

基于深度学习的短时交通流预测研究综述

熊章友¹, 李卫军^{1,2+}, 朱晓娟¹, 杨国梁¹, 马馨瑜¹

1. 北方民族大学 计算机科学与工程学院, 银川 750021

2. 北方民族大学 图形图像智能处理国家民委重点实验室, 银川 750021

+ 通信作者 E-mail: lwj@nmu.edu.cn

摘要: 交通流预测是智能交通系统的重要组成部分, 旨在准确估计未来特定时间间隔内特定区域的交通流量。随着车辆的增长和路网中不同区域之间的复杂时空关系, 传统的交通预测方法难以准确描述交通数据的特征, 而深度学习的预测方法能够更好地处理复杂的特征结构, 因此, 深度学习的方法已成为短时交通流预测的研究热点。总结了传统交通流预测方法和深度学习交通流预测方法的研究现状, 详细介绍了深度学习架构卷积神经网络、自编码器、循环神经网络、图卷积神经网络、注意力机制与Transformer以及深度学习混合神经网络, 并且对深度学习的交通流预测文献、深度学习的超参数和场景进行了总结分析。总结了现有文献中常用的国内外公共数据集。根据前人的模型实验对交通预测模型的性能进行了对比分析。最后, 讨论了基于深度学习的交通预测领域的未来研究方向。

关键词: 交通流预测; 深度学习; 短时交通流; 交通数据集; 时空特征

文献标志码: A **中图分类号:** TP391 **doi:** 10.3778/j.issn.1002-8331.2407-0410

Short-Term Traffic Flow Prediction Based on Deep Learning

XIONG Zhangyou¹, LI Weijun^{1,2+}, ZHU Xiaojuan¹, YANG Guoliang¹, MA Xinyu¹

1. School of Computer Science and Engineering, North Minzu University, Yinchuan 750021, China

2. Key Laboratory of Images & Graphics Intelligent Processing of State Ethnic Affairs Commission, North Minzu University, Yinchuan 750021, China

Abstract: Traffic flow prediction is an important part of intelligent transportation system, which aims to accurately estimate the traffic flow of a specific area in a specific time interval in the future. With the increase of vehicles and the complex space-time relationship between different regions in the road network, traditional traffic prediction methods are difficult to accurately describe the characteristics of traffic data, while deep learning prediction methods can better deal with complex feature structures. Therefore, deep learning has become a research hotspot in short-term traffic flow prediction. Firstly, the research status of traditional traffic flow prediction methods and deep learning traffic flow prediction methods is summarized, and the deep learning architecture of convolutional neural network, autoencoder, recurrent neural network, graph convolutional neural network, attention mechanism and Transformer as well as deep learning hybrid neural network is introduced in detail. And the deep learning traffic flow prediction literature, deep learning hyperparameters and scenarios are summarized and analyzed. Secondly, the paper summarizes the common domestic and foreign public data sets in the existing literature. Then, the performance of traffic prediction models is compared and analyzed according to previous model experiments. Finally, the future research direction of traffic prediction based on deep learning is discussed.

Key words: traffic flow prediction; deep learning; short time traffic flow; traffic data set; spatio-temporal characteristics

基金项目: 宁夏高等学校科学研究项目(NYG2024086); 中央高校基本科研业务费(2021JCYJ12, 2022PT_S04); 国家自然科学基金(62066038, 61962001); 北方民族大学研究生创新项目(YCX24363)。

作者简介: 熊章友(1997—), 男, 硕士, CCF 会员, 研究方向为时空交通流预测; 李卫军(1979—), 男, 博士, 讲师, CCF 会员, 研究方向为本体的构建与重用、知识图谱的构建、深度学习的研究; 朱晓娟(2000—), 女, 硕士, CCF 会员, 研究方向为胶囊网络研究、目标检测; 杨国梁(1998—), 男, 硕士, CCF 会员, 研究方向为时空交通流预测; 马馨瑜(2000—), 女, 硕士, CCF 会员, 研究方向为胶囊网络研究、时序知识推理。

收稿日期: 2024-07-24 **修回日期:** 2024-11-05 **文章编号:** 1002-8331(2025)11-0067-16

随着社会经济的发展和城市规模的扩大,汽车保有量飞速增长,导致交通拥堵成为制约城市和经济发展的主要问题之一。现代城市正逐步发展成智慧城市给城市交通带来了巨大的管理压力,智能交通系统(intelligent traffic system, ITS)作为一种新型城市交通解决方案,成为现代社会的重要组成部分^[1]。在这一背景下,交通预测能够优化交通管理、提升交通效率、改善居民出行体验,推动城市交通系统朝着更加智能化、高效化、可持续化的方向发展。

交通预测方法可分为两类:中长期预测和短时交通预测。中长期预测通常以天或年为单位,但由于不确定因素的影响,其长期趋势变化较大,导致准确性相对较低。而短时交通流量预测则关注未来5到60分钟内的道路或交通网络流量。短时预测对实时交通管理至关重要,准确性受到多种因素的影响,主要包括交通数据的动态时空依赖性以及外部因素,如天气条件、事件或道路属性。因此,提高预测模型的精确性和实时性是提升交通系统运行效率的关键。

短时交通预测的方法主要采用数据驱动的方法来进行交通预测,而数据驱动的方法可以分为基于统计分析、基于传统机器学习方法和基于深度学习方法三类。基于统计分析的交通流预测,主要采用经典统计方法,这类方法要求序列满足平稳性假设,并且其中的参数设置依赖于专业领域的知识,限制了非线性交通流的高度可表达性,无法直接建模时间序列中交通数据的各种依赖关系。而基于传统机器学习的方法可以更好地处理交通流量预测中的复杂的非线性问题,具有较好的预测性能。这类方法在交通预测领域常见的模型包括:隐马尔可夫模型^[2]、支持向量机模型(SVM)^[3]和K近邻模型^[4]等。然而传统的机器学习方法面临着难以处理日益增长的车辆数量和复杂的交通情况的挑战,应对这一挑战采用深度学习模型来更好地挖掘数据关联、引入时空特征建模、融合多模态数据以及增量学习。

基于深度学习的方法已经成为交通预测的研究热点之一,由Hinton等^[5]首次提出。它可以从大量的交通数据中学习复杂的非线性关系,从而在交通预测任务中表现出色。其中,多层感知机网络(multi-layer perceptron, MLP)最早应用于短时交通流预测,但其场景运用存在局限性。随着交通流预测场景的不断增加,模型的时空依赖关系变得愈加复杂,因此卷积神经网络(convolutional neural network, CNN)和循环神经网络(recurrent neural network, RNN)以及长短期记忆网络(long short-term memory, LSTM)广泛应用于交通流预测。为了解决以往方法在处理交通道路网络图结构时效果不佳的问题,图卷积神经网络的优势逐渐显现。与此同时,随着对外部因素的关注加深,深度学习混合神经网络模型开始受到重视。越来越多的学者在交通流

预测中引入各种注意力机制,并结合Transformer及其变体,提出了一系列新算法,这些进展显著提升了交通流预测模型的性能。

近几年,许多学者从不同角度对短时交通流预测进行了综述。Boukerche等^[6]总结了机器学习模型在交通流预测领域的研究进展,并分析了这些模型的优缺点。Tedjopurnomo等^[7]则对深度神经网络模型在交通预测中的研究进行了详细讨论,主要包括卷积神经网络、循环神经网络和前馈神经网络。然而,这些研究并未涉及图神经网络模型。为此,Jiang等^[8]将交通流量问题划分为路级、区域级和车站级三个层次,全面总结了不同图神经网络模型在交通预测中的表现。尽管这些研究对深度学习在交通预测中的应用做出了阐述,然而,它们并未介绍Transformer及其变体或混合神经网络在交通流预测领域的应用。同时,关于不同深度学习方法之间的优缺点对比分析,以及模型的超参数和场景分析,也尚未得到充分总结。目前仍然缺乏一篇对深度学习方法在交通预测领域进行全面介绍的综述。因此,本文系统总结了近年来深度学习在交通预测领域的研究,全面对比与分析了现有深度学习方法及其性能,并探讨了未来交通领域的发展方向。具体贡献如下:

(1)详细介绍了基于短时交通流预测的深度学习相关方法,深入比较了各方法的优缺点,为研究者选择合适的模型提供了参考。

(2)对深度学习交通预测中的超参数选择和应用场景进行了讨论,并分析了以往交通流预测模型的预测性能,揭示了各方法的适用性和局限性。

(3)对交通预测数据集进行了全面分类与总结,探讨了未来研究方法的发展趋势,为后续研究提供了新的视角与思路。

1 传统交通流预测方法

近年来,一些基于数据的交通预测方法被提出,它们通常通过统计方法和机器学习技术来确定目标函数,将解释变量与目标变量联系起来。根据实现技术的不同,可分为两类:基于统计分析方法和基于机器学习方法。

1.1 基于统计分析方法

早期的交通预测方法主要集中在时序数据的相关性上,采用经典统计模型如卡尔曼滤波分析法(Kalman filter, KF)^[9]、向量自回归法(vector autoregression, VAR)^[10]、历史平均法(historical average, HA)^[11]和差分自回归移动平均模型(autoregressive integrated moving average model, ARIMA)^[12]等。这些方法通过对历史数据的分析和模式识别,以及简单的数学运算来推断未来交通状态的可能走势。KF是一种递归滤波方法,适用于线性动态和高斯噪声的系统状态估计,如车辆位置和速度。在交通预测中,可用于处理车辆位置和速度

