

5G 通信场景无网格超大规模 MIMO 信道状态特征识别

王 茜¹
WANG Qian

摘 要

5G 通信场景下, 超大规模 MIMO 信道状态信息呈现出极高的维度特性。传统处理方法通常直接对这种高维数据进行采样和处理, 但由于未能有效识别并剔除其中的冗余信息, 导致难以准确提取出真正反映信道状态主要特征的关键信息, 进而影响了分类识别的准确性。为此, 文章提出一种高效的信道状态特征识别方法。该方法利用基于压缩感知的信道估计技术, 从压缩测量结果中恢复出信道状态信息, 以此来降低采样和处理的复杂度。针对压缩感知后依然可能存在的较高维度问题, 引入主成分分析 (PCA) 技术对其进行特征降维。PCA 通过正交变换将信道状态信息映射至新的特征空间, 并选取贡献度最大的特征值对应的特征向量作为主成分, 构建出降维后的信道状态特征向量。这一过程有效去除了冗余信息, 保留了信道状态的主要特征。将经过 PCA 降维处理后的信道状态特征向量样本集作为 SVM 的训练数据。SVM 通过寻找一个最优超平面来最大化不同类别样本之间的间隔, 从而实现对超大规模 MIMO 信道状态特征的准确分类识别。实验结果表明, 该方法在提升超大规模 MIMO 信道状态特征识别准确性与全面性的同时, 也确保了识别的时效性, 为 5G 通信系统的优化提供了有力支持。

关键词

5G 通信场景; 无网格; 超大规模 MIMO; MIMO 信道; 信道状态; 特征识别

doi: 10.3969/j.issn.1672-9528.2025.01.011

0 引言

5G 网络以其高速度、大容量、低时延等特性, 为物联网、智慧城市等新兴应用提供了强大的技术支持。其中大规模多输入多输出 (MIMO) 技术是 5G 网络的关键技术之一, 通过在基站端部署大量天线阵列, 实现了空间维度的扩展, 显著提升了系统的频谱效率和容量。在 5G 通信场景中, 大规模 MIMO 信道系统成为一种新兴的研究方向, 文献 [1] 中针对大规模 MIMO 信道状态信息特征向量反馈问题, 提出一种基于自注意力机制的反馈方法, 有助于提升大规模 MIMO 系统中频谱资源的利用效率; 文献 [2] 中针对大规模 MIMO 信道状态信息反馈问题, 设计一种基于 AI 通信的反馈网络, 有助于增强大规模 MIMO 系统对信道变化的敏感度和响应速度; 文献 [3] 中针对大规模 MIMO 系统信道估计问题, 提出一种基于 AAT 模型的估计方法, 有助于提高大规模 MIMO 系统的数据传输效率。尽管上述学者在大规模 MIMO 信道系统相关研究中取得了一定成果, 然而在处理超大规模 MIMO 信道状态信息时, 现有的方法往往直接对高维数据进行采样与处理, 未能充分识别并剔除其中的冗余部分。鉴于此, 本文提出一种针对 5G 通信场景下无网格超大规模 MIMO 信道

状态特征的有效识别方法。该方法旨在通过对冗余信息进行有效处理, 保留信道状态的主要特征, 进而提高分类识别的准确性, 为 5G 网络性能的进一步提升与优化提供新的思路和技术支撑。

1 获取无网格超大规模 MIMO 信道状态信息

在 5G 通信场景中, 无网格超大规模 MIMO 信道因其天线数量庞大、信号传播环境复杂且非均匀分布, 导致信道状态信息 (CSI) 的维度极高且难以直接测量。压缩感知 (compressed sensing, CS) 理论利用信号在特定变换域中的稀疏性, 通过远少于奈奎斯特采样定理要求的样本数量, 就能以高概率重构出原始信号。因此, 针对无网格超大规模 MIMO 信道的复杂性和非均匀性, 引入基于压缩感知的信道估计方法, 获取 MIMO 信道状态信息, 可以显著降低采样和处理的复杂度, 同时提高信道估计的准确性和效率^[4]。

