

一种面向高动态网络的因果增强 时空图预测模型

张家畅, 霍永华, 张立斌

(中国电子科技集团公司 第五十四研究所, 石家庄 050081)

摘要: 针对高动态环境下网络链路质量预测的问题, 提出了一种状态聚类引导的因果时空图卷积网络架构 Causal-Clustered STGCN; 突破了基于形状相似性的时序状态划分、状态特异的因果图构建, 以及因果约束下的时空特征聚合等关键技术, 实现了对网络运行模式的自适应感知与跨物理连接的隐性依赖捕捉; 核心思想是通过 K-shape 聚类将连续状态划分为典型模式, 并在各状态内部基于因果检验构建有向加权因果图, 以取代传统物理拓扑作为图卷积的空间先验, 使特征聚合严格遵循因果路径; 实验基于 SynthSoM 数据集, 在标准场景下预测精度较最优基线提升 6.7%, 并在复杂场景中保持优势。

关键词: 图神经网络; 因果图; 链路质量; K-shape 聚类; 高动态网络

A Causally Enhanced Spatio-Temporal Graph Prediction Model for Highly Dynamic Networks

ZHANG Jiachang, HUO Yonghua, ZHANG Libin

(The 54th Research Institute, China Electronics Technology Group Corporation, Shijiazhuang 050081, China)

Abstract: To address the challenge of predicting network link quality in highly dynamic environments, a state-clustering-guided causal spatio-temporal graph convolutional network architecture, Causal-Clustered STGCN, is proposed, which makes breakthroughs in key technologies such as time-series state partitioning based on shape similarity, state-specific causal graph construction, and spatio-temporal feature aggregation under causal constraints, thereby adaptively perceiving network operation modes and capturing hidden dependencies across physical connections. The core idea is to divide continuous states into typical patterns via K-shape clustering and to construct the directed, weighted causal graphs based on causal tests within each state. These causal graphs replace the traditional physical topology as the spatial prior for graph convolution, ensuring that feature aggregation strictly follows causal pathways. Experiments on the SynthSoM dataset demonstrate that compared with the optimal baseline model, the proposed model improves the prediction accuracy by 6.7% in standard scenarios and maintains its advantage in complex scenarios.

Keywords: graph neural network; causal graph; link quality; K-shape clustering; highly dynamic networks

0 引言

网络链路质量预测是网络性能管理、资源优化和故障诊断的关键技术, 对保障网络服务质量 (QoS) 具有重要意义^[1]。然而, 链路质量在高动态网络环境中表现出剧烈的波动性和不确定性。具体而言, 此类环境表现出以下几个显著特征: 1) 网络拓扑持续快速变化, 节

点间的连接关系频繁建立和断裂, 导致有效通信时间窗口极短; 2) 无线信道质量波动频繁, 信号衰减、多径效应、多普勒频移等现象显著, 使得链路信噪比等关键参数在短时间内可能发生明显剧烈; 3) 网络中存在大量瞬时出现的弱连接, 这些连接虽然通信质量较差, 却可能承载关键的控制信令或路由信息。

这种动态性给链路质量预测带来了巨大挑战。传统

收稿日期: 2025-12-19; 修回日期: 2025-12-30。

作者简介: 张家畅 (1998-), 男, 硕士研究生。

通讯作者: 霍永华 (1977-), 女, 硕士, 正高级工程师。

引用格式: 张家畅, 霍永华, 张立斌. 一种面向高动态网络的因果增强时空图预测模型[J]. 计算机测量与控制, 2026, 34(2): 104

- 110.

的基于历史平均或简单回归的预测方法难以捕捉毫秒级的质量波动, 而基于固定拓扑的图神经网络也无法适应连接关系的快速变化。最具挑战的是高动态环境中的链路质量往往表现出强烈的非平稳特性, 其统计特征随时间快速演变, 使得基于平稳性假设的预测模型往往在高动态链路质量预测这一领域取得的效果平平。在这种情况下, 准确预测链路质量不仅关系到数据传输的可靠性, 更直接影响网络的拓扑维护、路由选择和资源分配等关键功能。例如, 在车联网安全应用中, 对链路质量的准确预测可以帮助系统提前发现潜在的通信中断风险, 为紧急制动、碰撞预警等安全关键应用提供至关重要的决策时间。

近年来, 研究者们通过融合图神经网络 (GNN) 与循环神经网络 (RNN) 为网络链路质量预测领域提供了新的思路^[2]。对于通信网络这种抽象图结构来说, 图神经网络相较于其他深度学习模型更具备优势, 同时结合时序神经网络能够兼顾网络中的空间拓扑特征与时间动态演化, 有效地提升了链路质量的预测精度^[3]。故而涌现了许多基于图神经网络的模型^[4-9]用于处理时空序列预测任务。

