

分类号 C8/356  
U D C

密级  
编号 10741



硕士学位论文  
(专业学位)

论文题目: 多视角图注意力门控单元网络:方法优化及  
停车位预测应用

研究生姓名: 杨克旭

指导教师姓名、职称: 黄恒君 教授

学科、专业名称: 统计学 应用统计硕士

研究方向: 大数据分析及应用

提交日期: 2023年5月30日

# 独创性声明

本人声明所呈交的论文是我个人在导师指导下进行的研究工作及取得的研究成果。尽我所知，除了文中特别加以标注和致谢的地方外，论文中不包含其他人已经发表或撰写过的研究成果。与我一同工作的同志对本研究所做的任何贡献均已在论文中作了明确的说明并表示了谢意。

学位论文作者签名: 杨克旭 签字日期: 2023年5月30日

导师签名: 黄红 签字日期: 2023年5月30日

导师(校外)签名: 张亚东 签字日期: 2023年5月30日

## 关于论文使用授权的说明

本人完全了解学校关于保留、使用学位论文的各项规定，同意（选择“同意”/“不同意”）以下事项：

- 1.学校有权保留本论文的复印件和磁盘，允许论文被查阅和借阅，可以采用影印、缩印或扫描等复制手段保存、汇编学位论文；
- 2.学校有权将本人的学位论文提交至清华大学“中国学术期刊（光盘版）电子杂志社”用于出版和编入CNKI《中国知识资源总库》或其他同类数据库，传播本学位论文的全部或部分内容。

学位论文作者签名: 杨克旭 签字日期: 2023年5月30日

导师签名: 黄红 签字日期: 2023年5月30日

导师(校外)签名: 张亚东 签字日期: 2023年5月30日

# **Multi-perspective attention gated unit network: method optimization and parking space prediction application**

**Candidate: Yang Ke Xu**

**Supervisor: Huang Heng Jun**

## 摘要

随着社会经济的不断发展,汽车走进了千家万户,汽车保有量得到了迅速的提升。汽车的普及表明社会经济的变革丰富了人们的生活,但由此带来的社会性问题也不容小觑。汽车保有量的迅速增长使得我国各大城市中汽车与停车位的配比严重失衡,同时,由于车位信息在供给端和需求端的不对称,很多停车场的空置率高达50%以上,这两种看似矛盾的现象造成了各大城市中广泛存在的交通拥挤问题,停车难题正困扰着每一个司机,给道路资源管理带来了巨大的压力。

车位数量预测信息对于提高车位利用率、缓解交通拥堵具有重要意义,它可以平衡停车场车位占用数量的分布。然而目前的车位预测算法大多仅关注数据的时间相关性,对于空间相关性的研究相对较少。为了深入挖掘空间信息在车位数量预测中的重要作用,进一步提高车位预测算法的精度,本文提出了一种多视角图注意力门控单元网络(Multi-View Graph Attention Gating Unit Network, MGA-GRU)模型,它对门控循环单元神经网络(Gate Recurrent Unit, GRU)进行了改造,在原先只能用于提取时间信息的两个门控单元的基础上增加了两个图注意力卷积门控单元(GA),用于提取空间信息。图注意力卷积门控单元使得MGA-GRU模型能够同步的提取与处理时间特征和空间特征,减少了时空信息之间的相互干扰,其中所采用的注意力机制可以根据不同节点序列间的注意力系数来对邻居节点的信息进行聚合,更加科学合理。此外, MGA-GRU模型在构造关系图时,融合了多种空间信息构造多视角拓扑图,使空间特征更加全面与准确,进一步的提高了模型的预测效果。

为了验证模型效果,我们在现实数据集兰州停车场数据集上进行了实验,证明了MGA-GRU模型不论是在短期还是长期车位预测效果上都优于大多数的现有模型,预测结果在多个指标上达到了最优。最后,本文还进行了实用性探索,为了能够将模型进行推广并获得更广泛的使用,本文以MGA-GRU模型为基础开发了车位预测应用,挖掘模型的实用价值。

**关键字:** 车位预测 图神经网络 注意力机制 时空融合

## Abstract

With the continuous development of social economy, automobiles have entered thousands of households, and the number of automobiles has been rapidly increased. The popularity of automobiles shows that social and economic changes have enriched people's lives, but the resulting social problems should not be underestimated. The rapid growth of car ownership has caused a serious imbalance in the ratio of cars and parking spaces in major cities in my country. At the same time, due to the asymmetry of parking space information on the supply side and the demand side, the vacancy rate of many parking lots is as high as 50%. Seemingly contradictory phenomena have caused widespread traffic congestion problems in major cities, and parking problems are plaguing every driver, bringing enormous pressure to road resource management.

The prediction information of the number of parking spaces is of great significance for improving the utilization rate of parking spaces and alleviating traffic congestion. It can balance the distribution of the number of parking spaces occupied by the parking lot. However, most of the current parking space prediction algorithms only focus on the temporal correlation of data, and there are relatively few studies on spatial correlation. In order to deeply explore the important role of spatial information in the prediction of the number

of parking spaces and further improve the accuracy of the parking space prediction algorithm, this paper proposes a Multi-View Graph Attention Gating Unit Network (MGA-GRU) Model, which transforms the Gate Recurrent Unit (GRU) neural network, and adds a graph attention convolution gate unit (GA) for extracting spatial information. The graph attention convolution gating unit enables the MGA-GRU model to simultaneously extract and process temporal features and spatial features, reducing the mutual interference between spatio-temporal information. The attention mechanism adopted can be based on the attention between different node sequences. It is more scientific and reasonable to aggregate the information of neighbor nodes by using the force coefficient. In addition, when the MGA-GRU model constructs the relationship graph, it integrates a variety of spatial information to construct a multi-view topological graph, which makes the spatial features more comprehensive and accurate, and further improves the prediction effect of the model.

In order to verify the effect of the model, we conducted experiments on the real data set Lanzhou parking lot data set, which proved that the MGA-GRU model is superior to most of the existing models in both short-term and long-term parking space prediction, and the prediction results are in many reached the optimum in terms of indicators. Finally, this paper also conducts a practical explorati

on. In order to promote the model and obtain wider use, this paper develops a parking space prediction application based on the MGA-GRU model to tap the practical value of the model.

**Keywords:** Parking space prediction; Graph neural network; Attention mechanism; Spatiotemporal Fusion

# 目 录

<b>1 绪 论</b> .....	<b>1</b>
1.1 研究背景及其意义 .....	1
1.2 国内外研究现状 .....	2
1.3 主要研究内容及创新点 .....	6
1.3.1 模型构建.....	6
1.3.2 现实应用.....	6
1.4 研究结构安排 .....	7
<b>2 相关原理与技术</b> .....	<b>9</b>
2.1 拓扑图.....	9
2.2 门控循环单元（GRU） .....	11
2.3 图神经网络.....	13
2.3.1 图卷积神经网络（GCN） .....	13
2.3.2 图注意力神经网络（GAT） .....	15
2.4 本章小结.....	17
<b>3 MGA-GRU 预测模型构建</b> .....	<b>18</b>
3.1 MGA-GRU 网络结构.....	18
3.2 GA-GRU 单元.....	19
3.3 多视角图构建 .....	21
3.3.1 地理距离.....	22
3.3.2 可达性.....	22
3.3.3 兴趣点.....	23
3.3.4 三种空间信息的组合.....	24
3.4 MGA-GRU 模型伪代码.....	25
3.5 本章小结.....	26
<b>4 兰州市停车场车位预测实证分析</b> .....	<b>27</b>
4.1 兰州市停车场建设概况 .....	27

4.2 数据集.....	29
4.3 基于兰州市停车场的多视角拓扑图构建 .....	30
4.4 评价指标.....	33
4.5 参数设置.....	33
4.6 实验结果与分析 .....	35
4.6.1 多模型结果.....	35
4.6.2 长期预测能力比较.....	38
4.6.3 消融实验.....	39
4.7 MGA-GRU 预测模型的原型系统开发.....	41
4.7.1 原型系统介绍.....	41
4.7.2 系统架构.....	41
4.7.3 原型系统整体界面展示.....	42
4.8 本章小结.....	43
<b>5 总结与展望 .....</b>	<b>45</b>
5.1 研究总结.....	45
5.2 未来展望.....	46
<b>参考文献 .....</b>	<b>47</b>
<b>致谢 .....</b>	<b>53</b>

# 1 绪 论

## 1.1 研究背景及其意义

随着社会经济的不断发展,汽车走进了千家万户,汽车保有量得到了迅速的提升。根据国家统计局公布数据,2021 年末全国民用汽车保有量达到了 30151 万辆,比 2020 年末增加了 2064 万辆。汽车的普及表明社会经济的变革丰富了人们的生活,但汽车保有量的增长所带来的社会性问题也不容小觑。据统计(李盼道等,2019),在我国的一线城市中,汽车与停车位的比例约为 1:0.8,二线城市则约为 1:0.5,汽车与停车位之间的配比严重失衡。在本文所研究的兰州市,这一情况则更为严重,机动车与停车位的比例甚至仅达到了 1:0.11。而依据国际标准,这一比例保持在 1:1.1~1:1.3 较为合适。因此,保守的估计,我国的停车位缺口超过 5000 万个,停车位缺乏的情况较为严重,停车难题正困扰着每一个司机,在各大城市中广泛的造成了交通拥挤问题,给道路资源管理带来了巨大的压力。

虽然车位数量不足是造成停车难问题的一个重要原因,但车位利用率低下也是一个不可忽视的因素。根据最新研究(王宏国,2021),由于管理落后和车位信息的不透明,使得大多数停车场的车位不能得到充分利用,在中国,91%的城市车位空置率达到了 50%以上,即使车位空置率最低的深圳也达到了 45%。本就不足的车位数量加上较高的车位空置率,使得城市拥堵问题雪上加霜。在各大城市用地紧张背景下,增加停车位的供给将不是一个可持续的方案,那么要解决停车难题,提高车位利用率将是一个新的方向。

提高车位利用率不仅要提高停车场的管理能力,推进停车场的智能化建设,更重要的是要打通停车场与用户之间的信息交流渠道,为用户提供更具参考性的建议,帮助用户进行决策(魏成等,2022)。例如,在大型商场、公共场所以及各种娱乐中心等人员流动密集的地方,就需要大量的停车位来配合人员的密集流动,但在这些地方停车通常依靠驾驶者自行决定,驾驶者大多选择集中在有限几个容易寻找的停车场停车,导致经常出现排队等位的情况,而在其他区域可能存

在拥有空位的停车场。面对这种情况，司机往往需要花费很长时间来进行排队停车，容易造成局部地区堵塞。因此在这些热点地区，时效性的车位信息对于驾驶者来说很重要。虽然目前部分地图软件可以实现预测堵车的概率，提供路段以及多目的地规划的选择（Hsu 等，2018）。但是，在人流高峰期到达一些热门区域时，停车位紧缺的问题仍然不能解决。为了帮助司机找到停车场，除了价格和到目的地的距离等因素外，这些软件仍然没有提供一个重要的信息，即在到达目的地后，附近停车场车位的预测信息。这一信息将有助于司机在出发前根据自己的实际情况选择停车场，避免在到达目的地时进入一个没有车位的热门停车场。

综上，车位预测信息对于提高车位利用率、缓解交通拥堵有着很重要的作用。对于驾驶者来说，车位预测信息可以帮助他们更好地了解当前车位的使用情况，规划出行，减少寻找车位的时间，提高出行效率。对于政府来说，车位预测信息可以帮助政府更好地管理停车场，提高停车场的使用效率，降低停车场的空置率，从而节省政府的费用。因此，提供一种高效的车位信息管理系统将是一个切实可行的方案，此方案意在对城市车位进行合理规划来提高停车位的利用率。在高效的车位信息管理系统中，时效性的可用停车位数量预测信息在驾驶员停车的决策过程中起着重要作用。但由于复杂的时间和空间依赖性（Amara-Ouali 等，2021），准确实时的交通预测一直是一项备受关注的难题。其中，时间依赖性主要是对于交通状态随时间而产生的动态变化，主要表现在周期性和趋势性上；空间依赖性主要是指空间对象某种属性的相似性和其位置的相似性具有一定的联系，在交通问题中主要体现在交通状态的变化受其所处城市道路网络拓扑结构的影响。那么，如何学习路网的空间拓扑特征和复杂的时间特征，将两者结合和应用，是提高交通预测准确率的关键。

## 1.2 国内外研究现状

时序预测是一项重要的任务，它可以帮助我们预测未来的趋势和变化，从而做出更准确的决策。随着人工智能技术的不断发展，时序预测的方法也不断更新和优化。本文将从传统的时序预测模型、基于机器学习的时序预测模型、基于深度图网络的时空预测模型和拓扑图的构建几个方面，对时序预测的研究进展进行

综述。

### (1) 传统的时序预测模型

传统的时序预测模型通常基于统计方法，常见的有线性回归模型（Tranmer 等，2008；李林波等，2020）、自回归滑动平均 ARMA 模型（Choi，2012；Chu，2009）、自回归积分滑动平均 ARIMA 模型（Ahmed 等，1979；Hamed 等，1995）、马尔科夫模型（Gupta 等，2012；Sun 等，2013）等线性模型。其主要优点在于鲁棒性好，泛化能力强，拥有坚实的数学基础支撑，这是其与机器学习模型最大的不同。然而，这类算法对数据质量要求较高，一般假设时间序列数据是稳定的，即时间序列期望与方差不随时间变化。因此，其预测对象一般是某一区域的短期数据，在时间粒度与空间粒度上都受到很大限制，而且这类传统模型对于序列的非线性特征提取不佳，在实际应用上有一定困难。

### (2) 基于机器学习的时序预测模型

另一类预测方式为机器学习模型，与传统的统计学方法相比，基于机器学习的时序预测的最大优势在于其强大的非线性拟合能力，其预测结果准确性较高。交通预测中的机器学习模型一般包含支持向量回归 SVR 模型（Lee 等，2000；Sun 等 2017；Zhou 等，2019）和神经网络模型如循环神经网络 RNN 模型（Tokg 等，2018；Yip 等，1998），长短期记忆神经网络 LSTM 模型（Abbasimehr 等，2020；Ip 等，2021；Kong 等，2017）等。也有学者尝试将不同的模型组合起来，利用不同模型的优势，提出了多种组合预测框架（谭文安等，2019）。黄恒君等(2020)采用 VMD 分解方法对原始数据信号进行分解，并利用优化的 ELSTM 预测模块进行分信号预测，获得了更高的预测精度。Yang 等(2017)提出了一种组合预测模型，包括数据预处理策略和模糊时间序列预测算法。此外，为了证明预测系统的有效性，还应用了人工神经网络、统计模型和支持向量回归模型来证明所使用的组合模型表现出优于单一模型的预测效果，能够有效提高模型预测精度。

### (3) 基于深度图网络的时空预测模型

就以上两种模型来说，从传统模型到机器学习模型，其学习能力越来越强，预测效果也获得了提升。然而，考虑到对于交通状况的预测，影响因素过多，输入的数据所包含的信息量不足，因此其预测效果受到了限制。例如，针对停车位

的预测,目前国内外的研究一般仅考虑时间因素,却忽略了停车场之间相互影响的空间因素等,而这些因素对于车位预测有明显的影响。出现这种情况的其中一个重要原因是交通预测的对象在空间上呈现不规则的分布,以往能够处理空间特征的机器学习方法,例如卷积神经网络(CNN),只能在规则的网格数据中得到应用(Hung等,2022;Ma等,2017),很难处理这种非欧几里得数据。为了应对这种情况,Kipf等(2016)将图的概念引入到了模型构建中,提出了图卷积神经网络(GCN),图卷积神经网络是直接图上计算,整个计算的过程,沿着图的结构进行,这样处理的好处是能够很好的保留图的结构信息,因此能够对非欧几里得数据的结构信息进行学习。这种特性使得将空间信息纳入预测模型成为可能。在这后,不断有基于图神经网络的预测模型出现,并在各种预测任务中得到大量应用。Zhao等(2019)提出了一种新的基于神经网络的交通组合预测方法,即时间图卷积网络(T-GCN)模型,它结合了图卷积网络(GCN)和简单高效的门控循环单位(GRU)对道路交通量进行了预测,取得了较好效果。Cui等(2019)提出了一种新颖的深度学习框架,即交通图卷积长短期记忆神经网络(TGC-LSTM),以学习交通网络中道路之间的相互作用并预测全网流量状态。这些加入了图卷积神经网络的模型大大提高了预测的准确性,但也存在一些缺陷,例如图卷积神经网络(GCN)在聚合信息时会忽视序列之间相互影响的大小,平等的对待所有邻居节点,并且构建的模型参数依赖于图的结构,归纳学习能力不足。针对这种缺点,有学者将注意力机制引入到图卷积网络中(Velickovic等,2017),构建了图注意力神经网络(GAT),GAT能通过注意力机制为邻居节点分配不同的权重来聚合信息。在这之后,一些学者尝试将图注意力网络与循环神经网络结合(Zhang,2020;顾默等,2022),进一步提高了模型的预测效果。

