

基于多特征时空图卷积网络的水运通航密度预测

董伟, 张磊磊, 金子恒, 孙伟, 高俊波

(上海海事大学信息工程学院, 上海 201306)

摘要: 面对港航信息化发展的需求, 物联网技术助力我国水运交通感知网络的建设。水运交通大数据分析已成为交通领域研究者和实践者关注的热点。在水运交通中, 各港口的通航密度具有非线性、时空相关性和异质性, 对其进行精准预测将面临巨大的挑战。提出一种基于多特征时空图卷积网络 (MFSTGCN, multi-feature spatio-temporal graph convolution network) 的预测方法, 解决了水运交通中通航密度的预测问题。MFSTGCN 方法从通航量、船舶平均航速和船舶密度 3 个特征出发, 利用空间维图卷积和时间维卷积操作有效捕获通航密度的时空相关性。在某航运平台采集的长江港口船舶自动识别系统 (AIS, automatic identification system) 数据集上进行实验, 结果表明, MFSTGCN 方法的预测效果优于时空图卷积网络 (STGCN, spatio-temporal graph convolution network) 方法的预测效果。

关键词: 水运交通; 通航密度; 时空相关性; 图卷积网络; 多特征

中图分类号: U697

文献标识码: A

doi: 10.11959/j.issn.2096-3750.2020.00176

Prediction of the waterborne navigation density based on the multi-feature spatio-temporal graph convolution network

DONG Wei, ZHANG Leilei, JIN Ziheng, SUN Wei, GAO Junbo

College of Information Engineering, Shanghai Maritime University, Shanghai 201306, China

Abstract: In the face of the development of the information technology in the port and waterway, the Internet of things (IoT) technology can help to build China's water transport perception network. The big data analysis of the waterborne transport has become a hot topic for researchers and practitioners in the field of transportation. The navigation density of each port in the water transportation is nonlinear and spatio-temporal correlation, so it is a great challenge to accurately predict it. A multi-feature spatiotemporal graph convolution network (MFSTGCN) was proposed to solve the problem of the traffic density prediction. MFSTGCN effectively captured the spatial-temporal correlation of the ship navigation density data by using the spatial convolution and temporal convolution through three features, which were navigation volume, average ship speed and ship density. The experiment was carried out on the automatic identification system (AIS) data set collected from a shipping platform. The results show that the prediction effect of the MFSTGCN model is better than the spatio-temporal graph convolution network (STGCN) model.

Key words: waterborne traffic, navigation density, spatio-temporal correlation, graph convolution network, multiple feature

1 引言

随着港航管理信息化的快速发展, 物联网技术被应用于我国内河通航管理。在“十二五”规划期

间, 交通运输部组织开展了长三角航道网及京杭大运河水系智能航运信息服务 (船联网) 应用示范工程^[1]。在江苏、浙江和上海地区开展了物联网关键技术研究及攻关, 建设内河水运交通感知网络, 满

收稿日期: 2020-05-18; 修回日期: 2020-07-06

通信作者: 孙伟, weisun@shmtu.edu.cn

足海量数据管理与区域化应用需求。在“十三五”规划期间,我国的智慧交通建设不断发展,水运领域交通大数据的服务水平和决策能力得到大幅度提高。此外,宝船网、船讯网、船队在线(HiFleet)等航运智慧平台的出现是水运交通基础数据和数据交换平台的建设成果,同时表明面向管理服务、决策与智能化应用的智慧水运研究正在不断发展。

我国的内河水运交通以内河货运船舶为主,通航密度是指在单位时间内通过某一航道断面的船舶或船队数量,它是水运交通中评价港口和航道通航情况的重要交通量,是一种典型的时空数据,同时在时间维度和空间维度上呈现相关性和异质性。通航密度的预测将为内河码头和航道的规划与建设、船舶航行安全预警和内河码头选址等提供可靠的数据支撑,对智慧水运建设具有重要的现实意义。因此,通航密度预测问题是智慧水运交通的研究热点之一。

2 交通量预测的相关研究

针对水运通航密度的预测问题,本文提出一种基于深度学习的通航密度预测方法——MFSTGCN模型。从与水运通航密度相关的多个交通量出发,使用基于STGCN的深度学习模型处理水运路网中的空间结构特征和时空相关性,既可以有效融合数据的多特征,又可以有效捕获数据的时空特性。