数据以及估计未来的交通状况。Kumar等^[13]使用KF方法仅用前两天的流量数据高精度预测第二天的流量,并且尝试结合历史数据和当天实时数据进行预测,取得了较好的结果。但当流量波动较大时,KF方法难以取得较佳的预测表现。HA是一种简单的预测方法,它基于过去一段时间内的平均状态来预测未来的交通状态。这种方法假设未来的交通状态将与过去的平均状态相似,因此通过计算历史数据的平均值来进行预测。尽管它原理简单计算速度快,但其交通预测结果的精度不高。ARIMA模型是常用的时间序列分析方法,结合了自回归和移动平均模型,能捕捉时间序列的趋势和季节性,用于未来值的预测。然而,ARIMA模型存在一些局限性,包括对数据的线性、平稳性假设、参数选择困难、对异常值敏感、无法处理非线性关系以及对数据平稳性要求严格,因此,在实际应用中需要谨慎考虑这些限制。Dong等^[14]通过对不同时间段的数据进行训练,进一步优化了ARIMA模型,提高了其准确性。通过实验证明,使用面向时间的数据进行训练比非时间导向的数据训练模型效果更好。

1.2 基于机器学习的方法

机器学习的方法在智能交通系统中的应用备受关注,相比之下,传统预测方法受到随机波动的限制,而基于机器学习的方法能够更有效地处理复杂的非线性问题,并综合考虑历史数据和空间相关性,因此成为研究热点。基于机器学习的方法利用神经网络模型、决策树、支持向量机等算法对交通数据进行建模和预测,提高了预测准确性,为交通管理提供了更可靠的支持。文献[15]利用核函数将短时交通流预测问题转化为高维空间中的线性回归问题,并提出了基于支持向量机回归的预测模型。模型的预测结果与实际数据相符,且预测误差小于基于卡尔曼滤波的方法,从而验证了支持向量机回归模型的可行性和有效性。考虑到上下游交通流的密切联系,Sun等^[16]提出了基于隐马尔可夫模型的拥堵繁忙路段模式预测方法。通过分析流动车辆轨迹数据,校准了模型并预测了区域的拥堵模式。结果表明预测精度达到了83.4%,比自回归方法和移动平均模型提高了5.8个百分点,验证了隐马尔可夫模型方法的可行性和有效性。Cai等^[17]用改进的KNN模型通过使用等效距离替代物理距离,采用时空状态矩阵描述交通状态,并利用高斯加权欧氏距离选择最近邻,以及调整时空因素的影响,提高了基于时空相关性的预测精度,实现了多步预测。然而,以上的研究在等效近距离上和高峰时效期预报精度较低。文献[18]介绍了一种基于多任务学习的多城市时空依赖提取方法,不仅在交通流预测中表现出良好的结果,而且显示出优于其他基线模型的性能。Tu等^[19]则提出了一种基于隐马尔可夫模型的拥堵模式预测模型SG-CNN,并将其与著名的交通预测

基线模型ARIMA进行了比较,通过实验表明,SG-CNN模型具有良好的性能。以上研究展示了不同方法在交通预测领域的应用,为改进交通预测模型提供了有价值的参考和启示。

2 深度学习交通流预测方法

传统模型采用参数化的方法来预测^[20],然而,由于交通流具有随机性和非线性特征,参数化方法无法进行准确预测^[21]。因此,非参数化的机器学习方法成为了交通预测的首选。然而,随着大数据时代的到来,传统机器学习模型因其结构相对简单,在处理高维数据集和复杂架构时存在一些限制。因此,深度学习技术在短期交通流量预测中的优越性逐渐显现。深度学习不仅能够与模型超参数无关地提供稳定的预测效果,还能够有效挖掘交通流量数据之间的隐含特征,使其在复杂交通流数据建模方面具有重要优势。此外,深度神经网络能够有效地捕获交通流数据的时空特征,因此已成为短期交通流预测的主流方法。目前,常见且效果显著的深度学习模型包括卷积神经网络、自编码器、循环神经网络、图卷积神经网络、注意力机制与Transformer、深度学习混合神经网络等。

2.1 卷积神经网络

CNN是一种深度学习模型,主要用于处理和分析具有网格结构的数据,如图像、语音等。它的设计灵感来自生物学中对动物视觉系统的理解。CNN在图像识别、图像分类、目标检测、语义分割等领域取得了巨大成功。CNN主要由卷积层、池化层和全连接层组成。在卷积层中,网络通过应用一系列滤波器来提取输入数据的特征,生成特征图。池化层用于减少特征图的空间尺寸,降低计算复杂度,通常采用最大池化或平均池化操作。最后,全连接层将高级特征映射到最终的输出,用于执行分类或回归任务。上述特征使CNN能够有效地捕获交通数据的特征,从而在交通量预测中表现出色。下面详细介绍基于卷积神经网络在交通预测领域的主要工作。

Yang等^[22]提出的MF-CNN模型融合了多个时空特征和外部因素数据,与五种基线模型相比,显著提升了预测性能。然而,它未考虑其他不可预见情况所引起的变化。Bogaerts等^[23]提出一个深度神经网络,利用图CNN-LSTM架构实现了多步预测,CNN-LSTM架构能够在来自GPS轨迹的交通数据中找到空间和时间关系。除此之外,还提出了一种数据缩减技术,并与最先进的TF算法(如K-NN、SVM或LSTM)进行了比较,取得较好的预测效果。目前,在交通预测领域,针对长期预测问题仍然存在挑战。因此,Zang等^[24]提出了一种多尺度时空特征学习网络(MSTFLN)模型,MSTFLN模型是基于CNN的一种经典模型,旨在解决高架公路长期交

通速度预测的问题,如图1所示。MSTFLN模型包含四个CNN模块:CNN1、CNN2和CNN3用于每个时间尺度的特征提取,其生成的特征映射被传送给CNN4进行多尺度特征联合学习和预测结果生成,实现了多尺度信息的融合和学习,并且此方法能够有效地预测长期速度信息。




图1 MSTFLN 模型图

Fig.1 MSTFLN model diagram

2.2 自编码器

自编码器(self-ensembling autoencoder, SAE)是一种无监督的神经网络,通过学习输入数据的压缩表示来进行特征提取。SAE将自编码器或自动关联配置定义为一个重建其输入信号的判别图形模型,其中输出被约束为与输入相同^[25]。SAE模型如图2所示,它通过堆叠将自编码器在下面一层的输出作为当前的输入。面对SAE在隐藏层的尺寸与输入层相同或者大于输入层的情况,模型显示出明显的缺点,比如模型可能被复制输入,不提取有用的特征。目前,解决这种情况主要有两种方法:一种是使用去噪自编码器,另一种是使用稀疏自编码器。由于稀疏自编码器特征提取能力强、能够处理高维数据并且能与LSTM、CNN等预测模型结合,大部分学者在交通领域主要使用稀疏自编码器,因此,本文主要讨论稀疏自编码器。




图2 SAE 模型图

Fig.2 SAE model diagram

为了对不同时间段交通流量进行评估,Duan等^[26]通过250个实验进一步评估了所提出的SAE模型在白天和晚上交通流预测中的性能,通过整合工作日和非工作日的最佳超参数组合,表明基于深度学习的交通预测方法可以是多种SAE的组合,不同参数适应不同的时间段,能够捕捉到不同时间段的流量特征。为了解决交通

流量波动大和流量数据少导致模型过拟合的问题,Yang等^[27]提出了一个新的SAE-LE模型,通过为SAE神经网络架构引入一个方案来提高交通预测的精度。该方案通过重新排列训练数据来重新训练SAE,以增强网络的泛化能力,并通过构建SAE的集合来提高预测的准确性。目前,在交通预测领域中,常常利用深度神经网络和SAE的优势组成混合模型,以捕获交通数据中的时空关系。例如,Essien等^[28]利用LSTM和SAE架构用于多步交通流量预测,捕获到了时空特征,提高了预测的准确性。Tian等^[29]也提出一种SAE和LSTM组合的混合交通预测模型,此融合模型充分利用SAE和LSTM特征,实现了通过全连接层对交通流的预测,并且得到了交通流的时空特征。

2.3 循环神经网络

CNN在交通流预测中虽然有良好的效果,但在处理交通的时空特性时可能面临挑战。由于交通数据具有复杂的时空关联性,RNN及其变体在交通流预测中得到了广泛的应用^[30],其结构如图3所示。由于梯度消失和梯度爆炸问题的存在,标准的RNN在处理需要长期时间依赖性的任务时表现不佳。




图3 RNN 结构图

Fig.3 RNN structure diagram

在传统的标准RNN中,重复的神经元模块包含一个非常简单的结构。这个结构将隐藏层的输入值与上一个时间步的输出值进行整合,然后将整合后的结果送入一个激活函数(例如tanh()函数)。最终得到的输出即为当前神经元的输出。这种设计允许RNN能够处理序列数据,并且具有记忆能力,能够捕捉序列数据中的长期依赖关系。其公式表示如下:

$$h_t = \sigma_h(W_{xh}x_t + W_{hh}h_{t-1} + b_h) \quad (1)$$

其中, W_{xh} 是输入层到隐藏层的权重矩阵, W_{hh} 是隐藏层内部神经元之间的权重矩阵, b_h 是隐藏层的偏置向量, σ_h 是隐藏层的激活函数。

长短期记忆递归神经网络(LSTM-RNN)^[31]被用来解决RNN中的梯度消失和梯度爆炸问题。相比传统的RNN,LSTM具有门控机制,能够有选择地存储和遗忘信息,使其能够更有效地处理长期时间依赖性任务,LSTM结构如图4所示。

LSTM利用记忆单元来替换RNN的隐藏单元,其中,记忆单元主要包括遗忘门 f_t 、输入门 O_t 、输出门 i_t 这三个门控单元。




图4 LSTM 结构图

Fig.4 LSTM structure diagram

其中,遗忘门决定了当前时刻需要保留或舍弃之前细胞状态中的信息,其公式表示如下:

$$f_t = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f) \quad (2)$$

输入门决定了在当前时间步要将新的信息融入细胞状态中,其公式表示如下:

$$i_t = \sigma(W_i \cdot [h_{t-1}, X_t] + b_i) \quad (3)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, X_t] + b_C) \quad (4)$$