#### (4) 拓扑图的构建

此外拓扑图的构建也是基于深度图网络时空预测模型中的一个重要问题。拓扑图指的是将时空数据转化为图结构的过程,通常需要考虑数据的空间位置、相似度等因素,图网络时空预测模型预测效果的优劣很大一部分取决于拓扑图构建的准确与否。交通预测中,基于单一信息拓扑图的网络模型与循环神经网络相结合,做到了将空间信息与时间信息的结合,提高了模型预测精度,但此类模型中

所用的拓扑图大多都只是根据节点间的距离所构建的静态图,对于预测任务来说,仅考虑距离信息和时间信息是不全面的,例如对于车位预测来说,停车场之间在空间上的相互影响,不仅要考虑距离的远近,还要考虑道路是否连通,以及周围的兴趣点等因素(李王鸣等,2012)。为了在图神经网络中融入更多的信息,有学者从图的构建方面入手,将不同的空间影响因素融合到邻接矩阵中。Phu 等(2021)提出了一个基于图的模型用于因果关系的识别,该模型构建了交互图,以捕获输入文档中 DECI 重要对象之间基于话语、基于语法和基于语义的信息。还有学者试图通过构建多关系图的方式来提取多种不同的信息。Wang 等(2019)在模型中构建了用户多关系图,其中节点是电子商务平台的用户,不同的边代表了各种关系,包括友谊、同事和同学。Dou 等(2020)构建一个评论图,其中用户在图中表示为节点,并定义了三种用户之间的关系来捕捉他们的行为模式。

#### (5) 文献评述

综上所述,时序预测模型在现实应用中表现各有优异,但是也面临着一些问题。首先传统的统计预测模型对于数据的质量要求较高,难以适应时间序列内含的非平稳、含噪声等特点,对于序列的非线性特征提取不佳,在实际应用上有一定困难。其次,传统的统计模型和部分机器学习模型都只关注了交通状况在一段时间内的动态变化而忽略了研究对象之间的空间依赖性。一些关注时空依赖性的时空预测模型也存在一些不足,例如,图网络中用于提取时空特征的 GCN 模型忽视了序列之间相互影响的大小,在消息传递时平等的对待所有邻居节点,并且网络参数是基于整个拓扑图的网络的,一次计算就要更新全图的节点特征,这使得 GCN 在归纳任务上遇到困境。同时,大多数时空预测模型中只是将空间特征提取模块和时间特征提取模块进行前后组合,分步的处理时空信息,可能出现时空信息时的相互干扰的问题。最后,基于单一图的模型与循环神经网络相结合做到了将空间距离信息与时间信息的结合,提高了模型预测精度,但仅单一的考虑空间距离信息和时间信息是不充分的,容易忽视了其他可能对预测值有重要影响的因素。

## 1.3 主要研究内容及创新点

本文的主要研究内容是多视角图注意力门控单元网络的构建及在车位数量预测中的应用。针对停车场数据中复杂的时空依赖性问题,本文引入了图注意力机制,并将其与时序循环神经网络相结合,完成了时空信息的同步提取与处理任务。针对单一图空间信息不全面问题,本文构建了一个多视角信息融合图,完成了将多种空间信息融入预测模型的任务。具体研究内容及创新点如下:

### 1.3.1 模型构建

(1) 针对现有时空组合预测模型前后组合造成时空信息的相互干扰,以及图卷积神经网络在消息聚合中的缺陷。本文提出了一种新的时空预测模型,称为多视角图注意力门控单元(MGA-GRU)网络模型,它对门控循环单元神经网络(GRU)进行了改造,在其原先只能提取时间信息的两个门控单元的基础上增加了两个图注意力卷积门控单元(GA)用于提取空间信息。图注意力卷积门(GA)引入了注意力机制,通过不同序列间的空间注意力系数对节点进行信息聚合,使得改造后的MGA-GRU模型具备了处理空间信息的能力。区别于以往只是将图模型与循环神经网络进行前后组合,分步的处理时空信息的组合模型,MGA-GRU模型能够同步的进行时间信息与空间信息的提取与处理,提高了图模型与循环神经网络的整合程度,解决了组合模型分步处理时空信息时的相互干扰问题。

(2) 针对单一图空间信息不全面问题,本文在构造拓扑关系图时,融合了多种空间信息构造多视角拓扑图,将距离信息、可达性信息、兴趣点信息融入到一张图中,使得空间特征更加全面与准确。图注意力卷积门与多视角拓扑图相结合,进一步的提高了模型的预测效果。

### 1.3.2 现实应用

(1) 在真实的兰州市停车场车位数据集上进行了实验,通过设计消融实验,比较模型中不同子模块对于预测效果的影响,验证模型的理论正确性。还通过比

较多种主流的基准模型与 MGA-GRU 模型的预测效果以及各模型的长期预测能力,验证了我们的模型不论是预测精度还是长期预测能力都优于其余基准模型。

(2) 我们基于提出的 MGA-GRU 模型开发了车位预测 APP,这个 APP 可以随时随地获取停车场的空余车位数量的实时预测信息,让市民更好地了解城市停车资源的分布情况,为他们提供更好的出行建议,帮助市民更好地规划自己的出行路线,更方便地找到空余车位。还可以为政府提供更好的城市管理服务,提高停车场的使用效率,降低停车场的空置率,从而节省政府的费用。我们相信,这个 APP 将会在未来的城市发展中起到越来越重要的作用。

## 1.4 研究结构安排

本文正文内容分为六个章节,文章框架如下:

(1) 第一章:绪论。从车位预测任务的研究背景及研究难点出发,介绍了车位预测任务的研究背景及意义。然后从时间预测模型与时空预测模型的角度,概述了国内外研究现状。最后对本文的研究内容进行了总结概括。

(2) 第二章:相关原理与技术。介绍了车位预测任务的相关理论。并且介绍了本文所使用的技术知识,包括拓扑图的构建、门控循环神经网络、长短期记忆力网络、图卷积网络以及图注意力神经网络等相关内容,为本文所提出的网络提供理论基础。

(3) 第三章:MGA-GRU 预测模型构建。介绍了 MGA-GRU 预测模型中各部分的设计思路及构建方式,包括网络的搭建方式、模型的输入和输出。然后就模型的核心模块 GA-GRU 单元进行了详细论述,包括 GA-GRU 单元的具体构造、图注意力卷积门(GA)的定义与工作原理。在这之后对 MGA-GRU 预测模型所使用的多视角信息图的构建方法进行了阐述。最后介绍了模型所使用的损失函数与模型的伪代码。

(4) 第四章:兰州市停车场车位预测实证分析。首先介绍了本文所使用的数据集、多视角拓扑图的构建、基准模型以及性能评估指标。然后通过实验分析,验证了本文 MGA-GRU 预测模型的长短期预测性能以及各个模块的有效性。最后进行了实用性探索,为了能够将模型进行推广并获得更广泛的使用,本文以

MGA-GRU 模型为基础开发了车位预测应用，探索模型的实用价值。

(5) 第五章：总结与展望。简要总结了本文的研究工作，并对研究的下一步工作进行了展望。

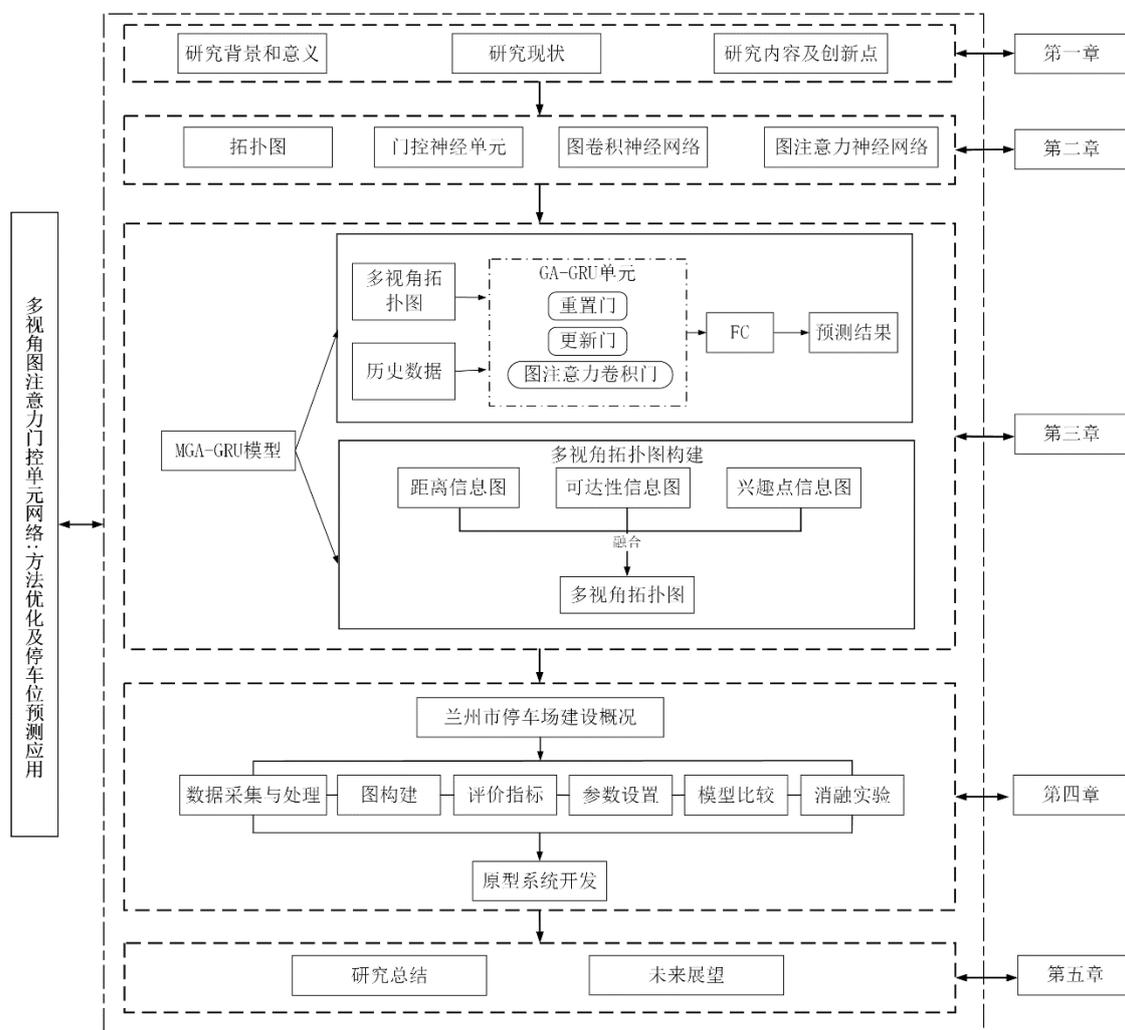


图 1.1 本文架构图

## 2 相关原理与技术

车位数量时空预测任务,是根据各停车场的历史车位数据以及各停车场在空间上的分布网络来进行的。我们将停车场网络上的车位历史信息视为网络中节点的属性特征,表示为 $X \in R^{N \times P}$ ,其中 $P$ 表示节点特征,即停车场车位历史序列的长度, $N$ 表示节点数目,即停车场的个数,因此,时空车位预测问题可以认为是在路网拓扑 $G$ 和特征矩阵 $X$ 的前提下学习映射函数 $f$ ,然后计算接下来 $T$ 时刻的车位信息,如式1所示:

$$[X_{t+1}, \dots, X_{t+n+1}] = f(G; (X_t, \dots, X_{t-T+1}, X_{t-T})) \quad (1)$$

其中 $T$ 是用于预测的历史时间序列的长度, $n$ 是需要预测的时间序列。

### 2.1 拓扑图

拓扑图构建的是图神经网络的重要基础,所谓“拓扑”就是将现实中的事物剥离其大小形状等特征,将其抽象成一个点,并将点与点之间的联系抽象成线,再以拓扑结构图的形式来描述这些点和线之间关系,构建拓扑图的目的就是研究这些点与线之间的联系。

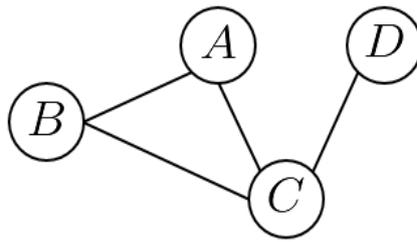


图 2.1 拓扑图

由上述简单定义可以得到,图是一种十分常用的数据结构。图一般是由顶点的集合所组成,其中,一个顶点代表一个研究对象,顶点之间的连边对应着不同研究对象之间的相互关系。图(H U Ttel 等, 2021)通常可以表示为 $G(V, E)$ 。

其中,  $V = \{v_1, v_2, \dots, v_N\}$  表示的是图  $G$  中所有节点的集合,  $v_i$  表示的是所有顶点集合中的第  $i$  个节点,  $N$  表示的是图中的节点数量。图  $G$  中的节点之间连边集合可以表示为  $E = \{e_1, e_2, \dots, e_m\}$ ,  $m$  表示的是图中节点之间的边的数量。

拓扑图的构建主要考虑不同节点之间的邻近关系和特征关系, 对于邻近关系, 根据地理学第一定律 (奚桂锴, 2021), 所有的事物都与其他事物相关, 但是距离相近的事物比远处的事物更相关。因此, 在大多数研究中都以距离作为事物之间的空间关系, 即邻近关系。根据两个节点之间是否相邻近来判定两个节点之间是否有连边。

例如, 如图 2.1 中所示的拓扑图, 节点 A 会和周围的其他邻近的节点 (节点 B 和节点 C) 分别产生连边。基于此, 可以得到对应邻近关系的邻接矩阵  $A$ ,  $A \in \mathbf{R}^{N \times N}$ 。邻接矩阵  $A$  只包含 0 和 1 元素, 若两个节点之间没有连接则元素为 0, 元素表示为 1 的则代表两个节点之间有相连的边。邻接矩阵定义如下:

$$A_{ij} = \begin{cases} 1, & e_{ij} \in E \\ 0, & otherwise \end{cases} \quad (2)$$

由邻接矩阵定义可以得到图 1 中拓扑图的邻接矩阵:

$$A = \begin{bmatrix} 0 & 1 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix} \quad (3)$$

拓扑图的度矩阵即为顶点的度所构成的对角矩阵, 对角矩阵中的对角线上的各个元素为所对应的各个节点的度数, 即:

$$D_{ii} = \sum A_{ij} \quad (4)$$

所以, 邻接矩阵  $A$  所对应的度矩阵  $D$  为:

$$D = \begin{bmatrix} 2 & 0 & 0 & 0 \\ 0 & 2 & 0 & 0 \\ 0 & 0 & 3 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (5)$$

拓扑图的构建是时空预测建模的前提,但我们也发现,传统的拓扑图构建方法往往仅能容纳一种空间信息,若模型需要更多的空间信息,传统的方法将很难再发挥作用。

## 2.2 门控循环单元 (GRU)

获取时间信息是车位预测的重要内容,在机器学习方法中,循环神经网络(RNN)广泛应用于对时间序列的建模,但 RNN 网络容易出现梯度爆炸以及历史信息记忆能力不足的现象。为了解决这一问题,出现了 RNN 网络的变体 LSTM 与 GRU 网络,他们具有相似的结构,都使用门控机制来记忆尽可能多的长期信息,并且由于门控机制大大减少了梯度计算时的累乘操作,使得梯度爆炸现象得到了缓解。两种网络的不同之处在于 GRU 相较 LSTM 网络结构更加简单高效,GRU 的门控单元更少,其参数也比 LSTM 网络少,使 GRU 网络比 LSTM 网络收敛的更快,尤其在训练数据很大时,GRU 模型能节省大量时间。

门控递归单元的输入和输出的结构与 RNN 和 LSTM 相同。具体来说,就是都具有当前时刻的输入 $x_t$ ,和之前时刻的节点传递过来的隐藏特征 $h_{t-1}$ , $h_{t-1}$ 的矩阵中隐含了有关上一个节点的历史信息。结合 $x_t$ 和 $h_{t-1}$ ,GRU 模型会获得当下隐藏节点的输出,并且将隐藏特征 $h_t$ 传递给下一个节点。GRU 模型的结构如下图所示:

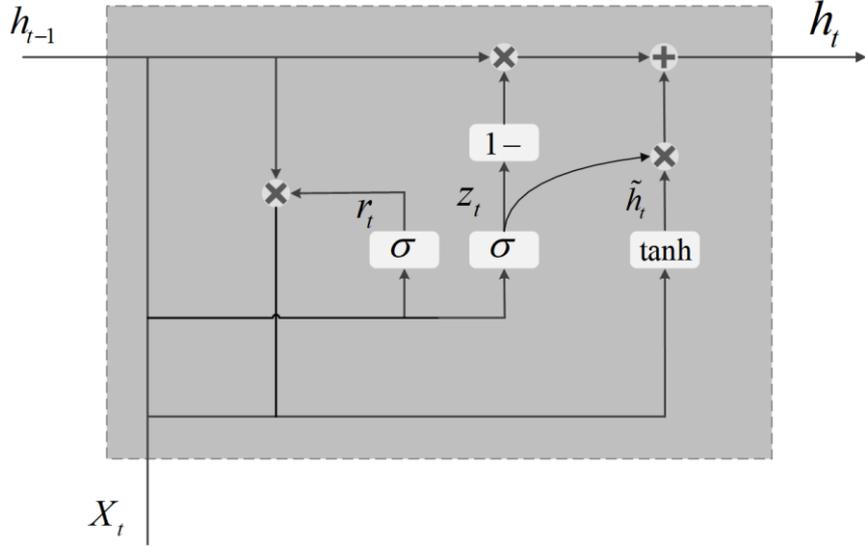


图 2.2 GRU 结构图

在 GRU 模型中，更新门的作用在于控制新的输入信息如何与前面的记忆进行结合。其过程为将前一个时刻神经单元的输入  $h_{t-1}$  和当前时刻的输入  $x_t$  输入到  $z_t$  中去，更新门向量中的值越大，就表示引入前一状态的信息越少，当前的信息写入的越多。具体计算过程为：

$$z_t = \sigma(\mathbf{W}_u[\mathbf{X}_t, \mathbf{h}_{t-1}] + \mathbf{b}_u) \quad (6)$$

GRU 模型中的重置门的作用就在于决定上一层状态中有多少信息量传递到当下状态。重置门向量中的值越大，表示之前状态信息量被写入到候选值控制单元中的就越多。其具体计算过程为：

$$r_t = \sigma(\mathbf{W}_r[\mathbf{X}_t, \mathbf{h}_{t-1}] + \mathbf{b}_r) \quad (7)$$

模型中用来存储记忆内容即为候选值的生成，其是产生候选值  $\tilde{h}_t$  的部分，其输入包括前一个时刻神经单元的输入  $h_{t-1}$ 、当前时刻的输入  $x_t$  以及计算出来的  $r_t$ 。具体计算过程为：

$$\tilde{h}_t = \tanh(\mathbf{W}_h[\mathbf{X}_t, (\mathbf{r}_t \odot \mathbf{h}_{t-1})] + \mathbf{b}_c) \quad (8)$$

在计算完成  $r_t$ 、 $z_t$ 、 $\tilde{h}_t$  之后，就可以生成该单元的输出值以及向输出层传递的值，具体计算过程为：

$$\mathbf{h}_t = z_t \odot \tilde{h}_t + (1 - z_t) \odot \mathbf{h}_{t-1} \quad (9)$$

GRU 模型在获取当前交通信息的同时，仍然保留了历史信息的变化趋势，并具有获取时间相关性的能力。因此本文在对于车位时间信息提取模块的设计上主要参照了 GRU 的设计思路，在 GRU 的基础上进行修改。

## 2.3 图神经网络

### 2.3.1 图卷积神经网络（GCN）

对于停车位预测任务来说，在复杂的道路网络中提取空间依赖性是提高预测性能的关键，传统的卷积神经网络（CNN）虽然可以用来提取空间信息，但卷积操作仅能在规则的欧几里得数据中应用，如常见的图片数据和规则网格数据等。对于停车场网络来说，由于该网络结构不是以规则的网格的形式而是以拓扑图的形式呈现，CNN 不足以处理这种具有复杂拓扑结构的数据，这就没有办法准确的提取到空间依赖性。而 GCN 可以处理不规则图结构数据，上文介绍了图的相关概念，基于此，GCN 就是能够处理图数据的一种深度学习的方法。该方法将邻接矩阵  $A$  引入了进来，然后通过 GCN 模型在傅里叶域构造一个滤波器。该滤波器的作用就是能够作用于图的节点，获取节点的信息。不仅如此，还能通过利用其一阶邻域来捕捉各个节点之间的空间特征，得到空间特性之后，再通过叠加多个卷积层，这就能建立出一个 GCN 模型，该模型可以用公式表示为：

$$\mathbf{H}^{(l+1)} = \sigma(\tilde{\mathbf{D}}^{-\frac{1}{2}} \hat{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{H}^{(l)} \mathbf{W}^{(l)}) \quad (10)$$

$A$  为邻接矩阵， $D$  为度矩阵， $H^{(l)}$  是  $l$  层的输出， $W^{(l)}$  是包含该层的参数， $\sigma(\cdot)$  表示非线性模型的 *sigmoid* 函数。

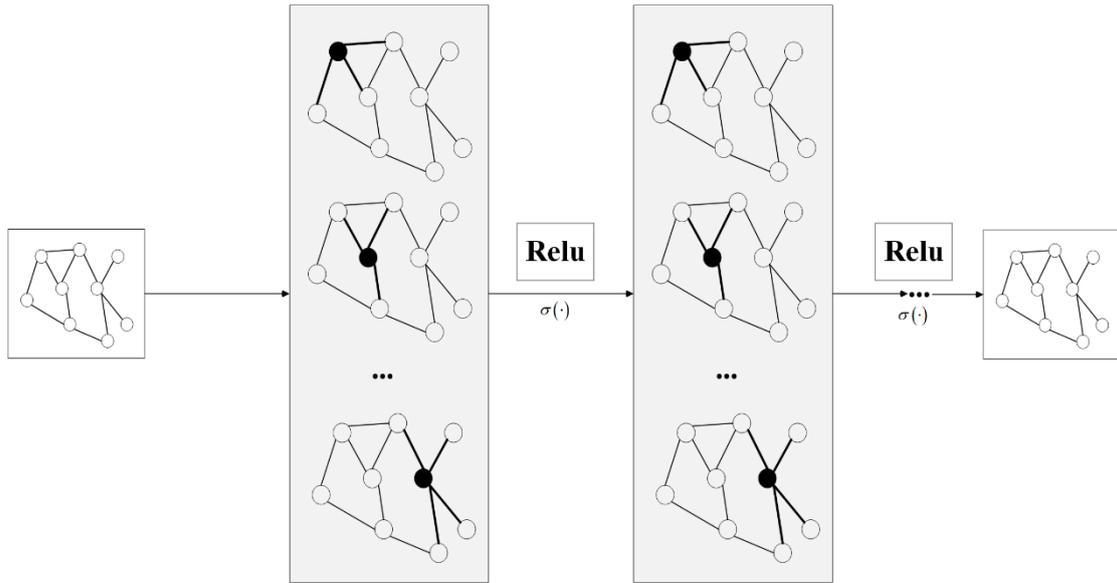


图 2.3 GCN 模型结构图

GCN 模型结构如上图所示，以两层 GCN 模型为例来获得空间依赖性，其可以表示为：

$$f(\mathbf{X}, \mathbf{A}) = \sigma(\hat{\mathbf{A}} \text{ReLU}(\hat{\mathbf{A}} \mathbf{X} \mathbf{W}_0) \mathbf{W}_1) \tag{11}$$

其中  $\hat{\mathbf{A}}$  表示的是加了自循环的邻接矩阵， $\mathbf{W}_0 \in \mathbf{R}^{P \times H}$  表示的是第一层网络的参数矩阵， $P$  是特征矩阵的长度， $H$  是隐含层的单元数。 $\mathbf{W}_1 \in \mathbf{R}^{H \times T}$  表示的是第二次网络的参数矩阵。 $\text{ReLU}$  表示的是激活函数， $f(\mathbf{X}, \mathbf{A})$  表示当前层的网络输出。

GCN 在频域上完成图上的卷积操作，依次对各节点的信息进行聚合更新，下图为 GCN 网络的消息传递过程：

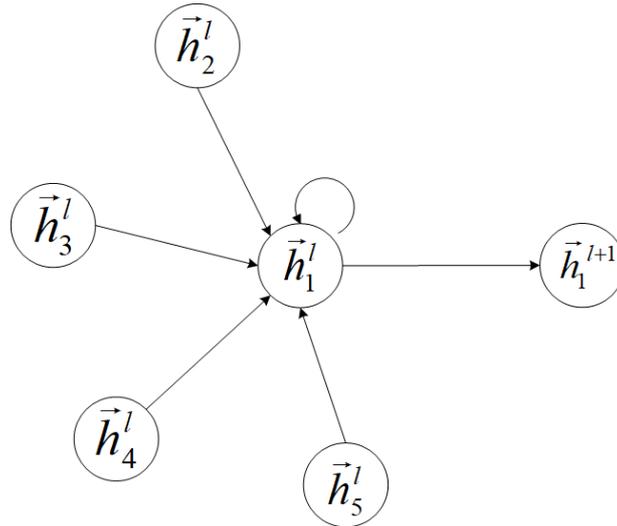


图 2.4 GCN 网络的消息传递过程

如上图所示,当前节点每次进行消息更新时都会将自身以及邻居节点的信息全部聚集,消息传递过程可以改写成下式:

$$\vec{h}_1^{l+1} = \sigma(b^l + \sum_{j \in N_i} \frac{1}{c_{ji}} \vec{h}_j^l \mathbf{W}^l) \quad (12)$$

其中  $N_i$  是节点  $i$  邻居节点的集合,  $c_{ji}$  是节点  $i$  和节点  $j$  的度分别开根号的乘积, 即  $c_{ji} = \sqrt{|D_{jj}|} \sqrt{|D_{ii}|}$ ,  $\sigma$  是激活函数, 从式 12 可以看出消息的聚集方式一般是采取平均的策略, 即将当前节点以及周围邻居节点的信息加总然后求平均作为当前层的输出。

GCN 在聚集消息时平等的对待所有节点的方式可能会降低空间信息提取的准确性, 因为不同节点序列之间的影响大小是不同的, 忽略这种影响直接进行消息聚合会带来更多的误差。

### 2.3.2 图注意力神经网络 (GAT)

现实中交通网络都呈现不规则的空间分布, 以往提取规则网格数据特征的卷积神经网络不在适用。基于此, 本文将图注意力神经网络 GAT 引入到空间信息的提取中, GAT 属于图网络的一种, 都通过拓扑图对节点间的消息传递进行处理, 它能够对现实中的不规则网络数据的特征提取与聚合。图网络图注意力神经

网络 GAT 相较于较早出现的图卷积神经网络 GCN 模型, 不同之处在于 GCN 以平均的方式聚合邻居节点的信息, GAT 神经网络则对不同节点的重要性进行区分, GAT 通过引入了注意力机制, 可以在对邻居节点进行信息聚合时根据序列间的相关性赋予不同的节点序列不同的权重, 以此来对提高信息聚合的准确性。

具体来讲, 加入图注意力机制后, 对于序列间的消息传递如下图所示:

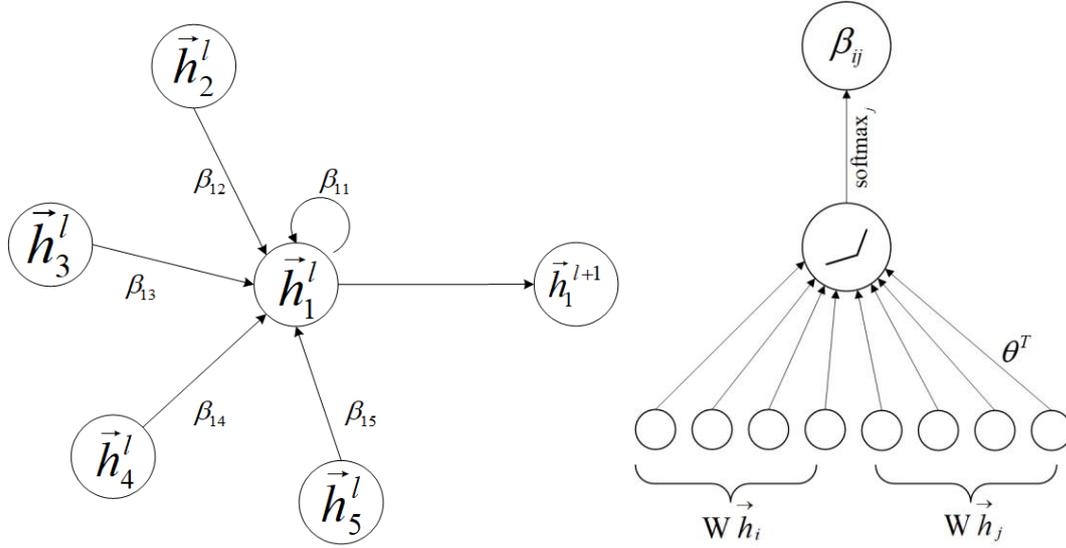


图 2.5 GAT 网络消息传递过程 (左) GAT 网络注意力系数计算过程 (右)

以 5 个节点为例, 左图展示了图注意力网络中的消息是如何传递的, 右图展示了注意力权重系数的计算过程。其中  $h_i$  和  $h_j$  是当前输入层的节点  $i$  与节点  $j$  的特征表示,  $W$  是线性变换矩阵, 维度为  $W \in R^{F \times F'}$ ,  $F$  为输入特征的维度。  $F'$  为输出特征的维度。  $\bar{h}_i$  为当前层网络节点  $h_i$  经过聚合后的输出。

$\beta_{ij}$  为节点  $i$  与节点  $j$  之间的权重系数, 通过下式计算得出:

$$e_{ij} = \text{LeakyReLU}(\theta^T [\mathbf{W}h_i \parallel \mathbf{W}h_j]) \quad (13)$$

$$\beta_{ij} = \text{softmax}_j(e_{ij}) = \frac{\exp(e_{ij})}{\sum_{k \in N_i} \exp(e_{ik})} \quad (14)$$

$e_{ij}$  为不同序列间的相关性大小,  $\parallel$  是向量拼接操作, 原本维度为  $F$  的输入向量  $h_i$  与  $h_j$  经过  $W$  线性变换后维度均变为  $F'$ , 经过拼接后得到维度为  $2F'$  的向量, 与维度同样为  $2F'$  的可学习系数向量  $\theta^T$  相乘后经 LeakyReLU 激活, 得到 1 维的  $e_{ij}$ ,

依次计算出所有节点两两间的相关性大小 $e_{ik}$ ,  $k \in N_i$ ,  $N_i$ 为所有与节点 $v_i$ 相连通的邻居节点。对所有的 $e_{ij}$ 进行 softmax 归一化处理得到 $\beta_{ij}$ , 即节点 i 与节点 j 之前的权重系数。则当前层的输出 $\vec{h}_i^{l+1}$ 为各节点序列与对应注意力权重系数的乘积和:

$$\vec{h}_i^{l+1} = \sigma\left(\sum_{j \in N_i} \beta_{ij} \mathbf{W} \vec{h}_j^l\right) \quad (15)$$

此外 GAT 还引入了多头注意力机制(Multi-Head Attention)来增强模型的稳定性, 具体过程为进行多次消息传递操作后, 将每次得到的向量拼接或者求平均, 公式如下:

$$\mathbf{h}_i^{l+1} = \sigma\left(\frac{1}{K} \sum_{k=1}^K \sum_{j \in N_i} \beta_{ij}^k \mathbf{W}^k \mathbf{h}_j^l\right) \quad (16)$$

GAT 通过其独特的结构与计算方式, 避免了整个网络对于图的依赖, 当图结构发生变化时, GAT 也能对新的图进行较好的预测, 这对于交通预测尤为重要, 使得模型归纳外推能力得到提高。

## 2.4 本章小结

本章介绍了车位预测任务的相关理论。并且介绍了本文所使用的技术知识, 包括拓扑图的构建、门控循环神经网络、图卷积网络以及图注意力神经网络的相关内容。

### 3 MGA-GRU 预测模型构建

#### 3.1 MGA-GRU 网络结构

MGA-GRU 模型是本文对于传统门控循环神经单元的改进,通过引入图注意力卷积门 (GA) 来使 GRU 单元具有同时处理历史车位信息与空间信息的能力,从而捕捉到车位数量的全局变化趋势。

