CNN based channel reconstruction model

综上,本文提出的智能信道预测方法通过预测移动终端的移动轨迹、估计预测轨迹的信道,实现信道预测。其中,轨迹预测通过基于CNN的移动方

向预测模型实现,信道估计通过基于 CNN 的信道重构模型实现。根据移动终端规划路线、所在位置和移动速度大小等易获取的信息,借助构建的 CPM,利用训练好的 CNN 即可实现信道的预测。因此,该方法能够无导频信道估计,同时可以节省反馈估计信道的开销,解决信道老化问题。

4 仿真分析

4.1 仿真参数设置

本文利用 Wireless InSite 软件^[18]收集移动方向预测和信道重构两个模型的数据集,如图 6 所示,为所搭建的射线跟踪仿真环境。在 Wireless InSite 生成规划路线及其拐点之间的移动所在位置和若干目标位置,用于训练移动方向预测模型并评估其性能,其中,规划路线的中拐点个数 $N_c = 10$ 。本文为移动方向预测模型收集的训练集和测试集样本数目分别为 10000 和 320 个。移动方向预测模型中每个卷积层使用的卷积核大小为 2×2 ,其在两个维度上的移动步长均为 1。模型训练迭代次数和小批量的大小均为 100,反向传播过程采用 Adam 优化器,学习率为 0.01。

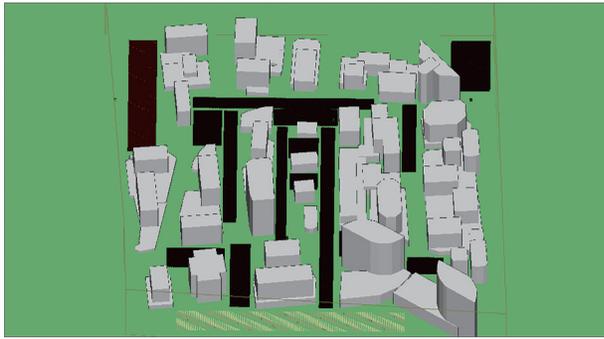


图 6 射线跟踪仿真环境

Fig. 6 The ray tracing simulation environment

其次,通过射线跟踪方法收集基站覆盖范围内均匀分布的接收位置项的有效路径信息,用于构建 CPM,其中,各位置项之间的间隔 $d = 0.5 \text{ m}$ 。收集信道特性时,基站和移动终端安装的 UPA 天线在垂直和水平方向的天线数分别为 $N_E = 4$ 和 $N_z = 8$,采用垂直极化的传播方式,每个位置上保存信号接收功率最高的 $N_L = 25$ 条直射和反射等路径的信息。然后在该范围内生成随机目标位置并收集其坐标信息和有效路径信息,用于训练信道重构模型、评估模型性能。所收集的信道重构

模型训练和测试样本分别为 6000 和 2000 个,训练迭代次数为 100,小批量的大小为 50。采用 Adam 优化器计算 Loss 损失函数的梯度并更新参数,其学习率为 0.01。

最后,利用训练好的移动方向预测模型获得预测方向向量,根据预测方向向量,运用运动学原理计算预测轨迹。进一步地,从构建的 CPM 中获取预测轨迹上各目标位置的级联信道特性矩阵,利用训练好的信道重构模型估计预测轨迹的信道,实现信道预测。收集测试样本中规划路线拐点之间各目标位置的有效路径信息,即真实轨迹的信道,用于评估信道预测方法的性能。

4.2 移动方向预测模型的性能

本文采用 N_{test} 个预测目标位置与真实目标位置间的均方根误差 (Root-Mean-Square Error, RMSE) 的平均值 RMSE_p^j ,以及 N_{test} 条预测轨迹与真实轨迹间的总均方根误差的平均值 RMSE_ζ ,评估移动方向预测模型的性能。 RMSE_p^j 表示为:

$$\text{RMSE}_p^j = \frac{1}{N_{\text{test}}} \sum_{n=1}^{N_{\text{test}}} \|\mathbf{p}_{\text{des}}^n - \hat{\mathbf{p}}_{\text{des}}^n\|_F \quad (13)$$

其中, N_{test} 为测试样本数, $\mathbf{p}_{\text{des}}^n$ 和 $\hat{\mathbf{p}}_{\text{des}}^n$ 分别表示单位时间间隔数目为 j 时,第 n 个目标位置和相应预测目标位置。进一步地, RMSE_ζ 表示为:

$$\text{RMSE}_\zeta = \frac{1}{N_{\text{test}}} \sum_{n=1}^{N_{\text{test}}} \sum_{j=1}^{N_{\Delta t}} \|\mathbf{p}_{\text{des}}^n - \hat{\mathbf{p}}_{\text{des}}^n\|_F = \sum_{j=1}^{N_{\Delta t}} \text{RMSE}_p^j \quad (14)$$