输出门决定了当前时间步的神经元结构要输出的值,其公式表示如下:

$$o_t = \sigma(W_o \cdot [h_{t-1}, X_t] + b_o) \quad (5)$$

$$h_t = o_t \times \tanh(C_t) \quad (6)$$

基于循环神经网络交通流预测已经得到了广泛的应用。随着时间序列长度的增加,LSTM模型在交通预测中难以解决过于长期的依赖关系。因此,Yang等^[32]提出了一种LSTM+特征增强的模型,将序列时间步长的高影响值与当前时间步长联系起来,并使用注意力机制捕捉这些高影响的交通流值,从而弥补LSTM在超长距离依赖下的不足。Zhao等^[33]融合了路网在时间和空间上的相互作用,提出了一种基于长短期记忆(LSTM)网络的交通预测模型。与传统预测方法不同,LSTM网络通过一个由多个记忆单元组成的二维网络来考虑交通系统的时空相关性。通过与其他典型预测模型的对比,验证了所提出的新型交通预测模型能够获得更好的性能。Ma等^[34]采用深度RNN-RBM架构对网络拥堵的发生、传播和消散进行建模,并试图将深度学习理论扩展到大规模交通网络分析中。Lyu等^[35]提出了一种新的基于深度学习的LC-RNN模型来预测交通速度,通过将RNN和CNN两种模型的组合,用来学习交通动态的时间序列模式。同时提出了一种网络嵌入卷积的方法来捕获道路网络特征,并通过自适应融合其他信息来进一步提高了交通预测的准确度。此外,RNN网络中的编码器-解码器结构用于流量预测,其中编码器将历史数据编码为向量表示,解码器利用此向量生成未来流量预测。编码器-解码器结构能够捕捉时间依赖关系,实现准确预测,为决策提供支持。文献[36-38]使用这种方法解决了交通预测问题。

在循环神经网络中,GRU(gated recurrent unit)是

一种变体的循环神经网络,相较于LSTM更简单,但同样解决了长期依赖和梯度消失问题。它利用重置门和更新门来控制信息流动,避免了传统RNN的内存单元,并更有效地训练,同时在序列数据处理任务上表现出良好性能。Chung等^[39]提出了一种门控反馈RNN(GF-RNN)方法,通过引入门控机制来扩展现有的叠加多个循环层的方法。这一方法利用门控循环单元(GRU)来解决梯度消失问题,通过在循环层之间引入门控机制,每个循环层都能够自主地控制信息的传递和反馈,从而改善网络对长期依赖性的处理能力,提高了网络的性能和表现。Sun等^[40]提出了一种堆叠门控循环单元模型(SSGRU),用于解决复杂道路网络中的交通流预测问题。SSGRU通过线性回归系数进行空间模式挖掘,并采用堆叠门控循环单元(SGRU)增强多道路交通流预测能力。该模型从网络角度进行预测,具备高适应性和实用性,结果显示SSGRU在提高预测准确性和降低计算成本方面优于LSTM。

2.4 图卷积神经网络

卷积神经网络(CNN)通常适用于处理具有欧几里得结构的数据,对于非欧几里得数据,如交通道路网等不规则的图网结构就表现不佳。相较之下,图卷积网络(GCN)能更有效地应对非欧式空间结构数据,在交通流预测领域,GCN^[41]逐渐取代CNN成为了研究的热点。

图卷积操作主要包括两类:基于空域和谱域的图卷积。基于空域的方法将图卷积操作定义为图中相邻节点之间的特征信息的聚合。基于谱域的方法从处理图信号出发,并且引入滤波器实现图卷积的推导,操作被解释为从图信号中去除噪声。这两种方法在处理图数据时各有优势,可以根据实际需求选择合适的方法。

基于图卷积神经网络交通预测模型,其中经典的模型是Bai等^[42]提出的一种关注时间图卷积网络(A3T-GCN)流量预测方法。A3T-GCN模型在T-GCN模型^[43]基础上,利用GRU去学习时间序列中的短时流量预测,并通过GCN捕获路网结构的时空相关性,同时引入了注意力机制,以整合全局的时间信息,以捕获时间相关性。A3T-GCN模型在SZ-taxi和Los-loop实际数据集上证明了模型的有效性和鲁棒性,其模型架构如图5所示。Ali等^[44]为了克服交通人口流量预测中的复杂的时空依赖关系以及外部因素,提出了一种图卷积网络和长短期记忆组合的动态深度时空神经网络模型(GCN-DHSTNet)。GCN-DHSTNet模型能够捕获动态时空特征和短期时间特征,并考虑了其他外部因素。Li等^[45]提出了一种名为扩散卷积神经网络(DCRNN)的模型,将交通流视为有向图上的扩散过程,并通过双向随机游走捕捉空间依赖性。尽管DCRNN在交通预测方面表现优异,但未能解决时空异质性问题。针对此问题,Jiang等^[46]提出了基于时空数据的元图学习机制模型(Mega-




图5 A3T-GCN模型图

Fig.5 A3T-GCN model diagram

CRN),该模型通过引入时空元图学习器,有效解决了交通流量的时空异质性和非平稳性问题。为了解决多数方法在融合后面临的效率问题,Wang等^[47]提出了一种名为实时融合流量门控图神经网络(Traffic-GGNN)的方法。该方法通过融合的方式提取时空相关性,并引入自注意力机制,从而提高了融合效率并提升了交通流量预测的精度。

2.5 注意力机制与Transformer

注意力机制(attention mechanism)是一种模仿人类视觉或认知系统的技术,在深度学习领域中被广泛应用。它最初在自然语言处理(NLP)领域中得到了广泛的应用^[48],后来也被应用于计算机视觉等领域。它根据输入序列中每个元素的重要性给予不同的权重,这种权重是根据每个元素与目标之间的相关性动态计算的。

Liu等^[49]提出了一种新的交通预测方法,此方法利用了注意力机制,实现了时间聚类 and 层次关注的功能。采用了基于注意力的分层机制,在每个时间步中提取特征。Zheng等^[50]提出了一种图多注意力网络(GMAN)的方法,用于预测路网图上不同时间步长的交通状况。通过转移注意力的方法,GMAN模型能够建立起历史和未来时间步长之间的关系,使用这一方法能够有效地减少交通预测的误差。Zhang等^[51]使用自我注意力机制捕捉时间序列数据,并结合生成对抗网络和强化学习机制来预测交通流量。实验结果显示,相对于基准模型DNM、LSTM等,这种方法的效果更佳。

Transformer是一种深度学习框架,用于自然语言处理等任务。Transformer放弃了传统的CNN和RNN,以注意力机制为模型基础,由self-attention和前馈神经网络组成,解决了RNN按序计算的限制,使序列中任意两个位置的距离在同一级别,解决了RNN长期依赖问题^[52]。此外,Transformer能够实现并行计算,大大提高了训练效率,同时其自注意力机制能够有效捕捉全局信息,尤其适用于长序列任务。而在结合图卷积网络(GCN)后,Transformer还可以利用GCN的优势,捕捉数据中的空间拓扑结构,增强模型的空间信息处理能力。通过将Transformer的时序全局建模能力与GCN的空间特征提取能力相结合,能够更好地解决时空数据预测问题,显著提升模型的预测性能。其Transformer模型图如图6所示。




图6 Transformer模型图

Fig.6 Transformer model diagram

例如,Cai等^[53]提出了一种新型深度学习架构(traffic Transformer),traffic Transformer架构通过GCN和Transformer分别捕获时间序列的连续性、周期性以及空间依赖性。然而traffic Transformer模型忽视了不同空间(如郊区与市中心)和时间(如高峰时段与非高峰时段)上的复杂性及其不均匀分布问题。因此,Chen等^[54]提出了一种双向时空自适应Transformer模型(Bi-STAT),该模型通过编码器回忆历史交通流数据,并通过解码器为未来预测任务提供额外的上下文信息,实验结果表明其性能优于traffic Transformer模型。此外,为了克服基于GCN的交通流预测中的过度平滑问题,Huo等^[55]提出了一种分层交通流预测网络,结合了Transformer和时空图卷积网络,以更好地捕捉交通流的短期和长期时间关系。针对长期预测问题的挑战,Xu等^[56]提出一种新的

时空 Transformer(STTNs)模型。STTNs 模型设计有一个时空块捕获动态的长期时空相关性,并提出了一种 GNNs 网络的变体获取交通流流向变化,实验证明 STTNs 在长期交通流预测方面具有优势。

目前,图神经网络在交通预测中应用广泛,大多数模型采用时空图神经网络(STGNNs)的方法进行复杂的时空信息分析。然而,这种方法结合了多种模型,导致模型结构日益复杂,影响时空交通预测的效果。为了解决这些问题,Ma 等^[57]提出了一种新的时空编码架构,融合了 Transformer,并使用预训练的语言模型来提高交通流预测的精度。

2.6 深度学习混合神经网络

深度学习混合模型整合了统计分析、机器学习以及深度学习时空数据处理技术,旨在克服单一模型的局限性,提高交通流预测的准确性和鲁棒性。通过综合多种模型和技术,混合模型能够更全面地考虑交通流的时空特征,为交通管理和规划提供更强有力的支持。混合体主要包括 CNN、RNN 和 LSTM 以及 GCN 等类别。

