

• 信息与通信工程 •

场景化毫米波特征选择和波束预测算法



孙长印^{1,2*}, 梁有为¹, 江帆^{1,2}, 王军选^{1,2}

(1. 西安邮电大学通信与信息工程学院 西安 710121; 2. 西安邮电大学陕西省信息通信网络及安全重点实验室 西安 710121)

【摘要】为减少毫米波波束训练的时间和功耗开销,提出了一种基于通信场景的波束特征选择和预测算法。首先,根据功率损耗概率最小化准则选择最优特征波束,并利用最优波束概率生成特征波束集(波束索引的子集)。其次,为了获得通信场景的最优波束概率,采用基于局部学习的特征选择聚类算法(LLC-fs)。最后,由于场景化特征波束集与最优波束之间为隐式、非线性映射关系,利用了DNN模型逼近该映射,进而使用离线训练模型实现从特征波束集到最优波束的预测。仿真结果表明,使用离线训练场景化DNN模型即可在线预测最优毫米波波束。预测性能可以逼近穷举波束搜索算法,并有效减小波束搜索的开销。

关键词 波束预测; 波束训练; 深度神经网络; 特征选择; 毫米波通信
中图分类号 TN928 **文献标志码** A **doi**:10.12178/1001-0548.2022214

Scenario-Based mmWave Feature Selection and Beam Prediction Algorithm

SUN Changyin^{1,2*}, LIANG Youwei¹, JIANG Fan^{1,2}, and WANG Junxuan^{1,2}

(1. School of Communications and Information Engineering, Xi'an University of Posts and Telecommunications Xi'an 710121;

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

Abstract To reduce the time and power overhead of millimeter wave (mmWave) beam training, a beam feature selection and prediction algorithm based on communication scenarios is proposed. First, the optimal feature-beam is selected according to the power loss probability minimization criterion, and a feature-beam set (a subset of beam indices) is generated using the optimal beam probability. Second, to obtain the optimal beam probability for communication scenarios, the local learning based clustering algorithm with feature selection (LLC-fs) is adopted. Finally, since there is an implicit and nonlinear mapping relationship between the scene-based feature-beam set and the optimal beam, the DNN model is used to approximate the mapping, and the offline training model is used to realize the prediction from the feature-beam set to the optimal beam. The simulation results show that the optimal mmWave beam can be predicted online by using the offline-trained scene-based DNN model. The prediction performance can approach the exhaustive beam search algorithm and effectively reduce the overhead of beam search.

Key words beam prediction; beam training; deep neural network; feature selection; mmWave communications

在毫米波 (millimeter wave, mmWave) 通信系统中,使用大规模多输入多输出 (massive multiple input multiple output, Massive MIMO) 结合波束赋形 (beamforming, BF) 技术可提高空间自由度^[1],实现 mmWave 的定向远距传输^[2]。由于基站 (base station, BS) 会发射大量定向窄波束^[3],所以利用波

束搜索技术使移动台 (mobile station, MS) 和 BS 快速对准到最优波束是 mmWave 通信技术的重要研究方向之一^[4]。

目前,搜索精度最高的是 mmWave 穷举搜索算法^[3,5]。此类方案的缺点是随着波束数量变多,算法的开销会急剧增大,导致通信时延。为了解决此

收稿日期: 2022-07-01; 修回日期: 2022-08-24

基金项目: 国家自然科学基金 (61871321, 62071377)

作者简介: 孙长印 (1963-), 男, 博士, 副教授, 主要从事人工智能在无线通信中的应用、无线异构网络干扰管理、资源分配技术等方面的研究。

*通信作者: 孙长印, E-mail: changyin_sun@163.com

问题, 现有 mmWave 波束搜索方案研究主要从以下几个方向展开。文献 [5-9] 提出了基于固定码本的波束搜索算法, 这类方案主要通过提前定义波束码本以降低搜索训练开销, 搜索方法可使用穷举法搜索或分级搜索以减少搜索次数。为了提高搜索效率, 文献 [10-12] 提出了在双频通信系统中基于辅助信息和并行传输的波束搜索算法, 利用 Sub-6 GHz 频段和 mmWave 频段的空域相关性, 基于并行信道间的映射关系, 实现了利用辅助信息减少 mmWave 信道估计和波束训练开销。但是由于在实践中这种映射关系往往不是完美的双射, 会导致搜索性能不佳, 并且这类方案应用场景只局限于双频通信系统。文献 [13-15] 将机器学习引入波束搜索领域, 利用深度神经网络 (deep neural network, DNN) 的分类预测能力完成波束训练, 但针对特定场景训练 DNN, 使得方案泛化性能受限。文献 [16-17] 提出了基于压缩感知的波束搜索算法, 利用 mmWave 信道的稀疏性, 使用压缩感知算法估计波束方向, 算法计算复杂度高, 应用范围有限。

与上述研究方向不同, 本文考虑场景因素对 mmWave 传输的影响, 提出了一种基于场景化的特征选择和波束预测方案。本方案分为离线和在线两个阶段。首先, 对于给定应用场景, 在离线阶段选择特征波束构建特征波束集 (波束索引的子集), 并使用交叉验证确定特征波束集的大小, 达到缩小波束搜索范围减少波束训练开销的目的。接下来考虑到场景化特征波束集与最优波束之间为隐式、非线性映射关系, 采用了 DNN 模型逼近该映射, 从而减少在线阶段 mmWave 信道估计和波束训练的开销。最后, 使用场景化 DNN 模型即可在线预测最优波束, 完成波束搜索。

1 系统和信道模型

1.1 系统配置

如图 1 所示, 考虑到 mmWave 天线通常采用模拟 BF 或混合 BF^[18], 本文采用模拟 BF 架构, 由一条射频 (radio frequency, RF) 链连接全部天线端口。假设 BS 配备均匀平面阵列 (uniform planar array, UPA) 天线, MS 配备单个全向天线。其中, BS 部署的 UPA 具有 N_{BS} 个阵列元件, 其中 $N_{BS} = N_{BS}^v \times N_{BS}^h$, 而 N_{BS}^v 和 N_{BS}^h 分别是垂直和水平方向上的阵列元件的数量, 天线间隔为半波长。




