

基于多元特征的建筑工程货运车辆行程时间预测

杜江¹, 宁朝阳¹, 赵长龙¹, 江泽浩², 王宇阳^{2*}

¹中海建筑有限公司 贵州贵阳

²华中科技大学土木与水利工程学院 湖北武汉

【摘要】目的 建筑工程货运车辆行程时间预测对于项目管理至关重要。其在城市中行驶受到不同因素的影响, 通过捕捉影响因素特征提高预测精度已成为当前亟需解决的问题。**方法** 首先, 使用图卷积网络 (Graph convolution network, GCN) 捕捉城市网格中行驶轨迹的空间特征; 然后, 借助转换器网络 (Transformer) 捕捉城市网格中行驶轨迹的时间特征; 其次, 将外部因素作为文本信息, 通过嵌入模型提取属性特征; 最后, 构建基于多元特征的工程货运车辆行程时间预测模型。将武汉市内某一建设项目的 2320 条行驶轨迹作为实验数据, 划分行驶区域为 500×500、1000×1000 和 1500×1500m 的网格序列, 借助本文模型预测工程运输车辆行程时间, 并与基线模型进行对比。**结果** 研究表明: 三种空间粒度下, 本文模型预测结果的均方根误差分别为 89.08、111.32 和 141.6; 与基线模型相比, 该模型的均方根误差分别平均降低了 25.83%、26.43% 和 27%。**结论** 研究成果为工程运输行业行程时间预测提供了新的思路, 可为项目管理提供技术支撑。

【关键词】 交通运输系统工程; 行程时间预测; 工程货运车辆; 图卷积网络; 转换器模型

【基金项目】 湖北省自然科学基金(2024AFD410); 中海建筑有限公司科技项目 (ZHJ-GZ-KJ-009); 华中科技大学与新南威尔士大学联合科研种子基金项目

【收稿日期】 2024 年 12 月 12 日 **【出刊日期】** 2025 年 1 月 18 日 **【DOI】** 10.12208/j.jer.20250004

Travel time prediction of construction freight vehicles based on multiple features

Jiang Du¹, Chaoyang Ning¹, Changlong Zhao¹, Zehao Jiang², Yuyang Wang^{2*}

¹China Overseas Construction Limited, Guiyang, Guizhou

²School of Civil and Hydraulic Engineering, Huazhong University of Science and Technology, Wuhan, Hubei

【Abstract】Objective The travel time prediction of construction freight vehicles is very important for project management. Its driving in the city is affected by different factors. It has become an urgent problem to improve the prediction accuracy by capturing the characteristics of influencing factors. **Methods** Firstly, the spatial features of travel tracks in the urban grid were captured using the Graph convolution network (GCN). Then, the Transformer network was used to capture the time characteristics of the driving trajectory in the urban grid; Secondly, the external factors were taken as text information, and the attribute features are extracted by embedding the model. Finally, the travel time prediction model of construction freight vehicles based on multiple features was constructed. 2320 driving tracks of a construction project in Wuhan were taken as experimental data and divided into grid sequences with driving areas of 500×500, 1000×1000 and 1500×1500m. The travel time of engineering transport vehicles was predicted by this model and compared with the baseline model. [Findings]The results show that the root-mean-square errors (RMSE) of the model prediction results are 89.08, 111.32 and 141.6, respectively. Compared with the baseline model, the RMSE of this model were reduced by an average of 25.83%, 28.43%, and 27%, respectively. **Conclusions** The research results provide a new idea for the travel time prediction of engineering transportation industry, and can provide technical support for project management.

