arXiv:2602.17011v1 [cs.MM] 19 Feb 2026

CAFE：用于稳健生物信号空间超分辨率的通道自回归因子化编码

Hongjun Liu [*1] **Leyu Zhou** [*1] **Zijianghao Yang** [1] **Rujun Han** [1] **Shitong Duan** [2] **Kuanjian Tang** [2] **Chao Yao** [2]

摘要

高密度生物信号记录对于神经解码和临床监测至关重要，但受硬件和运行条件限制，现实部署通常依赖低密度（LD）电极布局。这推动了从低密度观测中进行空间超分辨率重建，但稀疏且含噪的测量中存在的异质依赖关系，往往会导致伪影传播和错误的非局部相关性。为此，我们提出 CAFE，一种即插即用展开生成方案，通过几何对齐阶段重建完整导联布局。从 LD 通道开始，CAFE 首先恢复邻近通道，然后逐步扩展到更远的区域，在引入非局部交互之前充分利用可靠的局部结构。在训练过程中，我们对通道组实施逐步监督，并沿组维度采用结合 epoch 级计划采样的教师强制，以减少暴露偏差，从而实现各步骤间的并行计算。在测试时，CAFE 在各通道组之间执行自回归展开，同时通过复用任意时序骨干网络作为共享预测器，保持即插即用特性。在 4 种模态和 6 个数据集上的评估表明，CAFE 在 3 种骨干网络（多层感知机、卷积、Transformer）上展现出即插即用的通用性，并且重建效果始终优于 5 种具有代表性的基线方法。

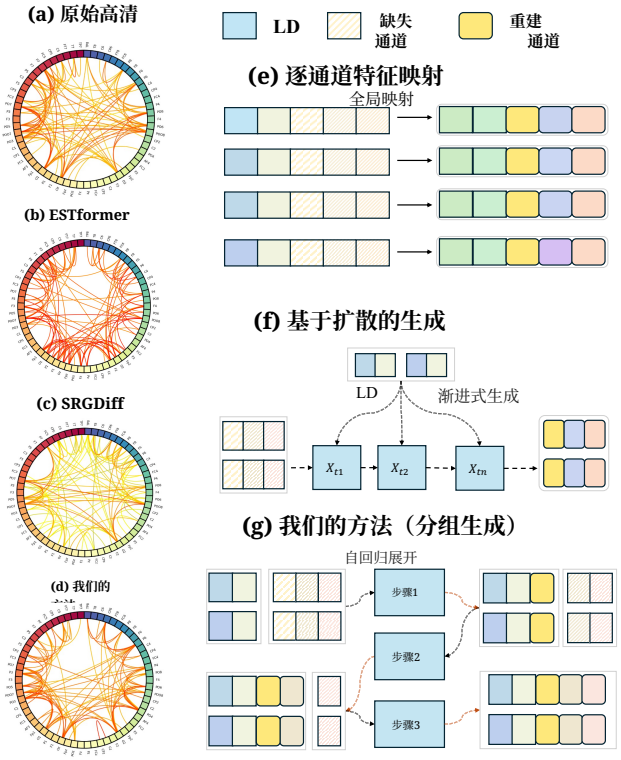

图*1.* **研究动机：异质通道拓扑。** 上：弦图展示了跨通道依赖关系（以脑电图为例）在不同传感器间存在异质性，较强的交互集中在特定功能区域内。下：通道处理策略的示意图对比。彩色方块表示通道及其特征；方形方块表示应用策略前的特征，圆角方块表示得到的表征。

1. 引言

多通道生物信号和传感器阵列，如脑电图（EEG）、肌电图（EMG）、心电图（ECG）和皮层脑电图（ECoG），能够提供丰富的非侵入式或微创测量神经和生理活动的测量，为神经科学和临床实践中的广泛应用提供支持，包括神经解码（Jiang 等人，2025年）、临床诊断（Liu 等人，2025年）和脑机接口（Yin 等人，2024）。然而，其空间分辨率先天受限于传感器的数量和布置，以及容积传导或相关场传播效应（Li 等人，2025）。拥有数百个通道的高密度（HD）系统虽可缓解这些问题，但成本高昂、部署繁琐，且长时间佩戴不舒适；相比之下，低密度（LD）配置（例如 4 或 8 个通道）实用得多，却存在严重的欠

[*]共同贡献 [1]北京科技大学智能科学与技术学院，北京，中国 [2]北京科技大学计算机与通信工程学院，北京，中国。通讯作者：Chao Yao <yaochao.ustb.edu.cn>。

预印本。*2026*年*2*月*20*日。

采样偏差（Wang 等人，2025b）。因此，从稀疏记录中重建高密度测量的空间超分辨率技术日益受到关注，成为面向真实世界脑机接口及更广泛多通道传感应用的一项关键工具。

现有的多通道空间超分辨率研究大致分为三类，如图1所示：(i) 插值方法（Dong 等人，2021年）利用空间先验估计缺失通道；(ii) 特征映射方法（Li 等人，2025年；Tang 等人，2023）直接根据低密度特征回归出高密度信号；(iii) 生成模型（Liu 等人，2026年；Wang 等人，2025b），包括生成对抗网络和基于扩散的模型，以低密度输入为条件生成高密度信号。尽管架构各不相同，这三类方法都采用了相似的跨通道依赖建模方案，其基础是全局稠密耦合：通道通过不受约束的全局注意力或完全连接的通道混合进行交互，使任一观测通道的信息都能直接影响任一重建通道。

然而，由于不良导联、运动伪影和接触不稳定，多通道生物信号通常是在稀疏观测且噪声不可忽略的情况下记录的（Mihajlovi´c 等人，2014年），导致各传感器的测量值不完整且不可靠。此外，跨通道依赖关系具有异质性：局部耦合往往更强且更稳定，而在稀疏观测下，非局部交互较弱且稳定性较差（Srinivasan 等人，2007年）（图1(a)）。**这启发了一种重建原则：模型不应一开始就对所有通道进行全局混合，而应逐步引入跨通道依赖，先利用可靠的局部结构，再纳入不确定性更高的非局部交互**。现有全局稠密耦合的一个关键局限在于，它通过不受约束的全局注意力或完整的通道混合一次性混合所有通道，因此无法控制何时利用哪些依赖关系。

