

代丽, 诸梦娇, 向家文. 基于 BiGRU-Att 的高校食堂窗口人流量预测研究[J]. 智能计算机与应用, 2025, 15(7): 194-199.
DOI:10.20169/j.issn.2095-2163.250729

基于 BiGRU-Att 的高校食堂窗口人流量预测研究

代丽, 诸梦娇, 向家文

(浙江理工大学 经济管理学院, 杭州 310018)

摘要: 为优化食堂资源配置与服务管理, 本文提出了一种结合双向门控循环单元 (Bidirectional Gated Recurrent Unit, BiGRU) 和注意力机制 (Attention) 的组合模型, 用于预测食堂人流量。该模型通过 BiGRU 提取历史数据中的时间依赖关系, 再借助 Attention 机制对关键信息进行筛选, 挖掘深层次特征, 进一步降低多步预测误差。通过对某高校一卡通消费数据实验表明, BiGRU-Att 模型在预测高校食堂窗口人流量任务上表现出卓越的性能。相比单一的 BiGRU 和支持向量回归 (Support Vector Regression, SVR), 其预测结果的均方误差分别降低了 0.051 和 1.134, R^2 分别提高 0.017 和 0.374。研究证明, BiGRU-Att 模型充分融合了循环神经网络的序列建模能力和注意力机制的特征权重自适应学习能力, 更精确地捕捉人流量的动态演变规律, 有助于提高餐饮行业科学决策能力, 优化其服务管理流程。

关键词: 人流量预测; 双向门控循环单元; 注意力机制; 深度学习

中图分类号: TP183

文献标志码: A

文章编号: 2095-2163(2025)07-0194-06

Research on pedestrian flow prediction of university canteen window based on BiGRU-Att

DAI Li, ZHU Mengjiao, XIANG Jiawen

(School of Economics and Management, Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: In order to optimize cafeteria resource allocation and service management, this paper proposes a combined model combining Bidirectional Gated Recurrent Unit (BiGRU) and Attention mechanism to predict cafeteria pedestrian flow. The model uses BiGRU to extract the time dependence relationship into the historical data, and then uses the Attention mechanism to screen the key information, mine the deep features, and further reduce the multi-step prediction error. Experiments on the consumption data of a university card in Zhejiang Province show that the BiGRU-Att model shows excellent performance in predicting the pedestrian flow of university canteen Windows. Compared to the single BiGRU and Support Vector Regression (SVR), it reduces the mean square error by 0.051 and 1.134, respectively, and increases the R-squared value by 0.017 and 0.374. Studies show that the BiGRU-Att model fully integrates the sequence modeling ability of recurrent neural network and the feature weight adaptive learning ability of attention mechanism, which can more accurately capture the dynamic evolution law of pedestrian flow, and help to improve the scientific decision-making ability of the catering industry and optimize its service management process.

Key words: pedestrian flow prediction; bidirectional gated recurrent unit; attention mechanism; deep learning

0 引言

随着高等教育的发展和高校规模的扩大, 校园内的食堂数量逐渐增多, 为了更有效地管理食堂运营, 人流量的预测变得至关重要。准确的人流量预测可以帮助食堂管理部门提前做好原材料采购和生产准备, 从而避免因原材料短缺而影响食品供应。

同时, 人流量预测也可以帮助食堂管理部门合理安排工作人员, 优化营业布局和就餐区域, 以满足学生就餐需求。人流量预测问题并不仅仅局限于食堂区域, 其应用范围非常广泛。如, 城市交通管理、商场运营规划、旅游景区管理等领域。

人流量预测属于时间序列预测问题, 国内外学者们已经在该领域进行了广泛研究。传统的预测方

基金项目: 国家自然科学基金(32071909); 浙江省自然科学基金(LGN20E050006); 杭州市科技发展计划项目(2020ZDSJ0488)。

作者简介: 代丽(1977—), 女, 博士, 副教授, 主要研究方向: 机械机构分析优化与综合, 管理信息系统, 数据库技术。Email: 2463805386@qq.com; 诸梦娇(1999—), 女, 硕士研究生, 主要研究方向: 物流企业运营; 向家文(2000—), 男, 硕士研究生, 主要研究方向: 物流企业管理。