其中, N_{test} 为测试样本数, $N_{\Delta t}$ 为可预测轨迹长度。

首先,根据移动方向预测模型输出的预测方向向量以及未来时间间隔时长,计算预测目标位置,然后计算预测目标位置与真实目标位置间的均方根误差。如图 7 所示,为 $N_{\text{test}} = 320$ 个预测目标位置

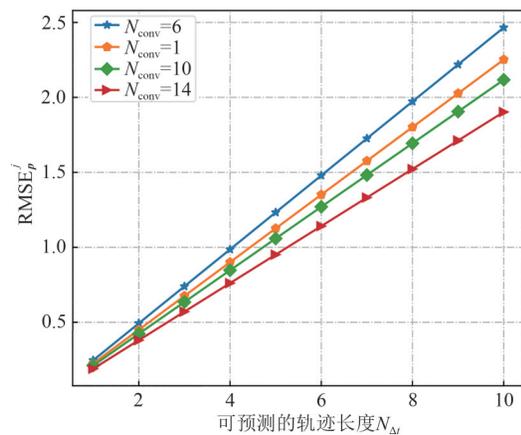


图 7 RMSE_p^j 随 j 变化

Fig. 7 RMSE_p^j varies with j

与真实目标位置间的均方根误差的平均值 RMSE_p^j 随单位时间间隔的数目 j 变化的曲线。其中,对于不同的 j ,使用相同的 320 个预测方向向量计算预测位置。从图 7 中可以看出,当 j 较小时,卷积层使用不同卷积核个数 $N_{\text{conv}} = \{1, 6, 10, 14\}$,其移动方向预测模型的 RMSE_p^j 都比较高,因为此时预测位置和真实位置与移动终端所在位置间的距离都比较近,由不同的模型参数选取方法引起的 RMSE_p^j 差距较小。随着 j 增加, RMSE_p^j 呈线性上升趋势,这是因为对于同一个预测方向,若预测方向存在误差,则时间间隔越长,预测位置与真实位置间的距离越大。此外,随着 j 的增加,使用卷积核个数 $N_{\text{conv}} = \{1, 6, 10, 14\}$ 的模型,在 RMSE_p^j 方面的差距变得越来越大,其中, N_{conv} 为 14 时, RMSE_p^j 是最小的。

其次,根据移动方向预测模型输出的预测方向向量以及可预测轨迹长度,计算预测轨迹,然后计算预测轨迹与真实轨迹间的总均方根误差。如图 8 所示,为 $N_{\text{test}} = 320$ 条预测轨迹与真实轨迹间的总均方根误差的平均值 RMSE_ζ 随可预测轨迹长度 N_{Δ} 变化的曲线,其中,对于不同的 N_{Δ} ,使用相同的 320 个预测方向向量计算预测轨迹。从图 8 中可以看出, $N_{\text{conv}} = 14, N_{\Delta} \leq 4$ 时, RMSE_ζ 低于 2; 随着 N_{Δ} 的增加, RMSE_ζ 急剧增大,这是因为 RMSE_ζ 曲线的斜率 $\text{RMSE}_\zeta^{N_{\Delta}}$ 随着 N_{Δ} 的增加线性上升。

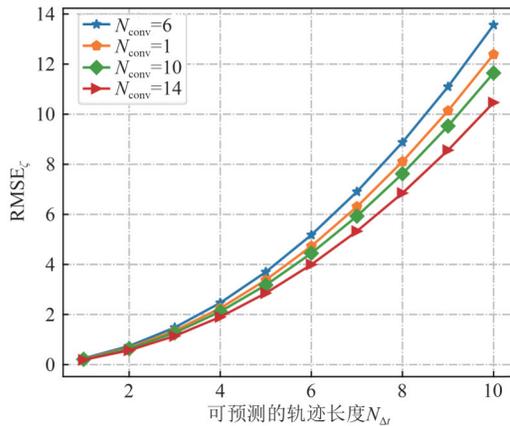


图 8 RMSE_ζ 随 N_{Δ} 变化

Fig. 8 RMSE_ζ varies with N_{Δ}

4.3 信道重构模型的性能

进一步地,为了验证本文所提出的基于 CNN 的信道重构模型的性能,将其与基于 KNN 插值的信道重构方法和基于全连接神经网络 (Fully Connected neural Network, FCN) 的信道重构模型进行比较。

基于 KNN 插值的信道重构方法估计的目标位置信道 $\hat{\mathbf{B}}_{\text{des}} \in \mathbf{R}^{5 \times N_L}$ 可以表示为:

$$\hat{\mathbf{B}}_{\text{des}} = \frac{\sum_{k=1}^K \frac{1}{d_k} \mathbf{B}_k}{\sum_{k=1}^K \frac{1}{d_k}} \quad (15)$$