为弥补这一空白，我们提出**CAFE**，一种用于生物信号空间超分辨率的即插即用展开方案，以由局部到全局的方式重建缺失通道。为
为满足这一约束，缺失通道按邻近程度分层划分为互不重叠的组，并相对于低密度锚点按由近及远的顺序排列。每一步中，骨干无关共享预测器将可见通道作为掩码条件导联输入，并输出全导联估计。训练期间，逐步监督仅对当前目标组计算损失，并通过教师强制构建逐步上下文，从而能够在展开步之间进行并行计算。为弥合训练与测试之间的差距，计划采样沿组维度混合真实值历史与模型生成历史。

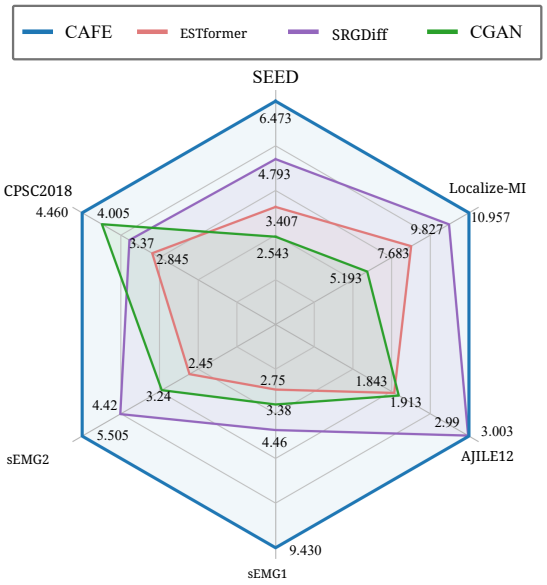

图 2. CAFE 的性能。结果（信噪比）为所有超分辨率缩放因子的平均值。CAFE 在 6 个常用数据集上优于强基线方法。

测试时，自回归展开会将先前预测的组反馈给共享预测器。总之，我们的主要贡献如下：

- 我们将空间超分辨率重新表述为通过结构化的下一组预测分解进行的分组条件生成。
- 我们提出一种具备拓扑感知能力的分组自回归解码调度：根据传感器间距离，将通道划分为几何一致组；随后按照距离顺序逐组重建，并通过多步细化使用单个共享预测器。
- 我们通过采用具有代表性的卷积神经网络、多层感知机和基于 Transformer 的超分辨率模型来实例化共享预测器，同时保持解码调度不变，证明了分组自回归展开与骨干网络无关。

2. 方法

2.1. 任务设定与符号说明

本文研究固定规范电极布局上的生物信号空间超分辨率，该布局包含 C_H 个通道和 T 个时间样本。令 $X^H \in \mathbb{R}^{C_H \times T}$ 表示对应的高密度（HD）信号。测试时，仅观测到一组低密度（LD）通道。LD通道的索引为 $\mathcal{L}$（其中 $|\mathcal{L}| = C_L$），缺失通道的索引为 $\mathcal{U}$，其中 $\mathcal{L} \cup \mathcal{U}$ 覆盖整个电极布局，且 $\mathcal{L} \cap \mathcal{U} = \varnothing$。令 $X_{\mathcal{L}} \in \mathbb{R}^{C_L \times T}$ 表示观测到的低密度记录，$X_{\mathcal{U}} \in \mathbb{R}^{(C_H - C_L) \times T}$ 表示未观测通道。

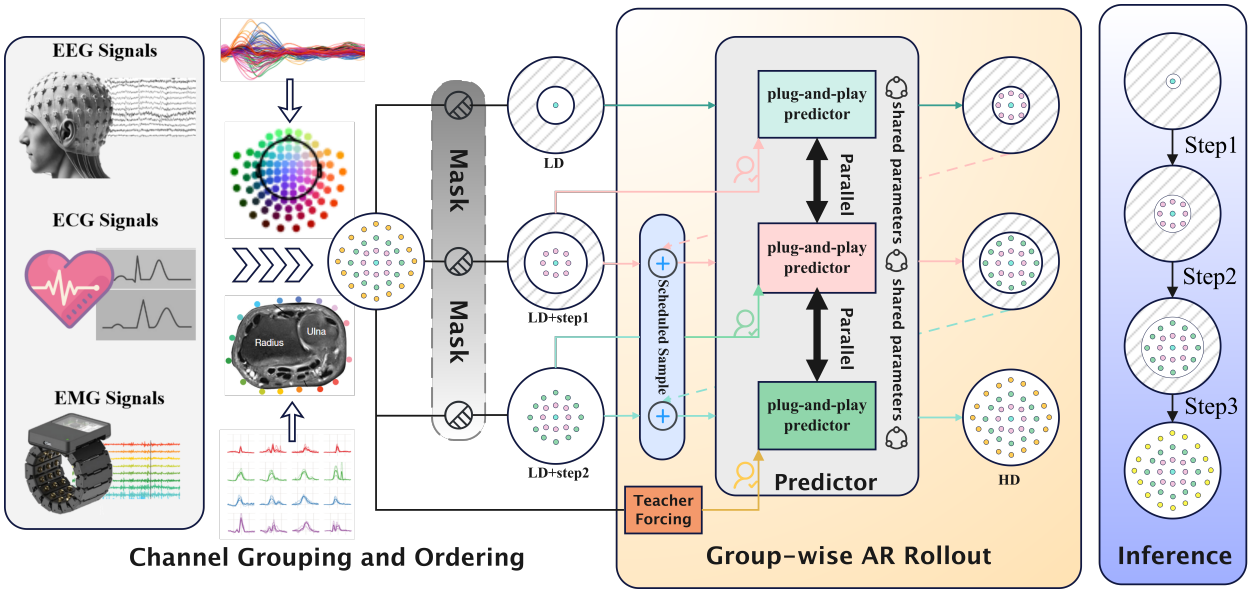

图 3. CAFE模型概览。

给定 $X_{\mathcal{L}}$，我们的目标是重建缺失通道 $\widehat{X}_{\mathcal{U}}$，并构建高密度估计 $\widehat{X}^{H} = \mathrm{Merge}(X_{\mathcal{L}}, \widehat{X}_{\mathcal{U}})$。

