

基于多交通模式改进的共享单车需求预测算法研究

胡智维, 张建同

(同济大学管理科学与工程系, 上海 200092)

✉ 2130404@tongji.edu.cn; zhangjiantong@tongji.edu.cn



摘要: 现有的共享单车预测模型大多将共享单车视为封闭交通系统, 忽略了不同交通系统之间的交互影响, 因此设计了一种使用非负矩阵分解算法改进的图卷积神经网络。首先, 利用非负矩阵分解算法将其他交通系统的需求数据分解为不同的出行模式; 其次, 确定不同出行模式的含义; 最后, 将分解后的需求信息作为辅助信息与共享单车需求数据一同输入图卷积神经网络中进行预测。实验结果表明: 与不考虑其他交通方式影响的模型相比, 使用非负矩阵分解算法改进的图卷积神经网络的平均绝对误差下降了 10.84%, 并且非负矩阵分解方法能较好地解释辅助交通系统是如何提升单车需求预测效果的。

关键词: 非负矩阵分解; 图卷积神经网络; 共享单车需求; 可解释性

中图分类号: TP183 **文献标志码:** A

Research on Demand Forecasting Algorithm for Shared Bicycles Based on Improved Multi-mode Transportation Mode

HU Zhiwei, ZHANG Jiantong

(Department of Management Science and Engineering, Tongji University, Shanghai 200092, China)

✉ 2130404@tongji.edu.cn; zhangjiantong@tongji.edu.cn

Abstract: Most existing shared bicycle prediction models consider shared bicycles as closed transportation systems and ignore the interaction between different transportation systems. Therefore, this paper proposes to design a graph convolutional neural network improved by non-negative matrix decomposition algorithm. Firstly, the demand data of other transportation systems are decomposed into different travel modes using the non-negative matrix decomposition algorithm. Secondly, the meanings of different travel modes are determined. Finally, the decomposed demand information is used as auxiliary information and input into the graph convolutional neural network along with the shared bicycle demand data for prediction. Experimental results show that compared with models that do not consider the influence of other transportation modes, the average absolute error of the graph convolutional neural network improved by the non-negative matrix decomposition algorithm has decreased by 10.84%, and the non-negative matrix decomposition algorithm can better explain how auxiliary transportation systems improve the effectiveness of bicycle demand forecasting.

Key words: non-negative matrix decomposition; graph convolutional neural network; shared bicycle demand; interpretability

0 引言 (Introduction)

共享单车是当前公共交通系统中的重要组成部分, 但共享单车需求的潮汐效应也给公共交通系统和共享单车系统运营

方带来了额外的压力^[1-2], 因此一个高效的调度系统对共享单车系统的高效运营非常重要, 而调度系统的高效运营依赖于精确的短期需求预测^[3-4]。国内外的学者对共享单车短期需求预

测进行了大量的研究,使用的方法大多基于机器学习^[5-6]和深度学习等数据驱动方法。例如,张建同等^[7]结合随机森林、极端梯度提升(eXtreme Gradient Boosting, XGBoost)及梯度提升决策树(Gradient Boosting Decision Tree, GBDT)三类算法提出了组合预测模型;孙启鹏等^[8]分析了单车出行模式,并尝试将单车出行模式与多层前馈神经网络结合预测共享单车需求;姜晓等^[9]、陆凯韬等^[10]、ZHANG 等^[11]尝试使用长短期记忆网络进行预测。共享单车作为一种交通系统,具有天然的图结构,因此图卷积神经网络^[12]在交通流预测中也被广泛使用,CHAI 等^[13]基于图卷积神经网络提出了多图卷积神经网络预测共享单车系统中的需求。但是,以上研究大多将共享单车需求视为单一系统,忽略了其与其他交通系统之间的联系。近年的部分研究主张在共享单车需求预测任务中结合其他公共交通系统的信息,以提升需求预测的准确度。例如,LIANG 等^[14]考虑了如地铁人流量等其他交通模式的信息,有效改善了共享单车需求的预测效果。CHO 等^[15]比较了不同交通系统与单车系统之间的联系。