图 1 系统配置图

1.2 信道模型

本文采用 mmWave 几何 (物理) 信道模型^[18], 该信道模型的优点在于它能够捕获信号传播的物理特性, 包括对环境几何形状、材料、频带等的依赖性^[18], 这对于本文的场景化波束预测至关重要。基于此模型的 mmWave 信道可以表示为:

$$\mathbf{h}_{\text{mmW}}(k) = \sum_{d=0}^{D-1} \sum_{l=1}^L \alpha_l e^{-j \frac{2\pi k}{\lambda} d} p(dT_S - \tau_l) \mathbf{a}(\theta_l, \phi_l) \quad (1)$$

式中, L 为信道的多径数量; $\mathbf{a}(\theta_l, \phi_l)$ 为阵列响应; α_l 、 τ_l 、 θ_l 、 ϕ_l 分别为第 l 条信道的路径增益 (包括路径损耗)、延迟、到达俯仰角和到达方位角; T_S 为采样周期; D 为循环前缀长度。假设最大延迟小于 DT_S 。

1.3 码本构造

在模拟 BF 中, 大小为 $N_{CB} \times 1$ 的 BF 向量 \mathbf{f}_{RF}^k 从大小为 $N_{CB} \times K$ 的预定义量化码本矩阵 \mathbf{F} 中得到, 其中 K 是波束的总数量。因此, 码本矩阵 $\mathbf{F} = [\mathbf{f}_1, \mathbf{f}_2, \dots, \mathbf{f}_K]$ 将波束索引与天线阵列元素对应起来。

基于上述配置, 对于三维空间中的任意方向 (θ_k, ϕ_k) , 阵列响应矩阵可以表示为:

$$\mathbf{G}_k = \begin{bmatrix} \varphi_{1,1}^k & \varphi_{1,2}^k & \dots & \varphi_{1,N_{BS}^h}^k \\ \varphi_{2,1}^k & \varphi_{2,2}^k & \dots & \varphi_{2,N_{BS}^h}^k \\ \vdots & \vdots & \ddots & \vdots \\ \varphi_{N_{BS}^v,1}^k & \varphi_{N_{BS}^v,2}^k & \dots & \varphi_{N_{BS}^v,N_{BS}^h}^k \end{bmatrix} = \begin{bmatrix} \mathbf{g}_1^k & \mathbf{g}_2^k & \dots & \mathbf{g}_{N_{BS}^h}^k \end{bmatrix} \quad (2)$$

式中, $\varphi_{u,v}^k$ 为 UPA(u, v) 处的第 k 束波束的相位响应, $u = 1, 2, \dots, N_{BS}^v$, $v = 1, 2, \dots, N_{BS}^h$ 。因此, 码本矩阵 \mathbf{F} 由相应列堆叠而成, 即:

$$\mathbf{F}_k^T = \begin{bmatrix} \mathbf{g}_1^{kT} & \mathbf{g}_2^{kT} & \dots & \mathbf{g}_{N_{BS}^h}^{kT} \\ \mathbf{f}_1^k & \mathbf{f}_2^k & \dots & \mathbf{f}_{N_{BS}^h}^k \end{bmatrix} \quad (3)$$

码本矩阵 \mathbf{F} 的第 k 列即是第 k 束波束的 BF 向

量。如果令 $\mathbf{f} \in \mathbf{C}^{M_{\text{mmw}} \times 1}$ 表示下行链路 BF 向量, 那么 MS 处的接收信号可以表示为:

$$\mathbf{y}_{\text{mmw}}(\bar{m}) = \mathbf{h}_{\text{mmw}}^T(\bar{m})\mathbf{f} + n_{\text{mmw}}(\bar{m}) \quad (4)$$

式中, $\mathbf{h}_{\text{mmw}}(\bar{m}) \in \mathbf{C}^{M_{\text{mmw}} \times 1}$ 表示在第 \bar{m} 个子载波从基站的 mmWave 阵列到 MS 处的下行链路信道; BF 向量 \mathbf{f} 选自码本 \mathbf{F} 即 $\mathbf{f} \in \mathbf{F}$, $|\mathbf{F}| = N_{\text{CB}}$ 。

2 特征选择和波束预测方案

本节论证依据功率损耗概率最小化准则选择场景化最优特征波束的合理性, 作为算法的理论基础。然后给出了场景化特征选择和波束预测方案。

2.1 依据最优波束概率选择特征波束

波束特征是指波束所对应信道的某些特征。这些特征可以是接收信号的强度^[19]或来自接入点信道的多径特征^[20]。本文定义波束特征是给定位置处不同波束的接收功率。此外还需定义接收功率损耗, 本文将波束最大接收功率与通过波束索引 k 选择的波束接收功率之比定义为功率损耗, 功率损耗可以表示为:

$$\xi = \frac{\max_{l \in B} \gamma_l}{\gamma_k} \quad (5)$$

式中, $\gamma_k = \|\mathbf{h}_k\|^2$ 是索引为 k 的波束接收功率; $\max_{l \in B} \gamma_l$ 是集合 B 中波束的最大接收功率, 集合 B 由所有发射波束构成。集合 S 是特征波束集且 $S \subset B$ 。接下来, 功率损耗概率定义为对于某些阈值 $c \geq 1$ 时, $\xi > c$ 的概率, 即:

$$P_{\text{pl}}(c, S) = \mathbb{P}[\xi > c] = \mathbb{P}\left[\max_{k \in B} \gamma_k > c \max_{i \in S} \gamma_i\right] \quad (6)$$