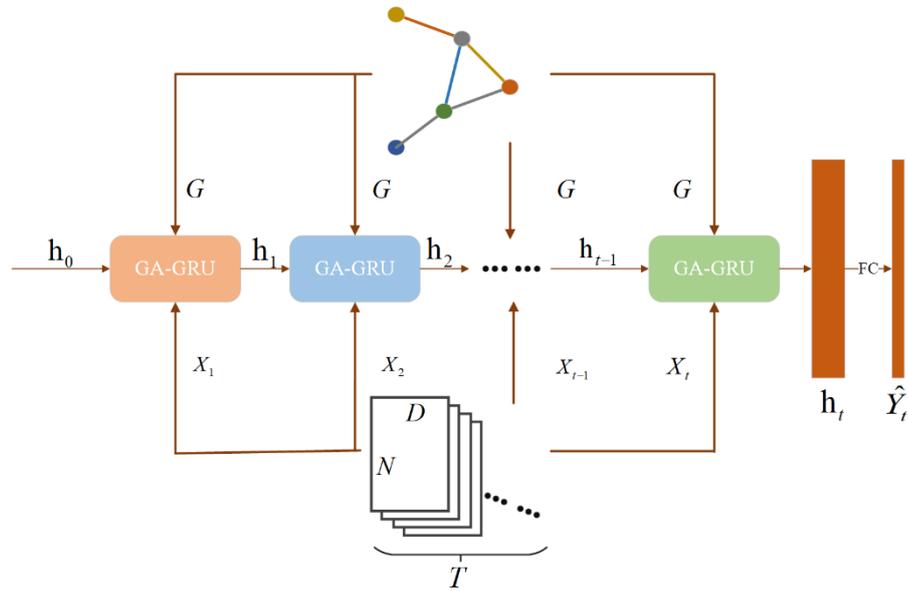


图 3.1 模型的网络结构

图 3.1 为 MGA-GRU 的网络结构,整个网络由多个 GA-GRU 单元组成,在进行数据输入时,每个单元依次输入停车场网络拓扑图  $G(V, E)$  和车位历史数据  $X \in R^{N \times T}$ ,最终得到模型的预测值。其中  $N$  为节点数量,  $T$  为用于预测的时间序列长度,图中  $D$  为每日车位数据的特征维度,本文中车位数据中只有车位占用数量这一特征维度,因此  $D=1$ 。在 MGA-GRU 网络中,前项传播过程和传统的 GRU 基本相同,并且都通过记忆矩阵  $H$  来记录序列中的历史信息,但 GA-GRU 单元相比传统的 GRU 单元多出两个图注意力卷积门,用于提取和处理输入序列间的空间信息。

### 3.2 GA-GRU 单元

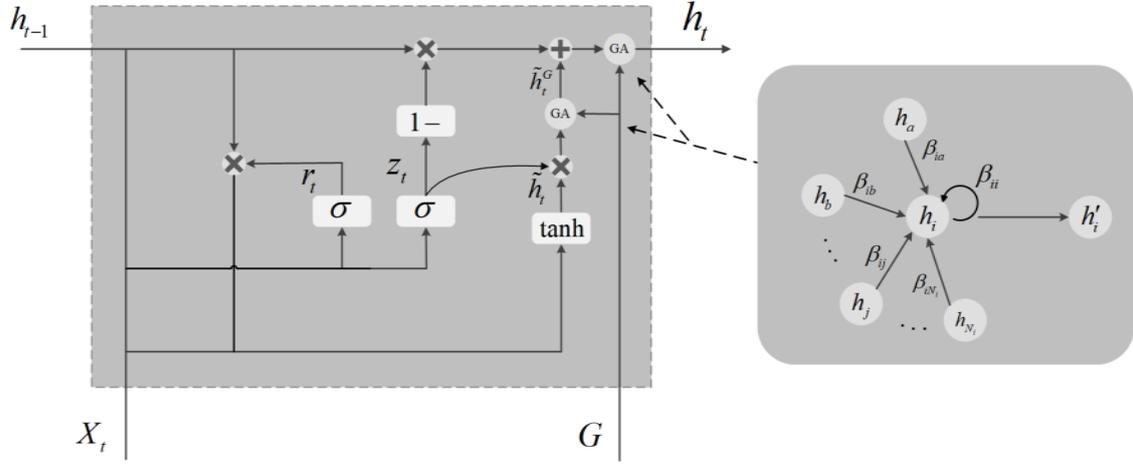


图 3.2 GA-GRU 单元结构

图 3.2 为 GA-GRU 单元的具体结构，数据经过 GA-GRU 单元时通过两条分支进行传输，一条传输并加工处理当前信息和历史信息得到候选激活值  $\tilde{h}_t$ ，另一条传输历史信息  $h_{t-1}$ ，最终结合当前信息和历史信息得到单元输出  $\tilde{h}_t^\sigma$ ，此外，GA-GRU 单元由四个门控单元组成，其中，更新门控制新的输入信息如何与前面的记忆进行结合，重置门决定上一层状态中有多少信息量传递到当下状态。

$$z_t = \sigma(W_u[X_t, h_{t-1}] + b_u) \quad (17)$$

$$r_t = \sigma(W_r[X_t, h_{t-1}] + b_r) \quad (18)$$

其中  $z_t$  表示更新门， $r_t$  表示重置门， $\sigma$  表示激活函数， $W$  和  $b$  为需要学习的参数。MGA-GRU 模型在重置门和更新门的基础上加入了两个图注意力卷积门 (GA)，其中一个图注意力卷积门位于 GA-GRU 单元一条数据传输分支的末端，即候选激活值  $\tilde{h}_t$  后，用于将空间信息添加到候选激活值中，另一个图注意力卷积门位于中间输出  $\tilde{h}_t^\sigma$  后，用于将空间信息融入到中间输出中。两个图注意力卷积门确保了在整个数据传输过程中时空信息的融合，能够同步的进行时空信息的提取和处理。以下为图注意力卷积门 (GA) 的计算公式：

$$GA(X) = \sigma\left(\sum_{j \in N_i} \beta_{ij} W X\right) \quad (19)$$

$$\beta_{ij} = \frac{\exp(e_{ij})}{\sum_{k \in N_i} \exp(e_{ik})} \quad (20)$$

$$e_{ij} = \text{LeakyReLU}(\boldsymbol{\theta}^T \alpha_{ij} [\mathbf{W}x_i \parallel \mathbf{W}x_j]) \quad (21)$$

其中 $\boldsymbol{\theta}$ 和 $\mathbf{w}$ 为需要学习的参数, 式(21)用于计算节点 $v_i$ 和 $v_j$ 序列之间的相关性大小 $e_{ij}$ , 在这个过程中,  $\alpha_{ij}$ 是构建拓扑图时对应节点 $v_i$ 和 $v_j$ 之间的交互得分, 在本模型中用于将拓扑图中的空间信息纳入到序列相关性的计算中来, 当 $\alpha_{ij} = 0$ 时 $e_{ij}$ 为0,  $\alpha_{ij}$ 越大, 序列相关性 $e_{ij}$ 受拓扑图中的空间信息的影响越大。式(20)用于计算注意力权重 $\beta_{ij}$ , 在计算出节点 $v_i$ 所有 $\alpha_{iu} \neq 0, u \in N$ 的节点的序列相关性大小后, 使用 softmax 函数对它们进行归一化, 得出节点 $v_i$ 和 $v_j$ 之间的注意力权重 $\beta_{ij}$ 。最后使用注意力权重 $\beta_{ij}$ 将候选激活值 $\tilde{\mathbf{h}}_t$ 和中间输出 $\hat{\mathbf{h}}_t$ 中各节点的信息进行聚合, 输出同时含有时间信息和空间信息的图候选激活值 $\tilde{\mathbf{h}}_t^G$ 和最终输出 $\vec{\mathbf{h}}_t$ :

$$\tilde{\mathbf{h}}_t = \tanh(\mathbf{W}_h[\mathbf{X}_t, (\mathbf{r}_t \odot \mathbf{h}_{t-1})] + \mathbf{b}_c) \quad (22)$$

$$\tilde{\mathbf{h}}_t^G = GA(\tilde{\mathbf{h}}_t) \quad (23)$$

$$\hat{\mathbf{h}}_t = \mathbf{z}_t \odot \tilde{\mathbf{h}}_t^G + (1 - \mathbf{z}_t) \odot \mathbf{h}_{t-1} \quad (24)$$

$$\vec{\mathbf{h}}_t = GA(\hat{\mathbf{h}}_t) \quad (25)$$

GA 门的应用使得注图注意力机制与记忆机制的整合度更高, 并且使改进的 GA-GRU 单元具备了同步处理时空信息的能力, 这是非常重要的, 以往的图网络与循环神经网络相结合的时空预测模型, 分析其结构大部分都是组合模型, 即将图网络与循环神经网络前后组合, 分步处理空间信息与时间信息, 由于序列中空间信息与时间信息相互干扰, 可能造成特征提取的不准确。MGA-GRU 模型在加入图注意力卷积门 GA 后, 数据在网络中传递过程中时空信息的提取同步进行, 减小了相互之间的干扰, 理论上能够提高预测的准确度。

在训练过程中, 训练目标是使实际样本值与预测值之间的误差最小化。我们使用 $Y_t$ 和 $\hat{Y}_t$ 分别表示实际样本值和预测值。MGA-GRU 模型的损失函数等式如下:

$$\text{loss} = \left\| Y_t - \hat{Y}_t \right\|^2 + \lambda L_{reg} \quad (26)$$

第一项的作用是使最小化实际样本值和预测值之间的误差。第二项 $\lambda L_{reg}$ 为正

则化项, 有助于避免过拟合问题,  $\lambda$ 是超参数。

### 3.3 多视角图构建

在 MGA-GRU 模型中, 空间信息都存储在拓扑图 (G) 中, 在传统的图构建方法中, 通常使用邻接矩阵 A 将所有顶点间边的信息存储到二维矩阵中, 矩阵中每个元素代表一对顶点是否连接。对于停车场网络, 首先要做的是解决如何使用邻接矩阵来捕捉节点间的边信息。据我们所知, 在以前涉及到交通预测类的研究中大多使用的邻接矩阵都是单一的基于距离的, 即不同站点之间的欧几里得距离或自然地理距离 (Chen 等, 2020; Yu 等, 2017; Zhang 等, 2020; Zhao 等, 2019)。而对于本文所涉及的车位预测领域, 仅有少数现有研究考虑了空间依赖性, 在其停车占用预测模型中引用图神经网络并使用欧几里得距离 (Xiao 等, 2021; Xiao 等, 2021; Yang 等, 2019) 构建邻接矩阵。但仅考虑距离是不全面的, 一些研究表明 (Balmer 等, 2021): 可达性、兴趣点也会对车位占用有着很大的影响, 这些因素在车位预测模型中具有尚未被开发的巨大潜力。

基于以上图构建理论与多种因素对车位的影响, 以往的拓扑图构建方法将不在适用, 因此本文对车位预测的空间网络进行了重新设计, 将地理距离、可达性、兴趣点融合到同一个拓扑图中, 构建多因素邻接矩阵用于模型预测。

本节的目标是生成一个交互图  $G = \{V, E\}$ , 以促进图网络的表示学习。我们的车位预测问题的 G 中的节点和边构造如下:

**节点:** 我们的交互图 G 的节点集 V 应该捕获相关对象, 用于车位预测。如前文所述, 我们将各停车场作为研究的相关对象, 即  $V = \{v_1, v_2, \dots, v_N\}$ ,  $v_i$  代表第 i 个停车场, N 代表停车场的数量。

**边:** 在本文中, 我们在 E 的数据集中使用邻接矩阵  $A = \alpha_{ij} \quad i, j \in N$  来表示。在这里, 由于我们的目标是使用邻接矩阵 A 作为图网络的输入来学习车位数据的表示向量, 所以我们希望 A 中能够包含我们所需的所有空间信息, 因此我们在 A 中使用 V 中两个节点  $v_i$  和  $v_j$  之间的值  $\alpha_{ij}$  是用来表示两个节点间在空间上的相关性。通过构建邻接矩阵,  $v_i$  和  $v_j$  可以直接交互并影响彼此的表示计算。如上文所述, 我们利用三种类型的信息来设计边 E (或计算我们模型中 G 的交互分数

$\alpha_{ij}$ ), 包括基于地理距离、可达性、兴趣点的信息。

### 3.3.1 地理距离

地理距离在关于交通预测的图构建中应用的最多, 地理距离  $h^D(x_i, x_j)$  一般由各节点的经纬度 (lat, lon) 计算, 首先将两个节点的经纬度转化为弧度 (rlat, rlon), 然后使用 haversine 公式计算地理距离:

$$h^D(x_i, x_j) = 2 \arcsin \sqrt{\sin^2\left(\frac{rlat_i - rlat_j}{2}\right) + \cos(rlat_i) \cos(rlat_j) \sin^2\left(\frac{rlon_i - rlon_j}{2}\right)} \quad (27)$$

计算出两两节点的地理距离  $h^D(x_i, x_j)$  后, 可根据实际需求定义阈值  $D$  来界定节点之间是否连通。

$$\alpha_{ij}^D = \begin{cases} 1 & \text{若 } h^D(x_i, x_j) < D \\ 0 & \text{其他} \end{cases} \quad (28)$$

我们建议在  $V$  中计算  $\alpha_{ij}^D$  作为节点  $v_i$  和  $v_j$  之间基于地理距离的交互得分, 若节点  $v_i$  和  $v_j$  之间的  $h^D(x_i, x_j) < D$ ,  $\alpha_{ij}^D$  为 1, 否则为 0。

### 3.3.2 可达性

可达性的概念由 Hansen 在 1959 年首次提出, 将可达性的定义为交通网络中各节点相互作用机会的大小。应用在本文中, 可达性指在不同停车场节点之间相互作用的机会大小, 而这种机会大小是在整个路网中计算的, 所以不同于地理距离, 可达性实际上是对于停车场之间路网交通信息的描述。不同停车场之间的可达性对于停车场的车位数量影响在理论方面已经有所研究, Rajabioun 等(2015)指出, 在城市道路中彼此距离不同的停车场之间的停车使用率存在相关性。Lu 等(2020)在车位占有率预测中考虑了相邻道路或车库的占用信息。Sisman 等(2020)在确定停车场选址的 3 个主要标准组和 18 个子标准中就考虑了新设施建设时应该考虑道路中已有的停车场, 避免造成资源浪费。因此, 在路网中不同停车场之间的可达性是在构建图时应该考虑的因素。据我们所知, 将可达性应用在车位预测图的构建中我们是首次。

在路网中可达性的衡量一般使用 OD 成本矩阵法 (马书红等, 2022), 基于

道路网络构建起始地-目的地成本矩阵。矩阵中的元素 $OD_{ij}$ 对应了节点 $v_i$ 和 $v_j$ 之间连通的最短道路的长度 $h^R(x_i, x_j)$ 。通过 OD 成本矩阵算出各节点之间的道路距离后我们可以计算在路网中节点 $v_i$ 到达 $v_j$ 的时间 $t^R(x_i, x_j)$ ，即 $t^R(x_i, x_j) = \frac{h^R(x_i, x_j)}{v^R}$ ，其中 $v^R$ 为车辆行驶速度，在市区通常车辆行驶速度为 $v^R = 20 \text{ km/h}$ 。 $t^R(x_i, x_j)$ 衡量了节点之间的可达性， $t^R(x_i, x_j)$ 越小则说明可以在较短的时间从节点 $v_i$ 到达 $v_j$ 。在停车时，相邻停车场之间的可达性越好，则车位数量的相互影响越大。

计算出两两节点的可达性 $t^R$ 后，构建可达性图时可根据实际需求定义阈值 AC 来界定节点之间是否连通。

$$\alpha_{ij}^R = \begin{cases} 1 & \text{若 } t^R(x_i, x_j) < R \\ 0 & \text{其他} \end{cases} \quad (29)$$

我们建议在 V 中计算 $\alpha_{ij}^R$ 作为节点 $v_i$ 和 $v_j$ 之间基于可达性的交互得分，若节点 $v_i$ 和 $v_j$ 之间 $t^R(x_i, x_j) < R$ ， $\alpha_{ij}^R$ 为 1，否则为 0。

### 3.3.3 兴趣点

兴趣点是指日常生活中常见的商场、学校、酒店等点状地理要素。在对车位规划时对不同的地理要素有不同的配建指标，以满足停车需求(李王鸣等, 2012; 吴德华等, 2005)。因此，车位配置和兴趣点本质上来说是供给与需求的关系。例如人流量多的商场、酒店就需要供给更多的车位满足停车需求，所以在这些地方所建设的停车场的车位占用数量相互之间是有很大的影响的：在一个区域内，假设在现有停车场数量恒定的情况下，公共设施的数量越多，则对车位的需求越多，每个停车场的车位占用数量的相互影响程度则越大，只有当这个区域的车位满足不了需求的情况下，人们才考虑去更远的地方停车或者离开。基于这种停车场相互间的车位数量影响，本文认为在构建图时应该将兴趣点这一空间因素纳入进来。

在衡量这种相关性时，首先对兴趣点的种类进行选择，考虑到不同类型的兴趣点对于车位的需求是不同的，在人流量大的兴趣点区域车位需求量越多，停车

场相互间的影响越大。因此本文主要考虑一些大型公共设施,具体的种类包含宾馆、酒店、景区、学校、农贸市场、商场、医院、写字楼。

在确定兴趣点种类后,为了避免统计一些距离较远影响力较小的兴趣点,需要确定一个区域,统计在这个区域内的兴趣点。这个区域大小的选择主要参考其他学者对于公共设施服务边界的划定,田金欢等(2022)在对昆明市中心的公共服务设施边界研究中对各类兴趣点的服务半径进行了测定,其中对于上述挑选的兴趣点服务半径都在 500m 左右,在这个区域内的市民会选择到这些地点活动。因此本文在计算两停车场节点 $v_i$ 和 $v_j$ 之间基于兴趣点的影响大小时,同样选择以 $v_i$ 和 $v_j$ 中点为圆心,500m 为半径的区域 $P_{ij}$ 来测定兴趣点对停车场节点 $v_i$ 和 $v_j$ 之间的影响,具体方法为统计区域 $P_{ij}$ 内的大型公共设施归一化数量 $n^P = \frac{\exp(N_{poi \in P_{ij}})}{\exp(N_{poi})}$ ,作为停车场之间的相互影响程度的度量。其中 $N_{poi \in P_{ij}}$ 为 $P_{ij}$ 内的大型公共设施数量, $N_{poi}$ 为模型所研究区域内大型公共设施的总数量。

$$\alpha_{ij}^P = \begin{cases} 1 & \text{若 } n^P > 0.3 \\ 0 & \text{其他} \end{cases} \quad (30)$$