本文提出一种基于非负矩阵分解改进的多图卷积网络预测模型,在共享单车需求预测任务中结合其他公共交通系统的信息,以达到提升预测效果的目的。实验结果表明:与不考虑其他交通方式影响的模型相比,使用非负矩阵分解算法改进的图卷积神经网络的平均绝对误差下降了 10.84%,并且非负矩阵分解方法能较好地解释辅助交通系统是如何提升单车需求预测效果的。

1 数据与模型(Data and model)

1.1 数据来源与预处理

本文主要使用两个数据集:(1)纽约市自行车系统公开数据(NYC Citi Bike),记录的信息类型有单车 ID、出发时间、结束时间、出行持续时长、出发点和终点坐标等,包括 2020 年 7 月至 9 月纽约市内 1 104 个区域的单车出行数据,共有约 690 万条的出行记录,本文将起止点距离小于 50 m 的记录去除,并排除每天平均用车记录小于 10 条的区域,共得到 848 个区域 2020 年 7 月至 9 月每小时的用车需求。(2)纽约市出租车需求数据集,来自纽约市出租车和豪华轿车委员会(TLC),记录了 2020 年 7 月至 9 月约 55 万条用车记录,包括乘客的上车时间、下车时间、上车区域 ID、下车区域 ID、上车地点、下车地点和出行里程等信息。两个数据集的简介如表 1 所示。

表 1 两个数据集的简介

Tab.1 Introduction to the two datasets

数据集名称	字段	时间范围	数据量
纽约市自行车系统公开数据	单车 ID, 出发时间, 结束时间, 出行持续时长, 出发点和终点坐标	2020 年 7 月至 9 月	约 690 万条
纽约市出租车需求数据集	上车时间, 下车时间, 上车区域 ID, 下车区域 ID, 上车地点, 下车地点和出行里程	2020 年 7 月至 9 月	约 55 万条

本文根据数据集中上车和下车地点名称,结合谷歌地图中

的数据获取上车和下车位置的坐标信息,同样去除每天平均用车需求小于 10 条的区域和起止点距离小于 500 m 的区域。纽约市出租车出行模式作为辅助交通模式输入,帮助改善单车需求预测效果。

1.2 使用非负矩阵分解(NMF)改进的多关系图卷积神经网络

对共享单车需求进行预测的大多数算法通常将共享单车需求视为封闭系统,忽略了共享单车系统与其他交通系统之间的相互作用。但是,共享单车作为交通系统的一个组成部分,成为解决“最后一公里”问题的存在。因此,共享单车系统的需求很难不受其他交通系统的影响。例如,乘坐地铁的乘客很可能在出站后选择共享单车,出租车需求旺盛的区域或目的地区域可能代表这些区域是交通热点,共享单车在这些区域可能有比其他区域更高的需求。多关系图卷积神经网络(Multi-Relational Graph Neural Network)^[14]是一种用于在跨交通模式中提取信息在预测节点中共享并提升预测效果的网络结构。但是,多关系图卷积神经网络缺乏可解释性,也无法解释辅助交通模式中的哪一部分信息提升了预测效果。本文基于非负矩阵分解改进多关系图卷积神经网络,希望通过非负矩阵分解帮助模型学习更多深层次信息的同时,还可以直观地观察辅助交通模式中的信息是如何提升模型预测效果的,使模型具有良好的可解释性。本文选取纽约市出租车的出行数据集作为单车需求预测的辅助数据集,也可以应用其他任意出行模式的数据作为辅助数据或是多个交通模式的数据集同时作为辅助数据进行预测。