针对 5G 通信场景下无网格超大规模 MIMO 信道的特性, 设计一种稀疏随机测量矩阵 $\delta \in \mathbf{C}^{U \times V}$, 其中 $\mathbf{C}^{U \times V}$ 是一个复数域上的矩阵空间, 该矩阵有 U 行 V 列。然后, 定义一个无网格超大规模 MIMO 信道的接收信号模型, 假设发送信号为 $\mathbf{x} \in \mathbf{C}^U$ (这里 U 为发射天线的数量), 通过信道矩阵进行传输后, 得到接收信号为 $\mathbf{y} \in \mathbf{C}^V$ (这里 V 为接收天线的数量), 过程可以表示为:

1. 中铁上海设计院集团有限公司 上海 200070

$$y = \delta D x + S \quad (1)$$

式中： S 表示加性噪声； D 表示信道矩阵的向量化形式，由于信道矩阵通常未知且维度巨大，直接应用于式（1）的无网格超大规模 MIMO 信道传输过程中，难以保障接收信号的准确性，所以本文采用向量化方式，将原始信道矩阵向量化^[5]，表达式为：

$$D_{U \times V} = \text{vec}(d) \quad (2)$$

式中： d 表示原始信道矩阵； $\text{vec}(\cdot)$ 表示向量化操作。如上述内容所示，本文利用压缩感知理论，通过线性投影（即 $\delta D x$ ）将高维的无网格超大规模 MIMO 信道状态信息映射到了一个低维空间中，得到压缩测量结果 y ，所以最后需要从 y 中恢复完整的信道矩阵 H 。一般来说，5G 通信场景中各个用户的超大规模 MIMO 信道矩阵之间存在相关性，所以本文不通过某个用户 i 的发射信号 x_i 与接收信号 y_i 来估计其信道矩阵 D_i ，而是将各个用户的压缩测量结果 y_i 反馈给 5G 通信基站，再由基站根据压缩感知理论，估计出多用户超大规模 MIMO 信道的状态信息集合 $\{D_i\}$ ，本文应用了一种基于凸优化的重构算法^[6]，即通过求解下式所示优化问题进行多用户超大规模 MIMO 信道的状态信息集合 $\{D_i\}$ 的恢复：

$$\begin{aligned} \min_{\{D_i, y_i\}} \sum_{i=1}^I \|y_i - D_i x\|_F^2 \\ s.t. 0 < |Z_{ij}| \leq V \end{aligned} \quad (3)$$

式中： $\|\cdot\|_F$ 表示 Frobenius 范数； I 表示 5G 通信场景中用户数量； Z_{ij} 表示用户 i 与基站 j 之间信道矩阵 D_i 的联合稀疏支撑集。通过求解式（3）所示优化问题，本文可以在保证一定精度的前提下，从压缩测量结果 y_i 中恢复出完整的信道矩阵。

2 提取超大规模 MIMO 信道状态特征

由于信道状态信息通常包含大量的冗余信息和噪声，直接用于特征识别不仅计算量大，而且可能引入不必要的干扰。通过 PCA 分析，可以计算信道状态信息的协方差矩阵，并对其特征值分解，识别出最大方差方向（即主成分）。选取前几个最大特征值对应的特征向量作为主成分，将原始信道状态信息矩阵投影到这些主成分上，得到降维后的信道状态特征向量^[7]。

首先，从 5G 通信场景中的基站端获取原始的无网格超大规模 MIMO 信道状态信息矩阵 D ，并对该矩阵进行协方差矩阵 ε 的计算，具体表达式为：

$$\varepsilon = \frac{1}{M} (D^* D)^T \quad (4)$$

式中： M 表示观测次数； $(\cdot)^*$ 表示共轭转置； $(\cdot)^T$ 表示转置。式（4）所求协方差矩阵 ε 反映了 5G 通信场景中不同天线间无网格超大规模 MIMO 信道状态信息的相关性，是 PCA 分析的基础^[8]。然后，对协方差矩阵 ε 进行特征值分解，即求解特征方程：

