

基于 GINODE 模型的交通流量结构辨识与时序建模研究

刘 锦^{1,2}, 范宏程³

- (1. 陕西国防工业职业技术学院 人工智能学院, 西安 710300;
2. 西安电子科技大学 人工智能学院, 西安 710071;
3. 中国人民解放军空军工程大学 信息与导航学院, 西安 710051)

摘要: 针对交通流量预测中复杂的远程时空相关性问题, 开展了结构辨识与时序建模的研究; 设计了一种基于图同构常微分方程网络 (GINODE) 的建模方法, 利用图同构网络 (GIN) 增强对图结构的表达能力, 实现对交通网络中空间结构与时间动态的联合建模; 采用深层图神经网络结合常微分方程框架同步提取空间连接特征与时序依赖关系; 通过多个真实交通数据集的对比实验验证, 该方法在预测精度和模型稳定性方面优于现有主流时空预测模型; 研究结果表明, 该模型具备较强的时空特征学习能力, 能够有效提升交通流量预测性能, 满足复杂交通场景下的应用需求。

关键词: 图同构网络; 常微分方程; 图神经网络; 时间序列预测; 时空信号处理

Traffic Flow Structure Identification and Temporal Modeling Based on the GINODE Model

LIU Jin^{1,2}, FAN Hongcheng³

- (1. School of Artificial Intelligence, Shaanxi Institute of Technology, Xi'an 710300, China;
2. School of Artificial Intelligence, Xidian University, Xi'an 710071, China;
3. Air Force Engineering University, Department of Information and Navigation, Xi'an 710051, China)

Abstract: To address the challenge of complex remote spatiotemporal correlations in traffic flow prediction, a study on the structure identification and temporal modeling is conducted. A modeling method based on the graph isomorphism neural ordinary differential equation (GINODE) is designed. The graph isomorphism network (GIN) is used to enhance the representation of graph structures, and achieve the joint modeling of spatial structures and temporal dynamics in traffic networks. By integrating deep graph neural networks with an ordinary differential equation framework, the correlations with spatial connectivity features and temporal dependencies are extracted synchronously. Comparative experiments on multiple real-world traffic datasets show that the proposed model outperforms existing mainstream spatiotemporal prediction ones in prediction accuracy and model stability. The results indicate that the model has strong spatiotemporal feature learning capability and effectively improves traffic flow prediction performance, meeting the application requirements in complex traffic scenarios.

Keywords: GIN; ordinary differential equation; graph neural network; time series forecasting; spatiotemporal signal processing

0 引言

近年来, 时空预测已成为一个备受关注的研究领域并在日常生活中有着广泛的应用, 例如交通流量预测、

传染病传播预测、电力负荷预测等^[1-4]。时间序列数据通常被视为对一个随时间连续演化的潜在动态过程的离散采样观测。这种潜在的连续表示对于理解和定义时间序列之间的依赖关系具有至关重要的语义价值。在动态

收稿日期: 2025-05-06; 修回日期: 2025-06-04。

基金项目: 2024 年陕西国防工业职业技术学院科研计划项目 (Gfy-24-31)。

作者简介: 刘 锦 (1993-), 女, 硕士, 讲师。

引用格式: 刘 锦, 范宏程. 基于 GINODE 模型的交通流量结构辨识与时序建模研究[J]. 计算机测量与控制, 2025, 33(10): 305-311.

系统中,时间不仅仅是一个参考维度,更在本质上塑造了变量之间的因果结构和依赖模式^[5-10]。具体而言,时间的单向性决定了依赖关系的不对称性,即过去的状态可以影响未来,而未来无法直接作用于过去。这种不对称性进一步区分了两类依赖关系:局部的、直接的依赖关系和全局的、间接的依赖关系。局部依赖关系通常发生在极短的时间尺度内,仅涉及受系统内部其他变量影响较小的直接相互作用,例如生物系统中的神经元信号传递或物理系统中的局部力学作用。而间接依赖关系则涉及更长时间尺度的演化过程,可能受到多个中间变量的累积效应影响,例如经济系统中的市场趋势、气候系统中的长期变化模式等^[11-13]。