第一作者简介: 杜江, 男, 贵州省遵义市人, 本科, 工程师;
*通讯作者: 王宇阳

【Keywords】 Transportation system engineering; Travel time prediction; Construction freight vehicle; Graph convolution network; Transformer model

引言

工程货运车辆运送货物具有易蒸发、凝固、损坏的特点,其时效性决定了项目的有序推进工作。行程时间预测对于工程项目管理的高效运行至关重要,有助于项目管理人员推进及时材料管理、库存调度和跨地点快速运送等工作^[1-4]。

传统的数据收集方法提供了一般的见解,但缺乏对现代交通动力学所需的深度分析^[5,6]。GPS、WiFi和蓝牙设备等位置感知传感器的使用日益增多,产生了大量城市轨迹数据,这些数据捕捉了在城市中旅行的个人和车辆的时空移动轨迹。这些轨迹数据的准确利用对于理解和预测复杂场景下的工程运输车辆交通行为至关重要。

许多关于交通的研究都集中在对交通变量的短期预测上,包括交通流模式、流速、行驶时间和匹配距离^[7-9]。行程时间预测的能力可以大大增强和扩展模型在现实世界交通管理和基于位置的信息服务

(Location-based information service, LBS) 解决方案中的适用性。Scellato 等分析用户的到达和停留时间的非线性数据序列,预测未来位置^[10]。胥帅等引入记忆网络从相似用户在城外的移动轨迹中进一步提炼出行意图,将用户城内签到与城外出行意图进行交互建模,从而强化用户城外移动偏好表示^[11]。Do 和 Gatica-Perez 通过集成方法提取和组合不同的移动模式形成概率框架,预测下一个地点和停留时间^[12]。Du 等将 RNN 和时间点过程结合起来作为循环标记时间点过程 (Recycle marking time point process, RMTTP),以同时模拟用户的访问时间和位置^[13]。Krishna 等人通过过去的活动和持续时间序列作为历史数据,设计了两个不同的长短时记忆 (Long-short term memory, LSTM) 网络,估计未来活动及其持续时间的概率^[14]。Chen 等人结合了基于分层 RNN 的顺序依赖编码器、空间上下文提取器、周期性上下文提取器以及基于共同注意的社交和时间上下文提取器,用于联合移动和时间预测^[15]。

然而,针对工程货运车辆的行程时间预测研究较少。其原因可能在于,工程货运车辆具有只服务于工程项目而不服用于公众的特点,未能引起学者足够重视。另外,服务领域特殊性导致其交通行为

与一般性交通存在差异,行驶轨迹数据的收集具有一定的难度。最后,多种因素影响其行程时间预测精度,深入研究这些因素的作用规律以提高预测精度是必要的。

因此,结合行驶轨迹数据,本文提出一种基于多元特征的工程货运车辆行程时间预测模型。首先,采用图卷积 (Graph convolution network, GCN) 和转换器 (Transformer) 捕捉行驶轨迹数据的时空相关特征。然后,考虑到工程货运车辆行驶极易受到天气条件、出行时间、时效约束等因素的影响,使用嵌入模型处理这些文本信息,生成文本嵌入向量,作为属性特征被提取。最后,构建融合上述特征的行程时间预测模型,并通过真实数据对比验证本文模型的有效性。

1 模型构建

1.1 问题定义

出行时间预测是一个基本的时空预测问题。本研究的目的是利用 GPS 数据预测货车行程时间。每个货车的行程通常分布于城市的不同区域,形成一批空间序列。将城市区域网络定义为一个图 $G(V,E,A)$,如图 1 所示。首先,假设以规则网格 $200\text{m}\times 200\text{m}$ 标准划分城市区域,网格数量为 6×6 ,则示例图代表城市范围为 $1200\times 1200\text{m}$ 。灰色表示车辆途径该网格区域,白色则表示未经过。连续红色箭头表示抽象化的车辆行驶路径,起终点为 M 点和 N 点。其中 V 是节点集合,表示车辆途径的区域网络。 E 是边集合,表示车辆途径的区域网格是否相连,此处以行驶路径为准,而不是网格客观上是否相邻。 A 表示相连网格区域的连接强度。

