Journal of Nanjing University of Aeronautics & Astronautics (Natural Science Edition)

DOI:10.16356/j.1005-2615.2025.02.016

# 数据缺失下的航班地面保障关键环节时间预测

顾思诗<sup>1</sup>, 吴薇薇<sup>1</sup>, 蒋 燕<sup>2</sup>, 张皓瑜<sup>1</sup>

(1.南京航空航天大学民航学院,南京 211106; 2.中国国际航空股份有限公司地面服务部枢纽运行中心, 北京 101300)

摘要:准确预测航班地面保障关键环节时间可以更高效地为航班过站做好保障工作,实现航班精细化管理。在 实际航班运行生产过程中,保障数据缺失与异常普遍发生。传统预测模型在面对数据缺失挑战时,其预测性能 往往遭受显著制约。为克服此局限,在因果图卷积网络(Causal graph convolutional network, CGCN)的基础上, 引入动态时间规整(Dynamic time warping, DTW)模块,构建了面向数据缺失场景的航班保障时间节点预测模 型。通过缺失值的自主式处理与时空特征的深入挖掘、为数据缺失下的航班地面保障时间预测提供了一种更为 有效的解决方案。以国内某大型机场航班保障数据集(共6480条数据)为例进行验证,实验结果表明:与考虑缺 失值的因果图卷积网络(Causal graph convolutional network with missing data, CGCNM)、动态时空图卷积神经 网络(Dynamic spatial-temporal graph convolution network, DSTGCN)、贝叶斯时间因子矩阵分解(Bayesian temporal matrix factorization, BTMF)、长短期记忆网络(Long short-term memory, LSTM)等7种基准模型相比, 所提模型在20%~80%缺失率的场景下,各保障时间节点预测结果的平均绝对误差(Mean absolute error, MAE)至少降低8.1%,均方根误差(Root mean square error, RMSE)至少降低4.6%;且随着缺失率的增加,所提 模型的优势更加明显。实例证明,建立的考虑缺失值的航班地面保障时间预测模型在预测精度和预测稳定性上 都优于上述基准模型,能够为机场保障运行提供客观可靠的决策依据。 关键词:航空运输:时间预测:深度学习:航班保障网络:数据缺失

中图分类号:V351.11;U8 文献标志码:A **文章编号:**1005-2615(2025)02-0349-12

## Time Prediction of Key Links in Flight Ground Support Under Missing Data

GU Sishi<sup>1</sup>, WU Weiwei<sup>1</sup>, JIANG Yan<sup>2</sup>, ZHANG Haoyu<sup>1</sup>

(1. College of Civil Aviation, Nanjing University of Aeronautics & Astronautics, Nanjing 211106, China;

2. Hub Operation Center, Ground Services Department, Air China Limited, Beijing 101300, China)

Abstract: Accurate flight ground service time prediction can improve the flight transit efficiency and realize flight refinement management. However, the lack and abnormality of relevant data make the research more challenging in real scenarios. To this end, a flight ground service time prediction model considering missing values is proposed. A dynamic time warping (DTW) algorithm is introduced on the basis of the causal graph convolutional network (CGCN) to realize the prediction of flight ground service link time under different data missing modes and missing rates. The flight support dataset (6 480 items) of a large airport in China is used as an example for validation. The results show that the proposed model can maintain high prediction performance under conditions of 20%-80% missing rates, compared with the remaining seven benchmark models including causal graph convolutional network with missing data (CGCNM), dynamic spatial temporal graph convolution network (DSTGCN), Bayesian temporal matrix factorization (BTMF), long

第 57 卷第 2 期 2025年4月

基金项目:国家自然科学基金(U2033205,U1933118);民航局安全能力专项项目(1007-IMH22004);南京航空航天大学 科研基金(1007-YAT23021)。

收稿日期:2024-06-06;修订日期:2024-12-17

通信作者:吴薇薇,女,教授,博士生导师,E-mail:nhwei@nuaa.edu.cn。

引用格式:顾思诗,吴薇薇,蒋燕,等.数据缺失下的航班地面保障关键环节时间预测[J].南京航空航天大学学报(自然 科学版), 2025, 57(2): 349-360. GU Sishi, WU Weiwei, JIANG Yan, et al. Time prediction of key links in flight ground support under missing data[J]. Journal of Nanjing University of Aeronautics & Astronautics (Natural Science Edition), 2025, 57(2):349-360.

short-term memory (LSTM), etc. The mean absolute error (MAE) of the prediction results for each service time node is reduced by more than 8.1%, and the root-mean-square error (RMSE) is reduced by more than 4.6%. The experiment demonstrates that the proposed model is better than the baseline model in terms of prediction accuracy and prediction stability. It can provide an objective and reliable decision-making basis for flight support operations.

Key words: air transportation; time prediction; deep learning; flight support network; missing data

近年来,随着航空运输量的不断增长,航班的 高密度运行已成为常态,如何缓解机场航班延误与 保障运行安全成为亟待解决的关键问题。航班地 面保障工作作为机场运行的核心环节,面对航班流 量的激增、保障资源的紧缺以及相关关系的模糊 性,对各类干扰的敏感度显著提高。换言之,在保 障过程中即便是微小的扰动,也可能对航班的正常 运行产生显著影响,导致航班延误<sup>[1]</sup>。因此,对航 班保障时间节点的精准预测是实现航班精细化管 理、提升保障工作抗干扰能力、减少航班延误的关 键<sup>[2]</sup>。机场管理人员可以根据预测结果对航班排 序、资源优化、旅客引导等做出决策,从而提高机场 运行效率和保障作业精细化程度,并改善乘客出行 体验,提升旅客满意度。

目前国内外学者在航班保障预测方面已经积 累了许多研究,除了单环节保障时长的预测外<sup>[3-5]</sup>, 更多的研究集中于整体保障时间的预测。现有的 预测模型主要有贝叶斯网络<sup>[2,6]</sup>、支持向量机<sup>[7]</sup>、线 性回归和随机森林<sup>[8]</sup>、神经网络<sup>[9-11]</sup>以及混合启发 式算法<sup>[12]</sup>等。然而,现有研究方法存在不足,主要 体现在以下两个方面。

