

低轨卫星多波束组播预编码及用户分组联合优化算法

郭李莉 冯艺萌* 袁沛鸿 高跃

(复旦大学空间互联网研究院 上海 200438)

摘要: 针对多波束低轨卫星(LEO)通信系统中全频率复用引发的波束间干扰,以及现有组播预编码算法计算复杂度高、用户分组公平性不足的挑战,该文提出了一种高效的联合优化方案。首先,设计了一种基于卷积神经网络-长短期记忆网络(CNN-LSTM)混合架构的无监督深度学习预编码模型。该模型能够从信道状态信息(CSI)和信噪比(SNR)中有效提取特征,在满足单天线功率约束(PAC)的前提下最大化系统总速率,其在线计算复杂度仅随天线数量线性增长,显著低于传统方法的立方级复杂度。其次,针对DVB-S2X标准下基于帧的组播预编码对等容量用户分组的硬性要求,该文提出了约束K-means(CK-means)和公平感知MAUG(FA-MAUG)用户分组算法。前者可在保证每组用户数量严格一致的同时维持较高的组内信道相似度;后者通过优先保障边缘弱用户分组质量,有效提升了系统公平性和整体鲁棒性。仿真结果表明,所提深度学习预编码方案在总速率性能上显著优于传统MMSE算法,在不同SNR下平均提升约48%;同时,改进的用户分组算法进一步增强了组内信道一致性并显著提高了系统吞吐量。研究结果展现了所提算法良好的实用价值和工程适用性,为多波束低轨卫星通信系统的资源优化提供了有效技术途径。

关键词: 低轨卫星通信; 组播预编码; 无监督学习; 用户分组; 单天线功率约束

中图分类号: TN927

文献标识码: A

文章编号: 1009-5896(2026)00-0001-11

DOI: 10.11999/JEIT260375

CSTR: 32379.14.JEIT260375

1 引言

随着6G通信技术的快速发展,低轨(Low Earth Orbit, LEO)卫星已成为实现全球无缝覆盖以及高速率、低时延服务的重要技术之一^[1]。全频率复用技术^[2]显著提升了高吞吐量卫星系统的频谱效率,但同时也引发了严重的波束间干扰。预编码技术利用天线空间自由度在发射端联合处理多波束信号,可有效预先消除干扰,使系统吞吐量至少达到传统非预编码系统的两倍以上^[3],其中组播预编码(Multicast Precoding)技术通过对接收用户进行分组,并在组内实现数据复用,有效解决了单播方式的资源浪费和广播方式的安全隐患,已成为现代卫星通信业务的核心方案。在用于星地下行链路的DVB-S2X标准^[4]中,采用捆绑式物理层帧(PLFRAME)的超帧结构^[5]允许同一波束内的多个用户终端在同一物理层帧中进行数据复用,这使其特别适合于组播服务,因此组播预编码也被称为基于帧的预编码(Frame-based Precoding)。

现有组播预编码研究主要围绕两类核心优化问题展开:一是在满足所有用户信干噪比(Signal to

Interference plus Noise Ratio, SINR)门限的前提下最小化总发射功率,即服务质量(Quality of Service, QoS)问题;二是在总功率约束下最大化所有用户(加权)最小SINR,即最大-最小公平(Max-Min Fairness, MMF)问题。这两类问题均为非凸优化问题,且已被证明属于NP-hard难题^[6]。针对上述问题,最小均方误差^[7](Minimum Mean Square Error, MMSE)、正则化迫零^[8](Regularized Zero Forcing, RZF)等传统线性预编码方案因实现简单、复杂度较低,被广泛应用于多用户MIMO系统。为进一步提高预编码增益,研究者提出了半正定松弛(Semidefinite Relaxation, SDR)、连续凸逼近(Successive Convex Approximation, SCA)等经典优化方法^[6,9,11-12],但存在复杂度高、初始解依赖等问题。文献^[13]进一步结合SCA与拉格朗日对偶理论,将优化变量维度由天线数降低至用户组规模,有效降低了计算复杂度。近年来,深度学习逐渐成为解决预编码问题的重要方向。文献^[14,17]分别针对Massive MIMO及毫米波混合预编码场景,利用深度学习实现预编码矩阵逼近,在降低在线计算复杂度的同时获得接近传统优化算法的性能。文献^[18]将传统交替优化过程与深度网络结合,通过神经网络优化模拟预编码,并利用解析方法求解数字预编码,兼顾复杂度与性能,相比纯数据驱动方案具有更好的结构可解释性与迁移能力。文献^[19]提出联合信道预测与多波束预编码框架,

收稿日期: 2026-03-31; 改回日期: 2026-07-14; 网络出版: 2026-07-25

*通信作者: 冯艺萌 ymfeng@fudan.edu.cn

基金项目: 国家自然科学基金(62595745)

Foundation Item: The National Natural Science Foundation of China (62595745)

通过学习时序信道特征实现CSI预测与预编码协同优化,提升LEO卫星场景下的鲁棒性与实时性。目前,深度学习已成为6G低轨卫星预编码技术的重要演进方向^[20-22]。

由于同一物理层帧内多个用户共享相同数据流与预编码矩阵,组内用户信道相似度会直接影响组播预编码性能。因此,高质量用户分组是提升系统吞吐量和降低波束间干扰的关键。现有用户分组方法大致可分为两类:一类基于传统聚类思想,如Agglomerative Hierarchical Clustering (AHC)、K-means等方法^[23,24],其能够有效利用用户间信道相似性,但难以满足DVB-S2X对固定组容量的严格约束;另一类则遵循“组内相似、组间正交”原则^[25],典型方法包括基于半正交用户调度^[26]的MAUG算法^[5]或MaxDist代表用户选择方法^[24,27]。这类方法能够降低组间干扰,但通常仅依据单一代表用户衡量组内相似度,忽略了组内整体信道结构,因此难以实现全局最优分组效果。

针对低轨卫星多波束组播系统中全频率复用引起的严重波束间干扰,以及用户分组与预编码之间强耦合导致的非凸优化问题,本文提出一种兼顾低复杂度与公平性的联合优化框架。本文重点研究用户分组对组内信道相关性及用户总速率的影响,并通过深度学习实现预编码矩阵的低复杂度求解。主要贡献如下:

(1)针对传统预编码算法在大规模天线场景下计算复杂度高、实时性不足的问题,设计了一种融合卷积神经网络(Convolutional Neural Network, CNN)与长短期记忆网络(Long Short-Term Memory, LSTM)的无监督深度学习预编码方案,建立了信道矩阵到预编码矩阵的非线性映射关系。该方法利用神经网络求解高维非凸优化问题,避免了传统迭代求逆运算,并通过LSTM进一步学习深层特征之间的非线性关联。其在线推理复杂度随天线规模线性增长,为大规模LEO实时通信提供了一种低复杂度解决方案。