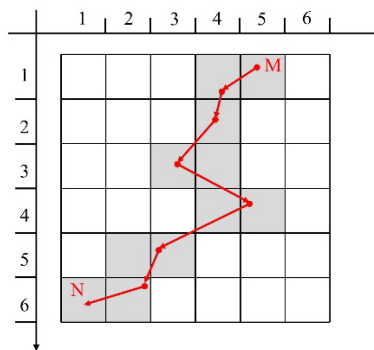


图1 城市区域网格划分

$A \in \mathbf{R}^{n \times n}$ 是邻接矩阵, 表示两个交通网络区域之间是否连接。行程时间作为属性特征, 分别选取前一周、前一天、和当天的历史信息构建特征矩阵 $X_{nt} = X_{nt}^U X_{nt}^K X_{nt}^R$:

$$A = \begin{bmatrix} W_{11} & W_{12} & \cdots & W_{1j} \\ W_{21} & W_{22} & \cdots & W_{2j} \\ \vdots & \vdots & & \vdots \\ W_{i1} & W_{i2} & \cdots & W_{ij} \end{bmatrix} \quad (1)$$

$$X_{nt} = \begin{bmatrix} x_{1t-m} & x_{1t-m+1} & \cdots & x_{1t} \\ x_{2t-m} & x_{2t-m+1} & \cdots & x_{2t} \\ \vdots & \vdots & & \vdots \\ x_{nt-m} & x_{nt-m+1} & \cdots & x_{nt} \end{bmatrix} \quad (2)$$

式中: X_{nt} 是货车历史行程时间; n 是节点数, 表示区域网络数量; t 表示当前时刻; 上标 U、K 和 R 分别表示前一周、前一天和当天; X_{nt}^U 、 X_{nt}^K 和 X_{nt}^R 分别表示区域网格 n 在前一周、前一天和当天的 t 时刻的历史行程时间输入; m 是时间窗口步长, 表示或称行程时间的历史时间序列数量。

1.2 模型结构

1.2.1 空间特征

一些传统的交通预测模型往往将交通网络视为一个网格矩阵, 忽略了网络拓扑结构对预测精度的影响。在本节中, 我们应用 GCN 来捕捉道路交通网络中站点之间的拓扑关系。图卷积网络源自于卷积神经网络, 具有处理复杂图结构信息的优点, 因此受到研究学者广泛关注。目前, GCN 凭借其优异的空间信息提取能力, 已成功应用于交通预测、图分类、目标检测等领域, 并且已取得突出的研究效果^[16-18]。本研究中, GCN 主要用于对道路交通网络的拓扑结构进行编码, 从而捕捉行程轨迹的空间依赖性。

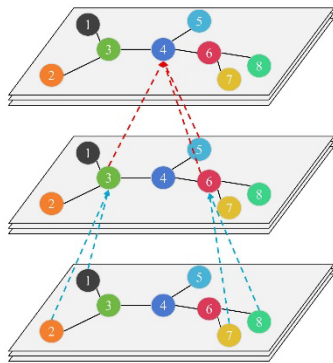


图2 图卷积工作原理

给定一个邻接权重矩阵 $A \in \mathbf{R}^{n \times n}$ 后, 图卷积网络借助多层卷积处理特征信息, 提取工程车辆行驶轨迹的空间相关性。即:

$$X^{(l+1)} = R(D^{-\frac{1}{2}} B D^{-\frac{1}{2}} X^{(l)} W^{(l)} + b) \quad (3)$$

$$B = A + I \quad (4)$$

式中: $X^{(l+1)}$ 表示图卷积网络第 $l+1$ 层的特征矩阵; R 为激活函数; $D \in \mathbf{R}^{n \times n}$ 为 A 的节点度矩阵; B 为自连接矩阵; $X^{(l)} \in \mathbf{R}^{n \times n}$ 为 n 个节点第 l 层的特征矩阵; $W^{(l)} \in \mathbf{R}^{m \times k}$ 为第 l 层训练得到的权重矩阵; $b \in \mathbf{R}^{m \times k}$ 为偏置向量; $I \in \mathbf{R}^{n \times n}$ 为单位矩阵。

对于不规则网络拓扑结构, 图卷积具有有效地分类聚合图中节点的能力。如图 2 所示, 对于节点 3 和节点 6, GCN 分别捕捉邻居节点 1、节点 2 的特征信息融合到节点 3, 邻居节点 7、节点 8 的特征信息融合到节点 6。进入下一卷积层, GCN 捕捉节点 4 的邻居节点 3、节点 5 和节点 6 的特征信息进行融合。