尽管在各领域的性能提升明显, 但基于图神经网络的模型在处理网络领域问题时仍有不足之处, 比如链路质量表现出来的诸如高时延、高丢包这种特征并不仅仅由路由拓扑决定, 而是受到了多种因素如无线干扰、拥塞传播、环境变化的干扰。因此在图卷积特征输入过程中, 对于依靠物理拓扑而构建的邻接矩阵强制聚合了大量无关甚至误导性的邻居特征, 不仅无法有效利用空间依赖性, 反而削弱了模型的泛化能力和可解释性。另一方面, 同样也无法感知并聚合那些虽无直接连接但通过共享干扰、竞争资源等方式对目标链路产生隐性影响的节点信息。因此, 聚焦于如何更精准、更合理地定义图

结构, 超越简单的物理连通性, 探索并构建能够真实反映节点间内在动态影响机制的图模型, 成为提升预测性能的关键挑战, 也是一个富有潜力的进步方向^[10-13]。

为应对高动态网络环境中拓扑剧变与链路不稳定的核心挑战, 本文提出了一种基于状态聚类与因果推理的链路质量预测方案, 核心思想是通过状态聚类与因果推理的深度融合, 对传统 STGCN 进行改进。

1 基于状态聚类与因果推理的链路质量预测方案设计

1.1 模型整体架构

本文提出的 Causal-Clustered STGCN (CC-STGCN) 模型整体架构如图 1 所示。模型首先在离线通过 K-shape 聚类将历史时序划分为若干状态模式, 并为每个状态构建基于信息流检验的因果图; 实际预测时, 模型根据当前数据匹配最相似的状态并调用对应的因果图, 以此驱动 STGCN 进行时空特征聚合与链路质量预测。使模型能自适应网络状态变化, 并确保信息沿因果路径传播, 从而提升预测准确性与可解释性。以下各小节分步解释具体模型设计原理。

1.2 K-shape 聚类

从原始高维时序数据中提取本质的链路状态模式, 采用 K-shape 聚类算法对链路与时序特征进行状态划分与抽象。整个过程以每条链路和每个节点的连续时序观测作为输入。首先, 通过计算归一化互相关系数 (NCC, normalized cross-correlation) 来量化每两个时序序列 $X = (x_1, \dots, x_T)$ 和 $Y = (y_1, \dots, y_T)$ 在形状上的相似度, 公式如下:

$$NCC_c(x, y) = \frac{\sum_{t=1}^{T-c} (x_{t+c} - \bar{x})(y_t - \bar{y})}{\sum_{t=1}^T \sqrt{(x_t - \bar{x})^2} \sum_{t=1}^T \sqrt{(y_t - \bar{y})^2}} \quad (1)$$

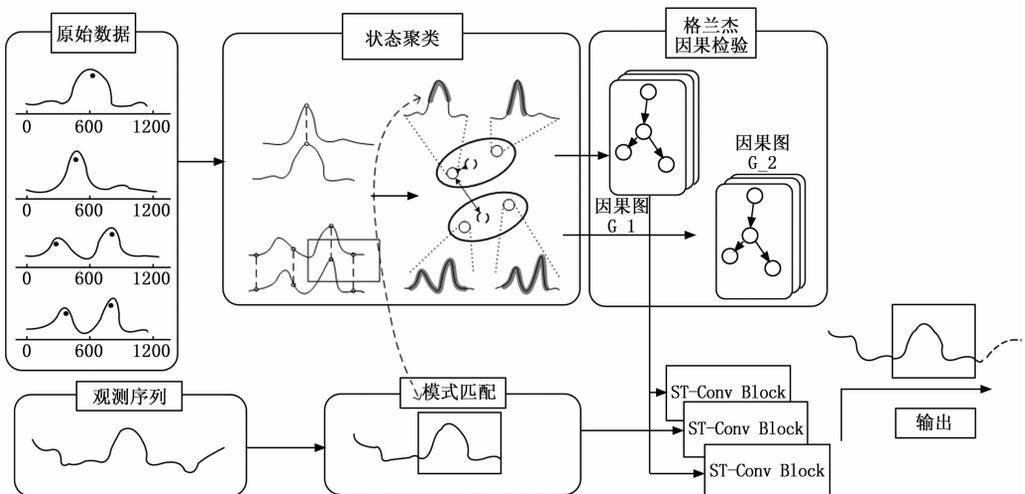


图 1 模型结构图

其中： T 为序列长度， c 为时延偏移量，和 \bar{x} 和 \bar{y} 分别是序列的均值。为了找到两条序列最佳的形状对齐方式，取所有可能时延偏移 c 下 NCC_c 绝对值的最大值，作为最终的形状相似度得分 $S(x, y)$ ：