其中, d_k 为第 k 个位置项与目标位置之间的距离, $\mathbf{B}_k \in \mathbf{R}^{5 \times N_L}$ 为第 k 个位置项的信道特性矩阵。根据 KNN 插值算法的实现原理可推出,基于 KNN 插值的信道重构方法需要进行 $K - 1$ 次矩阵加法运算,其时间和空间复杂度与 \mathbf{B}_k 中元素的个数呈正相关。基于 FCN 的信道重构模型采用的全连接神经网络结构如图 9 所示,包括一个输入层、一个展平层、三个全连接层和一个输出层。其中,输入层以距离目标位置最近的 K 个位置项的信道特性矩阵作为输入,预测目标位置的信道特性矩阵。展平层则用于将输入的多维信息展平,作为全连接层的输入。三个全连接层分别由 $5N_L\beta_1, 5N_L\beta_2$ 和 $5N_L$ 个神经元组成,其作用是从这 K 个位置项的信道特性矩阵中提取特征,重构目标位置的信道特性矩阵。输出层则将最后一个全连接层输出的特征映射成大小为 $5 \times N_L$ 的二维矩阵,作为目标位置的信道特性矩阵预测结果。

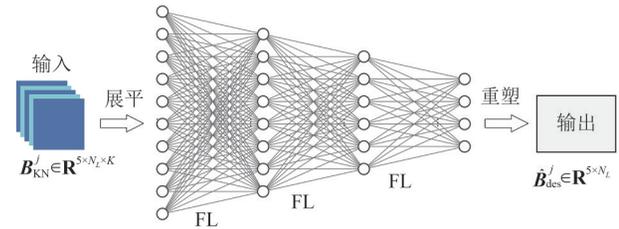


图 9 基于 FCN 的信道重构模型

Fig. 9 FCN based channel reconstruction model

在无位置预测误差的情况下,本文采用 N_{test} 个估计的随机目标位置的信道特性矩阵,与其真实信道特性矩阵间的相对误差 (Relative Error, RE) 的平均值 RE_B , 评估信道重构模型的性能。 RE_B 表示为

$$\text{RE}_B = \frac{1}{N_{\text{test}}} \sum_{n=1}^{N_{\text{test}}} \frac{\|\mathbf{B}_{\text{des}}^n - \hat{\mathbf{B}}_{\text{des}}^n\|_F}{\|\mathbf{B}_{\text{des}}^n\|_F} \times 100\% \quad (16)$$

其中, N_{test} 为测试样本数, $\hat{\mathbf{B}}_{\text{des}}^n \in \mathbf{R}^{5 \times N_L}$ 和 $\mathbf{B}_{\text{des}}^n \in \mathbf{R}^{5 \times N_L}$ 分别为估计的第 n 个随机目标位置的信道特性矩阵,以及第 n 个随机目标位置的真实信道特性矩阵。

如图 10 所示,为基于 FCN 和 CNN 的信道重构

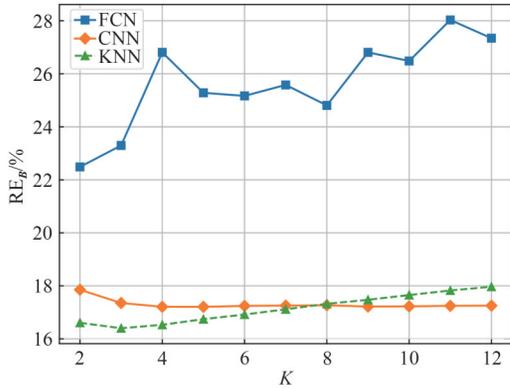


图 10 RE_B随K值变化
Fig. 10 RE_B varies with K

模型以及基于KNN插值的信道重构方法对随机目标位置的信道估计相对误差平均值RE_B随K值变化的曲线,其中,N_{test} = 2000,FCN中β₁ = 7,β₂ = 2。从图10中可以观察到各方法的RE_B随K值变化的规律:随着K值增大,基于CNN的信道重构模型的RE_B逐渐减小,在K > 4之后RE_B减小的幅度较小;KNN插值方法的RE_B先降后升,K = 3时达到最小值;而基于FCN的信道重构模型的RE_B有随着K值的增大逐渐变大的趋势。进一步地,根据图10,可以比较这三种方法在RE_B方面的优劣。首先,基于FCN的信道重构模型在RE_B方面的表现最差,为26%左右,而其他方法的RE_B低于18%。基于CNN的信道重构模型的RE_B比基于FCN的信道重构模型的RE_B低8%左右,是因为相比于FCN,CNN能够从K个位置项的信道特性矩阵中提取到局部特征,更适合用于重构目标位置的信道特性矩阵。其次,K < 8时,基于CNN的信道重构模型在RE_B上的表现稍落后于KNN插值方法,差距约为1%;K = 8时,二者表现相当;K > 8时,基于CNN的信道重构模型优于KNN插值方法,差距也约为1%。综上所述,本文提出的基于CNN的信道重构模型能够有效地重构出目标位置的信道特性矩阵,K = 4时RE_B达到最小值,K较大时比KNN插值方法更好。