对于不规则结构图中节点 4 的相关节点, GCN 能够经过卷积层堆叠收集到所有与其相关节点 (包括不相邻节点) 的特征信息。因此, 本文通过 GCN 捕捉工程运输车辆行驶轨迹的空间相关性。借助上述优点, 采用站点网络图作为初始邻接权重矩阵输入到 GCN 中, 经过训练迭代更新权重矩阵, 并输出最佳的权重矩阵, 以获取最优的空间相关特征。

1.2.2 时间特征

Transformer 架构使用注意力机制来捕捉输入和输出之间的全局相关性, 这消除了对卷积和递归神经网络的需要^[19]。这允许更多的并行计算, 并增强了模型的预测能力^[20]。图 3 示出了 Transformer 模型如何处理每个像素的当前和先前接触值以生成预测值。




图3 转换器模型工作原理

Transformer 模型通过时间序列输入来获得隐藏层 h_i 。这通过首先应用线性投影并将其与位置嵌入相结合来实现:

$$\{C_i^t\}_{i=1}^S = [c_i^1, c_i^2, \dots, c_i^S] \quad (5)$$

$$h_i = \text{LayerNorm}(\text{MLP}(c_i^t) + \text{Position}(t)) \quad (6)$$

式中: $\{C_i^t\}_{i=1}^S \in \mathbb{R}^S$, c_i^t 表示 t 时第 i 个时间序列的值; LayerNorm 和 MLP 分别表示层标准化和多层感知; Position 表示时间 t 时的位置嵌入。

Transformer 模型包含位置编码, 使用具有不同频率的正弦和余弦函数来表示过去和未来时刻的时间。与卷积和递归神经网络不同, Transformer 模型缺乏编码位置信息的固有方式。因此, 为了有效地使用序列数据来预测未来值, 位置编码是必要的。这种编码是通过使用不同频率的正弦和余弦函数实现:

$$\text{Position}(t) = [p_i(1), \dots, p_i(l)] \quad (7)$$

$$\begin{cases} p_i(i) = \sin(pos \cdot 10000^{-\frac{i}{l}}), \text{if } i \text{ is even number} \\ p_i(i) = \cos(pos \cdot 10000^{-\frac{i}{l}}), \text{if } i \text{ is odd number} \end{cases} \quad (8)$$

式中: pos 为位置, l 表示位置编码的维数, 与嵌入维数相同。

Transformer 模型编码器和解码器通常由几个相同的层组成, 每一层都包含自关注机制, 该自关注机制学习查询矩阵 $Q=f_q(\{h_i\}_{i=1}^S)$ 、键矩阵 $K=f_k(\{h_i\}_{i=1}^S)$ 和相应的值矩阵 $V=f_v(\{h_i\}_{i=1}^S)$ 。对于查询和键矩阵, 这些矩阵的维数为 d_k ; 值矩阵维数为 d_v 。为了预测下一个概率, 使用 Softmax 函数进行线性变换来转换解码器输出。最后, 可计算注意力:

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (9)$$

多头注意力机制允许模型在不同的位置同时关注多个子空间的表征, 如式所示:

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_i)W \quad (10)$$

$$\text{Head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \quad (11)$$

被称为 Concat 的全连接层被用于合并 m 个注意力, 具有参数矩阵 $W_i^Q \in \mathbb{R}^{l \times dq}$ 、 $W_i^K \in \mathbb{R}^{l \times dk}$ 、 $W_i^V \in \mathbb{R}^{l \times dv}$ 及 $W \in \mathbb{R}^{mdv \times l}$ 。这些投影用于合并过程, 以增强模型的表达能力。

1.2.3 属性特征

货车的行程时间受到诸多外部因素的影响, 例如天气信息、出发时间、时效约束等。如图 4 所示, 本文设计了属性模块来提取这些外部因素的特征。将天气信息、出发时间和时效约束作为文本信息, 使用嵌入模型处理这些文本信息。嵌入模型的输出是文本信息的属性特征向量。