(2)针对传统K-means分组算法无法满足DVB-S2X固定帧结构约束的问题,设计了一种约束K-means用户分组算法,针对信道特性,提出了综合组内相似度和DVB-S2X帧结构约束的联合分配机制,在严格保证每组用户数相等的前提下提高组内相似度,实现了物理层标准约束和分组相似度的兼顾。

(3)针对组播系统中边缘用户易成为系统瓶颈、传统分组方法公平性不足的问题,提出了一种基于公平性感知的全局用户分配机制的分组算法

(FA-MAUG),通过优先保障边缘用户与弱信道用户的分组质量,提高组内信道一致性,在保证系统吞吐量的同时进一步提升了系统公平性与鲁棒性。

仿真结果表明,所提联合优化框架在系统吞吐量、公平性与复杂度之间取得了良好平衡。在不同信噪比条件下,基于所提CNN-LSTM预编码方案的总速率相较传统MMSE算法平均提升48.59%,CK-means算法相较随机分组增益达到30.12%,同时显著降低了信关站侧在线计算复杂度,验证了所提方法在大规模低轨卫星通信场景中的有效性与工程应用潜力。本文其余部分的结构安排如下:第2节介绍系统模型和问题建模。第3节推导了基于CNN-LSTM混合架构的预编码设计,并进行了计算复杂度分析。第4节介绍了所提出的用户分组算法。第5节给出了仿真结果。最后,在第6节得出结论。

本文采用以下符号惯例: $\mathbf{a}$ 表示向量, a 表示标量, $\mathbf{A}$ 表示矩阵。 $|\mathbf{A}|$ 和 $\|\mathbf{A}\|$ 分别表示矩阵 $\mathbf{A}$ 的行列式和范数。 $\mathbf{A}^H$ 表示矩阵 $\mathbf{A}$ 的共轭转置。 $\Re(\mathbf{A})$ 、 $\Im(\mathbf{A})$ 分别表示矩阵 $\mathbf{A}$ 的实部和虚部。 $\mathbf{I}$ 表示单位矩阵。 $\mathbf{a} \sim \mathcal{CN}(\mathbf{m}, \mathbf{R})$ 表示 $\mathbf{a}$ 为服从均值 $\mathbf{m}$ 和协方差 $\mathbf{R}$ 的循环对称复高斯随机向量。 $\mathbf{C}^{M \times N}$ 表示 $M \times N$ 复矩阵集。 $\mathbb{R}$ 表示实数。 $\mathcal{A}$ 表示集合。

2 系统设计

考虑一个组播系统,一颗多波束低轨卫星通过透明转发载荷为 N_u 个单天线地面用户终端(User Terminals, UTs)提供服务,信关站根据用户通过反馈链路回传的信道状态信息(Channel State Information, CSI)计算预编码矩阵,如图1所示。卫星配备均匀平面阵列(Uniform Planar Array, UPA),由 $N_t = N_x \times N_y$ 根天线组成,其中 N_x 和 N_y 分别表示天线平面 x 轴和 y 轴上的天线数量。信关站采用基于帧的预编码技术,通过 K 个不同的波束传输信息。用户终端集合被划分为多个组播组,记为 $\mathcal{G} = \{\mathcal{G}_1, \mathcal{G}_2, \dots, \mathcal{G}_K\}$, K 为用户组数。其中 $\mathcal{G}_k$ 代表第 k 组的用户集合。每个组与一个特定的波束相关联。用户在各组中均匀分布,即对于所有 $k \in K \triangleq \{1, 2, \dots, K\}$,均有 $|\mathcal{G}_k| = M = N_u/K$, M 为每组用户数。

2.1 信号模型与问题建模

从卫星发送至用户的信号公式为:

$$\mathbf{x} = \sum_{k=1}^K \mathbf{w}_k \mathbf{s}_k = \mathbf{W} \mathbf{s} \quad (1)$$

其中, $\mathbf{w}_k \in \mathbb{C}^{N_t \times 1}$ 表示第 k 个组播组的预编码向量, $\mathbf{W} \triangleq [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_K] \in \mathbb{C}^{N_t \times K}$ 为预编码矩阵。




图 1 低轨卫星组播通信系统

s_k 为发往第 k 组的公共数据流，用户数据流向量定义为 $s \triangleq [s_1, s_2, \dots, s_K]^T \in \mathbb{C}^{K \times 1}$ 。为不失一般性，假设数据符号为独立同分布且功率归一化，即 $\mathbb{E}[ss^H] = \mathbf{I}_K$ 。因此，第 k 组中第 i 个用户接收到的信号表示为：

$$y_i(t) = \mathbf{h}_i^H \mathbf{w}_k s_k e^{j2\pi f_{d,i}(t)t} + \sum_{l \neq k} \mathbf{h}_i^H \mathbf{w}_l s_l(t) e^{j2\pi f_{d,i}(t)t} + n_i(t), \forall i \in \mathcal{G}_k \quad (2)$$

其中， $\mathbf{h}_i \in \mathbb{C}^{N_t \times 1}$ 表示卫星与用户 i 之间的信道。 $f_{d,i}(t)$ 表示卫星移动对用户 i 引起的多普勒频移。多普勒频移可表示为 $f_d(t) = f[v(t)c]\psi(t)$ ，其中 f 为载波频率， $v(t)$ 为卫星瞬时运动速度， c 为光速， $\psi(t)$ 为卫星运动方向与星地链路之间的夹角。在 LEO 卫星系统中，多普勒预补偿机制可使残余频偏在短时传输窗口内保持较小，信道在帧周期内呈现准静态特性。项 $n_i \sim \mathcal{CN}(0, \sigma_i^2)$ 表示均值为零、方差为 σ_i^2 的加性高斯白噪声 (Additive White Gaussian Noise, AWGN)。为简化后续分析，我们基于加性噪声项对接收信号进行归一化处理，使得噪声具有单位方差，即 $\sigma_i^2 = 1$ 。基于上述假设，在公式 (2) 中，右边第一项表示所需的组播信号，第二项表示组间干扰。由于信号以组/帧的形式传输，每组的 SINR 由该组内用户的最小 SINR 决定。第 k 组的 SINR 由下式给出：

$$\gamma_k = \min_{m \in \mathcal{G}_k} \frac{|\mathbf{w}_k^H \mathbf{h}_m|^2}{\sum_{l \neq k} |\mathbf{w}_l^H \mathbf{h}_m|^2 + \sigma_m^2} \quad (3)$$