$$S(x, y) = \max_c [|NCC_c(x, y)|] \quad (2)$$

当得分越接近 1，表明两个时序序列形状越相似。

基于上述过程，整个 k-shape 的聚类目标可以形式化为一个优化问题：将数据集划分为 K 个簇 $\{C_1, \dots, C_K\}$ ，以最大化所有簇内序列与其聚类中心 μ_k 的形状相似度之和。则其目标函数可表示为：

$$\arg \max_{\{C_k\}} \sum_{k=1}^K \sum_{x \in C_k} S(x, \mu_k) \quad (3)$$

算法将形态相似的时序轨迹，如均呈现“高时延、高抖动”或“低负载、高吞吐”等共同模式的归入同一簇中。每个最终得到的聚类中心 μ_k 即代表一个典型的网络状态原型。整个算法过程如下：

算法 1：状态聚类算法

输入： $X = \{x_1, x_2, \dots, x_N\}$ 时序特征集合， K 聚类数， \max_iters 最大迭代次数。

输出： $\{C_1, C_2, \dots, C_K\}$ 聚类结果， $\{\mu_1, \mu_2, \dots, \mu_K\}$ 聚类中心，Labels 状态标签。

```

Begin
 $\{\mu_1, \dots, \mu_K\} \leftarrow \text{RandomSelect}(X, K)$ 
for iter=1 to  $\max\_iters$  do
for  $i=1$  to  $N$  do
 $k^* = \arg \max_k S(x_i, \mu_k)$ 
 $C_k \leftarrow C_k \cup \{x_i\}$ 
Labels[ $i$ ] =  $k^*$ 
end for
for  $k=1$  to  $K$  do
 $\mu_k^{new} = \arg \max_{\mu} \sum_{x \in C_k} S(x, \mu)$ 
end for
if  $\{\mu_k\} = \{\mu_k^{new}\}$  then break
else  $\{\mu_k\} \leftarrow \{\mu_k^{new}\}$ , delete  $\{C_k\}$ 
end if
end for
End
    
```

最终，整个连续时序数据被分割为 K 个具有代表性的状态模式片段，并为每个时间步的每条链路和节点生成一个离散的状态标签，从而将原始的复杂时序数据流转化为一个简洁的状态标签序列，为后续的因果分析与时序图神经网络提供高质量、高语义的输入基础。

1.3 因果图构建

为简化系统建模的复杂性并专注于验证状态聚类与因果推理机制的有效性，采用一个全局静态图结构来涵盖仿真场景中所有潜在的车辆节点与通信链路。在此静态图基础上，通过状态聚类识别出不同的网络运行模

式，并为每一种模式构建一个状态特异性的因果邻接矩阵。该矩阵并不改变全局静态图的物理拓扑，而是定义了特定状态下，不同特征变量间进行空间聚合时应遵循的因果规则，从而实现了在稳定的图结构上对动态因果关系的建模。

为了解决因果关系会随时间或环境变化的问题，对不同状态进行区分并将其提取出来。也就是对聚类后得到的每一个目标状态类别 c ，提取所有被标记为该状态的时间点索引 $\{t: S_t = c\}$ 。根据这些索引，从经过预处理的原始时序特征中切片，并将每个节点特征向量与链路特征向量以及环境变量在特征维度进行展开与拼接，形成一个扁平化的多变量时间序列集合。得到该状态对应的数据子集 $D_c \in R^{T_c \times N_{var}}$ ，其中 N_{var} 是网络中所有节点与链路特征变量的总和， T_c 是该状态下的总时间步数。随后，对 D_c 的每一列进行 Augmented Dickey-Fuller (ADF) 单位根检验^[14]，验证其平稳性。对识别出的非平稳序列进行一阶差分处理，直至其满足平稳性要求，最终得到平稳化后的数据集 D'_c 。

经过基于信息流的因果检验，即对于平稳数据集任意两个变量 X_i 和 X_j ，执行双变量检验。判断变量 X_i 的历史数据是否对预测变量 X_j 的未来值具有统计显著性。而检验方法通过构建两个回归模型，其一为受限模型 (Restricted Model)，仅用 X_j 的历史数据预测其当前值 Y_t ，公式如下：

$$Y_t = \alpha + \sum_{i=1}^p \beta_i Y_{t-i} + \epsilon_{restricted} \quad (4)$$

其中： α 为截距项， p 为通过赤池信息准则^[15] (AIC) 确定的最优滞后阶数， β_i 为滞后 i 期的回归系数， $\epsilon_{restricted}$ 为受限模型的残差项。

另一个是非受限模型 (Unrestricted Model)，同时使用 X_i 和 X_j 的历史数据进行预测，公式如下：

$$Y_t = \alpha + \sum_{i=1}^p \beta_i Y_{t-i} + \sum_{j=1}^q \gamma_j X_{t-j} + \eta \quad (5)$$