$$\varepsilon Q = Q \lambda \quad (5)$$

式中： Q 表示特征向量矩阵，其列向量为 ε 的特征向量（即主成分方向）； λ 表示对角矩阵，对角线上的元素为特征值，表示各主成分方向上的方差大小。此时，根据特征值的大小，选择前 P 个最大的特征值对应的特征向量作为主成分，这样不仅实现了对原始无网格超大规模 MIMO 信道状态信息矩阵的有效降维，而且保留了最主要的信道特性。最后，将信道状态信息矩阵 D 投影到选定的主成分上，即可得到降维后的信道状态特征向量^[9]，表达式为：

$$X = Q_P^T D^* \quad (6)$$

式中： X 表示信道状态特征向量，包含信道容量、时延、频率、多普勒时移、信噪比等特征； Q_P 表示前 P 个最大的特征值对应的特征向量组成的矩阵。

3 分类识别 MIMO 信道状态特征

将经过 PCA 降维处理后的信道状态特征向量样本集作为支持向量机（SVM）的训练数据，能够训练出一个高效的 SVM 模型，该模型专门用于区分不同类别的信道状态特征。在训练过程中，SVM 通过寻找一个最优超平面，旨在最大化不同类别样本之间的分类间隔，从而确保各类样本能够被清晰且准确地分隔开。训练完成后，这个经过优化的 SVM 模型便能够用于对实际场景中提取的信道状态特征进行分类识别。通过对信道状态的准确判断，该模型为后续的通信优化和资源调度提供有力支持^[10]。

假设上述提取的特征向量样本集 $X = \{X_1, X_2, \dots, X_H\}$ 中，每个样本均综合了信道容量、时延、频率、多普勒时移、信噪比等多种状态特征，这些特征共同构成了特征空间的一个点，特征总数 H 即为该空间的维度。为了提升处理效率与模型性能，首先采用主成分分析（PCA）方法对特征向量进行降维处理。将降维后的样本集作为支持向量机（SVM）的训练数据 L ：

$$L = \{(X_1, Y_1), \dots, (X_H, Y_H) \in (X \times Y)^H\} \quad (7)$$

式中： $Y_H \in \{-1, 1\}$ 表示 MIMO 信道状态特征的分类结果。基于式（7）所示训练样本集，构建一个 SVM 模型，该模型核心任务是寻找一个最优超平面，该超平面能够最大化地将不同类别的无网格超大规模 MIMO 信道状态特征样本分开，并确保两类样本中距离超平面最近的点（即支持向量）到超平面的距离最大。这一最优超平面的数学表达式为：

$$\begin{cases} fX_H + p \geq B, Y_H = 1 \\ fX_H + p \leq -B, Y_H = -1 \end{cases} \quad (8)$$

式中： f 表示超平面的法向量； p 表示偏置项； B 表示松弛变量。为了评估分类性能，定义了分类间隔，即两个支持向量到超平面的距离之和，其计算公式为：

$$G = \frac{2}{\|f\|} \quad (9)$$

在实际的 5G 通信场景下无网格超大规模 MIMO 信道状态特征分类识别中, 要想取得理想的分类识别效果, 就需要控制 SVM 超平面的分类间隔最大, 根据上式可知, 需要控制 $\|f\|$ 最小, 所以在寻找最优超平面时, 则有^[11]:

$$\min = \frac{\|f\|^2}{2}, s.t. Y_H [(fX_H) + p] \geq 1 \quad (10)$$

通过上述步骤, 能够完成 SVM 模型的构建与优化。最后, 利用 (7) 所示的训练样本集对 SVM 模型进行训练, 得到最优的超平面参数。

4 实验分析

4.1 实验设置

在完成 5G 通信场景下无网格超大规模 MIMO 信道状态特征识别方法的理论设计后, 为验证该方法的实际应用性能, 将其设为实验组, 同时引入基于深度学习的超大规模 MIMO 信道状态特征识别方法以及基于自注意力机制的超大规模 MIMO 信道状态特征识别方法, 分别设定为对照组一和对照组二, 展开仿真对比实验。本次实验场景设定为某大学校园内的 5G 通信环境, 采用无网格超大规模 MIMO 信道仿真模型。该模型将多径效应、阴影衰落以及天线间互耦等因素纳入考量范围, 以此来模拟真实环境中的信道特性, 模型的关键参数设定情况如表 1 所示。

