

基于变分自编码器的太赫兹信道多径分簇算法

郝昕宇¹, 廖希¹, 郑相全², 王洋¹, 林峰¹, 陈前斌¹, 张杰¹

(1. 重庆邮电大学通信与信息工程学院, 重庆 400065; 2. 中国人民解放军32002部队, 北京 100036)

摘要: 针对太赫兹信道中多径分簇算法在多维参数适应性和无监督特征分离中的不足, 提出了一种基于变分自编码器的潜层空间多径分簇 (VAE-LMC) 模型。首先, 通过变分自编码器 (VAE) 学习多径时延与到达角度的潜在表示, 增强特征可分离性。其次, 将K-Means分簇嵌入VAE框架, 联合优化重构损失、KL散度和分簇损失函数, 解决无监督学习中的特征分离难题。最后, 在潜层空间完成多径分簇并将结果映射至真实数据空间。在小型工厂场景中开展129.5~135 GHz的太赫兹信道测量, 构建训练数据集和测试数据集。实验结果表明, VAE-LMC模型在簇内和簇间特性、环境一致性及复杂度等方面均有显著优势, 为复杂场景下的太赫兹信道多径分簇提供了高效解决方案。

关键词: 太赫兹信道; 信道测量; 多径分簇; 变分自编码器; 无监督学习

中图分类号: TN92

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2025084

Variational autoencoder-based multipath clustering algorithm for terahertz channels

HAO Xinyu¹, LIAO Xi¹, ZHENG Xiangquan², WANG Yang¹, LIN Feng¹, CHEN Qianbin¹, ZHANG Jie¹

1. School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

2. PLA Unit 32002, Beijing 100036, China

Abstract: To address the shortcomings of multipath clustering algorithms in terahertz channel modeling, particularly in terms of multidimensional parameter adaptability and unsupervised feature separation, a variational autoencoder-based latent space multipath clustering (VAE-LMC) model was proposed. Firstly, the variational autoencoder (VAE) was utilized to learn latent representations of multipath delays and arrival angles, enhancing feature separability. Secondly, K-Means clustering was embedded into the VAE framework, with joint optimization of reconstruction loss, KL divergence, and clustering loss functions to resolve the challenges of feature separation in unsupervised learning. Finally, multipath clustering was performed in the latent space, and the results were mapped back to the real data space. Terahertz channel measurements at 129.5~135 GHz were conducted in a small factory scenario to construct training datasets and testing datasets. Experimental results demonstrate that the VAE-LMC model exhibits significant advantages in intra-cluster and inter-cluster characteristics, environmental consistency, and computational complexity, providing an efficient solution for terahertz channel multipath clustering in complex scenarios.

Keywords: terahertz channel, channel measurement, multipath clustering, variational autoencoder, unsupervised learning

收稿日期: 2025-03-06; 修回日期: 2025-04-27

通信作者: 廖希, liaoxi@cqupt.edu.cn

基金项目: 国家自然科学基金资助项目 (No.62271095, No.62171071); 重庆市自然科学基金资助项目 (No.cstc2021jcyj-msxmX0634, No.CSTB2022NSCQ-MSX1125); 重庆市教委科学技术研究资金资助项目 (No.KJZD-K202300607); 重庆市自然科学基金创新发展联合基金资助项目 (No.CSTB2022NSCQ-LZX0037)

Foundation Items: The National Natural Science Foundation of China (No.62271095, No.62171071), The Natural Science Foundation of Chongqing (No.cstc2021jcyj-msxmX0634, No.CSTB2022NSCQ-MSX1125), The Science and Technology Research Program of Chongqing Municipal Education Commission (No.KJZD-K202300607), The Natural Science Foundation Innovation and Development Joint Fund Project of Chongqing (No.CSTB2022NSCQ-LZX0037)

*第二十七届中国科协年会“6G技术创新与未来产业发展”专题

0 引言

太赫兹通信凭借其超大的带宽资源和高速数据传输能力, 已成为 6G 通信的关键候选技术之一^[1]。在工业物联网、高精度定位等场景中, 太赫兹通信需支持密集多径环境下的实时信道建模, 这对多径分簇算法的效率和精度提出了更高要求。在太赫兹信道中, 多径分量 (MPC, multipath component) 的物理参数, 如时延、功率和到达角等, 表现出了显著的分簇特性^[2]。根据接收信号的传播时延、接收功率和到达角度等传播参数对 MPC 进行分簇, 利用多径簇代表具有相似传播特性的 MPC 可以有效简化无线信道模型^[3]。基于多径簇的信道建模方法兼顾准确性和复杂度, 已被 3GPP TR 38.901、TR 25.996、COST 2100 等标准采用, 逐渐成为信道建模的重要趋势^[4]。

太赫兹波因高频短波特性的, 易受衰减与多径效应的影响, 导致传播过程复杂度和分簇难度显著增加。传统的分簇算法包括 K-Means、DBSCAN^[5-6]和谱聚类 (SC, spectral clustering)^[7]等。其中 K-Means 算法应用最为广泛, 并衍生出多种改进算法, 如考虑信号功率的 KPowerMeans 算法^[8-11]和考虑功率密度的 K-power density 算法^[12]。然而, 这些传统算法基于特定的距离度量或相似性度量, 在处理不同维度信道参数时仍存在适应性不佳的问题。

近年来, 深度学习在图像处理和自然语言处理领域取得了巨大成功, 其与分簇算法的结合为多径分簇算法研究开辟了新方向。例如, Xie 等^[13]提出了深度嵌入分簇 (DEC, deep embedded clustering) 模型, 通过 KL (Kullback-Leibler) 散度损失函数衡量微调过程中的软标签表示, 实现了深度嵌入特征表示和分簇分配结果的联合优化, 为深度分簇算法提供了范例。深度学习模型能够通过权重矩阵、偏置和激活函数等参数, 将输入信道数据映射到潜层空间, 每个潜层空间都能够捕获信道数据中的不同特征。基于潜层空间的多径分簇算法通过将原始信道数据投影到不同潜层空间来突出信道数据中的特定传播特征, 从而反映多径信号的相似性^[14-17]。此外, 将分簇过程直接嵌入深度学习模型中, 以联合优化潜层表示, 分簇目标的方法也受到广泛关注^[18-20]。除了传统的深度学习算法外, Yu 等^[21]提出了一种最大最小距离算法辅助的自组织特征映射 (MMD-SOM, maximum-minimum distance algorithm assisted

self-organizing feature map) 模型, 利用自组织特征映射模型的竞争学习机制, 对信号参数进行降维和离散化映射, 从而在映射空间得到符合信道真实分布的多径簇。上述研究均表明, 利用深度学习算法将原始数据转换到新的特征空间进行分簇具有巨大应用潜力。然而, 由于信道特征学习的有效性不足和无监督学习中特征分离难题的存在, 如何设计能够捕捉多径信号特性的网络结构并在无标签的情况下有效进行分簇, 仍然是一个亟待解决的难题^[22]。