4.4 智能信道预测方法的性能

最后,本文利用训练好的移动方向预测模型进行目标位置和轨迹的预测,然后利用训练好的信道重构模型以及基于KNN插值的信道重构方法,对预测目标位置和预测轨迹的信道进行估计,实现信道预测。最后,为了验证本文所提出的基于CNN的信道预测方法的性能,将基于CNN和FCN的信道预测

方法和基于KNN插值的信道预测方法的性能进行对比。

进一步地,在存在位置预测误差的情况下,本文采用N_{test}个估计的预测目标位置的信道特性矩阵,与真实信道特性矩阵间的相对误差的平均值RE_B^j,以及N_{test}条估计的预测轨迹信道,与真实轨迹信道之间的总相对误差(Sum of Relative Error,SRE)的平均值SRE_B^{N_Δ},评估信道预测方法的性能。RE_B^j表示为:

$$RE_B^j = \frac{1}{N_{test}} \sum_{n=1}^{N_{test}} \frac{\|B_{des}^n - \hat{B}_{des}^n\|_F}{\|B_{des}^n\|_F} \times 100\% \quad (17)$$

其中,N_{test}为测试样本数,B_{des}ⁿ和B_{des}^{̂n}分别为单位时间间隔数目为j时,第n个目标位置的信道特性矩阵和估计的第n个预测目标位置的信道特性矩阵。进一步地,SRE_B^{N_Δ}表示为:

$$SRE_B^{N_{\Delta}} = \frac{1}{N_{test}} \sum_{n=1}^{N_{test}} \sum_{j=1}^{N_{\Delta}} \frac{\|B_{des}^n - \hat{B}_{des}^n\|_F}{\|B_{des}^n\|_F} \times 100\% = \sum_{j=1}^{N_{\Delta}} RE_B^j \quad (18)$$

其中,j为单位时间间隔Δt的数目,N_Δ为可预测的轨迹长度。

如图11所示,为基于KNN插值、基于FCN和基于CNN的信道预测方法对预测目标位置的信道估计相对误差平均值RE_B¹随K值变化的曲线,其中,N_{test} = 320,FCN中β₁ = 7,β₂ = 2。从图11中可以看出,在RE_B¹方面,基于CNN和基于KNN插值的信道预测方法明显优于基于FCN的信道预测方法。其次,结合图10和图11可以发现:在存在位置预测误差的情况下,基于FCN和CNN的信道预测方法的RE_B¹和RE_B随K值变化的规律相似;而基于KNN插值的信道预测方法的RE_B¹与RE_B随K值变化的规律

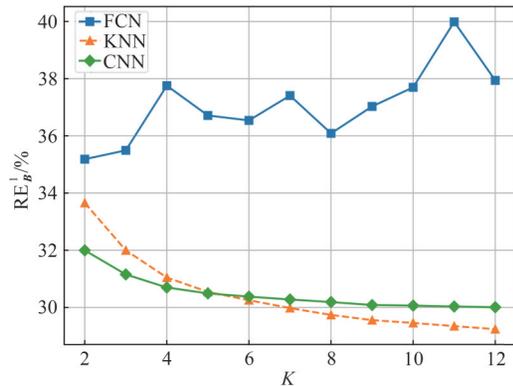


图 11 RE_B¹随K值变化
Fig. 11 RE_B¹ varies with K

几乎相反,即 RE_B 随着 K 值的增大先降后升,而 RE_B^1 随着 K 值的增大逐渐减小。因此,在信道估计相对误差随 K 值变化的规律方面,基于KNN插值的信道预测方法受位置预测误差增大的影响最大。最后,通过比较基于CNN和基于KNN插值的信道预测方法在 RE_B^1 上的表现得出:在 $K < 6$ 时,基于CNN的信道预测方法明显优于基于KNN插值的信道预测方法; $K = 6$ 时,二者表现相当; $K > 6$ 时,由于基于CNN的信道预测方法的 RE_B^1 下降幅度较小,基于KNN插值的信道预测方法的 RE_B^1 比基于CNN的信道预测方法的 RE_B^1 小1%左右。结合图10和图11,得出以下结论:在无位置预测误差时, $K > 8$ 之后,基于CNN的信道重构模型优于基于KNN插值的信道预测方法。然而,在存在位置预测误差的情况下, K 值较小时,基于CNN的信道预测方法反而更有优势。