因此,理解时间序列中的依赖结构不仅需要考察短时间内的直接影响,还需要探索跨时间尺度的长期动态模式。这对于构建更精确的时间序列建模方法、优化因果推断算法以及提升复杂系统的预测能力都具有重要意义。因此,准确的时空预测在提高这些应用的服务质量方面起着重要作用。本文研究了时空预测中最具代表性的问题之一——交通流量预测,这是智能交通系统(ITS, intelligent transportation systems)的重要组成部分。交通流量预测旨在根据历史交通状况和底层道路网络预测未来的交通流量^[14-16]。

这一任务的主要挑战在于交通网络中复杂且长距离的时空依赖性。作为交通的内在现象,不同人群的出行距离差异很大,这意味着近邻和远距离的空间依赖通常同时存在。一个节点不仅与其地理邻居相连,还与远距离相关的节点相连。此外,由于行为属性的不同,交通流量序列表现出多样化的时间模式,二者之间的复杂交互进一步导致交通流量预测问题变得棘手。针对交通流量的空间模式,大量研究提出利用图神经网络(GNN, graph neural network)提取交通网络中的空间特征,典型方法包括 STGCN、DCRNN、MTGNN 等^[5-7]。这些方法大多将 GNN 与循环神经网络(RNN, recurrent neural network)结合,通过卷积结构改进循环结构以提升训练稳定性和效率,将空间模式和时间模式分开建模,忽视二者之间的交互,限制了模型的表达能力。具体而言,DCRNN^[6]将交通流建模为扩散过程,捕捉有向图上的空间依赖;STGCN^[5]设计了空间和时间上的分离卷积模块,实现快速训练和参数效率。两者均采用加权邻域聚合方式,且时间和空间依赖通过独立组件建模,难以捕获二者的联合动态。MTGNN^[7]进一步引入可学习的图结构自适应模块,通过图注意力机制动态调整邻域权重,同时采用门控卷积捕获复杂时序特征,提升模型对时空依赖的捕捉能力。然而,MTGNN^[7]的邻域聚合仍然基于归一化加权和,且时空特征的融合仍依赖于分步处理,未能实现空间和时间的完全同步建模。

与此不同,GINODE 模型通过引入图同构网络(GIN, graph isomorphism network)和常微分方程(ODE, ordinary differential equation)框架,实现空间结构与时间动态的同步建模,强化了对时空交互作用的捕捉能力。GINODE 引入神经常微分方程(Neural ODE)对隐藏状态的导数进行参数化,采用连续消息传递机制,缓解了过度平滑现象,同时通过自适应正则化和重启分布技术提升模型稳定性。类似于 CGNN^[11]和 STGODE^[1]利用 ODE 建模时空动态,GINODE 在此基础上进一步结合图同构网络,实现更深层次的时空特征同步融合^[17-20]。

综上所述,现有的时空预测算法并不能很好地适应交通流量数据,尤其是对不同交通节点间特征聚合的和长时间依赖处理的能力较差。本文基于交通流的空间连通构造了邻接矩阵。其次,引入图同构网络(GIN, graph isomorphism network)的非线性特征聚合更新机制并在层之间添加残差连接,以缓解图神经网络过平滑问题^[8]。进一步,将具有残差连接的离散层可以看作是常微分方程(ODE)的离散化^[1],从而导出了图同构常微分方程网络(GINODE)来同时考虑空间和时间模式,并模拟复杂的时空相互作用^[21-24]。

1 GINODE 交通流量预测框架及原理

如图 1 所示,由于道路网络通常具有地理和语义上的联系,因为适合使用图结构来进行建模这些关系。将道路网络表示为一个图 $G = (V, E, A)$,其中 V 是包含 N 个节点的集合, E 是边的集合, $A \in \mathbb{R}^{N \times N}$ 是邻接矩阵。使用 $x_t^i \in \mathbb{R}^F$ 表示节点 i 在时间节点 t 的观测值, $X_t = [x_t^1, x_t^2, \dots, x_t^N] \in \mathbb{R}^{N \times F}$ 表示 t 时间上所有节点的观测值。 $X = (X_1, X_2, \dots, X_T) \in \mathbb{R}^{T \times N \times F}$ 表示所有时间点上所有节点的观测值。

在给定交通网络 G 上观察到的张量 χ 的情况下,交通预测的目标是学习一个映射函数 f ,从历史的 T 个观测值中预测未来的 T' 个交通观测值:

$$[X_{t-T+1}, X_{t-T+2}, \dots, X_t; G] \xrightarrow{f} [X_{t+1}, X_{t+2}, \dots, X_{t+T'}] \quad (1)$$