基于非负矩阵分解方法改进后的多关系图卷积神经网络利用从辅助数据集和共享单车历史需求数据中提取的时空特征预测单车需求。为了直观地观察辅助交通模式中的哪一部分信息改善了单车需求的预测,在使用多关系图卷积神经网络提取时空特征之前,要先使用非负矩阵分解法将出行矩阵分解为 k 种出行模式。非负矩阵分解法的非负约束让分解出的矩阵非负,因此分解后得到的基矩阵 $\mathbf{W}_{m \times k} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_m]^T$ 、系数矩阵 $\mathbf{H}_{k \times t} = [\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_t]$ 具有明确的物理意义。根据现实意义, $\mathbf{w}_m$ 可以理解为 k 种出行模式在区域 m 的出行规模大小, $\mathbf{h}_t$ 可以理解为 k 种出行模式在时间点 t 的出行强度, $\mathbf{w}_m^T$ 和 $\mathbf{h}_t$ 均为 k 维向量,则将 $\mathbf{W}_{m \times k}$ 和 $\mathbf{H}_{k \times t}$ 中对应的第 k 种出行模式的行向量和列向量相乘,得到 $m \times t$ 维矩阵 $\mathbf{V}'_k$, 其中 $[\mathbf{V}'_k]_{ij} = \mathbf{W}_{ik} \mathbf{H}_{kj}$ 。矩阵 $\mathbf{V}'_k$ 为估计的第 k 种出行模式的需求矩阵,将矩阵 $\mathbf{V}'_k$ 和单车出行矩阵一起作为预测模型的输入,多关系图卷积神经网络负责捕捉各个出行模式内部的和跨模式的出行节点之间的有效信息,预测层利用卷积模块捕捉到的各个站点的信息表示和依赖关系完成单车需求的预测。基于非负矩阵分解方法改进后的多关系图卷积神经网络模型的整体结构如图 1 所示。

1.2.1 使用非负矩阵分解法的出行模式分解

非负矩阵分解法于 1999 年被提出,与传统的奇异值分解(SVD)、独立成分分析(ICA)、主成分分析(PCA)等方法相比,非负矩阵分解法对分解出的子矩阵有非负约束,该特性让非负




图1 基于非负矩阵分解方法改进后的多关系图卷积神经网络模型的整体结构

Fig. 1 The overall structure of a multi-relational graph convolutional neural network model improved by non-negative matrix decomposition method

矩阵分解法分解出的子矩阵拥有良好的可解释性。本文以非负矩阵分解法为基础,将庞大的出租车出行矩阵分解为子矩阵,拆解为可解释的不同出行模式,并将其作为辅助共享单车需求预测的辅助交通模式。

非负矩阵分解法的基本思想可以概括为对于非负矩阵 V , 非负矩阵分解法可以找到一个非负矩阵 W 和一个非负矩阵 H , 使 $V \approx WH$, 由于分解算法很难求得完全相等的分解矩阵, 因此使用约等号。非负矩阵分解法保证了分解过程的非负性, 分解出的矩阵往往是具有实际物理意义的。对于出租车出行矩阵, 假设有出行矩阵 $V_{m \times t}$, 记录了 m 个空间区域内在 t 个时间点的出行需求, 找到矩阵 $W_{m \times k} = [w_1, w_2, \dots, w_m]^T$ 和矩阵 $H_{k \times t} = [h_1, h_2, \dots, h_t]$, w_m^T, h_t 均为 k 维向量。使 $V_{m \times t} \approx W_{m \times k} H_{k \times t}$, 矩阵 $W_{m \times k}$ 被称为基矩阵, 矩阵 $H_{k \times t}$ 被称为系数矩阵。在对有实际意义的出行矩阵 $V_{m \times t}$ 的分解过程中, w_m 可以理解成 k 种出行模式在区域 m 的出行规模大小, h_t 可以理解成 k 种出行模式在时间点 t 的出行强度。通过对基矩阵和系数矩阵的分析可以得出出租车出行模式在空间和时间维度的分布特征。本文仅介绍非负矩阵分解法的具体步骤而不做推导。

Step 1: 输入非负矩阵 $V_{m \times t}$, 设定非负矩阵分解的最大可接受误差 ϵ 。

Step 2: 随机生成基矩阵 W 和系数矩阵 H 。

Step 3: 计算以 Frobenius 范数定义的损失函数

$$\|V - WH\|_F^2 = \sum_{i=1}^m \sum_{j=1}^t [D_{ij} - (WH)_{ij}]^2$$

Step 4: 使用梯度下降法更新, 即

$$W_{ik} = W_{ik} \cdot \frac{(DH^T)_{ik}}{(DH^T)_{ik}}$$

$$H_{kj} = W_{kj} \cdot \frac{(W^T V)_{kj}}{(W^T WH)_{kj}}$$

Step 5: 计算损失函数, 判断它是否满足小于 ϵ , 若满足, 更新结束; 若不满足, 则返回 Step 4 继续更新, 直到损失函数小于 ϵ 或达到迭代上限为止。