进一步地,采用 $RE_B^1 - RE_B$ 衡量有无位置预测误差对预测目标位置的信道估计相对误差的影响程度。如图12所示,为基于KNN插值、基于FCN和基于CNN的信道预测方法的 $RE_B^1 - RE_B$ 随 K 值变化的曲线。从图12中可以看出 $RE_B^1 - RE_B$ 恒大于零,是因为预测目标位置与目标位置间的误差,使得预测目标位置附近位置项的信道与目标位置附近位置项的信道存在偏差,导致分别以前者和后者作为输入特征的信道预测方法估计的信道之间存在误差。此外,基于FCN的信道预测方法的 $RE_B^1 - RE_B$ 约为11%,基于CNN的信道预测方法和基于KNN插值的信道预测方法的 $RE_B^1 - RE_B$ 约为13%,因此,基于FCN的信道预测方法的信道估计相对误差受有无位置预测误差的影响最小。

除了 K 值,未来时间间隔时长也会影响对预测

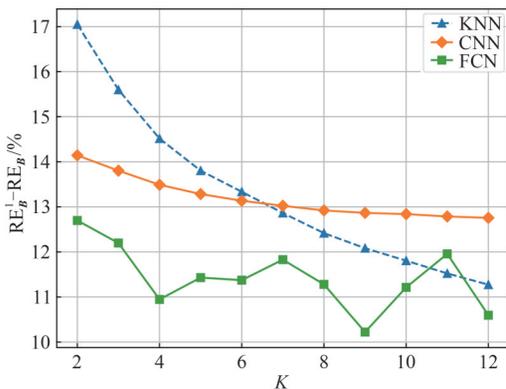


图12 $RE_B^1 - RE_B$ 随 K 值变化
Fig. 12 $RE_B^1 - RE_B$ varies with K

目标位置的信道估计相对误差。如图13所示,为基于KNN插值和基于CNN的信道预测方法的 RE_B^1 随单位时间间隔数目 j 变化的曲线。从图13来看, RE_B^1 随着 j 的增加逐渐上升。这是由于 $RMSE_B^1$ 随 j 的增加呈线性上升趋势,导致以预测目标位置附近位置项的信道特性矩阵作为信道预测输入的信道预测方法和基于CNN的信道预测方法,估计的预测目标位置的信道与真实信道间的误差变大。此外,与从图11中得出的结论类似, $K = 6$ 时,基于CNN和基于KNN插值的信道预测方法的 RE_B^1 曲线几乎重合,两者在 RE_B^1 方面表现相当。

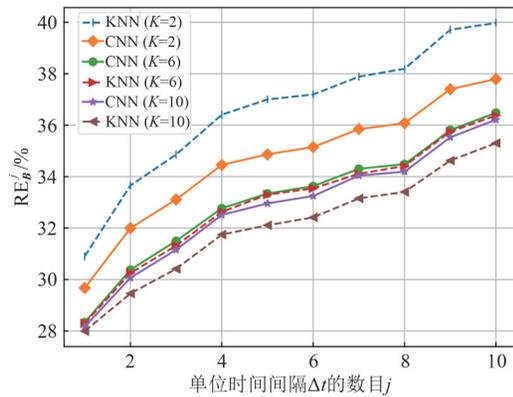


图13 基于KNN插值和基于CNN的信道预测方法的 RE_B^1 随单位时间间隔数目 j 变化
Fig. 13 RE_B^1 of KNN interpolation and CNN based channel prediction methods varies with j

此外,本文还将基于CNN的信道预测方法与其他基于神经网络的信道预测方法,在不同的未来时间间隔时长下进行了比较。如图14所示,为基于

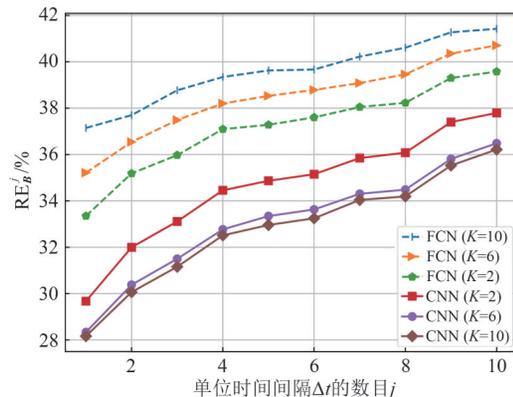


图14 基于FCN和CNN的信道预测方法的 RE_B^1 随单位时间间隔数目 j 变化
Fig. 14 RE_B^1 of FCN and CNN based channel prediction methods varies with j

FCN 和 CNN 的信道预测方法的 RE_B^j 随单位时间间隔数目 j 变化的曲线, 其中, FCN 中 $\beta_1 = 7, \beta_2 = 2$ 。从图 14 中可以看出, 随着 j 的增加, RE_B^j 缓慢上升, 并且基于 CNN 的信道预测方法明显优于基于 FCN 的信道预测方法。其次, K 值从 2 增加到 6 和 10, 基于 CNN 的信道预测方法的 RE_B^j 逐渐变小, 且减小幅度越来越小, 而基于 FCN 的信道预测方法的 RE_B^j 逐渐变大, 这与图 11 中基于 CNN 和 FCN 的信道预测方法的 RE_B^j 随相应 K 值变化的规律相符。