其中： p 和 q 分别为两个变量的滞后阶数， γ_j 为变量 X_i 滞后 j 期的回归系数， η 为非受限模型的残差项。再通过 F 检验比较两模型的预测能力，若非受限模型显著优于受限模型，则认为 X_i 对 X_j 存在因果关系。公式如下：

$$F = \frac{RSS_R - RSS_{UR}}{RSS_{UR} / (T - p - q - 1)} / q \quad (6)$$

其中： RSS_R 为受限模型的残差平方和， RSS_{UR} 为非受限模型的残差平方和，分子的含义是加入 X_i 后模型拟合能力的提升，分母为非受限模型的残差方差， T 为样本数量。

根据检验结果，构建有向加权邻接矩阵 $W \in R^{N \times N}$ ，矩阵元素 W_{ij} 的值由显著性水平决定，其计算公式为：

$$W_c[i, j] = \begin{cases} -\log(p_{ij}) & \text{if } p_{ij} < \alpha \\ 0 & \text{otherwise} \end{cases} \quad (7)$$

其中: p_{ij} 为从变量 X_i 到变量 X_j 的因果检验的 p 值, α 为显著性水平。权重值 W_{ij} 越大, 表明从变量 X_i 到变量 X_j 的因果影响越显著、强度越高。

最终, 为每个状态类别 c 均生成一个独有的因果权重矩阵 W_c 。而因果权重矩阵集合 $\{W_1, W_2, \dots, W_k\}$ 则精确刻画了网络在不同运行状态下节点间的动态因果依赖关系, 可直接作为 STGCN 的空间先验输入, 为其提供精准且可解释的拓扑结构。

需要说明的是, 本方案采用的因果检验方法, 其核心在于比较引入潜在原因变量前后对目标变量预测信息量的增益(如公式(6)所示)。这一框架主要关注变量间的预测信息流, 而非局限于特定的线性关系。因此, 当变量间存在显著的非线性依赖关系时, 该检验方法仍能在一定程度上捕捉其统计意义上的因果影响。在未来工作中, 可进一步集成如基于神经网络的非线性预测器, 以更显式地建模复杂函数关系。

1.4 基于因果图的时空图卷积网络

为利用前述步骤所提取的状态特异性因果图, 采用经典的时空图卷积网络(STGCN)作为预测核心。该模型通过堆叠时空块(ST-blocks)交替进行空间与时间特征捕获, 其核心改进在于将通用 STGCN 中的静态拓扑邻接矩阵替换为由 1.2 节生成的、状态感知的加权有向因果邻接矩阵 W_c 。

首先原始输入为时空数据 $X \in R^{T_{\text{hist}} \times N_{\text{var}} \times F}$ (时间步 \times 节点数 \times 特征维度)。其中 T_{hist} 为历史时间步长, N_{var} 为系统变量总数, F 为特征维度。将输入通过图卷积层建模空间依赖关系。采用切比雪夫图卷积(ChebConv)作为基础算子, 其以因果矩阵 W_c 作为空间结构依据。该操作可表述为:

$$Z = \sigma \left[\sum_{k=0}^{K-1} \Theta_k \cdot T_k(\tilde{L})X \right] \quad (8)$$

其中: \tilde{L} 为由归一化后的因果对称矩阵, $\tilde{W}_c = \frac{W_c + W_c^T}{2}$ 所计算的拉普拉斯矩阵, T_k 为切比雪夫多项式, Θ_k 为可训练参数, K 为多项式阶数。取多项式阶数 $K=1$, 使空间卷积严格限定于因果图中直接相连的一阶邻居, 避免多跳聚合稀释关键因果信息。

随后为捕获动态时序模式, 在空间卷积后接入一维时序卷积层(TCN)。TCN 利用空洞因果卷积与残差连接, 将卷积核大小设置为 3, 并使空洞扩张率采用指数序列 $[1, 2, 4]$ 。高效提取多尺度时序依赖, 其公式如下:

$$H = \text{ReLU}(\Phi * Z + b) \quad (9)$$

其中: $\Phi * Z$ 表示空洞因果卷积操作。 Φ 为卷积核

参数, b 为偏置项。较小的卷积核有利于捕捉信噪比、时延等指标的瞬时抖动, 而指数增长的空洞率则使网络感受野逐层扩大, 兼顾局部细节与整体演变。

每一个空间图卷积与时间卷积共同构成一个时空卷积块(ST-block), 为促进梯度流动并防止深层网络退化, 在每个 ST-block 内部及块之间均引入残差连接, 即第 l 个块的输出为:

$$H^{(l)} = F[H^{(l-1)}] + H^{(l-1)} \quad (10)$$

其中: F 表示公式(8)和(9)所定义的序列操作。整个网络由 $L=2$ 层的 ST-block 堆叠而成, 这样的设计足以捕获本任务中的时空特征, 同时避免过深网络带来的过拟合风险, 在多个时空块(图卷积与时间卷积交替)级联后, 网络最终通过一个全连接输出层, 将特征映射至预测空间, 生成未来 τ 个时间步的包接收率(PRR)预测值 $\hat{y} \in R^{\tau \times N_{\text{var}} \times 1}$ 。PRR 作为衡量链路可靠性的核心连续指标, 其取值区间为 $[0, 1]$ 。通过回归预测 PRR, 可为网络上层协议提供精确、细粒度的未来链路状态信息。

