

基于 DNN 的 Sub-6 GHz 辅助毫米波网络功率分配算法

孙长印^{1,2}, 刘李延¹, 江帆^{1,2}, 姜静^{1,2}

(1. 西安邮电大学通信与信息工程学院, 陕西 西安 710121; 2. 西安邮电大学信息通信网络与安全重点实验室, 陕西 西安 710121)

摘 要: 针对毫米波系统功率控制测量伴随的信令开销与功耗, 以及迭代操作带来的复杂度问题, 提出了一种使用 Sub-6 GHz 频段预测毫米波链路功率分配的算法。首先, 分析了 Sub-6 GHz 频段信道信息到毫米波频段最佳功率分配的映射关系。其次, 基于这种映射关系设计了一种深度神经网络 (DNN) 模型, 通过使用加权最小均方误差 (WMMSE) 准则对神经网络进行了不同场景的训练, 实现利用 Sub-6 GHz 频段对毫米波频段信道的功率分配进行预测。仿真结果表明, 所提算法在仅采用 Sub-6 GHz 频段信道信息的情况下, 与毫米波频段下的 WMMSE 算法相比, 可在耗时少于其 0.1% 的同时, 获得其不小于 97% 的和速率性能。

关键词: 毫米波通信; 功率分配; 深度学习; 神经网络

中图分类号: TN928

文献标识码: A

DOI: 10.11959/j.issn.1000-436x.2021170

DNN-based Sub-6 GHz assisted millimeter wave network power allocation algorithm

SUN Changyin^{1,2}, LIU Liyan¹, JIANG Fan^{1,2}, JIANG Jing^{1,2}

1. School of Communication and Information Engineering, Xi'an University of Posts and Telecommunications, Xi'an 710121, China

2. Key Laboratory of Information Communication Network and Security, Xi'an University of Posts and Telecommunications, Xi'an 710121, China

Abstract: Aimed at the problems of the signaling cost and power consumption in the power control measurement of the millimeter wave system, as well as the complexity caused by iteration operations, a millimeter wave link power allocation prediction algorithm using the Sub-6 GHz frequency band was proposed. Firstly, the mapping between the Sub-6 GHz band channel information and the optimal power allocation of the millimeter wave band was analyzed. Then, a deep neural network (DNN) model was utilized to realize this mapping function. To predict the power allocation of millimeter wave channel with Sub-6 GHz channel as input, the neural network was trained with the weighted mean square error minimization method (WMMSE) as the supervisor in different scenarios. The simulation results show that compared with the WMMSE algorithm in millimeter wave band, the proposed algorithm can obtain more than 97% of its sum-rate performance while taking less than 0.1% of the time.

Keywords: millimeter wave communication, power allocation, deep learning, neural network

1 引言

随着当前蜂窝网络数据需求的迅猛增长, 传统蜂窝网络所采用的频段已经无法胜任工作, 无线通

信系统正向更高的频率发展^[1]。毫米波 (mmWave, millimeter wave) 频段具有丰富的可用频谱资源, 可以使无线通信系统实现更大的容量。此外, 毫米波还具有速率高、波束窄、能量集中且方向性好等

收稿日期: 2021-04-07; 修回日期: 2021-07-01

基金项目: 国家自然科学基金资助项目 (No.61801382, No.61871321, No.62071377); 陕西省自然科学基金资助项目 (No.2019JZ-06); 陕西省重点产业链项目 (No.2020ZDLGY02-06, No.2019ZDLGY07-06)

Foundation Items: The National Natural Science Foundation of China (No.61801382, No.61871321, No.62071377), The Natural Science Foundation of Shaanxi Province (No.2019JZ-06), The Key Chain Project of Shaanxi Province (No.2020ZDLGY02-06, No.2019ZDLGY07-06)

优点, 这使毫米波可以成为未来通信系统的主要工作频段。

而对于传统蜂窝网络系统, 无线资源的管理是十分重要的, 如用户接入、波束形成器设计或发射功率控制^[2]等。由于用户间相互干扰产生的非凸性, 功率分配问题很难得到最优解^[3]。因此, 寻找一个次优、高效的解决方案一直是研究的重点。通常功率分配的目标是实现干扰广播信道的加权和速率最大化。为此学者提出了一些经典算法, 如加权最小均方误差 (WMMSE, weighted mean square error minimization) 算法^[4]、迭代注水算法^[5]和干扰定价算法^[6]。虽然这些迭代算法都有不错的性能表现, 但是都有较大的时间开销。处理多输入多输出 (MIMO, multiple-input multiple-output) 干扰系统功率分配问题时, 经典算法每一步迭代都需要涉及奇异值分解或者矩阵求逆操作。而信道信息、用户分布等参数都在快速变化, 因此此类算法实现实时处理较困难。神经网络的出现为这个难题提供了解决的方案, 深度神经网络可以很好地逼近传统迭代算法, 并且加快了计算时间^[7]。

与传统 Sub-6 GHz 频段相比, 毫米波的频段的天线尺寸相应较小, 有利于移动终端在保持元器件高度集成化的同时, 结合大规模 MIMO 技术部署更大规模的天线阵列, 有效地提高系统的频谱利用率以及抗干扰能力^[8-9]。然而, 更多数量的天线也意味着波束成形以及信道信息的获取变得更加困难。另一方面, 毫米波在空气中传播会被水蒸气、氧气等吸收, 导致很大的路径损耗以及随机阻挡。因此, 如何对采用毫米波频段的蜂窝网络通信系统进行有效的无线资源管理, 以提供稳健高速的链路质量, 仍然是一个值得研究的问题。其中毫米波的功率控制问题是亟须解决的。文献[10]研究了在终端直通 (D2D, device-to-device) 场景下毫米波系统的资源分配与功率控制问题, 考虑最大化系统吞吐量, 提出了一种基于干扰管理的启发式算法, 结合匈牙利算法求出最佳功率分配。文献[11]研究了在毫米波系统的功率控制中应用非合作博弈论, 针对毫米波系统中不同的信干噪比门限值的特点, 设计了一种新的效用函数, 降低了计算的复杂度。考虑毫米波网络的高间歇性, 文献[12]利用强化学习模型来预测阻塞状态从而得到功率分配的最优解。与传统通信系统的功率控制算法相同, 上述毫米波系统功率控制算法都认为信道信息是已知的, 并未考