交通量预测是一类典型的时空数据预测问题,不同类别的交通数据内嵌于连续空间,并且随时间发生动态变化。特别地,学者们将深度学习方法用于解决时空数据预测问题,利用卷积神经网络(CNN, convolutional neural network)可以有效提取网格数据的空间特征和交通量的空间特征。从发展历程来看,交通量预测方法可分为基于统计的方法、传统机器学习方法和基于深度学习的方法3类。其中,基于统计的方法包括历史均值(HA, history average)法、自回归积分滑动平均(ARIMA, auto-regressive integrated moving average)法^[2]、卡尔曼滤波等;传统机器学习方法包括K近邻算法^[3]、支持向量机^[4]和随机森林算法等。近年来,深度学习方法被用于解决交通量预测问题,成为水运交通领域研究的热点之一。如何对复杂的时空依赖关系建模将是交通量预测的重点,对于此类时空预测问题,研究工作主要从两个方面展开:1)将问题视作时序预测类问题,将空间依赖看作是静态的,进而

采用图卷积定义空间依赖关系;2)将时间依赖看作是严格周期性的,以图卷积方法建模动态的空间依赖关系。

长短期记忆(LSTM, long short-term memory)网络以其端到端建模、易于映外生变量和自动特征抽取的特点,成为一种流行的时间序列建模框架。Ma等^[5]最先将LSTM网络应用于交通领域,借助道路交通的传感器数据预测未来的道路交通速度。之后, Ma等^[6]提出了一种基于CNN的交通速度预测方法,将交通网络作为图像进行学习,并对大规模、全网范围内的交通速度进行预测。Liu等^[7]考虑交通流数据的时间特征、空间特征和周期性特征,结合CNN和LSTM网络生成一个Conv-LSTM模块,用于提取交通流的时空特征,然后使用Bi-LSTM(Bi-directional long short-term memory)技术提取交通流的周期特征。Yao等^[8]提出了一种时空动态网络(STDN, spatial-temporal dynamic network),基于局部CNN门控机制对空间位置之间的动态相似性进行建模,并使用周期性注意力转移机制处理长期的周期性时间转移。Li等^[9]借鉴循环神经网络(RNN, recurrent neural network)提出扩散卷积递归神经网络(DCRNN, diffusion convolutional recurrent neural network),在有向图上对交通流以扩散形式进行建模,同时集成了交通流中的空间与时间依赖。其他基于RNN的研究工作包括时空多图卷积神经网络(STMGCN, spatiotemporal multi-graph convolution network)^[10]、时间图卷积神经网络(T-GCN, temporal graph convolution network)^[11]、图注意力长短期记忆(GAT-LSTM, graph attention long short-term memory)网络^[12]、基于特征的长短期记忆(FBLSTM, feature based long short-term memory)网络^[13]、时空循环卷积网络(SRCN, spatiotemporal recurrent convolutional network)^[14]。

Yu等^[15]提出了STGCN解决交通领域的时间序列预测问题,没有使用常规的CNN和RNN单元,而是将问题用图表示出来,并建立具有完整卷积结构的模型,使得模型训练速度更快、参数更少。STGCN模型通过对多尺度交通网络的建模,有效地捕获了时空相关性。冯宁等^[16]在STGCN模型的基础上,结合交通流量的周期特征,提出了多组件STGCN,通过3个组件分别建模流量数据的近期、日周期、周周期特性,并相继提出时空注意力机制

图卷积网络 (ASTGCN, attention spatial-temporal graph convolutional network)^[17]和时空同步图卷积网络 (STSGCN, spatial-temporal synchronous graph convolutional network)^[18]。ASTGCN 利用空间注意力机制捕捉不同位置之间的动态空间相关性; STSGCN 以路网结构为基础, 将多个近邻时间步的空间图连接起来, 使用图卷积方法捕获复杂的局部时空相关性, 同时针对时空网络序列的不同部分使用相互独立的组件对时空异质性进行建模。Diao 等^[19]针对空间依赖关系会随时间变化的问题提出图卷积神经网络 (GCNN, graph convolution neural network), 其核心是对拉普拉斯矩阵进行动态分析, 将张量分解融入深度学习框架, 将实时交通数据分解为一个稳定的、依赖于长期时空关系的全局分量和一个捕捉短期波动的局部分量。