2.2. 通道分组与排序

为了控制每个预测步骤中暴露哪些跨通道依赖关系，并延后可能带有噪声的非局部交互，CAFE不会一次性重建所有缺失通道 $\mathcal{U}$。相反，CAFE将重建过程因子化为一系列几何引导预测步骤，每个步骤针对规范电极布局上的一个小型、按邻近程度分层的通道组。

给定规范电极坐标 $p_{i}{}_{i=1}^{C_H}$ 以及观测到的低密度通道的索引集合 $\mathcal{L} \subseteq 1, \ldots, C_H$，CAFE根据缺失通道与观测通道之间的欧氏距离对缺失通道进行分组。对于每个缺失通道 $u \in \mathcal{U}$，计算其到观测通道的平均距离：

$$d(u) = \frac{1}{|\mathcal{L}|} \sum_{\ell \in \mathcal{L}} \|p_u - p_\ell\|_2. \tag{1}$$

CAFE随后按$d(u)$升序对缺失通道集合 $\mathcal{U}$ 排序，并将排序后的列表划分为 G 个连续组，其中 G 表示展开深度，即预测步骤的数量。设排序后的缺失通道列表为$(u_{(1)}, \ldots, u_{(N)})$，其中 $N = |\mathcal{U}|$ 满足 $d(u_{(1)}) \leq \cdots \leq d(u_{(N)})$。为定义该划分，CAFE选取固定的分割比例 $0 < \beta_1 < \cdots < \beta_{G-1} < 1$，并为 $g = 1, \ldots, G-1$ 设置边界索引 $b_g = \lfloor \beta_g N \rfloor$，其中 $b_0 = 0$且 $b_G = N$。于是，第 g 个目标组即为以下连续区块

$$\mathcal{U}_g = \{u_{(i)} : b_{g-1} < i \leq b_g\}, \tag{2}$$

从而得到一个互不相交的划分 $\mathcal{U} = \biguplus_{g=1}^{G} \mathcal{U}_g$。在我们的实验中，我们采用较小且固定的展开深度 $G = 3$，并在各数据集上使用固定的分割比例 $\beta_1 = \frac{1}{6}$ 和 $\beta_2 = \frac{1}{2}$。

2.3. 分组自回归展开

给定有序的通道组 $\{\mathcal{U}_g\}_{g=1}^{G}$，CAFE 通过使用单个共享预测器 f_θ 并在各步重复使用它，进行 G 步展开来重建完整电极布局。自回归沿通道组维度进行，而非沿时间轴进行。核心思想是维护一个逐步单调扩大的可见集合：在第 g 步，预测器只能以观测到的 LD通道和先前步骤中重建的通道组为条件，而所有后续通道组仍保持隐藏。形式上，第 g 步的可见索引集合定义为

$$\mathcal{V}_g = \mathcal{L} \cup \bigcup_{k<g} \mathcal{U}_k, \tag{3}$$

并在规范电极布局上用二值掩码 $M_g \in \{0,1\}^{C_H}$ 对其进行编码，其中 $(M_g)_i = \mathbb{I}[i \in \mathcal{V}_g]$。

为了在 $\mathcal{V}_g$ 扩展时保持稳定且与通道对齐的特征空间，CAFE 在规范电极布局上运行，并维护一个组装后的全通道张量 $\widetilde{X}^{(g)} \in \mathbb{R}^{C_H \times T}$。该张量通过将观测到的LD通道置于规范通道顺序中，并将其余通道填零来初始化：

$$\widetilde{X}^{(0)}[i] = \begin{cases} X_{\mathcal{L}}[i], & i \in \mathcal{L}, \\ 0, & i \in \mathcal{U}. \end{cases} \tag{4}$$

在步骤 g，将掩码后的全电极布局输入构造为 $C_g = (M_g \mathbf{1}_T^\top) \odot \widetilde{X}^{(g-1)} \in \mathbb{R}^{C_H \times T}$，共享预测器生成全导联估计 $\widehat{X}^{(g)} = f_\theta(C_g)$。随后，通过写入当前

预测结果，仅更新目标组，同时保持其他所有通道不变：

$$\widetilde{X}^{(g)}[i] = \begin{cases} X_{\mathcal{L}}[i], & i \in \mathcal{L}, \\ \widehat{X}^{(g)}[i], & i \in \mathcal{U}_g, \\ \widetilde{X}^{(g-1)}[i], & \text{otherwise.} \end{cases} \tag{5}$$

经过 G 步后，最终的高密度估计为 $\widehat{X}^H = \widetilde{X}^{(G)}$。

$$\widehat{X}^H = \mathrm{Merge}(X_{\mathcal{L}}, \widehat{X}_{\mathcal{U}}) = \widetilde{X}^{(G)}. \tag{6}$$

训练和推理采用相同的展开过程，唯一的区别在于形成 C_g时如何提供 $\mathcal{U}_{<g}$ 上的历史信息。训练期间，采用教师强制和计划采样方案，根据真实值和模型预测构建 $\widetilde{X}^{(g-1)}$。推理期间，展开过程完全采用自条件化，$\widetilde{X}^{(g-1)}$仅包含锚点和先前步骤的预测。由于展开计划、掩码规则和逐步监督是在 f_θ之外定义的，因此任何能够将掩码条件化的规范电极布局映射为完整电极布局输出的时序骨干网络都可充当 f_θ，使该方案具备即插即用的特性。附录进一步对展开过程进行了形式化说明，并展示了随着可见集合的扩展，条件不确定性如何降低。

2.4. 使用教师强制和计划采样进行训练

目标函数。 训练仅监督每一步当前的目标组，在共享预测器的组级自回归展开中形成下一组重建目标。通过使用可用性掩码对组装后的电极布局进行掩码处理，可得到第 g 步的上下文 C_g；其中，$M_g \in \{0,1\}^{C_H}$ 沿时间轴广播，以匹配 $C_H \times T$ 的形状，而 $\odot$ 表示逐元素乘法。目标函数为

$$\min_{\theta} \mathbb{E}_{(X_{\mathcal{L}}, X^H)\sim\mathcal{D}} \left[\sum_{g=1}^{G} \left\| f_\theta(C_g)[\mathcal{U}_g] - X_{\mathcal{U}_g} \right\|_2^2 \right]. \tag{7}$$