首先,上述预测模型对于缺失或异常数据的处 理通常采用删除的方式,预测性能受到显著的影响 和限制。在现实场景中,航班保障数据的采集主要 依赖于传感器设备和人工记录,由于设备故障、数 据接口不稳定以及人工失误导致的数据缺失是无 法避免的,这为航班保障时间的预测带来了更大的 挑战<sup>[13]</sup>。目前基于缺失数据的时空预测研究主要 分为两种。第1种是在进行预测之前使用一系列 插补算法等对缺失数据进行填补。然而这类方法 对数据集长度的要求会更高,并且预测误差的叠加 会导致预测精度下降,尤其是对于高缺失率的数 据<sup>[14]</sup>。因此许多学者提出了第2种方法,即一步式 精准预测,主要集中在地面交通、地理气象等领 域。张壮壮等[15]针对交通流预测问题,提出了一 种连续缺失数据情况下的时空卷积神经网络预测 模型,实现了不同缺失模式下的交通流的预测。张 海静[16]基于深度学习的框架,通过深度置信网络 和卷积神经网络提取交通流量的时空特征,结合长 短期记忆网络(Long short-term memory, LSTM) 神经网络对高峰时期的短时交通流进行预测。王 培晓等[14]考虑数据缺失的情况,设计了一种因果 图卷积网络,实现一步式时空预测。徐东伟等<sup>[17]</sup>结合节点向量和生成对抗网络,实现数据缺失下的 交通流预测。易茜等<sup>[18]</sup>在碳耗预测问题中,改进 了生成对抗填补网络,引入正则化机制实现对碳耗 数据的预测。然而在航班保障预测领域,相关研究 还非常少,Liu等<sup>[13]</sup>首次将其应用于航班地面保障 时间预测问题中,并提出了一种新的滑动双向图网 络模型框架,借助图卷积网络来处理缺失值的预测 问题。

其次,随着人工智能技术的兴起,已经有许多 学者将机器学习、深度学习的方法运用于航班地面 保障预测。Lian等<sup>[7]</sup>对比了经典回归算法与人工 神经网络算法,提出一种基于粒子群优化的改进支 持向量机算法,用以预测飞机的推出滑行时间。 Yin 等<sup>[8]</sup>考虑了地面瞬时流量指数、地面累积流量 指数等4个预测因子,提出一种基于随机森林的飞 机起飞滑行时间预测模型。Yuan等<sup>[9]</sup>分析了影响 航班过站时间的关键因素,采用3层BP(Back propagation)神经网络对航班过站时间展开预测。 邢志伟等<sup>[10]</sup>基于自适应多层遗传算法对传统 BP 神经网络进行改进,实现了航班保障时间的精准估 计。此外,考虑到航班保障资源到位时间的不确定 性,邢志伟等<sup>[11]</sup>还提出一种基于深度神经网络的 航班过站保障时间预测模型。然而,传统的机器学 习模型在训练学习时,主要关注如何更精确地拟合 每个特征与目标值的关系,通过综合考量得出最终 的预测值。这样的方法会存在一定缺陷,即忽略了 特征间可能存在的时间因果关联,这种时间上的依 赖关系在模型中并未得到充分体现。与此不同,因 果卷积网络则明确考虑到了这一关键因素。它不 仅能够处理多维特征之间的复杂关系,还能有效地 捕捉和利用时间上的因果依赖,从而使得预测结果 更加准确和可靠<sup>[19]</sup>。

从研究现状来看,因果卷积网络与图卷积网络 在时空特征挖掘方面具有显著优势,但在航班地面 保障预测领域应用较少,且缺乏对数据缺失情况的 考虑。因此,本文聚焦不同数据缺失模式下的航班 地面保障节点时间预测问题,提出一种融合了动态 时间规整(Dynamic time warping, DTW)的因果图 卷积网络(Casual graph convolutional neural, CGCN)预测模型。所提模型能够有效解决数据缺 失场景下的保障时间节点预测问题,提升不同缺失 模式乃至高缺失率情况下的预测精度与稳定性,实现对航班地面保障各时间节点的精细化预测。

## 1 问题描述

## 1.1 航班保障流程

航班地面保障是机场运行管理中的重要一环, 对于航班能否正常推出起着关键作用。本文研究的 航班地面保障过程主要是指从上轮挡开始到撤轮档 结束,以旅客登机、航油加注、行李货邮装卸等环节 为核心的机坪保障活动。机场航班地面保障流程的 关键环节及相应时间节点如图1所示,任何一个节点 发生延误都有可能影响航班乃至整个机场的正常运 行。因此航班地面保障是一个具有严格服务时序、 多资源协同运作的复杂流程控制问题。





#### 1.2 数据缺失下的航班保障时间预测

近年来,图卷积网络由于其强大的图结构关系 提取和表达能力,被广泛应用于交通领域。基于空 间图结构的方法在道路交通缺失数据的预测问题 中也表现出了良好的性能<sup>[14-17]</sup>。由于航班地面保 障服务流程是由一系列保障工作节点组成,与道路 交通网络具有相似的结构特征,因此也可以将其抽 象为一种空间图结构,即将不同的保障节点理解为 空间节点<sup>[13]</sup>。基于上述分析,航班地面保障流程 网络可以抽象为图结构 $G = (V, \epsilon, A)$ ,其中V是节 点集合,表示图 G中一共有 n个保障节点, ε表示各 保障节点之间的关联关系, A则表示节点间的加权 关联矩阵。

$$V = \left\{ v_i \right\}_{i=1}^n \tag{1}$$

按照机场航班序列对时间进行离散处理,分成 若干个时间窗口,每一个航班t对应一个时间窗口  $\tau_t$ ,因此可以得到一个航班保障网络时间图序列 (Time-graph series, TGS),如图2所示。

$$\Gamma GS = \left\{ G^{t} \right\}_{t=1}^{m} \tag{2}$$





每个航班保障环节代表一个空间节点,每个航 班对应的保障时间窗口代表一个时间节点。因此, 图 *G*<sup>'</sup>中的每个保障节点都对应了一个时空数据 *x*<sup>'</sup><sub>i</sub>,表示节点 *v*<sub>i</sub>在时间窗口 *τ*<sub>i</sub>内采集到的数值,即 航班 *t*所对应的保障节点 *v*<sub>i</sub>的运行时刻。图 *G*<sup>'</sup>中 所有保障节点的时空数据可以用时空状态矩阵 *X*∈R<sup>n×m</sup>来表示,如图3所示。其中

$$\boldsymbol{x}_{i} = \left\{ \boldsymbol{x}_{i}^{t} \right\}_{i=1}^{m} \in \mathbf{R}^{1 \times m} \tag{3}$$