基于深度学习混合神经网络有学者对此展开了研究,Liu 等^[58]提出了一种端到端的深度学习框架,将卷积神经网络与长短期记忆网络(LSTM)相结合,形成了一个 Conv-LSTM 模块,用于提取交通流的时空信息特征。Ranjan 等^[59]提出了一种预测网络范围内拥堵程度的混合神经网络架构,混合神经网络架构结合了卷积神经网络、长短期记忆和转置卷积神经网络,用于捕获交通流的时空特征和时空关系。通过实验对比,该方法优于其他两种深度神经网络(auto-encoder和conv-LSTM)。Zheng 等^[60]提出一种图卷积神经网络和生成对抗网络模型(GCN-GAN),利用 GCN 模块提取历史交通流信息,使用 GAN 解决动态网络中的边缘权重稀疏性和宽阈值问题。针对交通流的短期非平稳性和时空相关性问题,Yin 等^[61]提出了一种时空混合预测模型 ST-VGBiGRU,通过融合 VMD 算法、图注意网络(GAT)和双向门控循

环单元(BiGRU)网络,不仅提高了预测精度和收敛速度,还降低了短期非平稳性的影响,并成功捕获了更多的交通流空间特征。Du 等^[62]提出了一种用于短期交通流预测的混合多模态深度学习方法,混合多模态方法结合了一维 CNN 和 GRU 模型以及联合模型组成,其模型图如图 7 所示。

混合多模态深度学习模型利用 CNN 捕捉特殊模式序列数据的局部趋势特征,结合 GRU 学习短期时间变化和长期依赖周期性特征。然后,将这些组件通过带有注意力机制的特征层融合,从而获取各个交通数据的时空特征,将这些时空特征联合作为回归层的输入,得到最终的交通量预测结果。此模型能够提取多模态数据的特征并建模时空依赖关系。这种结合能够有效处理交通数据的复杂性,提高预测的准确性和鲁棒性。

其在给定的训练模态数据集 I_i 上,每个时空特征级别可以被表示为:

$$C(I_i) \rightarrow S_i, G(S_i) \rightarrow S_i T_i, MA(S_i T_i) \rightarrow R_i$$

其中, S_i 和 T_i 分别代表从每个交通模态输入数据集 I_i 中提取的时空相关特征: S_i 表示使用 CNN 模型提取的特征, T_i 表示使用 GRU 模型提取的特征。 MA 表示带有注意机制的多模态特征级融合层, R_i 表示具有注意辅助学习 S_i 和的 T_i 共享表示。

2.7 深度学习交通预测文献对比分析

本文对深度学习在交通流预测领域的文献进行了总结与分析,按照不同的深度学习技术进行了分类,如表 1 所示。由于交通流预测缺乏统一的基准数据集,表 1 中所展示的数据集具有多样性,因此部分文献中的 MAE 和 RMSE 这两个评价指标存在一定的差异。其中,文献[45-46]都采用 PEMS-BAY 数据集和 15 min 时间间隔,文献[42-43,47]都使用 SZ-taxi 数据集和 15 min 时间间隔,文献[58]和[61]也采用相同的数据集和相同的实验配置。




图7 混合多模态深度学习模型

Fig.7 Hybrid multimodal deep learning model

表1 深度学习的交通预测文献方法的对比
Table 1 Comparison of traffic prediction literature methods by deep learning

分类	文献	数据集	MAE	RMSE	主要方法	主要特征
CNN	文献[22]	PeMS数据集	0.024	0.038	多特征深度模型	时空、外部因素
	文献[23]	GPS轨迹数据	3.430	5.070	CNN-LSTM	时空
	文献[24]	上海数据集	6.570	—	多尺度时空网络	多尺度时空特征
SAE	文献[26]	PeMS数据集	38.28	59.07	超参数组合	时空
	文献[27]	英国高速公路	—	—	SAE-LE	空间和短期时间
RNN	文献[32]	PeMS数据集	31.80	48.37	Lstm+Attention	长期时间
	文献[35]	上海数据集	—	4.68	RNN-CNN	时间、周期、上下文
	文献[45]	PEMS-BAY	1.38	2.95	扩散卷积递归神经网络	时空
	文献[46]	PEMS-BAY	1.28	2.72	元图卷积循环网络	时空
GCN	文献[43]	SZ-taxi	2.82	4.13	GCN-GRU	时空
	文献[42]	SZ-taxi	2.74	4.07	GCN-GRU-attention	时空
	文献[47]	SZ-taxi	2.64	4.03	门控图神经网络	时空融合
Attention	文献[49]	杭州萧山区	1.50	2.30	时间聚类和层次关注	时空
	文献[50]	PeMS数据集	3.55	6.38	动态图卷积	时空
	文献[53]	PeMS数据集	1.22	2.78	Transformer	时间连续性和周期性、空间
	文献[54]	PeMS数据集	—	—	Multi-head attention、GAT	时空
Hybrid	文献[58]	PeMS数据集	14.02	15.41	Conv-LSTM	时空
	文献[61]	PeMS数据集	12.27	13.32	VMD-GAT-BiGRU	时空、多模态
	文献[62]	英国高速公路	—	4.35	CNN-GRU-attention	时空、多模态

深度学习短时交通流预测领域常用的评价指标包括平均绝对误差(MAE)、平均绝对百分比误差(MAPE)和均方根误差(RMSE)。MAE是预测值与真实值之间差值的绝对值的平均数,衡量了预测误差的平均大小。RMSE是预测值与真实值之间差值平方的平均数的平方根,对预测误差的较大值更为敏感。在选择评价指标时,需要根据具体应用场景和模型特点进行选择。MAPE是预测误差的绝对值与真实值的比例的平均数,通常以百分比表示,可以评估预测的相对准确度。以下是三种交通预测常用的评价指标公式:

$$MAE = \frac{1}{J} \sum_{i=1}^J |x_i - y_i| \tag{7}$$

$$RMSE = \sqrt{\frac{1}{J} \sum_{i=1}^J (x_i - y_i)^2} \tag{8}$$

$$MAPE = \frac{1}{J} \sum_{i=1}^J \left| \frac{x_i - y_i}{x_i} \right| \times 100\% \tag{9}$$

其中, x_i 和 y_i 分别表示时间间隔 i 的交通流量的实际观测数值和预测值, J 表示交通预测测试样本的数量。

交通预测是一项极具挑战性的任务,因为它的数据是具有时空性质的。这些数据随着时间和空间的变化,展现出复杂的动态时空依赖关系。为了有效处理大规模且复杂的时空交通流数据,研究者们已经开发了多种深度学习方法。通常,卷积神经网络(CNN)用于提取交通网络数据中的空间相关性。相比循环神经网络(RNN),CNN通过多层卷积扩大感受野,从而精确控制依赖关系的长度。同时,CNN允许并行计算,而RNN依赖前一时刻的计算,需维护完整的隐藏状态,导致并行

效率较低。例如,文献[22]和文献[24]分别通过多个二维卷积和堆叠多个CNN模型,实现了多特征和多尺度的交通流预测。SAE由于很容易处理错误标记的数据,能够从交通数据中发现非线性时空相关性,通常也用于交通流预测。而循环神经网络(如RNN、LSTM、GRU)则用于捕捉交通预测中的时间相关性。例如,文献[45]在递归神经网络中融入了扩散卷积单元,更好地捕获了时间依赖性,有效提高了交通预测的精度;文献[46]引入了元图学习器,在相同数据集PEMS-BAY上的表现优于文献[45]。如图8(c)和(d)所示,在15 min间隔下,MAE和RMSE分别降低了0.10和0.23。在30 min和60 min的误差也显著降低,展现了该方法在短期交通流量预测中的优势。然而,基于RNN的模型在处理历史数据时依赖于数据的顺序,当时间序列较长时,预测精度往往会降低。为此,研究者们引入了编码器-解码器结构来处理长时间序列,尽管这种结构能有效处理长序列,但由于其长度固定,容易导致信息丢失。为了克服这一局限,注意力机制被引入到时间序列中,更好地捕捉序列中的时空相关性。例如文献[49]使用注意力的分层机制在每个时间步中提取时空特征,文献[50]也设计了一种时空图注意机制来自适应地模拟不同时间步长之间的非线性相关性,这些文献通过引入注意力机制,有效提升了交通预测的精度。然而,这些研究未充分考虑时间序列的连续性和周期性特征。因此,文献[53-54]采用了Transformer深度学习架构,从而更好地处理了时间序列的连续性和周期性问题。

此外,图卷积神经网络(GCN)将卷积运算扩展到图




图8 文献模型对比分析图

Fig.8 Comparative analysis of literature models

结构数据,这使得它更适合于表示交通网络的结构,从而提高了预测的准确性和效率。文献[42]在文献[43]的基础上引入了注意力机制,效果显著提升。如图8(a)和(b)所示,在SZ-taxi数据集中,MAE和RMSE在15 min、30 min、45 min及60 min的时间间隔内明显降低。此外,文献[47]采用时空融合方法,相较于文献[42-43]取得了显著进展。

随着深度学习技术的不断进步,在进行交通预测时,不仅要考虑数据的时空特性,还需要综合考虑外部因素,包括天气条件、周期性变化、突发事件以及道路属性等多种因素。文献[22]、[35]、[61]、[62]均考虑了外部因素。尽管文献[61]加入了多模态数据和多个模块,但其结果仍优于文献[58],MAE和RMSE分别降低1.75和2.09。这表明多模态融合是交通流预测领域未来的研究趋势之一。

2.8 深度学习交通预测超参和场景分析

基于深度学习的短时交通流预测模型中,超参数的选择对模型性能至关重要。超参数通常包括学习率、批量大小、网络层数、隐藏单元数、正则化参数以及优化器选择等。批量大小和学习率在在一定程度上影响模型的权值,从算法优化的角度来看,它们是影响模型预测性

能的关键参数。合理的超参数配置可以提升模型的预测精度和泛化能力,而不合理的配置则可能导致模型过拟合或欠拟合,从而影响预测效果。本文对深度学习交通流的超参数和场景进行了总结分析,如表2所示。