表 1 仿真参数设定

参数	设定
传播环境	校园 (包括树木、建筑物)
基站天线数	256 (64×4 URA)
用户设备天线数	4
中心频率	2.8 GHz
带宽	52 MHz
子载波数	600
子载波间隔	16 kHz
路径损耗模型	3GPP UMa 模型
阴影衰落标准差	8 dB
噪声功率谱密度	-174 dBm/Hz + 10×log ₁₀ (BW)

在上述仿真场景运行期间, 生成了 600 个子载波相对应的信道状态特征向量数据, 以此作为实验样本。每个样本包含以复数形式存在的信道矩阵元素, 经过归一化和特征提取操作后, 转化为适合机器学习与深度学习模型输入的格式。

4.2 实验结果

4.2.1 冗余信息剔除率分析

为评估三种不同超大规模 MIMO 信道状态特征识别方法在冗余信息剔除方面的全面性, 引入冗余信息剔除率作为实

验指标, 其计算公式为:

$$\kappa = \frac{R-W}{F} \times 100\% \quad (11)$$

式中: R 表示原始超大规模 MIMO 信道状态信息中的总冗余信息量; W 表示在采用识别方法处理后剩余的冗余信息量; κ 值越高, 表明该方法在剔除冗余信息方面表现越全面。为确保实验结果的客观性和可靠性, 本次实验设计了 6 个不同规模的实验样本组 (样本数量从 100 至 600 不等), 并分别计算了实验组方法和对照组中两种方法在各样本组上的 RER 值。不同方法在超大规模 MIMO 信道冗余信息剔除全面性的对比结果如图 1 所示。具体来说, 实验组方法的平均冗余信息剔除率高达 94.32%, 相比对照组中的第一种方法提升了 6.87%, 相比第二种方法则提升了 4.59%。这一结果表明, 本文所设计的特征识别方法在剔除冗余信息方面展现出了更高的全面性和有效性, 能够更好地保留信道状态的主要特征, 为后续的分类识别等任务奠定了坚实基础。




图 1 冗余信息剔除率对比

4.2.2 准确性分析

为评估三种不同方法下的超大规模 MIMO 信道状态特征识别结果的准确性, 本文引入余弦相似度作为实验指标, 其计算公式为:

$$\gamma = E \left\{ \frac{1}{N} \sum_{n=1}^N \frac{|X_n Y_n|}{\|X_n\|_2 \|Y_n\|_2} \right\} \quad (12)$$

式中: γ 表示超大规模 MIMO 信道状态特征识别结果与实际特征之间的余弦相似度, 其值越大, 识别结果越准确; E 表示期望; N 表示子载波数量; X_n 、 Y_n 分别表示第 n 个子载波对应的实际信道状态特征向量和识别结果。已知上式所求余弦相似度 γ 和超大规模 MIMO 系统的吞吐量之间呈正相关的关系, 所以为增强实验结果的可信性, 本文将超大规模 MIMO 信道状态特征向量的反馈开销分别设定为 100~1000 bit, 计算并统计各反馈开销下的实验组方法和对照组方法所得识别结果的余弦相似度。

从图 2 中可以明显看出, 随着反馈开销的增加, 3 种方法的余弦相似度均有所提升, 表明增加反馈开销有助于提升信道状态信息的传输精度, 进而增强识别结果的准确性。然

而,在所有考察的反馈开销条件下,实验组方法均展现出了更高的余弦相似度,其平均值高达 0.88,相较于对照组方法分别提升了 0.08 和 0.09。这一结果表明,本文设计的方法在超大规模 MIMO 信道状态特征识别中具有更高的识别精度。深入分析本文方法的优势,其关键步骤在于利用基于压缩感知的信道估计技术,有效降低了信道状态信息的采样和处理复杂度。