表示保障节点 v<sub>i</sub>在所有时间窗口下的时间序列。 在时间序列上观测到的保障数据称为时间维度观



Fig.3 Temporal and spatial data graph of flight ground service

测值。

$$\boldsymbol{x}^{t} = \left\{ \boldsymbol{x}_{i}^{t} \right\}_{i=1}^{n} \in \mathbf{R}^{n \times 1}$$

$$\tag{4}$$

表示航班 t 对应的时间窗口 τ<sub>t</sub>下所有保障节点的空间序列。在空间序列上观测到的保障数据称为空间维度观测值。

为了处理保障网络中缺失的节点数据,引入一个 0-1 掩码矩阵  $M \in \mathbb{R}^{n \times m}$ ,该矩阵用于区分时空数 据中的真实值与缺失值。如果保障节点  $v_i$ 在时间 窗口  $\tau_i$ 内的数据缺失,则  $m'_i = 0$ ,即  $x'_i$ 为空。因此,  $m_i \in \mathbb{R}^{1 \times m}$ 用于区分时间序列  $x_i$ 中的真实值与缺失 值, $m' \in \mathbb{R}^{n \times 1}$ 用于区分空间序列 x'中的真实值与 缺失值。最终,图 G'可以用式(5)表示。

$$G^{t} = \langle V, \varepsilon, A, x^{t}, m^{t} \rangle \tag{5}$$

因此,本文将构建一个函数f,基于含有缺失数 据的航班保障网络时间图序列,准确预测未来航班 的保障节点时空数据,即如式(6)所示,W表示模 型中需要学习的参数。

$$\hat{\boldsymbol{G}}^{m+1} = f\left(\left\{\boldsymbol{G}^{t}\right\}_{t=1}^{m}, \boldsymbol{W}\right)$$
(6)

## 2 航班保障时间节点预测模型

本文采用的模型为考虑数据缺失的时间动态 规整因果图卷积网络(Dynamic time warping causal graph convolutional network with missing data, DTWCGCNM)。该模型由两大核心组件构成:缺 失值处理机制和时空特征提取模块。在缺失值处 理部分,模型致力于挖掘时间图序列中缺失数据的 模式,并根据这些模式自动修复不同类型的缺失 值。而在时空特征提取部分,模型专注于描绘时空 图序列间的复杂关联。在图卷积技术中融入动态 时间规整算法来揭示数据间的空间依赖关系,并运 用因果卷积技术来探索时间序列中的时间因果联 系。最后,通过最小化模型预测值与真实观测值之 间的损失函数,实现对模型参数的优化。图4展示 了模型的全流程。



图4 航班保障时间节点预测模型全流程 Fig.4 Overall schematic of the proprosed model

## 2.1 航班保障数据缺失值处理

本文将保障数据的缺失模式分为随机缺失和 连续块状缺失两种<sup>[15]</sup>。

定义1 随机缺失:随机缺失是指单个时间点 上的观测值出现缺失,在这种模式下,缺失的发生 是随机的,不依赖于未观测到的数据值本身。

定义2 连续块状缺失:连续块状缺失是指数 据在时间序列上连续缺失多个观测点。这种缺失 往往由系统故障、记录中断或特定事件引起,导致 一段时间内无法获取数据。

为了更清晰地表达这两种缺失模式的内涵,本 文以一个小案例加以说明。在某时段内有8个航 班,对应了8个时间窗口 $\tau_1 \sim \tau_8$ ,每个航班有16个保 障节点 $v_1 \sim v_{16}$ ,其中加油环节结束节点为 $v_{30}$ 。假设 航班4的加油环节结束时间缺失,即 $x_3^4$ 为缺失值。 此时,若航班4的邻近航班的航班加油结束时间节 点数据并未缺失,则 $x_3^4$ 属于随机缺失;反之,若航 班4的邻近航班的加油结束时间节点数据也缺失, 则 $x_3^4$ 属于连续块状缺失,如图5所示。

为了实现对数据缺失模式的精确辨识,本文引 入一个辅助变量 p'





表示缺失值*x*;距离最近一次观测值的时间间隔步长,其计算方法为

$$p_{i}^{t} = \begin{cases} \tau_{t} - \tau_{t-1} + p_{i-1}^{t} & t > 1, \ m_{i}^{t-1} = 0\\ \tau_{t} - \tau_{t-1} & t > 1, \ m_{i}^{t-1} = 1 \ 0 \end{cases}$$
(8)

式中:当 $p'_i$ =1且 $m'_i$ =0时,节点 $v_i$ 在时间窗口 $\tau_i$ 内趋向于随机缺失模式,即只有单个时间窗内的数 据缺失;当 $p'_i$ >1且 $m'_i$ =0时,节点 $v_i$ 在时间窗口  $\tau_i$ 内趋向于连续块状缺失模式,即至少连续3个时 间窗的数据都缺失。

在随机缺失模式下,数据的整体趋势在时间维 度上是连续的,因此当某个时间点的数据缺失时, 可以通过相邻时间点的观测值来预测推断。在连 续块状缺失模式下,由于数据的缺失跨越了多个时 间窗,因此时间维度上的连续性被打破。相比之 下,在空间维度上可能存在的某种模式或规律,可 用于该节点的缺失值推断。例如,当某个航班的加 油结束节点数据缺失时,可以通过邻近航班的加油 节点数据对其进行推断补全;当连续多个航班的加 油结束节点数据全部缺失时,说明该节点的数据采 集或存储过程存在问题,无法再从时间(航班)维度 进行推断,此时可以寻找与加油结束节点具有相似 时间模式的其他保障节点(例如食品配餐等),通过 类比推理对缺失值进行补全。因此,可以得出结 论:在随机缺失模式下,缺失值与时间维度观测值 的关联性更高;在连续块状缺失模式下,缺失值与 空间维度观测值的关联性更高。基于该分析结果, 本文将采用空间观测值和时间观测值的加权组合 作为缺失值的最终估计结果,权重的确定依赖于具 体的缺失模式,计算方法为

式中: $x^{\text{etm}}$ 表示所有节点在时间维度上的最近一次 可直接观测到的数据值; $x^{\text{tsm}}$ 表示所有节点在空间 维度上的最相似观测值,通过计算节点间的空间相 似性向量,得到与目标节点最为相似的节点进行数 据迁移,如图6所示; $\delta'$ 表示由P'计算的缺失模式 概率,当 $\delta'$ 趋近于1时,缺失数据模式趋向于随机 缺失,当 $\delta'$ 趋近于0时,缺失数据模式则趋向于连 续块状缺失; $W_a$ 和 $q_a$ 分别表示在缺失数据处理过 程中可优化的参数。本文的模型并不是直接通过 观测值来填补缺失值,而是考虑到最终的时空预测 任务,不断地对权重 $W_a$ 进行学习,从而自主确定 缺失值的处理策略。



Fig.6 Spatial-temporal correlation of the target node

#### 2.2 航班保障网络时空特征挖掘

本文采用的预测算法结合了图卷积网络和因 果卷积网络,旨在挖掘航班保障时间图序列的时空 依赖关系。具体而言,基于图卷积操作,目标节点 能够有效地整合其邻域节点的状态信息,从而捕捉 空间维度上的关联性。同时,利用因果卷积操作, 目标节点能够吸收其自身的历史状态信息,进而在 时间维度上建立关联性。这两种操作的结合使得 算法能够全面分析航班保障时间图序列中的时空 依赖关系。

