

MiNiformer: 基于 Mixer-Adapter 增强的基础 Transformer 在长期交通预测中的实践与探索

赵箬箬

中国人民大学

DOI:10.32629/acair.v3i4.17929

[摘要] 近年来,交通预测领域的学术研究热度持续攀升,多数研究聚焦于短期交通预测并取得了良好成果。但在实际场景中更具应用价值的长期交通预测仍面临两大关键挑战:一方面,现有方法多以捕捉短期历史数据中的依赖关系与相关性为核心,在处理长期时空预测任务时性能明显下降,凸显出有限的可扩展性;另一方面,多数方法往往过度强调时间维度信息的建模,却忽视了交通路网中至关重要的空间地理信息,难以全面刻画交通流的时空演化规律。针对这两大挑战,本文提出一种基于Transformer架构的交通预测方法MiNiformer,其核心组件为专门设计的空间特征提取器Mixer-Adapter,该组件能有效助力MiNiformer高效提取并深度整合空间特征;实验结果表明,MiNiformer通过充分挖掘空间信息与长期依赖关系,展现出稳健的长期特征提取能力,在短期与长期预测场景中均实现了优异的性能表现。

[关键词] 时空,交通预测; Transformer; Mixer-adapter

中图分类号: C913.32 **文献标识码:** A

MiNiformer: Practical Application and Exploration of a Mixer-Adapter Enhanced Transformer for Long-Term Traffic Forecasting

Zhengzheng Zhao

Renmin University of China

[Abstract] In recent years, academic research in traffic forecasting has gained significant momentum. While most studies have focused on short-term traffic prediction with promising outcomes, long-term traffic forecasting—which holds greater practical value in real-world scenarios—still faces two critical challenges. Firstly, existing methods predominantly concentrate on capturing dependencies and correlations within short-term historical data, exhibiting markedly diminished performance when tackling long-term spatio-temporal prediction tasks, thereby highlighting their limited scalability. Secondly, most approaches place excessive emphasis on modelling temporal information while neglecting the crucial spatial-geographical information within transport networks, making it difficult to comprehensively characterise the spatio-temporal evolution patterns of traffic flows. To address these challenges, this paper proposes MiNiformer, a traffic forecasting method based on the Transformer architecture. Its core component is the specially designed spatial feature extractor, Mixer-Adapter, which effectively enables MiNiformer to efficiently extract and deeply integrate spatial features. Experimental results demonstrate that by fully leveraging spatial information and long-term dependencies, MiNiformer exhibits robust long-term feature extraction capabilities, achieving outstanding performance in both short-term and long-term forecasting scenarios.

[Key words] spatio-temporal; traffic forecasting; Transformer; Mixer-Adapter

引言

随着城市化进程加快与交通系统复杂度的提升,精准的交通预测对于缓解拥堵、优化路网规划及提升出行效率具有重要

意义^[1]。然而,当前主流研究多集中于短期交通预测,其在长期预测场景中的适用性仍面临显著局限。一方面,现有方法通常依赖对短期历史数据中依赖关系的建模,难以有效捕捉长时间跨度

下的复杂动态模式; 另一方面, 多数模型在强调时间建模的同时, 未能充分融合路网中固有的空间地理信息, 导致对交通流时空演化机制的表征能力不足。为应对上述挑战, 本文提出了一种基于Transformer架构的长期交通预测模型——MiNiformer。其核心创新在于引入了一种可学习的空间特征提取模块Mixer-Adapter, 该模块能够显式、高效地从路网拓扑结构中提取空间特征, 并与时间信息进行深度融合。此外, 模型还集成了可学习的噪声嵌入机制, 以增强对实际交通数据中突发波动与不确定性的适应能力。实验部分基于PEMS04和PEMS08数据集验证了MiNiformer在长短期预测任务中的有效性及稳健性, 结果表明其在多项评价指标上均优于现有基线方法, 展现出良好的可扩展性与实用性。