基于上述定义, 选择特征波束的目标是最大化接收功率, 该目标可以通过选择波束以最小化功率损耗概率 $P_{\text{pl}}(c=1, S)$ 来实现。对于给定的训练预算 N_b (即特征波束集大小), 该问题可以公式化为子集选择问题, 即:

$$\underset{S \subset B}{\text{minimize}} P_{\text{pl}}(1, S) \quad (7)$$

式中, $|S| = N_b$, $|S|$ 表示集合 S 的基数。问题 (7) 是一个子集选择问题, 本质上是组合问题, 通常很难解决, 特别是当 $|B|$ 较大时将变得更难求解。不过根据 $P_{\text{pl}}(1, S)$ 的构成, 该问题存在一个有效的解决方法。

问题 (7) 可以等价于 $\underset{S \subset B}{\text{maximize}} \bar{P}_{\text{pl}}(1, S)$, 其中 $\bar{P}_{\text{pl}}(1, S) = 1 - P_{\text{pl}}(1, S)$ 。由于:

$$\bar{P}_{\text{pl}}(1, S) = \sum_{l \in S} \mathbb{P}\left[\gamma_l = \max_{k \in B} \gamma_k\right]$$

是一个模函数, 那么由算法 1 给出的贪婪解就是最优的, 详见文献 [21]。这是一个已知的结论, 并已被多篇文献引用 (详见文献 [22])。

命题 1 $\bar{P}_{\text{pl}}(1, S)$ 是模函数

证明: 根据式 (6) 中功率损耗概率, 当 $c = 1$ 时,

$$P_{\text{pl}}(1, S) = \mathbb{P}\left[\max_{k \in B} \gamma_k > \max_{i \in S} \gamma_i\right] = \quad (8)$$

$$\sum_{l \in B} \mathbb{P}\left[\gamma_l > \max_{i \in S} \gamma_i \mid \gamma_l = \max_{k \in B} \gamma_k\right] \mathbb{P}\left[\gamma_l = \max_{k \in B} \gamma_k\right] = \quad (9)$$

$$\sum_{l \in B \setminus S} \mathbb{P}\left[\gamma_l = \max_{k \in B} \gamma_k\right] = \quad (10)$$

$$1 - \sum_{l \in S} \mathbb{P}\left[\gamma_l = \max_{k \in B} \gamma_k\right] \quad (11)$$

其中式 (9) 是全概率公式在事件 $\left\{\gamma_l = \max_{k \in B} \gamma_k\right\}$ 上的应用。此外式 (10) 中如果 $l \in S$, 则 $\mathbb{P}\left[\gamma_l > \max_{i \in S} \gamma_i \mid \gamma_l = \max_{k \in B} \gamma_k\right] = 0$, 如果 $l \in B \setminus S$, 那么 $\mathbb{P}\left[\gamma_l > \max_{i \in S} \gamma_i \mid \gamma_l = \max_{k \in B} \gamma_k\right] = 1$ 。

根据 $\sum_{l \in B} \mathbb{P}\left[\gamma_l = \max_{k \in B} \gamma_k\right] = 1$, 可得到式 (11), 从而可得:

$$\bar{P}_{\text{pl}}(1, S) = \sum_{l \in S} \mathbb{P}\left[\gamma_l = \max_{k \in B} \gamma_k\right] \quad (12)$$

因此, 对任意的 $S \subset R \subset B$ 以及 $\forall n \in B \setminus T$, 总是存在:

$$\bar{P}_{\text{pl}}(1, S \cup \{n\}) - \bar{P}_{\text{pl}}(1, S) = \bar{P}_{\text{pl}}(1, R \cup \{n\}) - \bar{P}_{\text{pl}}(1, R) = \mathbb{P}\left[\gamma_n = \max_{k \in B} \gamma_k\right] \quad (13)$$

这即是模函数的定义^[22-23]。

虽然算法 1 能够直观有效的选择特征波束, 但是使用贪婪搜索来解决最小化问题不够高效。为此, 可以将最优波束概率定义为:

$$P_{\text{opt}}(i) = \mathbb{P}\left[\gamma_i = \max_{k \in B} \gamma_k\right] = \mathbb{P}\left[\gamma_i \geq \gamma_k, \forall k \in B \setminus \{i\}\right] \quad (14)$$

通过证明命题 1 可以提出了一个更有效的特征选择解决方案。即, 根据式 (11), 当 $i \in B \setminus S_{n-1}$ 时, 最小化 $P_{\text{pl}}(1, S_{n-1} \cup \{i\})$ 等价于:

$$k = \underset{i \in B \setminus S_{n-1}}{\operatorname{argmax}} P_{\text{opt}}(i) \quad (15)$$

这意味着算法 1 等价于将波束的最优波束概率降序排列, 选择前 N_b 个波束即可完成特征波束集的构造。因此, 该方案所需要训练的波束个数远小于 $|B|$ 。

算法 1 mmWave 波束的贪婪搜索算法

输入 S_0, N_b, S_n, S_m

输出 特征波束 S_t

算法初始化: 设定 $n = 1$; 将 S_0, S_m 初始化为空集

for $n = 1 : N_b$ do

$S_m = \arg \min_{i \in B \setminus S_{n-1}} P_{\text{pl}}(1, S_{n-1} \cup \{i\})$

$S_t = S_{n-1} \cup S_m$

end for

2.2 特征波束集的离线生成

在本文 2.1 节的基础上, 本小节使用基于局部学习的特征选择聚类算法 (local learning based clustering algorithm with feature selection, LLC-fs) 计算最优波束概率^[24], 通过交叉验证确定特征波束集大小, 获得场景化的特征波束集。假设将给定场景均匀划分为 P 个部分, MS 部署在这 P 处收集训练数据。假设发射波束码本集合 B 的维度为 K , 训练

数据集 T 由 P 个 K 维接收功率向量组成, 记作 $r_i, i = 1, 2, \dots, P$ 。当 MS 位于位置 i 时, BS 通过交替发射 K 个波束生成接收向量 $r_i, i = 1, 2, \dots, P$ 。数据集 T 可以随机分为训练集 P_{train} 和测试集 P_{test} , 大小分别占数据集 T 的 70% 和 30%。根据以下两个步骤获得场景化特征波束集。