其中 $POI$ 为设施点,统计时我们将影响较小的归一化数量 $n^P < 0.3$ 的剔除,避免噪声的影响。最后我们建议在 $V$ 中计算 $\alpha_{ij}^P$ 作为节点 $v_i$ 和 $v_j$ 之间基于兴趣点的交互得分,若节点 $v_i$ 和 $v_j$ 之间的服务区内的设施归一化数量 $n^P > 0.3$ , $\alpha_{ij}^P$ 为1,否则为0。

### 3.3.4 三种空间信息的组合

到目前为止,根据不同的信息源(即地理距离、可达性、兴趣点)得到了不同的交互得分(即 $\alpha_{ij}^D$ 、 $\alpha_{ij}^R$ 、 $\alpha_{ij}^P$ )。接下来要做的就是将不同的信息组合起来,为方便起见,我们将每个节点 $v_i$ 和 $v_j$ 的3个交互分数分组为一个大小为3的向量 $d_{ij} = [\alpha_{ij}^D, \alpha_{ij}^R, \alpha_{ij}^P]$ 。将 $d_{ij}$ 中的分数统一起来形成一个整体 $G$ 中 $v_i$ 和 $v_j$ 的交互得分 $\alpha_{ij}$ ,我们使用以下归一化:

$$\alpha_{ij} = \frac{\exp(d_{ij}\mathbf{1}^T)}{\sum_{j=1}^{N_i} \exp(d_{ij}\mathbf{1}^T)} \quad (31)$$

其中 $\mathbf{1}$ 是全为 1 的 3 维向量,用于将地理距离、可达性、兴趣点的信息聚合。经过归一化过程后节点 $v_i$ 的所有交互得分都转化为 0~1 之间,并且节点 $v_i$ 所有的交互得分之和相加等于 1。依次进行以上操作后,得到邻接矩阵 A 中所有节点之间的交互得分 $\alpha$ ,在这里我们最终获得了多种空间信息的组合交互图 G。将其与停车场车位历史数据同时送入 MGA-GRU 模型我们就可以得到最终的时空预测结果。

### 3.4 MGA-GRU 模型伪代码

---

算法 1 MGA-GRU

---

输入: 车位历史数据X,多视角拓扑图G

输出: 训练好的MGA-GRU模型

```

1: function MINIMIZE(loss =  $\|Y_t - \hat{Y}_t\|^2 + \lambda L_{reg}$ )
2:   for  $i = 1 \rightarrow i = epoch$  do
3:     X and  $H_{t-1}$  get  $\tilde{h}_t$  after  $r_t$  and  $z_t$ 
4:     GA(x):
5:        $e_{ij} = \text{LeakyReLU}(\theta^T \alpha_{ij} [Wx_i \| Wx_j])$ 
6:        $\beta_{ij} = \frac{\exp(e_{ij})}{\sum_{k \in N_i} \exp(e_{ik})}$ ;
7:        $GA(x) = \sigma(\sum_{j \in N_i} \beta_{ij} Wx)$ ;
8:      $\tilde{h}_t = \tanh(W_h [X_t, (r_t \odot h_{t-1})] + b_c)$ ;
9:      $\tilde{h}_t^G = GA(\tilde{h}_t)$ ;
10:     $\hat{h}_t = z_t \odot \tilde{h}_t^G + (1 - z_t) \odot h_{t-1}$ ;
11:     $\vec{h}_t = GA(\hat{h}_t)$ ;
12:    计算 loss;
13:    更新参数;
14:  end for
15: end function
16: 保存模型;
```

---

MGA-GRU 模型的具体训练过程如算法 1 所示,在整个前向传播过程,GA-GRU 单元中每条数据传输线路都经过了 GA 门的处理,同步的进行了时间特征与空间特征的提取。聚合时空信息得到 GA-GRU 单元的最终输出 $\vec{h}_t$ 后,通过一个全连接层获得最终预测结果。最后经过反向传播更新网络参数。多次重复以上过程直至损失值不再变化或达到最大的训练次数后停止训练,最终获得训练好

的 MGA-GRU 模型。

### 3.5 本章小结

本章首先介绍了 MGA-GRU 预测模型中各部分的设计思路及构建方式，包括网络的搭建方式、模型的输入和输出。然后就模型的核心模块 GA-GRU 单元进行了详细论述，包括 GA-GRU 单元的具体构造、图注意力卷积门（GA）的定义与工作原理，并对 MGA-GRU 预测模型所使用的多视角信息图的构建方法进行了阐述。最后介绍了模型所使用的损失函数与模型的伪代码。

## 4 兰州市停车场车位预测实证分析

### 4.1 兰州市停车场建设概况

兰州市位于中国西北地区，是甘肃省省会，也是黄河上游地区的重要城市。它的地理位置十分重要，是连接西北和西南地区的交通要道，也是中亚和欧洲的重要通道。

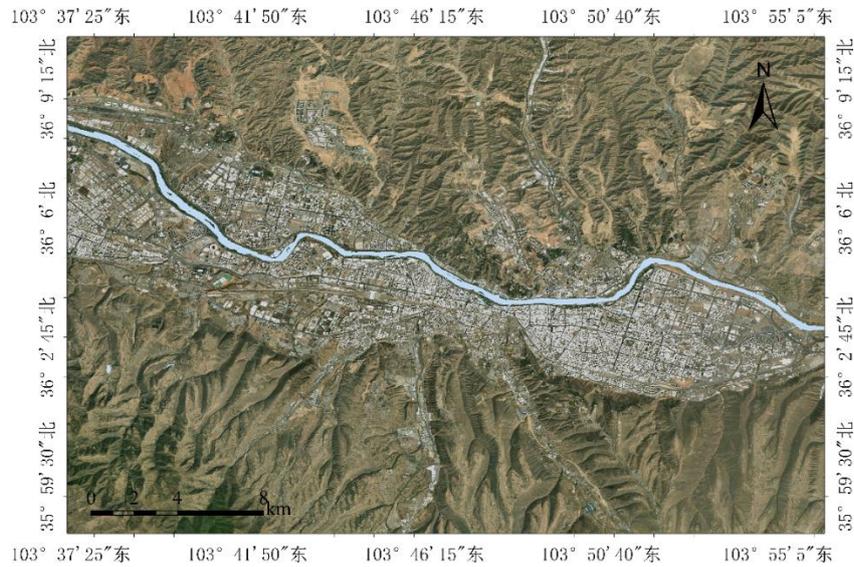


图 4.1 兰州市地形图

如图 4.1 所示，兰州市位于黄河两岸，地形复杂，地势南高北低。南部是连绵的祁连山，北部是宽阔的黄河平原。兰州市境内的山地、丘陵、平原等地貌类型丰富，地形地貌呈现出多样性。此外，兰州市的城市规划布局主要分为南北两个区域，南部是城区，北部是新区。城区位于黄河南岸，是兰州市的中心区域，包括了市中心商业区、政府机关区、文化教育区等。新区位于黄河北岸，是兰州市的发展重心，包括了高新技术产业园区、现代农业示范区等。然而随着城市化进程的不断加速，城市规划布局也存在一些缺陷。首先，城市发展不够均衡，南北两部分之间的发展差距较大，南部城区发展较为成熟，北部新区仍处于建设初期。其次，城市交通不畅，城市路网不够完善，交通拥堵问题较为突出，影响了城市的发展和居民的出行。

根据百度地图联合清华大学、同济大学等机构发布的《2021 年度中国城市交通报告》，2021 年兰州市通勤高峰拥堵指数为 1.5，在百城拥堵排行榜中排名第 37 名，同期全国通勤高峰拥堵指数排名前一百的城市平均水平也为 1.5。这一数据说明，兰州市交通拥堵问题并非孤例，而是一个需要全国范围内共同应对的难题。同时也说明，虽然兰州市与国内其他比较发达的城市在解决交通拥堵方面存在着一定差距，但是兰州市所面临的交通拥堵问题在全国已经比较普遍，研究兰州，能够从侧面了解全国大多数城市的交通拥堵状况。因此，本文接下来通过对兰州市停车场问题进行综合而深入的研究和分析，深入挖掘各种影响停车位的因素，对此进行全面比较和分析，更加准确地了解兰州市市的交通拥堵状况，为兰州市及其他面临交通拥堵的城市提供有针对性的建议。

首先是停车场数量方面。根据兰州市交通运输局 2020 年和 2021 年发布的《兰州市交通运输行业发展统计公报》，截至 2021 年底，兰州市共有各类停车场共计 1188 个，停车位总数为 114500 个。其中，室内停车场 425 个，室外停车场 763 个，停车位分别为 67500 个和 47000 个。而 2021 年兰州市民用汽车拥有量达到了 103.92 万辆，机动车与停车位的比例为 1:0.11，车位供给严重失衡，同其他城市相比，即便是一些经济发展水平与兰州市类似的中西部城市，如郑州、西安等，其停车场数量和停车位数量也都要比兰州市多。这使得兰州市一直面临着因车位缺少而造成的城市拥堵问题。

其次是停车场分布方面。兰州市位于多山环绕的狭长带状地区，整个城市中有五条东西向干道断头于城市交通的“蜂腰”地带，南北向干道也有多条断头路。此外，城市道路交叉中以平面交叉为主，缺少立体交通规划，横跨黄河的桥梁数量少，南北向跨河交通压力大。兰州市特殊的地理环境迫使整个城市在规划时不得不在有限的区域内建设尽可能多的设施，这也更进一步挤压了停车位的建设空间（康琦，2016）。这使得兰州市的停车场绝大部分集中在市区内，且大多分布于商业中心、居民区等人流密集地带，分布不均衡，不能满足广大居民的停车需求，尤其是在旅游景点周边或市郊地区。相比之下，一些发达城市的停车场分布则更为广泛和均衡，能够更好地满足车主停车需求。

最后是停车场设施方面。近年来，兰州市政府加强了对停车场设施建设的管

理和规范,许多停车场已经配备了自助缴费机、智能引导系统等高科技设备,方便了市民和游客的停车体验。但与一些发达城市相比,仍然存在着一一定差距。例如,在一些较为发达的城市,停车场还配备了电动汽车充电桩、自助洗车等服务,满足了车主的多样化需求。

总体而言,由于兰州市停车场数量有限,因此需要通过科学合理的规划和管理手段,提高停车场的利用率和效率。而车位数量预测则是一种重要的方法,能够帮助驾驶者和城市管理者预测未来需求趋势,从而做出更加精准的决策。本文所提出的 MGA-GRU 模型,能够对历史停车数据进行分析 and 挖掘,进而预测未来停车需求量,方便居民进行停车规划和政府制定相应的停车场建设和拓建计划。这样不仅能够缓解停车位紧缺的问题,还可以提高城市管理水平和服务质量。

## 4.2 数据集

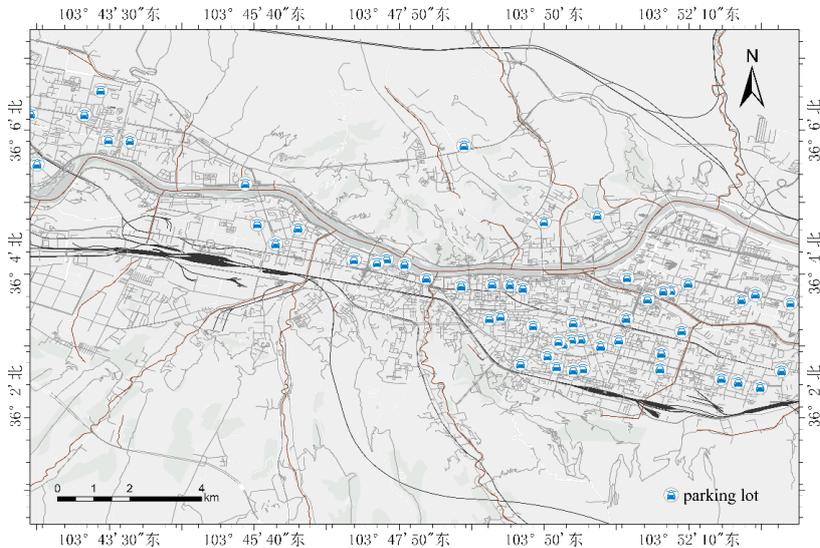


图 4.2 停车场节点分布

本文使用了兰州交通发展建设集团有限公司提供的真实交通数据集,即兰州市停车场数据集,来对各停车场的车位进行预测,数据收集了兰州市 62 个停车场自 2019 年 7 月 1 日到 2020 年 12 月 31 日每小时剩余车位数量数据共 6600 条数据。此外还收集了兰州市的路网、POI 以及停车场经纬度数据集用于构建邻接

矩阵。

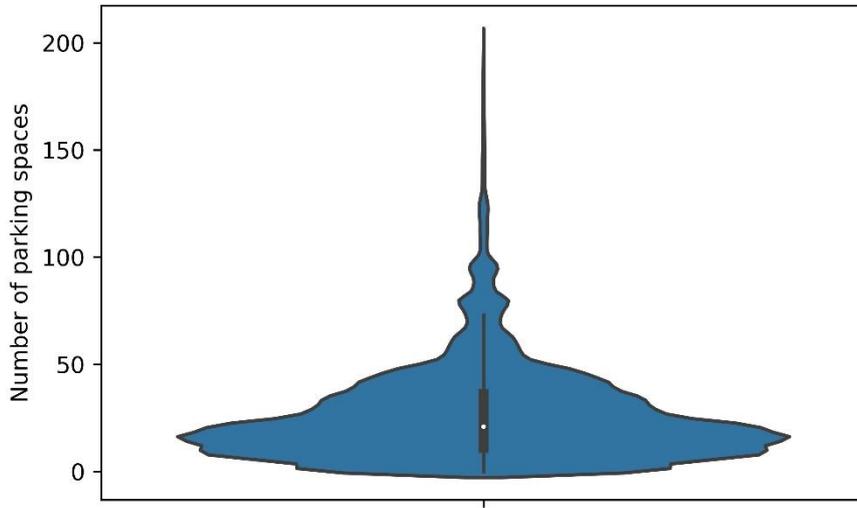


图 4.3 车位数据小提琴图

上图为停车场数据集的小提琴图，可以看出数据呈现非正态分布的形态，大部分数据在 0-60 之间，同时具有极端值。因此在建模前需要对数据进行预处理，去除异常值和极端值，并对缺失值进行插补。本文采用常用的拉伊达法（Liang 等，2020）对异常值与极端值进行剔除，然后对数据归一化处理，最后采用 KNN 算法（Garc 等，2009）对缺失值进行重新插补。

### 4.3 基于兰州市停车场的多视角拓扑图构建

通过对获得的数据集进行处理后，我们可以得到各节点在空间距离、可达性、兴趣点上的交互信息，如下所示：

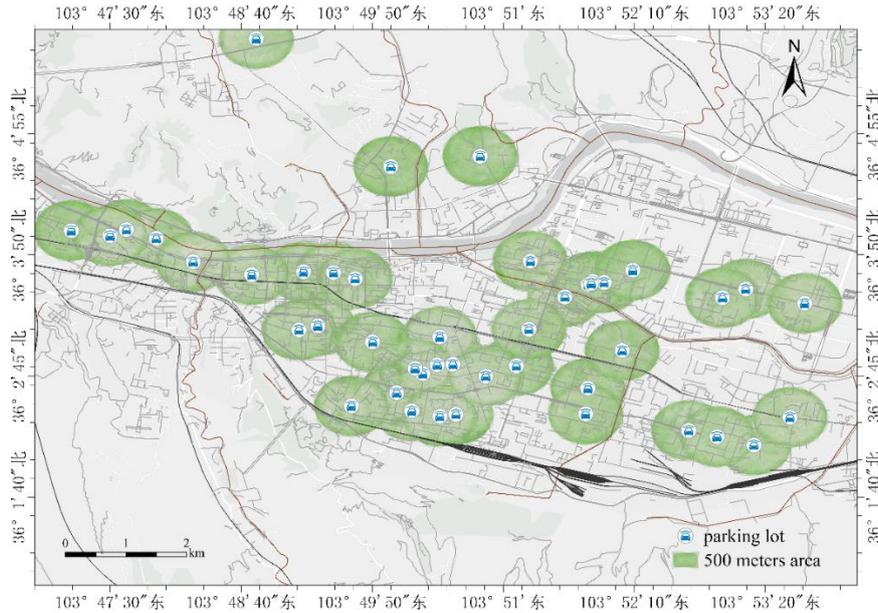


图 4.4 距离关系图

在获取不同停车场之间的空间距离信息 $\alpha_{ij}^D$ 时，根据停车行为的相关研究（孙展等，2018）以及经验，选择阈值  $D=500m$  作为决定节点之间是否连通的依据。如上图所示，蓝色图标表示每个节点，即停车场。蓝色图标周围的绿色区域表示以该停车场为圆心的 500 米区域，若节点  $v_i$ 和 $v_j$ 之间的绿色区域重叠 $\alpha_{ij}^D$ 为 1，否则为 0。