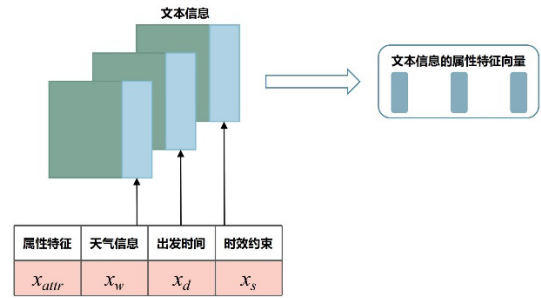


图 4 嵌入模型提取属性特征

将得到的向量进行连接, 通过一个全连接层即可得到车辆行程的属性编码向量, 记为 x_{attr} 并输入到模型中, 如式所示:

$$x_{attr} = \text{FC}(\text{concat}(\text{Emb}(x_w), \text{Emb}(x_d), \text{Emb}(x_s))) \quad (12)$$

式中: FC 表示全连接网络; concat 表示连接操作; Emb 表示嵌入操作; x_w 表示天气信息; x_d 表示出发时间; x_s 表示时效约束。

1.2.4 预测模型框架

结合时间模块、空间模块及属性模块构建基于多元特征的工程货运车辆行程时间预测模型。如图 5 所示, 将 X_m 作为作为输入数据, 提取时间、空间及属性特征信息, 输出预测结果 X_{m+1} 。本文采用全局路线预测, 直接获取工程运输车辆的行程时间。

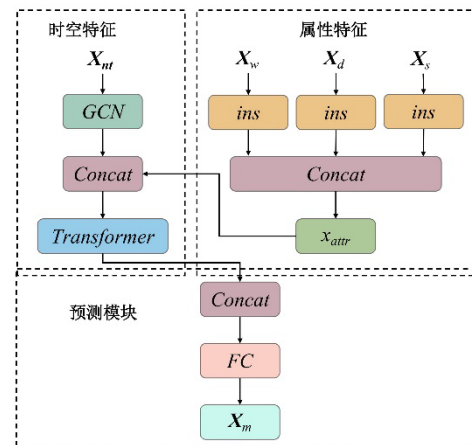


图 5 工程货运车辆行程时间预测模型框架

2 实验

2.1 实验设置

2.1.1 数据集

本文选取武汉市区内某一建筑工程项目的 20 辆工程货运车辆行驶轨迹数据, 共 2391 条, 包含 54.87 万个轨迹点, 轨迹间隔 10 秒记录一次, 如表 1 所示。数据起始日期为 2022 年 5 月 30 日, 结束日期为 2022 年 8 月 30 日。该建筑工程项目地处市区, 货物运输行程为 50km, 施工时间为 7:00-19:00。非工作日保持正常施工, 对数据规律性不产生干扰。

表 1 工程货运车辆行驶轨迹记录

车辆编号	记录时间	经度	纬度
7*****	5-30-2022 07:10:17	114.7502	30.6213
7*****	5-30-2022 07:10:27	114.7444	30.6199
...
5*****	8-30-2022 18:59:45	114.3397	30.5416
3*****	8-30-2022 18:59:55	114.3410	30.5404

处理过程中, 城市区域分别以 500×500、1000×1000 和 1500×1500m 为空间粒度划分, 这些空间粒度中的轨迹数据被统计为行程时间, 作为输入数据。在输入模型之前, 本文使用最小-最大标准化方法将所有的数据调整为[0,1]。在对比评价中, 预测行程时间信息将会重新调整为正常值, 有助于与真实行程时间对比。另外, 数据集以 8:1:1 的比例划分为训练集、验证集和测试集。

2.1.2 评价指标

本文采用预测行程时间和真实行程时间信息之间的误差作为评价模型预测性能的指标。即:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (13)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - y_i| \quad (14)$$

$$WMAPE = \sum_{i=1}^n \left(\frac{x_i}{\sum_{j=1}^n x_j} \left| \frac{x_i - y_i}{x_i} \right| \right) \quad (15)$$

式中: RMSE、MAE 和 WMAPE 分别表示均方根误差、平均绝对误差和加权平均绝对百分比误差; x_i 和 x_j 分别表示工程货运车辆 i 和 j 的行程时间真实值; y_i 表示工程货运车辆 i 的行程时间预测值。