1) 对 K 个场景化波束加权并排序

首先, 在不考虑 P_{train} 中元素排列顺序的情况下, 将所有元素以矩阵形式输入 LLC-fs 算法。然后, LLC-fs 算法将根据最优波束概率降序输出 K 个波束的索引, 将 LLC-fs 算法输出的 K 维加权向量, 记作 z 。

2) 生成场景化特征波束集

假设正整数 N_b 是特征波束集 S 的大小 ($N_b \leq K$), 选择 z 的前 N_b 项即可生成特征波束集 S 。 N_b 可以通过交叉验证算法确定^[25]。具体而言, 令 μ 表示波束搜索期望精度, 令特征波束集 S 的初始大小为 N_0 , 使用 S_0 训练生成的波束预测 DNN 模型, 并用与 P_{test} 相关的测试点计算 DNN 预测精度 μ_0 , 判断 μ_0 是否达到 μ , 并据此不断修改 N_0 的大小, 直到 $\mu_0 = \mu$ 。算法 2 总结了场景化特征波束集的产生过程, 并在图 2 中做了直观的展示。使用特征波束集离线训练波束预测 DNN 模型的具体步骤将在 2.3 节详细阐述。

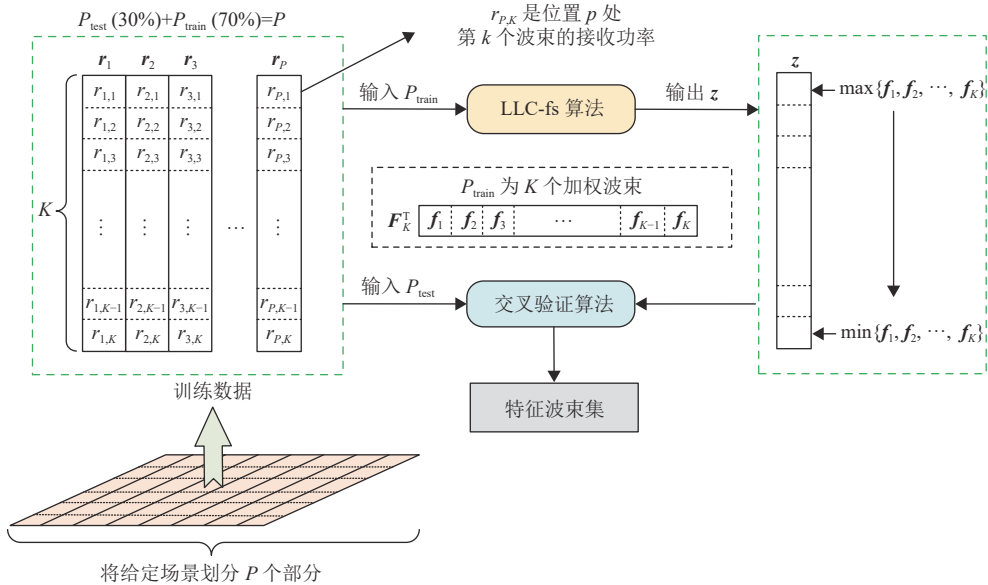


图 2 特征波束集生成示意图

算法 2 基于 LLC-fs 的波束训练算法

输入 训练数据集 T , 期望精确度 μ , 即时精确度 μ_t , 特征波束集大小 N_b

输出 场景化特征波束集 S 和 DNN 模型 M

算法初始化: 设定 $N_b = 1; \mu_t = 0$; 将数据集 T 随机分为两个子集, 其中 70% 用于训练集 P_{train}

和 30% 用于为测试集 P_{test}

将 P_{train} 输入 LLC-fs 算法, 输出波束索引按降序排序的加权向量 \mathbf{z}

for $\mu_t = 0 : \mu$ do

令 S_t 和 M_t 为即时特征波束集和即时 DNN 模型, S_t 由 \mathbf{z} 的前 N_b 项组成。

利用 S_t 生成给定应用场景的 M_t , 并使用 P_{test} 验证 M_t 预测结果, 得到即时精确度 μ_t 。

$N_b = N_b + 1$

$S = S_t$

$M = M_t$

end for

2.3 DNN 模型的离线训练和在线预测过程

根据本文第 1 节中设定的系统和信道模型, 下行可达速率可以表示为:

$$\mathbf{R}(\mathbf{y}_{\text{mmW}}(u), \mathbf{f}) = \sum_{u=1}^U \log_2(1 + \text{SNR} |\mathbf{h}_{\text{mmW}}^T(u) \mathbf{f}|^2) \quad (16)$$

式中, $\mathbf{h}_{\text{mmW}}(u)$ 表示 mmWave 下行信道; $\mathbf{y}_{\text{mmW}}(u) = |\mathbf{h}_{\text{mmW}}^T(u) \mathbf{f}|^2$ 表示接收功率; \mathbf{f} 表示 BF 向量, 如第 1 节所示, 假设 \mathbf{f} 在模拟域中产生。每个子载波的信噪比定义为:

$$\text{SNR} = \frac{P_{\text{mmW}}}{K\sigma_{\text{mmW}}^2} \quad (17)$$

最优 BF 向量 \mathbf{f}^* 为:

$$\mathbf{f}^* = \arg \max_{\mathbf{f} \in \mathcal{F}} \mathbf{R}(\mathbf{y}_{\text{mmW}}(u), \mathbf{f}) \quad (18)$$

对于 \mathbf{f} 的约束使得下行可达速率的优化问题是一个非凸问题, \mathbf{f}^* 需要通过穷举搜索获得。然而, 实现这样的搜索需要估计 \mathbf{h}_{mmW} 并且在线穷举波束训练, 在应用 Massive MIMO 技术后, 这两者较大的训练开销都将难以接受。为了减少这些开销, 本文将利用特征波束集离线训练场景化的 DNN 模型在线预测最优 BF 向量。