空间上的邻接矩阵定义为:

$$A_{ij} = \begin{cases} \exp\left(-\frac{d_{ij}^2}{\sigma^2}\right), & \text{if } \exp\left(-\frac{d_{ij}^2}{\sigma^2}\right) \geq \epsilon \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

其中: d_{ij} 是节点 i 和节点 j 间的距离, σ^2 和 ϵ 是用来控制矩阵稀疏性的阈值。

考虑一个连续时间深度模型:

$$x(t) = x(0) + \int_0^t \frac{dx}{d\tau} d\tau = x(0) + \int_0^t f(x(\tau), \tau) d\tau \quad (3)$$

其中: $f((x, \tau), \tau)$ 可以通过神经网络参数化来建模隐藏的动态。可以通过常微分方程(ODE)求解器反




图 1 交通网络的时间与空间特征

向传播该过程, 而无需任何内部操作, 这时可以将其作为整个神经网络的一个模块进行构建。

图 2 为 GINODE 的整体框架, 其主要包含 3 个部分, 包括基于 LSTM 的时间序列特征提取模块, 图同构网络的特征聚合模块和一个基于张量的常微分方程 (ODE) 求解器。经提取后的交通网络特征会输入到 ODE 求解器中, 以提取不同层次的特征信息。




图 2 GINODE 网络框架图

2 GINODE 的模型设计

图神经网络 (GNNs) 在处理结构化数据方面展现出了强大的潜力, 尤其在建模交通网络这一类具有复杂空间拓扑和动态演化特征的系统, GNN 为时空预测提供了新的解决思路。然而, 当前大多数 GNN 方法主要依赖于邻域聚合机制, 即通过将节点邻居的信

息整合进自身特征表示来建模空间相关性。尽管这一机制在实践中表现良好, 但其理论上的表示能力仍存在较大局限。

为深入分析 GNN 的结构表达能力, Weisfeiler-Lehman (WL) 图同构测试是一种强大的图结构判别方法, 广泛用于判断不同图结构是否同构。WL 测试的核心思想是迭代更新每个节点的特征表示, 并通过邻居节点特征的聚合增强结构辨识能力。

在交通网络中, 节点通常表示交通路口或监测点, 边表示道路或交通流的传输通道。由于不同路口的交通行为具有高度异质性, 仅依靠简单的聚合函数 (如求和、平均) 很难有效地区分不同拓扑结构或捕捉微妙的交通动态特征。因此, 为了增强 GNN 在交通场景下的表示能力, 图同构网络 (GIN, graph isomorphism network) 应运而生。GIN^[22] 提出了一个理论框架。GIN 的更新可以通过如下的公式表达:

$$H_{l+1} = GIN(H_l) = MLP[(\hat{A}H_l + \epsilon \cdot \text{diag}(H_l))] = MLP[(1 + \epsilon)h_v^{l+1} + \sum_{u \in N(v)} h_u^{l+1}] \quad (4)$$

$H_l \in \mathbb{R}^{N \times C}$ 是第 l 层的整体表示, $\text{diag}(H_l)$ 是 H_l 中节点自身特征的对角矩阵, h_v^l 表示节点 v 在第 l 层的特征向量, $N(v)$ 是节点 v 的邻居集合, ϵ 是一个可学习的标量参数, 用于调节自节点特征与邻居特征的权重比例, 该参数控制节点自身特征与邻居聚合特征之间的比例。它允许模型灵活地调整“自环”节点特征的重要性, 避免在某些层中自节点特征被邻居特征过度覆盖, 增强了模型的表达灵活性和鲁棒性。通过对邻居节点特征的简单求和, 保证了信息的无损传递。相比于均值或归一化求和, 简单求和避免了信息稀释, 更充分地保留了邻域结构信息, 从而增强对节点局部结构的敏感度。MLP 通过多层非线性映射提升了特征的表达能力, 使模型能够学习复杂的特征组合和更高阶的图结构信息, 进一步提升对不同图结构的区分能力。研究表明, 当网络层数加深时, GNN 已被证明会遭遇过度平滑问题^[12-13], 这极大地限制了其对长距离依赖关系的建模能力。为此, 提出了 GINODE 模块。