深度学习模型通常采用随机梯度下降算法或其变体进行训练。大量实验证明,当使用大批量时,模型的泛化能力会下降,这一现象被称为“泛化差距”。Hoffer等^[63]首次尝试解决“泛化差距”现象,研究了深度学习中超参数批量大小的优化方法,引入了一种简单而高效的算法“Ghost-BN”,该算法在保持训练时间不变的情况下显著提高了泛化性能。然而,此方法在处理图卷积网络时效果不佳,因此Chen等^[64]提出了一种超参数自动优化算法,讨论了批量大小和学习率对T-GCN模型的影响,并给出了最优的超参数选择。为了解决深度神经网络在地铁站客流预测中的超参数设置问题,Tsai等^[65]提出了一种新的超参数优化搜索经济学元启发式算法。该算法通过将解空间划分为一组子空间,并根据每个子空间的不同属性分配不同数量的搜索解,从而提高了搜索效率和优化效果。实验证明,该算法可用于其他基于DNN的算法解决其他复杂的优化问题。此外,在DCRNN模型中,研究了学习率和图卷积核大小对模型

表2 交通流预测中的超参数配置与场景影响分析

Table 2 Hyperparameter configuration and scene impact analysis in traffic flow prediction

模型	超参数	优化器	适应场景	主要优势
Ghost-BN	参数批量大小	—	泛化差距	提高模型在大批量情况下的泛化能力
自动优化算法	批量大小、学习率	Adam	时间图卷积网络	超参数自动优化算法能够对T-GCN的超参数进行选择
DCRNN	学习率、卷积核大小	RMSprop	长时间预测	动态调整学习率加速收敛
元启发式算法	解空间划分、搜索解数量	—	地铁车站客流预测	提高搜索效率和优化效果,适用于其他基于深度神经网络的复杂优化问题
STFGCN	卷积核大小、扩张因子	Adam	天气因素	结合时间卷积网络显著提升预测准确性
3DGCNm	K 值、超参数 θ	Adam	区域性差异、流量模式	通过 K -means 聚类捕捉空间特征
AGCRN	参数分解、节点特定参数	Adam	区域性差异、节假日	节省参数,解决参数过多的问题
STPGNN	K 值(分区数量)	Adam	区域性差异	捕捉交通道路中不同区域节点之间的时空依赖关系
ST-SSL	批量大小、学习率	Adam	工作日与节假日、时空异质性	自适应方法增强模型对时空异质性的识别能力
DHSTNet	批量大小、学习率	—	天气条件、POI	集成四个组件提升整体预测性能
MegaCRN	批量大小、学习率	Adam	高峰期与非高峰期	提升模型鲁棒性,适应多种交通状况
SAE	最佳超参数组合	SGD	白天与夜间、工作日与周末	更好地捕捉工作日与周末交通流量的差异
ST-ResNet	批量大小、学习率	Adam	天气因素	设计了残差卷积单元,并结合天气和降水因素,更好地预测了地区流量状况

性能的影响,发现动态调整学习率能够加速模型收敛,并通过网格搜索确定了最佳的卷积核大小。Qi等^[66]提出的STFGCN模型融合了天气因素与交通数据,采用随机搜索(random search)对多个超参数进行调整,从而优化了模型性能。STFGCN模型通过时序卷积网络(TCN)调整卷积核大小和扩张因子,克服了传统CNN在时间建模中的局限性,并避免了梯度消失和爆炸的问题,提升了模型的预测能力。Xia等^[67]提出的3DGCNm模型结合超参数优化的策略,分区数量 K 通过 K -means聚类将城市划分为 K 个子区域,用于捕捉区域的空间和时间特征,适当的 K 值在准确模拟区域功能与防止过拟合之间取得平衡。超参数 θ 则用于平衡标记与未标记区域的贡献,合理调节 θ 值能优化半监督节点划分效果,提升预测性能。为了解决以往深度学习模型使用共享的参数空间捕获细粒度数据时表现不佳的问题,AGCRN模型^[68]引入了节点自适应参数学习(NAPL)模块。该模块将传统图卷积网络(GCN)中的参数 θ 分解为两个矩阵,并通过节点嵌入从共享的权重池和偏差池中生成节点特定参数,从而有效解决了参数过多的问题。实验结果表明,AGCRN模型的预测效果优于STSGCN、ASTGCN以及DCRNN模型。

优化器的选择对模型性能同样关键,常见的优化器包括RMSprop、SGD和Adam。Adam优化器在交通预测领域应用广泛。例如,GraphWave-Net采用Adam优化器,凭借自适应学习率的更新策略,使模型在训练过程中快速收敛,并在大规模交通流预测任务中表现优异。DSTAGNN和ASTGCN分别尝试了SGD和Adam优化器,实验结果表明,虽然SGD在某些场景下表现良好,但Adam整体上更加稳定,尤其在处理复杂时空数据时,Adam通过动态调整梯度方向,使模型更高效地训练并获得更好的收敛性。在STSGCN模型中,研究发现

RMSprop在处理复杂时空特征的交通流预测任务中表现出色,尤其在对梯度变化敏感的场景中,加速了模型收敛。而Adam优化器通过更平滑的梯度更新,适合在噪声较大的数据集上使用。

在交通流预测中,不同方法在特定场景下的预测效果各有千秋。常见的场景包括:高峰时期的交通流量波动、长期预测、天气、节假日和特殊时段的流量变化、区域性差异(如商业区与居民区的流量差异),以及昼夜交通流量的不同。针对这些场景,研究人员提出了多种模型与方法,分别从不同角度捕捉时空依赖关系、时间异质性和空间异质性,以提高预测的准确性。其中,区域性差异是一个不可忽视的因素。由于不同地区的地理位置差异,交通流量分布存在显著不同。例如,Kong等^[69]提出了一种基于关键节点的STPGNN模型,能够捕捉交通道路中不同区域节点之间的时空依赖关系。该模型在交通预测领域取得了显著成效,预测性能优于DSTAGNN等模型。

此外,Ji等^[70]为了更好地捕获因时间变化而引起的交通模式异质性(如工作日与节假日之间的流量差异)以及区域间的空间异质性,提出了自适应时空自监督学习框架(ST-SSL)。ST-SSL模型通过自适应异质性感知的数据增强方法和自监督学习策略来建模时空异质性,从而增强了模型的识别能力,对时空异质性的理解也更加深入,在交通流预测方面也表现出色。文献[44]考虑了天气条件、兴趣点(POI)分布以及交通拥堵情况,提出了DHSTNet模型。该模型将交通流量分为四个独立的组件:最近流量、每日流量、每周流量和外部因素。通过分别分析这四个组件并集成其预测结果,模型显著提升了整体的预测性能。针对高峰期的交通流预测,文献[46]采用MegaCRN模型,成功捕捉了不同道路在高峰期与非高峰期的流量特征,且提高了模型的鲁棒性,能

够适应从正常到非平稳的多种交通状况,从而大幅提升了预测的精度。文献[26]提出的SAE模型对比分析了白天和夜间交通流预测的表现。实验结果表明,白天的MAE和RMSE值明显较大。通过整合工作日和周末的最佳超参数组合,发现该模型在这两个时间段的预测效果都相对较好,能够较好地捕捉工作日与周末交通流量的差异。此外,STFGCN模型考虑天气因素并引入时间卷积网络(TCN),显著提高了交通流预测的准确性。Zhang等^[7]提出的时空残差神经网络(ST-ResNet)也考虑了降水等天气因素对交通道路的影响,为最近、周期和趋势特征的各个属性设计了残差卷积单元。该模型通过动态整合残差卷积单元的输出,为不同分支和区域分配不同的权重,并将整合结果进一步结合外部因素,如天气状况和一周中的具体日期,从而预测整个地区的流量状况。实验结果表明,考虑天气因素后,交通流预测的精度得到了显著提升。

3 基于交通预测的数据集

高质量的数据集对于交通预测至关重要,在本章将总结用于交通预测的公共数据集。这些数据集从多个来源收集和整合,并经过数据清洗、整理和转换,以确保数据质量和完整性,从而为交通预测模型提供可靠的特征和输入。如表3所示,对交通预测的国内外的公共数据集进行了分析总结。

3.1 高速公路数据集

PeMS数据集是一个非常重要的交通数据集,用于监测和评估加州州内的交通流量和交通状况。PeMS通过实时采集来自超过39 000个单独的探测器的数据,其中,探测器数据主要是高速公路和大都市区域。这些数据包括车辆速度、流量、拥堵情况等信息,为交通管理、规划和研究提供了重要的依据。现有公开的数据集有PeMS03、PeMS04、PeMS07、PeMS08以及PeMS-BAY等。

METR-LA交通数据集包含从洛杉矶县高速公路环

路检测器收集的交通信息。洛杉矶高速数据集包含了2012年3月1日到6月30日的207个检测器检测到的交通数据,采样时间间隔为5 min。

Loop数据集主要是西雅图地区的环路数据,覆盖了I-5、I-405、I-90和SR-520这4条高速公路的数据。Loop数据集包含了来自整个323个传感器站的交通状态数据,采样时间间隔为5 min。

Los-loop数据集是由位于洛杉矶县高速公路上的环路探测器实时收集的。数据集包含了207个传感器,并记录了从2012年3月1日到3月7日的交通速度数据。这些交通速度数据每5 min进行一次汇总。

3.2 交通工具数据集

TaxiBJ数据集是一个包含北京地区出租车GPS轨迹数据和气象数据的数据集,涵盖了2013年到2016年期间超过34 000辆出租车的信息。这些数据以30 min的时间间隔进行采样。

SZ-taxi数据集是关于深圳市2015年1月1日到1月31日期间的出租车轨迹数据。数据集以深圳市的罗湖区为研究区域,包含了156条主要道路。在这个数据集中,每15 min计算一次每条道路的交通速度。