目前, 交通量预测问题在道路交通领域已取得丰硕的研究成果, 但是在目标主体、数据采集方式和领域特征方面, 水运交通与道路交通有一定区别。1) 道路交通的主体是车辆, 水运交通的主体是运输船舶, 而不同类型的船舶在船舶长度和航速上存在较大差异, 单个主体之间的差异将影响交通量预测的准确性。2) 在道路交通中, 采集的交通量通常比较密集, 交通量具有平稳性, 并有明显的周期性和趋势性; 水运交通受采集手段 (如 AIS 发送频率与船速相关)、气象水文和通航状态 (如停航、施工) 等因素的影响大, 交通量的误差大、时间间隔长、波动性大, 表现出非平稳性和周期性不显著等特征。因此, 水运交通的交通量预测更具挑战性。

本文考虑水运交通的通航密度受船舶自身属性影响较大, 不能准确反映交通规律。将通航密度、船舶的平均航速与船舶密度相关特征结合起来, 建立多特征的通航密度预测模型, 克服单个主体之间差异的难点, 并可以在一定程度上解决水运交通中交通量预测的非平稳性和周期性不显著的问题。

3 问题定义

在水运交通领域, 各港口的通航情况是一个动态系统, 而内河的船舶航线较固定, 因此, 通航密度具有显著的时空特征。

3.1 水运路网

将水运路网定义为无向图 $G=(V, E, A)$, 水运路网如图 1 所示。其中, V 为节点集, 即港口或航道

重要节点 (如桥梁、水闸等) 的集合, $|V|=N$ 为节点的个数; E 为边集, 表示节点之间的连通性; $A \in R^{N \times N}$ (R 为实数) 为 G 的邻接矩阵。设在水运路网 G 上的每个节点都检测 F 个采样频率一致的时间序列数据, 即每个节点在每个时间段内都会产生一个长度为 F 的特征向量。




图 1 水运路网

用 A 表示长江中太仓港、江阴港和南京港 3 个港口之间的邻接矩阵, A 的元素表示为 A_{ij} , A_{ij} 定义如式(1)所示。

$$A_{ij} = \begin{cases} \exp\left(-\frac{d_{ij}}{\sigma^2}\right), & i \neq j, \exp\left(-\frac{d_{ij}}{\sigma^2}\right) \geq \varepsilon \\ 0, & \text{其他} \end{cases} \quad (1)$$

其中, d_{ij} 表示两港口之间的距离, σ^2 与 ε 分别取 10 和 0.5, 用于控制矩阵的分布和稀疏性。

3.2 通航密度预测

设水运路网 G 中采集的数据集由一个三阶张量表示, 即 $D(d_1, d_2, d_3)$, 其中, d_1, d_2, d_3 分别为 G 的节点集、特征向量和时间维, $D_{ij} \in R^T$ 表示节点 i 、特征向量第 j 项特征值的时间序列。设各节点的第 $f \in (1, \dots, F)$ 个时间序列为通航密度序列, 未来某一段时间范围内的通航密度为待预测的目标量。用 $x_t^{i,f} \in R$ 表示第 i 个节点的第 f 个特征在 t 时刻的值, $x_t^f \in R^N$ 表示所有节点的第 f 个特征在 t 时刻的值, $x^f = (x_1^f, x_2^f, \dots, x_\tau^f) \in R^{N \times \tau}$ 表示所有节点的第 f 个特征在 τ 时间段内的值, $x_t = (x_t^1, x_t^2, \dots, x_t^F) \in R^{F \times N}$ 表示所有节点的全部特征在 t 时刻的值。

设 $y_t^i = x_t^{i,f} \in R$ 是第 i 个节点在 t 时刻的通航密度值, 已知水运路上所有节点的历史 τ 时间段内的全部特征时间序列值为 X , 而预测目标是未来所有节点在窗口长度为 T_p 的通航密度序列 $\hat{Y} = (\hat{y}^1, \hat{y}^2, \dots, \hat{y}^N)^T \in R^{N \times T_p}$, 其中, $\hat{y}^i = (\hat{y}_{\tau+1}^i, \hat{y}_{\tau+2}^i, \dots,$

$\hat{y}_{\tau+T_p}^i \in R^T$ 表示节点 i 的预测目标。

4 MFSTGCN

本文提出的 MFSTGCN 模型是在 STGCN^[15] 的基础上增加对多特征的支持, STGCN 总体架构如图 2 所示。MFSTGCN 模型由 3 个堆叠的时空卷积块 (ST-Conv block) 和一个全连接的输出层组成, 与 STGCN 不同的是, MFSTGCN 模型的每个时空卷积块中增加了一个特征维度, 并且各特征之间共享卷积核, 建立特征之间的相关性。其中, 每个时空卷积块包含两个时间门控卷积层和一个空间图卷积层, 时间门控卷积层的卷积核数量为 64 个, 空间图卷积层的卷积核数量为 32 个。将两个时间门控卷积层和一个空间图卷积层堆叠起来, 在特征上构成一个直筒式结构。