张量 τ 可以看作一个多维数组, 张量与矩阵的乘法定义在某个模式纤维上, 例如:

$$(\tau \times_2 M)_{ik} = \sum_{j=1}^{n_2} \tau_{ijk} \cdot M_{jl} \quad (5)$$

其中: $\tau \in \mathbb{R}^{n_1 \times n_2 \times n_3}$, $M \in \mathbb{R}^{n_2 \times n'_2}$, $\tau \times_2 M \in \mathbb{R}^{n_1 \times n'_2 \times n_3}$, $\times_2$ 表示张量-矩阵乘法是在模式-2 (即第二个下标) 上进行的。GINODE 模块的离散形式可以表示为:

$$H_{l+1} = GIN(H_l) \times_2 U \times_3 W + H_0 \quad (6)$$

其中: $H_l \in \mathbb{R}^{N \times T \times F}$ 是一个空间-时间张量, 表示第 l 层节点的隐藏嵌入; $\times_i$ 表示在模式 i 上的张量-矩

阵乘法; $\mathbf{U}$ 是时间变换矩阵; $\mathbf{W}$ 是特征变换矩阵; H_0 表示 GNN 的初始输入, 这一特征可以通过另一个专门设计的神经网络结构获得。与现有方法通常将空间信息和时间信息分开处理不同, 方法创新性地将空间-时间张量整体作为模型的输入, 使得模型能够在统一框架下同时建模空间结构和时间动态。这种表示方式不仅保留了空间邻接关系和时间序列变化的原始结构信息, 还为捕捉更深层次的交互提供了可能。为了有效实现空间与时间之间复杂的耦合关系, 在张量的每一个模式上引入张量乘法操作, 从而实现多维信息的高效融合。该操作允许模型在不同维度之间建立动态关联, 增强了空间-时间特征的表达能力, 进而提升了整体建模效果。

受 CGNN^[11] 的启发, 引入了一个重启分布 H_0 来缓解过平滑问题。具体而言, 公式的展开形式如下所示:

$$H_l = \sum_{i=0}^l (\text{GIN}^i(H_0) \times_2 \mathbf{U}^i \times_3 \mathbf{W}^i) \quad (7)$$

输出表示 H_l 汇聚了所有层的信息, 也就是说, 最终的输出从所有不超过 l 阶邻居中收集信息, 而不会丢失初始特征。将离散形式扩展为连续表达。直观地, 用连续变量 t 替换:

$$H(t) = \int_0^{t+1} \text{GIN}^t(H_0) \times_2 \mathbf{U}^t \times_3 \mathbf{W}^t dt \quad (8)$$

关键点在于将残差结构转化为一个常微分方程 (ODE) 结构。显然, 已经得到了一个常微分方程, 其形式如下:

$$\frac{dH(t)}{dt} = \text{GIN}^{t+1} \times_2 \mathbf{U}^{t+1} \times_3 \mathbf{W}^{t+1} \quad (9)$$

STGODE 理论上证明了一种基于张量的隐藏表示的连续形式^[1]。受启发, 提出了一种 GINODE 学习框架。

$$H(t) = \text{ODESolve}\left(\frac{dH(t)}{dt}, H_0, t\right) \quad (10)$$

长短期记忆网络 (LSTM, long short-term memory) 能够捕捉长期依赖关系, 这对于处理具有长期时间相关性的任务至关重要。与传统的 RNN 相比, LSTM 通过引入记忆单元和门控机制, 能够在较长的时间跨度上保留信息并进行有效的更新。解决梯度消失和梯度爆炸问题: LSTM 通过其独特的结构 (包括输入门、遗忘门和输出门) 有效地控制梯度流动, 避免了梯度消失和梯度爆炸的问题, 这使得它在处理长时间序列时表现更加稳定。为了增强提取长期时间依赖的性能, 这里采用了一种长短期记忆网络:

$$H_{lstm}^l = \begin{cases} X, & l = 0 \\ \text{LSTM}(H_{lstm}^{l-1}, W_l), & l = 1, 2, \dots, L \end{cases} \quad (11)$$

其中: $X \in \mathbb{R}^{N \times T \times F}$ 是 LSTM 的输入, $H_{lstm}^l \in \mathbb{R}^{N \times T \times F}$ 是第 l 层 LSTM 的输出, W^l 是第 l 层 LSTM 的权重。整体的 GINODE 层。如图 3 所示, 由两个 LSTM 块和一个 GINODE 求解器组成。这种结构使得