在智能交通系统(ITS)领域, 交通预测作为一项时空数据挖掘任务占据关键地位。它通过算法挖掘历史交通数据中的模式, 进而实现对未来交通流量的预测^[2]。交通预测直接影响人们的日常生活, 准确高效的模型能够支持明智的出行决策和生活方式调整。传统方法旨在提取历史数据的潜在分布和显著特征, 从而在特定时间窗口内预测未来交通模式。

传统方法通常依赖基于图的方法, 如时空图神经网络(STGNNs)。这些方法通过将交通数据采集传感器视为图神经网络(GNN)框架中的节点来建模历史交通流量数据^[3]。然而, 基于图的方法需要预先定义图结构的拓扑类型, 这严重阻碍了模型对具有不同拓朴类型路网的迁移能力。这种预先定义将模型的关注点限制在训练数据的拓朴类型上, 导致在不同拓朴类型的路网中评估时出现灾难性的性能下降。近年来, 基于Transformer的模型成为一种替代方案, 它们采用与基于图的方法不同的方式, 避开空间拓朴类型, 转而专注于时间序列数据的时间特征。这些模型已展现出良好的性能, 引发了学术界的研究热潮。可是, 它们忽视了空间信息在实际交通预测中的关键作用。为弥补这一遗漏, 一些研究通过隐式空间嵌入模块整合空间信息。但这些设计的隐式特性阻碍了可解释性, 因为无法明确哪些特定的时空特征对提升预测性能贡献最大。

本文提出一种灵活且可学习的空间信息适配器——Mixer-Adapter, 它通过专门设计的特征提取模块有效压缩和提取空间信息^[4]。该模块能够显式提取空间特征并将其与时间特征整合, 使模型具有高度的空间敏感性, 从而提升预测精度和鲁棒性。

其次, 将可学习的噪声嵌入模块与基础Transformer整合。该模块能够理解并从噪声中学习, 此处的“噪声”指数据中可能不直接影响输出但具有潜在可学习模式或结构的随机或不一致部分。

为验证MiNiformer在长期和短期场景中的有效性, 本文基于PEMS04和PEMS08数据集进行了大量实验, 证明其优于现有方法。

1 MiNiformer

MiNiformer的核心思想(如图1所示)在于显式且高效地提取路网拓朴信息。除了设计Mixer-adapter嵌入模块以压缩空间信息外, MiNiformer还采用可学习噪声模块来模拟现实世界中数据的突发变化。

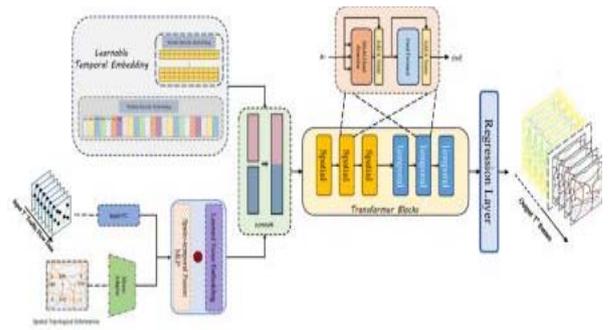


图1. MiNiformer的架构示意图

1.1 Mixer-adapter。如何有效提取空间信息是时空数据挖掘领域的关键问题。现有研究主要通过两种途径整合空间信息：预定义网络结构和可学习隐式嵌入模块。预定义网络结构无法从空间信息中学习特征提取过程, 而可学习隐式嵌入模块则隐式地使用空间信息, 降低了可解释性^[5]。Mixer Adapter作为地理信息提取器, 以网络结构为输入, 无需预定义即可有效提取网络结构的空表示。网络结构的输入独立于时间序列数据, 这意味着Mixer-Adapter是一种显式、高效且可学习的提取方法。Mixer-Adapter的示意图如图2所示。