教师强制。 为在预言机历史下训练每一步，上下文通过以下方式构造，其中包含真实历史组$X_{\mathcal{U}_{<g}}$：

$$\widehat{X}^{\mathrm{TF}(g)} = f_\theta(C_g^{\mathrm{TF}}), \qquad \widehat{X}^{\mathrm{TF}}_{\mathcal{U}_g} = \widehat{X}^{\mathrm{TF}(g)}[\mathcal{U}_g]. \tag{8}$$

这使 f_θ 在干净上下文下进行训练，并为每个组生成稳定的条件映射。

计划采样。 在测试时，C_g 必须由模型预测构建，这可能会引入暴露偏差。为在保持组间训练可并行化的同时近似这一条件，我们采用轮次级计划采样策略，并沿组维度实施。具体而言，我们维护一个逐样本缓存，其中保存上一轮预测的缺失组，记为 $\bar{X}^{(e-1)}_{\mathcal{U}_k}$；该缓存通过使用模型快照$\theta^{(e-1)}$ 执行一次自回归展开获得（即仅使用先前组的模型预测，$\pi = 0$）。

在第 e 个训练轮次，对于每个 $k < g$，我们采样 $z_{e,k} \sim$ 伯努利分布(π)，并构造混合历史：

$$\widetilde{X}^{(e)}_{\mathcal{U}_k} = z_{e,k}\, X_{\mathcal{U}_k} + (1 - z_{e,k})\, \bar{X}^{(e-1)}_{\mathcal{U}_k}. \tag{9}$$

使用 $\{\widetilde{X}^{(e)}_{\mathcal{U}_k}\}_{k<g}$ 构建 $C_g^{(e)}$，我们进行预测

$$\widehat{X}^{(e,g)} = f_\theta(C_g^{(e)}), \qquad \widehat{X}^{(e,g)}_{\mathcal{U}_g} = \widehat{X}^{(e,g)}[\mathcal{U}_g]. \tag{10}$$

由于缓存 $\bar{X}^{(e-1)}$ 相对于当前参数 θ是固定的，因此可以在前向传播之前构建所有上下文 $\{C_g^{(e)}\}_{g=1}^{G}$，并通过将 $\{C_g^{(e)}\}$ 沿批次维度堆叠，实现组间并行计算。完成第 e 个训练周期后，我们使用 $\theta^{(e)}$对 $\pi = 0$ 执行一次展开操作来刷新缓存，从而为下一个训练周期生成 $\bar{X}^{(e)}$。训练期间，我们使用固定的采样率 $\pi = 0.95$。推理时，使用 $\pi = 0$，且仅使用预测得到的前序组。

3. 实验

3.1. 实验设置

数据集。 为评估所提出的 CAFE 的有效性，我们在以下6 个公开可用的多通道生物信号数据集上评估我们的方法：两个高密度脑电图基准数据集（**SEED**、**Localize-MI**）；两个用于离散手势和手写识别的高密度**表面肌电图**数据集（Kaifosh&Reardon，2025年）；**AJILE12**颅内皮层脑电图语料库（Peterson 等人，2022年）；以及一个 12 导联心电图数据集（**CPSC2018**）。详细的数据集描述和预处理方案见附录。

实验设置。 对于每个数据集，我们采用多个上采样因子（SEED：$2/4/8\times$；Localize-MI：$2/4/8/16\times$；AJILE12：$2/4/8\times$；表面肌电图：$2/4\times$；CPSC2018：$4/12\times$），每种因子选取 C_{HD}/s 个观测通道，并将其余通道视为缺失。我们遵循 SRGDiff 和 ESTformer 的评估协议，使用四种预定义的低密度通道布局，以最大化空间覆盖范围。为确保公平比较，所有方法均在相同的四种布局上进行评估。除非另有说明，否则报告四种布局和测试受试者的平均结果（详细设置见附录）。CAFE 的超参数设置汇总于附录。

指标。 CAFE 从三个互补层面评估空间超分辨率质量。**信号保真度：** 相对于高密度参考信号的归一化均方误差、皮尔逊相关系数和重建信噪比。**特征与频谱**

表1. CAFE 通过通道组自回归（AR）展开，在不同架构上提升单次重建效果。“Orig”表示一次性全导联输出，“+AR”应用 CAFE 展开，而“增益”表示从 Orig 到 +AR 的相对变化（%）。

模型	指标	SEED			Localize-MI			AJILE12			sEMG1			sEMG2			CPSC2018		
		原始	+自回归	增益↑	原始	+自回归	增益↑	原始	+自回归	增益↑	原始	+自回归	增益↑	原始	+自回归	增益↑	原始	+自回归	增益↑
Conv	归一化均方误差↓	0.18	0.12	33%	0.024	0.016	33%	0.34	0.33	3%	0.20	0.17	15%	0.10	0.08	20%	0.41	0.41	0%
	PCC↑	0.86	0.93	8%	0.96	0.98	2%	0.80	0.83	4%	0.91	0.92	1%	0.96	0.97	1%	0.69	0.71	3%
	SNR↑	6.98	9.04	30%	16.12	17.91	11%	4.66	5.01	8%	6.90	7.63	11%	9.94	10.81	9%	3.76	3.87	3%
MLP	归一化均方误差↓	0.24	0.14	42%	0.042	0.024	43%	0.47	0.35	26%	0.35	0.35	0%	0.14	0.09	36%	0.49	0.47	4%
	PCC↑	0.85	0.88	4%	0.96	0.96	0%	0.73	0.81	11%	0.81	0.81	0%	0.94	0.96	2%	0.60	0.61	2%
	SNR↑	6.12	8.19	34%	13.73	16.17	18%	3.26	4.94	52%	4.54	4.59	1%	8.47	10.23	21%	3.09	3.24	5%
Trans	归一化均方误差↓	0.22	0.14	36%	0.034	0.022	35%	0.45	0.35	22%	0.35	0.33	6%	0.13	0.08	38%	0.48	0.47	2%
	PCC↑	0.86	0.88	2%	0.97	0.97	0%	0.74	0.81	9%	0.81	0.82	1%	0.94	0.97	3%	0.61	0.62	2%
	SNR↑	6.50	8.24	27%	14.63	16.56	13%	3.43	4.90	43%	4.51	4.75	5%	8.71	10.73	23%	3.10	3.27	5%