在多波束组播预编码场景中，组间干扰是影响传输性能的重要因素。合理的用户分组策略和预编码技术可以最大限度地减少组间干扰，并最大化用户总速率。多波束组播预编码的优化问题表示为：

$$\begin{aligned} \text{P: } & \max_{\{\mathcal{G}_k, \mathbf{w}_k\}_{k=1}^K} \sum_{k=1}^K M \log_2(1 + \gamma_k) \\ \text{s.t. } & \bigcup_{k=1}^K \mathcal{G}_k = \mathcal{U}, \\ & |\mathcal{G}_k| = M, \forall k \in \{1, 2, \dots, K\}, \\ & \left[\sum_{k=1}^K \mathbf{w}_k \mathbf{w}_k^H \right]_{nn} \leq P_n, \forall n \in \{1, 2, \dots, N_t\} \end{aligned} \quad (4)$$

前两个约束条件为用户分组约束，其中 $\mathcal{U}$ 代表用户集合。第三个约束条件是单天线功率约束 (Per-Antenna Constraint, PAC)。由于传输符号 s 的功率已归一化，天线功率由预编码矩阵 $\mathbf{W}$ 决定。此处， P_n 代表每根天线的功率预算， $[\cdot]_{nn}$ 代表矩阵的第 (n, n) 个元素。在实际应用中，发射端天线单元通常配备独立的功率放大器，各射频链路间的功率无法实现跨通道共享。因此，本文针对单天线功率约束 (PAC) 场景，构建并求解组播预编码优化问题。

2.2 信道模型

与地面通信网络不同，卫星到用户终端的传播距离远大于地面链路，且卫星天线附近几乎不存在散射体，因此卫星与用户终端之间的信道通常被建模为视距 (Line of Sight, LoS) 传播。同时，由于传输距离极长，卫星链路会受到多种大气衰减的显著影响，因此需要综合考虑以下因素：自由空间路径损耗、接收机噪声功率、收发天线增益以及雨衰等。信道模型如下：

$$\mathbf{h} = \sqrt{\frac{C_L G_R}{P_R \xi_n}} G_T(\alpha) \cdot \mathbf{v}(\phi, \theta) \in \mathbb{C}^{N_t \times 1} \quad (5)$$

其中， C_L 为自由空间损耗， G_T 为卫星天线增益， G_R 为接收天线增益， P_R 为接收噪声功率， ξ_n 为雨衰， $\mathbf{v}(\phi, \theta) \in \mathbb{C}^{N_t \times 1}$ 为 UPA 的阵列响应向量。各部分的详细说明如下：

(1) 卫星天线增益 G_T 主要由离轴波束指向角 ψ 决定： $G_T = G_{\max} - 3 \left(\frac{\psi}{\psi_{3\text{dB}}} \right)^2 \in \mathbb{R}$ ，其中 $G_{\max} \in \mathbb{R}$ 代表最大卫星天线增益， ψ 是离轴角， $\psi_{3\text{dB}}$ 是 3 dB 波束宽度的一半。

(2) 用户终端的接收噪声功率 $P_R = \kappa B T \in \mathbb{R}$ ，其中 κ 、 B 和 T 分别代表玻尔兹曼常数、用户终端接收带宽和噪声温度。

(3) 自由空间损耗 $C_L = \left(\frac{c}{4\pi f \sqrt{d_u^2 + d_h^2}} \right)^2 \in \mathbb{R}$ ，

其中 c 为光速， f 为载波频率， d_u 和 d_h 分别为卫星覆盖区域中心到卫星的距离以及到用户终端的距离。

(4) 雨衰 $\xi_n = 10^{\frac{20}{\xi_{dB}}} \in \mathbb{R}$, 其中 ξ_{dB} 代表以 dB 为单位的雨衰功率增益, 它服从均值为 μ 、标准差为 σ 的对数正态分布, 即 $\ln(\xi_{dB}) \sim \mathcal{CN}(\mu, \sigma^2)$ 。

(5) UPA 响应向量 $\mathbf{v}(\phi, \theta) = \mathbf{v}_x(\varphi_x) \otimes \mathbf{v}_y(\varphi_y) \in \mathbb{C}^{N_t \times 1}$, 其中 $\otimes$ 表示克罗内克 (Kronecker) 积, $\varphi_x = \sin \theta \cos \phi$ 和 $\varphi_y = \sin \theta \sin \phi$ 是相对于 UT 传播路径关联的 x 轴和 y 轴的角度, 其中 θ 和 ϕ 分别是仰角和方位角。考虑半波长卫星天线间距, 对于 $d \in D \triangleq \{x, y\}$, 其相对于 x 轴或 y 轴的阵列响应向量 $\mathbf{v}_d(\varphi_d) = [1, e^{j\pi\varphi_d}, \dots, e^{j\pi(N_d-1)\varphi_d}]^T \in \mathbb{C}^{N_d \times 1}$ 。

在实际低轨卫星通信系统中, 由于信道估计误差、反馈误差等因素, 网关通常难以获得精确 CSI。因此本文基于加性 CSI 误差模型, 以评估算法在实际环境下的鲁棒性。估计信道 $\hat{\mathbf{H}} = \mathbf{H} + \mathbf{E} \in \mathbb{C}^{N_t \times N_r}$, 其中 $\mathbf{E} \sim \mathcal{CN}(0, \sigma_e^2 \mathbf{I})$ 为误差矩阵, σ_e^2 表示误差功率。

3 组播预编码方案

鉴于组播预编码通常按组/帧进行, 我们将原问题分解为两个子问题: 用户分组与预编码矩阵设计。本节首先聚焦预编码矩阵的求解算法, 下一节阐述用户分组方法。用于求解预编码矩阵的子优化问题如下:

$$\begin{aligned} P_{bf}: \quad & \max_{\{\mathbf{w}_k\}_{k=1}^K} \sum_{k=1}^K M \log_2(1 + \gamma_k) \\ \text{s.t.} \quad & \left[\sum_{k=1}^K \mathbf{w}_k \mathbf{w}_k^H \right]_{nn} \leq P_n, \forall n \in \{1, 2, \dots, K\} \end{aligned} \quad (6)$$

针对该问题, 本文基于预编码矩阵与信道矩阵的内在关系, 提出了一种 CNN-LSTM 混合无监督深度学习模型, 以最大化用户总速率为目标, 在满足功率约束的前提下优化预编码矩阵。然后分析了模型的计算复杂度。