算法 2: 因果时空图卷积网络

输入: $X \in R^{T_{\text{hist}} \times N_{\text{var}} \times F}$ 历史时空序列, K 聚类数, α 显著性水平。

输出: $\hat{y} \in R^{\tau \times N_{\text{var}} \times 1}$ 未来预测值。

Begin

$\{C_k\}, \{\mu_k\} \leftarrow \text{KShapeClustering}(X, K)$

for $k=1$ to K do

$D_k \leftarrow \text{ExtractStateData}(X, C_k)$

$W_k \leftarrow \text{GrangerCausalGraph}(D_k, \alpha)$

end for

fortintestsequencedo

$X_m \leftarrow X[t-T:t, :, :]$

$s = \text{argmin}_k \|X_m - \mu_k\|$

$\tilde{W} \leftarrow \text{Symmetrize}(W_s)$

$H \leftarrow X_m$

for $l=1$ to L do

$Z \leftarrow \text{ChebConv}(H, \Theta_l, \tilde{W})$

$H \leftarrow \text{TCN}(Z)$

end for

$\hat{Y}_t \leftarrow \text{Linear}(H)$

end for

End

2 实验对比

为验证模型的有效性, 基于仿真数据进行了实验验证。

2.1 仿真环境与数据集构建

为精准模拟高动态车联网的核心特征, 本仿真设计在场景构建与特征提取层面进行了针对性建模。使用了

由山东大学与北京大学联合发布的 SynthSoM 多模态车联网数据集^[16]，利用其高保真的信道模型参数与多场景先验知识，作为构建 SUMO 与 NS-3^[17]联合仿真平台的基础；具体而言，基于 SynthSoM 数据集中提供的城镇十字路口、高架立交桥及山区公路等多种道路拓扑结构，在 SUMO 中重构了相应的动态车联网测试场景，并通过控制车辆生成率实现了低密度（小于 15 辆/公里）、中密度（15~25 辆/公里）与高密度（大于 25 辆/公里）3 种交通流状态；在 NS-3 仿真中，依据 SynthSoM 已验证的路径损耗模型与信道矩阵数据配置了 sub-6 GHz 通信协议栈，并通过动态调整传播损耗参数精确模拟了正常天气与降雨天气下的信道衰减特性^[18]，从而捕捉高动态环境中链路通断频繁、质量瞬时抖动的本质特征。

最终仿真输出被构建为时空图序列数据集，每个时间步 t 的网络状态表示为图 $G_t = (V_t, E_t)$ ，其中节点集 V_t 代表车辆节点，其特征向量包含经度坐标，纬度坐标，瞬时速度；边集 E_t 在车辆间距离小于 250 米通信半径时建立，边特征向量包含 [信噪比，距离，平均时延，时延抖动] 四项关键链路质量指标。这些指标均基于 SynthSoM 提供的通信特征并通过 NS-3 的物理层模型计算得出；每个时间步附带场景类型与天气条件两类环境标签，共同构成包含多维度特征的时序图数据集。

为了全面评估基于状态聚类与因果推理的链路质量预测方案的实用性，又将数据集划分为 IID 和 OOD 两种设置，其中 OOD 场景进一步细分为拓扑 OOD 与事件 OOD，旨在模拟真实世界中的两类主要分布变化^[19]。其中 IID 划分是从所有地形和天气事件的全景数据中随机抽取 70% 作为训练集，15% 作为验证集，剩余 15% 作为测试集。该划分保证了训练集和测试集源于完全相同的环境联合分布，用于评估模型的基础性能。

拓扑 OOD 的划分则是将高车辆密度场景下的全部数据保留为测试集，仅使用低、中车辆密度场景的数据进行训练。高车辆密度环境下，车辆间通信链路的数量与复杂性呈指数级增长，网络拓扑结构变得极为复杂，这与训练数据中的稀疏至中等连接模式有本质区别，用于测试模型对超复杂网络结构的泛化能力。

在事件 OOD 划分中，训练集包含了正常天气条件的数据，而测试集则由暴雨天气场景下的数据构成。暴雨天气通过 NS-3 中的 Log Distance Propagation Loss Model 参数调整模拟额外的信号衰减，这种天气条件对链路质量的影响机制与训练数据中的正常条件有显著不同，用于测试模型对天气相关干扰的推断能力。