网络输入 τ 个时间段的水运路网的交通量为 $X = (X^1, X^2, \dots, X^N)^T$ 、 $X^i = (x_1^{i,1}, x_2^{i,2}, \dots, x_\tau^{i,F}) \in R^{\tau \times F}$ (F 为特征个数) 以及对应的邻接矩阵 $A \in R^{N \times N}$ 。通过时空卷积块连贯地探索空间和时间的依赖关系, 输出 \hat{y}^i 为第 i 个节点后一时刻的预测值。

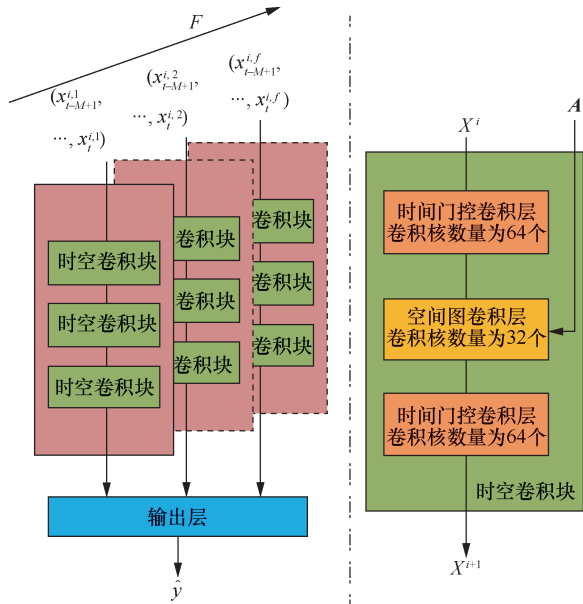


图2 STGCN 总体架构

4.1 时域卷积

时间门控卷积层为一个一维卷积, 卷积核的宽度为 K_t , 门控线性单元 (GLU, gated linear unit) 为非线性激活函数, 时域卷积块如图 3 所示。对于水运路网 G 中的各节点, 时间门控卷积层的输入序列

长度为 M , 并且有 C_i 个通道 (在本文中, 通道是指选取特征的数目), 记作 $X \in R^{M \times C_i}$ 。时域卷积是对各输入序列的 K_t 个近邻进行一维卷积运算, 则将序列长度缩短了 K_t-1 。本文采用 STGCN 中的因果卷积, 与 RNN 方法不同, 其卷积操作不需要依赖之前的输出, 可以并行计算使得模型训练速度更快。时间门控卷积计算式为

$$\Gamma * \tau X = P \odot \sigma(Q) \in R^{(M-K_t+1) \times C_0} \quad (2)$$

其中, 卷积核为 $\Gamma \in R^{K_t \times 2C_0}$, P, Q 均是 GLU 的门控输入, $[PQ] \in R^{(M-K_t+1) \times 2C_0}$, \odot 表示哈达玛积。

GLU 的门控将卷积输出结果等分为两部分, 其中一部分由 sigmoid 函数 (即 $\sigma(Q)$) 激活, 再与另一部分做哈达玛积。一方面可以保持模型的非线性, 另一方面可以防止梯度消失。由此, 每个节点的时域卷积输出长度为 $M-K_t+1$ 的序列, 记作 $Y \in R^{(M-K_t+1) \times C_0}$ 。




图3 时域卷积块

4.2 空域卷积

水运路网不同于城市道路网格结构, 其近似于稀疏图结构。因此, 使用谱图方法将卷积操作推广至图结构数据, 以捕获数据的空间结构模式和特征。在谱图方法中, 利用拉普拉斯矩阵将图结构转化为代数形式, 进而通过分析拉普拉斯矩阵以及对应的特征值分析图的拓扑属性。

将图的拉普拉斯矩阵定义为 $L = D - A$, 其规范化形式为 $L = I_n - D^{-\frac{1}{2}} A D^{-\frac{1}{2}}$ 。其中, A 为邻接矩阵, I_n 为单位矩阵, D 为度矩阵, 即 $D_{ii} = \sum_j A_{ij}$ 。