虑毫米波系统的特点, 即天线数目多以及覆盖范围小带来的波束搜索开销与盲搜索功耗。

近年来, 已经有学者注意到 Sub-6 GHz 信号与毫米波信号在到达角、离开角和角度功率谱上存在一致性^[13], 而未来的毫米波通信系统可以在多个频段 (包括 6 GHz 以下和毫米波频段) 运行^[14-15]。文献[16]将毫米波信道信息的获取转化为压缩感知问题, 在 Sub-6 GHz 频段提取支撑信息用于辅助毫米波信道估计。基于 Sub-6 GHz 和毫米波频段之间的空间相关性, 文献[17]研究了毫米波系统中的流量调度算法, 使用 Sub-6 GHz 链路作为备份以减少毫米波链路容易中断带来的影响。文献[18]提出了在特定条件下从 Sub-6 GHz 到毫米波频段存在映射关系, 并利用深度学习工具对毫米波波束以及阻塞进行预测。考虑到 Sub-6 GHz 信号相对于毫米波信号的传播对阻塞具有更强的稳健性, 并且衰减更小, 借助一些 Sub-6 GHz 信道信息来辅助毫米波系统的运行十分有效。

因此, 受已有研究的启发, 本文提出基于深度神经网络 (DNN, deep neural networks) 的 Sub-6 GHz 辅助毫米波网络功率分配算法, 旨在解决毫米波功率控制中面临的 3 个问题。首先, 毫米波由于覆盖小并且易受遮挡, 因此其传输以及功率控制所需的测量都需要波束搜索与跟踪, 对于数量众多的天线系统, 产生巨大信令的开销; 其次, 由于毫米波覆盖小, 还会导致用户在覆盖范围外时进行盲搜索, 使功耗增加; 最后, 传统功率控制算法需要迭代运算, 复杂度高。

本文的主要研究工作如下。

1) 在 Sub-6 GHz 与毫米波双频段通信系统中, 提出了从 Sub-6 GHz 频段信道信息到毫米波频段的最佳功率分配的映射关系。这种确定性映射关系是非线性的, 无法从理论上进行显式描述。

2) 利用神经网络模型强大的逼近能力, 设计深度神经网络模型用于学习上述映射关系, 从而实现使用 Sub-6 GHz 频段来预测毫米波频段的最佳功率分配, 避免了毫米波特性的搜索开销与功耗。

3) 为了验证所提方案的可行性, 本文在进行了理论分析的基础上, 开展了广泛的仿真实验。结果表明, 使用 Sub-6 GHz 频段信道信息来辅助深度学习模型预测毫米波频段的功率分配可以在耗时极少的情况下获得较好的性能表现。

2 系统模型

本文考虑如图 1 所示的移动通信场景。假设场景下共有 K 个小区，每个小区每个调度时刻只服务一个用户。基站同时拥有工作 Sub-6 GHz 频段以及毫米波频段的均匀线性阵列 (ULA, uniform linear array) 天线，天线数目分别为 $T^{\text{sub-6}}$ 和 T^{mmW} 。移动端在 Sub-6 GHz 频段以及毫米波频段都使用单天线进行通信。Sub-6 GHz 频段的基站采用纯数字结构，用于上行信令及业务传输，以及进行信道估计。毫米波天线则选用纯模拟设计，主要考虑下行数据传输^[19]。




图 1 移动通信场景

设 i^k 表示第 k 个基站服务的用户 i ，用 $\bar{h}_{i,k}^{\text{sub-6}} \in \mathbb{C}^{T^{\text{sub-6}} \times 1}$ 表示用户 i 到基站 k 的 Sub-6 GHz 信道矩阵。则基站接收到用户 i^k 上行信号可以表示为

$$\mathbf{y}_{i^k}^{\text{sub-6}} = \bar{h}_{i,k}^{\text{sub-6}} \bar{s}_{i^k} + \mathbf{n}_k^{\text{sub-6}} \quad (1)$$

其中， \bar{s}_{i^k} 为用户 i^k 向基站 k 发送的上行链路导频信号， $\mathbf{n}_k^{\text{sub-6}} \sim \mathcal{N}(0, \sigma^2 I)$ 表示基站 k 处 Sub-6 GHz 天线接收到的噪声， $i=1, \dots, I, k=1, \dots, K, I=K$ 。

为了降低毫米波链路的路径损耗，使用基于码本的波束赋形方案。若 $\mathbf{b} \in \mathbb{C}^{T^{\text{mmW}} \times 1}$ 表示波束成形向量， $\bar{h}_{i,k}^{\text{mmW}} \in \mathbb{C}^{T^{\text{mmW}} \times 1}$ 表示从基站 k 到用户 i^k 的毫米波频段信道矩阵，那么移动端接收到的下行毫米波信号可以写为

$$\mathbf{y}_{i^k}^{\text{mmW}} = [\bar{h}_{i,k}^{\text{mmW}}]^T \mathbf{b}_k s_k + \sum_{l \neq k} [\bar{h}_{i,l}^{\text{mmW}}]^T \mathbf{b}_l s_l + \mathbf{n}_{i^k}^{\text{mmW}} \quad (2)$$

其中，波束成形向量 \mathbf{b}_k 从包含 N 组候选波束成形向量的量化码本 \mathbf{B} 中选取， s_k 为基站 k 试图传输的符

号， $\mathbf{n}_{i^k}^{\text{mmW}}$ 表示用户 i^k 接收到的噪声。

用户 i^k 处毫米波频段的信干噪比可以表示为

$$\text{SINR}_{i^k} = \frac{|h_{i,k}^{\text{mmW}}|^2 p_k}{\sum_{j \neq k} |h_{i,j}^{\text{mmW}}|^2 p_j + \sigma_{i^k}^2} \quad (3)$$