以上是对单个预测目标位置的信道估计相对误差, 通过估计预测轨迹上各预测目标位置的信道, 可以获得预测轨迹的信道。如图 15 所示, 为基于 KNN 插值的信道预测方法, 和本文提出的基于 CNN 的信道预测方法对预测轨迹的信道估计总相对误差 $SRE_B^{N_\Delta}$, 随可预测轨迹长度 N_Δ 变化的曲线。从图 15 中可以看出, 随着 N_Δ 的增加, $SRE_B^{N_\Delta}$ 呈线性上升的趋势, 这是因为 $SRE_B^{N_\Delta}$ 是对预测轨迹上所有预测目标位置的信道估计相对误差的求和结果, 而上升趋势是线性的, 则是因为各线段的斜率相差较小。例如, $K = 2$ 时, CNN 的 $SRE_B^{N_\Delta}$ 曲线中第 1 条线段的斜率为

$$\kappa_1 = SRE_B^2 - SRE_B^1 = \sum_{j=1}^2 RE_B^j - \sum_{j=1}^1 RE_B^j = RE_B^2 \quad (19)$$

第 2 条线段的斜率为

$$\kappa_2 = SRE_B^3 - SRE_B^2 = \sum_{j=1}^3 RE_B^j - \sum_{j=1}^2 RE_B^j = RE_B^3 \quad (20)$$

两条线段的斜率之差为 $\Delta\kappa = \kappa_2 - \kappa_1$, 由图 13 可得, $\Delta\kappa$ 约为 2%。以此类推, 各线段的斜率差都在 1%~2% 左右。与 $SRE_B^{N_\Delta}$ 曲线 35% 左右的斜率相比, 斜率

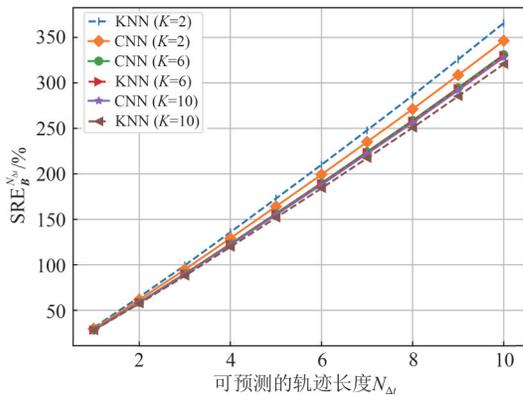


图 15 基于 KNN 插值和基于 CNN 的信道预测方法的 $SRE_B^{N_\Delta}$ 随可预测轨迹长度 N_Δ 变化

Fig. 15 $SRE_B^{N_\Delta}$ of KNN interpolation and CNN based channel prediction methods varies with N_Δ

差较小, 因此, 随着 N_Δ 的增加, $SRE_B^{N_\Delta}$ 上升的趋势几乎是线性的。其次, 从图 15 中的仿真结果来看, 当 K 值较小, 例如 $K = 2$ 时, 在 $SRE_B^{N_\Delta}$ 方面, 基于 CNN 的信道预测方法明显优于基于 KNN 插值的信道预测方法; 当 K 增加到 6 时, 基于 CNN 的信道预测方法与基于 KNN 插值的信道预测方法的表现相当; $K > 6$ 之后, 基于 KNN 插值的信道预测方法以微弱优势领先于基于 CNN 的信道预测方法, 但需要进行 $K - 1$ 次矩阵加法运算, 其时间和空间复杂度与信道特性矩阵中元素的个数呈正相关。而基于 CNN 的信道预测方法与信道特性矩阵中元素的个数无关, 用于估计信道的信道重构模型参数参数较少, 只有 5 个大小为 $3 \times K$ 的卷积核参数, 训练好的模型能实现快速的信道估计。此外, 在 $SRE_B^{N_\Delta}$ 方面, 基于 CNN 的信道预测方法受 K 值变化的影响较小, 鲁棒性较好, 适用于更广泛的应用场景。

另外, 在 $SRE_B^{N_\Delta}$ 方面, 基于 CNN 的信道预测方法能够获得比基于 FCN 的信道预测方法更好的性能。如图 16 所示, 为基于 FCN 和 CNN 的信道预测方法的 $SRE_B^{N_\Delta}$ 随可预测轨迹长度 N_Δ 变化的曲线, 其中, FCN 中 $\beta_1 = 7, \beta_2 = 2$ 。从图 16 中可以看出, 在 $SRE_B^{N_\Delta}$ 方面, 基于 CNN 的信道预测方法的表现明显优于基于 FCN 的信道预测方法, 并且随着 N_Δ 的增加, 基于 CNN 的信道预测方法的优势变得更加明显。