针对传统的分簇算法在多维参数适应性和无监督学习中的不足, 本文提出了一种基于变分自编码器的潜层空间多径分簇 (VAE-LMC, variational autoencoder-based latent space multipath clustering) 模型, 通过潜层空间映射与多域联合分簇策略, 实现不需要人工干预的多径分簇。该模型将变分自编码器 (VAE, variational autoencoder) 与 K-Means 分簇相结合, 通过联合优化重构损失和聚类损失函数, 解决了无监督学习中的特征分离难题。利用小型工厂太赫兹信道的实测数据构建数据集, 全面评估了本文模型的性能。实验结果表明, 分簇结果与空间环境高度一致。此外, 本文还深入分析了太赫兹信道多径簇的时延扩展、角度扩展等特性, 为理解多径簇的时空特性提供了参考。

1 VAE-LMC 模型

在无线信道中, MPC 在相似时延和角度域上分布密集, 这使单域分簇模型的性能受限。为了克服这一问题, 多域联合分簇模型通过综合考虑时延、角度和功率等多个维度的信息, 能够更准确地识别和区分具有相似传播特性的 MPC 簇。多域联合分簇中通常使用多径分量距离 (MCD, multipath component distance)^[23]计算 MPC 之间的距离, MCD 可以表示为

$$\text{MCD}_{ij} = \sqrt{\|\text{MCD}_{\text{AoA},ij}^2\| + \zeta \text{MCD}_{\tau,ij}^2} \quad (1)$$

其中, $\text{MCD}_{\text{AoA},ij}$ 和 $\text{MCD}_{\tau,ij}$ 分别是第 i 和 j 个 MPC 在角度域和时延域的距离; ζ 是时延比例因子, 用于均衡时延域和角度域的差异。 $\text{MCD}_{\text{AoA},ij}$ 表示为

$$\text{MCD}_{\text{AoA},ij} = \frac{1}{2} \left| \begin{pmatrix} \sin(\varphi_i) \\ \cos(\varphi_i) \end{pmatrix} - \begin{pmatrix} \sin(\varphi_j) \\ \cos(\varphi_j) \end{pmatrix} \right| \quad (2)$$

其中, φ_i 和 φ_j 是第 i 和 j 个 MPC 的到达方位角。对应地, $\text{MCD}_{\tau,ij}$ 表示为

$$MCD_{\tau,ij} = \frac{|\tau_i - \tau_j|}{\Delta\tau_{\max}} \frac{\tau_{\text{std}}}{\Delta\tau_{\max}} \quad (3)$$

其中, τ_i 和 τ_j 分别是第*i*和第*j*个MPC的多径时延, $\Delta\tau_{\max}$ 是最大MPC时延差, τ_{std} 是多径时延标准差。

理论上, MCD可以解决多径时延和到达角度的缩放问题^[24], 但由于时延比例因子 ζ 取值范围广, 且需要结合主观视觉判断来不断修正, 使对不同场景和频段确定合适的 ζ 值变得困难。

为解决上述问题, 本文提出了一种基于变分自编码器的VAE-LMC模型, 通过变分自编码器学习多径时延和到达角度的潜在表示, 增强多径分簇的可分离性, 并在潜层空间中实现多径分簇。VAE-LMC模型在无监督学习框架下通过迭代训练进行优化, 采用联合损失函数引导多径分簇潜层空间的构建。对于选定的测量点, 假设共接收到*N*个MPC, 在此模型中, 输入数据由这些MPC的时延和到达方位角组成。输出是重构后的MPC时延和到达方位角, 以及每条MPC的分簇结果, VAE-LMC模型结构如图1所示。

1.1 变分自编码器

VAE由编码器和解码器两部分构成, 二者协同工作以实现数据的深度处理。编码器负责对输入的时延和角度等信道参数进行表征学习, 并通过非线性变换映射至潜层空间, 捕获信道参数的内在结构和关键信息。解码器则负责对输入的信道参数进行重构, 力求在保持关键特征的同时实现数据的完整还原。编码和解码的结构设计旨在提高数据处理

效率, 同时增加数据的可解释性和鲁棒性。编码器和解码器的运算过程可以表示为

$$h = \sigma(W_{\text{enc}}x + b_{\text{enc}}) \quad (4)$$

$$\tilde{x} = \sigma(W_{\text{dec}}h + b_{\text{dec}}) \quad (5)$$

$$l_{\text{rec}} = \frac{1}{N} \sum_i \|x_i - \tilde{x}_i\|_2^2 \quad (6)$$

其中, x 是编码器的输入, h 是编码器的输出, 同时也是解码器的输入, \tilde{x} 是解码器的输出, W_{enc} 和 W_{dec} 分别是编码器和解码器的权重, b_{enc} 和 b_{dec} 分别是编码器和解码器引入的偏置项, $\sigma(\cdot)$ 是激活函数引入的非线性运算, l_{rec} 是变分自编码器的重构损失, N 是输入的多径时延和角度数量, 即MPC的个数。

VAE-LMC模型的编码器和解码器由若干残差块组成, 残差块结构如图2所示。该结构由3个全连接层(FC₁、FC₂和FC₃)构成, 其中激活函数采用线性整流函数(ReLU, rectified linear unit)。特别地, FC₂和FC₃层引入了失活率为0.2的神经元随机失活机制, 目的是降低神经元之间的相互依赖性, 进而增强模型的泛化能力。对于输入参数为(*p*,*q*)的残差块, 输入层维度为*p*×*N*, 其中, *p*表示上一层输出的特征数量(如果是第一个残差块, 输入则是MPC的时延和到达方位角), *N*表示样本数量。输出维度为*q*×*N*, 其中*q*表示输出特征数量, 残差连接通过跳跃传递梯度, 并形成最终的输出。残差连接缓解了深层网络训练过程中的梯度消失问题, 同时保留了原始特征信息, 提升了模型对稀疏多径数据的适应性。