3.1 深度学习网络设计

在用户分组确定的前提下, 根据上式, 目标函

数仅依赖于预编码矩阵 $\mathbf{W}$ 和信道矩阵 $\mathbf{H}$ 。因此, 信道矩阵的特征提取对求解最优预编码至关重要。低轨卫星信道具有时变性强、维度高、复杂度大的特点。传统方法通常依赖大量先验知识和复杂的工程设计。相比之下, 无监督学习编码器能通过数据驱动的方式有效降维并提取潜在特征, 特别适合处理无标签的高维信道矩阵数据, 且具备较好的抗干扰能力和鲁棒性。为此, 本文设计了一种基于卷积神经网络与长短期记忆网络混合架构的无监督学习编码器, 记为 CNN-LSTM, 旨在建立从不完美 CSI 到最优预编码矩阵的非线性映射, 模型整体结构如表 1 所示。

考虑到卫星大规模天线阵列中显著的空间相关性, 模型首先采用 CNN 提取局部空间特征并实现维度压缩。其次, LSTM 通过门控机制对特征流中的长期依赖关系进行建模, 从而增强不同用户、不同波束之间隐式相关特征的表达能力。最后使用三个独立的全连接层对所提取的特征进行整合。

为提升模型在不同统计特性信道下的训练稳定性和泛化能力, 每个全连接层后均引入批归一化 (Batch Normalization), 以缓解过拟合并使优化过程更平稳。整体 CNN-LSTM 混合架构如图 2 所示。

为提升模型在不完美信道下的鲁棒性, 模型基于估计信道进行训练和预测。由于现有主流深度学习框架主要支持实值运算, 将估计信道矩阵的实部与虚部进行拼接作为输入:

表 1 CNN-LSTM 模型参数

模型层名称	输出维度	激活函数	参数量
输入层	$64 \times 36 \times 1$	\	0
卷积层	32×64	ReLU	4672
LSTM 层	64×1	\	33024
全连接层 1	512×1	ReLU	33280
全连接层 2	256×1	ReLU	131328
全连接层 3	128×1	sigmoid	32896




图 2 CNN-LSTM 模型混合架构

$$\hat{\mathbf{H}} \triangleq [\Re(\tilde{\mathbf{H}}), \Im(\tilde{\mathbf{H}})] \in \mathbb{C}^{N_t \times 2N_u} \quad (7)$$

模型在全连接层后使用重塑层，其大小基于通信系统参数进行设计，从而直接输出预编码矩阵的实部和虚部，然后合并得到预编码矩阵。随后在Lambda层中基于预编码矩阵计算单天线功率并进行缩放，使模型输出满足公式(6)中的功率约束。由于该过程参与反向梯度传播，因此不会影响输出最优性。最后基于真实信道对公式(6)中的目标函数进行计算并取负值，作为损失函数，以最大化系统总速率。同时，为使模型感知不同信噪比下的最优预编码策略，将SNR作为模型辅助输入，进一步提升跨信噪比区间的泛化性能。考虑到系统速率受组内最弱用户限制，计算各组用户SINR最小值作为辅助指标，用于提升组播公平性。为提高训练效率与收敛稳定性，使用Adam优化器对网络参数进行迭代更新，并采用学习率衰减策略：缩减因子为0.2，patience为20个epoch，最小学习率设为 5×10^{-5} 。

3.2 计算复杂度分析

基于浮点运算次数(Floating Point Operations per Second, FLOPs)分析所提CNN-LSTM模型的计算复杂度。离线训练阶段的模型复杂度主要由卷积层、LSTM层以及全连接层的前向与反向传播过程决定。结合本文网络结构参数，单样本训练复杂度约为 3.75×10^6 FLOPs，在50,000个epoch条件下，总离线训练复杂度约为 $10^{13} \sim 10^{14}$ FLOPs，属于可接受的训练规模，在现代GPU平台中可高效完成部署。

在线阶段的模型复杂度如表2所示。相比现有深度学习预编码方案，所提CNN-LSTM方案无需在线迭代优化、参数更新及环境交互，仅通过一次前向传播即可完成预编码矩阵生成，在充分挖掘高维信道特征的同时保持较低在线计算复杂度。与MMSE算法相比，前者的复杂度随天线数线性增长，而后者由于涉及矩阵求逆运算，复杂度随天线数 N_t 呈三次方增长，且模型部署后仅需前向推理即可直接预测预编码矩阵，避免了MMSE算法在

每个时隙重复进行矩阵求逆运算的问题。即使模型在训练样本分布影响下会损失少量性能，但复杂度显著降低，适用于大规模低轨卫星实时通信场景。

4 自适应用户分组算法

在多波束卫星组播系统中，除预编码算法外，系统性能还高度依赖于用户分组质量。传统聚类算法难以保证DVB-S2X超帧结构每组用户数固定且一致的要求；波束边缘用户信道条件较差、增益较低，常规分组易导致这些用户被边缘化，降低系统整体鲁棒性。针对上述问题，本节提出适用于LEO卫星场景的自适应用户分组策略，包括约束K-means算法和公平感知MAUG算法。

4.1 约束 K-means 算法

根据第2.2节建立的卫星信道模型，地理位置相近用户的阵列响应向量高度相关，其信道具有较高的空间相似性，更适合划分至同一组，这与聚类算法的核心思想一致。因此，本文提出一种约束K-means(CK-means)用户分组算法，在满足DVB-S2X等规模分组约束的基础上，结合低轨卫星信道空间相关特性，对用户分配过程进行联合优化。该算法流程如算法1所示。具体步骤如下：

(1)初始化：采用多初始解并行策略(多次随机初始化质心并行运行)，选取聚类性能最优的初始质心集合，以缓解K-means对初值敏感和易陷入局部最优的缺陷；

(2)距离计算与排序：计算所有用户到各质心的欧氏距离矩阵，并对距离元素整体升序排列。由于空间位置接近的用户通常具有更高的信道相关性，因此该步骤能够优先保留高相似度用户之间的聚类关系；

(3)贪心分配：将每个用户-质心对按照排序后的距离序列逐一遍历，若当前用户尚未分配且目标组未达到容量上限，则分配至该组；否则跳至次优匹配；

(4)迭代更新：所有用户分配完成后更新质心位置，重复步骤(2)和(3)，直至质心收敛。

该方法最终输出满足等规模约束的最优用户分

表 2 代表深度学习预编码算法在线计算复杂度

论文	模型	在线复杂度
Lin 2020 ^[14]	端到端神经网络	$O((2N_I - 1)N_O)$
Luo 2022 ^[17]	CNN+迭代优化算法	$O(N_o N_i + 2N_t S)$
Li 2025 ^[13]	多智能体强化学习	$O(N_a T B N_p)$
本文	端到端CNN+LSTM	$O(N_o N_i + 4N_L(N_L + N_X) + (2N_I - 1)N_O)$