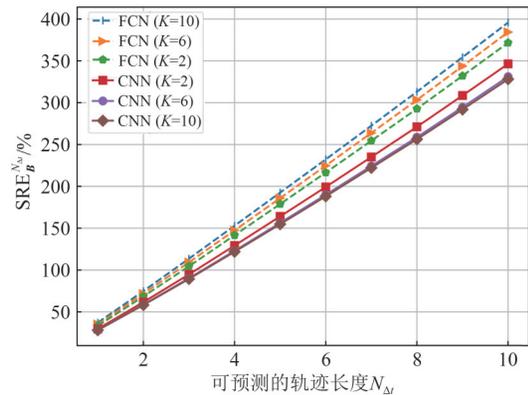


图 16 基于 FCN 和 CNN 的信道预测方法的 $SRE_B^{N_\Delta}$ 随可预测轨迹长度 N_Δ 变化

Fig. 16 $SRE_B^{N_\Delta}$ of FCN and CNN based channel reconstruction model varies with N_Δ

从仿真结果中可以得出以下结论: 在无位置预测误差的情况下, 与基于 KNN 插值的信道重构方法相比, $K > 8$ 时, 本文提出的信道模型对随机目标位

置的信道估计相对误差更小;与基于FCN的信道重构模型相比,本文提出的信道模型信道估计相对误差较小。其次,在存在位置预测误差的情况下,与基于KNN插值的信道预测方法相比, $K < 6$ 时,本文提出的信道预测方法对预测目标位置和预测轨迹的信道估计相对误差和总相对误差更小,并且受 K 值变化的影响较小,适用于更广泛的场景;与基于FCN的信道预测方法相比,本文提出的信道预测方法更适合用于预测目标位置和预测轨迹的信道估计。

此外,与传统信道估计方法相比,本文提出的信道预测方法实现了无导频信道估计,并节省了反馈估计信道开销等。其次,与实际信道估计方法在移动过程中频繁地进行信道估计的方法不同,所提方法通过估计长度为 N_{L} 的预测轨迹的信道,实现信道预测,解决信道老化问题。进一步地,利用所提方法预测的信道,可以辅助无线传输方案(例如预编码)的设计,并且通过预测最佳的无线传输方案,可避免移动过程中频繁的信道估计和无线传输方案设计,进一步降低了建立基站与移动终端之间通信链路所需的时间。

5 结论

本文提出的智能信道预测方法用于预测移动终端在未来一段时间内的信道,该方法分为轨迹预测和信道重构两个部分。通过利用移动方向预测模型预测方向向量,运用运动学原理可以预测移动终端的移动轨迹,其中,预测轨迹由若干个目标位置组成。基于多任务学习,本文采用两个结构相同的CNN设计移动方向预测模型,能够获得较低的预测位置与真实位置间的均方根误差。进一步地,根据目标位置附近 K 个位置项的信道特性矩阵,利用信道重构模型估计目标位置的信道特性矩阵,进而实现对预测轨迹的信道估计,其中,信道重构模型采用CNN进行设计。最后,利用Wireless InSite搭建仿真环境,生成规划路线,使用其提供的先进的射线跟踪功能生成信道样本等数据集,对移动方向预测模型和信道重构模型进行训练,训练好的模型被用于实现智能信道预测。仿真结果表明,所提方法能够有效地估计MIMO信道特性。此外,从预测轨迹的信道估计总相对误差来看, K 值较小时,所提方法比基于距离权重的KNN插值方法更好,并且受 K 值变化的影响较小,适用于更广泛的场景;与基于

FCN的信道预测方法相比,所提方法的总相对误差明显较小,更适合用于预测轨迹的信道估计。另外,与传统信道估计方法相比,所提方法无需发送导频,可以节省反馈估计信道开销。所提方法通过信道预测解决信道老化问题,所预测的信道可用于辅助无线传输方案的设计,避免了移动场景下频繁的信道估计和无线传输方案设计过程,能够降低通信延迟。