其中， $h_{i,k}^{\text{mmW}}$ 为从基站 k 到用户 i^k 最佳波束的信道增益， p_k 为基站 k 对用户 i^k 的发射功率， $\sigma_{i^k}^2$ 为噪声功率。单位带宽用户 i^k 的速率可表示为

$$R_i = \log(1 + \text{SINR}_{i^k}) = \log \left(1 + \frac{|h_{i,k}^{\text{mmW}}|^2 p_k}{\sum_{j \neq k} |h_{i,j}^{\text{mmW}}|^2 p_j + \sigma_{i^k}^2} \right) \quad (4)$$

其中， $0 \leq p_k \leq P_{\max}$ ， P_{\max} 为发射机的最大传输功率。

本文考虑加权和速率最大化为目标的功率分配问题求解。令 $\mathbf{P} = \{p_1, p_2, \dots, p_K\}$ 表示用户的功率分配矢量。 $h^{\text{mmW}} = \{|h_{1,1}^{\text{mmW}}|, |h_{1,2}^{\text{mmW}}|, \dots, |h_{2,1}^{\text{mmW}}|, |h_{2,2}^{\text{mmW}}| \} \dots \{ \dots, |h_{I,K}^{\text{mmW}}| \}$ 表示所有用户经过波束赋形后的下行毫米波信道增益。则系统中所有用户的加权和速率可以表示为

$$R(h^{\text{mmW}}, \mathbf{P}) = \sum_{i=1}^I \eta_i R_i \quad (5)$$

其中， $\eta_i > 0$ 为用户的优先级。而系统的加权和速率最大化问题可表示为

$$\begin{aligned} & \max_{\mathbf{P}} R(h^{\text{mmW}}, \mathbf{P}) \\ & \text{s.t. } 0 \leq p_k \leq P_{\max}, k=1, 2, \dots, K \end{aligned} \quad (6)$$

那么，用户的最佳功率分配为

$$\mathbf{P}^* = \underset{\mathbf{P}}{\text{argmax}} R(h^{\text{mmW}}, \mathbf{P}) \quad (7)$$

此时，系统的加权和速率可以取得最大值 R_{\max} 。

由于式(3)中各小区功率相互耦合，系统加权和速率最大化变为 NP-hard 问题^[20]。传统的求解算法是将问题转化为求次优解，往往通过迭代实现，复杂度较高。此外，传统的功率控制算法单独依赖于下行信道信息，当获得下行信道信息比较困难时，如在双频段毫米波通信系统中，将无法实现功率实时控制。

3 Sub-6 GHz 辅助毫米波网络功率分配

本节将双频段系统中毫米波网络功率分配问题分 3 个部分进行论述。首先，提出了在特定的条

件下存在 Sub-6 GHz 的信道数据到毫米波频段的最佳功率分配的确定性映射。然后, 对 WMMSE 算法进行简化, 并且用于产生毫米波频段的最佳功率分配。最后, 得到从 Sub-6 GHz 信道到毫米波频段最佳功率分配的复合映射, 并且证明可以使用神经网络学习这种映射关系, 从而预测毫米波频段的功率分配。

3.1 将 Sub-6 GHz 信道映射到毫米波最优功率分配

首先, 对图 1 所示的双频段毫米波通信系统场景, 假设基于量化码本的波束搜索, 分别得到每个用户 2 个频段信道增益矢量 $\mathbf{h}^{\text{sub-6}}$ 与 \mathbf{h}^{mmW} 。若以 S_i 表示任意用户 i^k 的位置, $\{S_i\}$ 表示用户 i^k 所有位置的集合。那么, 对于用户 i^k , 可以定义以下 2 种从位置到信道增益的映射函数。

$$\begin{cases} f_{\text{sub-6}}: \{S_i\} \rightarrow \{|h_{i,1}^{\text{sub-6}}|, |h_{i,2}^{\text{sub-6}}|, \dots, |h_{i,K}^{\text{sub-6}}|\} \\ f_{\text{mmW}}: \{S_i\} \rightarrow \{|h_{i,1}^{\text{mmW}}|, |h_{i,2}^{\text{mmW}}|, \dots, |h_{i,K}^{\text{mmW}}|\} \end{cases} \quad (8)$$

假设 1 $f_{\text{sub-6}}$ 是双射。

通常情况下, 由于天线的数目和阵列形状、信号传播路径以及环境等因素的影响, 映射 $f_{\text{sub-6}}$ 是双射的概率非常高^[21-22]。若 $f_{\text{sub-6}}$ 是双射, 那么它的逆映射 $f_{\text{sub-6}}^{-1}$ 的存在性也是本文后续进行推广的基础。

更进一步地, 考虑到系统中的多个用户, 使用 $S = \{S_1, S_2, \dots, S_I\}$ 表示当前所有用户的位置分布, 则可以将上述 2 个映射扩展为

$$\begin{cases} g_{\text{mmW}}: \{S\} \rightarrow \{\mathbf{h}^{\text{mmW}}\} \\ g_{\text{sub-6}}: \{S\} \rightarrow \{\mathbf{h}^{\text{sub-6}}\} \end{cases} \quad (9)$$

不难看出, $g_{\text{sub-6}}(\cdot)$ 与 $g_{\text{mmW}}(\cdot)$ 只是 $f_{\text{sub-6}}(\cdot)$ 与 $f_{\text{mmW}}(\cdot)$ 的简单叠加。因此, 映射 $g_{\text{sub-6}}(\cdot)$ 也存在逆映射 $g_{\text{sub-6}}^{-1}(\cdot)$ 。在此基础上可以进行简单的推导, 在映射中隐去用户群位置 S 可得

$$\Psi(\cdot) = g_{\text{mmW}}(g_{\text{sub-6}}^{-1}(\cdot)) \quad (10)$$

从而得到所有用户的 Sub-6 GHz 信道增益到毫米波信道增益的映射为

$$\Psi: \{\mathbf{h}^{\text{sub-6}}\} \rightarrow \{\mathbf{h}^{\text{mmW}}\} \quad (11)$$