* N_o : 卷积层输出维度; N_i : 卷积层输入维度; S : 卷积层特征大小; N_O : 全连接层输出维度; N_I : 全连接层输入维度; N_X : LSTM层输入维度; N_L : LSTM层隐藏层维度; N_a : 智能体个数; T : 状态更新步数; B : 缓冲采样数; N_p : 前向传播数量

算法 1 约束K-means用户分组算法(CK-means)

输入：用户位置集合 $\mathcal{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{N_u}\}$ ，组数 K ，每个组用户数 M

输出：最优聚类集合 $\mathcal{G} = \{\mathcal{G}_1, \mathcal{G}_2, \dots, \mathcal{G}_K\}$

- 1: 初始化 K 个质心位置 $C = \{\mathbf{c}_1, \mathbf{c}_2, \dots, \mathbf{c}_K\}$
- 2: **Repeat**
- 3: 计算距离矩阵 $D = \|\mathbf{x}_i - \mathbf{c}_k\|^2 \in \mathbb{C}^{N_u \times K}, i \in \{1, 2, \dots, N_u\}, k \in \{1, 2, \dots, K\}$
- 4: 将 D 中元素值按照升序重新排列
- 5: **for** D 中元素 $d_{i,k}, i \in \{1, 2, \dots, N_u\}, k \in \{1, 2, \dots, K\}$ **do**
- 6: **if** 用户 $\mathbf{x}_i$ 尚未被分配 **and** $|\mathcal{G}_k| < M$ **then**
- $\mathcal{G}_k \leftarrow \mathcal{G}_k \cup \{\mathbf{x}_i\}$
- 7: **end if**
- 8: **end for**
- 9: 更新质心: $\mathbf{c}_k \leftarrow \frac{1}{|\mathcal{G}_k|} \sum_{\mathbf{x} \in \mathcal{G}_k} \mathbf{x}, \forall k \in \{1, 2, \dots, K\}$
- 10: **until** 质心集合 C 不再发生变化
- 11: **return** 最优聚类集合 $\mathcal{G}$

组结果，有效平衡了分组相似度与标准帧结构要求，为后续预编码设计提供了可靠基础。

4.2 公平感知 MAUG 算法

MAUG算法主要分为两个阶段：首先利用类Gram-Schmidt正交化过程为每组选定代表用户，以最小化组间干扰；其次为每个代表用户所属组依次分配剩余用户。然而，该算法在第二阶段未考虑分配顺序。若分配顺序不当，边缘用户极易被忽略或分配到次优组，导致分组公平性显著下降，并最终降低系统总吞吐量。针对这一问题，本文分析了分组顺序对性能的影响，并进行了改进，如**算法2**所示。

具体而言，在低轨卫星场景中，用户均匀分布于覆盖区域，边缘用户对分组结果更敏感——因其可匹配的相似信道用户较少。根据第2.2节的信道模型，在接收噪声功率、雨衰及接收增益服从相似分布的情况下，用户信道范数主要受自由空间路径损耗影响。因此，距离波束中心越远的用户，其信道增益通常越低，更容易成为限制组播速率的瓶颈用户。基于上述分析，本文在MAUG算法基础上引入公平性感知的全局用户分配机制。首先，将第一阶段选出的代表用户按照信道范数升序排列，使信道条件较差的边缘用户优先参与分组，从而降低弱信道用户被分配至次优组的概率。具体步骤如下：

(1)代表性用户选择：采用类Gram-Schmidt正交化筛选代表用户，确保组间干扰最小化。

(2)剩余用户公平分配：对剩余待分配用户按信道范数升序排序，并依次遍历。对于当前用户，

算法 2 公平感知MAUG用户分组算法(FA-MAUG)

输入：卫星天线数 N_t ，用户数 N_u ，组数 K ，每组用户数 M ，用户信道向量 $\tilde{\mathbf{h}}_i \in \mathbb{C}^{N_t \times 1}, i \in \{1, 2, \dots, N_u\}$

输出：最优分组集合 $\mathcal{G} = \{\mathcal{G}_1, \mathcal{G}_2, \dots, \mathcal{G}_K\}$

- 1: 初始化代表用户集合 $\mathcal{I} = \emptyset$ ，剩余用户集合 $U = \{1, 2, \dots, N_u\}$
- 2: **步骤1：选择代表用户**
- 3: **for** $i = 1$ **to** K **do**
- 4: **for** $j \in U$ **do**
- 5: $\mathbf{g}_j = \tilde{\mathbf{h}}_j - \sum_{q=1}^{i-1} \frac{\tilde{\mathbf{h}}_j^H \mathbf{g}_q}{\|\mathbf{g}_q\|^2} \mathbf{g}_q$
- 6: **end for**
- 7: 选择代表用户: $j^* = \arg \max \|\mathbf{g}_j\|$
- 8: $\mathcal{I} \leftarrow \mathcal{I} \cup \{j^*\}, U \leftarrow U \setminus \{j^*\}, \mathcal{G}_i \leftarrow \mathcal{G}_i \cup \{j^*\}, \mathbf{g}_i = \mathbf{g}_{j^*}$
- 9: **end for**
- 10: **步骤2：剩余用户分配**
- 11: 将 U 中剩余用户按照信道范数降序重新排列
- 12: **for** $i \in U$ **do**
- 13: **for** $j = 1$ **to** K **do**
- 14: **if** $|\mathcal{G}_j| \leq M$ **then** 计算用户 i 与代表用户 $\mathcal{I}\{j\}$ 的相似度
- $u_{i,j} = \frac{\tilde{\mathbf{h}}_{\mathcal{I}\{j\}}^H \tilde{\mathbf{h}}_i}{\|\tilde{\mathbf{h}}_{\mathcal{I}\{j\}}\|^2} \tilde{\mathbf{h}}_i$
- 15: **end if**
- 16: **end for**
- 17: 查找相似度最高的组并进行分配:
- $j^* = \arg \max u_{i,j}, \mathcal{G}_{j^*} \leftarrow \mathcal{G}_{j^*} \cup \{i\}$
- 18: **end for**
- 19: **return** 最优聚类集合 $\mathcal{G}$

计算其信道与各代表用户的相关性，选择相关性最高的组进行分配。

通过引入公平性感知的全局分配策略，该算法在保证组间正交性的同时，进一步提高了分组公平性，为组播预编码提供了鲁棒性更高的用户分组结果。

4.3 计算复杂度分析

MAUG算法的计算复杂度为 $O(N_t N_u K + N_u K \log(N_u K))$ ，其中主要开销来自距离计算和排序分配。相较之下，FA-MAUG仅额外引入了对剩余用户按信道范数排序的步骤，复杂度增加 $O(N_u \log(N_u))$ 。CK-means算法的复杂度为 $O(N_t N_u K + N_u K \log(N_u K))$ ，分别对应距离矩阵计算和带约束的排序分配过程。各算法复杂度对比如表3所示。在大规模UPA低轨卫星场景中，天线数 N_t 通常极大，成为复杂度的主导因素。此时，用户排序开销可忽略，而FA-MAUG和CK-means仍能显著提升边缘用户吞吐量和系统公平性，充分体现了所提算法在计算效率与性能间的良好平衡。