### 2.2.1 基于图卷积的空间依赖挖掘

由于航班地面保障过程是一个具有严格时间 约束和空间约束的复杂流程,各保障环节之间存在 相互影响的显性关系与隐性关系,例如下客环节延 迟会影响后续清洁、加油等环节,体现出了节点间 的显性影响关系。而各节点之间的隐性影响关系 则需要通过数据进一步挖掘。因此,准确获取节点 间的空间依赖关系是保障时间预测的一个关键问 题。传统的卷积神经网络(Convolutional neural network, CNN)在局部空间特征提取方面表现出 色,但其应用范围主要局限于欧几里得空间,如图 像处理和规则网格数据等[17]。本文的航班保障网 络不是二维网格,CNN模型不能反映节点间的拓 扑结构。近年来,CNN被推广到可以处理任意图 结构数据的图卷积网络(Graph convolutional network, GCN)中,受到了广泛的关注,且GCN模型 已成功应用于许多领域,包括流量预测、轨迹识别 和图像分类等[16]。因此,本文采用图卷积网络来 挖掘各保障节点间的空间依赖关系。在图卷积操 作中,目标保障节点在空间维度上接收邻域节点的 状态信息,其计算方法为

$$*^{g} v_{i} = \sum_{j \in N_{i}} A_{ij} x_{j} W_{g}$$
(10)

式中:\*<sup>8</sup>表示图卷积操作;N<sub>i</sub>表示节点v<sub>i</sub>的空间领 域集合;W<sub>g</sub>表示图卷积操作中需要学习的参数; A<sub>ii</sub>表示节点间加权邻接矩阵。

在图卷积操作中,邻接矩阵起着关键作用,它 决定了节点自身及其邻域信息的聚合方式<sup>[20]</sup>。传 统邻接矩阵的构建往往侧重于距离等因素的考量, 而航班保障节点之间并不遵循此类空间距离的约 束,并且部分节点间存在一定的因果关联,因此本 文更关注保障节点间的时间相似性与因果关联 性。与人工设计的基于先验知识构造的邻接矩阵 不同,本文采用DTW算法生成邻接矩阵,这种方 法完全基于数据驱动,并且补偿了普通空间图无法 反映的时间序列间隐藏的时空依赖关系<sup>[19]</sup>。 DTW算法可以对时间序列之间的相关性进行度 量,从而反映出对应空间节点间的潜在的关联性, 使得改进后的图卷积网络更符合航班保障系统的 运作逻辑。假设有两个时间序列 O=  $\{o_1, o_2, \dots, o_n\}, U = \{u_1, u_2, \dots, u_n\}, 计算两个时序$ 数据之间的距离矩阵 $H_{m \times n}$ ,DTW算法的目标是在 矩阵 H 中找到一条最优的翘曲路径使得序列 O 与 U所有匹配点的损失和最小。那么可以找到这样 一条翘曲路径*L*,它的第*s*个元素为 $l_{s} = (i, j)_{s}$ ,  $l_s \in \mathbb{R}^2, L = (l_1, l_2, \dots, l_s, \dots, l_s), \ddagger \psi \max(m, n) \leq$  $S \leq n + m - 1$ 。该路径满足以下约束:

(1)边界约束: l<sub>1</sub>=(1,1), l<sub>s</sub>=(m, n),保证序列 O和U的第一个和最后一个元素对应,具体地说, 要保证在选择路径时,从左下角的位置开始,并且 终点在右上角的位置;

(2)连续性:如果 $l_{s-1} = (i', j')$ ,那么下一个点  $l_s = (i, j)$ 需要满足 $i - i' \leq 1, j - j' \leq 1$ ,也就是说, 不可越过自己相邻的点与其他点对齐;

(3)单调性:如果 $l_{s-1} = (i', j')$ ,那么路径的下 一个点 $l_s = (i, j)$ 需要满足 $i - i' \ge 0, j - j' \ge 1$ ,这 就限制了L上的点必须遵循时间单调性。

由动态规划求出最短路径,即路径上的元素和 最小,计算过程如算法1所示。最终得到矩阵A<sub>ij</sub> 作为后续图卷积模型的加权邻接矩阵。

$$A_{ij} = \operatorname{dist}(v_i, v_j) \tag{11}$$

算法1 DTW算法生成邻接矩阵

输入: 
$$O = \{o_1, o_2, \dots, o_n\}, U = \{u_1, u_2, \dots, u_m\}$$
  
(1) for  $i = 1, 2, \dots, n$  do

- (2) for  $j = 1, 2, \dots, m$  do
- $(3) H_{ii} = |o_i u_i|$

(4) if 
$$i = 0, j = 0$$
 then  $H_{c}(i, j) = H_{ij}^{2}$ 

(5) else if 
$$i = 0$$
 then  $H_c(i, j) = H_{ij}^2 + H_c(i, j-1)$ 

(6) else if 
$$j=0$$
 then  $H_c(i,j)=H_{ij}^2+H_c(i-1,j)$ 

(7) 
$$else H_{c}(i,j) = H_{ij}^{2} + \min(H_{c}(i-1))$$

1, j-1);

(9) end

J) enu

(10) return dist(O, U) =  $\sqrt{H_c(n, m)}$ 

 $(1, j), H_{c}(i, j-1), H_{c}(i-1)$ 

2.2.2 基于因果卷积的时间依赖挖掘

对于时间序列数据的建模通常会使用循环神 经网络,这主要得益于其独特的循环自回归结构, 这种结构能够有效地捕捉和表示时间序列数据中 的时间依赖性和动态变化,但循环神经网络存在梯 度消失以及梯度爆炸的问题。传统的CNN由于卷 积核大小的限制,不适用于时间序列数据的处理。 而因果卷积网络,也称时序卷积网络,能够较好地 保持历史数据之间的先后关系,即数据在时间轴上 的因果性。在数据序列特征提取过程中,在时间轴 方向上保持数据特征时序的一致性能有效提升模 型预测的准确性[21]。因果卷积作为一种特定类型 的卷积运算,仅依赖于过去时间步的信息,这种局 部依赖特性在时间维度上约束了卷积核的作用域, 有效降低了内存使用量。因此,因果卷积网络具有 更短的网络训练时间以及模型的性能验证时 间<sup>[19]</sup>。它的反向传播路径与输入的时序数据的时 间方向并不相同,从而能避免循环神经网络(Recurrent neural network, RNN)中经常出现的梯度爆 炸等问题<sup>[22-23]</sup>。

因此,本文通过因果卷积操作,使目标保障节 点在时间维度上接收并处理自身的历史状态信 息。鉴于传统的因果卷积在处理长序列时存在困 难,本文采用因果膨胀卷积操作来替换传统的因果 卷积操作,即在卷积核移动过程中加入步长间隔参 数 dilation 以获得更长远的时间依赖关系<sup>[22]</sup>。该操 作可以在不增加模型参数数量与时间建模长度的 前提下实现时间序列特征的精准捕获,如图7、8所 示。因果卷积和因果膨胀卷积的计算方法为

$$(*^{c}x_{i})(t) = \operatorname{sum}(W_{c} \odot (x_{i}', x_{i}^{t-1}, ..., x_{i}^{t-k+1})) (12)$$
  
$$(*^{cd}x_{i})(t) = \operatorname{sum}(W_{cd} \odot (x_{i}', x_{i}^{t-d}, ..., x_{i}^{t-(k-1)d}))$$