将图变换到谱域实现图上的卷积操作即为图卷积, 但当图的顶点较多时, 直接对拉普拉斯矩阵进行特征值分解的计算复杂度较大, 因此, 本文采用文献[16]的切比雪夫多项式近似展开求解拉普拉斯矩阵的特征值, 图卷积操作为

$$\Theta_g x = \Theta(L)x \approx \sum_{k=0}^{K-1} \theta_k T_k(\tilde{L})x \quad (3)$$

其中, Θ_g 为对参数矩阵 g 做的卷积, 其卷积核定义为 Θ , 切比雪夫多项式定义为 $T_k(\tilde{L}) \in R^{m \times n}$, k 为切比

雪夫多项式的阶数, $\tilde{L} = \frac{2L}{\lambda_{\max}} - \mathbf{I}_n$ 将拉普拉斯矩阵 L 缩放至 $[-1, 1]$, λ_{\max} 是 L 的最大特征值, 也称为谱半径, $\theta_i \in R^K$ 为切比雪夫多项式系数。采用切比雪夫多项式近似展开求解, 提取每个节点的 $0 \sim (K-1)$ 阶邻居节点的信息, 即更新该节点本身的特征信息。

4.3 输出层

根据时域卷积块的一维卷积, 每经过一个时空卷积块则数据在时间维度的长度将减小 $2(K_t-1)$ 。所以经过 3 个时空卷积块后, 输出为 $Y \in R^{(M-6(K_t-1)) \times n \times C_0}$ 。输出层包括一个时域卷积层和一个全连接层, 时域卷积层的卷积核大小为 $M-6(K_t-1)$, 将输出映射至 $Z \in R^{n \times C_0}$, 全连接层为 $\hat{y} = Z\omega + b$, 其中, $\omega \in R^{C_0 \times F}$ (ω 为参数矩阵, F 为特征个数), 则输出为 $\hat{y} \in R^n$ 。模型采用 L_2 损失函数, L_2 损失函数如式(4)所示。

$$L(\hat{y}; W_\theta) = \|\hat{y}(x_{t-M+1}, \dots, x_t, W_\theta) - x_{t+1}\|^2 \quad (4)$$

其中, W_θ 是所有可训练参数, \hat{y} 是预测值, x_{t+1} 是真实值。

5 实验与结果分析

为了验证本文所提模型的性能, 利用真实的内河船舶 AIS 数据集进行对比实验。本节将对数据集和实验设置进行说明, 并对实验结果进行详细的对比分析。

5.1 数据集

采用船队在线平台提供的长江下游港口的船舶 AIS 数据, 该数据集包含预先指定的太仓港水域 ($31^\circ 31.38'N \sim 31^\circ 32.42'N$, $121^\circ 21.03'E \sim 121^\circ 22.42'E$)、江阴港水域 ($31^\circ 56.35'N \sim 31^\circ 57.00'N$, $120^\circ 15.83'E \sim 120^\circ 16.70'E$) 和南京港水域 ($32^\circ 10.55'N \sim 32^\circ 10.98'N$, $118^\circ 54.90'E \sim 118^\circ 55.62'E$) 从 2018 年 3 月 1 日 0 时至 2018 年 9 月 30 日 24 时共 7 个月的船舶 AIS 数据。船舶的 AIS 数据包括: 船舶水上移动通信业务标识码 (MMSI, maritime mobile service identify)、采集时间、船位 (经纬度)、航向、船速、船艏向、转向速度、AIS 消息编号和船舶类型等信息。

5.2 数据预处理

首先, 将 3 个港口的 AIS 数据集中不完整 AIS 数据和航向异常 AIS 数据去除。其次, 以 0.5 h 为时间间隔统计船舶通航量、船舶的平均航速和船舶