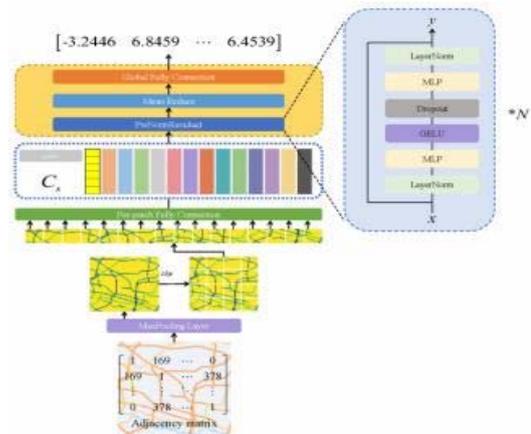


图2 Mixer-Adapter示意图

池化操作后, 空间拓朴结构被划分为多个网格, 随后展平为一维数据并输入空间提取模块。最终, 这些数据被处理为包含空间信息的潜在向量^[6]。全面且有效地建模网络结构的依赖信息并非易事。本文充分考虑了如何从原始交通信号矩阵中压缩和聚合数据, 以使整个模块具备更好的空间特征学习和表示能力。

对于交通信号矩阵, 首先采用最大池化操作。池化操作后的矩阵浓缩了路网拓朴中的位置依赖关系、连通性和距离信息^[7-8]。这些信息经过补丁处理(Patch processing)和矩阵特征处理(Matrix Feature Processing)两个模块后, 被压缩为保留空间拓朴信息的潜在向量。矩阵通过均值归一化操作进行降维。至此, 路网结构的空信息已被压缩为潜在向量。为更好地与时间序列信息整合, 引入另一个MLP层以统一时空数据的空维度^[9]。

2 实验

2.1实验设置。数据集: 本文选择两个广泛使用的数据集PEMS04和PEMS08。两个数据集均由交通绩效测量系统(PeMS)构建, 采样频率为每5分钟一次, 即每小时12次, 每天288次。详细信息如表1所示。

表1 数据集摘要

Dataset	Sensors(N)	Time steps	Time Range	Time interval
PEMS04	307	16,992	01/2018-02/2018	5 min
PEMS08	170	17,856	07/2016-08/2016	5 min

数据处理: 将数据集按6:2:2比例划分为训练集、验证集和测试集。根据具体任务, 从不同设置(24、36、48步)采样数据, 以预测相同采样粒度的未来数据。与以往任务的区别在于, 本文聚焦长期交通预测。

基线模型: 本文将MiNiFormer与以下基线方法进行比较:

历史平均法(HA): 直接使用过去时间序列数据的平均值作为预测值。

向量自回归模型(VAR): 通过将系统中每个内生变量视为所有内生变量滞后值的函数构建模型, 避免结构化模型的要求。

深度卷积循环神经网络(DCRNN): 结合卷积神经网络(CNN)和循环神经网络(RNN)的深度学习模型, 专为处理含空间特征和时间依赖的序列数据(如交通流量预测)设计。

图波网络(GWNet): 用于深度时空图建模的神经网络模型, 通过结合图卷积和循环单元捕捉图数据中复杂的时空依赖关系, 增强动态图结构数据的分析与预测能力。

图多注意力网络(GMAN): 通过多种图池化策略和注意力机制高效聚合图中节点特征, 以拟合时空数据的深度学习模型。

自适应图卷积循环神经网络(AGCRN): 通过引入节点自适应参数学习模块和数据自适应图生成模块, 捕捉交通序列中复杂的时空相关性。

注意力机制时空图神经网络(ASTGNN): 结合自注意力机制和动态图卷积, 捕捉时间序列局部上下文和空间数据动态相关性的交通预测模型。

自监督时空瓶颈注意力网络(SSTBAN): 采用自监督学习和时空瓶颈注意力机制, 优化计算复杂度和数据利用效率。

运行环境: 所有实验在配备NVIDIA Force A6000 GPU和256GB内存的服务器上进行, 操作系统为Ubuntu 18.04。MiNiFormer代码完全使用Pytorch-2.1.0和Python 3.9.7实现。