式中:\*<sup>c</sup>表示因果卷积操作;\*<sup>cd</sup>表示因果膨胀卷积 操作; ③为 Hadamard 积,即逐元素相乘;( $x'_i$ ,  $x'_i^{t-1}$ ,…, $x'_i^{t-k+1}$ )和( $x'_i$ , $x'_i^{t-d}$ ,…, $x'_i^{-(k-1)d}$ )表示需 要卷积的向量;k表示卷积核的大小; $W_c$ 和 $W_{cd}$ 分 别表示两种卷积操作中可优化的参数。

2.2.3 基于因果图卷积的时空依赖挖掘

本文地面保障时间节点预测模型的核心在于 集成上述图卷积和因果膨胀卷积操作,兼顾航班地 面保障网络时序图的时空相关性特征。具体集成 操作为

$$*^{g}v_{i}' = \sum_{j \in N_{i}} A_{ij} x_{j}' W_{g}$$
(14)

$$\begin{aligned} x_{is} = & \{ x_{ii}^{1}, x_{ii}^{2}, \cdots, x_{is}^{t-1}, x_{is}^{t} \} = \{ *^{g} v_{i}^{1}, *^{g} v_{i}^{2}, \cdots, *^{g} v_{i}^{t-1}, \\ & *^{g} v_{i}^{t} \} \end{aligned}$$
(15)

$$(*^{cd} [x_i] [x_{is}])(t) =$$

$$\sup \left( W_{cd} \odot \begin{pmatrix} x_i^t, x_i^{t-d}, \cdots, x_i^{t-(k-1)d} \\ x_{is}^t, x_{is}^{t-d}, \cdots, x_{is}^{t-(k-1)d} \end{pmatrix} \right) (16)$$

式中:\*<sup>8</sup>v<sub>i</sub>表示节点v<sub>i</sub>在时间窗口<sub>τ</sub>中的图卷积结 果,x<sub>i</sub>∈**R**<sup>i×1</sup>则表示节点v<sub>i</sub>在不同时间窗口附带的 空间信息,\*<sup>cd</sup>为因果膨胀卷积操作。本文将两种 操作的集成方式如下:首先将一组航班保障时间图 序列输入一层图卷积网络,输出一组融入了邻域空 间关系的时间图序列。然后将包含空间和时间关 系的两组时间图序列并联输入至N层因果卷积网 络中得到最终输出。此种并联集成的方式允许模 型同时利用时间和空间两个维度的信息,而不会因 为信息的串联(即图卷积操作的输出直接作为因果 卷积操作的输入)而丢失或扭曲原有的时间模式。 因此,将时间和空间序列并联拼接的方法可以在不 破坏原有时间模式的基础上引入额外的空间信息, 相比现有的时空图神经网络<sup>[15-17]</sup>,能有效提升模型 的预测效果。在后续实验分析中可以证明,相比时间图卷积网络(Temporal graph convolutional network, TGCN)<sup>[23]</sup>、谱图马尔科夫网络(Spectral graph Markov network, SGMN)<sup>[21]</sup>等串联集成的时空图神经网络,本文模型的预测精度至少能提升10%以上。

#### 2.3 航班保障时间节点预测模型优化

本文采用的 DTWGGCNM 模型在训练过程 中,目标是尽量减少航班保障时间节点预测值与真 实值之间的均方误差。考虑到数据缺失对预测结 果的影响,本文选择采用可观测数据优化模型的参 数。损失函数为

 $Z(W) = \min(x^{t+1} \odot m^{t+1} - \hat{x}^{t+1} \odot m^{t+1})^2 (17)$ 式中: $x^{t+1} \in \mathbb{R}^{n \times 1}$ 表示时间窗口 $\tau_{t+1}$ 内的观测值;  $\hat{x}^{t+1} \in \mathbb{R}^{n \times 1}$ 表示时间窗口 $\tau_{t+1}$ 内的预测值; $m^{t+1} \in \mathbb{R}^{n \times 1}$ 用于区分 $x^{t+1}$ 中的观测值与缺失值;W表示模型 中需要优化的参数。当节点 $v_i$ 在时间窗口 $\tau_{t+1}$ 中 的观测值缺失时, $m_i^{t+1}$ 为0,即损失函数不累计节 点 $v_i$ 在时间窗口 $\tau_{t+1}$ 内的预测误差。

## 3 实验与分析

为验证 DTWGGCNM 模型的有效性与适用 性,本文选用国内某大型机场的实际航班保障数据 进行验证分析。不同类型的航班在保障需求方面 存在差异性,其中过站航班的保障需求具有时间紧 迫性,其保障作业效率直接影响航班运行准点率。 因此,本文选用的航班数据中并未纳入过夜航班, 而是聚焦于过站航班的保障场景,选取了国内某大 型机场2023年1月至3月的过站航班地面保障实 际数据,涵盖24个关键保障节点,共6480个时间 窗口进行试验。数据样例如表1所示。由于机场 的航班运行时间存在日周期性,航班保障时间节点 数据分布也存在明显的日周期性。因此,本文将包 含6480个时间窗口的时间序列数据以天为单位进 行切分,划分为多个包含完整周期的大时间窗,结 合因果膨胀卷积操作,以更好地捕获数据中的周期 性规律[24-25]。本文方法可以处理具有明确时间顺 序或潜在周期性规律的时间序列数据,因此可服务 多领域的时空预测任务,例如交通流量、气象数据、 经济指标等。

表 1 航班保障数据样例 Table 1 Data sample of flight support

							8				
航班号	日期	上轮挡	廊桥/客 梯车对接	开客 舱门	开货 舱门	下客 开始	下客 结束	行李装 卸开始	行李装 卸结束	 关客 舱门	撤轮挡
XX	$1 \sim 31$	7:10	7:12	7:14	7:19	7:18	7 <b>:</b> 33	7:25	7 <b>:</b> 52	 7 <b>:</b> 58	8:01