5 性能评估

在本节中，我们首先介绍CNN-LSTM预编码模型的样本生成与参数设置，随后通过仿真实验，从组内相似度^[25]和用户总速率两方面评估了所提用户分组算法及CNN-LSTM预编码方案的性能。

本文设置天线数 $N_t = 64$ ，组数 $K = 9$ ，每组用户数 $M = 2$ 。根据第2.2节信道模型分别生成真实与估计信道，误差功率 $\sigma_e^2 = 5 \times 10^{-2}$ ，样本数为1000。首先基于信道进行用户分组和预编码模型训练和预测，最后计算用户总速率均值。预编码模型训练阶段采用批大小 $batch_size = 20$ ，每批次训练50,000个epoch；每个训练批次随机采样不同SNR值计算损失，从而提升模型对SNR变化的泛化能力。

5.1 用户分组结果

我们首先使用组内余弦相似度指标评估分组质量，定义如下：

$$\text{sim}(\mathbf{H}_{\mathcal{G}_k}) = \frac{\sum_{i,j \in \mathcal{G}_k, i \neq j} |\bar{\mathbf{h}}_i^H \bar{\mathbf{h}}_j|}{|\mathcal{G}_k| (|\mathcal{G}_k| - 1)} \quad (8)$$

其中 $\bar{\mathbf{h}}_{i(j)}$ 为归一化信道向量。该指标反映组内用户信道方向的平均一致性，值越大表示组内信道越集中，有利于获得更高波束增益和总速率。我们比较了CK-means、FA-MAUG、原始MAUG以及随机分组在不同用户总数下的平均组内相似度(每组相似度取平均)，结果如图3所示。

图中可见，所有算法的平均组内相似度随用户数量变化较小，但所提CK-means算法表现最优，

表 3 用户分组算法计算复杂度

用户分组算法	计算复杂度
CK-means	$O(N_t N_u K + N_u K \log(N_u K))$
FA-MAUG	$O(N_t N_u K^2 + N_t N_u K + N_u \log(N_u))$
MAUG	$O(N_t N_u K^2 + N_t N_u K)$




图 3 用户分组算法平均组内相似度

其相似度较FA-MAUG和MAUG高约0.1，较随机分组高近0.5。这表明CK-means在满足DVB-S2X等组规模硬约束的前提下，显著提升了分组质量，为后续预编码提供了更优的信道基础。

5.2 总速率性能

在本节中，我们评估了低轨卫星多用户组播预编码场景下，不同用户分组与预编码算法组合对系统总速率的影响。假设系统为每根天线平均分配功率预算，即 $P_n = P/N_t, n = \{1, 2, \dots, N_t\}$ 。其中， P 为天线总功率。我们分别给出了总速率随信噪比和天线总功率的变化趋势，如图4、5所示。随着SNR和发射功率增加，各算法的总速率均持续提升，CNN-LSTM预编码均明显优于传统MMSE算法。同时，CK-means和FA-MAUG均优于随机分组，其中CK-means性能最佳，验证了提高组内信道相似度能够有效提升组播预编码增益。在不同SNR下，基于CNN-LSTM预编码的系统总速率相较于MMSE算法平均提升48.59%，CK-means用户分组较随机分组平均提升30.12%。




图 4 用户总速率 vs 信噪比




图 5 用户总速率 vs 天线总功率

此外,为验证模型在不同规模系统下的性能,我们分别分析了每组用户数、组数及天线数对系统速率的影响,如图6、7、8所示。随着组内用户数和组数增加,相比MMSE算法,CNN-LSTM方案仍保持较高增益,说明其具有更强的多用户干扰抑




图6 用户总速率 vs 每组用户数




图7 用户总速率 vs 组数




图8 用户总速率 vs 天线数

制能力。同时,CK-means始终获得最高总速率,进一步证明合理的用户聚类能够有效改善组播性能。随着天线规模扩大,各算法性能均明显提高,但CNN-LSTM方案增长速度更快。这是因为更多天线能够提供更高的空间自由度,而深度学习模型能够更充分地挖掘高维信道特征,实现更有效的干扰抑制与波束赋形。在不同组用户数、组数和天线数下,基于CNN-LSTM预编码的系统总速率相较MMSE算法分别平均提升83.79%、86.59%和97.61%。

综合图4至图8可以看出,所提出的CNN-LSTM预编码结合CK-means和FA-MAUG用户分组策略,在不同系统参数条件下均表现出稳定且显著的性能优势,验证了本文联合优化方案在提升系统总速率和增强系统扩展性方面的有效性。

6 结束语

针对低轨卫星通信系统面临的严重波束间干扰和高计算复杂度挑战,本文提出了一种将无监督深度学习预编码与改进用户分组策略相结合的联合优化方案。通过构建基于CNN-LSTM混合架构的神经网络模型,实现了单天线功率约束条件下的预编码矩阵优化,将计算复杂度从传统算法的立方级降至线性级,同时显著提升系统总速率性能。为适配DVB-S2X标准的组容量约束,进一步设计了约束K-means和公平感知MAUG两种分组算法,在维持高组内信道相似度的前提下有效提升了系统公平性和整体鲁棒性。仿真结果表明,所提方案在多种信噪比和功率约束场景下均表现出色,大幅提高了系统吞吐量,并显著降低了计算开销,展现出良好的实用价值和工程适用性。

参考文献

- [1] KUMARI S and HOSSAIN A. Comprehensive review on performance analysis for satellite communication MIMO over terrestrial communication MIMO[J]. *International Journal of Satellite Communications and Networking*, 2026, 44(4): 445–463. doi: [10.1002/sat.70035](https://doi.org/10.1002/sat.70035).
- [2] 郑斌, 曾令昕, 黄辉, 等. 密集低轨卫星网络辅助地面通信的鲁棒波束赋形方法[J]. *电子与信息学报*, 2025, 47(3): 623–632. doi: [10.11999/JEIT240732](https://doi.org/10.11999/JEIT240732).
ZHENG Bin, ZENG Lingxin, HUANG Hui, et al. Robust beamforming method for dense LEO satellite network assisted terrestrial communication[J]. *Journal of Electronics & Information Technology*, 2025, 47(3): 623–632. doi: [10.11999/JEIT240732](https://doi.org/10.11999/JEIT240732).
- [3] European Telecommunications Standards Institute. ETSI EN 302 307-1 V1.4. 1 Second generation framing structure, channel coding and modulation systems for broadcasting,