收稿日期: 2023-11-06

哈尔滨工业大学主办 ◆ 科技创见与应用

法通常可以分为两类:一是经典的统计学方法。如,文凯^[1]等学者对旅游城市做 5G 规划时,引入 SARIMA 算法来替代原有的趋势外推法进行容量预测。主要利用 SARIMA 模型呈现人流量随季节性变化的特点,使规划更有针对性。二是非线性预测模型,主要是基于机器学习的预测模型^[2-4]。如,林培群^[5]设计了基于手机信令数据的城市交通枢纽人流量 k 近邻预测算法,并以节假日与非节假日两种不同交通模式环境进行算法测试。以往研究已经显示了在各种现实世界应用中的有效性,但在复杂的非线性数据上预测性能并不理想。

随着深度学习的发展,已经提出了许多用于非线性数据预测的神经网络模型。以卷积神经网络 (Convolutional Neural Network, CNN)、循环神经网络 (Recurrent Neural Network, RNN) 和 Transformer 模型^[6]为代表的深度学习算法,在时间序列预测任务中取得了丰硕的成果^[7-8]。RNN 因其内部包含记忆机制,能够有效地捕捉时间序列数据中的时间相关性和序列依赖关系,因此在处理时间序列数据方面非常有用。然而,当输入序列很长,包含大量时间步长时,RNN 容易出现梯度消失或梯度爆炸的问题,使其在实际应用中难以准确捕捉时间序列中较远时间步长之间的依赖性^[9]。长短期记忆网络 ((Long Short-Term Memory, LSTM) 和门控循环单元 (Gated Recurrent Unit, GRU) 解决了这个问题,并在许多领域得到了广泛应用。然而,随着输入序列长度的不断增加,单个 LSTM 和 GRU 模型的性能将急剧下降^[10-11]。对于时间序列预测,为了更好地获得其变化规律信息,需要输入更长的序列。注意力机制可以独立选择输入信息,与循环神经网络相结合,可以很好地解决输入序列长的问题^[12-13]。有学者已经提出了许多基于循环神经网络变体和注意力机制的网络结构。例如,刘培培^[14]等提出一种基于空洞卷积的密集连接网络人流量预测模型,通过 SE-LSTM 模块帮助网络学习更重要的特征,并学习数据中的周期性和动态时间性,并在公开数据集上验证了提出模型的有效性。

综上所述,将深度学习技术应用于校园区域人流量数据分析,是值得关注的研究方向,可望为人流量管理和规划提供更精确高效的解决方案。本文提出的 BiGRU-Att 模型集成了 BiGRU 模型良好的时序模式捕捉能力和注意力机制自适应的关键特征提取能力^[15],这种集成使模型可以有效分析时间序列数据的内在规律,从而获得较优的预测效果。

值得一提的是,本研究所构建的模型不仅可以应用于校园内商铺的人流量预测,其方法与技术也具有较强的迁移学习价值,该模型框架可以推广到其他时序预测任务中,为更多领域提供借鉴参考。

1 算法原理

在复杂时间序列预测任务中,融合不同算法的优势以达到协同效果十分关键。本文结合双向门控循环神经网络和注意力机制两种算法,充分发挥各自的优势,建立了一个对时间序列建模更加高效和准确的框架。

1.1 双向门控循环神经网络

GRU 作为一种循环神经网络,能够克服长期依赖问题,避免梯度消失或梯度爆炸的困扰^[16],在处理时序数据方面表现卓越。不同于传统的 LSTM,GRU 将遗忘门和输入门合并为一个称为更新门的单一门控机制,并且在细胞状态和隐藏状态之间进行了更紧密的混合^[17]。由于这种简化的结构,GRU 具有更少的训练参数,有助于提高训练速度,并在一定程度上提高了模型的性能。GRU 细胞单元内部结构如图 1 所示。




图 1 GRU 细胞单元结构
Fig. 1 Structure of GRU cell unit

图 1 中, x_t 表示 t 时刻的输入向量, h_t 表示隐藏状态,其中包含了在 t 时刻之前的所有相关信息。 z_t 表示更新门,主要作用是调控信息流向下一个时刻的状态,需要经过激活函数 σ 处理; r_t 表示重置门,用于决定信息是否需要被保留或被遗忘;这两个门控机制共同塑造了隐藏状态的输出,从而影响了模型的信息传递与状态更新。GRU 的这些设计元素协同工作,使其成为一种有效的循环神经网络结构。在 GRU 细胞单元中,主要公式如下:

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \tag{1}$$

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \tag{2}$$

$$\tilde{h} = \tanh(W_h \cdot [r_t \times h_{t-1}, x_t]) \tag{3}$$

$$h = (1 - z_t) \times h_{t-1} + z_t \times \widetilde{h}_t \quad (4)$$

其中, W_r, W_z, W_h 均为激活函数输入权重, σ 表示 Sigmoid 函数。

GRU 传输方式是单向从前往后传输,常应用于模型输出仅与历史信息有关的场景,而食堂窗口人流量时间序列的输出不只受到历史信息的影响,还与未来时刻的信息有很大关联。针对该问题,本文采用双向门控循环单元,整合了双向信息流动,将正向和反向信息结合在一起,可以充分挖掘相邻日期间人流量的双向时序耦合特征,从而完整地学习到人流量的整体特征^[18]。前向 GRU 和后行 GRU 分别捕捉目标的前向信息和后向信息,输出拼接得到标签向量列表 $h_s \in R^{n \times 2d}$, 其中 d 是隐藏状态的维度。

1.2 注意力机制

注意力机制是计算模型中的一项重要技术,其模拟人类的关注机制,使得模型能够有选择性地聚焦于输入数据中的关键信息,从而提高任务处理的效率和准确性,已成功应用于多个领域^[19]。通过对 BiGRU 网络输入的特征向量进行加权求和,再由 Softmax 函数计算得到注意力分数 α , 将输入特征与注意力分数相乘生成权重矩阵。注意力机制原理如图 2 所示。




图 2 注意力机制模型结构

Fig. 2 Structure of the attention mechanism model

注意力机制的工作过程包括 3 个关键步骤:

- (1) 通过将查询 (Query) 与各个键 (Key) 进行相似性计算,得到权重系数;
- (2) 使用 Softmax 函数对上述权重系数进行标准化;
- (3) 将权重与相应的值 (Value) 进行加权求和。这一过程允许模型动态地关注输入中的相关信息。内部主要计算公式如下:

$$e_i = \text{utanh}(w h_i + b_i) \quad (5)$$

$$\alpha_i = \frac{\exp(e_i)}{\sum_{j=0}^i e_j} \quad (6)$$

$$c_i = \sum_{i=0}^t \alpha_i \cdot h_i \quad (7)$$

其中, u 与 w 为权重系数; b 为偏置系数; h_i 是通过 BiGRU 网络输出得到的隐藏层向量; α_i 表示注意力机制对 BiGRU 隐藏层输出的注意力权重值; c_i 是加入注意力机制后的输出向量。

2 BIGRU-Attention 预测模型构建

本文提出的高校食堂窗口人流量预测模型结构如图 3 所示,输入为前 n 个时刻的人流量数据,输出为对应第 $n + 1$ 时刻的人流量数据的预测结果。




图 3 BiGRU-Attention 的高校食堂窗口人流量预测模型

Fig. 3 BiGRU - Attention model for predicting people flow in college canteen windows

预测模型由 4 层架构组成:

第一层为输入层,该层将预处理好的窗口人流量数据输入到模型中。

第二层为 GRU 网络层,其中包含了两个双向的 GRU 层,每个层都在不同的级别上处理输入数据。在每个 BiGRU 层的输出之后,都添加了一个 Dropout 层。Dropout 层是一种正则化技术,可以随机地将一些神经元的输出置为 0^[20],有助于防止神经元之间的过度依赖,以减少过拟合的风险并增加模型的鲁棒性。这两层组合使模型能够从输入数据中逐步提取特征,并为后续的注意力和预测层提供

丰富的信息。

第三层为注意力机制层。在前面的 BiGRU 层之后,通过一个注意力层来集中关注输入序列中的特定部分。该层计算每个时间步的权重,用以指导模型对输入的关注程度。这种机制允许模型更加集中地关注输入序列中与任务相关的部分,从而提高了模型的性能。

第四层为输出层。经过前面的处理之后,注意力机制层的输出被送入全连接层,将学到的特征与任务的目标值建立关联。全连接层将特征表示映射到最终的 $n + 1$ 时刻食堂人流量预测结果。

通过 4 个部分的组合,使得模型能够在处理序列数据时自动地学习重要的特征和关联关系,从而进行准确的预测。不同部分之间的层级结构和信息传递,使模型能够从数据中获取丰富的信息,实现更好的性能。

3 实验结果分析

3.1 数据集

本文所用数据集来源于浙江某高校一卡通消费数据,该数据集中包含高校学生一卡通消费数据中的记录号、学工号、卡上消费操作计数、终端上的操作时间、终端编号、本终端记录流水号等字段。去重后累计包括 943 799 条消费记录数据,涉及消费终端数量 3 460 台,共计包括 14 种消费类型。消费终端和消费类型一一对应,时间跨度为 2020 年 11 月到 2021 年 3 月。本实验随机抽取一台类型为餐费支出的消费终端,统计该消费终端上的时间间隔为 60 min 的刷卡人数,做为本实验数据集。其中,选取数据集的前 80% 作为训练集,剩余 20% 作为测试集。

