

城市轨道交通车站客流预测模型与算法研究

薛寄霖 王慧 王素蒙 何晔 于佳慧

辽宁工业大学汽车与交通工程学院, 辽宁 锦州 121001

[摘要]近年来, 中国经济水平快速提升, 交通行业对交通的需求大幅增加, 给城市交通带来较大压力, 为缓解城市交通拥堵, 给城市居民带来更快、更优质的出行服务。引用 GRU 算法构建门控循环单元模型进行客流预测, 最后以杭州地铁某一站点客流数据为例进行验证, 为地铁公司提供预测精度较高的短时客流预测方案。

[关键词]轨道交通; 门控循环单元模型; GRU 算法

DOI: 10.33142/sca.v6i6.9373

中图分类号: U291.69

文献标识码: A

Research on Passenger Flow Prediction Model and Algorithm of Urban Rail Transit Station

XUE Qilin, WANG Hui, WANG Sumeng, HE Ye, YU Jiahui

School of Automobile and Traffic Engineering, Liaoning University of Technology, Jinzhou, Liaoning, 121001, China

Abstract: In recent years, Chinese economic level has rapidly improved, and the demand for transportation in the transportation industry has significantly increased, bringing greater pressure to urban transportation. In order to alleviate urban traffic congestion and provide faster and better travel services for urban residents. The GRU algorithm is used to build a gated cycle unit model for passenger flow prediction. Finally, the passenger flow data of a station of Hangzhou Metro is taken as an example to verify, providing a short-term passenger flow prediction scheme with high prediction accuracy for the metro company.

Keywords: rail transit; gated cyclic unit model; GRU algorithm

引言

近年我国经济水平迅速发展, 机动化水平迅速提高, 机动车保有量随之倍增, 导致道路资源缺口日益增大, 由此产生的污染、交通拥堵、资源匮乏、道路安全等问题严重影响了城市效率和经济发展, 每年因城市拥堵给国家造成巨大损失。

城市轨道交通凭借其乘客运载量大, 运行时环保无污染等特点逐渐成为各大城市乘客出行的首要选择, 但是因为其站点内部空间环境与其他出行方式相比较为狭窄, 所以一旦出现较大客流量时便会使站点内部变得拥挤, 轻则影响乘客的出行效率, 重则威胁到整个城市的交通网络系统, 带来损失和安全隐患。所以对城市轨道交通短时客流的精准预测一直以来都是城市轨道交通研究的重点之一。

对城市轨道交通站点的精准短时客流量预测, 从实际效果、社会效益以及乘客出行三方面都具备重要意义^[1]。短时客流预测能够有效改善城市轨道交通站点的拥挤现象, 解决能源短缺问题, 减少国家的财产损失; 做好短时客流预测, 能够使城市的运作效用有所提升, 并且能够改善环境, 减少由交通问题所形成的环境污染; 更准确的短时客流预测可以满足乘客的出行要求, 使乘客的出行效用以及出行满意程度得到大大提高^[2]。从现实生活的应用方面, 城市轨道交通站点的精准短时客流量预测结果也具有重要意义。可以成为城市智慧交通系统的数据保障, 帮助乘客选择正确的交通出行工具以及路线, 尽可能避免发生交通拥堵问题; 可以作为城市交通有关部门为地铁站提供客流预警的依据, 帮助乘客提

高出行效率; 可以做出提前准备以应对接下来时间段内的客流变化, 当预测结果显示站点客流量大于站点的容纳水平时, 应该马上采取安保措施, 维护乘客的出行秩序, 并且提前进行客流的限流以及分流, 尽快降低站内的客流量^[3]。

本课题首先分析了中国地铁的发展现状以及预测地铁短期客流的必要性和重要性, 解释了城市车站进出客流短期预测的原理, 说明了本文的数据来源, 在此基础上对数据进行整理和清洗, 检查数据中的异常值, 同时分析了城市车站进出数据的空间和时间特征。针对具有时间序列特征的客流, 构建 GRU 模型进行客流预测。利用杭州地铁某一车站进行实例分析研究。

1 GRU 数据与处理

1.1 GRU 系统

GRU 系统 GRU 是 LSTM 的一个变种, 它还被提出来解决反向传播中的长记忆和梯度等问题^[4]。GRU 和 LSTM 在很多情况下实际表现上相差无几, 但是 GRU 计算更简单, 更易于实现。下面是整体的结构图:

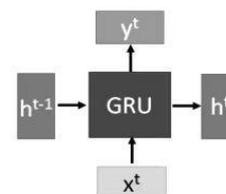


图1 整体结构图

下图为 GRU 的详细内部结构:

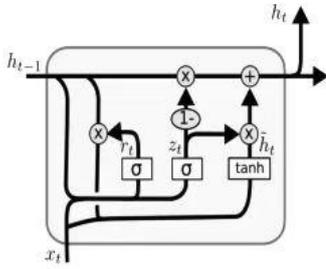


图2 GRU 详细内部结构

其中,

$$Z_t = \sigma(W_z \cdot [h_{t-1}, X_t]) \quad (1)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, X_t]) \quad (2)$$

$$h_t = \tanh(W \cdot [r_t h_{t-1}, X_t]) \quad (3)$$

$$h_t = (1 - Z_t) * h_{t-1} + Z_t * h_t \quad (4)$$

GRU 只有两个门。即一个复位门 (reset door) 和一个更新门 (updating door)。GRU 将 LSTM 中的输入门和遗忘门合二为一, 称为更新门 (update door), 上图中的 Z_t , 控制可以继续存储在内存中的数据量, 直到当前时刻。或者说决定有多少前一时间步的信息和当前时间步的信息要被继续传递到未来; GRU 的另一扇门称为复位门 (reset door), 上图中的 r_t , 控制要遗忘多少过去的信息。直观地说, 复位门决定了新的输入信息如何与以前的记忆相结合, 而更新门决定了以前的记忆有多少被储存在当前的时间步骤中。如果我们将复位门设置为 1, 更新门设置为 0, 我们又会得到标准的 RNN 模型。使用门机制来学习长期依赖关系的基本思想与 LSTM 相同, 但有一些重要的区别:

-GRU 有两个门 (一个复位门和一个更新门), 而 LSTM 有三个门 (一个输入门、一个遗忘门和一个输出门)。

-GRU 不控制或维护内部存储器, 也没有 LSTM 的输出门。

-LSTM 的输入门和遗忘门与 GRU 的更新门相对应, 复位门则直接对以前的嵌入状态进行操作。

-输出计算不使用二阶非线性。

1.2 GRU 数据

论文所采用的原始客流数据是杭州地铁一卡通的刷卡数据, 时间范围是 2019 年 1 月 1 日至 2019 年 1 月 26 日龙翔桥站的进站客流数据。地铁龙翔桥站地处杭州繁华的市中心, 北面毗邻武林商业圈, 南面紧邻吴山商圈, 周围交通便利, 商业繁华, 客流量大, 汇集了住宿、餐饮、休闲、娱乐等众多商家。这个站点距离西湖风景名胜古迹区步行仅需 5 分钟, 是前往西湖最近的站点。客流量相对比较密集, 方便研究。原始数据保存在 CSV 格式的文件中, 共计 26 个 CSV 文件。数据包含 7 个字段。每隔 5 分钟一次, 一天共包含 288 个时间段, 每条数据记录包含的信息有: 开始时间、输入流量、输出流量和结束时间。

2 基于 GRU 模型的城市轨道交通站点短时刻客流预测

门控循环单元 (Doord circulation unit, GRU) 是

LSTM 的一种变体, 在 LSTM 的众多变体中 GRU 几乎是最为优秀的一种, 它不仅对 LSTM 做了很多结构上的优化还保留着和 LSTM 相同的效果。

门控循环单元与传统的递归神经网络的主要区别是, 后者支持隐蔽状态调节。这意味着该模型有一个特殊的机制来决定什么时候应该更新隐藏状态, 什么时候应该重置^[5]。输入是由当前时间步长的输入和前一个时间步长的隐藏状态给出的。两个门的输出由两个使用西格玛激活函数的完全耦合层给出。

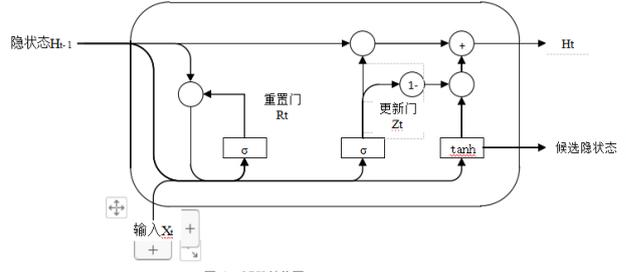


图1 GRU 结构图

图3 GRU 结构图

其主要的优化以及前向解析如下:

①取消输出门, 引入复位门 (Reset Door) r_t , 复位门决定了前一时刻的信息有多少需要被遗忘, 将 LSTM 的遗忘门和输入门合并成了更新门 (Updating Door) z_t , 保留了 LSTM 两个门对于上一时刻的记忆有多少保留到当前时刻的功能, 消除了其冗余缺陷。