由于非负矩阵分解需要对需求矩阵整体进行分解, 为了不影响测试集结果, 所以训练和测试阶段的分解方法略有不同,

在训练阶段使用的分解法为非负矩阵分解法的分解步骤, 在 Step 4 中使用梯度下降法, 同时更新基矩阵 $W_{m \times k}$ 和系数矩阵 $H_{k \times t}$ 。而在测试阶段, 本文假定在各个出行区域中的不同出行模式的占比在一定时间内是稳定的, 因此固定在训练阶段生成的基矩阵 $W_{m \times k}$, 依据现有的基矩阵 W 生成系数矩阵 H , 步骤如下: 固定基矩阵 $W_{m \times k}$ 后, 基于测试集数据使用梯度下降法生成新系数矩阵 $H_{k \times t}$ 。

Step 1: 输入非负矩阵 $V_{m \times t}$, 设定非负矩阵分解的最大可接受误差 ϵ , 此处 t 为输入数据的时间步长。

Step 2: 随机生成系数矩阵 H 。

Step 3: 计算以 Frobenius 范数定义的损失函数

$$\|V - WH\|_F^2 = \sum_{i=1}^m \sum_{j=1}^t [D_{ij} - (WH)_{ij}]^2$$

Step 4: 使用梯度下降法更新, 即

$$H_{kj} = W_{kj} \cdot \frac{(W^T V)_{kj}}{(W^T WH)_{kj}}$$

Step 5: 计算损失函数, 判断它是否满足小于 ϵ , 若满足, 更新结束; 若不满足, 则返回 Step 4 继续更新, 直到损失函数小于 ϵ 或达到迭代上限为止。

1.2.2 多交通模式的时空图建模

本文将不同区域的共享单车出行和出租车出行之间的联系建模为时空图。纽约市的各个出行区域为构造的图的顶点, 顶点特征为各个区域的需求信息。由于本文需要提取不同交通模式之间的依赖关系, 因此除了构建一般的单个交通模式内部的时空图, 还需要构建跨交通模式的时空图。对于单个交通模式内部的时空图, 以共享单车为例, 它的内部图被构建为 $G_B = (V_B, A_B)$, 其中 V_B 为需求站点, A_B 为站点间依赖关系的邻接矩阵。同理, 出租车出行需求也可以被构建为 $G_T = (V_T, A_T)$, 并且出租车需求被分解后的不同需求模式共享同样的内部图。对于跨交通模式的时空图, 其作用是捕捉共享单车站点和出租车需求区域之间的联系。本文将跨交通模式的时空图定义为 $G_{BT} = (V_B, V_T, A_{BT})$, 其中 V_B, V_T 为共享单车需求站点和出租车出行区域, A_{BT} 为 V_B, V_T 之间依赖关系的邻接矩阵。

为了更有效地捕捉不同站点和出行区域之间的相互依赖关系, 本文从不同的视角定义邻接矩阵。纽约市的各个需求站点和出行区域为构造的图的顶点, 顶点特征为各个区域的需求信息, 可以从距离和历史流量相似度视角出发, 构建邻接矩阵:

$$[A_D]_{ij} = \begin{cases} \frac{1}{\text{Dist}(\text{lng}_i, \text{lat}_i, \text{lng}_j, \text{lat}_j)}, & i \neq j \\ 0, & i = j \end{cases} \quad (1)$$

$$[A_p]_{ij} = \begin{cases} \rho_{ij}, & i \neq j \\ 0, & i = j \end{cases} \quad (2)$$

其中: 距离函数 Dist 为两点之间的曼哈顿距离, ρ_{ij} 为两个区域历史流量的相似度, 相似度函数用皮尔逊相关系数定义。因此, 最终构造有以下不同的图结构, 分别代表单车需求站点和出租车需求区域内部和互相的依赖关系:

$$G_{T,D} = (V_T, A_{T,D}) \quad (3)$$

$$G_{T,P} = (V_T, A_{T,P}) \quad (4)$$

$$G_{B,D} = (V_B, A_{B,D}) \quad (5)$$

$$G_{B,P} = (V_B, A_{B,P}) \quad (6)$$

$$G_{BT,D} = (V_B, V_T, A_{BT,D}) \quad (7)$$

$$G_{BT,P} = (V_B, V_T, A_{BT,P}) \quad (8)$$

公式(3)至公式(6)代表出租车出行时空图和单车出行时空图分别根据距离和相关系数定义的图连接结构,公式(7)和公式(8)代表共享单车需求节点和出租车出行区域共同构成的时空图根据距离和相关系数的图连接结构。