密度 3 项值, 并将其作为本文模型的特征。

1) 船舶通航量: 在单位时间内通过的船舶数量 (去重复) 为

$$C_0 = \frac{1}{n} \sum_{i=1}^n c_i \quad (5)$$

其中, n 为去重复的船舶数。

2) 船舶的平均航速: 在单位时间内通过的各船舶速度之和的平均值, 如式(6)所示。

$$\bar{v} = \frac{1}{n} \sum_{i=1}^n v_i \quad (6)$$

其中, v_i 为某时间间隔内第 i 只船舶的航速。

3) 船舶密度: 航道单位长度上在某时间段内的船舶数量 (不去重复), 具体计算式为

$$k = \frac{n'}{l} \quad (7)$$

其中, n' 为不去重复的船舶数, l 为航道的长度。

在模型输入数据前, 将数据的 3 个特征分别进行最大标准化和最小标准化, 具体计算如式(8)所示。

$$X' = \frac{X - \min(X)}{\max(X)} \quad (8)$$

其中, X 为原始数据, X' 为经过标准化的数据。

5.3 实验参数和基准

基于 MXNet 框架实现了 MFSTGCN 模型, 输入船舶通航量、船舶的平均航速和船舶密度 3 个特征, 分别经过 3 个时空卷积块进行连接, 时空卷积块中两个时域卷积和一个空域卷积的输出通道数分别为 64 个、64 个和 32 个, 采用均方根误差 (RMSE, root mean-square error) 作为损失函数, 整个模型训练时间约为 13 s/轮。关于时域卷积的输入序列长度, 经实验选定, 以 12 h 的数据作为历史数据, 时域卷积窗口大小选取 3 为最佳。空域卷积中提取每个节点的 $0 \sim 2$ 阶邻居节点的信息。

将本文提出的模型与以下 4 种时间序列预测方法进行比较。

1) HA: HA 的预测值为近期历史流量状况的平均值。在本文中, 使用最近 24 个时间片的平均值预测下一个时间片的值。

2) ARIMA^[2]: ARIMA 是时间序列分析中的一种经典方法。

3) LSTM^[5]: LSTM 是一种特殊的 RNN 模型, LSTM 单元由细胞、输入门、输出门和遗忘门组成。

4) STGCN^[15] (单特征)：STGCN 是一种基于空间方法定义的时空图卷积模型，采用多种划分策略将中心节点的邻居节点划分至不同子集，实现了卷积核的参数共享。

采用 RMSE 和平均绝对误差 (MAE, mean absolute error) 共同作为评价指标，具体如式(9)、式(10)所示。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{true} - y_{pred})^2} \quad (9)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{true} - y_{pred}| \quad (10)$$

其中， n 为样本组数， y_{true} 为数据真实值， y_{pred} 为模型预测值。

5.4 实验结果及分析

在实验中，将水运交通数据集以 6:3:1 的比例分为训练集、验证集和测试集；设置 MFSTGCN 模型的训练参数，批尺寸 (batch_size) 为 100，训练轮数 (epoch) 为 100 轮，学习率 (learning_rate) 为 10^{-4} ；模型输入为各节点 12 h (每 0.5 h 为一个采集点) 的多特征数据，即序列长度为 24，输出为各节点 0.5 h 的通航密度值。将 MFSTGCN 模型与 5.3 节的 4 种方法进行比较，各方法在 AIS 数据集上的通航量预测比较如表 1 所示，表 1 是对未来 0.5 h 内通航密度的预测性能的比较结果。

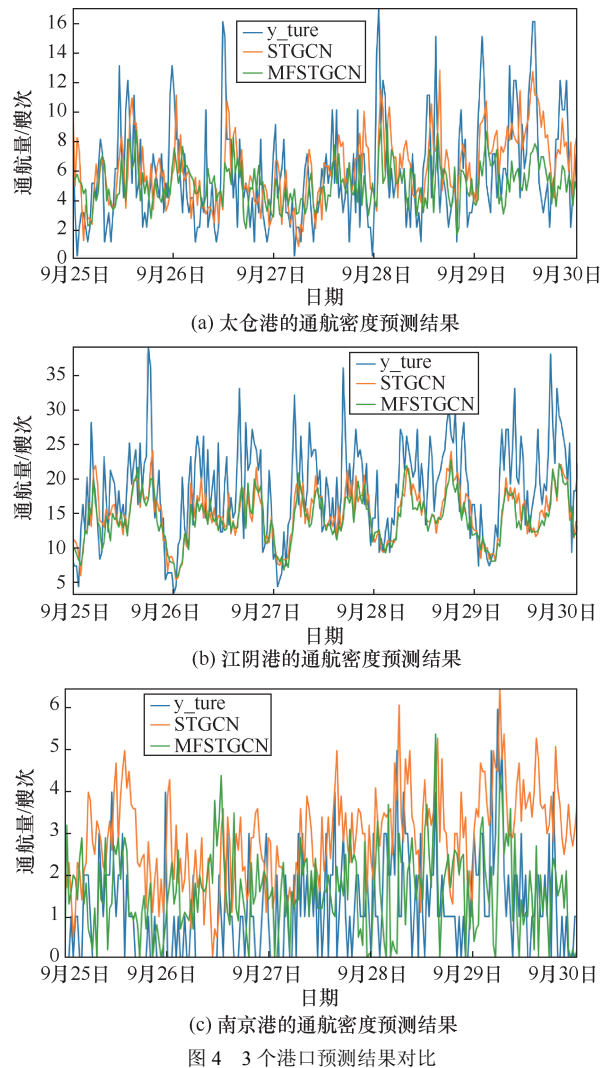
表 1 各方法在 AIS 数据集上的通航量预测比较

模型	RMSE	提升率	MAE	提升率
HA	6.01	38.4%	4.98	45%
ARIMA	4.77	22.4%	3.67	25.3%
LSTM	9.74	62%	2.15	—
STGCN	4.02	8%	2.97	7.7%
MFSTGCN (本文模型)	3.70	—	2.74	—