在本文设定场景下, 结合式(6), 可以得到下行毫米波信道加权和速率最大化问题如下

$$\begin{aligned} & \max_{\mathbf{P}} R(\Psi(\mathbf{h}^{\text{sub-6}}), \mathbf{P}) \\ & \text{s.t. } 0 \leq p_k \leq P_{\max}, k=1, 2, \dots, K \end{aligned} \quad (12)$$

而下行毫米波信道的最佳功率分配可以描述为

$$\mathbf{P}^* = \arg \max_{\mathbf{P}} R(\Psi(\mathbf{h}^{\text{sub-6}}), \mathbf{P}) \quad (13)$$

3.2 WMMSE 算法

WMMSE 算法最初是为了设计线性波束形成器而提出的, 其后被推广到其他的和效用最大化问题^[4]。本文对其进行调整, 以利于用 DNN 和 Sub-6 GHz 预测的毫米波信道功率分配 \mathbf{P}^* 。

本文假设双频段都完成波束搜索, 故下行毫米波信道可以近似看作一个单输入单输出的多小区干扰信道模型。则用户 i^k 接收到来自基站 k 的信号可以表示为

$$y_{i^k}^{\text{mmW}} = h_{i,k}^{\text{mmW}} v_k s_k + \sum_{l \neq k} h_{i,l}^{\text{mmW}} v_l s_l + n_{i^k}^{\text{mmW}} \quad (14)$$

其中, v_k 表示基站 k 的波束增益, $n_{i^k}^{\text{mmW}}$ 表示用户 i^k 处的噪声。用户接收到的传输符号可以写为

$$\hat{s}_k = u_k y_{i^k}^{\text{mmW}} = u_k \left(h_{i,k}^{\text{mmW}} v_k s_k + \sum_{l \neq k} h_{i,l}^{\text{mmW}} v_l s_l + n_{i^k}^{\text{mmW}} \right) \quad (15)$$

其中, u_k 表示用户 i^k 处的接收机波束形成增益。假设传输符号与噪声之间相互独立, 那么用户 i^k 处传输符号的均方误差为

$$e_k = \left| u_k h_{i,k}^{\text{mmW}} v_k s_k - 1 \right|^2 + \sum_{l \neq k} \left| u_k h_{i,l}^{\text{mmW}} v_l \right|^2 + |u_k|^2 \sigma_{i^k}^2 \quad (16)$$

根据式(16), 下行信道的加权均方误差最小化问题可以表示为

$$\begin{aligned} & \min_{\{w_k, v_k, \alpha_k\}} \sum_{k=1}^K \alpha_k (w_k e_k - \log w_k) \\ & \text{s.t. } |v_k|^2 \leq P_{\max}, k=1, 2, \dots, K \end{aligned} \quad (17)$$

其中, w_k 为正的权重系数; 为了便于计算, 使用 α_k 代替前文中 η_i 表示的基站 k 服务的用户 i^k 的优先级。

式(6)与式(17)已被证明是等价的^[4], 式(17)可利用块坐标下降的方法进行求解。算法详细的迭代步骤如算法 1 所示。

算法 1 加权最小均方误差功率分配算法

输入 $\mathbf{h}^{\text{mmW}}, P_{\max}, \{\sigma_{i^k}^2\}, \forall i^k$

步骤 1 算法初始化

设定 $t=0$; 随机初始化发射端增益

$$v_k \in [0, \sqrt{P_{\max}}], \forall k$$

$$\text{计算接收端增益 } u_k = \frac{|h_{i,k}^{\text{mmW}}| v_k}{\sum_{j=1}^K |h_{i,j}^{\text{mmW}}|^2 v_j^2 + \sigma_{i^k}^2}, \forall k$$

计算权重系数 $w_k = (1 - u_k |h_{i,k}^{\text{mmW}}| v_k)^{-1}, \forall k$

步骤 2 迭代计算

循环以下过程，直至 t 等于设定循环次数

1) 迭代次数更新 $t = t + 1$

2) 根据 u_k 与 w_k 计算 v_k' , $0 \leq v_k' \leq \sqrt{P_{\max}}$;

$$v_k' = \frac{\alpha_k |h_{i,k}^{\text{mmW}}| u_k w_k}{\sum_{j=1}^K \alpha_j v_j |h_{i,j}^{\text{mmW}}|^2 u_j^2}, \forall k$$

3) 根据 v_k' 计算 $u_k' = \frac{|h_{i,k}^{\text{mmW}}| v_k}{\sum_{j=1}^K |h_{i,j}^{\text{mmW}}|^2 v_j^2 + \sigma_{i,k}^2}, \forall k$

4) 根据 v_k' 与 u_k' 更新权重系数

$$w_k' = (1 - u_k |h_{i,k}^{\text{mmW}}| v_k)^{-1}, \forall k$$

5) $\{u_k, w_k, v_k\} = \{u_k', w_k', v_k'\}, \forall k$

输出 $\mathbf{P}^* = \{|v_1|^2, |v_2|^2, \dots, |v_K|^2\}$

3.3 基于 DNN 的功率分配算法

尽管上文已经通过式(13)给出了 Sub-6 GHz 频段的信道信息与毫米波频段的最佳功率分配之间的关系，但仍然不能直接通过普遍近似理论^[23]来证明此关系可以被神经网络学习。虽然 3.2 节给出了使用毫米波信道增益来计算 \mathbf{P}^* 的算法，但在通常情况下式(6)的解不是唯一的，为了使从 $\mathbf{h}^{\text{sub-6}}$ 到 \mathbf{P}^* 存在一个确定的映射，本文提出了假设 2。