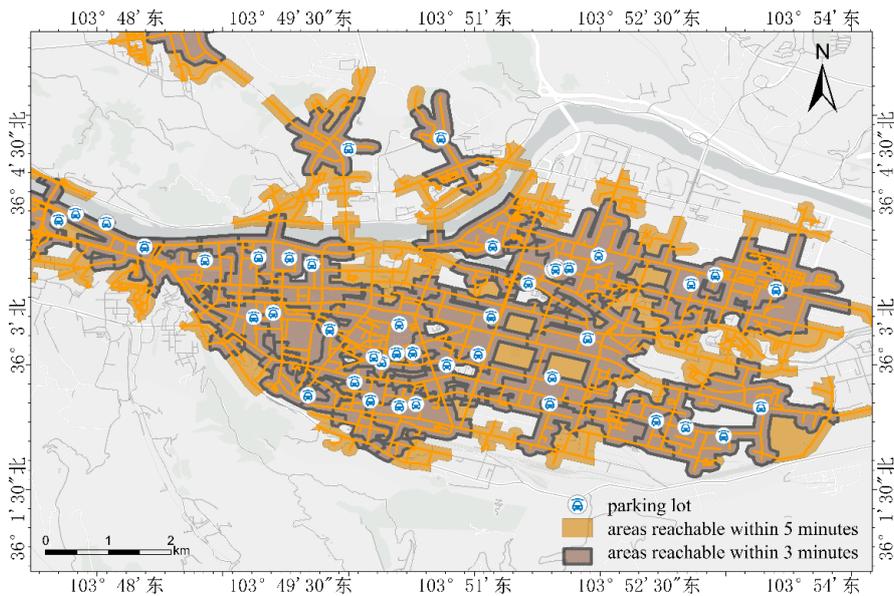


图 4.5 可达性关系图

在获取停车场之间的可达性信息 $\alpha_{ij}^R$ 时,根据相关研究(Lu 等, 2020; Rajabioun 等, 2015; Sisman 等, 2020)和经验选择阈值  $R=5$  分钟作为决定节点之间是否连通的依据。我们画出了每个节点在道路上的可达区域,如上图所示,蓝色图标表示每个节点,即停车场。蓝色图标周围的灰色区域表示该节点在 3 分钟内驾车以 20km/h 的速度在路网中能够到达的区域,黄色区域表示该节点在 5 分钟内驾车以同样的速度在路网中能够到达的区域,若  $R$  以 5 分钟为阈值,节点  $v_i$ 和 $v_j$ 之间的黄色区域重叠 $\alpha_{ij}^R$ 为 1,否则为 0。

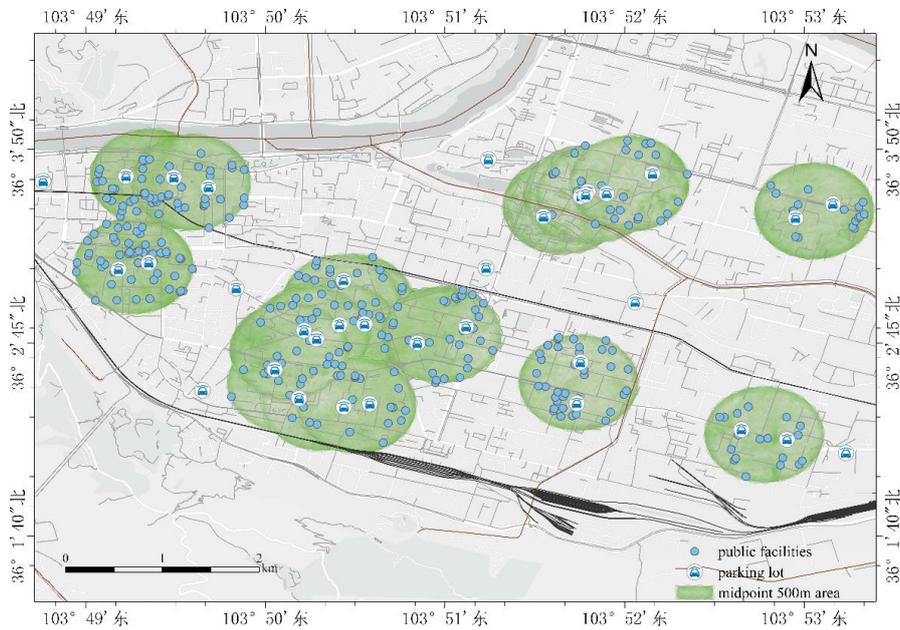


图 4.6 兴趣点关系图

获取停车场之间的兴趣点信息 $\alpha_{ij}^P$ 的具体过程如上图所示,绿色区域为两两停车场节点所处的服务区域  $P$ ,蓝色图标为停车场节点  $V$ ,蓝色圆点为该区域内的兴趣点设施  $POI$ ,我们将在区域  $P$  内  $POI$  的数量的多少作为两节点间相互影响大小的度量,若节点 $v_i$ 和 $v_j$ 之间的服务区内的设施归一化数量 $n^P > 0.3$ , $\alpha_{ij}^P$ 为 1,否则为 0。在图中我们可以看到一些节点如 $v_{50}$ 、 $v_{51}$ 等节点单独存在,是因为这些节点处于与其他节点不能构成半径 500m 的服务区,彼此之间和大型设施构成的供求关系很弱,所以这些节点不存在与其他节点连接的边。

在得到三种不同的空间信息 $\alpha_{ij}^D$ 、 $\alpha_{ij}^R$ 、 $\alpha_{ij}^P$ 后,依据多视角拓扑图的构建方法中的融合方法将以上三种信息融合为一个拓扑图,用于模型预测。

## 4.4 评价指标

为了评估模型的预测性能,基于以下指标评估实际交通速度与预测结果之间的误差

(1) 平均绝对误差 (MAE)

$$MAE = \frac{1}{MN} \sum_{j=1}^M \sum_{i=1}^N |y_i^j - \hat{y}_i^j|$$

(2) 均方根误差 (RMSE)

$$RMSE = \sqrt{\frac{1}{MN} \sum_{j=1}^M \sum_{i=1}^N (y_i^j - \hat{y}_i^j)^2}$$

(3) 判决系数 ( $R^2$ )

$$R^2 = 1 - \frac{\sum_{j=1}^M \sum_{i=1}^N (y_i^j - \hat{y}_i^j)^2}{\sum_{j=1}^M \sum_{i=1}^N (y_i^j - \bar{Y})^2}$$

(4) 对称平均绝对百分比误差 (SMAPE)

$$SMAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{\frac{|\hat{y}_i| + |y_i|}{2}}$$

其中 $y_i^j$ 和 $\hat{y}_i^j$ 分别是停车场节点  $i$  在预测时间间隔  $j$  上的车位数量真实值和预测值。 $N$  是道路上的节点数。 $M$  是时间样本的数量。 $Y$  是 $y_i^j$ 的集合, $\bar{Y}$ 是  $Y$  的均值。采用 RMSE、SMAPE 和 MAE 测量预测误差,其值越小,预测效果越好,反映了较高的预测精度。 $R^2$ 用于计算相关系数,衡量预测结果代表实际数据的能力,值越大,预测效果越好。

## 4.5 参数设置

MGA-GRU 模型的超参数包括学习率、训练次数和隐藏单元的数量。在实验中,学习率和训练次数是根据经验手动设置的,分别为 0.001 和 1000,其余模型参数根据正态分布随机初始化。我们在不同数量的隐藏单元(8、16、32、64、100、128)上测试了模型,并选择了性能最佳的数字 32。在本研究中,使用 80% 的车位数据作为训练集,其余 20% 的数据作为测试集。预测未来 1、2、3 小时

的车位信息。

为了验证模型的有效性,本文将 MGA-GRU 模型的预测结果与以下几种基准模型进行比较。

(1) ARIMA 模型 (Choi, 2012): 自回归综合移动平均模型是传统统计学中预测时间序列使用的非常广泛的模型, 通过一个参数模型进行预测。

(2) LSTM 模型 (Kong 等, 2017): 长短期记忆网络通过遗忘门、更新门、输出门控制信息的传递, 多个门控单元使得 LSTM 模型能够记忆更久远的信息, 同时也缓解了梯度爆炸的问题。

(3) GRU 模型 (Fu 等, 2016): 门控递归单元是 LSTM 的简化版, 通过更新门和重置门控制信息的传递, 参数较 LSTM 少, 效率更高。

(4) T-GCN 模型 (Zhao 等, 2019) : 图卷积网络 (GCN) 和门控递归单元 (GRU) 的组合模型。具体来说, GCN 用于学习复杂的拓扑结构以捕获空间依赖性, 门控循环单元用于学习交通数据的动态变化以捕获时间依赖性。

(5) GAT-GRU 模型 (Wang 等, 2022): 图注意力神经网络 (GAT) 与门控神经单元 (GRU) 的组合模型。

(6) LCNN 模型 (Niu 等, 2018): 基于 CNN 和 LSTM 提出的一种名为 L-CNN 的组合神经网络, 使用卷积神经网络在规则网格中提取空间特征, 使用 LSTM 来提取时间特征。

(7) GAT-GRU 模型 (Cheng qing 等, 2023): 基于图注意力神经网络 (GAT) 与门控递归单元 (GRU) 的一种组合模型, 应用图注意力网络 (GAT) 算法聚合和提取节点的空间特征。然后, 将提取的特征放入门控递归单元 (GRU) 获得预测结果。

通过对各模型的预测结果进行比较, 从精度、时空预测能力、长期预测能力和全局特征捕获能力的角度对 GA-GRU 模型的性能进行了分析。

## 4.6 实验结果与分析

### 4.6.1 多模型结果

表4.1展示了本文提出的MGA-GRU模型与其余6种模型预测未来1、2、3小时车位数量的误差，由于时空模型LCNN模型、T-GCN模型、GAT-GRU模型都是仅考虑空间距离因素的模型，因此MGA-GRU模型为了与这三种模型具有可比性，也划分了基于距离的单一信息拓扑图（1Graph）模型和基于距离、可达性、兴趣点的多视角拓扑图（3Graph）模型，表中的表中黑体加粗指标为最优值。

表 4.1 各模型预测误差

		ARMA	GRU	LSTM	LCNN	T-GCN	GAT-GRU	MGA-GRU (our)	
								1Graph	3Graph
1 小 时	MAE	7.62	4.51	4.26	4.57	3.83	3.81	<b>3.61</b>	<b>3.47</b>
	RMSE	9.36	7.26	6.59	6.67	5.56	5.47	<b>4.92</b>	<b>4.71</b>
	R <sup>2</sup>	-	0.91	0.93	0.94	0.95	0.95	<b>0.96</b>	<b>0.96</b>
	SMAPE (%)	19.96	17.10	14.04	12.99	12.79	12.70	12.99	<b>12.60</b>
2 小 时	MAE	11.76	5.44	4.53	4.96	4.24	4.29	<b>4.06</b>	<b>3.90</b>
	RMSE	14.39	8.59	6.94	7.42	6.28	6.40	<b>5.54</b>	<b>5.35</b>
	R <sup>2</sup>	-	0.88	0.92	0.94	0.94	0.93	<b>0.95</b>	<b>0.95</b>
	SMAPE (%)	29.99	16.71	14.91	<b>13.73</b>	13.96	13.85	14.51	13.98
3 小 时	MAE	13.56	5.72	4.72	5.23	4.44	4.51	<b>4.30</b>	<b>4.16</b>
	RMSE	16.46	9.02	7.28	8.00	6.63	6.87	<b>5.91</b>	<b>5.74</b>
	R <sup>2</sup>	-	0.86	0.91	0.93	0.93	0.92	<b>0.94</b>	<b>0.95</b>
	SMAPE (%)	33.91	17.36	15.40	<b>14.28</b>	14.61	14.46	15.28	14.78

从表4.1中可以看出，本文提出的MGA-GRU模型预测精度较高，不论是单一图模型还是多视角拓扑图模型在3个预测时间尺度上各项评价指标基本达到了最佳的预测效果。

从时间特征建模的角度来说，基于神经网络的模型普遍优于传统的ARMA模型，六种神经网络模型的网络结构中都包含了循环神经网络，此类模型在预测时都充分考虑了时间特征的重要性，利用了序列中的历史信息进行预测，结果更为精确。以1小时预测为例，神经网络模型中表现较差的GRU模型的平均绝对误

差 (MAE)、均方根误差 (RMSE)、对称平均绝对百分比误差 (SMAPE) 比 ARMA 模型分别低了 3.11%、2.1%、2.86%，这是因为车位数据极端值较多，数据的波动大，ARMA 模型很难处理这种非平稳的长趋势数据。再比较单纯的基于时间特征建模的 GRU 与 LSTM 模型，在 3 个时间尺度的预测中，LSTM 模型都略优于 GRU 模型，这可能是因为 LSTM 较 GRU 模型拥有更多的门控单元，对于序列历史信息的提取与处理更加准确，这使得 LSTM 模型在预测中取得了优势。但 GRU 模型的网络参数更少，模型训练较 LSTM 模型更快，这在复杂网络的训练中有着不可忽视的作用。例如 LCNN 模型、T-GCN 模型、GAT-GRU 模型以及本文提出的 MGA-GRU 模型都在网络结构中采用了 GRU 模型或者在 GRU 模型的基础上进行改进。

从时空特征建模的角度来说，LCNN 模型、T-GCN 模型、GAT-GRU 模型以及 MGA-GRU 模型都是基于时空特征的预测模型，较只考虑时间特征的模型，时空模型的预测效果更好。在多个时间尺度的预测中，LCNN 模型全面的优于 GRU 模型，但与 LSTM 预测效果对比时仅在部分指标 (RMSE、 $R^2$ 、SMAPE) 上占据优势，这可能与 LCNN 模型中的卷积网络模块效率不高有关，其余所有的时空预测模型在所有预测指标都优于时间预测模型 GRU 与 LSTM 模型。另外，LCNN 模型、T-GCN 模型、GAT-GRU 模型以及 MGA-GRU 模型构成中都包含了 GRU 的网络结构，这四类模型在多个尺度预测中的各项指标较单纯的 GRU 模型都有所提高，可见加入空间特征后确实提高了模型的预测效果。

横向对比 LCNN 模型、T-GCN 模型、GAT-GRU 模型以及本文的 MGA-GRU 模型这四类时空预测模型，本文提出的 MGA-GRU 模型不论是在单一图模型还是多视角拓扑图模型上各项指标都接近最优。在分析原因时，考虑到影响此类时空模型预测效果的关键因素是对于时空特征的提取与处理是否准确。因此接下来从各时空模型对时空特征的提取与处理两方面进行分析：

#### (1) 空间特征的提取

可以将四种时空模型分为两类，一类是基于卷积神经网络来提取空间特征的 LCNN 模型，另一类是基于图神经网络的 T-GCN 模型、GAT-GRU 模型以及 MGA-GRU 模型。这两类比较，基于图神经网络的 3 种模型在四项指标上基本都优于基于卷积神经网络的 LCNN 模型，原因是 LCNN 中卷积神经网络在提取空间

特征时,将不同节点划分在不同网格中,在规则网格上提取空间特征信息,这使得卷积网络在面对稀疏数据时效率不高。在本例中,62个停车场节点的数据分布在 $50*50$ 的网格中,有效数据仅占2.48%,经过多层卷积后空间特征有可能会缺失,所以,对于这种不规则结构数据提取能力更好的3种图神经网络模型在各预测指标上有更好的表现。此外,在基于距离的单一图网络中,本文提出的MGA-GRU (1Graph)模型在几乎所有指标中都达到了最优,更进一步,在距离的信息的基础上加入了其他空间信息的多视角拓扑图MGA-GRU (3Graph)模型的预测精度又获得了提升,充分证明了MGA-GRU模型网络在相同条件下具有更好的性能,并且多视角融合图确实能够提高模型预测效果。

## (2) 空间特征的处理

LCNN模型、T-GCN模型、GAT-GRU模型都为组合模型,在处理时空数据时是分步进行的,先通过图网络处理序列中的空间信息,再通过循环神经网络处理序列中的时间信息,最后融合时空信息进行预测。这个过程中时空信息的处理是分离的,可能会造成时空信息的相互干扰。基于此,本文的MGA-GRU(1Graph)与其他模型比较时能取得更好预测效果的原因可能是MGA-GRU (1Graph)模型在GRU网络中添加了图注意力卷积门,能够同步的进行时间信息和空间信息的处理,提高了图模型和GRU模型的整合程度,有效避免了时空信息的相互干扰。另外,MGA-GRU (1Graph)模型在聚合节点间的信息时引入了注意力系数,对不同的邻居节点给与不同的权重,这种方式相较GCN网络平等对待各邻居节点更加合理。例如在未来1小时预测中,采用了注意力机制的GAT-GRU组合模型相较没有注意力机制的T-GCN组合模型在平均绝对误差(MAE)、均方根误差(RMSE)分别降低了0.02和0.09,本文提出的注意力机制MGA-GRU (1Graph)整合模型则表现更好,分别降低了0.22和0.64,MGA-GRU (3Graph)则降低了0.36和0.85。