对于一个特定的时间步骤 t , 假设输入的是小批量 $X_t \in R^{n \times d}$ (样本数量: n ; 输入数量: d), 前一个时间步骤的隐藏状态是 $H_{(t-1)} \in R^{d \times h}$ (隐藏单元个数: h), 那么, 复位门 $R_t \in R^{n \times h}$ 和更新门 $Z_t \in R^{n \times h}$ 的计算如下所示:

$$R_t = \sigma (W_{xr} X_t + H_{(t-1)} W_{hr} + b_{(hr)}) \quad (5)$$

$$Z_t = \sigma (X_t W_{xz} + H_{(t-1)} W_{hz} + b_z) \quad (6)$$

当中, $W_{xr}, W_{xz} \in R^{d \times h}$ 和 $W_{hr}, W_{hz} \in R^{d \times h}$ 是权重参数, $b_r, b_z \in R^{1 \times h}$ 是 \odot 偏差参数。接下来, 将复位门 R_t 的常规隐状态更新, 得到在时间步骤 t 的候选隐状态 (candidate hidden state) $H_t \in R^{n \times h}$ 。

②一个单元的状态和输出被合并为一个单一的状态 h , 同 LSTM 类似, 先通过复位门 r_t 的遗忘功能计算出候选状态 h_t 再通过更新门 Z_t 保留需要信息后进行输出。

$$H_t = \tanh (X_t W_{xh} + (R_t \odot H_{(t-1)}) W_{hh} + b_r) \quad (7)$$

其中, $W_{xh} \in R^{d \times h}$ 和 $W_{hh} \in R^{h \times h}$ 是权重参数, $b_h \in R^{1 \times h}$ 是偏差项, 符号 \odot 是 Hadamard 积 (按元素乘积) 运算符。在这里, \tanh 非线性激活函数用于确保候选潜伏状态的值落在 $(-1, 1)$ 范围内。

更新门 Z_t 只需要元素 $H_{(t-1)}$ 和 H_t 的凸组合来实现这一目标。这就导致了门的循环单元的最终更新公式:

$$H_t = Z_t \odot H_{(t-1)} + (1 - Z_t) \odot H_t \quad (8)$$

只要更新门 Z_t 接近 1, 模型就会倾向于只保持旧的

状态。此时，前一时刻的信息基本上被忽略了，实际上跳过了依赖链中的时间步骤 t 。相反，当 Z_t 接近 0 时，新的隐藏状态 H_t 会收敛到隐藏的候选状态 H_t 。

2.1 GRU 模型构建

选取杭州市地铁为调研对象，设计城市轨道短时预测模型，并利用杭州地铁一周以 5:00-24:00 的客流量数据进行预测实验。使用 Matlab 软件进行数据的处理以及模型的仿真，预测三日客流量并与实际客流量对比，由 Matlab 运行结果得出该模型基本与实际情况相对比^[6]。

3 实例分析

3.1 数据预处理

案例以杭州轨道交通中 1 号线 2019 年 1 月 1 日至 2019 年 1 月 26 日龙翔桥站的进站客流数据作为研究对象，数据会对模型产生影响，对输入序列应用多层门控递归单元 (GRU) RNN。对于输入序列中的每个元素，每一层计算以下函数：

$$r_t = \sigma(W_{ir}x_t + b_{ir} + W_{hr}h_{(t-1)} + b_{hr}) \quad (9)$$

$$z_t = \sigma(W_{iz}x_t + b_{iz} + W_{hz}h_{(t-1)} + b_{hz}) \quad (10)$$

$$n_t = \tanh(W_{in}x_t + b_{in}) + r_t * (W_{hn}h_{(t-1)} + b_{hn}) \quad (11)$$

$$h_t = (1 - z_t) * n_t + z_t * h_{(t-1)} \quad (12)$$

其中 t 是时间 t 的隐藏状态， x_t 是时间 t 的输入， $h_{(t-1)}$ 是时间 $t-1$ 的隐藏状态或时间 0 的初始隐藏状态， r_t , z_t , n_t 分别是复位、更新和新门。 σ 是 S 形函数， $*$ 是 Hadamard 乘积。在多层 GRU 中， l -th 层 ($l \geq 2$) 的输入 x 是前一层的隐藏状态 h_{l-1} 乘以矩阵 8_{t-1} ，其中每个 8_{t-1} 是一个伯努利随机变量，其概率为 0。

3.2 GRU 预测模型

在本文中，GRU 预测模型是用 MATLAB 软件编程的。首先，确定训练集函数和测试集函数。选取杭州市地铁为调研对象，设计城市轨道短时预测模型，并利用杭州地铁一周以 5:00-24:00 的客流量数据进行预测实验。使用 Matlab 软件进行数据的处理以及模型的仿真，预测三日客流量并与实际客流量对比，由 Matlab 运行结果得出该模型基本与实际情况相对比^[7]。