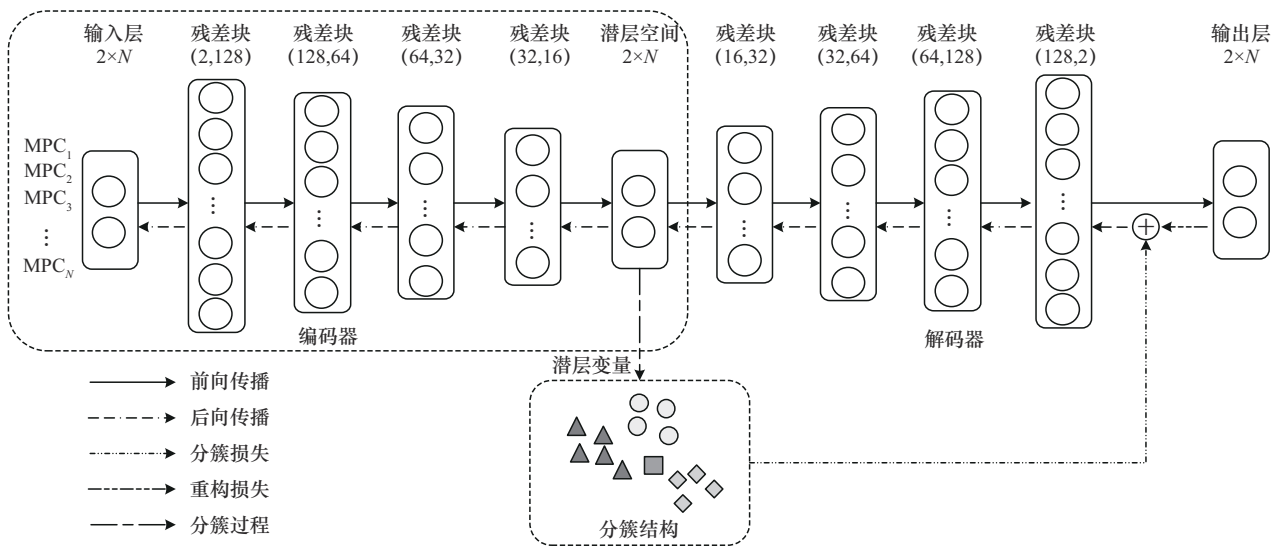


图1 VAE-LMC模型结构




图2 残差块结构

1.2 嵌入 K-Means 分簇

VAE 擅长学习数据的潜在表示，对比本文提出了一种创新策略，即将 K-Means 分簇结构嵌入 VAE 框架中，形成 VAE-LMC 模型。该模型利用 VAE 构建潜层空间，通过 K-Means 分簇结构对时延-角度的潜在表示进行分簇，并通过反向传播优化潜层空间。

针对多径分簇中不同评价指标可能导致评估结果不一致的问题，本文借鉴文献[25]中的联合指标构建方法，将轮廓系数 (SI, silhouette score)、方差比准则 (CHI, Calinski-Harabasz index) 和戴维森堡丁指数 (DBI, Davies-Bouldin index) 综合应用于多径分簇评价中，并通过反向传播参与模型参数更新，解决了无监督学习中的特征分离难题，有效提升了 VAE-LMC 模型的多径分簇性能。3 种评价指标介绍如下。

1) 轮廓系数 (SI)。SI 的取值范围在 -1~1，越接近 1 表示分簇效果越好，SI 表示为

$$SI = \frac{1}{N} \sum_{i=1}^N \frac{b_i - a_i}{\max(a_i, b_i)} \quad (7)$$

其中， N 是样本数量， a_i 是样本 i 到同簇其他样本的平均距离（即簇内距离）， b_i 是样本 i 到最近其他簇中所有样本的平均距离（即簇间距离）。

2) 方差比准则 (CHI)。CHI 值的大小直接反映了分簇效果的优劣，CHI 表示为

$$CHI = \frac{B}{W} \frac{N - k}{k - 1} \quad (8)$$

其中， B 是簇间方差， W 是簇内方差， N 是样本数量， k 是簇的数量。CHI 值越大表示簇间差异越大，簇内差异越小，即分簇效果佳。

3) 戴维森堡丁指数 (DBI)。DBI 值越小表示簇内样本越紧密，簇间样本越分散，即分簇效果越好，DBI 表示为

$$DBI = \frac{1}{k} \sum_{i=1}^k \max_{j \neq i} \left(\frac{\sigma_i + \sigma_j}{d(c_i, c_j)} \right) \quad (9)$$

其中， k 是簇的数量， σ_i 是簇 i 中所有样本到簇中心的平均距离， $d(c_i, c_j)$ 是簇中心 c_i 和 c_j 之间的距离。

1.3 损失函数

在 VAE-LMC 模型中，损失函数包括重构损失、KL 散度损失和分簇损失。重构损失通过均方误差 (MSE, mean squared error) 实现，确保时延-角度数据的精确重构。

KL 散度起到正则化潜层空间的作用，保证潜层空间和实际数据空间的一致性，有效解决了潜层空间分簇不连续的问题。KL 散度损失定义为

$$D_{KL}(q(z|x)||p(z)) = \sum_x q(z|x) \left[\ln \frac{q(z|x)}{p(z)} \right] \quad (10)$$

其中， $p(z)$ 是先验分布，在高斯信道中假设为标准正态分布， $q(z|x)$ 是潜层变量的后验分布，由编码器输出的均值 μ 和方差 $\ln(\sigma^2)$ 参数化得到。假设后验分布 $q(z|x)$ 是符合均值为 μ 和方差为 σ^2 的正态分布，则 KL 散度损失可以表示为

$$D_{KL}(q(z|x)||p(z)) = -\frac{1}{2} \sum_{j=1}^J (1 + \ln(\sigma_j^2) - \mu_j^2 - \sigma_j^2) \quad (11)$$

其中， μ 是潜层变量均值， σ^2 是对数方差， J 是潜层变量的维度。

为了进一步提升 VAE-LMC 模型的多径分簇性能，获取紧凑且有区分性的多径簇，将 SI、CHI 与 DBI 指标结合，形成分簇损失函数，引导模型的梯度下降过程，分簇损失函数表示为

$$l_{\text{cluster}} = \frac{\lambda}{1 \times 10^{-6} + |SI|} + \frac{\beta}{1 + |CHI|} + \gamma DBI \quad (12)$$

其中， λ 、 β 和 γ 分别是 3 个指标函数的权重，根据各指标的损失大小进行调节以平衡损失量级，实验中设置 $\lambda=\beta=\gamma=1$ 即可将损失限定到同一数量级。由此，VAE-LMC 模型的总体损失函数构造为

$$L = l_{\text{rec}} + D_{KL} + l_{\text{cluster}} \quad (13)$$

其中， l_{rec} 、 D_{KL} 和 l_{cluster} 分别是由式(6)、式(11)和式(12)求解的自编码器重构损失、KL 散度损失和分簇损失函数。

1.4 模型训练与分簇算法

VAE-LMC 模型通过集成 MSE、KL 散度和分簇损失函数,实现了数据重构、潜层空间正则化和分簇的多重优化。该模型通过迭代训练优化模型参数,过程如算法1所示。

算法1 基于自编码器的分簇潜层空间构建

输入 提取的 MPC, 目标簇数, 模型超参数

输出 构建潜层空间的模型参数和真实数据空间的分簇结果

- 1) 定义模型结构, 设置超参数、参数优化方法和目标簇数
- 2) 读取 MPC 的到达时延和到达方位角
- 3) 对到达方位角进行正弦运算处理
- 4) 对到达时延和到达方位角进行最小-最大归一化
- 5) 迭代训练:

初始化优化器和损失函数

遍历训练数据

优化器梯度清零

根据式(4)和式(5)计算自编码器模型输出

根据式(6)和式(11)计算重构损失和 KL 散度

每 20 次迭代设置评估点

根据式(4)计算编码器输出

使用 K-Means 算法进行分簇

根据式(12)计算分簇损失

根据式(13)计算总损失

反向传播总损失

更新优化器

输出迭代次数 k 和当前迭代下的损失函数

如果在 j 次迭代中损失没有降低, 或者到达最大迭代次数则训练停止

- 6) 保存最佳模型
- 7) 使用最佳模型输出分簇结果

VAE-LMC 模型的分簇过程如算法2所示, 在使用时仅需调用模型参数, 实现潜层空间分簇。

算法2 VAE-LMC 模型的分簇过程

输入 已训练的模型参数, 提取的 MPC, 目标簇数

输出 真实数据空间的分簇结果

- 1) 定义模型结构, 调用已训练的模型参数,

设置目标簇数

- 2) 读取 MPC 的到达时延和到达方位角
- 3) 对到达方位角进行正弦运算处理
- 4) 对到达时延和到达方位角进行最小-最大归一化
- 5) 根据式(4)调用模型将 MPC 参数映射到潜层空间
- 6) 使用 K-Means 算法进行分簇
- 7) 输出真实数据空间的分簇结果