评估指标: 为评估模型性能, 本文选择三个指标: (1)平均绝对误差(MAE)、(2)平均绝对百分比误差(MAPE)和(3)均方根误差(RMSE)。这些指标的公式如下:

平均绝对误差(MAE): 对所有误差赋予相同权重, 即大误差和小误差在计算中影响相同。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$

平均绝对百分比误差(MAPE): 直观表示误差相对于实际值

的比例。

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2)$$

均方根误差(RMSE): 更能反映模型对异常值的敏感性和预测精度。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

2.2主要结果。本文基于PEMS04和PEMS08数据集, 对8种模型在不同时间间隔下的性能进行了综合比较。这些任务的结果可以作为评估长期交通预测能力的依据。

PEMS04数据集包含307个采样点, 其复杂的数据构成使模型更容易受离散值影响。MiNiFormer在所有RMSE指标上均取得最佳性能。RMSE通过平方误差放大较大误差, 对显著误差更敏感, 表明本文的模型在异常值敏感性和预测精度方面表现优异。

PEMS08数据集上, MiNiFormer在MAE指标上持续表现良好。MAE是衡量模型趋势捕捉能力最直观的指标, 因此可以认为本文的模型能有效拟合目标数据。

在显示利用空间信息的模型中, SSTBAN性能最佳, 但其空间拓扑结构的使用不可学习, 无法迁移到不同空间拓扑结构的路网。相比之下, MiNiFormer的空间信息提取是可学习的, 因此表现更优。

STAEFormer是隐式使用空间信息的经典模型, 可解释性较低。MiNiFormer充分利用连通性和距离成本, 在大多数场景下性能更优。

3 结论

本文提出了MiNiFormer, 一种能够高效利用空间信息解决长期交通预测问题的模型。针对以往研究中无法显式学习空间信息的缺陷, 设计了可学习的空间信息捕捉模块Mixer-Adapter, 使模型在学习时间数据的同时兼顾空间信息, 实现了空间信息的显式学习和时空数据融合处理范式。此外, 还整合了噪声学习模块, 显著提升了模型的稳健性。通过在两个真实世界数据集上进行三种不同预测间隔的大量实验, 验证了MiNiFormer的优越性。

[参考文献]

- [1]张红.长期Transformer和自适应傅里叶变换的动态图卷积交通流预测研究[J].电子与信息学报,2025,47(7):2249-2262.
- [2]王雅慧.基于GM(1,1)修正模型的轨道交通长期客流预测[J].河南科技学院学报(自然科学版),2025,53(01):91-100.
- [3]刘浩.基于时空编码器-解码器的长期交通流量预测[D].华中科技大学,2024.
- [4]钟家俊.基于神经网络的高速公路长期交通流预测系统的设计与实现[D].电子科技大学,2024.
- [5]王森,禹丽峰,艾鹏鹏,等.大型地下空间综合交通枢纽中巨型斜柱长期沉降的监测及预测分析[J].科学技术与工程,2024,24(05):2052-2059.
- [6]李义群.基于序列到序列卷积长短时记忆神经网络的长期交通流预测不确定性量化[D].深圳大学,2021.

[7]高俊.面向PHEV能量管理的短期工况预测与长期交通信息生成技术研究[D].重庆大学,2018.

[8]阳明明,韦琦.基于空间经济理论模型的交通枢纽物流量长期预测[J].统计与决策,2015,(24):12-16.

[9]吕罡.空中交通流量长期预测方法研究[J].黑龙江科技

信息,2015,(18):38.

作者简介:

赵箐箐(1985--),女,满族,辽宁大连人,硕士,研究方向:大数据技术、人工智能。