保真度：使用冻结的 EEGNet 计算 EEG-FID，该模型经过训练在每个数据集的训练划分上，并采用基于短时傅里叶变换功率谱的频域失真指标（Spec-MAE）。频域失真指标（Spec-MAE）。
下游效用：SEED 上被试依赖情绪识别的准确率以及癫痫二分类的准确率，基于Localize-MI。除非另有说明，平均结果均为受试者和LD布局上的结果，并列于主表中。指标定义和实现细节见附录。

3.2. 自回归滚动比较

鉴于面向多通道空间超分辨率的分组自回归生成相对新颖，我们对其有效性的影响因素进行了系统分析。具体而言，我们考察了：(i) 在具有代表性的骨干网络家族之间的泛化能力，(ii) 重建顺序的作用，(iii) 不同展开方案对暴露偏差的缓解效果，以及 (iv) 通道组大小（即自回归步长）所带来的权衡。

3.2.1. 骨干网络泛化

我们提出的组级自回归展开被纳入了三种常用于空间超分辨率的代表性架构：（i）深度可分离卷积编码器（**卷积**），（ii）采用逐通道位置编码的轻量级多层感知机（**多层感知机**），以及（iii）标准时间序列变换器（**Transformer**）。这项实验旨在区分性能提升究竟源于结构化解码因子分解本身，还是骨干网络特有的归纳偏置。对于每种骨干网络，均报告原始模型、自回归增强模型在 NMSE、PCC 和 SNR 上的表现，以及相对提升幅度（增益）。为使提升更为直观，对于数值越低越好的指标，增益按$(m_{\text{orig}} - m_{\text{AR}})/m_{\text{orig}}$计算。表1 显示，自回归展开在三类骨干网络中均能持续提升重建质量，其中最大相对增益出现在高密度模态上，表明当存在丰富的空间结构时，结构化依赖扩展尤其有益。CPSC2018 上的增益较小，这可能是因为心电图导联被定义为电极对之间的电压差，导致通道间的空间耦合较弱且一致性较低。

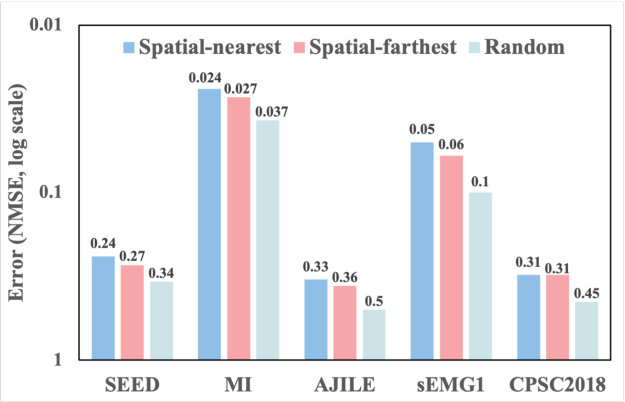

图4. 组级自回归重建中解码顺序的影响。

3.2.2. 重建顺序

我们的方法认为，性能增益来自拓扑感知渐进式条件化，而非仅仅来自自回归。因此，如果顺序是一个因果因素，那么反转或随机调整组的顺序应会明显降低性能；否则，结果应基本不受顺序影响。因此，我们通过比较以下方式来评估顺序敏感性：(i) 由近及远 的调度，按从最近到最远的顺序重建各组；(ii) 由远及近的反向调度；以及 (iii) 随机调度，即对组顺序进行均匀随机打乱。图 4 显示，由近及远的顺序始终能得到最低的归一化均方误差，而由远及近和随机调度则会降低性能。这支持了我们的假设：过早地

让预测器接触不可靠的远距离依赖关系，会在稀疏观测下加剧误差传播；相比之下，从可靠的局部组逐步扩展上下文，能够为后续的远距离组提供条件更好的输入。附录提供了各数据集上累积误差的补充证据。

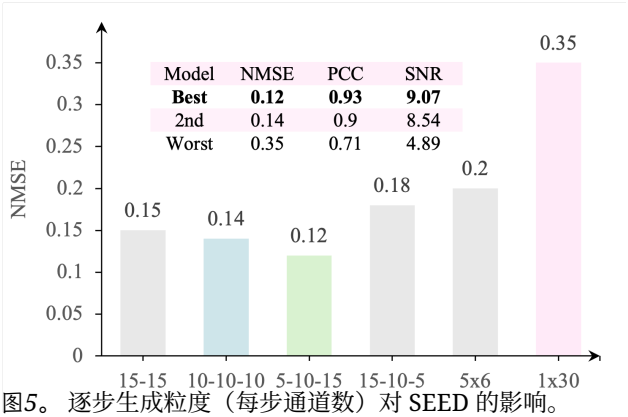

图*5*。 逐步生成粒度（每步通道数）对 SEED 的影响。

3.2.3. 逐步生成粒度

CAFE 采用多步解码，较早预测的分组会成为后续步骤上下文的一部分。因此，步长决定了一项根本性的权衡：较小的分组可降低逐步不确定性，但会增加逐步生成长度和误差累积；较大的分组则会缩短解码链，却会削弱渐进式条件化的效果。因此，在保持重建通道总数不变的情况下，我们改变了每步生成的通道数。如图 5所示，适中的三步方案（5–10–15）取得了最佳的归一化均方误差。采用 1×30 进行极细粒度解码时，表现较差，因为它需要进行 30 步逐步生成，每步预测一个通道，使重建对累积误差和暴露偏差高度敏感。相较于 5×6，此类逐步生成方案的表现也有所下降；3 步时，较长的解码链仍会累积中间误差。其他数据集上也呈现出相同趋势，结果见附录。

3.2.4. 展开方案

由于 CAFE 采用多步解码，训练上下文（真实值与预测历史）会直接决定暴露偏差的严重程度以及展开稳定性。本文评估了以下三种方案：（i）完全教师强制，即以真实历史组为条件；（ii）计划采样，即混合真实值组与模型生成组，以部分匹配推理阶段；以及（iii）纯展开训练，即始终以模型预测为条件。图7显示，随着序列链增长，纯滚动很快变得不稳定，表明将不完美的早期组反馈为上下文会导致误差大量累积；而教师强制虽然保持稳定，却受到