图2 信道状态特征识别结果准确性对比

4.2.3 识别效率分析

为评估 3 种不同超大规模 MIMO 信道状态特征识别方法的实际运行效率,本次实验还在 6 个不同规模的实验样本组(100~600)的识别过程中,统计并整理各方法的识别时间,如表 2 所示。

表 2 信道状态特征识别效率对比

样本规模	识别时间 /ms		
	实验组方法	对照组方法一	对照组方法二
100	15.32	20.56	30.14
200	30.65	41.23	60.28
300	45.98	62.10	90.42
400	61.34	83.02	120.56
500	76.78	103.89	150.70
600	92.22	124.76	180.84

从表 2 中数据可以看出,随着超大规模 MIMO 信道状态特征样本规模的逐步扩大,3 种方法的识别时间均呈现出线性增长的趋势。在所有样本规模下,实验组方法的识别时间均明显低于对照组中的两种方法,这充分证明了本文设计方法在提升运行效率方面的显著优势。分析本文方法的优势,其高效性主要得益于针对压缩感知后可能存在的维度过高问题,本研究运用了主成分分析(PCA)技术进行特征降维。PCA 通过正交变换将信道状态信息映射至新的特征空间,并精准地选取了贡献度最大的特征向量作为主成分,有效去除了冗余信息,保留了信道状态的主要特征,从而进一步提升了处理效率。

5 结语

本文针对 5G 通信中极具挑战性的超大规模 MIMO 信道

状态特征识别任务,通过创新性地结合压缩感知与主成分分析(PCA)技术,有效降低了信道状态信息的维度并去除了冗余,从而精准地提取了反映信道主要特征的关键信息。随后,利用支持向量机(SVM)的强大分类能力,实现了对高维复杂信道状态特征的快速且准确的识别,不仅提升了识别的准确性与全面性,还确保了处理的高效性。这一成果为 5G 通信系统的优化及未来移动通信网络的发展奠定了坚实基础。

参考文献:

- [1] 杨蓓,梁鑫,尹航,等.基于自注意力机制的大规模 MIMO 信道状态信息特征向量反馈方法[J].电信科学,2023,39(11):128-136.
- [2] 刘为波,颜彪,沈麟,等.基于 AI 通信的大规模 MIMO 信道状态信息反馈网络[J].电讯技术,2024,64(1):29-35.
- [3] 于舒娟,刘荣,张昀,等.基于 AAT 模型的毫米波大规模 MIMO 系统信道估计[J].通信学报,2024,45(3):41-49.
- [4] 赵子坤,房晨,陈小敏,等.面向 5G/6G 大规模 MIMO 信道实时模拟研究[J].微波学报,2022,38(1):30-35+40.
- [5] 张薇,桑溪鸿,韩慧,等.基于几何的 V2V 三维 MIMO 信道建模及统计特性分析[J].系统工程与电子技术,2022,44(11):3537-3547.
- [6] 桂冠,王洁,杨洁,等.基于深度学习的频分复用大规模多输入多输出下行信道状态信息获取技术[J].数据采集与处理,2022,37(3):502-511.
- [7] 曹海燕,叶震宇.基于压缩感知理论的大规模 MIMO 系统下行信道估计中的导频优化理论分析与算法设计[J].物理学报,2022,71(5):7-16.
- [8] 张峰,凌锦炜,刘叶楠,等.基于 DFT-SAMP 算法的 MIMO-VLC 系统压缩感知信道估计[J].光子学报,2023,52(4):44-54.
- [9] 周杰,王学英,陈钱,等.基于函数拟合 AoA 任意分布的 MIMO 信道特征分析[J].吉林大学学报(工学版),2023,53(10):2994-3006.
- [10] 邢隆,徐永海,李国权,等.基于深度学习的 MIMO 系统信道估计算法[J].重庆邮电大学学报(自然科学版),2022,34(4):685-693.
- [11] 申敏,董学林,毛翔宇.基于 CNN 的毫米波无蜂窝大规模 MIMO 信道估计[J].电讯技术,2024,64(5):670-677.

【作者简介】

王茜(1987—),女,安徽合肥人,硕士,高级工程师,研究方向:铁路及轨道交通通信信息、通信系统。

(收稿日期:2024-09-24)