2 基于矢量网络分析仪的频域信道测量

在含有离散散射体的小型工厂场景中, 开展了 129.5~135 GHz 频段的信道测量研究, 该场景的测量布置如图3所示, 单位为 m。

测量场景整体呈矩形分布, 长约 14 m, 宽 8.5 m, 顶部密布着灯管和不锈钢架子。北面有 8.5 m 长的墙壁, 嵌有 4.9 m 长的卷门 (测量时未关闭)。东面和西面各有 2 个贴满瓷砖的承重柱, 承重柱前有约 1 m 高的金属储物柜, 承重柱之间的距离是 5.3 m。在西北角, 西面有一截 3.3 m 长的墙壁, 嵌有约 2 m 长的不锈钢门。场景内离散分布着 5 台异构金属铣削机, 每台铣削机的长、宽和高分别为 1.7 m、1 m 和 1.8 m。发射机 (Tx) 和接收机 (Rx) 天线的高度分别设置为 1.6 m 和 1.5 m, 测量点 B1 至 B9 每个位置之间的距离为 1 m, B10、B11 和 B12 分别在 B3、B5 和 B8 东侧 2 m 的位置, 使用转台带动接收机旋转以充分捕获多径信号。测量平台为基于矢量网络分析仪 (VNA, vector network analyzer) 的频域信道测量平台, 主要组件包括矢量网络分析仪、矢量信号生成器、太赫兹收发模块、喇叭天线以及连接各部分的同轴电缆等器件, 基于 VNA 的频域信道测量平台如图4所示。

在信道测量前, 通过 SOLT (short-open-load-thru) 校准消除电缆、连接器和混频器等器件的插入损耗与相位偏移。在发射端, 信号发生器产生一个频率为 10.667 GHz 的本振 (LO, local oscillator) 信号, 然后通过倍频器进行 12 倍频, 再与 VNA 端口 1 产生的 1.5~7 GHz 中频 (IF, intermediate frequency) 信号混频到 129.5~135 GHz 频率范围内, 最终通过喇叭天线发出。在接收端, 输入相同的 LO 信号, 太赫兹信号被下变频到 IF 信号, 发送回 VNA 的端口 2, 获得 S_{21} 参数。发射天线为位置和角度固定的




图3 布有离散散射体的小型工厂场景

宽波束天线，接收器天线通过云台旋转，VNA 在每个旋转后进行一次频率扫描，构成虚拟均匀圆形阵列。

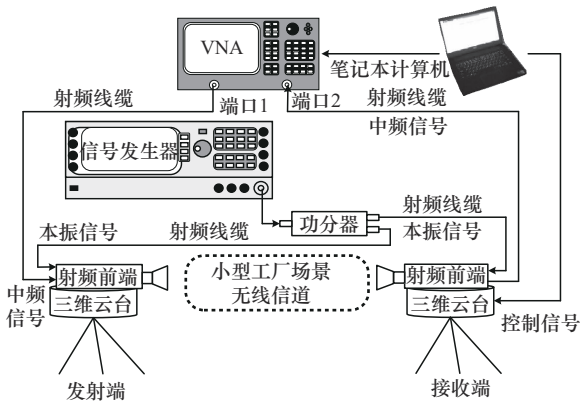


图4 基于VNA的频域信道测量平台

信道测量带宽 $B_w=5.5$ GHz，可以计算得到其时延分辨率 $\Delta\tau = \frac{1}{B_w} = 0.182$ ns，扫频间隔 $\Delta f=5$ MHz，扫频点数 $N = \frac{B_w}{\Delta f} = 1101$ ，最大剩余时延（MPC 的最大时延） $\Delta\tau_{max} = \Delta\tau N = 200$ ns。详细的太赫兹信道测量参数设置如表 1 所示。

表 1 太赫兹信道测量参数

小型工厂场景参数	数值
频率范围/GHz	129.5~135
带宽 B_w /GHz	5.5
中频信号频率 f_{IF} /GHz	1.5~7
本振信号频率 f_{LO} /GHz	10.667
倍频数 N_F	12
时延分辨率 $\Delta\tau$ /ns	0.182
扫频点数 N	1101
扫频间隔 Δf /MHz	5
中频带宽 B_{IF} /kHz	10
发射天线增益 G_{TX} /dBi	10
接收天线增益 G_{RX} /dBi	25
接收天线半波宽度 $HPBW_{Rx}$	H: 9°/E: 8°
接收方位角 ϕ	[0°:10°:360°]
接收俯仰角 θ	[-20°:10°:20°]
极化方式	垂直极化

3 性能分析

3.1 数据预处理

由于无法排除测量的信道脉冲响应中三维天线

方向图和相位误差的影响,本文通过功率门限法滤除噪声样本,剩余的所有样本认为是单独的MPC。在不同传播条件下,MPC传播参数的取值范围存在明显差异,不同传播参数之间的取值范围也具有较大差异。为了消除量纲影响,使用最小-最大归一化方法,将数据缩放到[0,1]区间内,表示为

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (14)$$

其中, x 是原始时延和角度数据, x' 是归一化时延和角度数据。

在太赫兹信道中,多径分量的到达方位角通常分布在 0° 至 360° 的环形范围内。若直接采用欧氏距离度量角度差异,可能会产生距离计算失真,例如,当2个角度分别位于环形边界的“两端”(如 350° 和 10°)时,其数值距离会被计算为 340° ,而实际物理空间中它们可能仅相差 20° (顺时针方向)。鉴于正弦值能直接反映角度的空间接近性,本文在数据处理中对到达角度进行正弦求解,将角度映射到 $[-1,1]$ 的连续区间内以避免边界的跳变问题。

3.2 分簇结果分析

物理信道特性是评估多径分簇性能的关键因素^[5]。对多径信号的分簇效果评估不仅依赖于时延和角度的区分程度,还需要考虑与物理空间的一致性。由于太赫兹信号的多径稀疏性,本文选择可以采集到丰富多径分量且接收信号功率不过分微弱的接收点B6进行单独分析。

实际测量中获取了大量的MPC,超过60 ns的多径成分由于路径损耗而功率较小,并且在固定扫描角度下,对远处散射体的角度分辨率也会减小,致使其无法准确区分散射体及其对信号的影响。为了准确探究散射体对多径传播的影响,在分析中仅提取了20~60 ns到达时间内具有较强接收功率的MPC。

对K-Means、高斯混合模型(GMM, Gaussian mixture model)、SC和SOM算法进行迭代分簇,使簇数在[4,15]区间遍历并利用紧凑指数^[26]确定最佳分簇数^[27]。对于DBSCAN算法,根据多径稀疏程度,将最小点数设置为5,使邻域半径在[0.01,1]区间内进行遍历以获取最佳邻域半径。