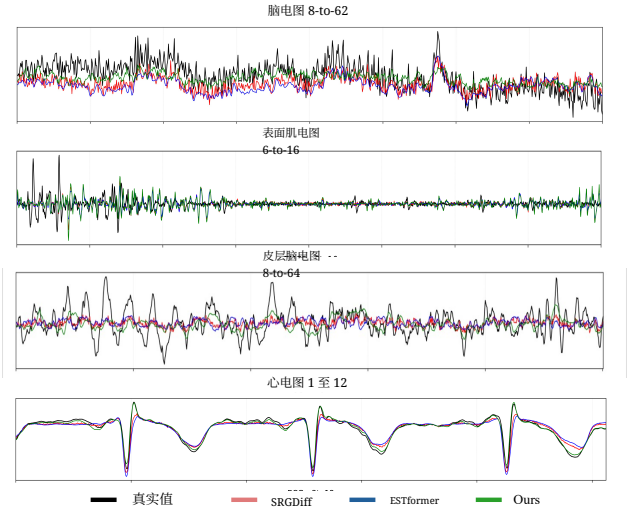

图*6.* 不同模态和方法的定性重建比较。

训练–测试不匹配。计划采样提供了一种折中方案，通过减少这种不匹配，显著提升了展开稳定性。

3.3. 基线比较

3.3.1. 基线方法

CAFE 与具有代表性且竞争力强的基线方法进行比较，这些方法涵盖了（i）多通道生物信号空间超分辨率的主要建模范式，以及（ii）广泛使用的时间序列重建范式。对于生物信号超分辨率，基线方法包括 **ESTformer** (Li 等人，2025年)（基于Transformer的超分辨率）、**SRGDiff** (Liu 等人，2026年)（基于扩散的超分辨率）和**CGAN** (Zhan 等人，2024年)（基于生成对抗网络的超分辨率）。为与更广泛的时间序列研究相衔接，我们还报告了一种基于图的多变量重建方法**GRIN** (Cini 等人，2022年)，以及一种强大的时间序列骨干网络，**TimeMixer++** (Wang 等人，2025a)，并将其作为直接的全电极阵列预测器，在相同的输入/输出协议下进行实例化。所有方法均采用相同的预处理、数据划分和输入长度进行训练与评估，且超参数均在同一验证集上调优。实现细节见附录。

3.3.2. 主要结果

表2 总结了在 6个数据集和多个上采样因子下的跨受试者通道超分辨率。 **CAFE** 始终实现最强的信号级重建效果，而且随着上采样因子增大，其优势进一步扩大，表明当观测值变得更稀疏、条件信息更弱时，模型仍具有更强的鲁棒性。在基线方法中，基于扩散的 SRGDiff 是高上采样因子下最强的竞争方法；然而，随着条件信息变得更加稀疏，它与 CAFE 的性能差距也随之扩大，这表明

表2. 6个多通道生物信号数据集上的跨受试者通道超分辨率结果（归一化均方误差/皮尔逊相关系数/信噪比）。

		SEED			Localize-MI				AJILE12			sEMG1		sEMG2		CPSC2018	
方法	指标	2×	4×	8×	2×	4×	8×	16×	2×	4×	8×	2×	4×	2×	4×	4×	12×
GRIN	归一化均方误差	0.40	0.43	0.54	0.07	0.13	0.19	0.27	0.56	0.81	0.92	0.55	0.75	0.43	0.65	0.53	0.79
	PCC	0.76	0.72	0.66	0.93	0.91	0.89	0.80	0.65	0.56	0.23	0.67	0.55	0.75	0.60	0.68	0.57
	SNR	4.06	3.58	2.79	12.13	8.57	6.82	5.53	2.57	0.89	0.43	2.63	1.92	3.39	1.76	2.72	1.16
CGAN	归一化均方误差	0.48	0.53	0.67	0.14	0.28	0.41	0.49	0.43	0.75	0.82	0.38	0.55	0.38	0.58	0.36	0.43
	PCC	0.73	0.70	0.65	0.88	0.79	0.77	0.72	0.73	0.51	0.40	0.79	0.67	0.79	0.65	0.78	0.73
	SNR	3.16	2.74	1.73	8.41	5.46	3.83	3.07	3.64	1.24	0.86	4.18	2.58	4.15	2.33	4.39	3.62
TimeMixer++	归一化均方误差	0.55	0.64	0.72	0.17	0.29	0.41	0.53	0.76	0.89	0.95	0.61	0.83	0.68	0.87	0.66	0.85
	PCC	0.64	0.57	0.51	0.91	0.84	0.77	0.66	0.49	0.32	0.21	0.65	0.39	0.57	0.33	0.56	0.36
	SNR	2.62	2.05	1.49	8.16	5.37	3.76	2.41	1.17	0.58	0.31	2.31	0.86	1.52	0.64	1.77	0.79
ESTformer	归一化均方误差	0.44	0.47	0.56	0.09	0.16	0.22	0.28	0.46	0.72	0.85	0.44	0.63	0.47	0.68	0.44	0.61
	PCC	0.74	0.72	0.65	0.95	0.92	0.88	0.85	0.74	0.53	0.38	0.75	0.62	0.73	0.58	0.75	0.63
	SNR	3.95	3.54	2.73	10.44	8.08	6.58	5.63	3.40	1.43	0.70	3.52	1.98	3.25	1.65	3.55	2.14
SRGDiff	归一化均方误差	0.27	0.38	0.45	0.04	0.06	0.19	0.23	0.36	0.65	0.73	0.26	0.49	0.27	0.48	0.40	0.52
	PCC	0.80	0.72	0.69	0.96	0.93	0.90	0.86	0.80	0.59	0.52	0.87	0.71	0.86	0.71	0.75	0.67
	SNR	5.69	4.57	4.12	13.65	12.15	7.21	6.30	4.89	1.97	1.39	5.83	3.09	5.67	3.17	3.93	2.81
CAFE	归一化均方误差	**0.12**	**0.24**	**0.37**	**0.02**	**0.04**	**0.14**	**0.20**	**0.33**	**0.59**	**0.67**	**0.05**	**0.23**	**0.19**	**0.41**	**0.31**	**0.41**
	PCC	**0.91**	**0.87**	**0.75**	**0.98**	**0.94**	**0.91**	**0.89**	**0.83**	**0.63**	**0.56**	**0.96**	**0.87**	**0.89**	**0.76**	**0.83**	**0.76**
	SNR	**9.07**	**6.15**	**4.20**	**15.32**	**13.18**	**8.54**	**6.79**	**5.01**	**2.10**	**1.90**	**12.56**	**6.30**	**7.20**	**3.81**	**5.06**	**3.86**