1.2.3 多关系图卷积神经网络

多关系图卷积神经网络是一种用于在跨交通模式中提取信息在预测节点中共享,并提升预测效果的网络结构^[14]。本文基于非负矩阵分解法改进多关系图卷积神经网络,在提升模型预测效果的同时,使结果具备良好的可解释性,可以直观地展示不同的交通模式如何改善共享单车需求预测的结果。

多关系图卷积神经网络是在图卷积神经网络的基础上改进的,它可以从不同交通模式的异构图中根据连接情况提取各顶点的有效信息,本文根据前文定义的距离图和流量相似度图提取有效信息。多关系图卷积神经网络结构如图2所示。




图2 多关系图卷积神经网络结构

Fig. 2 Structure of multi-relational graph convolutional neural network

图卷积神经网络结构是一种非常高效地从图结构数据中提取有效特征的网络结构,而交通网络具有天然的图结构,因此图卷积网络被广泛地应用于交通流预测领域并取得了良好的效果。在图卷积神经网络中,图中来自邻居的信息被汇总并用于逐步更新顶点的隐藏状态,这些信息在过渡网络中传播,最终使每个顶点都能捕获大邻域的信息。图卷积神经网络的卷积公式如下:

$$H^{l+1} = \sigma \left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^l w^l \right) \quad (9)$$

其中: σ 为激活函数; $\tilde{D}$ 为自连接的邻接矩阵的度矩阵; H^l 为输入特征矩阵,代表网络图的节点的特征; w^l 为第 l 层的可训练参数; $\tilde{A} = A + I_N$,代表有自连接网络的邻接矩阵。本文使用在图卷积结构的基础上改进的多关系图卷积神经网络提取跨交通模式的异构图中节点的相互信息。以共享单车和出租车两种出行模式为例,多关系图卷积神经网络的卷积公式如下:

$$H_{BT}^{l+1(c)} = \text{ReLU} \left[\tilde{A}_B (\tilde{A}_{BT} H_T^l) W_{BT}^{l(c)} + P_{BT}^{l(c)} \right] \quad (10)$$

$$H_{BT}^{l+1(d)} = \text{ReLU} \left(\tilde{A}_B | \tilde{A}_{BT} H_T^l - H_B^l | W_{BT}^{l(d)} + P_{BT}^{l(d)} \right) \quad (11)$$

$$Z_B^{l+1} = \text{ReLU} (\tilde{A}_B H_B^l W_B^l + P_B^l) \quad (12)$$

$$H_T^{l+1} = \text{ReLU} (\tilde{A}_T H_T^l W_T^l + P_T^l) \quad (13)$$

$\tilde{A} = \frac{A}{\text{rowsum}(A)}$ 为归一化后的邻接矩阵, $W_{BT}^{l(c)}$ 、 $P_{BT}^{l(c)}$ 、

$W_{BT}^{l(d)}$ 、 $P_{BT}^{l(d)}$ 、 W_B^l 、 P_B^l 、 W_T^l 、 P_T^l 均为可学习参数。公式(10)和公式(11)用于跨交通模式提取有效特征,其中公式(10)用于提取交通模式间相似性,公式(11)用于提取交通模式间的差异性,公式(12)和公式(13)则与普通的图卷积神经网络结构相同,用于提取交通模式内节点的有效特征。当学习到不同的有效特征后,将所有有效特征加法聚合后即成为下一层输入:

$$H_B^{l+1} = H_{BT}^{l+1(c)} + H_{BT}^{l+1(d)} + Z_B^{l+1} \quad (14)$$

1.2.4 预测

本文将从各个交通模式内部提取的时空特征输出和从跨交通模式提取的时空特征输出融合后作为预测层的输入,预测层由 L 个全连接层组成,模型训练目标是最小化共享单车出行需求和预测需求间的误差。损失函数如下:

$$\text{Loss} = \|F'_t - Y_t\| + \lambda L_{\text{reg}} \quad (15)$$

其中: $\|F'_t - Y_t\|$ 为Frobenius范数; F'_t 为模型预测结果; Y_t 为实际需求值; L_{reg} 为L2正则化函数,用于抑制模型的过拟合问题; λ 为正则化函数的权重。