以五分钟为单位进行分组预测

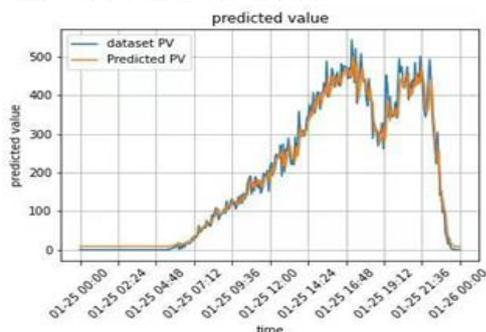


图 4 GRU 模型 5 分钟预测结果

以十分钟为单位进行分组预测

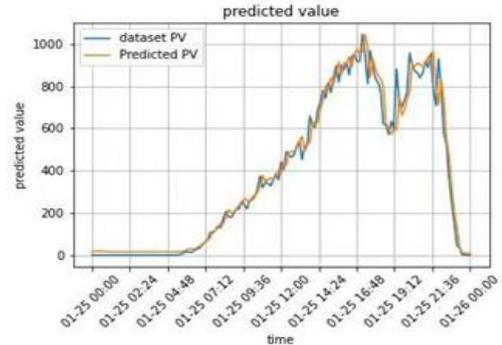


图 5 GRU 模型 10 分钟预测结果

3.3 模型误差分析

本文采用平均绝对值 (MAE)、平均绝对百分比 (MPAE)、均方根误差 (RMSE) 以及决定系数 R^2 四种评估本文件中提出的客运预测的准确性的评价标准。前三者作为最终预测结果的估计值，而决策系数 R^2 则作为神经网络参数调整的一个指标。四种误差分析的具体公式如下所示。

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{x}_i - x_i| \quad (13)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^n \left| \frac{\hat{x}_i - x_i}{x_i} \right| \times 100\% \quad (14)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{x}_i - x_i)^2} \quad (15)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{x}_i - x_i)^2}{\sum_{i=1}^n (\bar{x}_i - x_i)^2} \quad (16)$$

其中， i 是数据集中数据所在的位置数。 x_i 为原始数据集中的真值， \hat{x}_i 为模型估算后的预测值， \bar{x}_i 为真实平均数， n 为原始数据集中的数据数量。

表 1 预测模型误差分析

预测模型	RMSE	MAE	MAPE	R 方
5 分钟 GRU	30.777	21.243	0.210	0.970
10 分钟 GRU	65.223	40.420	0.370	0.968

计算的 RMSE、MAPE 和 MAE 这三个指标的数值越低，模型的可预测性就越好。可以看出，GRU 预测模型中这三个指标的数值都很小，而且 R 方数值越大，所以预测性越好。

3.4 结果分析

本文搭建了一个 GRU 预测模型，用于预测城市铁路车站的短期客流，从十分钟预测结果可以得到杭州地铁客流量 0 时到凌晨 5 点钟左右客流量几乎为 0，从凌晨 5 点到 13 点钟客流量基本呈直线增长，15 点左右客流量达到顶峰，15 到 19 点有下降趋势，19 点到 21 点呈上升趋势，19 点到凌晨客流量逐渐降低为 0。由图知，15 点和 21 点左右为高峰期，建议人们避开这个时间段出行。

4 结语

本文采用 GRU 模型对杭州轨道交通龙翔桥站进行了

短时客流预测,城市轨道交通是非常复杂的非线性问题,使用GRU预测模型更加简单,容易实现,而且预测性更好。本文所提出的一些方法可以解决一些复杂的非线性预测问题。这将成为城市轨道交通客流预测研究的基础。预测的结果可为轨道交通部门日常的管理提供便利,有利于改善轨道列车的调度、站点人员的安排以及峰值时段的客流拥挤,具有实用价值。

[参考文献]

- [1]龙小强,李捷,陈彦如.基于深度学习的城市轨道交通短时客流量预测[J].控制与决策,2019,34(8):1589-1600.
- [2]梁强升,许心越,刘利强.面向数据驱动的城市轨道交通短时客流预测模型[J].中国铁道科学,2020,41(4):153-162.

[3]张文娟,杨皓哲,张彬,等.考虑多时间尺度特征的城市轨道交通短时客流量预测模型[J].交通运输系统工程与信息,2022(6):212-223.

[4]李得伟,颜艺星,曾险峰.城市轨道交通进站客流量短时组合预测模型[J].都市轨道交通,2017,30(1):6.

[5]刘美琪,焦朋朋,孙拓.城市轨道交通进站客流量短时预测模型研究[J].城市轨道交通研究,2015,18(11):6.

[6]包磊.城市轨道交通客流量实时预测模型[J].城市轨道交通研究,2017,20(5):4.

[7]赵建立,石敬诗,孙秋霞.基于混合深度学习的地铁站进出客流量短时预测[J].交通运输系统工程与信息,2020,20(5):7.

作者简介:薛寄霖(2002-),辽宁工业大学,学生。