图5(a)~图5(f)分别展示了小型工厂场景中接收点B6处K-Means^[28-29]、DBSCAN^[30]、GMM^[26]、

SC、SOM^[21]和本文算法的分簇结果,图中不同形状的标记代表属于不同多径簇的MPC。

图5(a)中K-Means算法成功识别了位于25 ns处的主径信号,并对25~55 ns范围内来自不同散射体的多径信号进行了有效区分。但在30~35 ns范围内,MPC近似组成了一个球形簇,使K-Means算法无法有效对MPC进行分割而划为了同一簇。图5(b)中,DBSCAN算法获得了4个多径簇,除了多径簇2外,其余簇在时延域或者角度域上存在显著展宽。此外,实际场景中包含5台铣削机,包括视距路径在内应至少包含6个多径簇,而DBSCAN算法只区分得到了4个多径簇。不同于K-Means和DBSCAN算法,图5(c)中GMM算法成功区分了视距路径和来自铣削机A的一次反射路径,并将时延30~50 ns、方位角 250° 到 350° 处的多径分成了序号为3、4和7的3个紧凑多径簇。图5(d)中,SC分簇算法对时延域的差异敏感,在区分簇2和簇5、簇4和簇6时不够紧凑,总体效果不佳。图5(e)和图5(f)分别是SOM算法和VAE-LMC模型的分簇结果。在小型工厂场景中,金属设备反射产生时延相近但角度分散的多径,在时延-角度空间中呈长条形分布,SOM算法受限于网络结构无法处理复杂形状的多径分量,会强制分割或合并本应独立的簇,如25 ns和55 ns处。VAE-LMC模型通过潜层空间映射使具有相似特性的多径簇更加紧凑。

图6展示了小型工厂场景中B6接收点的多径传播路径,结合场景内散射体的空间分布,对图5(f)中展示的多径簇传播路径进行深入分析。首先,筛选簇中功率较强的若干分量作为主要多径成分。其次,分析主要多径成分的到达时延和到达方位角,推测信号传播距离和到达方向。之后,结合场景内散射体的物理位置,根据到达方向寻找对应的散射体,并核对信号由发射端到散射体再到接收端的距离是否与信号传播时间一致。最终,得到多径簇的传播路径和多径簇的来源。

图6中标注了8条不同线形的传播路径,各路径的标号与图5(f)中的多径簇标号一致。场景中的铣削机、场景边缘的承重柱和紧挨承重柱的金属储物柜共同构成了影响信号传播的主要散射体。