最后为了更好的展示不同模型的预测效果,在测试集中随机挑选一个停车场节点使用窗口滚动的方式预测3天内的车位数量。下图是各模型的预测结果。

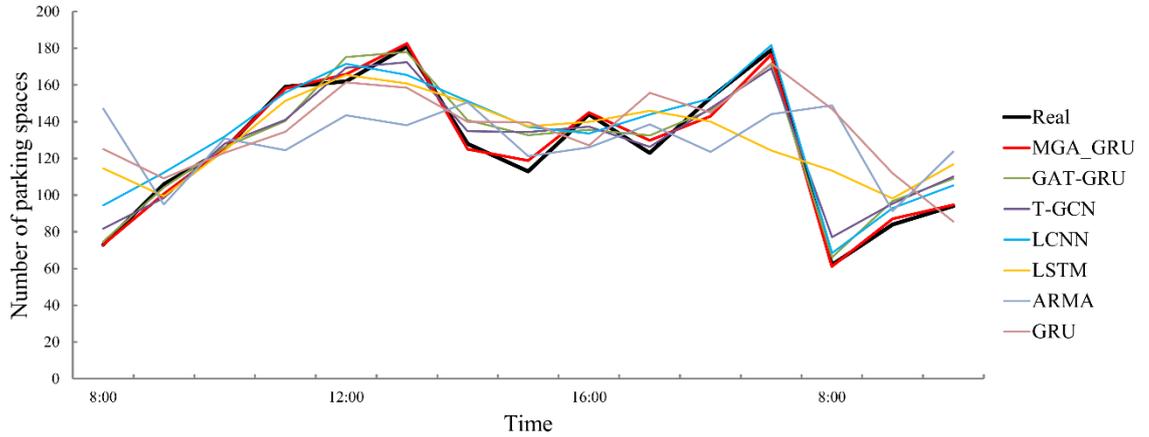


图 4.7 各模型的预测结果

从预测结果可以看出，ARMA模型仅能模拟大致的趋势，且具有一定的滞后性，时间特征模型GRU和LSTM模型虽然对曲线趋势的模拟较为准确，但对于曲线的局部最大/最小值的预测能力不足。时空特征模型LCNN模型、T-GCN模型、GAT-GRU模型对于局部最大/最小值的预测能力有所提升，但可能因为组合模型时空信息之间的相互干扰、卷积网络提取效率不高、或者图网络信息聚合缺少权重等问题，效果依然不如本文提出的MGA-GRU模型。

### 4.6.2 长期预测能力比较

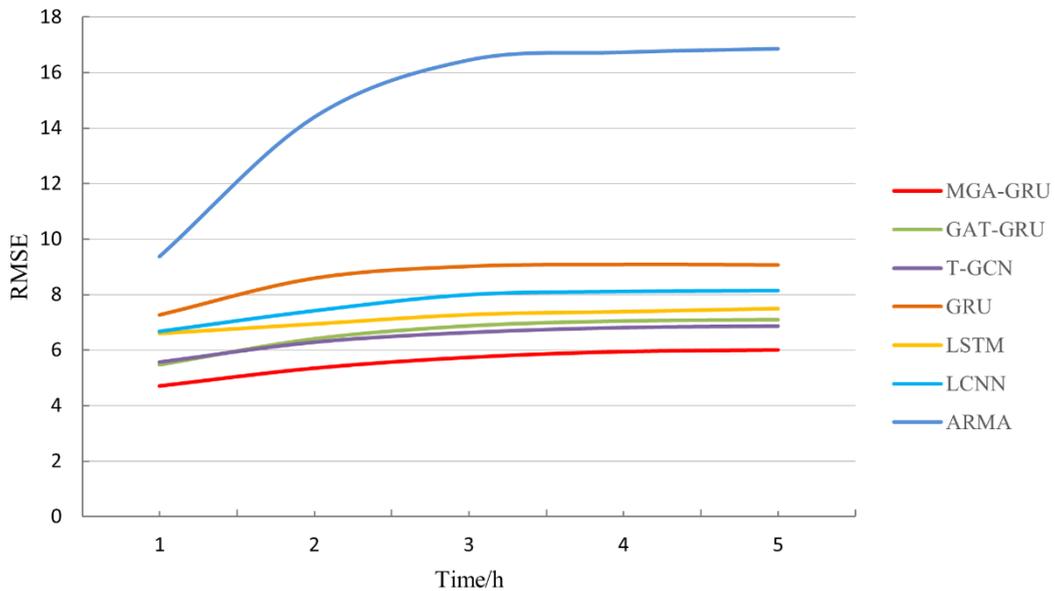


图 4.8 各模型的误差变化趋势

为了比较各模型长期预测能力,将本文提出的多视角拓扑图模型MGA-GRU模型与其他模型采用窗口滚动的方式进行多步预测,比较各模型的长期预测能力的优劣。图4.8展示了不同模型在不同预测步长的情况下,均方根误差(RMSE)的变化情况。

从结果来看,随着预测步长的增加,ARMA模型的整体误差都是所有模型中最大的,而且变化幅度也最大。剩余的机器学习模型中,得益于较多的门控单元,LSTM模型在长期预测中优势较为明显,随着预测步长的增加误差曲线变化幅度最小,但整体误差依然较大,曲线处于较高的位置。其余的模型构成中包含GRU网络结构的LCNN模型、T-GCN模型、GAT-GRU模型以及本文的MGA-GRU模型曲线变化程度都较单纯的GRU模型平缓,说明空间特征的加入提高了模型的长期预测能力。其中,本文提出的MGA-GRU模型随着预测步长的增加,整体误差都是所有模型中最小的,误差曲线位于最低的位置,变化趋势也较为平缓,预测第5个时间步时误差仅比第一个时间步增大了1.29,相比其余的时空预测模型误差增幅少了大约1%-25%,说明本文提出的MGA-GRU模型具有良好的长期预测能力。

### 4.6.3 消融实验

为了验证 MGA-GRU 模型理论的正确性,本节设计了消融实验,通过控制变量的方式,依次去除模型中的各组成模块,研究各模块是否能够提升模型的预测能力。

MGA-GRU 模型的创新点在于采用了新的拓扑图构造方法,融合距离信息、可达性信息、兴趣点信息构造多视角拓扑图,并在模型结构中引入了图注意力卷积门,将图注意力机制与 GRU 模型整合起来,同步的提取与处理时空信息。为了验证以上创新点是否能够提升模型的预测能力,依次将这些部分去除:

(1) MGA-GRU-3G (our): MGA-GRU 模型的完全结构,3G 表示拓扑图具备距离信息、可达性信息和兴趣点信息。

(2) MGA-GRU-2G: 构造拓扑图时去除兴趣点的信息,仅使用距离信息与可达性信息,验证兴趣点信息是否能够提升预测效果。

(3) MGA-GRU-1G: 构造拓扑图时去除兴趣点与可达性信息, 仅使用距离信息, 验证可达性信息是否能够提升预测效果。

(4) GAT-GRU-1G: 构造拓扑图时去除兴趣点与可达性信息, 仅使用距离信息。并且将整合进 GRU 结构的图注意力卷积门拆除, 使用前后结合的方式将注意力机制与 GRU 网络组合起来, 验证 MGA-GRU 将图注意力机制与 GRU 模型整合起来, 同步的提取与处理时空信息是否能够提升预测效果。

(5) GRU: 去除拓扑图构造和相应的图网络结构, 验证空间信息是否能够提升模型预测效果。

表 4.2 消融实验误差对比

模型	MAE	RMSE	R <sup>2</sup>	SMAPE (%)
GRU	4.51	7.26	0.91	17.10
GAT-GRU-1G	3.81	5.47	0.95	12.70
MGA-GRU-1G	3.61	4.92	0.96	12.99
MGA-GRU-2G	3.60	4.89	0.96	12.92
<b>MGA-GRU-3G</b>	<b>3.47</b>	<b>4.71</b>	<b>0.96</b>	<b>12.60</b>

从消融实验的误差对比表的结果来看, 空间特征的加入, 造拓扑图时融入距离信息、可达性信息、兴趣点信息, 并在模型结构中引入了图注意力卷积门, 将图注意力机制与 GRU 模型整合起来, 都有助于提高模型的预测效果。其中空间特征的加入和引入了图注意力卷积门, 将图注意力机制与 GRU 模型整合起来对模型的预测能力提升最多, 分别使得平均绝对误差(MAE)、均方根误差、(RMSE)、下降了 0.7、1.79 和 0.2、0.55, 判决系数 (R<sup>2</sup>) 提升了 0.04 和 0.01。在构造拓扑图时, 可达性信息和兴趣点信息的融入也使得模型预测的平均绝对误差(MAE)、均方根误差 (RMSE)、对称平均绝对百分比误差 (SMAPE) 下降了 0.14、0.21 和 0.39%。

综上所述, 本文提出的 MGA-GRU 模型的各个组成部分都对预测效果有着提升作用, 对于整体缺一不可。

## 4.7 MGA-GRU 预测模型的原型系统开发

### 4.7.1 原型系统介绍

原型系统要解决的主要难点在于驾驶员自身无法知道目标地点附近是否存在停车场,以及到达目标停车场时是否还有车位。而本文所使用的这一套方法能够很好的解决这一难题。因此,我们根据 MGA-GRU 预测模型开发了一个原型系统,能够实时显示目的地的停车场状况。从而协助停车决策者在兰州市更快、更便捷的找到停车位,同时也帮助政府相关部门更好地了解停车场的使用情况,从而更好地安排停车场的管理和维护。

### 4.7.2 系统架构

我们的系统应用使用了模块化的思想进行设计,将系统内的各部分功能分别封装,然后通过后端实现信息交互。设计完成的原型系统由三个部分组成:前端、后端、业务逻辑。其中每一个大的部分中又可以根据不同的使用需求进一步细分为不同的模块,不同的模块具有单独的功能。图 4.9 为系统应用中的三个部分以及对应的模块。

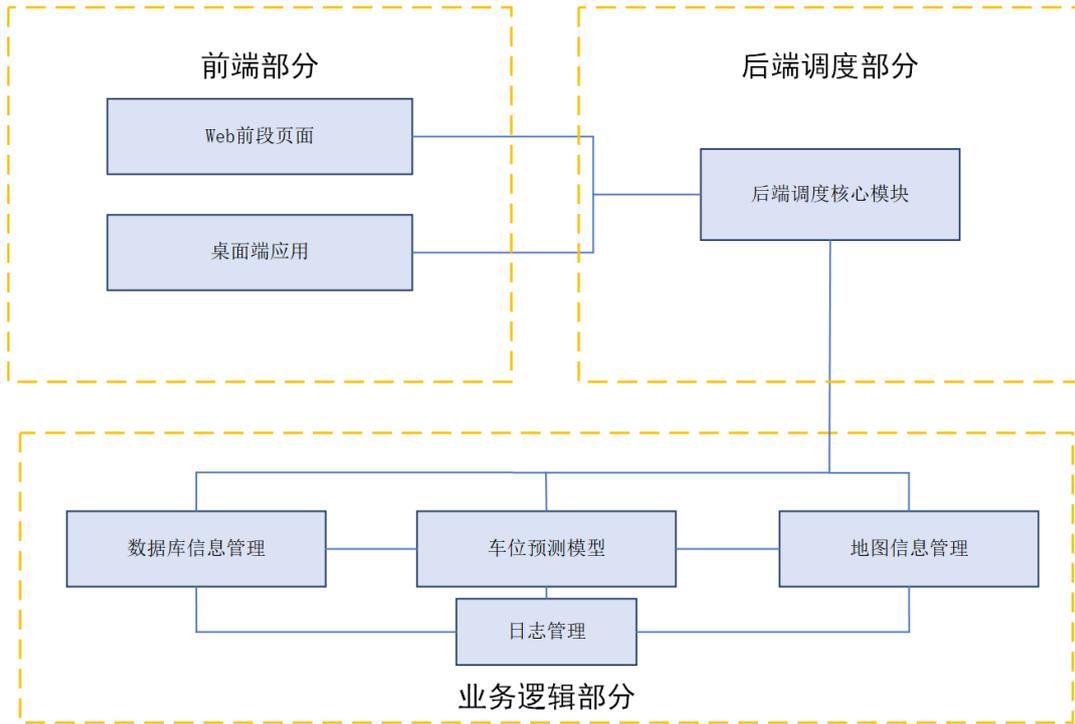


图 4.9 系统架构

其中，系统的逻辑视图主要展示了对象模型。逻辑架构主要用来展示系统的整体结构，系统的组织方式，以及各大模块之间的关联：前端页面调用百度地图的 API 接口，然后将数据传输到数据库并调用预测算法将用户需要查看的停车场及车位预测数据实时进行展示说明，使用户能够迅速找到当前最佳的停车位置，便于用户决策；后端将数据库中的数据进行清洗、整合后运用预测算法进行实时预测并将用户所处地点该时段附近可选范围内的车位预测信息传输给前段进行展示；数据库实时进行数据更新与存储，日志系统可根据历史数据进行溯源、记录系统各模块的运行状况。

### 4.7.3 原型系统整体界面展示

在原型系统的首页展示了三个功能区，如图 4.10 所示，第一个功能区为地图与预测结果的显示区域，展示兰州市的地图，已及相应的停车场的点位和相应车位数量预测信息。第二个功能区为输入区域，此区域为用户目标地点信息、停车场数量信息、以及搜索范围信息的输入区域。当用户输入信息后将与第一个功能区相关联，第一功能区将显示目标地点周围最近的几个停车场在未来预测步长

内的车位数量实时预测值。第三功能区为登录验证功能区，帮助用户进行登录验证以及个性化设置。

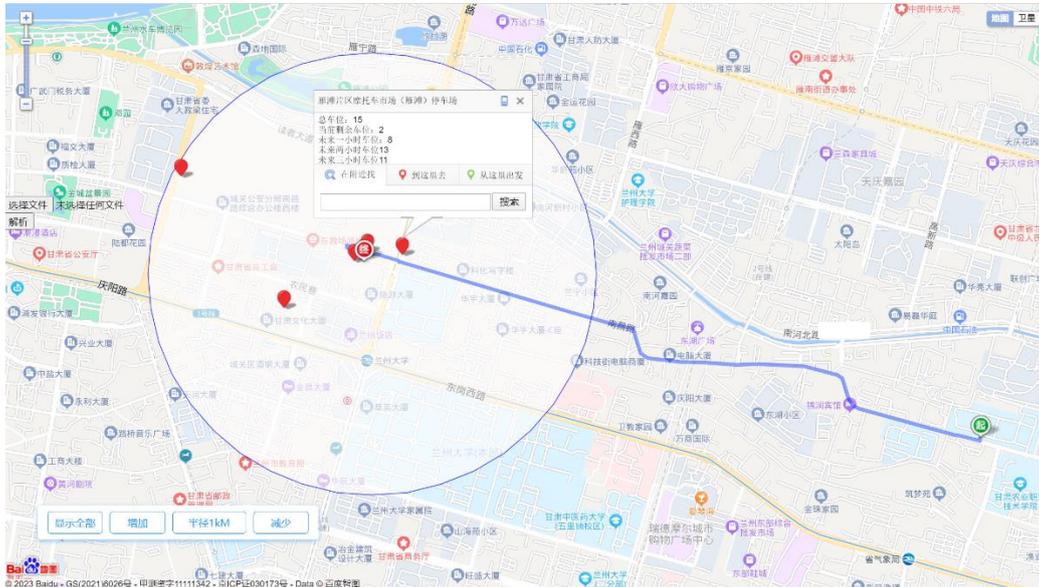


图 4.10 原型系统界面

在上图中展示了一个现实案例，图中展示了假设停车者要从某大学到达盛达中心，可以在地图中搜索盛达中心，系统界面会以圆形区域显示盛达中心 1000 米范围内的停车场，停车者可以依次点击标注的停车场以查看信息，显示的信息包含该停车场当前的停车位数量以及未来 3 小时内停车位数量的预测情况，当用户选择目标停车场后点击到这里去选项，会自动为用户规划最佳停车路线。整个过程力求摒弃复杂的交互逻辑，所见即所得，降低操作门槛。

整个界面的设计考虑到原型系统将面向整个年龄段，对于智能设备的掌握情况不同，所以整个原型系统主要围绕痛点问题开发，摒弃了其他多余功能，尽可能做到简约轻量，简单易用。用户可以在出门前在系统应用中很容易的查询到目标地点的停车场实时状况，以及未来的车位预测情况，帮助用户提高寻找车位的效率并且减少危险因素。