假设 2 由算法 1 计算出的毫米波功率分配矢量 \mathbf{P}^* 满足 $R(\mathbf{h}^{\text{mmW}}, \mathbf{P}^*) > R(\mathbf{h}^{\text{mmW}}, \mathbf{P}), \forall \mathbf{h}^{\text{mmW}}$ ，并且 $\mathbf{P}^* \neq \mathbf{P}$ 。

假设 2 意味着对于任意给定的 \mathbf{h}^{mmW} 都只存在唯一的 \mathbf{P}^* 使下行信道和速率达到 R_{\max} 。若存在 $R(\mathbf{h}^{\text{mmW}}, \mathbf{P}^*) = R(\mathbf{h}^{\text{mmW}}, \mathbf{P}^{**}) = R_{\max}$ ， $\mathbf{P}^* \neq \mathbf{P}^{**}$ 的情况，无论是选取 \mathbf{P}^* 或 \mathbf{P}^{**} 都对系统和速率有同样的贡献。因此，不妨认为假设 2 在本文设计的场景中成立。

那么，可以将从 $\mathbf{h}^{\text{sub-6}}$ 到 \mathbf{P}^* 的连续映射定义为

$$\Omega: \{\mathbf{h}^{\text{sub-6}}\} \rightarrow \{\mathbf{P}^*\} \quad (18)$$

根据普遍逼近定理^[23]，使用 $\Gamma_N(\cdot)$ 表示单个隐藏层有 N 个神经元构成的的密集神经网络的输出，那么对与连续的功率映射函数 $\Omega(\cdot)$ 以及任意给定的误差 $\varepsilon > 0$ ，都存在一个足够大的正整数 N 满足

$$\sup \|\Gamma_N(\mathbf{h}^{\text{sub-6}}) - \Omega(\mathbf{h}^{\text{sub-6}})\| < \varepsilon, \forall \mathbf{h}^{\text{sub-6}} \quad (19)$$

因此，本文可以通过神经网络模型来对这种隐式的映射进行学习，从而实现利用 Sub-6 GHz 频段的信道信息预测毫米波信道最佳功率分配的目的。值得一提的是，虽然可以使用单个隐藏层对这种连续的映射进行逼近，但经过验证，较好的预测性能表现仍然需要多个隐藏层。

4 神经网络模型与参数设定

4.1 网络结构

本文选择使用包含一个输入层、多个隐藏层以及一个输出层的全连接神经网络来逼近功率映射函数 $\Omega(\cdot)$ 。神经网络模型的输入层包含 IK 个节点，输入为 Sub-6 GHz 频段的信道增益 $\{\mathbf{h}^{\text{sub-6}}\}$ ；输出层包含 I 个节点，输出为计算得到的毫米波信道功率分配 $\{\mathbf{P}^*\}$ 。在隐藏层选用 ReLU 作为激活函数为神经网络引入非线性因素。特别地，考虑到发射机最大功率的约束条件，输出层设计了带约束的激活函数如下

$$y = \begin{cases} x & , 0 \leq x < P_{\max} \\ P_{\max} & , x \geq P_{\max} \end{cases} \quad (20)$$

代价函数选择使用每一个用户的预测功率分配 p_k 与标签 \hat{p}_k 之间均方误差的加权和

$$L_{\text{cost}} = \frac{1}{K} \sum_{k=1}^K (p_k - \hat{p}_k)^2 \quad (21)$$

表 1 总结了训练神经网络过程中的具体参数。

神经网络参数	
参数	值
隐藏层数/个	3
隐藏层节点数/个	200,80,80
优化器	RMSprop
学习率	2×10^{-3}
训练期数	500
批大小	300
数据集分割	0.8/0.2

4.2 数据集选取

由于实际信道数据的获取受限，工程中常采用基于射线追踪的方法生成信道数据。本文使用的数据来自 3D 射线追踪软件构建的 Deep MIMO 数据集^[24]。此数据集中的双频段通信场景 O1 包含 28 GHz 的毫米波基站数据集 O1_28 以及 3.5 GHz

的 6 GHz 以下基站数据集 O1_3p5。

本文所提神经网络模型采用非在线训练模式，可以大幅减少在线计算所需要的开销。首先，通过文献[24]中的脚本来分别生成双频段信道矩阵集合 $\{\bar{h}_{i,k}^{\text{sub-6}}\}, \{\bar{h}_{i,k}^{\text{mmW}}\}, \forall i, \forall k$ 。考虑到当使用 Sub-6 GHz 信道矩阵作为神经网络输入时，输入层神经元规模将十分庞大，本文利用波束搜索方案将 Sub-6 GHz 信道矩阵 $\bar{h}_{i,k}^{\text{sub-6}}$ 转变为信道增益 $|h_{i,k}^{\text{sub-6}}|$ ，大幅减少输入层的节点个数。其次，神经网络的输出，即毫米波频段的功率分配矢量 $\{P^*\}$ ，由 $\{\bar{h}_{i,k}^{\text{mmW}}\}$ 经过波束成形后通过算法 1 生成。最后，将每一组用户分布对应的 Sub-6 GHz 频段的信道增益矢量与毫米波频段功率分配矢量组合起来，得到数据集中的样本 $(\bar{h}_{(n)}^{\text{sub-6}}, P_{(n)}^*)$ ，其中 n 为样本索引。

4.3 场景设定

基于非在线的训练模式，本文选取了以下 3 种场景以检验所提算法的有效性以及性能。场景 1 与场景 2 神经网络模型的训练是独立的，仿真参数汇总在表 2 中，其中部分参数采用文献[18]。

场景 1 主街道场景。场景 1 是一条主街道的一部分，模拟用户在单条街道步行的情景。在街道两侧对称分布着 4 个具有双频段天线的基站，用户均匀分布在整个区域。每次都在候选用户集中为 4 个小区分别随机选取一个用户作为服务用户，每个用户被选取的概率相同。