#### 3.1 数据预处理

首先,本文对采集到的航班地面保障数据进行 了预处理,主要分为以下3个方面。

(1)缺失数据补齐。根据统计,本文采集到的 初始航班保障数据整体缺失率约为14.9%。其中 加清排污、下客环节的缺失率偏高,分别达到了 75%与62%,且多为连续块状缺失;挡/撤轮挡环 节的缺失率约为27%,开/关舱门环节的缺失率约 为7%;此外,上客、加油、清洁、配餐等环节的缺失 率偏低,均在5%以下,以随机缺失为主。为了验 证不同数据缺失场景下本文模型的适用性,首先需 要补全自然缺失值,从而保证后续试验环境的一致 性。本文采用性能较优的时空卷积神经网络模型 (Spatial-temporal convolutional neural network, ST-CNN)模型<sup>[15]</sup>对缺失数据进行补全。 (2)缺失场景构建。为了检验模型在不同缺 失场景下的性能,并进行对比分析,本文选择人工 构建不同类型的缺失场景,以保障试验环境的一致 性。参考文献[14]对数据集进行缺失处理,即人为 设置缺失数据。图9展示了处理过后的数据分布 情况,分别为20%、40%、60%和80%的随机缺失 与连续块状缺失。灰色代表缺失数据所在位置,在 随机缺失场景下,缺失数据均匀散布在数据集中, 而在连续块状缺失场景下,缺失数据以条块状分布 在数据集中。

(3)数据样本划分。本文依据二八准则,将处 理过的数据划分为训练数据集及测试数据集。其 中,训练数据集(占总数据的80%)作为训练过程 的输入,其余数据作为测试过程的输入。



## Fig.9 Constructing scenarios with missing data

#### 3.2 实验设置

3.2.1 基线模型对比

为了验证本文所提出的航班地面保障时间节 点预测模型DTWCGCNM的优越性,选取目前交 通领域内比较流行的机器学习与深度学习模型作 为基线模型,基于相同数据集下的预测结果与本文 模型进行对比分析。所选基线模型如下:

(1)考虑缺失值的因果图卷积网络(Causal graph convolutional network with missing data, CGCNM)<sup>[14]</sup>:结合因果卷积神经网络和图卷积神 经网络进行时空预测。

(2) 动态时空图卷积网络(Dynamic spatial-temporal graph convolution network, DST-GCN)<sup>[19]</sup>:一种基于动态自适应图卷积的时空依赖预测模型。

(3) 贝叶斯时间因子矩阵分解(Bayesian temporal matrix factorization, BTMF)<sup>[26]</sup>:对矩阵分解 的因子矩阵建立了向量自回归模型,并采用贝叶斯 推断对所构建的时序矩阵分解模型进行求解。

(4) SGMN<sup>[21]</sup>:基于图的马尔可夫过程的一种 新的时空数据预测的神经网络结构。

(5) TGCN<sup>[23]</sup>:适用于处理时间序列图数据 的神经网络算法,结合了图卷积网络和时间序列分 析的思想以解决时空数据预测问题。

(6) LSTM<sup>[20]</sup>:属于循环神经网络(Recurrent neural network, RNN)的一种,致力于解决长序列 训练时面临的梯度消失和梯度爆炸问题。

(7) 门控循环网络(Gated recurrent unit, GRU)<sup>[27]</sup>:通过门控机制控制输入,能够保存长期序列中的信息。在GRU模型中,所采用的训练数据集与在LSTM模型中相同。

### 3.2.2 评价指标选取

本文选取了平均绝对误差(Mean absolute error, MAE)和均方根误差(Root mean square error,RMSE)两个指标来评估模型的预测性能。 这两个指标能够量化预测结果的误差大小,指标数 值越低表示预测方法越优。

MAE = 
$$\frac{1}{n} \sum_{i}^{n} |x_{i}^{t} - \hat{x}_{i}^{t}|$$
 (18)

RMSE = 
$$\sqrt{\frac{1}{n} \sum_{i=1}^{n} (x_i^{t} - \hat{x}_i^{t})^2}$$
 (19)

式中:*x*<sub>i</sub>为真值,*x*<sub>i</sub>为预测值,*n*为样本总数。 3.2.3 参数选择

上述实验在 Python3.6 的软件环境下运行,通 过 Python 中的深度学习框架 Pytorch1.10.2 构建 模型。在模型训练过程中,本文主要使用控制变量 法获得超参数的最优组合<sup>[14]</sup>,主要包括以下参数: 时间依赖步长取36、卷积核大小取2、因果卷积网 络层数取4,且每层的卷积核数量分别取32、64、 32、1,膨胀因子分别为2、4、6、8。

## 3.3 实验结果分析

3.3.1 模型预测精度对比

图 10首先展示了在无缺失数据集上本文模型 DTWCGCNM与其他基线模型的预测精度结果比 较。从整体角度而言,8种方法都呈现了较优的预 测水平,预测精度差异不大。其中LSTM、GRU这 类时间序列预测模型的精度要高于DSTGCN、



Fig.10 Performance comparison of baseline models without missing data

TGCN 这种时空预测模型,原因可能是因为在没 有缺失的情况下,TGCN 这类串联式集成时空依 赖关系的模型会割裂了原有的时间模式。而本文 模型通过并联式集成卷积操作,使得原有的时间模 式不被破坏。总体而言,在无缺失数据集上,本文 基于动态时间规整的因果图卷积网络优势呈现出 了最佳预测性能,虽然领先优势不大,但随着数据 缺失率的增加,本文模型的优势会更加明显,展现 出更强的鲁棒性和适应性。因此,本文进一步比较 了不同缺失场景下各模型的预测效果。如表2所 示,各模型的预测精度展现出明显差异。

表2 基线模型精度对比(MAE/RMSE)

Table 2	Performance comparison of baseline models (MAE/RMSE)	

	DEBUGGGONDA	a 1.00004	DOTIONI	DOM	00101	mooni	LOTA	ODU
缺失惧式	DIWCGCNM	Causal-GCNM	DSIGCN	BIMF	SGMN	IGCN	LSIM	GRU
20%随机缺失	0.72/1.50	0.83/1.57	2.66/3.61	1.32/1.72	0.79/1.63	2.78/3.20	3.55/4.12	3.61/4.20
20% 块状缺失	0.74/1.52	0.84/1.58	2.87/4.63	1.35/1.85	1.30/2.46	2.79/4.04	2.82/5.12	2.83/5.14
40%随机缺失	0.73/1.51	0.85/1.59	5.36/5.96	1.32/1.78	0.86/1.74	5.13/5.54	4.59/5.05	4.61/5.07
40%块状缺失	0.92/2.00	1.02/2.11	4.80/6.54	1.59/2.21	2.22/3.59	4.72/5.96	4.52/6.97	4.54/7.01
60%随机缺失	0.78/1.59	0.88/1.60	7.49/8.17	1.95/2.77	0.99/1.99	7.68/8.19	8.75/9.29	8.94/9.47
60% 块状缺失	1.07/2.41	1.19/2.48	6.02/7.70	1.95/2.84	2.22/3.35	6.32/7.51	6.32/8.59	6.44/8.64
80%随机缺失	0.83/1.66	0.96/1.74	9.23/9.90	3.42/4.45	1.70/2.58	9.91/10.44	9.69/10.30	9.79/10.40
80%块状缺失	1.32/2.80	1.44/3.11	6.93/8.41	2.56/3.39	2.97/4.28	7.31/8.34	7.22/9.29	7.33/9.35