对于给定的环境, 令 $\{x_u\}$ 表示 MS_u 位置的集合, $\{\mathbf{h}_{\text{mmW}}\}$ 和 $\{\mathbf{h}_{\text{fea}}\}$ 分别表示 MS_u 与 mmWave 天线阵列之间的信道和特征信道集合, 其中 $\{\mathbf{h}_{\text{fea}}\}$ 由 $\{\mathbf{h}_{\text{mmW}}\}$ 经过特征选择得到的。当 MS 位置相同并采用大规模天线阵列时, 可以认为 $\{x_u\}$ 与 $\{\mathbf{h}_{\text{fea}}\}$ 和 $\{\mathbf{h}_{\text{mmW}}\}$ 间存在双射映射函数^[26-27], 定义为:

$$\begin{aligned} \Phi: \{x_u\} &\iff \{\mathbf{h}_{\text{mmW}}\} \\ \{x_u\} &\iff \{\mathbf{h}_{\text{fea}}\} \end{aligned} \quad (19)$$

那么接下来, 可以将 MS 位置与下行可达速率

的映射函数定义为 Ψ :

$$\Psi: \{x_u\} \rightarrow \{\mathbf{R}(\mathbf{y}_{\text{mmW}}(u), \mathbf{f}_n)\} \quad (20)$$

式中, n 是码本 \mathbf{F} 的索引, $n = 1, 2, \dots, |\mathbf{F}|$ 。 Ψ 将 mmWave 信道以及下行可达速率 \mathbf{R} 与 BF 向量 \mathbf{f} 结合起来。因此, 结合式 (19) 和式 (20) 可以推导出 mmWave 特征信道和下行可达速率之间存在映射关系 Γ :

$$\Gamma: \{\mathbf{h}_{\text{fea}}\} \rightarrow \{\mathbf{R}(\mathbf{y}_{\text{mmW}}(u), \mathbf{f}_n)\} \quad (21)$$

利用特征波束集预测最优 mmWave 波束的过程如下。

将 BS_A 服务区域分为多个子区域, 假设 MS_1 进入或停留在 BS_A 服务的子区 Q , 且子区 Q 的特征波束集 S_Q 已获得。下面分别说明 DNN 模型的离线训练过程和在线预测过程。

1) DNN 模型的离线训练过程

首先要构建训练网络的数据集, 使用本文第 2.2 节所提方法生成场景化特征波束集 S 。其次, 在每个相干时间内, 通过下行链路导频估计 mmWave 信道, 并且对 mmWave 下行链路进行穷举波束训练, 记录每个 BF 向量 \mathbf{f} 对应的下行可达速率。令 $\mathbf{R}^u = \{\mathbf{R}(\mathbf{y}_{\text{mmW}}^u, \mathbf{f}_1), \dots, \mathbf{R}(\mathbf{y}_{\text{mmW}}^u, \mathbf{f}_F)\}$ 表示 MS_u 处所有码本波束的下行可达速率。于是, 在每个相干时间数据点 $(\mathbf{y}_{\text{mmW}}^u, \mathbf{R}^u)$ 会被添加到数据集中。最后, 利用构建的训练集训练 DNN 模型直至收敛。基站通过该模型直接使用 MS_1 的 N_b 个接收功率来预测最优 mmWave 波束。

2) DNN 模型的在线预测过程

根据特征波束集产生过程可知, 给定的应用场景可以由 N_b 个特征波束代表。在线波束预测阶段在收到通信请求后开始, MS_1 发送上行导频报告向 BS_A 所处应用场景及位置。接下来, BS_A 选择 MS_1 所处位置的场景化特征波束集 S 和 DNN 模型, 并激活属于 S 的 N_b 个波束来覆盖 MS_1 , MS_1 将相应的 N_b 个接收功率向量记为 \mathbf{y} , 并将 \mathbf{y} 发送回 BS_A 。在基站侧将 \mathbf{y} 输入所属场景化的 DNN 模型, 输出用于服务 MS_1 的最优波束索引 k_{opt} , 至此在线阶段波束预测结束。这节省了与 mmWave 穷举波束训练过程相关的所有训练开销。算法 3 中总结了上述在线处理的过程。

算法 3 基于在线波束预测算法

输入 场景化的特征波束集 S_Q 和 DNN 模型 M_Q 。

输出 最优波束索引 k_{opt} 。

MS₁ 发送上行导频报告向 BS_A 所处位置。

BS_A 根据 MS₁ 所处位置, 激活属于 S_Q 的 N_b 个波束覆盖 MS₁。

MS₁ 将接收到的 N_b 个接收功率向量记作 \mathbf{y} , 并将其发送回 BS_A。

在基站一侧将 \mathbf{y} 输入 M_Q 。

输出预测的最优波束索引 k_{opt} 。

BS_A 将 k_{opt} 发送回 MS₁。

3 波束预测 DNN 模型与参数设定

3.1 网络结构

深度学习模型通过离线训练具有逼近非平凡函数的能力, DNN 利用辅助信息预测最优 mmWave 波束的可行性已被证明^[28]。对于本文的波束预测问题, 特征波束集中的每个特征波束所对应的信道被映射到 N_b 个索引之一。这可以看作一个分类问题并利用 DNN 卓越的分类预测能力解决。DNN 的任务是学习如何将特征波束接收功率向量映射到实值 N_b 维向量 \mathbf{p} 中。因此, 本文使用有单个输入层、多个隐藏层和单个输出层的多层感知器网络, 该网络包含一系列非线性向量变换, 如图 3 所示。隐藏层选用 ReLU 作为激活函数为神经网络引入非线性因素, 在每一个隐含层后增加了 Dropout 层, 降低网络对单个神经元的依赖, 确保正则化的同时避免过拟合, 增强了泛化能力。所有全连接层具有相同的宽度, 每层有 M_{NN} 个神经元。