表 2 仿真参数

参数	场景 1	场景 2	场景 3
激活基站序号	[1,2,3,4]	[5,6,7,8]	[1,2,3,4]
带宽 (Sub-6/mmWave) /GHz ^[18]	0.5/0.02	0.5/0.02	0.5/0.02
噪声功率/(dBm·MHz ⁻¹) ^[18]	-134	-134	-134
天线数目 (Sub-6/mmWave) /个	4/16	4/16	4/16
用户候选位置数/个	约 1.1×10 ⁵	9.7×10 ⁴	1×10 ⁴
训练集样本数/个	5×10 ⁵	5×10 ⁵	5×10 ⁵
测试集样本数/个	5×10 ⁴	5×10 ⁴	5×10 ⁴

场景 2 交叉路口场景。此场景选取 2 条主街道的交叉部分，模拟用户在经过交叉路口时的情景。4 个基站分布在街道角落的内侧，可以覆盖到均匀分布在整个区域的所有用户。数据集生成准则同场景 1。

场景 3 主街道-边缘场景。此场景内基站和用户分布都与场景 1 相同，区别在于用于测试神经网络模型的用户分布样本是在小区覆盖的边缘区域生成的。设计此场景的目的是验证用户身处小区覆盖边缘的情况下，所提算法预测的功率分配是否同样有效。

5 仿真结果与分析

5.1 可行性验证

为了检验使用 Sub-6 GHz 信道增益预测毫米波信道的功率分配的有效性，本文设计了相应的方案：当 2 个频段同时使用单天线进行通信时，在场景 1 和场景 2 下分别使用 2 个频段的信道增益作为神经网络输入，毫米波信道的功率分配作为神经网络输出来训练网络，并在测试阶段对 100 000 组样本和速率分布情况进行评估，仿真结果如图 2 和图 3 所示。

通过分析图 2 和图 3 可以看出，在 2 个场景下使用 Sub-6 GHz 信道增益（简称为 Sub6-DNN）与直接使用毫米波信道增益（简称为 mmW-DNN）来预测样本的毫米波频段功率分配所得到的和速率分布结果基本一致。即使是场景 2 中某些分布存在和速率接近为零的情况，所提 Sub6-DNN 也能与 mmW-DNN 预测结果保持一致。




图 2 场景 1 单天线收发和速率分布

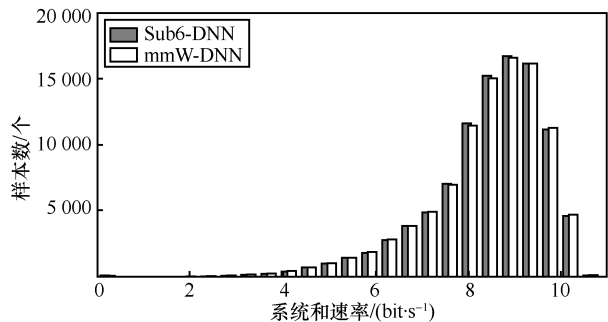


图 3 场景 2 单天线收发和速率分布

表 3 列举了 Sub6-DNN、mmW-DNN 和 WMMSE 算法所得所有样本的平均和速率。在不同的场景下，Sub6-DNN 的预测结果虽略逊于 mmW-DNN，但仍可以十分接近 WMMSE 算法的性能表现。这些结果验证了使用 Sub-6 GHz 信道预测毫米波频段功率分配的能力。

表 3 神经网络与 WMMSE 算法性能对比 (单天线)

算法	场景 1 平均和速率/(bit·s ⁻¹)	场景 2 平均和速率/(bit·s ⁻¹)
Sub6-DNN	8.700	8.406
mmW-DNN	8.702	8.411
WMMSE	8.725	8.484

此外，考虑到 mmW-DNN 需要使用毫米波信道的原始数据训练网络，但毫米波信道测量会有很大的开销与功耗，而使用 Sub-6 GHz 的信道信息可以避免这个问题，因此在性能表现相近的情况下选择使用 Sub-6 GHz 信道预测毫米波频段功率分配性价比更高。

5.2 预测性能表现

在场景 1 与场景 2 下，基站双频段都使用多个天线进行收发 (采用表 2 中的数据)。使用上文中的神经网络模型针对 2 个场景分别进行训练，并在测试阶段选用最大功率分配与随机功率分配方案进行对比。所得功率分配计算出系统和速率并绘制出累积分布曲线如图 4 与图 5 所示。




图 4 场景 1 不同算法和速率分布

如图 4 所示，在场景 1 下，最大功率分配与随机功率分配算法所得样本的和速率集中在区间[2,10]，样本和速率小于 9 bit/s 的概率为 1。而所提 Sub6-DNN 与 WMMSE 算法预测结果均分布在

区间[4,14]，明显优于最大功率分配与随机功率分配算法。虽然，所提算法预测的结果约有 40%的样本和速率分布在区间[4,12]内，和速率略小于 WMMSE 算法，但多数样本和速率大于 12 bit/s，预测结果与 WMMSE 算法所得高度一致。




图 5 场景 2 不同算法和速率分布

与图 4 类似，图 5 展示了场景 2 下 4 种算法的样本和速率对比。最大功率分配与随机功率分配算法所得样本的和速率集中分布在区间[1,8]，也明显劣于 Sub6-DNN 与 WMMSE 算法。不同的是，所提 Sub6-DNN 只有约 40%的样本预测结果与 WMMSE 算法保持一致，分布在大于 12 bit/s 的区间，而在场景 1 下有约 60%。

虽然已经证明了可以通过神经网络模型对 WMMSE 算法进行无限逼近，但通过仿真可以看出，对于部分和速率较低的样本，所提算法表现略差于 WMMSE 算法。若要继续减少所提算法的与 WMMSE 算法的差距，需要继续增加神经元或隐藏层的数量。

为了综合对比本文 Sub6-DNN 与 WMMSE 算法的性能，在表 4 与表 5 中列举了 2 种算法分别对不同场景下测试集的 50 000 组样本进行功率分配的耗时以及平均和速率。结果表明，所提 Sub6-DNN 在 2 种场景下均可以在耗时少于 WMMSE 算法的 0.1%的情况下，获得不小于 97%的和速率性能。