2 纽约市出租车出行模式分析 (Analysis of taxi travel modes in New York city)

使用NMF分解出行矩阵后,可以得到基矩阵 W 和系数矩阵 H 。从物理意义的角度解释,基矩阵 W 可以代表不同出行模式在空间分布上的强度,系数矩阵 H 则代表不同出行模式在不同时间段的强度。本文对纽约市出租车需求数据集进行非负矩阵分解,使用手肘法确定最优模式数 $k=4$ 。因此,最终分解出4种基本出行模式。利用系数矩阵 H 分析4种出行模式的时间分布情况,截取一个自然日内不同模式的出行强度并绘制折线图,出租车出行模式时间分布如图3所示。




图3 出租车出行模式时间分布

Fig. 3 Time distribution of taxi travel modes

通过观察图3可以看出,峰值出现在上午和晚上的出行模式为典型的通勤出行需求,分为通勤晚高峰的居民用车需求(需求高峰为16:00~18:00)和通勤早高峰的居民用车需求(需求高峰为7:00~9:00)。从9:00开始缓慢增加,到22:00~23:00达到高峰的出行需求推测为不需要工作的居民的娱乐出行需求;对于8:00、12:00和19:00均出现一个小高峰的出行需求,

则推测为其他零散的出行需求。

3 共享单车需求预测结果及可解释性分析 (Prediction results and interpretability analysis of demand for shared bicycles)

3.1 模型设置及实验结果

将2020年7月至9月纽约市内不同站点、不同区域的共享单车需求量和出租车需求量作为输入,数据集中记录每小时的需求数据,本文将数据集中的60%作为训练集,20%作为验证集,20%作为测试集。本文设置时间步数为12,将每12h的需求数据作为输入,预测后12h的需求, $epoch$ 设置为100,学习率设定为0.001。模型训练完成后在测试集中的预测误差如表2所示。

表2 预测误差表
Tab.2 Table of prediction errors

模型	均方误差 (MSE)	平均绝对误差 (MAE)	均方根误差 (RMSE)
LR	22.833 50	3.672 40	4.778 45
MLP	14.135 20	2.282 90	3.749 70
STGCN	13.218 00	2.135 40	3.635 67
GCN-Taxi	12.678 16	2.181 60	3.560 64
NMF-MRGCN 其他出行需求	11.492 55	2.007 40	3.390 06
NMF-MRGCN 晚高峰	11.712 59	2.031 26	3.422 37
NMF-MRGCN 早高峰	10.770 69	1.926 30	3.281 80
NMF-MRGCN 娱乐出行需求	11.589 77	2.037 20	3.404 40
NMF-MRGCN 同时输入	10.195 71	1.903 80	3.193 00

表2展示了经非负矩阵分解法改进的多关系图卷积神经网络与线性回归模型(LR)、全连接神经网络(MLP)、时空图卷积神经网络(STGCN)的预测误差的对比。NMF-MRGCN为基于非负矩阵分解法改进的多关系图卷积神经网络模型,表2展示了将不同的出租车出行模式作为辅助交通模式输入模型时的预测误差。从表2中可以看到,同时输入4种出行模式的预测误差最低,平均绝对误差仅为1.903 80,相比不考虑其他交通模式信息的STGCN,平均绝对误差下降了10.84%,提升效果最显著,说明模型从辅助模式中学习了有助于提升预测精度的信息。在各个辅助模式中,早高峰对预测结果的提升最明显,平均绝对误差为1.926 30,其他三种出行模式对预测结果的改善也有较明显的作用,主要误差指标均显著低于STGCN。GCN-Taxi为不进行非负矩阵分解,直接将出租车的需求数据输入模型作为辅助交通模式得到的模型预测精度,平均绝对误差为2.181 60,甚至略低于STGCN,预测效果明显差于基于非负矩阵分解法改进后的模型,说明矩阵分解模块在提升模型可解释性的同时,也较好地将出行模式的信息显性表达,让模型能更高效地学习辅助模式的特征。