上海出租车数据集是由香港科技大学智慧城市研究组提出的,包含了2007年2月20日在中国上海的4 000辆出租车全天的GPS报告。数据集记录了车辆行驶的各种信息,包括ID、时间、经纬度、速度等,采样时间间隔为1 min。

XC-Trans数据集记录了北京市西城区在2021年6月1日到12月31日期间的订单记录,涉及3种交通方式:自行车、公交车和出租车。这些数据划分了研究区域为175个互不重叠的子区域,并统计了每种交通方式在这些子区域中的流入和流出情况。

XC-speed数据集包含2021年6月1日到12月31日北京市西城区主要道路的车速记录,每个区域内道路段的平均速度来表示区域速度。

表3 交通预测公用数据集
Table 3 Public data sets for traffic prediction

数据集	主要特点	时间间隔/min	交通数据	链接
PeMS	流量、速度	5	39 000个	https://github.com/Davidham3/ASTGCN
PeMS-BAY	速度	5	325个	https://github.com/liyaguang/DCRNN
METR-LA	速度	5	207个	https://github.com/liyaguang/DCRNN
Loop	速度	5	323个	https://github.com/lehaifeng/TGCN/A3T
Los-loop	速度	5	207个	https://github.com/lehaifeng/TGCN/A3T
NYC Bike	流量	60	13 000辆	https://github.com/lucktroy/DeepST/
TaxiBJ	流量	30	34 000辆	https://github.com/lucktroy/DeepST
SZ-taxi	流量、速度	15	156条道路	https://github.com/lehaifeng/TGCN/A3T
上海出租车数据集	速度	1	4 000辆	https://www.cse.ust.hk/scrg/
XC-Trans	流量	30	175个子区域	https://github.com/EternityZY/CCHMM
XC-Speed	速度	30	11 753个	https://github.com/EternityZY/CCHMM
Q-Traffic	速度	15	12 073个路段	https://github.com/JingqingZ/BaiduTraffic#Dataset

Q-Traffic 数据集包含了 3 个子数据集:查询子数据集、交通速度子数据集和路网子数据集。这些数据集是从中国北京的百度地图上在 2017 年 4 月 1 日到 5 月 31 日期间收集而来的。

NYC Bike 数据集记录了从纽约市城市自行车系统收集的自行车轨迹。数据集包含了 13 000 辆自行车和 800 个车站的信息。

4 交通流预测模型性能对比

通过对文献的分析,结合前人的实验结果,本文总结了交通预测模型的性能,并对比了多个公共数据集,包括 PEMS03、PEMS04、PEMS07、PEMS08 以及 METRA-LA。值得注意的是,在 METRA-LA 数据集中,选择了最优的预测时间为 5 min,具体如表 4 所示。

从表 4 中,可以看出 DSTAGNN^[72]模型在 PEMS 数据集上具有较大的表现优势,DSTAGNN 通过利用时空感知距离构建的图结构来捕捉节点之间的空间依赖关系,这使得模型能够在没有空间先验信息的情况下取得良好的性能。其次,DCRNN 模型利用扩散卷积获取空间依赖性以及用递归神经网络捕获时间动态性,ASTGCN^[73]模型利用注意力机制和图卷积捕获了空间模型和时间特征,STSGCN^[74]模型利用时空同步建模机制捕获复杂的局部时空相关性。DCRNN、ASTGCN 和 STSGCN 都利用了时空中的空间依赖性,因此在交通预测方面表现优于考虑时间序列预测的 VAR、SVM、FC-LSTM^[75]等传统模型。但是 DCRNN 和 ASTGCN 只使用两个模块对时间相关性和空间依赖性进行建模处理,共享一个模块来提取不同时间段的时空相关性,忽略了时空数据中的异质性。相反,STSGCN 模型考虑了时空数据的异质性,因此比以前的交通预测模型具有更好的性能提升。

此外,未加入注意力机制的 STGCN^[76]模型将时间依赖性与空间特征相结合,超越了时间预测模型 LSTM 和 GRU,但其在 PEMS 数据集上优于 DCRNN 和 GraphWaveNet。ASTCG^[77]模型结合了 GRU、CNN 以及注意力机制,解决了长时间依赖关系和空间相关性问题的,

PEMS04 数据集的 307 个节点的预测任务上,ASTCG 模型的 RMSE 值相较于 STGCN 模型降低较多,证明 ASTCG 模型能够增强对交通流时空特征的提取。GraphWaveNet^[78]模型依赖矩阵捕获隐藏的空间依赖性,并且能够很好地处理数据系列。尽管在 PeMS 数据集上的效果不佳,但在 METRA-LA 数据集上取得了较好的实验结果。相比 ASTGCN 模型,GraphWaveNet 在 MAE 上降低了 2.17,MAPE 上降低了 2.31 个百分点,在 RMSE 上下降了 4.12。STPGNN 模型强调捕捉交通道路中关键节点的重要性,从而更好地理解不同区域节点之间的时空依赖关系。在 PEMS 数据集上的实验结果显示,该模型的性能显著优于表中其他模型,特别是在与 GraphWaveNet、DCRNN 和 STSGCN 的比较中,STPGNN 模型大幅减少了预测误差。这表明,STPGNN 在交通流预测任务中具有更强的能力和效果。

5 未来研究方向

5.1 迁移学习

现在,大部分交通流量数据都是密集型的,但是面对异常数据,如极端天气或临时交通管制时,很难获取准确的数据。这导致训练样本中异常情况的数据量比正常情况下更小,增加了学习的难度。另外,由于每个城市的发展水平不同,各城市的交通数据量差距很大,很多城市通常存在数据稀疏的问题。针对这个问题,未来可以采用迁移学习的方法,开发自适应迁移学习框架,能够动态适应不同城市的交通特征。例如,Yao 等^[79]通过引入迁移学习方法,提出了采用元学习范式的时空网络的模型,很好地解决短期周期数据采集下的时空预测问题。Wei 等^[80]则采用多模态迁移学习方法,将知识从数据丰富的城市迁移至数据稀疏的城市,有效解决了标签稀疏的问题。然而,现有方法在整合其他辅助数据来源方面仍有不足。未来研究可以开发多源数据迁移框架,通过多任务学习和联合学习方法,将天气、事件等多模态数据协同迁移到目标城市,以提高异常情况下的预测能力。

表 4 交通预测模型的性能对比

Table 4 Performance comparison of traffic prediction models

模型	PEMS03			PEMS04			PEMS07			PEMS08			METRA-LA		
	MAE	MAPE/%	RMSE	MAE	MAPE/%	RMSE	MAE	MAPE/%	RMSE	MAE	MAPE/%	RMSE	MAE	MAPE/%	RMSE
DCRNN	18.18	18.91	30.31	24.71	17.12	38.12	25.30	11.66	38.58	17.86	11.45	27.83	2.77	7.30	5.38
GraphWaveNet	19.85	19.31	32.94	25.45	17.29	39.70	26.85	12.12	42.78	19.13	12.68	31.05	2.69	6.90	5.15
STGCN	17.49	17.15	30.12	22.70	14.59	35.55	25.38	11.08	38.78	18.02	11.40	27.83	—	—	—
ASTGCN(r)	17.69	19.40	29.66	22.93	16.56	35.22	28.05	13.92	42.57	18.61	13.08	28.16	4.86	9.21	9.27
STSGCN	17.48	16.78	29.21	21.19	13.90	33.65	24.26	10.21	39.03	17.13	10.96	26.80	3.01	7.27	—
DSTAGNN	15.57	14.68	27.21	19.30	12.70	31.46	21.42	9.01	34.51	15.67	9.94	24.77	—	—	—
ASTCG	—	—	—	14.71	10.84	17.44	—	—	—	13.13	6.47	17.85	—	—	—
STPGNN	14.37	14.23	24.62	18.34	12.49	29.64	20.52	8.75	33.38	13.90	9.01	23.05	—	—	—

5.2 多模态数据融合

随着城市交通流量不断增加,交通拥堵预测越来越依赖于各种传感器和数据采集设备,然而,传感器维护成本昂贵,数据稀疏,面对大数据时代的庞大的数据效果不佳。因此,在交通预测领域中,可以考虑使用不同类型的数据集,例如交通流量、速度、行程时间、密度、天气、人口以及图像数据等,多类型数据的融合可以提高交通预测的准确性和鲁棒性。例如,Chen等^[81]利用多源数据(POI、路网、事件、天气等)构建多源属性图,并且考虑了动态因素和静态因素,提高了短时交通流的精度。Wu等^[82]提出了一种新的跨城市深度迁移学习框架CCTP以及新的时空学习模型。他们利用源城市充足的数据模型进行训练,从中获取了动态交通的知识。

此外,在交通领域,知识分布在多源、海量的交通大数据中。因此,将知识图谱融入交通数据能够挖掘更深层次的交通语义信息,从而提高预测性能。但是多模态交通数据之间的相互依赖关系以及单模态数据的时空特征急需处理。例如,Tan等^[83]为了解决多模态数据整合复杂且不完善的问题,构建了基于城市交通系统的知识图谱,并利用该图谱实现了知识的共享与复用。通过验证城市数据集的方法,证明了该模型能有效挖掘交通实体间的关联。为了更好地融入交通预测的外部因素信息,Wang等^[84]提出了一种KGR-STGNN的方法,通过融合知识图谱和时空神经网络,用以进行地铁交通流预测。这些方法在解决多模态数据整合复杂、算法复杂度高、适用范围有限以及知识图谱的不完善等问题上仍有改进空间,是未来需要深入研究的重要方向。

5.3 基准数据集缺乏

随着交通预测领域的发展,越来越多的交通预测模型被提出,但也伴随出现了一些问题。在交通流预测领域中,缺乏一致的实验设置和标准化的公共数据集。不同的学者在不同的论文中使用的数据集不同,各个数据集的外部因素也不相同,导致难以形成有效的实际预测性能。因此,设计具有标准化的公共数据集是非常重要的。