所有数据划分均确保了训练集与测试集在场景层面

的严格隔离，预处理参数仅从训练集计算并固定应用于相应测试集，避免信息泄漏。通过这样设置评估框架，从而检验提出的状态聚类与因果推理方案在面对真实世界复杂变化时的鲁棒性和适应性。

2.2 基线模型与评价指标

为全面评估本方案在高动态网络环境下的性能，将其与八类代表性基线模型进行对比，涵盖了从传统时序模型到前沿时空图网络的多种范式。评价指标采用平均绝对误差 (MAE) 和均方根误差 (RMSE)，旨在从不同角度衡量预测值与真实值之间的偏差。

从表 1 可以观察到几个关键现象。其一是在标准的 IID 测试场景中，所有模型均达到其最佳性能，其中本方案的 MAE 与 RMSE 最低，分别为 0.056 和 0.077，较表现次优的 MTGNN 模型在 MAE 上降低了约 6.7%。这表明，即使在训练与测试数据同分布的理想条件下，通过状态聚类与因果推理引入的精细化建模，仍能有效捕捉数据中更深层次的规律，从而带来预测精度的进一步提升。

表 1 各模型在 IID 和 OOD 场景下的链路质量预测精度对比

| 模型 | IID 测试集 | | 拓扑 OOD 测试集 | | 事件 OOD 测试集 | |
|-------------------------|------------|------------|------------|-------------|------------|------------|
| | MAE | RMSE | MAE | RMSE | MAE | RMSE |
| SVR ^[20] | 9.1 | 12.2 | 15.4 | 18.9 | 14.2 | 17.5 |
| LSTM ^[21] | 7.4 | 10.0 | 12.1 | 15.5 | 11.1 | 14.3 |
| TCN | 7.1 | 9.6 | 11.5 | 14.8 | 10.5 | 13.6 |
| GCN | 6.9 | 9.3 | 12.8 | 16.2 | 11.8 | 15.1 |
| GAT ^[22] | 6.7 | 9.1 | 11.9 | 15.2 | 10.9 | 14.1 |
| STGCN | 6.5 | 8.8 | 10.7 | 14.1 | 9.8 | 13.0 |
| GC-LSTM ^[23] | 6.3 | 8.6 | 10.2 | 13.5 | 9.3 | 12.5 |
| MTGNN ^[24] | 6.0 | 8.2 | 9.4 | 12.6 | 8.5 | 11.7 |
| 本方案 | 5.6 | 7.7 | 7.9 | 10.7 | 7.2 | 9.9 |

其次，当测试场景转为 OOD 设置时，所有基线模型的性能均出现显著下滑，但本方案的下降幅度最小。具体而言，在拓扑 OOD 测试集上，本方案的 MAE 为 0.079，较 MTGNN 与基础 STGCN 分别降低了 16.0% 与 26.2%；在事件 OOD 测试集上，本方案的 MAE 为 0.072，较二者分别降低了 15.3% 与 26.5%。结果证明本方案所采用的状态感知、因果驱动的架构，在处理高动态网络因拓扑剧变或环境扰动引发的分布偏移问题时，对比其他模型具有显著优势。

为深入评估模型在不同精度要求下的性能表现，通过动态调整预测误差的容许范围，评估各模型从宽松到严格标准下的性能表现。采用准确率-阈值曲线对不同模型的性能进行对比，如图 2 所示。

为了更精确地量化各模型对分布偏移的敏感性，进一步计算了其在 OOD 场景下的性能下降率（以 MAE

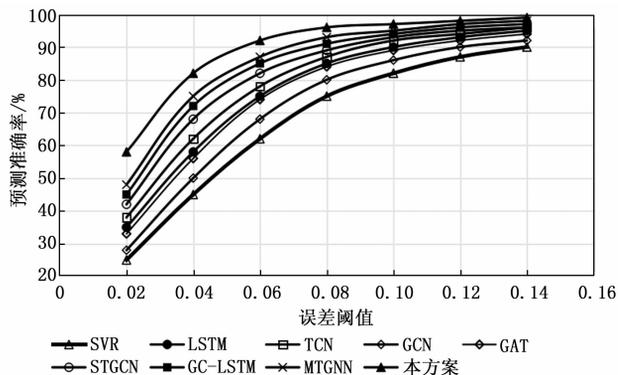


图 2 模型在不同误差阈值下的预测准确率对比

上升率表示), 结果如表 2 所示。

性能下降率分析揭示了各模型应对高动态性的本质能力差异。如表 2 所示, 纯空间模型如 GCN、GAT 在 OOD 场景下性能恶化最为严重, 特别是在拓扑 OOD 场景下, GCN 的 MAE 上升率高达 85.5%, 这反映出依赖固定物理拓扑的图结构在面对高动态网络环境下连接关系动态变化时, 其固有的静态先验会迅速失效, 成为模型泛化的主要瓶颈。相较之下, 时序模型 LSTM、TCN 和时空联合模型 STGCN、GC-LSTM 表现的更为稳健, 其 MAE 上升率平均降低约 15%~25%, 表明时空特征的协同建模能够有效捕捉通信链路中的动态规律, 从而提升模型的分布外泛化能力。