3.2 可解释性分析

首先观察4种出行模式同时输入的NMF-MRGCN相对于STGCN的预测提升效果。STGCN没有加入出租车出行数据作为辅助预测模式,将STGCN在每个单车需求点的测试集

中的平均绝对误差取均值,并与NMF-MRGCN在每个单车需求点的平均绝对误差取均值作差,这个差值代表NMF-MRGCN相对于STGCN的预测结果中平均绝对误差的下降幅度,将单车节点在邻接矩阵 $A_{BT,D}$ 、 $A_{BT,P}$ 中与出租车出行区域连接的权重相加,可得到单车节点与出租车出行节点的连接强度,NMF-MRGCN相对于STGCN的精度提升效果同单车节点与出租车出行节点连接强度的关系如图4所示。




图4 预测精度提升效果同单车节点与出租车出行节点连接强度的关系

Fig. 4 The relationship between the improvement of prediction accuracy and the connection strength between bicycle nodes and taxi nodes

图4中的横轴表示单车节点与出租车出行节点的连接强度,连接强度为邻接矩阵中与这个单车节点连接的出租车出行节点的权重之和,连接强度越大,说明单车节点与周围区域的出租车出行节点连接越紧密。纵轴表示加入出租车节点作为辅助模式后与STGCN相比减少的平均绝对误差。从图4可以看出,单车出行节点与出租车节点联系越紧密,预测效果的改善程度越好,说明模型可以从单车出行点周围的出租车节点学习有效信息进而辅助预测。

从表2的实验结果中可以观察到,与不考虑辅助交通模式的STGCN相比,将4种出行模式中的任意一种作为辅助模式输入NMF-MRGCN中都对预测精度有所提升,其中早高峰和其他出行需求提升效果均较为明显,提升效果最好的辅助模式为早高峰出行模式。将不同的出行模式作为辅助模式时的NMF-MRGCN模型在不同时段预测结果的均方误差进行对比,可以观察到以不同的出行模式作为输入时,NMF-MRGCN模型可以在STGCN的基础上提升预测性能,如图5所示。




图5 不同辅助模式下的预测性能改善效果

Fig. 5 Improved prediction performance under different auxiliary modes

图5展示了测试集上的不同辅助模式按时间段分别计算的预测均方误差,4种辅助模式均对预测结果有较明显的改善,并且在晚高峰时间段的改善效果最明显。从图5中可以看到,当辅助模式为早高峰模式时的预测性能最接近4种辅助模式同时输入的完整模型,说明早高峰模式提供的出行信息对提升预测效果的贡献最大,其他三种出行模式作为辅助模式时整体预测结果接近,没有明显区别。

从地理分区角度看,纽约的分区税务数据库(Zoning Tax Lot Database)记录了纽约各个分区的主要区域功能。将各个单车需求预测点与对应区域进行匹配,可以分区域观察不同的辅助模式在不同功能区的预测中发挥的作用,分区域误差表如表3所示。

表3 分区域误差表
Tab.3 Partition error table

区域功能	早高峰	晚高峰	娱乐出行	其他出行
商业区	0.371 9	0.214 4	0.215 5	0.232 5
工业区	0.065 7	0.012 2	0.003 1	-0.009 6
居民区	0.179 8	0.084 3	0.077 1	0.109 3

表3记录了不同出行模式作为辅助模式时,对应功能区的所有单车预测点位的均方误差平均下降幅度。整体而言,辅助模式在商业区和居民区发挥的作用最大,在工业区的辅助预测效果不够显著,尤其是娱乐出行模式和其他出行模式,可以推测可能是因为在工业区的总体出行需求中以早、晚高峰需求为主。早、晚高峰出行模式则对表3中三种区域的共享单车出行需求预测精度均有一定的提升效果。

4 结论(Conclusion)