在图5(f)中,可以观察到多条关于 180° 到达角度对称的多径簇,具体来说,多径簇4和多径簇6

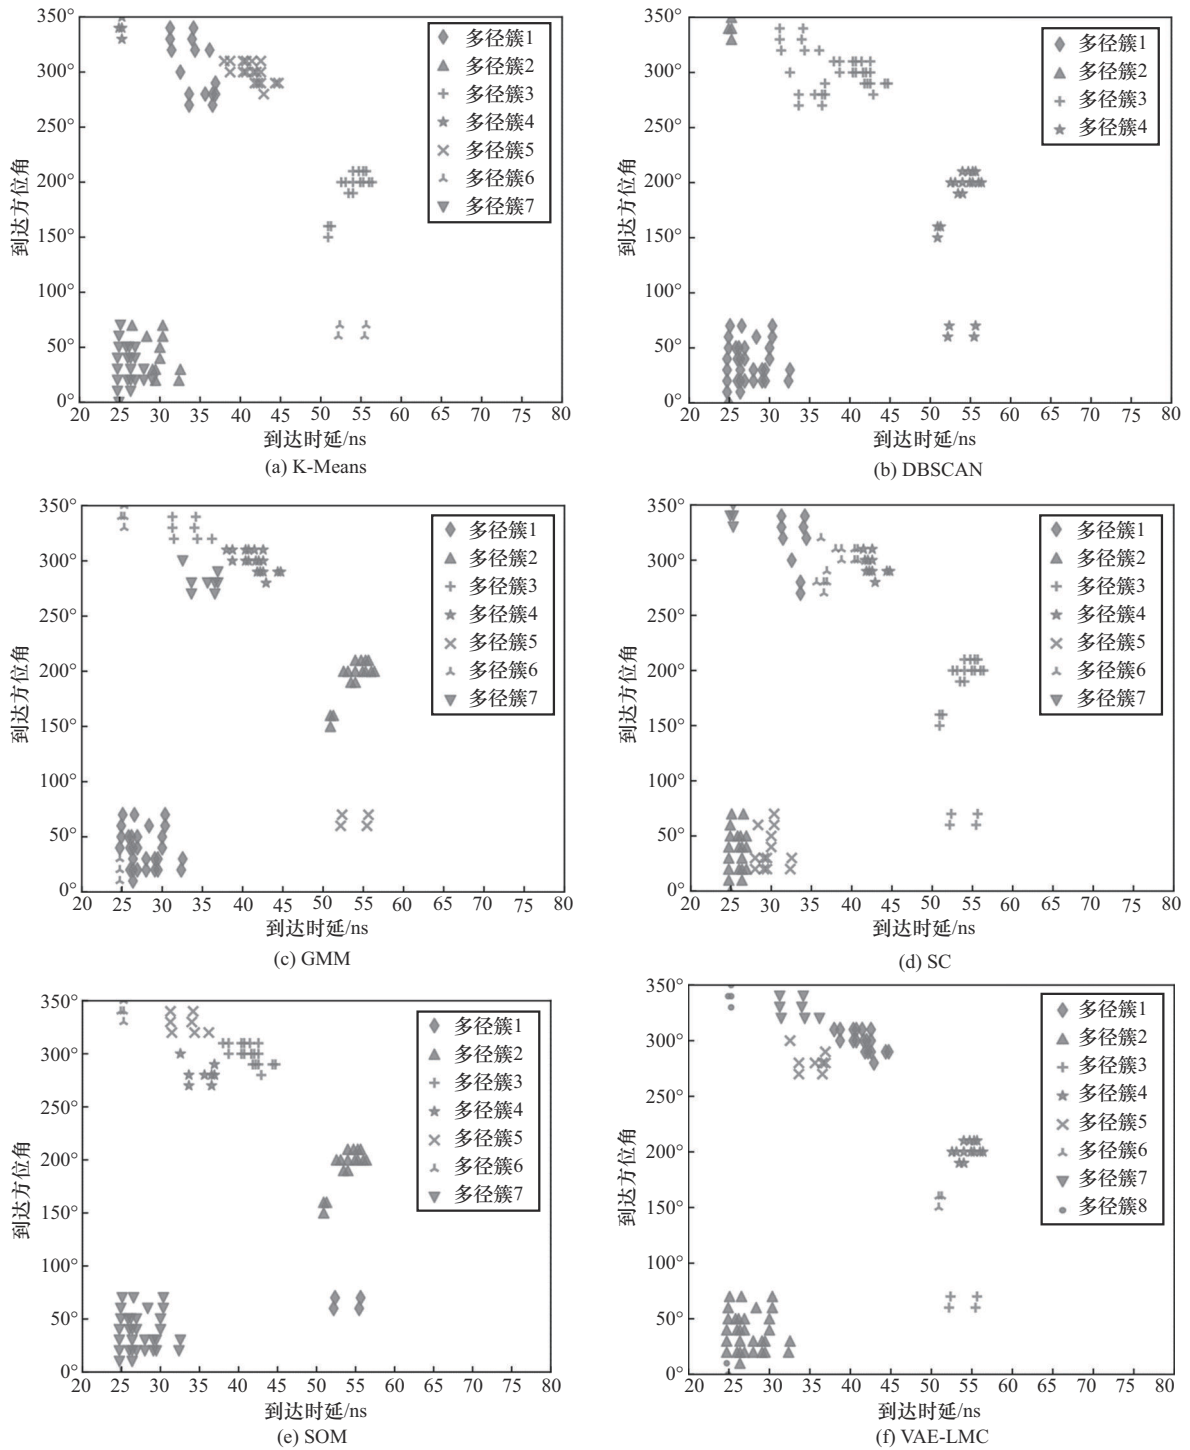


图5 小型工厂场景中B6接收点的分簇结果

是分别来自铣削机C和铣削机B的反射信号，到达角度分别位于210°和150°附近，形成明显的对称关系。多径簇2、多径簇7和多径簇5分别是来自铣削机A、铣削机E和铣削机D的一次反射，反映不同位置散射体对信号的反射效果。值得注意的是，多径簇1和多径簇3具有特殊传播特性，分别来自

西侧和东侧的承重柱以及金属储物柜的反射，2个多径簇的特点是每个多径簇包含2条传播路径：一条经由承重柱反射到达接收机，另一条经由金属储物柜反射到达接收机，2条传播路径在到达时间上有差异，但在到达角度上几乎一致，体现了亚太赫兹信号在复杂环境中传播的多样性。多径簇8是来自

Tx B 的直射路径, 其传播距离最短, 接收功率最强, 是最主要的传播路径。但该路径具有较大的角度拖尾, 在此处形成了不规则数据集, 导致这一部分多径被分为了两部分, 一部分组成了多径簇 8, 另一部分被归为了多径簇 2。




图6 小型工厂场景中B6接收点的多径传播路径

3.3 簇内特性分析

多径簇的紧密程度可以通过簇内多径在时延域和角度域的扩展进行分析。多径簇的均方根时延扩展表示为

$$\tau_{\text{mean}} = \frac{\sum_{i=1}^N \tau_i P_h(\tau_i)}{\sum_{i=1}^N P_h(\tau_i)} - \tau_{\text{min}} \quad (15)$$

$$\tau_{\text{RMS}} = \sqrt{\frac{\sum_{i=1}^N (\tau_i - \tau_{\text{mean}} - \tau_{\text{min}})^2 P_h(\tau_i)}{\sum_{i=1}^N P_h(\tau_i)}} \quad (16)$$

其中, τ_{mean} 是多径簇的平均附加时延, τ_{RMS} 是簇内均方根时延扩展, τ_i 和 $P_h(\tau_i)$ 分别是第 i 条多径的时延和功率时延谱, τ_{min} 是多径簇内的最小时延。同样, 多径簇的均方根角度扩展可以通过式(17)和式(18)计算。

$$\varphi_{\text{mean}} = \frac{\sum_{i=1}^{N_\varphi} \varphi_i P_h(\varphi_i)}{\sum_{i=1}^{N_\varphi} P_h(\varphi_i)} \quad (17)$$

$$\varphi_{\text{RMS}} = \sqrt{\frac{\sum_{i=1}^{N_\varphi} (\varphi_i - \varphi_{\text{mean}})^2 P_h(\varphi_i)}{\sum_{i=1}^{N_\varphi} P_h(\varphi_i)}} \quad (18)$$

其中, φ_{mean} 是多径簇的平均方位角, φ_{RMS} 是簇内均方根角度扩展, φ_i 和 $P_h(\varphi_i)$ 分别是第 i 条多径的方位角和功率角度谱。利用文献[31]中的角度变换方法来避免角度模糊问题, 参数通过对数正态分布拟合[6]。

表2给出了不同算法的簇内时延扩展 (CDS, cluster delay extension) 和簇内方位角扩展 (CASA, cluster azimuth spread of arrival angle) 参数, 最优结果加粗表示, 次优结果加下划线表示。VAE-LMC通过潜层空间特征分簇, 在CDS和CASA方面的均值和标准差均为最低, 验证了对多维度信道特征的解耦能力。K-Means算法受限于MCD权重分配和球形簇假设, 均值和标准差略高于VAE-LMC, 但仍优于GMM和SOM算法。DBSCAN算法的CDS和CASA显著高于其他算法, 表明密度聚类在时延扩展控制上存在局限性。

表2 不同算法的簇内时延扩展和簇内方位角扩展参数

算法	CDS/ns		CASA	
	μ	σ	μ	σ
K-Means	1.44	<u>0.87</u>	<u>11.84°</u>	<u>6.43°</u>
DBSCAN	2.20	3.27	17.99°	17.65°
GMM	1.62	1.20	14.42°	12.28°
SC	<u>1.39</u>	1.09	18.18°	14.31°
SOM	1.74	1.07	14.46°	12.78°
VAE-LMC	1.38	0.78	11.36°	6.23°

由于角度或时延密集的 MPC 出现时, DBSCAN算法容易将时延或角度相近的 MPC 错误地归为一簇, 导致DBSCAN算法的CDS和CASA增大。此外, GMM和SOM算法在CDS方面性能表现不佳, 但在CASA方面却展现出了较好的性能, 这表明2种算法更加注重MPC角度之间的区分, 忽视了时延差异。SC算法采用基于MCD的距离计算方式, 在分簇时更加关注时延之间的差别, 多径簇的紧凑程度在时延域优于角度域。综上所述, 聚类算法在处理多径分量时具有各自的特点和优势。在实际应用中, 应根据具体场景的数据特性选择合

适的算法，以达到最佳的分簇效果。

3.4 KL 散度和分簇损失消融分析

为验证 KL 散度与分簇损失函数在本文模型中的必要性及协同作用，本节设计了消融实验，通过逐步移除关键组件，评估其对多径分簇性能的影响。

消融实验分为 4 组，分别为：1) 禁用 KL 散度和分簇损失；2) 启用 KL 散度，禁用分簇损失；3) 禁用 KL 散度，启用分簇损失；4) 联合优化 KL 散度与分簇损失。实验结果如表 3 所示，最优结果加粗表示，次优结果加下划线表示。

表 3 KL 散度和分簇损失消融实验结果

实验	KL 散度	分簇损失	CDS/ns		CASA	
			μ	σ	μ	σ
1	不启用	不启用	2.03	1.34	19.32°	48.13°
2	启用	不启用	2.08	1.59	14.61°	14.05°
3	不启用	启用	<u>1.85</u>	<u>1.23</u>	<u>14.42°</u>	<u>13.28°</u>
4	启用	启用	1.38	0.78	11.36°	6.23°