### (1) 时空双维度特征捕捉的重要性

在数据缺失情况下,本文模型和 Causal-GCNM、SGMN、DSTGCN等时空预测模 型的预测精度明显优于LSTM、GRU等传统时间 预测模型,且随着缺失率的增加,模型性能差异也 越大。这说明在数据出现缺失时,传统时间序列预 测方法仅专注于时间维度的特征捕捉,已难以满足 对高精度预测的需求。相比之下,能够同时学习和 捕捉时空两个维度特征的模型,则显示出了更为强 大的适应性和准确性。此外,对比本文模型与 Causal-GCNM,DSTGCN与TGCN的预测结果可 知,融入了DTW算法后,模型进一步挖掘出了空 间图中的隐藏时空依赖关系,呈现出更优的预测 效果。

### (2) 缺失数据处理模块的作用

相较于DSTGCN、TGCN等不考虑缺失值的 机器学习模型,DTWCGCNM、SGMN和BTMF 等融入了缺失处理机制的模型在预测效果上表现 出明显优势。由此可见,对于保障预测模型而 言,精准的缺失值处理模块至关重要。本文模型通 过对缺失模式的分类学习与缺失数据的自主式处 理,增强了对各类数据缺失场景的适应性,提升了 模型的预测精度与稳定性,使平均绝对误差下降了 8.3%以上,均方根误差下降了4.6%以上。

综上所述,与基线模型相比,本文提出的DT-WCGCNM模型在预测性能方面展现出以下优势: ①预测精度高,无论是在何种缺失场景下,都具有 最高的预测精度;②预测性能稳定,即使在高缺失 率情况下依然保持较高的预测水平,与其他模型拉 开差距。

3.3.2 预测结果分析

以撤轮挡环节为例,图11直观展示了在20%、 40%随机缺失与连续块状缺失场景下预测值和观测 真值之间的差异,造成这些误差的原因可能源于多 个方面。在随机缺失模式下,部分丢失的数据中可 能包含对预测模型至关重要的特征。尽管缺失是随 机的,但每次缺失都会对模型的训练和学习产生少 量影响,从而造成偏差累积;在连续块状缺失模式 下,一方面是部分特征在缺失的数据块中被忽略或 扭曲,导致时间趋势和周期性的捕获存在偏差,另一 方面是连续块状缺失往往由系统故障、记录中断或 特定事件引起,这些事件可能对数据产生长期影响, 导致误差产生。因此,相比随机缺失,连续块状缺失 模式下的预测误差会更高。然而从整体结果来看, 两种不同的数据缺失模式下,真实值与模型预测值 之间的接近程度均较高,这表明本文所提出的模型 能够较为精确地捕捉并预测保障时空数据的变化趋 势,进一步验证了模型的有效性和可靠性。



Fig.11 Comparison between predicted values and true values in scenarios with 20% and 40% random missing and block missing

#### 3.3.3 模型计算效率分析

考虑到本文提出的DTWCGCNM属于深度 学习模型中的一种,故将其与Causal-GCNM、 TGCN、LSTM、GRU进行计算效率对比。模型设 计、硬件性能、数据处理等多方面影响。本小节从 训练速度和预测速度两个方面分析算法计算效率, 如表3所示。DTWCGCNM这类非迭代模型的计 算效率要明显优于LSTM、GRU这类迭代型模型。 虽然DTWCGCNM的训练与预测速度略低于 Causal-GCNM,但基本保持在同一水平,并且在预 测精度上有了明显提升。综上所述,虽然DTWC-GCNM在计算效率上的提升幅度相对有限,但在 面对不同缺失场景的预测任务尤其是高缺失率场 景时,其展现出了更优的预测效果与稳健性能。因 此,相较其他深度学习模型,DTWCGCNM在综合 性能方面更胜一筹。

	表3 模型计算效率对比	
Table 3	Model computation efficiency comparison	

	Tuble	e mouel computatio	n ennenency compu	libon	
参数	DTWCGCNM	Causal-GCNM	TGCN	LSTM	GRU
训练时间	2 972	2 933	4 156	4 507	4 281
预测时间	109	98	125	190	176

## 4 结 论

本文得到的主要结论如下:

(1) 在因果图卷积操作的基础上,引入了 DTW 算法以解决时间序列数据中的不对齐与伸 缩变异问题,能够在数据缺失情境下,有效捕捉时 间序列之间的相似性与动态匹配模式,从而提升模型对保障时空特性的解析能力,增强模型对不同数据缺失模式下时间预测任务的适应性。

(2)构建了8种不同的保障数据缺失场景 (20%、40%、60%、80%的随机和连续块状缺失 率)。预测结果表明,本文模型在数据缺失下的航 班地面保障时间预测方面具有显著优势。尤其是 在高缺失率场景下,与传统预测模型相比,本文模 型预测精度更高,预测性能更稳定,为机场保障运 行部门准确了解航班保障需求提供了具有应用价 值的预测模型,具有重要的现实意义。

本文研究主要集中于两种缺失模式,下一步将 针对混合型或更为复杂的数据缺失模式进行分 析。对于保障节点间的隐形关系,也会考虑更多影 响因素如不同时段、机型等进行更深一步的挖掘, 从而实现更精准的航班保障时间节点预测。

#### 参考文献:

- [1] EVLER J, LINDNER M, FRICKE H, et al.Integration of turna-round and aircraft recovery to mitigate delay propagation in airline-networks[J]. Computer & Operations Research, 2022, 138:105602.
- [2] 丁建立,赵键涛,曹卫东.基于贝叶斯网的航班过站时间动态估计[J].南京航空航天大学学报,2015,47 (4):517-524.

DING Jianli, ZHAO Jiantao, CAO Weidong. Dynamic estimation of flight transit time based on Bayesian networks[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2015, 47(4): 517-524.

- [3] 冯霞,张鑫,陈锋.飞机过站上客过程持续时间分布
   [J].交通运输工程学报,2017,17(2):98-105.
   FENG Xia, ZHANG Xin, CHEN Feng. Boarding duration distribution of aircraft turnaround[J]. Journal of Transportation Engineering, 2017, 17(2):98-105.
- [4] 李彪,邢志伟,王立文.飞机地面除冰保障过程动态 预测[J].北京航空航天大学学报,2024,50(1): 224-233.

LI Biao, XING Zhiwei, WANG Liwen. Dynamic prediction for aircraft ground deicing operation process [J]. Journal of Beijing University of Aeronautics and Astronautics, 2024, 50(1): 224-233.

- [5] GUO Z, YU B, HAO M, et al. A novel hybrid method for flight departure delay prediction using random forest regression and maximal information coefficient [J]. Aerospace Science and Technology, 2021, 116: 106822.
- [6] 王立文,李彪,邢志伟,等.过站航班地面保障过程动态预测[J].北京航空航天大学学报,2021,47(6): 1095-1104.