表 2 各模型在 OOD 场景下的性能下降率(MAE 上升率)对比 %

| 模型 | 拓扑 OOD 场景 MAE 上升率 | 事件 OOD 场景 MAE 上升率 | 平均上升率 |
|---------|-------------------|-------------------|--------------|
| SVR | +69.2 | +56.0 | +62.6 |
| LSTM | +63.5 | +50.0 | +56.8 |
| TCN | +62.0 | +47.9 | +55.0 |
| GCN | +85.5 | +71.0 | +78.3 |
| GAT | +77.6 | +62.7 | +70.2 |
| STGCN | +64.6 | +50.8 | +57.7 |
| GC-LSTM | +61.9 | +47.6 | +54.8 |
| MTGNN | +56.7 | +41.7 | +49.2 |
| 本方案 | +41.1 | +28.6 | +34.9 |

与使用了静态拓扑的其他模型相比, MTGNN 通过自适应图学习相较于其他模型在 OOD 场景下表现出较强的泛化能力, 但本方案通过引入因果推理构建的状态特异性因果图, 能更本质地捕获分布变化下的稳定规律。因此本方案在拓扑 OOD 和事件 OOD 场景下的平均性能下降率仅为 34.9%, 较 MTGNN 的 49.2% 的结果提升显著。这来源于两处关键设计, 其一是 K-shape 聚类能够按车辆移动和通信模式的形状相似性划分时序状态, 识别出城镇道路、山区公路等不同拓扑环境下的

典型通信模式; 其二是状态特异的因果图能进一步精细化地刻画了变量间的动态影响关系, 使后续 STGCN 在聚合空间特征时能够遵循更接近真实因果的结构, 从而在面对高密度车辆拓扑和恶劣天气条件时仍能保持可靠推理。

2.3 消融实验

本节通过消融实验, 来验证 CC-STGCN 中状态聚类、因果检验、以及状态特异性因果图这 3 个模块的作用。为此设计了以下 4 个消融变体:

- 1) w/o Clustering: 移除 k-shape 状态聚类模块, 直接对所有数据构建统一的因果图;
- 2) w/o Granger Causality: 移除因果检验模块, 使用传统的基于距离的相关性图作为空间先验;
- 3) w/o State-specific Causal Graph: 保留了聚类模块, 但在每个状态内部不使用其特有的因果图, 而是将所有状态的数据合并后学习一个全局统一的因果图;
- 4) Proposed Full Model: 完整的提出方案, 包含所有核心组件。

由表 3 可以分析出在状态聚类模块移除后性能下降最显著, 证明其对处理不同通信模式至关重要。而因果检验的缺失导致 OOD 场景性能明显恶化, 验证了真实因果关系相比统计相关具有更好的泛化能力。使用状态特异性因果图相比全局因果图在各场景下表现更优, 说明动态因果机制能更好适应不同通信状态。完整方案在保持 IID 场景最优性能的同时, 在 OOD 场景下展现出最强的鲁棒性, 证明各组件间存在良好的协同效应。

表 3 消融实验性能对比

| 模型变体 | IID-MAE | 拓扑 OOD-MAE | 事件 OOD-MAE | 平均下降率/% |
|-------|---------|------------|------------|---------|
| 无状态聚类 | 0.063 | 0.105 | 0.095 | +58.8 |
| 无因果检验 | 0.061 | 0.098 | 0.088 | +52.5 |
| 全局因果图 | 0.059 | 0.089 | 0.081 | +44.1 |
| 完整方案 | 0.056 | 0.079 | 0.072 | +34.9 |

3 结束语

实验结果表明, 本方案在 IID 与 OOD 场景下对比其他模型均取得最优表现, 尤其在高密度拓扑与降雨天气引发的分布偏移中表现稳健。这主要得益于三项核心设计: 首先, K-shape 聚类依据形状相似性划分通信状态, 使模型能够通过状态匹配自适应应对未见场景; 其次, 构建状态特异性的因果图, 动态捕捉随环境变化的因果关联; 最后, 将因果图作为 STGCN 的空间先验, 引导特征聚合严格遵循因果路径, 而非地理邻近关系。