2.1.3 参数设置

实验在一台拥有 GeForce RTX 3080 Ti GPU 的服务器上进行的。所提出的模型已经用 Python (3.8) 语言实现。PyTorch 深度学习框架用于并行计算, 可以有效地计算损失函数的梯度并更新模型参数并提高计算效率。

属性模块中天气、出发时间和施工时间的嵌入纬度选择基于实验结果和特征的维度需求, 通过交叉验证方法确定了最优的嵌入维度: 3、16、8。采用控制变量方法训练模型, 确定了模型的详细参数, 取得最优的预测性能。其中, 路段 ID 嵌入维度为 32; 图卷积网络的时间窗口步长为 6 个、训练批次为 32 批和图卷积核为 15 个; Transformer 的层数均为 3, 隐藏状态维度均为 64。时间间隔长度 ϵ 设置为 6, 时空模型学习率 α 设置为 10^{-3} 。

2.2 实验结果

为了评估本文模型的性能, 将其与基线模型进行了比较。这些模型是根据它们的最佳实验结果选择的。此外, 通过消融实验检验了不同模块在本文模型中的预测效果。基线模型如下所示:

HA: 依靠历史数据的平均值来预测下一时间步的值^[21];

ARIMA: 设置参数, 并使用获得的数据预测未来数据^[22];

SVR: 使用历史数据作为输入, 通过训练预测未来的公交客流。在这项研究中, 使用了线性核^[22];

GCN: 节点和特征信息用于获取空间相关性和预测交通信息。在这项研究中, 我们使用了停车距离图^[23];

Graph-WaveNet: 用扩展的偶然卷积组合以同时学习空间-时间相关性^[24];

如图 6、7 及 8 所示, 与支持向量回归 (SVR) 和 ARIMA 模型相比, 深度学习方法在预测精度上表现出显著优势。这一结果表明, 深度学习方法在处理城市范围内的非结构化数据时具备良好的时空特征提取能力。由于 ARIMA 模型在捕捉非线性特征方面能力有限, 导致其预测效果相对一般。相较于 SVR 和 ARIMA 模型而言, 三种空间粒度下, 本文提出的模型的 RMSE 分别平均降低了 44.76%和 31.23%。这说明本文模型捕捉时空特征的能力显著。此外, 与具有时空特征提取能力的 Graph-WaveNet

模型相比,本文模型的平均RMSE分别降低了6.39%,进一步验证了本文模型中属性模块在捕捉外部因素影响特征方面的有效性。

在三种空间粒度下,对比所有模型的预测效果,本文模型表现最优,其均方根误差RMSE平均降低了25.83%、26.43%和27%,平均绝对误差MAE平均降低了15.72%、18.04%和22.13%,加权平均绝对百分比误差WMAPE平均降低了5.83%、7.25%和9.61%。

为了验证属性模块与时间模块的有效性,对本文模型进行消融实验,实验结果如表2所示。可以看到,与本文模型的预测效果相比,去掉时间模块的模型预测性能一般, RMSE 降低了约 15.28%。同时,本文模型的预测性能优于去掉属性模块的模型,三种空间粒度下 RMSE 平均降低了约 8.29%。这表明天气信息、出发时间和时效约束的提取对模型的准确率均有一定影响,也证明了这些属性特征提取的有效性。




图 6 三种空间粒度下不同预测模型的均方根误差




图 7 三种空间粒度下不同预测模型的平均绝对误差




图 8 三种空间粒度下不同预测模型的加权平均绝对百分比误差

表 2 消融实验预测效果

空间粒度	500×500m			1000×1000m			1500×1500m		
评价指标	RMSE	MAE	WMAPE	RMSE	MAE	WMAPE	RMSE	MAE	WMAPE
去除时间模块	101.54	56.93	45.92%	132.97	73.08	41.35%	171.24	97.81	38.78%
去除属性模块	96.38	53.37	40.65%	120.63	68.27	36.89%	156.57	91.72	33.29%
本文模型	89.08	51.64	37.42%	111.32	64.84	33.17%	141.6	86.96	30.84%