表 3. SEED、Localize-MI 和 AJILE12 上重建的真实高密度拓扑图与真实高密度拓扑图之间的频域平均绝对误差。

模型	参考	SEED			Localize-MI ($\times 10^{-7}$)				AJILE12		
		2×	4×	8×	2×	4×	8×	16×	2×	4×	8×
GRIN	ICLR 2022	0.827	0.856	0.883	0.347	0.615	0.832	0.953	0.572	0.748	0.983
CGAN	NeurIPS 2024	0.474	0.497	0.518	0.113	0.517	0.633	0.763	0.287	0.519	0.746
TimeMixer++	ICLR 2025	1.372	1.528	1.753	0.434	0.976	1.361	1.832	0.756	0.947	1.462
ESTformer	KBS 2025年	0.511	0.520	0.613	0.145	0.550	0.777	0.823	0.392	0.589	0.849
SRGdiff	ICLR 2026	0.376	0.433	0.452	0.108	0.413	0.592	0.716	0.257	0.431	0.529
CAFE	Ours	**0.28**	**0.35**	**0.266**	**0.028**	**0.074**	**0.087**	**0.143**	**0.186**	**0.378**	**0.462**

仅靠随机去噪不足以确保依赖关系扩展与拓扑结构保持一致。表3 提供了补充性的频域证据：在所有尺度下，CAFE 的 Spec-MAE 都显著更低（例如，SEED 2×：0。28 对比 0。376–0。511；Localize-MI($\times 10^{-7}$) 2×：0。028 对比 0。108–0。145），说明这些改进不仅体现在波形保真度上，也体现在对时空频组织的更好保留上。在跨布局和不规则电极泛化场景下，CAFE 的鲁棒性显著更强；在这些场景中，训练与测试传感器布局并不相同，这表明所提出的拓扑感知滚动展开不会过拟合特定的缺失模式。通过向低密度锚点注入高斯噪声，进一步评估了模型对含噪低密度观测值的鲁棒性；随着噪声增大，CAFE 仍是最稳定的方法，其性能退化程度小于其他竞争基线方法。

3.3.3. 可视化结果

我们可视化了 Localize-MI 上不同方法的频域地形图（图8）。与高密度参考相比，CAFE 在空间定位和极性方面更加吻合，而 ES-Tformer 和 CGAN 则更常出现偏移或过度平滑的模式。SRGDiff 整体表现稳定，但在更精细的空间组织方面可能存在偏差。SEED 和 Localize-MI 上的完整地形图可视化见图8。此外，不同模态的定性时域波形对比见图6。与其他基线相比，CAFE 更忠实地保留了峰值时序和振幅动态，同时减少了伪振荡，从而生成更加平滑但不会过度阻尼的重建信号。更多示例见附录。

3.3.4. 下游层级比较

不同超分辨率因子下的下游准确率汇总于附录中。这些下游任务是功能性探测，用于评估重建信号除波形级保真度外，是否还保留了与任务相关的判别结构。随着上采样因子增大，所有方法的准确率均有所下降，但 CAFE 的降幅始终较小，表明其对

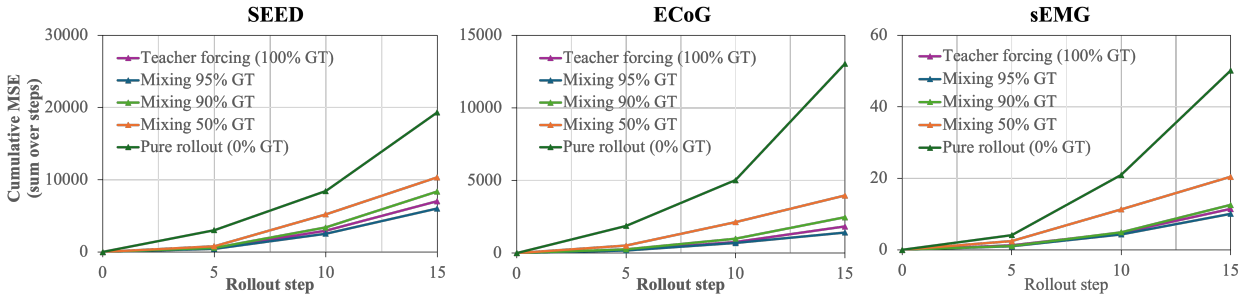

图7. SEED、皮层脑电图和表面肌电图上分组滚动的训练上下文消融。我们绘制了截至滚动步的累积归一化均方误差，分别对应教师强制（100% 真实值）、计划采样（混合真实值）和纯滚动（0% 真实值）。数值越低越好。g（$\sum_{i=1}^{g}$归一化均方误差$_i$）

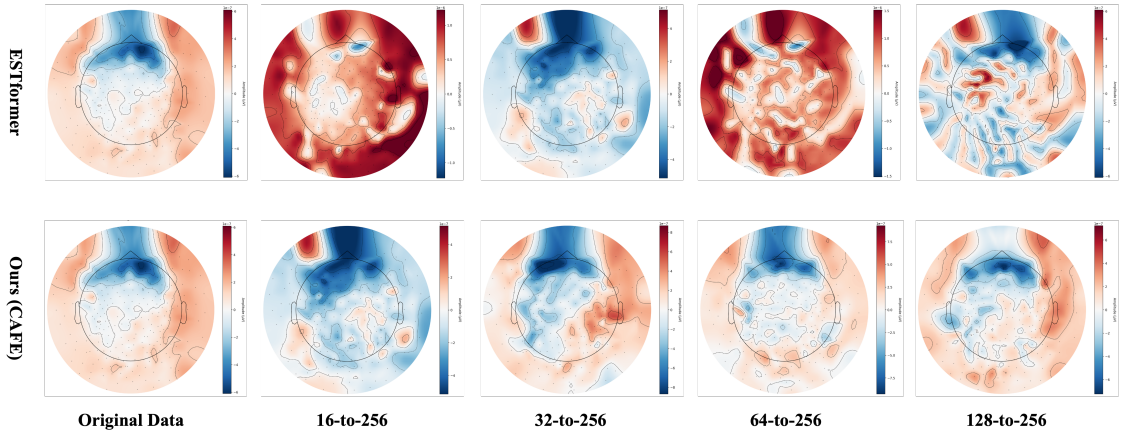

图8. 两个代表性示例的 Localize-MI 频谱地形图可视化。各列依次显示高密度参考信号，以及在相同超分辨率设置下由 ESTformer、SRGDiff、CGAN 和 CAFE 得到的重建信号。