而对于场景 3 的边缘分布用户，同样使用已经在场景 1 下训练好的神经网络模型进行测试，结果如图 6 所示。在未对数据集进行优化之前，所提 Sub6-DNN 所得样本的和速率虽然远优于最大功率分配与随机功率分配算法，但与 WMMSE 算法在整

个和速率区间上都有不小的差距。这是由于训练集中边缘用户分布样本较少导致了少数样本的预测性能表现不佳。

表 4 算法性能表现对比 (场景 1)

算法	平均和速率/(bit·s ⁻¹)	耗时/s
Sub6-DNN	11.491	0.210
WMMSE	11.676	632.232
比值	98.417%	0.033%

表 5 算法性能表现对比 (场景 2)

算法	平均和速率/(bit·s ⁻¹)	耗时/s
Sub6-DNN	11.536	0.380
WMMSE	11.814	1 381.035
比值	97.652%	0.028%




图 6 场景 3 和速率表现对比与数据集优化影响

这种数据集样本分布不均衡的现象在实际应用中非常常见，会对神经网络的性能造成一定影响。处理这种不平衡数据集的方案一般分为 2 种：算法级优化与数据级优化。算法级优化通常在分类问题中使用，通过调整分类边界来提高算法对少数类样本的敏感性。这种优化方案无法直接引入功率控制问题，因此本文考虑数据级优化方案对数据集进行处理。

最简便的数据级优化方案是增加数据集中少数类样本的数量，这也是最有效的解决方案。例如，考虑到实际情况中样本获取比较困难，文献[25]借助对抗生成网络 (GAN, generative adversarial network) 来对少数类样本进行数据增广，获取新的少数类样本，同样可以提高数据集中少数类的占比。此外，在训练时对数据集进行不同方式的采样，也可以缓解数据集的不均衡问题。

通过图 6 可以看出，向原数据集中添加不同占比的少数分布样本之后，所提算法的性能得到了不同程度的改善。当向原数据集中添加 15% 的少数分布样本时，和速率分布在区间[2,8]的样本占比减少了大约 50%。当添加的少数分布样本占比增加到 30% 时，和速率分布在小于 9 bit/s 的样本占比进一步减少。而当增加少数分布样本占比达到 50% 时，所提算法性能已经远超前未对数据集进行优化时，非常逼近 WMMSE 算法。

5.3 稳健性评估

考虑到实际中信道测量通常会有噪声与误差存在，这会造成经过测量得到的信道信息不准确。本节考虑基于随机扰动模型的信道估计误差^[26]，研究信道测量误差对算法性能的影响。具体来讲，在测试集数据中为每个用户的 Sub-6 GHz 频段信道矩阵叠加零均值，方差为 $\sigma_i^2 = \alpha \|\bar{\mathbf{h}}_{i,k}^{\text{sub-6}}\|^2$ 的高斯噪声，其中， α 为误差指数，用于模拟信道测量误差。然后，通过训练好的神经网络对带有不同误差指数的测试集数据进行测试。使用 WMMSE 算法计算无信道估计误差时的系统和速率，并将其作为本文所提算法预测结果的上界。

图 7 表明了场景 1 下，尽管输入神经网络模型的 Sub-6 GHz 频段信道信息出现偏差，本文所提算法表现仍然相对较好，这也突出了使用 Sub-6 GHz 信道有效预测毫米波信道功率分配的稳健性以及信道变动的适应性。而用于对比的最大功率分配算法与随机功率分配算法因为不需要信道数据，和速率不随信道测量误差变化。




图 7 各算法平均和速率与误差指数的关系

此外，通过将功率分配二值化，即 $p_k=0$ 或 P_{\max} ，可以在一定程度上提高预测精度，改善算

法性能^[7]。对于本文所提算法,在误差指数小于 10^{-3} 时,使用二值化功率分配为样本的平均和速率带来了约 0.3 bit/s 的提升,在一定程度上提高了神经网络的预测性能。但随着误差指数的增加,这种提升也逐渐减小,最终与未经过二值化的预测结果保持一致。这是由于信道测量误差较大时,二值化所带来的和速率提升远小于网络输入存在偏差带来的负面影响。这也侧面反映了在实际通信场景中,对信道信息的准确掌握是有效进行实时功率控制的前提。

6 结束语

为了在毫米波通信系统中实现实时高效的功率控制,本文首先提出了从 Sub-6 GHz 信道到毫米波信道最佳功率分配的映射函数。然后,利用普遍逼近理论,证明了可以通过神经网络模型来对此映射函数进行学习,从而预测毫米波最佳功率分配。为此,本文设计了一个神经网络模型,利用 Sub-6GHz 信道来执行预测任务,并且根据 DeepMIMO 数据集对神经网络模型进行了评估与测试。结果表明,所提神经网络算法在开销极小的情况下,具有良好的预测性能。

参考文献:

- [1] RAPPAPORT T S, XING Y C, KANHERE O, et al. Wireless communications and applications above 100 GHz: opportunities and challenges for 6G and beyond[J]. IEEE Access, 2019, 7: 78729-78757.
- [2] YU Y W, DUTKIEWICZ E, HUANG X J, et al. Downlink resource allocation for next generation wireless networks with inter-cell interference[J]. IEEE Transactions on Wireless Communications, 2013, 12(4): 1783-1793.
- [3] SHI J F, CHEN M, YANG Z H, et al. Power control and performance analysis for full-duplex relay-assisted D2D communication underlying fifth generation cellular networks[J]. IET Communications, 2017, 11(18): 2729-2734.
- [4] SHI Q J, RAZAVIYAYN M, LUO Z Q, et al. An iteratively weighted MMSE approach to distributed sum-utility maximization for a MIMO interfering broadcast channel[J]. IEEE Transactions on Signal Processing, 2011, 59(9): 4331-4340.
- [5] BALIGH H, HONG M Y, LIAO W C, et al. Cross-layer provision of future cellular networks: a WMMSE-based approach[J]. IEEE Signal Processing Magazine, 2014, 31(6): 56-68.
- [6] YU W, CIOFFI J M. FDMA capacity of Gaussian multiple-access channels with ISI[J]. IEEE Transactions on Communications, 2002, 50(1): 102-111.
- [7] SUN H R, CHEN X Y, SHI Q J, et al. Learning to optimize: training deep neural networks for wireless resource management[C]// Proceedings of 2017 IEEE 18th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). Piscataway: IEEE Press, 2017: 1-6.
- [8] RUSEK F, PERSSON D, LAU B K, et al. Scaling up MIMO: opportunities and challenges with very large arrays[J]. IEEE Signal Processing Magazine, 2013, 30(1): 40-60.
- [9] NGO H Q, LARSSON E G, MARZETTA T L. Energy and spectral efficiency of very large multiuser MIMO systems[J]. IEEE Transactions on Communications, 2013, 61(4): 1436-1449.
- [10] 文凯, 陈永丽, 颜枫. 一种毫米波蜂窝网络中的 D2D 资源分配方案[J]. 计算机工程, 2018, 44(11): 90-94.
- [11] 张芳, 邹卫霞, 杜光龙, 等. 60GHz 毫米波无线网络中基于归一化分阶效用函数功率控制算法[J]. 电子与信息学报, 2013, 35(2): 291-296.
- [12] 施钊, 孙长印, 江帆. 毫米波网络中基于 Q-Learning 的阻塞感知功率分配[J]. 计算机工程, 2020, 46(12): 185-192.
- [13] SHI Z, SUN C Y, JIANG F. Block-aware power allocation based on Q-learning in millimeter-wave network[J]. Computer Engineering, 2020, 46(12): 185-192.
- [14] ROH W, SEOL J Y, PARK J, et al. Millimeter-wave beamforming as an enabling technology for 5G cellular communications: theoretical feasibility and prototype results[J]. IEEE Communications Magazine, 2014, 52(2): 106-113.
- [15] PARKVALL S, DAHLMAN E, FURUSKAR A, et al. NR: the new 5G radio access technology[J]. IEEE Communications Standards Magazine, 2017, 1(4): 24-30.
- [16] GONZALEZ-PRELCIC N, ALI A, VA V, et al. Millimeter-wave communication with out-of-band information[J]. IEEE Communications Magazine, 2017, 55(12): 140-146.
- [17] 修越, 张忠培, 赵柏睿, 等. 基于 K 学习的 Sub-6 GHz 辅助毫米波信道信息获取[J]. 电子科技大学学报, 2020, 49(3): 453-457, 466.
- [18] XIU Y, ZHANG Z P, ZHAO B R, et al. Acquisition of channel state information based on K-learning sub-6GHz assist mmWave[J]. Journal of University of Electronic Science and Technology of China, 2020, 49(3): 453-457, 466.
- [19] HASHEMI M, KOKSAL C E, SHROFF N B. Out-of-band millimeter wave beamforming and communications to achieve low latency and high energy efficiency in 5G systems[J]. IEEE Transactions on Communications, 2018, 66(2): 875-888.
- [20] ALRABEIAH M, ALKHATEEB A. Deep learning for mmWave beam and blockage prediction using sub-6 GHz channels[J]. IEEE Transactions on Communications, 2020, 68(9): 5504-5518.
- [21] LI X F, ALKHATEEB A. Deep learning for direct hybrid precoding in millimeter wave massive MIMO systems[C]//Proceedings of 2019

- 53rd Asilomar Conference on Signals, Systems, and Computers. Piscataway: IEEE Press, 2019: 800-805.
- [20] LUO Z Q, ZHANG S Z. Dynamic spectrum management: complexity and duality[J]. IEEE Journal of Selected Topics in Signal Processing, 2008, 2(1): 57-73.
- [21] ALRABEIAH M, ALKHATEEB A. Deep learning for TDD and FDD massive MIMO: mapping channels in space and frequency[C]//Proceedings of 2019 53rd Asilomar Conference on Signals, Systems, and Computers. Piscataway: IEEE Press, 2019: 1465-1470.
- [22] VIEIRA J, LEITINGER E, SARAJLIC M, et al. Deep convolutional neural networks for massive MIMO fingerprint-based positioning[C]//Proceedings of 2017 IEEE 28th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC). Piscataway: IEEE Press, 2017: 1-6.
- [23] HORNIK K, STINCHCOMBE M, WHITE H. Multilayer feedforward networks are universal approximators[J]. Neural Networks, 1989, 2(5): 359-366.
- [24] ALKHATEEB A. DeepMIMO: a generic deep learning dataset for millimeter wave and massive MIMO applications[J]. arXiv Preprint, arXiv: 1902.06435, 2019.
- [25] ZHANG T, ZHU K, NIYATO D. A generative adversarial learning-based approach for cell outage detection in self-organizing cellular networks[J]. IEEE Wireless Communications Letters, 2020, 9(2): 171-174.
- [26] 徐勇军, 胡圆, 李国权, 等. 异构携能通信网络顽健资源分配算法[J].

通信学报, 2019, 40(7): 186-196.

XU Y J, HU Y, LI G Q, et al. Robust resource allocation algorithm for heterogeneous wireless network with SWIPT[J]. Journal on Communications, 2019, 40(7): 186-196.

[作者简介]



孙长印(1963-), 男, 陕西扶风人, 博士, 西安邮电大学副教授、硕士生导师, 主要研究方向为无线异构网络干扰管理、资源分配技术等。

刘李延(1998-), 男, 陕西咸阳人, 西安邮电大学硕士生, 主要研究方向为毫米波通信与功率控制技术。

江帆(1982-), 女, 江苏盐城人, 博士, 西安邮电大学教授, 主要研究方向为无线资源管理、D2D 通信技术边缘计算及缓存技术等。

姜静(1974-), 女, 陕西安康人, 博士, 西安邮电大学教授, 主要研究方向为人工智能在无线通信中的应用与 Massive MIMO 技术。