图 3 波束预测 DNN 示意图

在该神经网络中, 预测任务的输出数量随着特征波束集的大小而不同, 假设预测波束索引有 N_b 个波束选择, 最后一层是具有 N_b 个神经元的全连接层, 其将输入的多维波束特征向量映射到 N_b 维分类空间, 并将映射输入到 Softmax 层, 通过计算输入向量中每个元素 i 的如下概率生成概率分布:

$$p_i = e^{t_i} / \sum_{j=1}^{N_b} e^{t_j} \quad (22)$$

式中, t_j 是 N_b 维投影向量的第 j 个元素 (SoftMax 的输入); p_i 是第 i 个波束索引的预测概率。最后, 概率最高的索引将是用于服务 MS 的最优 mmWave 波束索引 k_{opt} 。表 1 总结了训练 DNN 过程中的具体参数。

表 1 深度神经网络配置参数

参数	值
隐藏层数/个	5
隐藏层神经元/个	2 048
优化器	SGDM
动量	0.9
丢弃率	10%
l_2 正则化	1×10^{-4}
学习率	0.001
数据集大小	9 050
数据集分割	30%~70%
特征波束集大小	10
最大迭代数	100

3.2 输入归一化及构建标签

令 $\Delta = \max\{|\mathbf{y}_{\text{mmw}}|\}$ 表示归一化因子, 接收功率向量由归一化因子处理后分解为实部和虚部, 最后重新组合成新的向量。长度为 $2N_b N_{\text{BS}}^v$ 的新实值向量将作为神经网络的输入。对于数据集中的波束预测标签, 可以建模为 N_{BS}^h 维独热向量。每个 mmWave 信道的一个独热向量在对应的最优 BF 向量的索引处为 1 (可由式 (18) 计算得到) 数据集准备就绪后, 训练 DNN 模型以实现最小化交叉熵损失函数, 该函数定义为:

$$I = - \sum_{i=1}^D t_i \log_2(p_i) \quad (23)$$

式中 $\mathbf{t}_i = [t_1, t_2, \dots, t_D]$ 是目标的独热向量; $\mathbf{p}_i = [p_1, p_2, \dots, p_D]$ 是 DNN 预测属于第 i 类的概率。

4 仿真结果与分析

4.1 仿真场景与参数设置

本文使用 DeepMIMO 数据集的两个开源仿真场景^[29], 分别是 28 GHz 的室外环境 “O1_28” 和 60 GHz 的室内场景 “I3_60”。图 4 是 “O1_28” 的示意图, 包含两条街道和一个十字路口。街道两

侧共部署 18 个基站 (BS₁ - BS₁₈), MS 位于在 3 个均匀的 x - y 网格中。图 5 是室内场景 “I3_60” 的示意图, 是一个包含走廊的会议室。会议室内墙部署 BS₁ 和 BS₂。MS 位于在 2 个均匀的 x - y 网格中, 分别是视距 (line of sight, LOS) 传播网格和非视距 (non line of sight, NLOS) 传播网格。最后, 所

有 MS 都配备了一个偶极子天线, 其轴线与 z 方向对齐。本文设置了以下 4 种场景来检验所提方案的性能。生成这 4 种场景数据集所需参数如表 2 所示, 这 4 种场景的基站天线数、OFDM 子载波数、OFDM 采样因子、天线间距和带宽均相同, 分别为 64、512、1、半波长和 0.5 GHz。

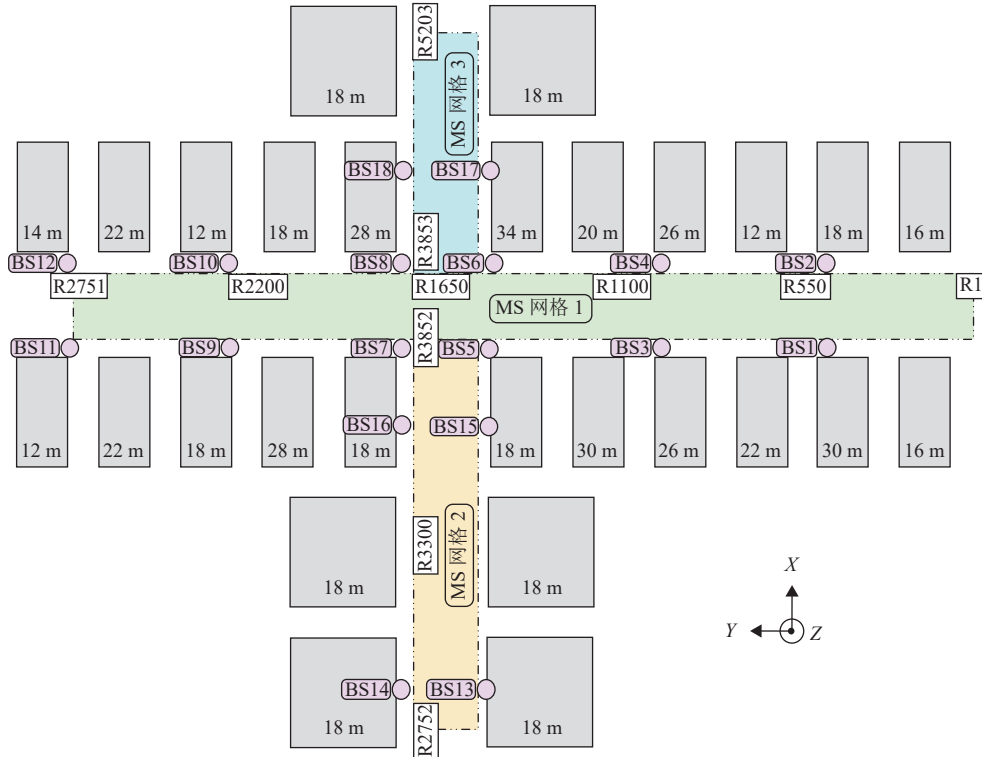


图 4 “O1_28” 室外场景示意图




图 5 “I3_60” 室内场景示意图

室外场景 1: 主街道场景。模拟 MS 和 BS 都在西侧街道的情景。

室外场景 2: 交叉路口场景。模拟 BS 部署在十字路口, MS 位于东西南北四侧街道上的情景。

室内 LOS 场景 3: 室内视距传播场景。
室内 NLOS 场景 4: 室内非视距传播场景。

4.2 性能评估指标

为了评估本文所提方案预测性能, 采用预测最优波束的准确性作为性能指标。准确性分为精度 Top-1 和 Top- n 两种主要性能指标。Top-1 精度定义为正确预测输入类别的频率, 记作 G_1 , 可表示为:

表 2 DeepMIMO 数据集生成参数

参数	场景1	场景2	场景3	场景4
数据集生成场景	O1_28	O1_28	I3_60	I3_60
激活基站序号	BS10	BS5	BS1	BS1
激活用户序号	R2150- R2200	R600-R650(E); R4000-R4050(N); R2150-R2200(W); R3300-R3350(S);	R1-R100	R600- R700
多径数	5	5	3	3

$$G_1 = \frac{1}{P} \sum_{p=1}^P \mathbb{I}(\omega_p^* = \tilde{\omega}_m) \quad (24)$$

式中, $\mathbb{I}(\cdot)$ 表示指示函数; ω_p^* 和 $\tilde{\omega}_m$ 分别表示第 p 个测试样本的实际类别和预测类别。此外, 由于分类 DNN 会产生所有波束索引的概率分布, 因此本文还研究了前 3 个预测结果中是否包含正确类别。使用 Top-3 精度进行量化, 记作 G_3 , 同理可以由式 (24) 得到。

4.3 波束预测性能

本文使用穷举波束训练得到的系统频谱效率作为性能上界(理论值), 并将本方案的预测结果与系统上界进行对比。

表 3 展示了在室外场景 1 下, Top-1 和 Top-3 的准确率。如表所示, 本文所提出方案可以明显对抗恶劣的噪声情况, 具有较好的鲁棒性。如当 SNR = -10 dB 时, Top-3 准确率依然可以达到 95.8%, 并且当 SNR = 0 dB 时, 该模型 Top-1 和 Top-3 准确率等于 85.9% 和 97.0%。这表明经过特征选择后, 少量的 mmWave 波束训练也可以得到媲美穷举法的性能, 即训练特征波束集中的 10 个波束而不是扫描整个码本(本例中为 64 个波束)。


表 3 波束预测 Top-1 和 Top-3 准确率

SNR/dB	Top-1/%	Top-3/%
-10	74.0	95.8
-5	83.1	96.4
0	85.9	97.0
5	87.3	97.1
10	89.5	97.4
15	89.7	98.5
20	90.2	98.9


为了验证所提方案在不同场景下的有效性, 在图 6a~图 6d 中分别展示了室外场景 1、室内 LOS 场景 3 和室内 NLOS 场景 4 在不同信噪比下 Top-1 和 Top-3 的频谱效率。为考察所提方案在同一室外环境不同子区的特征提取和波束预测性能, 图 6b 同时考察了室外场景 1 和室外场景 2 的 Top-1 性能, 便于绘图起见, 图 6b 仅考察 Top-1 准确率。

从图 6a~图 6d 中可以看出, 在不同场景下本方案 Top-3 可达率几乎与上界一致, 随着 SNR 的提高, Top-1 和 Top-3 频谱效率与上界的差距逐渐变小。并且当 SNR ≥ -2 dB 后, 图 6a~图 6d 的 Top-1 可达率平均值比上界平均值分别小 0.118 5、


0.076 1 和 0.201 3 bps/Hz。在图 6b 中可以看出由于户外场景 2 的各个子区距离基站较远, 通信质量较差导致 Top-1 准确率略低于室外场景 1, 但 SNR ≥ 0 dB 后, 都具有较好的预测准确率。




a. 室外场景 1



b. 多场景 Top-1 准确率



c. 室内 LOS 场景 3



d. 室内 NLOS 场景 4

图 6 不同场景波束预测性能图

4.4 特征波束集的大小对预测性能的影响

为了研究特征波束集的大小 M_b 对本方案预测

性能的影响, 在仅改变室外场景 1 配置中 N_b 大小时, 得到了不同 N_b 的 Top-3 频谱效率, 如图 7 所示。




图 7 N_b 对预测性能影响示意图

本例中码本包含 64 个波束, 当 $N_b = 5$ 时, Top-1 可达率平均值与上界平均值相差 0.328 4 bps/Hz, 预测性能较差。当 N_b 分别等于 10、15、20 时, Top-1 可达率平均值比上界平均值分别少 0.118 5、0.110 4、0.105 5 bps/Hz。可以发现随着 N_b 增大, Top-1 可达率逐渐增大并趋于稳定, 从而也反映出本方案提取的特征波束是有效的。

5 结束语

本文提出了场景化 mmWave 特征选择和波束搜索方案。在离线特征选择阶段, 考虑通信的场景特征, 利用 LLC-fs 算法获得最优波束概率并生成特征波束集, 再通过交叉验证确定特征波束集大小, 从而缩小波束搜索的范围减少波束搜索的开销。为进一步减少在线 mmWave 信道估计和穷举波束训练的开销, 利用了 DNN 模型逼近场景化特征波束集与最优波束之间为隐式、非线性的映射关系。在线波束预测阶段, 根据 MS 所处场景, 在 BS 侧将 MS 的接收功率向量送入训练好的场景化 DNN 模型, 即可输出服务于 MS 的最优波束索引, 完成在线波束搜索。