- interactive services, news gathering and other broadband satellite applications; Part 1 (DVB-S2)[S]. Cedex: ETSI, 2014.
- [4] European Telecommunications Standards Institute. ETSI EN 302 307-2 V1.4. 1 Second generation framing structure, channel coding and modulation systems for broadcasting, interactive services, news gathering and other broadband satellite applications; Part 2: DVB-S2 Extensions (DVB-S2X)[S]. Cedex: ETSI, 2024.
- [5] CHRISTOPOULOS D, CHATZINOTAS S, and OTTERSTEN B. Multicast multigroup precoding and user scheduling for frame-based satellite communications[J]. *IEEE Transactions on Wireless Communications*, 2015, 14(9): 4695–4707. doi: [10.1109/TWC.2015.2424961](https://doi.org/10.1109/TWC.2015.2424961).
- [6] SIDIROPOULOS N D, DAVIDSON T N, and LUO Zhiqian. Transmit beamforming for physical-layer multicasting[J]. *IEEE Transactions on Signal Processing*, 2006, 54(6): 2239–2251. doi: [10.1109/TSP.2006.872578](https://doi.org/10.1109/TSP.2006.872578).
- [7] YIN Shiqi and DONG Min. Computation-and-communication efficient coordinated multicast beamforming in massive MIMO networks[J]. *IEEE Transactions on Communications*, 2025, 73(9): 7811–7827. doi: [10.1109/TCOMM.2025.3541031](https://doi.org/10.1109/TCOMM.2025.3541031).
- [8] CHRISTOPOULOS D, CHATZINOTAS S, ZHENG Gan, *et al.* Linear and nonlinear techniques for multibeam joint processing in satellite communications[J]. *EURASIP Journal on Wireless Communications and Networking*, 2012, 2012(1): 162. doi: [10.1186/1687-1499-2012-162](https://doi.org/10.1186/1687-1499-2012-162).
- [9] WU S X, MA W K, and SO A M C. Physical-layer multicasting by stochastic transmit beamforming and Alamouti space-time coding[J]. *IEEE Transactions on Signal Processing*, 2013, 61(17): 4230–4245. doi: [10.1109/TSP.2013.2263500](https://doi.org/10.1109/TSP.2013.2263500).
- [10] KARIPIDIS E, SIDIROPOULOS N D, and LUO Zhiqian. Quality of service and max-min fair transmit beamforming to multiple Cochannel multicast groups[J]. *IEEE Transactions on Signal Processing*, 2008, 56(3): 1268–1279. doi: [10.1109/TSP.2007.909010](https://doi.org/10.1109/TSP.2007.909010).
- [11] LUO Zhiqian, MA W, SO A M C, *et al.* Semidefinite relaxation of quadratic optimization problems[J]. *IEEE Signal Processing Magazine*, 2010, 27(3): 20–34. doi: [10.1109/MSP.2010.936019](https://doi.org/10.1109/MSP.2010.936019).
- [12] 李振东, 巴建乐, 苏洲, 等. 可移动天线赋能的ISAC系统中波束赋形与天线位置联合优化[J]. *电子与信息学报*, 2025, 47(10): 3482–3491. doi: [10.11999/JEIT250146](https://doi.org/10.11999/JEIT250146).
- LI Zhendong, BA Jianle, SU Zhou, *et al.* Joint beamforming and antenna position optimization in movable antenna empowered ISAC systems[J]. *Journal of Electronics & Information Technology*, 2025, 47(10): 3482–3491. doi: [10.11999/JEIT250146](https://doi.org/10.11999/JEIT250146).
- [13] DONG Min and WANG Qiqi. Multi-group multicast beamforming: Optimal structure and efficient algorithms[J]. *IEEE Transactions on Signal Processing*, 2020, 68: 3738–3753. doi: [10.1109/TSP.2020.2994753](https://doi.org/10.1109/TSP.2020.2994753).
- [14] LI Huiting, JIANG Yanxiang, HUANG Yige, *et al.* A multi-agent DRL method for distributed energy-efficient association and hybrid precoding in mmWave cell-free massive MIMO systems[J]. *IEEE Communications Letters*, 2025, 29(1): 70–74. doi: [10.1109/LCOMM.2024.3494537](https://doi.org/10.1109/LCOMM.2024.3494537).
- [15] LIN Tian and ZHU Yu. Beamforming design for large-scale antenna arrays using deep learning[J]. *IEEE Wireless Communications Letters*, 2020, 9(1): 103–107. doi: [10.1109/LWC.2019.2943466](https://doi.org/10.1109/LWC.2019.2943466).
- [16] SOHRABI F, ATTIAH K M, and YU Wei. Deep learning for distributed channel feedback and multiuser precoding in FDD massive MIMO[J]. *IEEE Transactions on Wireless Communications*, 2021, 20(7): 4044–4057. doi: [10.1109/TWC.2021.3055202](https://doi.org/10.1109/TWC.2021.3055202).
- [17] ZHOU Huibin, GONG Xinrui, TSINOS C G, *et al.* GNN-enabled precoding for massive MIMO LEO satellite communications[J]. *IEEE Transactions on Communications*, 2025, 73(10): 9028–9042. doi: [10.1109/TCOMM.2025.3568216](https://doi.org/10.1109/TCOMM.2025.3568216).
- [18] LUO Jie, FAN Jiaocun, and ZHANG Jinbo. MDL-AltMin: A hybrid precoding scheme for mmWave systems with deep learning and alternate optimization[J]. *IEEE Wireless Communications Letters*, 2022, 11(9): 1925–1929. doi: [10.1109/LWC.2022.3188167](https://doi.org/10.1109/LWC.2022.3188167).
- [19] YING Ming, CHEN Xiaoming, QI Qiao, *et al.* Deep learning-based joint channel prediction and multibeam precoding for LEO satellite internet of things[J]. *IEEE Transactions on Wireless Communications*, 2024, 23(10): 13946–13960. doi: [10.1109/TWC.2024.3406952](https://doi.org/10.1109/TWC.2024.3406952).
- [20] ZHANG Yuxin, WANG Xingwei, LUO Xuewen, *et al.* A survey on AI-empowered task-oriented sensing, communication, and computation in 6G networks[J]. *Computer Science Review*, 2026, 60: 100899. doi: [10.1016/j.cosrev.2026.100899](https://doi.org/10.1016/j.cosrev.2026.100899).
- [21] 李国权, 程涛, 郭永存, 等. 基于深度强化学习的IRS辅助认知无线电系统波束成形算法[J]. *电子与信息学报*, 2025, 47(3): 657–665. doi: [10.11999/JEIT240447](https://doi.org/10.11999/JEIT240447).
- LI Guoquan, CHENG Tao, GUO Yongcun, *et al.* Deep reinforcement learning based beamforming algorithm for IRS assisted cognitive radio system[J]. *Journal of Electronics & Information Technology*, 2025, 47(3): 657–665. doi: [10.11999/JEIT240447](https://doi.org/10.11999/JEIT240447).
- [22] 薛青, 来东, 徐勇军, 等. 基于分布式联邦学习的毫米波通信系统波束配置方法[J]. *电子与信息学报*, 2024, 46(1): 138–145.