通过分组滚动减轻稀疏误差的影响。在高密度 SEED 数据集上，这一优势在较大的因子下尤为明显：在8×时，CAFE 达到 0.58，而最强的基线方法为 0.53，表明在通道稀疏性严重时，CAFE 能更好地保留分类模式。

3.3.5. 效率比较。

我们从可训练参数、GFLOPs 以及完成完整重建所需的实际运行延迟等方面比较推理效率。CAFE 采用轻量级卷积预测器，报告的 GFLOPs 和延迟均为端到端数值，并对所有 G 前向传播进行求和。GFLOPs 在 4s 输入窗口下计算，缺失设置与主要实验相同。延迟（ms）是在 RTX4090 上测得的每个样本平均端到端时间，输入长度固定，并对 100 次运行取平均值。如表4所示，CAFE 的总计算量最低（1.38 GFLOPs），端到端延迟最快（3.92 ms），且可训练参数（2.34M）显著少于其他基线方法。

表4. 不同超分辨率模型的计算成本和运行时间。

方法	参数量（M）	GFLOPs	运行时间（ms）
SRGDiff	20.421	5.439	92.541
ESTformer	12.111	4.302	5.039
CGAN	39.309	6.093	134.106
GRIN	0.079	14.803	657.573
TimeMixer++	2.913	2.042	6.436
CAFE	2.342	1.380	3.922

4. 结论

在本研究中，我们提出了一种名为 CAFE 的即插即用生物信号空间超分辨率框架。该框架对现有骨干网络施加分组、逐步生成约束，以沿空间维度进行分组自回归展开，取代一次性重建。通过采用共享预测器、掩码规范输入和下一组监督，CAFE 在多种模态和数据集上，始终能够提升缺失通道重建质量，并增强模型在通道稀疏性严重时的鲁棒性；同时，它的计算效率很高，GFLOPs 较低，且可训练参数少于表现强劲的基线方法。

影响声明

本文旨在推动机器学习领域的发展。我们的工作可能会带来许多社会影响，但我们认为没有哪一项需要在此特别强调。

参考文献

Cini, A.、Marisca, I.与Alippi, C. 填补空白：基于图神经网络的多元时间序列插补。见国际学习表征会议，2022年。

Dong, L.、Zhao, L.、Zhang, Y.、Yu, X.、Li, F.、Li, J.、Lai, Y.、Liu, T.与Yao, D. 参考电极标准化插值技术（RESIT）：一种用于头皮脑电图的新型插值方法。《脑地形图》，34(4):403–414，2021年。Jiang, W.、Wang, Y.、Lu, B.-l.与Li, D. Neurolm：一种用于弥合语言与脑电信号之间差距的通用多任务基础模型。见第十三届国际学习表征会议，2025年。Kaifosh, P.与Reardon, T. R. 一种用于人机交互的通用非侵入式神经运动接口。《自然》，645(8081):702–711，2025年。Li, D.、Zeng, Z.、Wang, Z.与Yang, H. ESTformer：利用时空依赖关系进行脑电图超分辨率的Transformer。《知识系统》，317:113345，2025年。Liu, H.、Yao, C.、Zhang, Y.、Wang, X.与Ban, X. 空间插补驱动脑电图分类的跨域对齐。见第*33*届*ACM*国际多媒体会议论文集，第8586–8595页，2025年。Liu, H.、Zhou, L.、Yang, Z.与Yao, C. 面向脑电图空间超分辨率的步感知残差引导扩散。第十四届国际学习表征会议，2026年。Mihajlovi´c, V.、Patki, S.与Grundlehner, B. 头部运动对脑电图与接触阻抗的影响：一种用于运动伪迹消除的自适应滤波方案。见*2014*年第*36*届*IEEE*医学与生物学工程学会国际年会，第5064–5067页。IEEE，2014年。

Peterson, S. M.、Singh, S. H.、Dichter, B.、Scheid, M.、Rao, R. P. 和Brunton, B. W. AJILE12：长期自然状态下的人类颅内神经记录与姿态。《科学数据》，9(1):184，2022年。

Srinivasan, R.、Winter, W. R.、Ding, J. 和Nunez, P. L. 脑电图和脑磁图相干性：新皮层动力学不同空间尺度上的功能连接测量。《神经科学方法杂志》，166(1):41–52，2007年。

Tang, Y., Chen, D., Liu, H., Cai, C., 和 Li, X. 通过关联脑结构与功能连接实现深度脑电超分辨率。*IEEE* 控制论汇刊，53(7):4410–4422，2023年。

Wang, S., Li, J., Shi, X., Ye, Z., Mo, B., Lin, W., Ju, S., Chu, Z., 和 Jin, M. Timemixer++：一种用于通用预测分析的通用时间序列模式机器。发表于国际学习表征会议，2025a。

Wang, S., Zhou, T., Shen, Y., Li, Y., Huang, G., 和 Hu, Y. 生成式人工智能通过时空自适应扩散学习实现脑电图超分辨率。*IEEE* 消费电子汇刊，71(1):1034–1045，2025b。Yin, K., Lim, E. Y., 和 Lee, S.-W. Gitgan：用于脑电图运动想象分析的生成式跨受试者迁移。模式识别，146:110015，2024。ISSN 0031-3203。Zhan, Z., Chen, J., Li, K., Huang, L., Xu, L., Bian, G.-B., Millham, R., de Albuquerque, V. H. C., 和 Wu, W. 由条件生成对抗网络驱动的可变时长单导联至12导联心电图重建。生物医学信号处理与控制，95: 106377，2024。