## 4.8 本章小结

本章首先介绍了本文所使用的数据集、多视角拓扑图构建、基准模型以及性

能评估指标。然后通过实验分析,验证了本文 MGA-GRU 预测模型的长短期预测性能以及各个模块的有效性。最后进行了实用性探索,为了能够将模型进行推广并获得更广泛的使用,本文以 MGA-GRU 模型为基础开发了一套车位数量预测应用,开发模型的实用价值。

## 5 总结与展望

### 5.1 研究总结

停车难一直是影响城市发展以及居民幸福的重要因素,由于城市大多数土地已经被开发,增加停车场的数量与面积将不是一个可持续的解决方案,但实施高效的停车管理将是一个切实可行的措施。智能停车系统是高效停车管理的重要组成部分,在智能停车系统中,时效性的车位数量预测对于停车决策者和城市规划者具有重要意义。因此,停车位数量预测是交通系统中一个关键但经常被忽视的要素,它可以平衡各停车场车位占用的情况,减少资源浪费。

本文从时间与空间的角度出发,提出了一种新的组合模型,称为MGA-GRU模型,它对门控循环单元神经网络进行了改造,在其原先只能提取时间信息的两个门控单元的基础上增加了两个图注意力卷积门控单元用于提取空间信息,图注意力卷积门控单元使得模型能够同步的进行时间特征和空间特征的提取与处理,减少时空信息之间的相互干扰,并且引入注意力机制后就可以结合不同节点序列间的注意力系数来对节点的信息进行聚合,使得模型结构更加科学合理。此外,在构造关系图时,融合了多种空间信息构造多视角拓扑图,使空间特征更加全面与准确。两者结合,提高模型的预测效果。

为了验证模型效果,我们在现实的数据集上进行了实验,对兰州市停车场车位数据进行了建模预测,并和目前流行的其他算法进行了对比,对MGA-GRU模型的短期预测能力、长期预测能力和各模块的科学合理性分别设计了实验进行验证,结果表明,MGA-GRU模型网络结构设计较为合理,各子模块对于整个模型来说缺一不可,多种空间信息融合而成的拓扑图也确实能够提高模型的预测效果,MGA-GRU模型无论在短期预测还是长期预测方面都具有令人满意的性能。此外,MGA-GRU模型依赖于城市交通历史信息与空间信息,构建了一个统一的交通预测范式,这使得MGA-GRU模型同样适用于其他地区的车位预测,甚至其他交通预测领域,具有更广的适用性。

最后,本文不仅仅在理论上进行研究,还将MGA-GRU模型应用到了现实场景中,开发了一套原型系统。在应用APP中集成了预测算法,可以在应用中输入

想要到达的目的地，APP可以搜索目的地周围的停车场并智能显示最近的停车场未来一段时间内的车位数量预测值，帮助用户进行停车决策，这套系统能够帮助驾驶者和政府帮助他们更好地规划出行，提高出行效率，更好地管理停车场，节省政府的费用，从而提高停车场的使用效率，以解决现实中的痛点问题。

## 5.2 未来展望

由于现实生活中的数据大多呈现为非规则的关系图，而MGA-GRU模型对于此类数据有很好的处理能力。所以本文所使用的这一套方法不仅仅可以用来预测车位数量，而且对于其他空间因素有着很大影响的预测任务同样有着很好的效果，例如车流量预测、出租车需求预测、充电桩需求预测等。

最后，本文虽然得到了一些研究成果，但就停车场车位数量预测问题的研究而言，依旧存在诸多可拓展之处：

第一、更多的样本特征。由于数据获取、处理等方面的限制，我们并未能够充分利用其他可能存在的特征。未来，随着数据处理技术的不断进步以及相关数据集的不断完善，我们有理由相信可以引入更多的特征来提高预测效果。例如，可以考虑加入天气状况、节假日信息、交通流量等特征，这些特征都可能对停车预测产生积极影响。通过引入更多的特征，我们期待能够进一步提高停车预测模型的准确性与可靠性，构建更广义的“多视角”数据融合预测模型，为城市出行带来更好的体验。

第二、简化模型结构。目前停车预测模型在计算效率方面存在一些挑战，这主要是由于数据量大且特征复杂、计算资源不足等客观因素所致。未来，我们可以通过更好的算法设计和技术提升来提高模型效率。例如，可以使用更加先进的深度学习框架，减少模型参数量和计算量，从而优化模型的计算效率。此外，还可以通过硬件设备的优化，如GPU并行计算、TPU加速等方法来提升模型训练的速度。通过这些技术手段的应用，我们有信心能够在未来进一步提高停车预测模型的计算效率和性能，为实际应用带来更多的便利和价值。

## 参考文献

- [1] Abbasimehr H, Shabani M, Yousefi M. An optimized model using LSTM network for demand forecasting[J]. Computers & industrial engineering, 2020, 143: 106435.
- [2] Ahmed M S, Cook A R. Analysis of freeway traffic time-series data by using Box-Jenkins techniques[M]. Transportation Research Board, 1979.
- [3] Amara-Ouali Y, Goude Y, Massart P, et al. A review of electric vehicle load open data and models[J]. Energies, 2021, 14(8): 2233.
- [4] Balmer M, Weibel R, Huang H. Value of incorporating geospatial information into the prediction of on-street parking occupancy--A case study[J]. Geospatial Information Science, 2021, 24(3): 438-457.
- [5] Chen Z, Zhao B, Wang Y, et al. Multitask learning and GCN-based taxi demand prediction for a traffic road network[J]. Sensors, 2020, 20(13): 3776.
- [6] Chengqing Y, Guangxi Y, Chengming Y, et al. A multi-factor driven spatiotemporal wind power prediction model based on ensemble deep graph attention reinforcement learning networks[J]. Energy, 2023, 263: 126034.
- [7] Choi B. ARMA model identification[M]. Springer Science & Business Media, 2012.
- [8] Chu F. Forecasting tourism demand with ARMA-based methods[J]. Tourism Management, 2009, 30(5): 740-751.
- [9] Cui Z, Henrickson K, Ke R, et al. Traffic graph convolutional recurrent neural network: A deep learning framework for network-scale traffic learning and forecasting[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 21(11): 4883-4894.
- [10] Dou Y, Liu Z, Sun L, et al. Enhancing graph neural network-based fraud detectors against camouflaged fraudsters[J]. Proceedings of the 29th ACM International Conference on Information & Knowledge Management, 2020: 315-324.

- [11] Fu R, Zhang Z, Li L. Using LSTM and GRU neural network methods for traffic flow prediction[J]. 2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC) IEEE, 2016: 324-328.
- [12] Garc I A-Laencina P J, Sancho-G O Mez J E L, Figueiras-Vidal A I B R, et al. K nearest neighbours with mutual information for simultaneous classification and missing data imputation[J]. Neurocomputing, 2009, 72(7-9): 1483-1493.
- [13] Gupta A, Dhingra B. Stock market prediction using hidden markov models[J]. 2012 Students Conference on Engineering and Systems IEEE, 2012: 1-4.
- [14] H U Ttel F B, Peled I, Rodrigues F, et al. Deep Spatio-Temporal Forecasting of Electrical Vehicle Charging Demand[J]. arXiv, 2021.
- [15] Hamed M M, Al-Masaeid H R, Said Z M B. Short-term prediction of traffic volume in urban arterials[J]. Journal of Transportation Engineering, 1995, 121(3): 249-254.
- [16] Hansen W G. How accessibility shapes land use[J]. Journal of the American Institute of planners, 1959, 25(2): 73-76.
- [17] Hsu C, Guo J, Yen Y, et al. A mobile application system based on time series forecasting for selecting parking lots[J]. 2018 IEEE International Conference on Applied System Invention (ICASI), 2018: 811-813.
- [18] Hung B T, Chakrabarti P. Parking lot occupancy detection using hybrid deep learning CNN-LSTM approach[J]. Proceedings of 2nd International Conference on Artificial Intelligence: Advances and Applications: ICAIAA, 2022: 501-509.
- [19] Ip A E, Irio L, Oliveira R. Vehicle trajectory prediction based on LSTM recurrent neural networks[J]. 2021 IEEE 93rd Vehicular Technology Conference (VTC2021-Spring), 2021: 1-5.
- [20] Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks[J]. arXiv preprint arXiv:1609.02907, 2016.

- [21] Kong W, Dong Z Y, Jia Y, et al. Short-term residential load forecasting based on LSTM recurrent neural network[J]. IEEE Transactions on Smart Grid, 2017, 10(1): 841-851.
- [22] Lee J, Lin C. Model selection for support vector machines via uniform design[J]. Computational Statistics & Data Analysis, 2007, 52(1): 335-346
- [23] Liang R, Chang X, Jia P, et al. Mine gas concentration forecasting model based on an optimized BiGRU Network[J]. ACS omega, 2020, 5(44): 28579-28586.
- [24] Lu E H, Liao C. Prediction-based parking allocation framework in urban environments[J]. International Journal of Geographical Information Science, 2020, 34(9): 1873-1901.
- [25] Ma X, Dai Z, He Z, et al. Learning traffic as images: a deep convolutional neural network for large-scale transportation network speed prediction[J]. Sensors, 2017, 17(4): 818.
- [26] Niu K, Cheng C, Chang J, et al. Real-time taxi-passenger prediction with L-CNN[J]. IEEE Transactions on Vehicular Technology, 2018, 68(5): 4122-4129.
- [27] Phu M T, Nguyen T H. Graph convolutional networks for event causality identification with rich document-level structures[J]. Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2021: 3480-3490.
- [28] Rajabioun T, Ioannou P A. On-street and off-street parking availability prediction using multivariate spatiotemporal models[J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(5): 2913-2924.
- [29] Sisman S, Aydinoglu A C. Using GIS-based multi-criteria decision analysis techniques in the smart cities[J]. International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences, 2020: 383-389.
- [30] Sun W, Zhang H, Palazoglu A, et al. Prediction of 24-hour-average PM2.

5 concentrations using a hidden Markov model with different emission distributions in Northern California[J]. *Science of the total environment*, 2013, 443: 93-103.

[31] Sun W, Sun J. Daily PM<sub>2.5</sub> concentration prediction based on principal component analysis and LSSVM optimized by cuckoo search algorithm[J]. *Journal of environmental management*, 2017, 188: 144-152.

[32] Tokg O Z A, U Nal G O Z. A RNN based time series approach for forecasting turkish electricity load[J]. 2018 26th Signal processing and communications applications conference (SIU), 2018: 1-4.

[33] Tranmer M, Elliot M. Multiple linear regression[J]. *The Cathie Marsh Centre for Census and Survey Research (CCSR)*, 2008, 5(5): 1-5.

[34] Velickovic P, Cucurull G, Casanova A, et al. Graph attention networks[J]. *stat*, 2017, 1050: 20.

[35] Wang D, Lin J, Cui P, et al. A semi-supervised graph attentive network for financial fraud detection[J]. 2019 IEEE International Conference on Data Mining (ICDM), 2019: 598-607.

[36] Wang S, Qiao L, Fang W, et al. Air Pollution Prediction Via Graph Attention Network and Gated Recurrent Unit[J]. *Computers, Materials and Continua*, 2022, 73(1): 673-687.

[37] Xiao X, Jin Z, Hui Y, et al. Spatial-Temporal Graph Convolutional Networks for Parking Space Prediction in Smart Cities[J]. 2021 IEEE 94th Vehicular Technology Conference (VTC2021-Fall), 2021: 1-5.

[38] Xiao X, Jin Z, Hui Y, et al. Hybrid spatial--temporal graph convolutional networks for on-street parking availability prediction[J]. *Remote Sensing*, 2021, 13(16): 3338.

[39] Yang H, Jiang Z, Lu H. A hybrid wind speed forecasting system based on a 'decomposition and ensemble' strategy and fuzzy time series[J]. *Energies*, 2017, 10(9): 1422.

- [40] Yang S, Ma W, Pi X, et al. A deep learning approach to real-time parking occupancy prediction in transportation networks incorporating multiple spatio-temporal data sources[J]. *Transportation Research Part C: Emerging Technologies*, 2019, 107: 248-265.
- [41] Yip C, Others. Time-series forecasting of foreign exchange rates using recurrent neural networks: a comparative study with statistical models[J]. Hong Kong Polytechnic University, 1998.
- [42] Yu B, Yin H, Zhu Z. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting[J]. *arXiv preprint arXiv:1709.04875*, 2017.
- [43] Zhang X, Huang C, Xu Y, et al. Spatial-temporal convolutional graph attention networks for citywide traffic flow forecasting[J]. *Proceedings of the 29th ACM international conference on information & knowledge management*, 2020: 1853-1862.
- [44] Zhao L, Song Y, Zhang C, et al. T-gcn: A temporal graph convolutional network for traffic prediction[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 21(9): 3848-3858.
- [45] Zhou Y, Chang F, Chang L, et al. Multi-output support vector machine for regional multi-step-ahead PM<sub>2.5</sub> forecasting[J]. *Science of the Total Environment*, 2019, 651: 230-240.
- [46] 顾默,赵兵,陈昊. 基于时间卷积网络与图注意力网络的分行业日售电量预测方法[J]. *电网技术*, 2022(04): 1287-1297.
- [47] 黄恒君,王伟科. 基于深度学习的PM<sub>2.5</sub>多模态集成预测应用[J]. *统计学报*, 2020(02): 39-47.
- [48] 康琦. 兰州交通规划研究初探[J]. *工业建筑*, 2016(10): 47-50.
- [49] 李林波,高天爽,姜屿. 基于生存分析的夜间驻留停车需求预测[J]. *东南大学学报(自然科学版)*, 2020(01): 192-199.
- [50] 李盼道,李洋. 停车产业化发展的现状及其动力机制研究[J]. *新疆大学学报*

- (哲学·人文社会科学版), 2019(01): 1-15.
- [51] 李王鸣,江勇,徐诚瑞. 基于个人行为选择视角的社会停车场优化措施研究——以浙江省衢州市中心城区为例[J]. 经济地理, 2012(07): 63-68.
- [52] 马书红, 等. 基于可达性的城市群交通网络公平性分析[J]. 交通运输系统工程与信息, 2022: 1-11.
- [53] 孙展,戴冀峰. 停车泊位共享可行性时空量化分析方法与应用[J]. 2018中国城市规划年会, 2018: 740-748.
- [54] 谭文安,刘新乐. 基于集成学习的城市空间停车难度预测[J]. 上海第二工业大学学报, 2019(01): 53-60.
- [55] 田金欢, 等. 昆明中心城区公共服务设施边界研究[J]. 华中建筑, 2022(04): 138-144.
- [56] 王宏国. 全域智慧停车产业生态研究[J]. 中国物业管理, 2021(12): 100-104.
- [57] 魏成,陈赛男,沈静. 人工智能驱动下的城市空间演变趋势与规划响应[J]. 城市发展研究, 2022(07): 47-54.
- [58] 吴德华, 等. 大城市客运中心社会停车场配建指标研究[J]. 重庆交通学院学报, 2005(03): 125-128.
- [59] 奚桂锴. 基于时空语义图神经网络的城市面域交通流预测方法[D]. 中国科学院大学(中国科学院深圳先进技术研究院), 2021.

## 致谢

研途三年，如梦如幻。时光荏苒，转眼间，我已经走过了这段求学之路。在这三年的时间里，我经历了许多，有喜有忧，有收获也有失落，也遇到了许多需要我永远铭记和感谢的人。

感谢我的家人。他们总是在背后默默支持和鼓励我，给与我无微不至地关心和照顾，让我在学业上没有后顾之忧。他们的爱和支持是我前进的动力，让我能够勇往直前，不断追求自己的梦想。愿你们身体健康，万事如意。

感谢我的导师黄恒君老师。他不仅是我的导师，更是我的良师益友。每当我遇到困难和瓶颈时，他总是能够及时给我指明方向和提供帮助，让我能够顺利地完成研究工作。在我的论文写作中，黄老师给予了我很多宝贵的建议和指导。他经常和我一起讨论论文和代码，帮助我理清思路，找到问题的解决方案，在这个过程中，我深刻地感受到了黄老师丰富的经验和专业的知识，他的指导让我受益匪浅。除了在研究方面给予我帮助外，黄老师还时时关心我们的生活和健康。在疫情期间，他时刻关注我们的情况，给我们提供了很多实用的建议和帮助，让我们倍感温暖和感动。在这里，衷心祝愿老师与师母身体健康、工作顺利、阖家幸福。

感谢我的舍友和同学们。他们是我求学之路上最好的伙伴和朋友。我们一起经历了许多，一起学习、一起调研，一起分享喜悦和忧愁。他们的陪伴和支持，让我在求学之路上更加坚定和自信。衷心希望你们能在人生的下个阶段取得更高的成就。

即将离开母校，开始新的人生旅程，这段宝贵的经历我将永远铭记在心。感恩母校、感恩各位师长、感恩家人和朋友们的支持和帮助。我将继续努力，不忘初心，砥砺前行，为实现自己的梦想而努力奋斗！