5.4 实时预测

目前,基于深度学习短时交通流预测的方法主要是基于历史交通流数据的预测,而针对实时交通流预测的模型和方法研究相对较少。例如,Manibardo等^[85]提出实时预测研究不足的问题,强调了设计轻量级神经网络以减少计算量、提升处理速度的重要性。实时预测的挑战在于计算复杂度高、数据不完整、模型更新困难等。未来可以开发轻量级模型结构,如Tiny-GCN,通过边缘计算结合在线学习,将模型部署在交通节点实现实时处理,并通过自适应模型更新策略应对交通状况的动态变化,平衡实时性与预测准确性之间的关系。

5.5 长期预测

近年来,中短期交通流预测取得了显著的研究成

果,而长期交通流预测的研究相对较少。与短期交通流预测不同,长期预测的时间跨度通常为数月数年,甚至更长。面对长预测问题,Peng等^[86]提出一种基于强化学习的动态图卷积网络的长期预测模型。该模型利用历史交通流量数据,并且使用交通流传输图和交通流概率图表示不同节点的流量转移关系。其次,针对应用中可能出现的数据不完善的问题,他们设计了动态图生成模块并应用于长期预测中用来减少交通流预测的误差。Qu等^[87]提出了一种结合历史交通流和上下文因素的深度神经网络,通过多层监督学习挖掘交通流与上下文因素的潜在关系,实验表明该方法在预测精度上优于传统方法。

然而,长期预测依然面临预测难度大、结果不稳定、数据和模型复杂度高、时空依赖复杂等问题。另外,多步预测模型在进行长期预测时,会出现严重的误差,从而导致预测精度下降。因此,如何在现有研究工作的基础上进一步提高长期交通流预测模型的精确性,是未来的重要研究方向之一。

6 结束语

近年来,得益于深度学习技术的发展,短期交通流预测的准确性和实时性得到显著提升。本文总结了基于深度学习的交通流预测研究现状,并简要回顾了传统交通流预测方法。深入叙述了深度学习相关技术,对相关文献和方法进行了分类讨论。超参数和场景在交通预测中也是关键因素,因此进行了分析和总结,旨在为解决交通流预测问题提供新思路。此外,收集并归纳了短时交通流量预测方法所使用的公共数据集,同时对前人的模型实验结果进行了性能分析汇总。最后,本文开放性地讨论了基于深度学习的短时交通流预测方法未来可能的研究方向。尽管深度学习在交通流预测中的应用前景广阔,但仍面临时空关系复杂、预测精度不足和多数据融合困难等问题。未来研究可聚焦于这些挑战,以探索更精确的交通流预测方法。

参考文献:

- [1] KARAMI Z, KASHEF R. Smart transportation planning: data, models, and algorithms[J]. Transportation Engineering, 2020, 2: 100013.
- [2] QI Y, ISHAK S. A hidden Markov model for short term prediction of traffic conditions on freeways[J]. Transportation Research Part C: Emerging Technologies, 2014, 43: 95-111.
- [3] SUN Y X, LENG B, GUAN W. A novel wavelet-SVM short-time passenger flow prediction in Beijing subway system[J]. Neurocomputing, 2015, 166: 109-121.
- [4] DAVIS G A, NIHAN N L. Nonparametric regression and short-term freeway traffic forecasting[J]. Journal of Transportation Engineering, 1991, 117(2): 178-188.

- [5] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. *Neural Computer*, 2006, 18(7): 1527-1554.
- [6] BOUKERCHE A, WANG J. Machine learning-based traffic prediction models for intelligent transportation systems[J]. *Computer Networks*, 2020, 181: 107530.
- [7] TEDJOPURNOMO D A, BAO Z F, ZHENG B H, et al. A survey on modern deep neural network for traffic prediction: trends, methods and challenges[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2020, 34(4): 1544-1561.
- [8] JIANG W W, LUO J Y. Graph neural network for traffic forecasting: a survey[J]. *Expert Systems with Applications*, 2022, 207: 117921.
- [9] OKUTANI I, STEPHANEDES Y J. Dynamic prediction of traffic volume through Kalman filtering theory[J]. *Transportation Research Part B: Methodological*, 1984, 18(1): 1-11.
- [10] CHOROWSKI J, BAHDANAU D, SERDYUK D, et al. Attention-based models for speech recognition[J]. *arXiv:1506.07503*, 2015.
- [11] 刘静, 关伟. 交通流预测方法综述[J]. *公路交通科技*, 2004, 21(3): 82-85.
LIU J, GUAN W. A summary of traffic flow forecasting methods[J]. *Journal of Highway and Transportation Research and Development*, 2004, 21(3): 82-85.
- [12] WILLIAMS B M, HOEL L A. Modeling and forecasting vehicular traffic flow as a seasonal ARIMA process: theoretical basis and empirical results[J]. *Journal of Transportation Engineering*, 2003, 129(6): 664-672.
- [13] KUMAR S V. Traffic flow prediction using Kalman filtering technique[J]. *Procedia Engineering*, 2017, 187: 582-587.
- [14] DONG H H, JIA L M, SUN X L, et al. Road traffic flow prediction with a time-oriented ARIMA model[C]//*Proceedings of the 5th International Joint Conference on INC, IMS and IDC*, 2009: 1649-1652.
- [15] 傅贵, 韩国强, 逯峰, 等. 基于支持向量机回归的短时交通流预测模型[J]. *华南理工大学学报(自然科学版)*, 2013, 41(9): 71-76.
FU G, HAN G Q, LU F, et al. Short-term traffic flow forecasting model based on support vector machine regression [J]. *Journal of South China University of Technology (Natural Science Edition)*, 2013, 41(9): 71-76.
- [16] SUN T T, HUANG Z F, ZHU H D, et al. Congestion pattern prediction for a busy traffic zone based on the hidden Markov model[J]. *IEEE Access*, 2021, 9: 2390-2400.
- [17] CAI P L, WANG Y P, LU G Q, et al. A spatiotemporal correlative k-nearest neighbor model for short-term traffic multi-step forecasting[J]. *Transportation Research Part C: Emerging Technologies*, 2016, 62: 21-34.
- [18] MOREIRA-MATIAS L, GAMA J, FERREIRA M, et al. Predicting taxi-passenger demand using streaming data[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2013, 14(3): 1393-1402.
- [19] TU Y, LIN S K, QIAO J Z, et al. Deep traffic congestion prediction model based on road segment grouping[J]. *Applied Intelligence*, 2021, 51(11): 8519-8541.
- [20] ZHENG H F, LIN F, FENG X X, et al. A hybrid deep learning model with attention-based conv-LSTM networks for short-term traffic flow prediction[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 22(11): 6910-6920.
- [21] CHEN K, CHEN F, LAI B S, et al. Dynamic spatio-temporal graph-based CNNs for traffic flow prediction[J]. *IEEE Access*, 2020, 8: 185136-185145.
- [22] YANG D, LI S J, PENG Z, et al. MF-CNN: traffic flow prediction using convolutional neural network and multi-features fusion[J]. *IEICE Transactions on Information and Systems*, 2019, 102(8): 1526-1536.
- [23] BOGAERTS T, MASEGOSA A D, ANGARITA-ZAPATA J S, et al. A graph CNN-LSTM neural network for short and long-term traffic forecasting based on trajectory data[J]. *Transportation Research Part C: Emerging Technologies*, 2020, 112: 62-77.
- [24] ZANG D, LING J W, WEI Z H, et al. Long-term traffic speed prediction based on multiscale spatio-temporal feature learning network[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 20(10): 3700-3709.
- [25] PALM R B. Prediction as a candidate for learning deep hierarchical models of data[D]. Lyngby: Technical University of Denmark, 2012.
- [26] DUAN Y J, LYU Y S, WANG F Y. Performance evaluation of the deep learning approach for traffic flow prediction at different times[C]//*Proceedings of the IEEE International Conference on Service Operations and Logistics, and Informatics*, 2016: 223-227.
- [27] YANG H F, DILLON T S, CHEN Y P. Optimized structure of the traffic flow forecasting model with a deep learning approach[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(10): 2371-2381.
- [28] ESSIEN A, PETROUNIAS I, SAMPAIO P, et al. A deep-learning model for urban traffic flow prediction with traffic events mined from twitter[J]. *World Wide Web*, 2021, 24(4): 1345-1368.
- [29] TIAN Y, WEI C C, XU D W. Traffic flow prediction based on stack AutoEncoder and long short-term memory network [C]//*Proceedings of the IEEE 3rd International Conference on Automation, Electronics and Electrical Engineering*, 2020: 385-388.
- [30] KASHYAP A A, RAVIRAJ S, DEVARAKONDA A, et al. Traffic flow prediction models-a review of deep learning techniques[J]. *Cogent Engineering*, 2022, 9(1): 2010510.
- [31] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.