空间-时间信息流动更加灵活和进一步扩展了模型发现复杂关联的能力。




图 3 GINODE 训练过程

在图神经网络的编码阶段, 在 GINODE 层之后引入了最大池化 (Max Pooling) 操作, 以实现对节点嵌入特征的选择性聚合。该操作能够在保持关键结构信息的同时, 有效压缩特征维度, 从而突出来自不同图块 (或子图) 中具有代表性的局部信息, 为后续的分类或回归任务提供更加紧凑且判别性强的全局表示。

在此基础上, 进一步设计了一个由两层组成的多层感知机 (MLP, multi-layer perceptron), 作为最终的输出模块。该模块将最大池化后的图表示输入, 通过非线性变换逐步映射到预测空间, 输出最终的预测结果。为了提高模型对异常数据的鲁棒性, 选用了 Huber 损失函数 (Huber Loss) 作为训练的优化目标。与传统的均方误差损失 (MSE, mean squared error) 相比, Huber 损失在处理异常值时表现出更强的稳定性: 在误差较小时与 MSE 一致, 而在误差超过设定阈值时转为线性增长, 从而减小小异常样本对整体模型训练的干扰, 提升预测性能和泛化能力。

$$L(Y, \hat{Y}) = \begin{cases} \frac{1}{2} (Y - \hat{Y})^2, & |Y - \hat{Y}| \leq \delta \\ \delta |Y - \hat{Y}| - \frac{1}{2} \delta^2, & \text{otherwise} \end{cases} \quad (12)$$

其中: δ 是一个超参数, 用于控制对异常值的敏感度。

3 PeMS 交通传感器数据集

交通流量预测作为一种典型的时空建模任务, 致力于利用由道路传感器、摄像头、GPS 设备等多源数据采集系统收集的历史交通状态信息, 预测未来一段时间内的交通状况, 如路段流量、速度或拥堵程度。这类任务不仅要求模型具备对空间拓扑结构的建模能力 (如路段之间的连接关系), 还需要能够捕捉时间序列中的周期性、趋势性和突变特征, 从而对复杂多变的交通行为进行准确建模与预测。

在当前交通预测研究中, 美国加州的交通性能测量

系统 (PeMS, performance measurement system) 被广泛用于交通建模任务的数据来源之一。PeMS 系统由加州交通局 (Caltrans) 开发, 覆盖全州主要高速公路路网, 在多个都市区共部署了超过 39 000 个感应检测器, 可以实时收集车辆流量、速度和占用率等关键交通指标。原始数据以高频率记录 (每 30 秒一次), 但在实际应用中通常会进行时间聚合, 如按 5 分钟为单位进行汇总, 这样一天共得到 288 个时间步长, 既能保持一定时间精度, 又有利于建模计算。

在众多基于 PeMS 系统构建的研究数据集中, 以下几个具有代表性:

PeMS03: 该数据集选自加州第 3 区的高速公路网, 包含 358 个传感器节点, 时间跨度为 2018 年 9 月至 11 月, 共 91 天的数据。PeMS03 所涵盖的区域路网相对中等规模, 常用于中等规模图时序建模实验。

PeMS04: 数据集来源于美国加州第 4 区的高速公路网络, 包含约 307 个传感器节点, 采集了流量、速度和占用率等多维交通指标的 5 分钟间隔时序数据。该数据集覆盖了较长时间跨度, 反映了城市高速路网的复杂交通模式, 包括季节性变化和高峰期波动。

PeMS07: 数据集均选自加州第 7 区 (Los Angeles 地区), 包含 1 026 个传感器节点, 覆盖区域和路段密度不同。其数据时间范围为 2012 年 5 月和 6 月的工作日 (即仅包含周一至周五的数据), 可用于分析高峰期通勤交通特性或模拟工作日规律流动。

METR-LA: 该数据集来源于洛杉矶地区真实交通感应器网络, 由 207 个传感器节点组成, 记录的指标主要为流量与速度。与 PeMS 不同, METR-LA 强调城市道路中的交通模式, 时间范围为 2012 年 3 月至 6 月, 数据质量较高, 常用于对比评估交通预测模型的性能, 尤其是在城市内部路网中的应用效果。