本文提出了一种使用非负矩阵分解算法改进的多关系图卷积神经网络模型,首先将辅助交通模式分解为可解释的模式,其次将各个出行模式的需求信息作为辅助信息和共享单车历史需求数据一起输入图卷积网络中进行预测。在实验中,本文以纽约市共享单车预测为例,将出租车需求分解为4种可解释的出行模式作为辅助信息帮助进行共享单车需求的预测,结果表明每种可解释的出行模式都对共享单车需求预测效果的改善有一定的帮助。与出租车出行区域联系越紧密的单车需求节点,对共享单车需求的预测精度提升越大,表示出租车需求数据可以向模型提供关于出行区域的额外信息,进而帮助改善预测效果。其中,出租车的早高峰出行模式的辅助对提升模型预测精度的作用最显著。对不同的功能区域而言,商业区和居民区的单车需求点位的改善效果最明显,工业区的改善效果最不明显。本文提出的使用非负矩阵分解法改进的多图卷积预测模型可以更高效地捕捉不同交通模式之间存在的潜在联系,从而获得比将共享单车视为单一封闭系统的模型更低的预测误差。

参考文献(References)

[1] 朱富强. 共享经济的现代发展及其潜在问题:以共享单车为例的分析[J]. 南方经济,2017(7):37-50.
[2] 郭鹏,林祥枝,黄艺,等. 共享单车:互联网技术与公共服务中的协同治理[J]. 公共管理学报,2017,14(3):1-10,154.
[3] 潘海啸,高雅. 共享单车的规模化扩张与精细化管理[J]. 上海城市管理,2017,26(4):58-62.

[4] 徐广. 我国共享单车行业存在的问题及对策分析[J]. 现代商业,2017(14):165-166.
[5] SATHISHKUMAR V E,PARK J,CHO Y Y. Using data mining techniques for bike sharing demand prediction in metropolitan city[J]. Computer communications, 2020, 153:353-366.
[6] SATHISHKUMAR V E,CHO Y Y. A rule-based model for Seoul Bike sharing demand prediction using weather data[J]. European journal of remote sensing, 2020, 53: 166-183.
[7] 张建同,孙嘉青. 基于组合预测法的共享单车租赁需求量预测[J]. 运筹与管理,2021,30(10):146-152.
[8] 孙启鹏,曾开邦,张锴琦,等. 北京市共享单车出行的时空规律与需求预测研究[J]. 交通运输系统工程与信息, 2022,22(1):332-338.
[9] 姜晓,白璐斌,楼夏寅,等. 基于多尺度时空聚类的共享单车潮汐特征挖掘与需求预测研究[J]. 地球信息科学学报, 2022,24(6):1047-1060.
[10] 陆凯韬,董红召,陈宁. 基于LSTM的公共自行车服务点租还需求量预测[J]. 计算机测量与控制,2017,25(9): 178-181.
[11] ZHANG C,ZHANG L N,LIU Y D, et al. Short-term prediction of bike-sharing usage considering public transport:a LSTM approach[C]//IEEE. Proceedings of the IEEE: 2018 21st International Conference on Intelligent Transportation Systems(ITSC). Piscataway:IEEE,2018: 1564-1571.
[12] XIAO G N,WANG R N,ZHANG C Q, et al. Demand prediction for a public bike sharing program based on spatio-temporal graph convolutional networks[J]. Multimedia tools and applications,2021,80:22907-22925.
[13] CHAI D,WANG L Y,YANG Q. Bike flow prediction with multi-graph convolutional networks[C]//ACM. Proceedings of the 26th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems. New York:ACM,2018:397-400.
[14] LIANG Y B,HUANG G,ZHAO Z. Bike sharing demand prediction based on knowledge sharing across modes: a graph-based deep learning approach[C]//IEEE. Proceedings of the IEEE: 2022 IEEE 25th International Conference on Intelligent Transportation Systems(ITSC). Piscataway:IEEE,2022:857-862.
[15] CHO J H,HAM S W,KIM D K. Enhancing the accuracy of peak hourly demand in bike-sharing systems using a graph convolutional network with public transit usage data[J]. Transportation research record: journal of the transportation research board,2021,2675(10):554-565.

作者简介:

胡智维(1998-),男,硕士生。研究领域:车辆路径优化,交通流预测。
张建同(1966-),女,博士,教授。研究领域:应用统计学,车辆路径优化,运筹与决策。