实验 1 中 CDS 与 CASA 的均值和标准差均显著偏高，表明模型缺乏正则化与聚类引导，导致簇内分布松散且不稳定。实验 2 启用 KL 散度改善了模型在角度域的分簇效果，但忽略了时延域的紧凑性。实验 3 启用了分簇损失，在降低时延域扩展的同时显著地提高了角度域的分簇紧凑性。实验 4 中 CDS 和 CASA 的均值和标准差显著降低，扩展均值较实验 1 分别降低 32% 和 41.2%，表明 KL 散度与分簇损失的协同作用在多目标优化中取得平衡，二者结合可以实现最优分簇。

3.5 模型复杂度分析

时间复杂度作为衡量算法执行时间的关键指标，反映了算法运行时间随输入规模增长的变化趋势。对于多径分簇，模型的计算复杂度决定了其在

大规模数据处理中的适用性。为了实现高效且准确的多径分簇，本文模型采用了离线训练和在线分簇相结合的策略。在离线训练阶段，本文模型对一组实测数据进行多次迭代训练，逐步优化分簇性能。每次训练中，需要对输入数据进行预处理、特征提取、分簇划分以及性能评估等多个步骤，并通过反向传播算法不断更新模型参数，以最小化分簇误差。这一过程虽然计算资源消耗较大，但能够确保模型学习到稳定且有效的分簇规则。在离线训练完成后，模型能够迅速依据已学习到的分簇规则，将 MPC 分配到最合适簇中。这种策略不仅提高了分簇的效率和准确性，还使模型能够灵活应对不同规模和特性的输入数据，在实际应用中适应性更强。

VAE-LMC 模型在离线训练时每一次迭代的时间复杂度可以表示为

$$O(nm) + O(n(m + l_1 + l_2 + l_3 + l_4 + l_{\text{latent}})) + O(nl_{\text{latent}}) + O(l_1 + l_2 + l_3 + l_4) + O(nmkt) \quad (19)$$

其中， n 和 m 分别是输入数据的行数和特征维度， l_1 、 l_2 、 l_3 、 l_4 和 l_{latent} 分别是第一层、第二层、第三层、第四层和潜层空间的神经元个数， k 是目标簇数， t 是分簇算法的迭代次数。 $O(nm)$ 是数据读取、归一化预处理和损失函数计算的时间复杂度， $O(n(m + l_1 + l_2 + l_3 + l_4 + l_{\text{latent}}))$ 是模型训练过程中前向传播和反向传播的时间复杂度， $O(nl_{\text{latent}})$ 是求解 KL 散度和进行重参数化的时间复杂度， $O(l_1 + l_2 + l_3 + l_4)$ 是模型参数更新的时间复杂度， $O(nmkt)$ 是模型中嵌入 K-Means 聚类的时间复杂度，总体时间复杂度可以进一步化简为

$$O(n(m + l_1 + l_2 + l_3 + l_4 + l_{\text{latent}})) + O(nmkt) \quad (20)$$

线上分簇阶段不需要进行反向传播和参数更新，其时间复杂度比每一次迭代的时间复杂度小，但属于同一量级，也可以由式(20)表示。表 4 对比了不同分簇算法的时间复杂度。

表 4 不同分簇算法的时间复杂度

分簇算法	数据读取和处理	分簇过程	总时间复杂度
K-Means	$O(nm)$	$O(n^2mkt)$	$O(n^2mkt)$
DBSCAN	$O(nm)$	$O(n^2m)$	$O(n^2m)$
GMM	$O(nm)$	$O(nm^2kt)$	$O(n(m^2kt + m))$
SC	$O(nm)$	$O(n^3 + n^2 + nmkt)$	$O(n^3 + n^2 + nmkt)$
SOM	$O(nm)$	$O(nmt)$	$O(nmt)$
VAE-LMC	$O(n(m + l_1 + l_2 + l_3 + l_4 + l_{\text{latent}}))$	$O(nmkt)$	$O(n(m + l_1 + l_2 + l_3 + l_4 + l_{\text{latent}} + mkt))$

使用MCD作为距离度量标准会额外引入 $O(n^2)$ 时间复杂度,这在多径分簇中是不可避免的。对于K-Means、DBSCAN、SC等依赖于MCD的算法,时间复杂度至少为 $O(n^2)$,无法适应未来的多天线通信场景。GMM算法依赖于数据量,对特征维度具有平方依赖,一般情况下特征维度远小于数据量,故GMM算法的时间复杂度较小且可控。SC算法需要进行复杂的矩阵运算,增加了计算量。SOM算法中节点数量一般远小于输入数据的数量,通过计算输入网络节点的距离,而不是输入之间的距离,减小了时间复杂度。VAE-LMC算法通过数据在潜层空间的映射和变换来避免复杂的距离求解。在数据被映射到子空间并完成变换后,直接利用变换后的数据进行聚类,而不需要进行复杂的距离计算,不仅降低了时间复杂度,还提高了分簇准确性和稳定性。信道数据量 n 对GMM、SOM和VAE-LMC算法时间复杂度的影响属于同一量级,当信道数据量 n 较大时,可以近似认为三者具有相近的时间复杂度。

4 结束语

本文研究了太赫兹信道建模中基于变分自编码器的多径分簇算法,通过改进传统K-Means分簇算法,利用变分自编码器的特征学习能力构建分簇潜层空间,并采用联合损失函数迭代优化分簇性能,解决了无监督学习中的特征分离难题。在小型工厂场景中进行了信道测量获取信道数据,并进行分簇和分析。实验结果表明,与K-Means、DBSCAN等算法相比本文算法多径分簇结果更加合理,在簇内和簇间特性、环境一致性以及计算复杂度方面表现出色,能够更好地反映信道的物理特性和多径传播特性。变分自编码器和分簇的结合为复杂场景下的多径信号处理提供了新思路。未来的研究将进一步优化算法参数,并拓展其在无线通信和信号处理领域的应用。

参考文献:

- [1] BIAN J, WANG C X, GAO X Q, et al. A general 3D non-stationary wireless channel model for 5G and beyond[J]. IEEE Transactions on Wireless Communications, 2021, 20(5): 3211-3224.
- [2] HE R S, AI B, STÜBER G L, et al. Geometrical-based modeling for millimeter-wave MIMO mobile-to-mobile channels[J]. IEEE Transactions on Vehicular Technology, 2018, 67(4): 2848-2863.
- [3] ZHANG J H, TANG P, YU L, et al. Channel measurements and models for 6G: current status and future outlook[J]. Frontiers of Information Technology & Electronic Engineering, 2020, 21(1): 39-61.
- [4] WANG C, ZHANG J H, TUFVESSON F. Random cluster number feature and cluster characteristics of indoor measurement at 28 GHz[J]. IEEE Antennas and Wireless Propagation Letters, 2018, 17(10): 1881-1884.
- [5] HE R S, AI B, MOLISCH A F, et al. Clustering enabled wireless channel modeling using big data algorithms[J]. IEEE Communications Magazine, 2018, 56(5): 177-183.
- [6] CHEN Y, LI Y B, HAN C, et al. Channel measurement and ray-tracing-statistical hybrid modeling for low-terahertz indoor communications[J]. IEEE Transactions on Wireless Communications, 2021, 20(12): 8163-8176.
- [7] HU M T, YE Y X, HE R S, et al. A novel power weighted multipath component clustering algorithm based on spectral clustering[C]//Proceedings of the 2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring). Piscataway: IEEE Press, 2020: 1-5.
- [8] CZINK N, CERA P, SALO J, et al. A framework for automatic clustering of parametric MIMO channel data including path powers[C]//Proceedings of the IEEE Vehicular Technology Conference. Piscataway: IEEE Press, 2006: 1-5.
- [9] LEE J. Cluster-based millimeter-wave outdoor-to-indoor propagation characteristics based on 32 GHz measurement analysis[J]. IEEE Antennas and Wireless Propagation Letters, 2021, 20(1): 73-77.
- [10] SUZUKI N, TSUKADA H, TAKAHASHI R, et al. Characterization of spatial consistency of cluster channels in urban environments at 24 and 60 GHz[J]. IEEE Antennas and Wireless Propagation Letters, 2024, 23(5): 1583-1587.
- [11] CALIST I, KIM M. Multipath cluster-based scatterer recognition by object detection techniques using panoramic images[C]//Proceedings of the 2023 International Technical Conference on Circuits/Systems, Computers, and Communications (ITC-CSCC). Piscataway: IEEE Press, 2023: 1-6.
- [12] HE R S, LI Q Y, AI B, et al. A kernel-power-density-based algorithm for channel multipath components clustering[J]. IEEE Transactions on Wireless Communications, 2017, 16(11): 7138-7151.
- [13] XIE J Y, GIRSHICK R, FARHADI A. Unsupervised deep embedding for clustering analysis[C]//Proceedings of the 33rd International Conference on Machine Learning. New York: PMLR, 2016: 478-487.
- [14] CARON M, BOJANOWSKI P, JOULIN A, et al. Deep clustering for unsupervised learning of visual features[C]//Proceedings of the European Conference on Computer Vision (ECCV). Piscataway: IEEE Press, 2018: 132-149.
- [15] PENG X, FENG J S, ZHOU J T, et al. Deep subspace clustering[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(12): 5509-5521.
- [16] ZHANG T, JI P, HARANDI M, et al. Neural collaborative subspace clustering[C]//Proceedings of the 36th International Conference on Machine Learning. New York: PMLR, 2019: 7384-7393.
- [17] ZHANG J J, LI C G, YOU C, et al. Self-supervised convolutional subspace clustering network[C]//Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2019: 5468-5477.
- [18] OPOCHINSKY Y, CHAZAN S E, GANNOT S, et al. K-autoencoders deep clustering[C]//Proceedings of the ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway: IEEE Press, 2020: 4037-4041.
- [19] PARK S, HAN S, KIM S, et al. Improving unsupervised image clustering with robust learning[C]//Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2021: 12273-12282.

- [20] YANG J W, PARIKH D, BATRA D. Joint unsupervised learning of deep representations and image clusters[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2016: 5147-5156.
- [21] YU L J, ZHAO X W, DU F, et al. Multipath component clustering based on improved self-organizing feature map for 5G millimeter wave radio channels[C]//Proceedings of the 2021 13th International Symposium on Antennas, Propagation and EM Theory (ISAPE). Piscataway: IEEE Press, 2021: 1-3.
- [22] WHITON R, CHEN J S, TUFVESSON F. Flexible density-based multipath component clustering utilizing ground truth pose[C]//Proceedings of the 2023 IEEE 98th Vehicular Technology Conference (VTC2023-Fall). Piscataway: IEEE Press, 2023: 1-6.
- [23] STEINBAUER M, OZCELIK H, HOFSTETTER H, et al. How to quantify multipath separation[J]. IEICE Transactions on Electronics, 2002, 85(3): 552-557.
- [24] CZINK N, CERA P, SALO J, et al. Improving clustering performance using multipath component distance[J]. Electronics Letters, 2006, 42(1): 33-35.
- [25] LIU Y M, ZHANG J H, ZHANG Y X, et al. A shared cluster-based stochastic channel model for integrated sensing and communication systems[J]. IEEE Transactions on Vehicular Technology, 2024, 73(5): 6032-6044.
- [26] LI Y P, ZHANG J H, MA Z Y, et al. Clustering analysis in the wireless propagation channel with a variational Gaussian mixture model[J]. IEEE Transactions on Big Data, 2020, 6(2): 223-232.
- [27] LUO J, LIAO X, WANG Y, et al. An entropy-based adaptive DBSCAN clustering algorithm and its application in THz wireless channels[J]. IEEE Transactions on Antennas and Propagation, 2023, 71(12): 9830-9837.
- [28] SUN G Q, HUANG C, CHENG Z H, et al. A study of clustering algorithms for time-varying multipath components in wireless channels[C]//Proceedings of the MILCOM 2021-2021 IEEE Military Communications Conference (MILCOM). Piscataway: IEEE Press, 2021: 414-419.
- [29] WANG H, PAN S G, GAO W, et al. Multipath/NLOS detection based on K-means clustering for GNSS/INS tightly coupled system in urban areas[J]. Micromachines, 2022, 13(7): 1128.
- [30] LI Y B, WANG Y Q, CHEN Y, et al. Channel measurement and analysis in an indoor corridor scenario at 300 GHz[C]//Proceedings of the ICC 2022-IEEE International Conference on Communications. Piscataway: IEEE Press, 2022: 2888-2893.
- [31] DONG W H, ZHANG J H, GAO X Y, et al. Cluster identification and properties of outdoor wideband MIMO channel[C]//Proceedings of the 2007 IEEE 66th Vehicular Technology Conference. Piscataway: IEEE Press, 2007: 829-833.

[作者简介]



郝昕宇 (1996-), 男, 山东淄博人, 重庆邮电大学博士生, 主要研究方向为毫米波太赫兹信道测量与建模、信道预测、机器学习等。



廖希 (1988-), 女, 四川绵阳人, 博士, 重庆邮电大学教授、博士生导师, 主要研究方向为 6G 毫米波太赫兹通信感知、6G 涡旋电磁波通信、散射反射通信等。



郑相全 (1972-), 男, 四川内江人, 博士, 中国人民解放军 32002 部队高级工程师, 主要研究方向为无线通信。



王洋 (1986-), 男, 重庆人, 博士, 重庆邮电大学教授、博士生导师, 主要研究方向为第六代移动通信技术、毫米波太赫兹信道测量与建模、涡旋电磁波、智能反射面等。



林峰 (1978-), 男, 山东烟台人, 重庆邮电大学高级工程师、硕士生导师, 主要研究方向为 5G-V2X 车联网与车路协同控制等。



陈前斌 (1967-), 男, 四川营山人, 博士, 重庆邮电大学教授、博士生导师, 主要研究方向为通信网理论与技术、无线通信、多媒体信息传输与处理等。



张杰 (1965-), 男, 山东临沂人, 博士, 重庆邮电大学特聘教授、博士生导师, 主要研究方向为室内-室外无线网络规划与优化、无线传播、小蜂窝和异构网络、自组织网络、智能建筑/电网、毫米波通信等。