不同数据集在节点规模、道路类型和时间跨度等方面存在显著差异, 这直接影响模型的训练难度与泛化能力。例如, PeMS07 (L) 节点数量较多、结构更复杂, 对模型的空间建模能力提出了更高要求; 而 METR-LA 更侧重于城市内部短时高频变动模式, 对模型的时序建模能力和泛化性能具有挑战性。相比之下, PeMS03 与 PeMS07 (M) 适合评估中等规模网络上的建模能力。

这些交通数据集不仅包含了丰富的时空依赖结构, 同时也具备大规模、高维度、强周期性等特征, 使其成为当前先进时序模型的实验标准数据集。在实际任务中, 研究人员通常将每个传感器视为图中的一个节点, 通过道路连接关系或交通流相关性构建图的邻接矩阵, 从而将交通预测问题建模为图时序学习问题, 并使用滑动窗口或递归方式预测未来多个时间步的交通状态。

4 实例分析与结果展示

4.1 实验设置

在实验设置方面, 将所有数据集按照 7 : 1 : 2 的比例划分为训练集 (Training Set)、验证集 (Validation Set) 和测试集 (Test Set), 以确保模型训练、调参与性能评估的科学性与泛化能力。其中, 训练集用于模型参数的学习, 验证集用于监控训练过程中的性能变化以避免过拟合, 测试集则用于最终评估模型的泛化表现。

在数据预处理方面, 为提升模型的训练稳定性与预测精度, 所有输入特征在划分前统一进行了标准化 (Z-score Normalization), 即将每个节点的时间序列特征按通道进行去均值并除以标准差。该处理可以缓解不同传感器之间数值尺度差异对模型训练的不利影响, 特别是在多节点图建模中有助于收敛速度的提升。

在数据使用策略上, 每条样本输入包含前一小时 (即连续 60 分钟) 的历史交通数据, 模型需基于这些输入预测接下来 60 分钟内的交通状况。这种设置符合实际交通预测的需求, 有助于建模复杂的时序依赖和空间一时间动态特征。

所有实验均在同一台配置良好的 Linux 服务器上完成。服务器硬件环境包括: 一颗 Intel (R) Xeon (R) CPU E5-2682 v4 @ 2.50 GHz 处理器, 以及一块 NVIDIA RTX3090 显卡, 拥有 24 GB 显存, 能够满足深度神经网络模型训练中对算力和内存的高要求。

模型结构参数方面, LSTM 模块的隐藏层维度被设定为 64, 以保证在学习序列特征时拥有足够的表示能力。同时, 每层包含 2 个串联的 GINODE 模块, 以增强图结构特征的提取深度与非线性建模能力。为了进一步提升模型的鲁棒性, 在损失函数中引入了正则化项, 其超参数 λ 设置为 0.8, 以平衡模型的拟合能力和泛化能力。

在模型优化方面, 采用 Adam 优化器进行参数更新, 学习率设置为 0.001, 能够在保证稳定收敛的同时加快训练速度。批量大小 (Batch Size) 设置为 64, 训练总轮数 (Epochs) 为 200, 以确保模型在不同数据样本上的充分学习。

为了全面评估模型的预测性能, 选用了 3 种常用的回归类评估指标: 均方根误差 (RMSE, root mean square error)、平均绝对误差 (MAE, mean absolute error) 以及平均绝对百分比误差 (MAPE, mean absolute percentage error)。这些指标能够从不同角度反映预测结果的精度、稳定性及对极值的敏感性, 为模型性能的综合评价提供了坚实依据。模型训练过程如图 3 所示。

4.2 模型对比

如表 1 所示, 比较 STODE 与以下基线模型:

- 1) ARIMA^[9]: 自回归积分滑动平均模型, 这是时间序列分析中众所周知的统计模型。
- 2) STGCN^[5]: 时空图卷积网络, 它利用图卷积和 1D 卷积分别捕捉空间依赖性和时间相关性。
- 3) DCRNN^[6]: 扩散卷积循环神经网络, 它将图卷积集成到编码器—解码器门控循环单元中。
- 4) MTGNN^[7]: 通过图学习模块自动提取变量之间的单向关系, 变量属性等外部知识可以很容易地集成到图学习模块中。进一步提出了一种新的混合跳传播层和扩展初始层来捕获时间序列中的时空依赖关系。
- 5) STSGCN^[10]: 时空图同步图卷积网络, 它利用多个局部化的时空子图模块来同步捕捉局部化的时空相关性。