WANG Liwen, LI Biao, XING Zhiwei, et al. Dy-

namic prediction of ground support process for transit flight[J]. Journal of Beijing University of Aeronautics and Astronautics, 2021, 47(6): 1095-1104.

- [7] LIAN G, ZHANG Y P, DESAI J, et al. Predicting taxi-out time at congested airports with optimization based support vector regression methods[J]. Mathematical Problems in Engineering, 2018, 2018; 1-11.
- [8] YIN J N, HU Y X, MA Y Y, et al. Machine learning techniques for taxi-out time prediction with a macroscopic network topology[C]//Proceedings of AIAA/ IEEE the 37th Digital Avionics Systems Conference. London, UK: IEEE, 2018: 1-8.
- [9] YUAN G, ZHI H Y, FEI J. A prediction method based on neural network for flight turnaround time at airport[C]//Proceedings of the 8th International Symposium on Computational Intelligence and Design (IS-CID). Hangzhou, China: IEEE, 2015: 219-222.
- [10] 邢志伟,韩大浩,罗谦.基于改进GA的神经网络航班保障时间估计[J].计算机工程与设计,2020,41
  (1):107-114.
  XING Zhiwei, HAN Dahao, LUO Qian. Estimation of flight support time based on improved GA neural network[J]. Computer Engineering and Design, 2020,41(1):107-114.
- [11] 邢志伟,李彪,朱慧,等.基于深度神经网络的航班 保障时间预测研究[J].系统仿真学报,2020,32
  (4):678-686.
  XING Zhiwei, LI Biao, ZHU Hui, et al. Research on

flight ground service time prediction based on deep neural network[J]. Journal of System Simulation, 2020, 32(4): 678-686.

[12] 邢志伟,唐云霄.枢纽机场航班保障服务时间估计 [J].系统仿真学报,2017,29(11):2856-2864, 2874.

XING Zhiwei, TANG Yunxiao. Flight support service time estimation of hub airport[J]. Journal of System Simulation, 2017, 29(11): 2856-2864, 2874.

- [13] LIU C, CHEN Y R, WANG H, et al. Airport flight ground service time prediction with missing data using graph convolutional neural network imputation and bidirectional sliding mechanism[J]. Applied Soft Computing, 2023, 133: 109941.
- [14] 王培晓,张彤,聂士超,等.顾及缺失值的因果图时 空预测网络[J].测绘学报,2023,52(5):818-830.
  WANG Peixiao, ZHANG Tong, NIE Shichao, et al. A causal graph convolutional netword considering missing values for spatio-temporal prediction[J]. Acta Geodaetica et Cartographica Sinica, 2023, 52(5): 818-830.
- [15] 张壮壮, 屈立成, 李翔, 等. 基于时空卷积神经网络的数据缺失交通流预测[J]. 计算机工程与应用,

2022, 58(7): 259-265.

ZHANG Zhuangzhuang, QU Licheng, LI Xiang, et al. Traffic flow prediction with missing data based on spatial-temporal convolutional neural networks[J]. Computer Engineering and Applications, 2022, 58 (7): 259-265.

- [16] 张海静.深度学习框架下的短时交通流预测及数据 补全技术研究[D].西安:长安大学,2020. ZHANG Haijing. Research on short-term traffic flow prediction and data completion technology under deep learning framework[D]. Xi'an:Chang'an University, 2020.
- [17] 徐东伟,朱宏俊,周磊,等.数据缺失下的交通流预 测方法研究[J/OL].武汉理工大学学报(交通科学与 工程版),2024:1-10[2024-03-28].http://kns.cnki. net/kcms/detail/42.1824.u.20230215.0951.004.html. XU Dongwei, ZHU Hongjun, ZHOU Lei, et al. Research on traffic flow prediction methods under missing data[J/OL]. Journal of Wuhan University of Technology (Transportation Science and Engineering Edition), 2024: 1-10 [2024-03-28]. http://kns.cnki.net/ kcms/detail/42.1824.u.20230215.0951.004.html.
- [18] 易茜,柳淳,李聪波,等.数据缺失下基于改进生成 对抗填补网络的碳耗预测方法[J].机械工程学报, 2023,59(11):264-275.
  YI Xi, LIU Chun, LI Congbo, et al. Prediction method of hobbing carbon consumption based on improved generative adversarial imputation net with missing data
  [J]. Journal of Mechanical Engineering, 2023, 59
- [19] 唐闻君.基于时空数据的交通流量预测算法研究
  [D].北京:北京交通大学,2022.
  TANG Wenjun. Research on traffic flow forecasting based on spatial-temporal data [D]. Beijing: Beijing Jiaotong University, 2022.

(11): 264-275.

[20] 屈景怡,叶萌,渠星.基于区域残差和LSTM网络的 机场延误预测模型[J].通信学报,2019,40(4): 149-159.

QU Jingyi, YE Meng, QU Xing. An airport delay pre-

diction model based on regional residual and LSTM network [J]. Journal of Communications, 2019, 40 (4): 149-159.

- [21] CUI Z Y, LIN L F, PU Z Y, et al. Graph Markov network for traffic forecasting with missing data[J]. Transportation Research Part C: Emerging Technologies, 2020, 117: 102671.
- [22] OORD A, DIELEMAN S, ZEN H, et al. Wavenet: A generative model for raw audio[J]. ArXiv Preprint ArXiv, 2016, 1609: 03499.
- [23] ZHAO Ling, SONG Yujiao, ZHANG Chao, et al. T-GCN: A temporal graph convolutional network for traffic prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(9): 3848-3858.
- [24] 董婉青,赵子榕,廖惠敏,等.动态路网下城市交通 事故风险预测模型研究与实现[J].计算机科学, 2024,51(S1):1203-1212.
  DONG Wanqing, ZHAO Zirong, LIAO Huiming, et al. Research and implementation of urban traffic accident risk prediction in dynamic road network[J]. Computer Science, 2024, 51(S1): 1203-1212.
- [25] 丁美荣, 张航, 蔡高琰, 等. 基于 MCQRDDC 的负荷 概率预测模型[J]. 计算机系统应用, 2023, 32(2): 281-287.

DING Meirong, ZHANG Hang, CAI Gaoyan, et al. Probabilistic load forecasting model based on MC-QRDDC[J]. Computer Systems and Applications, 2023, 32(2): 281-287.

- [26] CHEN Xinyu, SUN Lijun. Bayesian temporal factorization for multidimensional time series prediction[J].
   IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(9): 4659-4673.
- [27] 刘明宇,吴建平,王钰博,等.基于深度学习的交通流 量预测[J].系统仿真学报,2018,30(11):4100-4105.
  LIU Mingyu, WU Jianping, WANG Yubo, et al. Traffic flow prediction based on deep learning[J].
  Journal of System Simulation, 2018, 30(11): 4100-4105.

(编辑:张蓓)