2.3 案例研究

本文选取武汉市内某一建筑工程项目的具体案例,分析模型在不同空间粒度下的预测效果,

并与实际行程时间进行对比,展示模型的预测精度和实用性。三种空间粒度下某一工程货运车辆行程时间的真实值、本文模型预测值和基线模型预测值

进行拟合对比。这一工程运输车的作业时间与实验数据选取时间要求一致。如图 9、10 和 11 所示, 在与真实行程时间变化规律保持同步的基础上, 本文模型展示出良好的拟合效果。可以观察到, 较于 1000×1000 和 1500×1500m 空间粒度, 500×500m 具

有更多的区域网格且拟合效果突出。这是因为区域网格增多, Transformer 能够发挥捕捉时间序列特征的能力。

这进一步表明, 捕捉时间特征有助于提高预测能力。




图 9 500×500m 空间粒度下某一车辆行程时间的拟合效果




图 10 1000×1000m 空间粒度下某一车辆行程时间的拟合效果




图 11 1500×1500m 空间粒度下某一车辆行程时间的拟合效果

3 结论

本研究以工程货运车辆行程时间预测为研究对象, GPS 轨迹作为数据支撑, 提出了工程货运车辆行程时间预测模型。本文模型有效的捕捉了轨迹数据的时空相关特征, 提高了预测精度。此外, 本文模型考虑了天气信息、出发时间和时效约束等外部因素对预测精度的影响, 通过嵌入模型提取了这些文本信息的属性特征, 提高了模型的预测性能。本研究的结论不仅验证了模型的有效性, 也为未来行程时间预测模型的研究提供了新的方向, 特别是在考虑多元特征融合和深度学习技术的应用方面。综上, 本文提出的基于多元特征的预测模型不仅能够为工程项目管理人员精准对接工程材料提供决策依据, 也为提高工程运输车辆管理效率提供应用价值。

参考文献

- [1] Moniruzzaman M, Maoh H, Anderson W. Short-term prediction of border crossing time and traffic volume for commercial trucks: A case study for the Ambassador Bridge[J]. *Transportation Research Part C: Emerging Technologies*, 2016, 63: 182-194.
- [2] Golob T F, Regan A C. Impacts of highway congestion on freight operations: perceptions of trucking industry managers[J]. *Transportation Research Part A: Policy and Practice*, 2001, 35(7): 577-599.
- [3] Theophilus O, Dulebenets M A, Pasha J, et al. Truck scheduling optimization at a cold-chain cross-docking terminal with product perishability considerations[J]. *Computers & Industrial Engineering*, 2021, 156: 107240.
- [4] Fathollahi-Fard A M, Ranjbar-Bourani M, Cheikhrouhou N, et al. Novel modifications of social engineering optimizer to solve a truck scheduling problem in a cross-docking system[J]. *Computers & Industrial Engineering*, 2019, 137: 106103.
- [5] Zhou M, Kong N, Zhao L, et al. Understanding urban delivery drivers' intention to adopt electric trucks in China[J]. *Transportation Research Part D: Transport and Environment*, 2019, 74: 65-81.
- [6] Bai R, Xue N, Chen J, et al. A set-covering model for a bidirectional multi-shift full truckload vehicle routing problem[J]. *Transportation Research Part B: Methodological*, 2015, 79: 134-148.
- [7] 王九胜,戴许海,缪中岩,等.基于多元时空关系的公路交通流量时序预测模型[J].*公路交通科技*,2023, 40(10): 175-182.WANG Jiu-sheng, DAI Xu-hai, MIU Zhong-yan, et al. A Model for Time Series Prediction on Highway Traffic Flow Based on Multivariate Spatio-temporal Relationship. *Journal of Highway and Transportation Research and Development*. 2023, 40(10): 175-182 <https://doi.org/10.3969/j.issn.1002-0268.2023.10.020>.
- [8] Nadi A, Sharma S, Snelder M, et al. Short-term prediction of outbound truck traffic from the exchange of information in logistics hubs: A case study for the port of Rotterdam[J]. *Transportation Research Part C: Emerging Technologies*, 2021, 127: 103111.
- [9] Borowska-Stefańska M, Kowalski M, Kurzyk P, et al. Assessing the impacts of sunday trading restrictions on urban public transport: an example of a big city in central Poland[J]. *Journal of Public Transportation*, 2023, 25: 100049.
- [10] Scellato S, Musolesi M, Mascolo C, et al. Nextplace: a spatio-temporal prediction framework for pervasive systems[C]//*Pervasive Computing: 9th International Conference, Pervasive 2011, San Francisco, USA, June 12-15, 2011. Proceedings 9*. Springer Berlin Heidelberg, 2011: 152-169.
- [11] 胥帅,李博涵,许建秋,等.意图感知的社交网络用户城外移动行为预测[J/OL].*计算机学报*:1-16[2024-10-10].XU Shuai, LI Bo-han, XU Jian-qiu, et al. Intention-Aware Out-of-Town Mobility Prediction for Social Network Users. *Chinese Journal of Computers*. 2024-10-10: 1-16.
- [12] Do T M T, Gatica-Perez D. Contextual conditional models for smartphone-based human mobility prediction[C]//*Proceedings of the 2012 ACM conference on ubiquitous computing*. 2012: 163-172.
- [13] Du N, Dai H, Trivedi R, et al. Recurrent marked temporal point processes: Embedding event history to vector[C]//*Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data*