表 1 基线模型和 GINODE 在 PeMS 数据集上的性能比较

数据集	指标	ARIMA	STGCN	DCRNN	MTGNN	STSGCN	GINODE
PeMS03	RMSE	47.59	30.42	30.31	31.77	29.21	27.63
	MAE	35.41	17.55	17.99	18.12	17.48	16.35
	MAPE	33.78	17.43	18.34	17.90	16.78	15.72
PeMS04	RMSE	48.80	36.01	37.65	38.43	33.65	31.82
	MAE	33.73	22.66	24.63	23.67	21.19	20.64
	MAPE	24.18	14.34	17.01	16.52	13.90	12.87
PeMS07	RMSE	59.27	39.34	38.61	39.54	39.03	36.54
	MAE	38.17	25.33	25.22	26.43	24.26	20.88
	MAPE	19.46	11.21	11.82	10.97	10.21	10.12
METR-LA	RMSE	65.50	42.00	41.20	42.50	40.10	41.24
	MAE	42.22	27.32	26.56	27.21	25.58	24.60
	MAPE	20.57	12.68	12.06	11.88	11.24	11.20

PeMS07 数据集覆盖的是洛杉矶区域, 交通网络的连接结构更加复杂, 这种复杂性更适合 GINODE 在不同交通结构上的识别能力。因此, GINODE 模型能够更有效地捕捉该数据集的时空特征, 表现出更优的预测性能, 其 *MAPE* 等指标优于同类时序预测模型。

METR-LA 数据中可能存在少数异常或极端时段(如交通事故、高峰突发事件), 模型在这些点的预测误差非常大, 从而显著增加了整体 *RMSE*。*MAPE* 更能体现模型在多数正常交通流量时段的相对误差, 因此总体 *MAPE* 保持较低, 说明模型对大部分数据点预测较为精准。

为了验证 GINODE 不同模块的有效性, 在 PeMS04 数据集上进行了以下消融实验, 并设计了 3 种 GINODE 的变体:

- 1) STGCN: 将 ODE 求解器替换为图卷积层, 以验证 ODE 结构在提取长程依赖方面的有效性。
- 2) STGIN: 将图卷积层替换为图同构层, 以验证 GIN 在节点特征聚合方面的有效性。
- 3) GINODE: 同时具备 GIN 和 ODE 的模型结果

如图 4 所示。GINODE 比以前的 STGCN 表现得更好。结合图同构分析, 可以优化 GNN 在不同网络拓扑上的泛化能力。




图 4 GINODE 消融实验

GINODE 与 STGCN 在节点 47 和 52 的预测表现如图 5 所示。




图 5 GINODE 的预测表现

5 结束语

综上所述, GINODE 作为一种融合图同构网络与神经常微分方程的新型时空预测模型, 有效应对了深层图神经网络在长程依赖建模与图结构辨识方面的关键挑战, 显著提升了交通流预测任务中的性能表现。尽管当前模型在多个公开数据集上展现出优越性, 但在动态图建模能力、高效性与可扩展性, 以及鲁棒性与泛化能力等方面仍有待进一步完善。未来, GINODE 可望拓展至更广泛的图结构时空建模场景, 如智能交通、公共安全与能源管理等领域。城市交通网络结构复杂, 交通流量动态变化频繁。GINODE 通过融合图同构网络与神经常微分方程, 有效捕捉空间结构与时间动态的联合特征, 提升对复杂交通模式的识别和预测精度。能支持城市管理部门实时调度信号灯、优化路网流量分配, 缓解拥堵, 提升通行效率。随着交通传感器和物联网设备的

普及, 交通数据的实时采集成为可能。未来 GINODE 可结合流式数据处理框架, 实现对海量实时交通数据的高效接收与处理, 支持在线更新模型状态, 保证预测结果的时效性。通过不断迭代优化, GINODE 有望成为支撑下一代高精度、强泛化、可部署的时空预测系统的重要技术基石。

参考文献:

- [1] FAN G. Spatial-temporal graph ode networks for traffic flow forecasting [C] //Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining, 2021: 364–373.
- [2] HUANG Z, HWANG J, ZHANG J, et al. Causal Graph ODE: Continuous Treatment Effect Modeling in Multi-agent Dynamical Systems [C] //Proceedings of the ACM on Web Conference 2024, 2024: 4607–4617.
- [3] YIN D, JIANG R, DENG J, et al. MTMGNN: Multi-time multi-graph neural network for metro passenger flow prediction [J]. *GeoInformatica*, 2023, 27 (1): 77–105.
- [4] 陈源祥, 陈美君. 基于交通流时空图卷积网络的交通流量预测研究 [J/OL]. *智能计算机与应用*, 1–7 [2025–05–27]. <https://doi.org/10.20169/j.issn.2095-2163.24121202>.
- [5] YAN S, XIONG Y, LIN D. Spatial temporal graph convolutional networks for skeleton-based action recognition [C] //Proceedings of the Thirty-Second AAAI Conference on Artificial Intelligence and Thirtieth Innovative Applications of Artificial Intelligence Conference and Eighth AAAI Symposium on Educational Advances in Artificial Intelligence, 2018: 7444–7452.
- [6] LI Y, YU R, SHAHABI C, et al. Diffusion convolutional recurrent neural network: data-driven traffic forecasting [J]. *Arxiv Preprint Arxiv*: 1707.01926, 2017.
- [7] WU Z, PAN S, LONG G, et al. Connecting the dots: Multivariate timeseries forecasting with graph neural networks [C] //Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2020: 753–763.
- [8] 王永贵, 于 琦. 结合图同构和混合阶残差门控图神经网络的会话推荐 [J]. *计算机科学与探索*, 2025, 19 (2): 502–512.
- [9] 杨雪松, 王 菲, 夏 良, 等. 基于改进 ARIMA 模型的电力工程占地面积的预测研究 [J/OL]. *自动化技术与应用*, 1–6 [2025–05–27]. <http://kns.cnki.net/kcms/detail/23.1474.TP.20241227.1603.106.html>.
- [10] 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, 34 (1): 914–921.
- [11] XHONNEUX L P, QU M, TANG J. Continuous graph neural networks [C] //International Conference on Machine Learning, PMLR, 2020: 10432–10441.
- [12] LI Q, HAN Z, WU X M. Deeper insights into graph convolutional networks for semi-supervised learning [C] //32nd AAAI Conference on Artificial Intelligence, AAAI 2018. AAAI press, 2018: 3538–3545.
- [13] ZHOU J, CUI G, HU S, et al. Graph neural networks: a review of methods and applications [J]. *AI open*, 2020, 1: 57–81.
- [14] TRAPNELL C, CACCHIARELLI D, GRIMSBY J, et al. The dynamics and regulators of cell fate decisions are revealed by pseudotemporal ordering of single cells [J]. *Nature Biotechnology*, 2014, 32 (4): 381–386.
- [15] QIU X, MAO Q, TANG Y, et al. Reversed graph embedding resolves complex single-cell trajectories [J]. *Nature Methods*, 2017, 14 (10): 979–982.
- [16] BRACCO A, FALASCA F, NENES A, et al. Advancing climate science with knowledge-discovery through data mining [J]. *Npj Climate and Atmospheric Science*, 2018, 1 (1): 20174.
- [17] QIAN Z, ALAA A, BELLOT A, et al. Learning dynamic and personalized comorbidity networks from event data using deep diffusion processes [C] //International Conference on Artificial Intelligence and Statistics. PMLR, 2020: 3295–3305.
- [18] FRISTON K J, HARRISON L, PENNY W. Dynamic causal modelling [J]. *Neuroimage*, 2003, 19 (4): 1273–1302.
- [19] FRISTON K. Causal modelling and brain connectivity in functional magnetic resonance imaging [J]. *PLoS biology*, 2009, 7 (2): e1000033.
- [20] RUNGE J, BATHIANY S, BOLLT E, et al. Inferring causation from time series in Earth system sciences [J]. *Nature Communications*, 2019, 10 (1): 2553.
- [21] BELLOT A, BRANSON K, VAN DER SCHAAR M. Neural graphical modelling in continuous-time: consistency guarantees and algorithms [J]. *Arxiv Preprint Arxiv*: 2105.02522, 2021.
- [22] XU K, HU W, LESKOVEC J, et al. How powerful are graph neural networks? [J]. *Arxiv Preprint Arxiv*: 1810.00826, 2018.
- [23] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. *Advances in Neural Information Processing Systems*, 2017: 30.
- [24] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph attention networks [J]. *Stat*, 2017, 1050 (20): 48510–48550.