首先，本文提出的 MFSTGCN 模型和 STGCN 模型在 RMSE 和 MAE 两项评价指标方面优于 HA 和 ARIMA 等统计基准方法，说明 MFSTGCN 模型和 STGCN 模型更好地反映了水运交通量的时空相关性，因此，预测能力更优。其次，LSTM 模型作为深度学习中一种时序预测模型，在预测中没有利用空间相关性，虽然 MAE 指标在多个方法中更优，但 RMSE 与其他方法相比存在较大差距，说明 LSTM 模型在水运交通量这类波动性较大的数据集上表现并不理想。再次，MFSTGCN 模型较 STGCN

模型在 RMSE 方面性能提升 8%，MAE 提升 7.7%，说明多特征的引入对时空图卷积模型具有一定的提升效果。原因包括：1) 多特征模型能够关注船舶自身属性差异大这一特点，综合考虑船舶长度和船舶航速等因素，结合船舶平均速度、船舶密度和通航量 3 个特征项对通航量进行预测；2) 在水运交通中，交通量具有非平稳性和周期性不显著的特点，多特征模型可以在一定程度上反映交通量波动的原因，从而得到更优的预测结果。

为了进一步对比 MFSTGCN 模型和 STGCN 模型的时序预测能力，实验得到 2018 年 9 月 25 日至 9 月 30 日的太仓港、江阴港和南京港 3 个港口的船舶通航密度的预测结果，3 个港口预测结果对比如图 4 所示。



由实验结果可知：1) MFSTGCN 模型和 STGCN 模型都较好地预测了船舶通航密度的时序变化趋

势,但波动性方面与真实值存在差距;2) MFSTGCN 模型较 STGCN 模型更准确地预测了真实值的时序变化趋势细节,如太仓港 9 月 28 日的实验数据以及南京港 9 月 26 日和 9 月 27 日的实验数据,这是 MFSTGCN 方案更优的主要原因;3) 由于南京港的采集数据中存在一些零值,所以 STGCN 模型对南京港的预测结果与真实值存在较大出入;4) MFSTGCN 模型较 STGCN 模型预测结果更平稳,波动性更弱,如江阴港 9 月 29 日的实验数据,说明多特征的应用对预测结果有一定的修正作用。

接下来,为了观察 MFSTGCN 模型的参数选择对预测结果的影响, `batch_size` 和 `learning_rate` 分别取值为 $\{50,100\}$ 和 $\{10^{-3}, 10^{-4}\}$, 并进行了实验对比,选择不同 `batch_size` 与 `learning_rate` 的预测对比如表 2 所示。

表 2 选择不同 `batch_size` 与 `learning_rate` 的预测对比

<code>batch_size</code>	<code>learning_rate</code>	RMSE	MAE
50	10^{-3}	4.28	3.13
	10^{-4}	3.83	2.71
100	10^{-3}	4.00	2.83
	10^{-4}	3.70	2.74

由表 2 可知,当 `batch_size`=100、`learning_rate`= 10^{-4} 时, RMSE 相对较小。因此,将其作为本文实验选定的模型训练参数。

6 结束语

本文从水运交通中交通量的特点出发,提出了一种基于 MFSTGCN 的水运通航密度预测方法。该方法结合图卷积和标准卷积构造时空卷积块来同时捕获交通数据的时空特性,并将通航密度、船舶密度和平均船速等多个特征应用于预测模型,解决了水运交通量非平稳、随机性强和周期性不显著等特征造成的预测准确率低的问题。通过内河水运船舶 AIS 数据集上的实验,验证了本文所提模型在预测准确率上优于其他对比模型,表明该模型在捕获时空特征及时空相关性方面具有一定优势。本文探索了图卷积网络在水运交通领域中的应用,对智能水运交通的发展具有重要的现实意义。

参考文献:

[1] 董耀华, 孙伟, 董丽华, 等. 我国内河“船联网”建设研究[J]. 水运工程, 2012(8): 145-149.
DONG Y H, SUN W, DONG L H, et al. On construction of Internet of

ships[J]. Water Transport Engineering, 2012(8): 145-149.
[2] 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.
[3] VAN L H, VAN H C. Short-term traffic and travel time prediction models[J]. Transportation Research E-circular, 2012, 22(1): 22-41.
[4] JEONG Y S, BYON Y J, CASTRO-NETO M M, et al. Supervised weighting-online learning algorithm for short-term traffic flow prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2013, 14(4): 1700-1707.
[5] MA X L, TAO Z M, WANG Y H, et al. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data[J]. Transportation Research Part C: Emerging Technologies, 2015, 54: 187-197.
[6] MA X L, DAI Z, HE Z B, et al. Learning traffic as images: a deep convolutional neural network for large-scale transportation network speed prediction[J]. Sensors, 2017, 17(4): 818.
[7] LIU Y P, ZHENG H F, FENG X X, et al. Short-term traffic flow prediction with Conv-LSTM[C]//2017 9th International Conference on Wireless Communications and Signal Processing (WCSP). IEEE, 2017: 23-31.
[8] YAO H X, TANG X F, WEI H, et al. Revisiting spatial-temporal similarity: a deep learning framework for traffic prediction[C]//The AAAI Conference on Artificial Intelligence, 2019, 33: 5668-5675.
[9] LI Y G, YU R, SHAHABI C, et al. Diffusion convolutional recurrent neural network: data-driven traffic forecasting[C]//International Conference on Learning Representations. 2018.
[10] GENG X, LI Y G, WANG L Y, et al. Spatiotemporal multi-graph convolution network for ride-hailing demand forecasting[C]//The AAAI Conference on Artificial Intelligence. 2019, 33: 3656-3663.
[11] 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, 2019: 1-11.
[12] WU T L, CHEN F, WAN Y. Graph attention LSTM network: a new model for traffic flow forecasting[C]//2018 5th International Conference on Information Science and Control Engineering (ICISCE). IEEE, 2018: 241-245.
[13] 邓焯堃, 万良, 丁红卫, 等. 基于深度学习的交通流量预测研究[J]. 计算机工程与应用, 2019, 55(2): 234-241.
DENG X K, WAN L, DING H W, et al. Research on traffic flow prediction based on deep learning[J]. Computer Engineering and Applications, 2019, 55(2): 234-241.
[14] YU H Y, WU Z H, WANG S Q, et al. Spatiotemporal recurrent convolutional networks for traffic prediction in transportation networks[J]. Sensors, 2017, 17(7): 1501.
[15] YU B, YIN H T, ZHU Z X. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting[J]. Proceedings of the 27th International Joint Conference on Artificial Intelligence (IJCAI), 2018: 297-322.
[16] 冯宁, 郭晟楠, 宋超, 等. 面向交通流量预测的多组件时空图卷积网络[J]. 软件学报, 2019, 30(3): 759-769.
FENG N, GUO S N, SONG C, et al. Multi-component spatial-temporal graph convolution networks for traffic flow forecasting[J]. Journal of Software, 2019, 30(3): 759-769.
[17] GUO S N, LIN Y F, FENG N, et al. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting[C]//The AAAI Conference on Artificial Intelligence. 2019, 33: 922-929.

- [18] 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]//The AAAI Conference on Artificial Intelligence. 2020, 34(1): 914-921.
- [19] DIAO Z L, WANG X, ZHANG D F, et al. Dynamic spatial-temporal graph convolutional neural networks for traffic forecasting[C]//The AAAI Conference on Artificial Intelligence. 2019, 33: 890-897.



金子恒（1997-），男，上海人，上海海事大学硕士生，主要研究方向为深度学习、时序数据分析。

[作者简介]



董伟（1995-），男，安徽合肥人，上海海事大学硕士生，主要研究方向为注意力机制、海事交通大数据分析。



孙伟（1978-），男，黑龙江哈尔滨人，博士，上海海事大学副教授，主要研究方向为智能感知与优化、海事交通大数据分析等。



张磊磊（1996-），男，山西交城人，上海海事大学硕士生，主要研究方向为图卷积神经网络、海事交通大数据分析。



高俊波（1972-），男，安徽马鞍山人，博士，上海海事大学副教授，主要研究方向为人工智能、情感倾向分析、机会发现等。