- mining. 2016: 1555-1564.
- [14] Krishna K, Jain D, Mehta S V, et al. An lstm based system for prediction of human activities with durations[J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2018, 1(4): 1-31.
- [15] Chen C, Wang Y, Li L, et al. The retrieval of intra-day trend and its influence on traffic prediction[J]. Transportation research part C: emerging technologies, 2012, 22: 103-118.
- [16] YU B, LEE Y, SOHN K. Forecasting road traffic speeds by considering area-wide spatio-temporal dependencies based on a graph convolutional neural network (GCN)[J]. Transportation Research Part C-Emerging Technologies, 2020, 114: 189-204.
- [17] MOU L C, LU X Q, LI X L, et al. Nonlocal Graph Convolutional Networks for Hyperspectral Image Classification[J]. Ieee Transactions on Geoscience and Remote Sensing, 2020, 58(12): 8246-57.
- [18] 陈建忠, 吕泽凯, 蔺皓萌. 基于生成对抗和图卷积网络的含缺失值交通流预测模型[J]. 公路交通科技, 2023, 40(09): 205-214. CHEN Jian-zhong, LV Ze-kai, LIN Hao-meng. A Prediction Model for Traffic Flow with Missing Values Based on Generative Adversarial and Graph Convolutional Networks. Journal of Highway and Transportation Research and Development. 2023, 40(9): 205-214 <https://doi.org/10.3969/j.issn.1002-0268.2023.09.024>.
- [19] Zhou H, Zhang S, Peng J, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting[C]//Proceedings of the AAAI conference on artificial intelligence. 2021, 35(12): 11106-11115.
- [20] Tang B, Matteson D S. Probabilistic transformer for time series analysis[J]. Advances in Neural Information Processing Systems, 2021, 34: 23592-23608.
- [21] 刘静, 关伟. 交通流预测方法综述. 公路交通科技. 2004, 21(3): 82-85. LIU Jing, GUAN Wei. A Summary of Traffic Flow Forecasting Methods. Journal of Highway and Transportation Research and Development. 2004, 21(3): 82-85.
- [22] 王博文, 王景升, 朱茵, 等. 基于 ARMA-SVR 的短时交通流量预测模型研究[J]. 公路交通科技, 2021, 38(11): 126-133. WANG Bo-wen, WANG Jing-sheng, ZHU Yin, et al. Study on Short-term Traffic Volume Prediction Model Based on ARMA-SVR. Journal of Highway and Transportation Research and Development. 2021, 38(11): 126-133
- [23] Wang X, Huang L, Huang H, et al. An Ensemble Learning Model for Short - Term Passenger Flow Prediction[J]. Complexity, 2020, 2020(1): 6694186.
- [24] Wu Z, Pan S, Long G, et al. Graph wavenet for deep spatial-temporal graph modeling[J]. arXiv preprint arXiv: 1906.00121, 2019.

版权声明: ©2025 作者与开放获取期刊研究中心(OAJRC)所有。本文章按照知识共享署名许可条款发表。

<https://creativecommons.org/licenses/by/4.0/>