- doi: [10.11999/JEIT221536](https://doi.org/10.11999/JEIT221536).
- XUE Qing, LAI Dong, XU Yongjun, *et al.* Beam configuration for millimeter wave communication systems based on distributed federated learning[J]. *Journal of Electronics & Information Technology*, 2024, 46(1): 138–145. doi: [10.11999/JEIT221536](https://doi.org/10.11999/JEIT221536).
- [23] DONG Hao, HUA Cunqing, LIU Lingya, *et al.* Intelligent reflecting surface-aided integrated terrestrial-satellite networks[J]. *IEEE Transactions on Wireless Communications*, 2023, 22(4): 2507–2522. doi: [10.1109/TWC.2022.3212049](https://doi.org/10.1109/TWC.2022.3212049).
- [24] GUIDOTTI A and VANELLI - CORALLI A. Clustering strategies for multicast precoding in multibeam satellite systems[J]. *International Journal of Satellite Communications and Networking*, 2020, 38(2): 85–104. doi: [10.1002/sat.1312](https://doi.org/10.1002/sat.1312).
- [25] SU Delong, LIU Lingya, XU Jing, *et al.* Multicast-aware user grouping for frame-based precoding in multibeam satellite systems[C]. ICC 2024 - IEEE International Conference on Communications, Denver, USA, 2024: 1855–1860. doi: [10.1109/ICC51166.2024.10622393](https://doi.org/10.1109/ICC51166.2024.10622393).
- [26] YOO T and GOLDSMITH A. On the optimality of multiantenna broadcast scheduling using zero-forcing beamforming[J]. *IEEE Journal on Selected Areas in Communications*, 2006, 24(3): 528–541. doi: [10.1109/JSAC.2005.862421](https://doi.org/10.1109/JSAC.2005.862421).
- [27] ZHANG Shuo, JIA Min, WEI Yuming, *et al.* User scheduling for multicast transmission in high throughput satellite systems[J]. *EURASIP Journal on Wireless Communications and Networking*, 2020, 2020(1): 133. doi: [10.1186/s13638-020-01749-7](https://doi.org/10.1186/s13638-020-01749-7).
- 郭李莉：女，博士生，研究方向为卫星组播波束成形、星间激光通信，邮箱 24110240026@m.fudan.edu.cn。
- 冯艺萌：女，博士后，研究方向为5G毫米波通信、天空地一体化网络，邮箱 ymfeng@fudan.edu.cn。
- 袁沛鸿：男，助理教授，研究方向为信息论、编码理论与应用概率。
- 高 跃：男，教授，研究方向为卫星互联网、5G/6G软件定义网络、压缩感知与机器学习、软件无线电。

责任编辑：余 蓉

LEO Satellite Multi-beam Multicast Precoding and User Grouping Joint Optimization Algorithm

GUO Lili FENG Yimeng YUAN Peihong GAO Yue

(Institute of Space Internet, Fudan University, Shanghai 200438, China)

Abstract:

Objective In 6G LEO communication, multicast precoding is utilized to mitigate the significant inter-beam interference introduced by Full Frequency Reuse (FFR). However, traditional precoding algorithms are hindered by cubic computational complexity, making them unsuitable for massive MIMO. Additionally, existing user grouping strategies often fail to meet the fixed group size requirements of the DVB-S2X standard. Therefore, a joint optimization scheme is developed to integrate a low-complexity unsupervised deep learning model for precoding with improved user grouping algorithms to enhance sum rate and fairness.

Methods To address the precoding challenge, an unsupervised deep learning model based on a hybrid CNN-LSTM architecture is proposed (Fig. 2). The Convolutional Neural Network (CNN) is utilized to extract spatial features from the Channel State Information (CSI), while the Long Short-Term Memory (LSTM) network captures their deep feature correlations. Unlike supervised learning, this model is trained by directly maximizing the sum rate as the loss function, subject to the Per-Antenna Constraint (PAC). For user grouping, two algorithms are developed to comply with the DVB-S2X standard. First, the CK-means algorithm is introduced, which modifies the standard K-means to ensure an equal number of users in each group. Second, FA-MAUG algorithm is proposed which prioritizes users with poor channel quality, thereby enhancing the overall robustness and fairness of the grouping result.

Results and Discussions The intra-group similarity metric is employed to evaluate user grouping performance, which indicate that the CK-means algorithm achieves a similarity score approximately 0.1 higher than the MAUG algorithm and nearly 0.5 higher than random grouping across various group sizes (Fig. 3). This high similarity translates directly into better beamforming gain. In terms of throughput, the sum rate of the CNN-

LSTM precoding combined with CK-means grouping outperforms traditional MMSE across different SNRs and total powers (Fig. 4, Fig. 5). The sum rate based on the proposed CNN-LSTM precoding scheme is on average 48.59% higher than that of the traditional MMSE algorithm and the gain of the CK-means algorithm compared to random grouping reaches 30.12% under different SNR conditions. Additionally, we analyzed the effects of the number of users per group, the number of groups, and the number of antennas on the system rate (Fig. 6, Fig. 7, Fig. 8), verifying the performance of the model in systems of different scales. Additionally, the complexity analysis confirms that the proposed precoding approach reduces the online overhead from the cubic level of traditional MMSE to a linear level relative to the number of antennas, which is critical for real-time deployment in massive MIMO satellite systems.

Conclusions This paper presents a joint optimization framework for LEO satellite multicast systems, addressing the dual challenges of high computational complexity in precoding and lack of fairness in user grouping. Simulation results demonstrate that the proposed solution significantly enhances the system sum rate—by over 48.59% in typical SNR scenarios—compared to traditional methods. The approach provides a robust and scalable solution for the coordinated management of multi-beam interference in future 6G satellite communications. Future work will further explore the impact of hardware impairments and highly dynamic channel conditions on the generalization capabilities of the proposed model.

Key words: LEO satellite communication; Multicast precoding; Unsupervised deep learning; User grouping; Per-antenna constraint