相较于基线模型, 静态图模型 (GCN、GAT) 在拓扑变化下性能下降显著, 时空联合模型 (STGCN、

GC-LSTM) 有所改善。MTGNN 通过图学习提升泛化能力, 但其全局静态隐式图难以刻画状态特异的因果变化。本文方案通过聚类与因果图的协同, 在保持精度的同时显著提升了泛化能力, 但聚类参数敏感性与稀疏场景下的因果发现稳定性仍是后续改进方向。

参考文献:

- [1] HUAIZHOU S H, PRASAD R V, ONUR E, et al. Fairness in wireless networks: Issues, measures and challenges [J]. *IEEE Communications Surveys & Tutorials*, 2013, 16 (1): 5 - 24.
- [2] BRUNA J, ZAREMBA W, SZLAM A, et al. Spectral networks and locally connected networks on graphs [J/OL]. *Arxiv Preprint*, 2013 - 12 - 21. <https://arxiv.org/abs/1312.6203>.
- [3] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks [J/OL]. *Arxiv Preprint*, 2016. <https://arxiv.org/abs/1609.02907>.
- [4] WU Z, PAN S, LONG G, et al. Graph WaveNet for deep spatial-temporal graph modeling [J/OL]. *Arxiv Preprint*, 2019. <https://arxiv.org/abs/1906.00121>.
- [5] MALLICK T, BALAPRAKASH P, RASK E, et al. Graph-partitioning-based diffusion convolutional recurrent neural network for large-scale traffic forecasting [J]. *Transportation Research Record*, 2020, 2674 (9): 733 - 745.
- [6] SONG C, LIN Y, GUO S, et al. Spatial-temporal synchronous graph convolutional networks: a new framework for spatial-temporal network data forecasting [C] // *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020: 914 - 921.
- [7] ZHANG D, LIU H, MA Z, et al. Spatial-temporal gated graph convolutional network: a new deep learning framework for long-term traffic speed forecasting [J]. *Journal of Intelligent & Fuzzy Systems*, 2023, 44 (6): 10437 - 10450.
- [8] CHEN W, CHEN L, XIE Y, et al. Multi-range attentive bicomponent graph convolutional network for traffic forecasting [C] // *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020: 3529 - 3536.
- [9] KANG X, LIU Y, LI Y, et al. Masked graph neural networks for unsupervised anomaly detection in multivariate time series [J]. *Sensors*, 2023, 23 (17): 7552.
- [10] PAPARRIZOS J, GRAVANO L. K-shape: efficient and accurate clustering of time series [C] // *Proceedings of the 2015 ACM SIGMOD International Conference on Management of Data*, 2015: 1855 - 1870.
- [11] GRANGER C W. Investigating causal relations by econometric models and cross-spectral methods [J]. *Journal of the Econometric Society*, 1969: 424 - 438.
- [12] YU B, YIN H, ZHU Z. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting [J/OL]. *ArXiv Preprint*, 2017. <https://arxiv.org/abs/1709.04875>.
- [13] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [J/OL]. *Arxiv Preprint*, 2018. <https://arxiv.org/abs/1803.01271>.
- [14] DICKEY D A, FULLER W A. Distribution of the estimators for autoregressive time series with a unit root [J]. *Journal of the American Statistical Association*, 1979, 74 (366a): 427 - 431.
- [15] AKAIKE H. A new look at the statistical model identification [J]. *IEEE Transactions on Automatic Control*, 2003, 19 (6): 716 - 723.
- [16] CHENG X, HUANG Z, YU Y, et al. SynthSoM: a synthetic intelligent multi-modal sensing-communication dataset for Synesthesia of Machines (SoM) [J]. *Scientific Data*, 2025, 12 (1): 819.
- [17] RILEY G F, HENDERSON T R. The ns-3 network simulator [C] // *Modeling and Tools for Network Simulation*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010: 15 - 34.
- [18] FRIIS H T. A note on a simple transmission formula [C] // *Proc. IRE*, 1946, 34 (5): 254 - 6.
- [19] ARJOVSKY M, BOTTOU L, GULRAJANI I, et al. Invariant risk minimization [J/OL]. *Arxiv Preprint*, 2019. <https://arxiv.org/abs/1907.02893>.
- [20] CORTES C, VAPNIK V. Support-vector networks [J]. *Machine Learning*, 1995, 20 (3): 273 - 297.
- [21] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. *Neural Computation*, 1997, 9 (8): 1735 - 1780.
- [22] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph attention networks [J/OL]. *Arxiv Preprint*, 2017. <https://arxiv.org/abs/1710.10903>.
- [23] SEO Y, DEFFERRARD M, VANDERGHEYNST P, et al. Structured sequence modeling with graph convolutional recurrent networks [C] // *International Conference on Neural Information Processing*. Cham: Springer International Publishing, 2018: 362 - 373.
- [24] WU Z, PAN S, LONG G, et al. Connecting the dots: Multivariate time series forecasting with graph neural networks [C] // *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2020: 753 - 763.