仿真结果表明, 在不同应用场景以及同一应用场景的不同位置, 在本方案良好的预测性能基础上, 能有效缩小波束搜索的开销。

参 考 文 献

- [1] 黄劲安, 区奕宁, 董力, 等. 5G 空口设计与实践进阶[M]. 北京: 人民邮电出版社, 2019.
HAUNG J N, QU Y N, DONG L, et al. 5G air interface designing and network construction advancing[M]. Beijing: The People's Posts and Telecommunications Press, 2019.
- [2] KEBEDE T, WONDIE Y, STEINBRUNN J, et al. Precoding and beamforming techniques in mm wave-massive MIMO: Performance assessment[J]. *IEEE Access*, 2022, 10: 16365-16387.
- [3] KUTTY S, SEN D. Beamforming for millimeter wave communications: an inclusive survey[J]. *IEEE Communications Surveys & Tutorials*, 2016, 18(2): 949-973.
- [4] 侯嘉智. 5G 毫米波波束搜索算法研究[D]. 重庆: 重庆邮电大学, 2020.
HOU J Z. Research on 5G millimeter wave beam search algorithm[D]. Chongqing: Chongqing University of Posts and Telecommunications, 2020.
- [5] de DONNO D, PALACIOS J, WIDMER J. Millimeter-wave beam training acceleration through low-complexity hybrid transceivers[J]. *IEEE Transactions on Wireless Communications*, 2017, 16(6): 3646-3660.
- [6] 吴伟. 毫米波 MIMO 无线通信系统中的混合波束成型技术研究[D]. 北京: 北京邮电大学, 2019.
WU W. Research on hybrid beamforming technology in millimeter-wave MIMO wireless communication system [D]. Beijing: Beijing University of Posts and Telecommunications, 2019.
- [7] WANG J Y, LAN Z, PYO C W, et al. Beam codebook-based beamforming protocol for multi Gbps millimeter wave WPAN systems[J]. *IEEE Journal on Selected Areas in Communications*, 2009, 27(8): 1390-1399.
- [8] LEE H, KO Y. Low complexity codebook-based beamforming for MIMO-OFDM systems in millimeter wave wpAN[J]. *IEEE Transactions on Wireless Communications*, 2011, 10(11): 3607-3612.
- [9] 张仁民. 毫米波通信系统多分辨率码本设计与低开销波束训练技术研究[D]. 南京: 东南大学, 2019.
ZHANG R M. Multi-Resolution codebook design and low-overhead beam training for millimeter-wave communications[D]. Nanjing: Southeast University, 2019.
- [10] CHEN H J, SUN C Y, JIANG F, et al. Beams selection for mmwave multi-connection based on sub-6 GHz predicting and parallel transfer learning[C]//2021 IEEE/CIC International Conference on Communications in China. Xiamen: IEEE, 2021: 469-474.
- [11] ALRABEIAH M, ALKHATEEB A. Deep learning for mmwave beam and blockage prediction using sub-6GHz channels[J]. *IEEE Transactions on Communications*, 2020, 68(9): 5504-5518.
- [12] ALI A, GONZÁLEZ-PRELCIC N, Jr HEATH R. Millimeter wave beam-selection using out-of-band spatial information[J]. *IEEE Transactions on Wireless Communications*, 2018, 17(2): 1038-1052.
- [13] MA K, HE D X, SUN H C, et al. Deep learning assisted calibrated beam training for millimeter-wave communication systems[J]. *IEEE Transactions on Communications*, 2021, 69(10): 6706-6721.
- [14] KAO W, ZHAN S, LEE T. AI-Aided 3-D beamforming for millimeter wave communications[C]//2018 International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS). Ishigaki: IEEE, 2018: 278-283.
- [15] JOUNG S, JEONG C, CHOI S. Deep learning based beam

- selection for wide beam sweeping system[C]//2022 International Conference on Electronics Information and Communication (ICEIC). Jeju: IEEE, 2022: 1-3.
- [16] KIM T, LOVE D. Virtual AoA and AoD estimation for sparse millimeter wave MIMO channels[C]//2015 IEEE 16th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). Stockholm: IEEE, Jeju: IEEE, 2015: 146-150.
- [17] HAN Y, LEE J. Two-Stage compressed sensing for millimeter wave channel estimation[C]//2016 IEEE International Symposium on Information Theory (ISIT). Barcelona: IEEE, 2016: 860-864.
- [18] HEATH R, Jr 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.
- [19] LAKMALI B, DIAS D. Database correlation for GSM location in outdoor & indoor environments[C]//2008 4th International Conference on Information & Automation for Sustainability. Colombo: IEEE, 2008: 42-47.
- [20] KUPERSHTEIN E, WAX M, COHEN I. Single-Site emitter localization via multipath fingerprinting[J]. *IEEE Transactions on Signal Processing*, 2013, 61(1): 10-21.
- [21] EDMONDS J. Matroids and the greedy algorithm[J]. *Mathematical Programming*, 1971, 1(1): 127-136.
- [22] CALINESCU G, CHEKURI C, PAL M, et al. Maximizing a monotone submodular function subject to a matroid constraint[J]. *SIAM Journal on Computing*, 2011, 40(6): 1740-1766.
- [23] NEMHAUSER G, WOLSEY L, FISHER M. An analysis of approximations for maximizing submodular set functions—I[J]. *Mathematical programming*, 1978, 14(1): 265-294.
- [24] ZENG H, CHEUNG Y. Feature selection and kernel learning for local learning-based clustering[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2011, 33(8): 1532-1547.
- [25] TANAKA A, IMAI H. Kernel ridge regression with autocorrelation prior: Optimal model and cross-validation[C]//2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Barcelona: IEEE, 2020: 3872-3876.
- [26] ALRABEIAH M, ALKHATEEB A. Deep learning for TDD and FDD massive MIMO: Mapping channels in space and frequency[C]//2019 53rd Asilomar Conference on Signals, Systems, and Computers. Pacific Grove: IEEE, 2019: 1465-1470.
- [27] VIEIRA J, LEITINGER E, SARAJLIC M, et al. Deep convolutional neural networks for massive MIMO fingerprint-based positioning[C]//2017 IEEE 28th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC). Montreal: IEEE, 2017: 1-6.
- [28] HORNIK K, STINCHCOMBE M, WHITE H. Multilayer feedforward networks are universal approximators[J]. *Neural Networks*, 1989, 5(2): 359-366.
- [29] ALKHATEEB A. Deep MIMO: A generic deep learning dataset for millimeter wave and massive MIMO applications[EB/OL]. [2022-02-23]. <https://arxiv.org/pdf/1902.06435.pdf>.

编辑 税 红