参考文献

- [1] HE Shiwen, ZHANG Yan, WANG Jiaheng, et al. A survey of millimeter-wave communication: Physical-layer technology specifications and enabling transmission technologies[J]. Proceedings of the IEEE, 2021, 109(10): 1666-1705.
- [2] MACCARTNEY G R, SAMIMI M K, RAPPAPORT T S. Exploiting directionality for millimeter-wave wireless system improvement[C]//2015 IEEE International Conference on Communications. London, UK. IEEE, 2015: 2416-2422.
- [3] WANG Zhihao, CHEN Jian, HOI S C H. Deep learning for image super-resolution: A survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 43(10): 3365-3387.
- [4] YOUNG T, HAZARIKA D, PORIA S, et al. Recent trends in deep learning based natural language processing[J]. IEEE Computational Intelligence Magazine, 2018, 13(3): 55-75.
- [5] YE Hao, LI G Y, JUNAG B H. Power of deep learning for channel estimation and signal detection in OFDM systems[J]. IEEE Wireless Communications Letters, 2017, 7(1): 114-117.
- [6] ZENG Yong, XU Xiaoli. Toward environment-aware 6G communications via channel knowledge map[J]. IEEE Wireless Communications, 2021, 28(3): 84-91.
- [7] DING Dingyang, WU Di, ZENG Yong, et al. Environment-aware beam selection for IRS-aided communication with channel knowledge map[C]//2021 IEEE Globecom Workshops. Madrid, Spain. IEEE, 2021: 1-6.
- [8] HUANG Fengqing, HE Shiwen, HUANG Wei, et al. Location-assisted beam tracking and selection for downlink MISO via unsupervised learning[C]//2021 International Conference on Wireless Communications and Signal Processing. Changsha, China. IEEE, 2021: 1-5.
- [9] YANG Wenming, ZHANG Xuechen, TIAN Yapeng, et al. Deep learning for single image super-resolution: A brief review[J]. IEEE Transactions on Multimedia,

- 2019, 21(12): 3106-3121.
- [10] SOLTANI M, POURAHMADI V, MIRZAEI A, et al. Deep learning-based channel estimation [J]. IEEE Communications Letters, 2019, 23(4): 652-655.
- [11] SHI Qi, LIU Yangyu, ZHANG Shunqing, et al. Channel estimation for WiFi prototype systems with super-resolution image recovery [C]// 2019 IEEE International Conference on Communications. Shanghai, China. IEEE, 2019: 1-6.
- [12] DENG Ruichen, JIANG Zhiyuan, ZHOU Sheng, et al. A two-step learning and interpolation method for location-based channel database construction [C]//2018 IEEE Global Communications Conference. Abu Dhabi, United Arab Emirates. IEEE, 2018: 1-6.
- [13] 胡逸文, 杨晨阳, 刘婷婷. 无线信道预测: 联邦学习与集中式学习的通信开销 [J]. 信号处理, 2021, 37(10): 1930-1940.
HU Yiwen, YANG Chenyang, LIU Tingting. Wireless channel prediction: Communication overhead of federated learning and centralized training [J]. Journal of Signal Processing, 2021, 37(10): 1930-1940. (in Chinese)
- [14] HEATH R W, GONZÁLEZ-PRELCIC N, RANGAN S, et al. An overview of signal processing techniques for millimeter wave MIMO systems [J]. IEEE Journal of Selected Topics in Signal Processing, 2016, 10(3): 436-453.
- [15] TSAI Y, ZHENG Le, WANG Xiaodong. Millimeter-wave beamformed full-dimensional MIMO channel estimation based on atomic norm minimization [J]. IEEE Transactions on Communications, 2018, 66(12): 6150-6163.
- [16] KENDALL A, GAL Y, CIPOLLA R. Multi-task learning using uncertainty to weigh losses for scene geometry and semantics [C]//2018 IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA. IEEE, 2018: 7482-7491.
- [17] TURKKA J, KELA P, COSTA M. On the spatial consistency of stochastic and map-based 5G channel models [C]//2016 IEEE Conference on Standards for Communi-

cations and Networking (CSCN). Berlin, Germany. IEEE, 2016: 1-7.

- [18] Remcom, Wireless InSite [EB/OL]. <https://www.remcom.com/wireless-insite-em-propagation-software>, 2022-05-25.

作者简介



何世文 男, 1978年生, 湖南汝城人。中南大学计算机学院教授, 博士生导师, 主要研究方向为无线通信理论、分布式学习与优化计算理论、智能物联网(AIoT)和大数据分析的基础理论研究及智能网络平台开发及先进理论技术的验证。

E-mail: shiwen.he_hn@csu.edu.cn



黄凤青 女, 1998年生, 广西来宾人。中南大学计算机学院硕士研究生, 主要研究方向为机器学习及其应用。

E-mail: huangfq@csu.edu.cn



安振宇 男, 1988年生, 安徽蚌埠人。网络通信与安全紫金山实验室, 高级工程师, 主要研究方向为超可靠低时延通信、跨层优化、智能优化等。

E-mail: anzhenyu@pmlabs.com.cn



王良鹏 男, 1989年生, 江苏镇江人。网络通信与安全紫金山实验室, 工程师, 主要研究方向为无线通信与网络、大数据分析、人工智能算法、多尺度小波分析理论、图像处理与模式识别理论。

E-mail: jswanglp@163.com



熊绍文 男, 1996年生, 河南信阳人。中南大学计算机学院硕士研究生, 主要研究方向为图神经网络及深度Unfolding理论及其应用。

E-mail: shaowen.xiong@csu.edu.cn