3.2 模型参数设计

实验计算机配置基于 NVIDIA RTX 2080 Ti 显卡、12 核 Intel 处理器和 CUDA 10.1;Python 3.8 作为实验所用编程工具,PyTorch 1.6.0 作为深度学习框架。

BiGRU-Att 预测模型时间步长为 30,即将 30 个历史人流量数据作为输入,预测出后 1 个步长人流量数据。该模型参数根据所得结果不断调整,具体参数设置:GRU 隐藏层 hidden_size 为 128,设置 2 层 dropout 函数均为 0.3,batch_size 为 32,epoch 为 500,使用均方误差 (MSE) 作为目标函数,优化算法采用自适应矩估计 (Adaptive Moment Estimation, Adam) 算法。

3.3 评价指标

本文选择均方误差、均方根误差 (RMSE)、平均绝对百分比误差 (MAPE) 和决定系数 (R^2) 4 项指标来评估模型的预测性能。计算公式如下:

$$MSE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \tag{8}$$

$$RMSE(y, \hat{y}) = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \tag{9}$$

$$MAPE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \tag{10}$$

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \tag{11}$$

其中, $\hat{y}_i$ 为预测值; y_i 为真实值; $\bar{y}$ 为真实值的平均值; n 为总的样本个数。

3.4 结果分析

本文将所提出的 BiGRU-Att 组合预测模型同 BiLSTM、BiGRU、SVR 以及随机森林回归 (Random Forest Regression, RFR) 等常用的流量预测模型预测结果进行比对,以此验证本文模型的优越性。选用各个模型中测试集的最佳拟合结果来评价其预测准确性,各个模型的测试集实验结果见表 1。

表 1 7685 号食堂窗口人流量预测结果对比
Table 1 7685 comparison of cafeteria window pedestrian flow forecast results

模型	MSE	RMSE	R^2	MAPE
BiGRU	0.065 6	0.256 2	0.978 3	0.715 1
BiLSTM	0.110 3	0.332 2	0.963 5	0.718 3
SVR	1.148 8	1.071 8	0.620 5	0.887 4
RFR	1.052 7	1.026 0	0.652 2	0.846 1
BiGRU-Att	0.014 8	0.121 5	0.995 1	0.681 0

在高校食堂窗口人流量预测任务中,BiGRU 和 BiLSTM 在大多数评估指标上表现较好,特别是 BiGRU 展现出更低的 MSE、RMSE、MAPE 以及更高的 R^2 。这可以归因于这两种深度学习模型能够更有效地捕捉时间序列数据中的双向依赖关系和长程依赖性。与之相对,传统机器学习方法(如:SVR 和 RFR),在流量预测中是较为常用的回归模型。但效果的好坏取决于数据的特点和问题的复杂性,在这个任务上的表现相对较差,这可能是因为其未能充分考虑复杂的时间相关性。相较单一的 BiGRU 模型,BiGRU-Att 模型表现出了更佳的预测性能。具

体来说,BiGRU-Att 模型的 MSE 结果为 0.014 8,较 BiGRU 的 0.006 5 降低了 77.4%;同时,BiGRU-Att 的 R^2 为 0.995 1,比 BiGRU 的 0.978 3 提高了 1.7 个百分点。 R^2 接近于 1 的优异结果,进一步突显了 BiGRU-Att 模型能够很好地解释实际观测值的变异情况。

综上,实验结果定量证明了 BiGRU-Att 模型的预测优势,其能够显著降低预测误差,同时大幅提升预测准确率,全面超越了基准模型,验证了注意力机制对优化食堂人流预测的效果。

图 4~8 展示了不同模型在测试集上的人流量预测结果。分析可知,SVR 和 RF 的预测结果表现出不稳定、波动大等负面特征。尽管单一的 BiLSTM 和 BiGRU 稍显优势,但仍有提升的空间存在。基于注意力机制的 BiGRU 的预测值与真实值更为接近,对未来趋势的预测更加准确,两条曲线几乎重合,预测值与真实值之间的误差最小,且回归拟合效果最佳。这直观地验证了 BiGRU-Att 模型的出色拟合能力和优越性。