- [32] YANG B L, SUN S L, LI J Y, et al. Traffic flow prediction using LSTM with feature enhancement[J]. *Neurocomputing*, 2019, 332: 320-327.
- [33] ZHAO Z, CHEN W H, WU X M, et al. LSTM network: a deep learning approach for short-term traffic forecast[J]. *IET Intelligent Transport Systems*, 2017, 11(2): 68-75.
- [34] MA X, YU H, WANG Y, et al. Large-scale transportation network congestion evolution prediction using deep learning theory[J]. *PLoS One*, 2015, 10(3): 0119044.
- [35] LYU Z, XU J, ZHENG K, et al. LC-RNN: a deep learning model for traffic speed prediction[C]//*Proceedings of the 27th International Joint Conference on Artificial Intelligence*, 2018: 3470-3476.
- [36] LIAO B B, ZHANG J Q, WU C, et al. Deep sequence learning with auxiliary information for traffic prediction[C]//*Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2018: 537-546.
- [37] ZHANG Z C, LI M, LIN X, et al. Multistep speed prediction on traffic networks: a graph convolutional sequence-to-sequence learning approach with attention mechanism[J]. *arXiv:1810.10237*, 2018.
- [38] YE J C, SUN L L, DU B W, et al. Co-prediction of multiple transportation demands based on deep spatio-temporal neural network[C]//*Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2019: 305-313.
- [39] CHUNG J, GULCEHRE C, CHO K, et al. Gated feedback recurrent neural networks[C]//*Proceedings of the 32nd International Conference on Machine Learning*, 2015: 2067-2075.
- [40] SUN P, BOUKERCHE A, TAO Y J. SSGRU: a novel hybrid stacked GRU-based traffic volume prediction approach in a road network[J]. *Computer Communications*, 2020, 160: 502-511.
- [41] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[J]. *arXiv:1609.02907*, 2016.
- [42] BAI J D, ZHU J W, SONG Y J, et al. A3T-GCN: attention temporal graph convolutional network for traffic forecasting [J]. *ISPRS International Journal of Geo-Information*, 2021, 10(7): 485.
- [43] ZHAO L, SONG Y J, ZHANG C, et al. T-GCN: a temporal graph convolutional network for traffic prediction[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 21(9): 3848-3858.
- [44] ALI A, ZHU Y M, ZAKARYA M. Exploiting dynamic spatio-temporal graph convolutional neural networks for citywide traffic flows prediction[J]. *Neural Networks*, 2022, 145: 233-247.
- [45] LI Y G, YU R, SHAHABI C, et al. Diffusion convolutional recurrent neural network: data-driven traffic forecasting[J]. *arXiv:1707.01926*, 2017.
- [46] JIANG R H, WANG Z N, YONG J W, et al. Spatio-temporal meta-graph learning for traffic forecasting[C]//*Proceedings of the AAAI Conference on Artificial Intelligence*, 2023: 8078-8086.
- [47] WANG Y, ZHENG J, DU Y Q, et al. Traffic-GGNN: predicting traffic flow via attentional spatial-temporal gated graph neural networks[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(10): 18423-18432.
- [48] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate[J]. *arXiv:1409.0473*, 2014.
- [49] LIU D, TANG L, SHEN G, et al. Traffic speed prediction: an attention-based method[J]. *Sensors (Basel)*, 2019, 19(18): 3836.
- [50] ZHENG C P, FAN X L, WANG C, et al. GMAN: a graph multi-attention network for traffic prediction[C]//*Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 1234-1241.
- [51] ZHANG L, WU J Q, SHEN J, et al. SATP-GAN: self-attention based generative adversarial network for traffic flow prediction[J]. *Transportmetrica B: Transport Dynamics*, 2021, 9(1): 552-568.
- [52] ASHISH V. Attention is all you need[C]//*Proceedings of the 31st International Conference on Neural Information Processing Systems*, 2017: 6000-6010.
- [53] CAI L, JANOWICZ K, MAI G C, et al. Traffic transformer: capturing the continuity and periodicity of time series for traffic forecasting[J]. *Transactions in GIS*, 2020, 24(3): 736-755.
- [54] CHEN C, LIU Y, CHEN L, et al. Bidirectional spatial-temporal adaptive transformer for urban traffic flow forecasting[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, 34(10): 6913-6925.
- [55] HUO G Y, ZHANG Y, WANG B Y, et al. Hierarchical spatio-temporal graph convolutional networks and transformer network for traffic flow forecasting[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2023, 24(4): 3855-3867.
- [56] XU M X, DAI W R, LIU C M, et al. Spatial-temporal transformer networks for traffic flow forecasting[J]. *arXiv:2001.02908*, 2020.
- [57] MA J, ZHAO J, HOU Y. Spatial-temporal transformer networks for traffic flow forecasting using a pre-trained language model[J]. *Sensors (Basel)*, 2024, 24(17): 5502.
- [58] LIU Y P, ZHENG H F, FENG X X, et al. Short-term traffic flow prediction with Conv-LSTM[C]//*Proceedings of the 9th International Conference on Wireless Communications and Signal Processing*, 2017: 1-6.
- [59] RANJAN N, BHANDARI S, ZHAO H P, et al. City-wide traffic congestion prediction based on CNN, LSTM and transpose CNN[J]. *IEEE Access*, 2020, 8: 81606-81620.
- [60] ZHENG H L, LI X, LI Y F, et al. GCN-GAN: integrating graph convolutional network and generative adversarial network for traffic flow prediction[J]. *IEEE Access*, 2022, 10:

- 94051-94062.
- [61] YIN L S, LIU P, WU Y Y, et al. ST-VGBiGRU: a hybrid model for traffic flow prediction with spatio-temporal multi-modality[J]. *IEEE Access*, 2023, 11: 54968-54985.
- [62] DU S D, LI T R, GONG X, et al. A hybrid method for traffic flow forecasting using multimodal deep learning[J]. *International Journal of Computational Intelligence Systems*, 2020, 13(1): 85-97.
- [63] HOFFER E, HUBARA I, SOUDRY D. Train longer, generalize better: closing the generalization gap in large batch training of neural networks[J]. *arXiv:1705.08741*, 2017.
- [64] CHEN L, BEI L L, AN Y, et al. A hyperparameters automatic optimization method of time graph convolution network model for traffic prediction[J]. *Wireless Networks*, 2021, 27(7): 4411-4419.
- [65] TSAI C W, FANG Z Y. An effective hyperparameter optimization algorithm for DNN to predict passengers at a metro station[J]. *ACM Transactions on Internet Technology*, 2021, 21(2): 1-24.
- [66] QI X D, YAO J F, WANG P, et al. Combining weather factors to predict traffic flow: a spatial-temporal fusion graph convolutional network- based deep learning approach[J]. *IET Intelligent Transport Systems*, 2024, 18(3): 528-539.
- [67] XIA T, LIN J J, LI Y, et al. 3DGCN: 3-dimensional dynamic graph convolutional network for citywide crowd flow prediction[J]. *ACM Transactions on Knowledge Discovery from Data*, 2021, 15(6): 1-21.
- [68] BAI L, YAO L, LI C, et al. Adaptive graph convolutional recurrent network for traffic forecasting[C]//*Proceedings of the 34th International Conference on Neural Information Processing Systems*, 2020: 17804-17815.
- [69] KONG W Y, GUO Z Y, LIU Y B. Spatio-temporal pivotal graph neural networks for traffic flow forecasting[C]//*Proceedings of the AAAI Conference on Artificial Intelligence*, 2024: 8627-8635.
- [70] JI J H, WANG J Y, HUANG C, et al. Spatio-temporal self-supervised learning for traffic flow prediction[C]//*Proceedings of the AAAI Conference on Artificial Intelligence*, 2023: 4356-4364.
- [71] ZHANG J B, ZHENG Y, QI D K, et al. Predicting citywide crowd flows using deep spatio-temporal residual networks [J]. *Artificial Intelligence*, 2018, 259: 147-166.
- [72] LAN S, MA Y, HUANG W, et al. DSTAGNN: dynamic spatial-temporal aware graph neural network for traffic flow forecasting[C]//*Proceedings of the International Conference on Machine Learning*, 2022: 11906-11917.
- [73] GUO S N, LIN Y F, FENG N, et al. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting[C]//*Proceedings of the AAAI Conference on Artificial Intelligence*, 2019: 922-929.
- [74] SONG C, LIN Y F, GUO S N, 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.
- [75] SUTSKEVER I. Sequence to sequence learning with neural networks[J]. *arXiv:1409.3215*, 2014.
- [76] YU B, YIN H T, ZHU Z X. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting[J]. *arXiv:1709.04875*, 2017.
- [77] ZHANG Q, CHANG W, YIN C, et al. Attention-based spatial-temporal convolution gated recurrent unit for traffic flow forecasting[J]. *Entropy (Basel)*, 2023, 25(6): 938.
- [78] WU Z H, PAN S R, LONG G D, et al. Graph WaveNet for deep spatial-temporal graph modeling[J]. *arXiv:1906.00121*, 2019.
- [79] YAO H X, LIU Y D, WEI Y, et al. Learning from multiple cities: a meta-learning approach for spatial-temporal prediction[C]//*Proceedings of the World Wide Web Conference*, 2019: 2181-2191.
- [80] WEI Y, ZHENG Y, YANG Q. Transfer knowledge between cities[C]//*Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016: 1905-1914.
- [81] CHEN L, SHAO W, LYU M Q, et al. AARGNN: an attentive attributed recurrent graph neural network for traffic flow prediction considering multiple dynamic factors[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(10): 17201-17211.
- [82] WU Q, HE K W, CHEN X, et al. Deep transfer learning across cities for mobile traffic prediction[J]. *ACM Transactions on Networking*, 2022, 30(3): 1255-1267.
- [83] TAN J Y, QIU Q Q, GUO W W, et al. Research on the construction of a knowledge graph and knowledge reasoning model in the field of urban traffic[J]. *Sustainability*, 2021, 13(6): 3191.
- [84] WANG S, LYU Y M, PENG Y, et al. Metro traffic flow prediction via knowledge graph and spatiotemporal graph neural network[J]. *Journal of Advanced Transportation*, 2022, 2022: 2348375.
- [85] MANIBARDO E L, LANA I, LOBO J L, et al. New perspectives on the use of online learning for congestion level prediction over traffic data[C]//*Proceedings of the 2020 International Joint Conference on Neural Networks*, 2020: 1-8.
- [86] PENG H, DU B W, LIU M S, et al. Dynamic graph convolutional network for long-term traffic flow prediction with reinforcement learning[J]. *Information Sciences*, 2021, 578: 401-416.
- [87] QU L C, LI W, LI W J, et al. Daily long-term traffic flow forecasting based on a deep neural network[J]. *Expert Systems with Applications*, 2019, 121: 304-312.