图 4 RFR 预测拟合对比

Fig. 4 Comparison of RFR prediction fits




图 5 SVR 预测拟合对比

Fig. 5 Comparison of SVR prediction fits




图 6 BiLSTM 预测拟合对比

Fig. 6 Comparison of BiLSTM prediction fits




图 7 BiGRU 预测拟合对比

Fig. 7 Comparison of BiGRU prediction fits




图 8 BiGRU-Att 预测拟合对比

Fig. 8 Comparison of BiGRU-Att prediction fits

4 结束语

针对高校食堂窗口人流量预测问题,本文提出了 BiGRU-Att 的组合神经网络模型。通过真实案例,验证了引入注意力机制可进一步优化模型,实现自动学习人流量时间序列的关键特征;将注意力更集中在对预测贡献大的时序上,忽略无关时间步,使模型能够捕捉到人流量数据的整体趋势和周期性变化,且在具体时间点上能够较精确地预测人流量值,显示出较强泛化能力和预测性能,对实时监测与预测意义重大。未来研究可以考虑引入更多影响因素的数据(如:校园活动信息、天气数据等),以进一步提高波动点的预测准确性。

参考文献

[1] 文凯,陈浩,钱权智,等. 旅游城市 5G 容量预测及组网方法研究[J]. 计算机应用与软件,2022,39(6):121-126.
[2] LUO J, ZHANG Z, FU Y, et al. Time series prediction of COVID-19 transmission in America using LSTM and XGBoost algorithms[J]. Results in Physics, 2021, 27: 104462.
[3] 周思思,李勇,郭钊秀,等. 考虑时序特征提取与双重注意力融合的 TCN 超短期负荷预测[J]. 电力系统自动化,2023,47(18):193-205.
[4] 刘琳岚,冯振兴,舒坚. 基于时序图卷积的动态网络链路预测[J]. 计算机研究与发展,2024,61(2):518-528.
[5] 林培群,雷永巍,张孜,等. 面向手机信令数据的交通枢纽人流量短时预测算法[J]. 哈尔滨工业大学学报,2018,50(9):89-95.
[6] 陈嘉俊,刘波,林伟伟,等. 基于 Transformer 的时间序列预测方法综述[J/OL]. 计算机科学. 1-17[2025-04-13]. <http://kns.cnki.net/kcms/detail/50.1075.TP.20241030.0909.002.html>.
[7] 孟祥福,石皓源. 基于 Transformer 模型的时序数据预测方法综

述[J]. 计算机科学与探索,2025,19(1):45-64.

[8] 梁宏涛,刘硕,杜军威,等. 深度学习应用于时序预测研究综述[J]. 计算机科学与探索,2023,17(6):1285-1300.

[9] 张鑫阳,王可庆,贾新旺,等. 基于并行 TCN-SE-BiLSTM 模型的涡扇发动机剩余寿命预测[J]. 电子测量技术,2024,47(24):179-187.

[10] 宋江涛,崔双喜,樊小朝,等. 基于 SGMD-SE 与优化 TCN-BiLSTM/BiGRU 的超短期风功率预测[J]. 太阳能学报,2024,45(10):588-596.

[11] 迟玉伦,李希铭,朱文博,等. 基于 LSTM-GRU 神经网络的机床主轴回转误差分离降噪研究[J]. 计量学报,2024,45(11):1615-1625.

[12] 戚耀,王晨茜,吴啸宇,等. 地铁短时客流预测的 ATT-BiLSTM 模型[J]. 交通科技与经济,2025,27(1):89-96.

[13] 苗佳池,陈颖,生龙,等. 基于 RoBERTa-BiLSTM-SelfAttention-CRF 的中文地址解析方法[J]. 河北省科学院学报,2024,41(6):25-34.

[14] 刘培培,赵岭忠,翟仲毅,等. 基于空洞卷积的密集连接网络人流量预测模型[J]. 桂林电子科技大学学报,2021,41(5):375-381.

[15] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of Advances in Neural Information Processing Systems. 2017:5998-6008.

[16] 阴艳超,洪志敏,顾文娟,等. 融合多通道 CNN-BiGRU 与时间模式注意力机制的多工序工艺质量预测方法[J]. 计算机集成制造系统,2025,20(1):4-13.

[17] 杨世海,薛冰,李磊,等. 基于注意力机制的 CNN-BiGRU 超短期省间现货购电需求预测[J]. 电力系统及其自动化学报,2025,8(1):8-13. <https://doi.org/10.19635/j.cnki.csu-epsa.001547>.

[18] 杜秀丽,范志宇,吕亚娜,等. 基于双向长短期记忆循环神经网络的网络流量预测[J]. 计算机应用与软件,2022,39(2):144-149.

[19] 任欢,王旭光. 注意力机制综述[J]. 计算机应用,2021,41(S1):1-6.

[20] 徐海文,史家财,汪腾. 基于深度全连接神经网络的离港航班延误预测模型[J]. 计算机应用,2022,42(10):3283-3291.