

FCTNet:基于双域深度学习的公交车到站时间预测方法

张铭泽, 李轶, 吴文渊, 石明全, 王正江

引用本文

张铭泽, 李轶, 吴文渊, 石明全, 王正江. FCTNet:基于双域深度学习的公交车到站时间预测方法[J]. 计算机科学, 2024, 51(11A): 231000180-7.

ZHANG Mingze, LI Yi, WU Wenyuan, SHI Mingquan, WANG Zhengjiang. FCTNet:Bus Arrival Time Prediction Method Based on Dual Domain Deep Learning [J]. Computer Science, 2024, 51(11A): 231000180-7.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于CNN结合BiGRU的恶意流量分类算法研究](#)

Study on Malicious Traffic Classification Algorithm Based on CNN Combined with BiGRU
计算机科学, 2024, 51(11A): 231100106-9. <https://doi.org/10.11896/jsjcx.231100106>

[MB-ATMK:融合属性权重和时序元知识的多行为序列推荐模型](#)

MB-ATMK:Multi-behavior Sequential Recommendation Integrating Attribute Weights and Temporal Meta-knowledge
计算机科学, 2024, 51(11A): 231100047-9. <https://doi.org/10.11896/jsjcx.231100047>

[基于季节分解的混合神经网络的时间序列预测](#)

Time Series Prediction of Hybrid Neural Networks Based on Seasonal Decomposition
计算机科学, 2024, 51(11A): 231200008-7. <https://doi.org/10.11896/jsjcx.231200008>

[基于相对位置编码转换器模块的深度步态识别网络](#)

Deep Gait Recognition Network Based on Relative Position Encoding Transformer
计算机科学, 2024, 51(11A): 240400064-6. <https://doi.org/10.11896/jsjcx.240400064>

[基于改进超像素采样的立体匹配网络](#)

Stereo Matching Network Based on Enhanced Superpixel Sampling
计算机科学, 2024, 51(11A): 231100005-7. <https://doi.org/10.11896/jsjcx.231100005>

FCTNet:基于双域深度学习的公交车到站时间预测方法

张铭泽^{1,2} 李轶¹ 吴文渊¹ 石明全¹ 王正江³

1 中国科学院重庆绿色智能技术研究院自动推理与认知重庆市重点实验室 重庆 400714

2 中国科学院大学重庆学院 重庆 400714

3 重庆市公共交通控股集团凤筑科技有限公司 重庆 401120

(zhangmingze21@mails.ucas.ac.cn)

摘要 公交车到站时间预测是智能公交系统的重要组成部分,可以给乘客提供精确的到站时间,还可以帮助调度员进行更合理的调度安排。为此,提出一种基于卷积、注意力机制和FFT的对时域和频域进行双域深度学习的公交车到站时间预测算法FCTNet(FFT-Conv-Transformer),该算法融合了傅里叶变换、卷积神经网络和注意力机制,其可以对公交车单站和多站的到站时间进行预测。其中利用傅里叶变换和卷积神经网络在频域上学习输入数据的时空特征,同时保留时域信号,利用注意力机制学习输入序列的全局依赖关系,预测最终结果。在重庆市465,506和262这3条公交线路到站时间预测实验中,FCTNet网络模型的平均绝对百分比误差和平均绝对误差优于实验对比算法,在最繁忙的465线路中FCTNet网络模型的平均相对误差相对已有最好模型降低了2.34%,平均绝对误差降低了4.59s。

关键词:到站预测;注意力机制;时域频域转换;卷积神经网络;深度神经网络

中图分类号 TP183

FCTNet:Bus Arrival Time Prediction Method Based on Dual Domain Deep Learning

ZHANG Mingze^{1,2}, LI Yi¹, WU Wenyuan¹, SHI Mingquan¹ and WANG Zhengjiang³

1 Chongqing Key Laboratory of Automated Reasoning and Cognition, Chongqing Institute of Green and Intelligent Technology, Chinese Academy of Science, Chongqing 400714, China

2 Chongqing School, University of Chinese Academy of Sciences, Chongqing 400714, China

3 Fengzhu Technology Co., Chongqing Public Traffic Holdings Group, Chongqing 401120, China

Abstract Bus arrival time prediction is an important part of the smart bus system. It can provide passengers with accurate arrival time and help dispatchers make more reasonable scheduling arrangements. A bus arrival time prediction algorithm FCTNet(FFT-Conv-Transformer) based on convolution, attention mechanism and FFT is proposed for dual-domain deep learning of time domain and frequency domain. The algorithm integrates Fourier transform, convolutional neural network and attention mechanism to predict bus arrival times at single stops and multiple stops. Among them, Fourier transform and convolutional neural network are used to learn the spatiotemporal characteristics of the input data in the frequency domain while retaining the time domain signal. The attention mechanism is used to learn the global dependence of the input sequence and predict the final result. In the arrival time prediction experiment of three bus lines 465, 506 and 262 in Chongqing, the average absolute percentage error and average absolute error of the FCTNet network model are better than the experimental comparison algorithm. In the busiest bus No. 465, the average relative error of the FCTNet network model is better than that of the experimental comparison algorithm. Compared with the existing best model, it is reduced by 2.34%, and the average absolute error is reduced by 4.59s.

Keywords Arrival forecast, Attention mechanism, Time-frequency transformation, Convolution neural network, Deep neural network

1 引言

公交车到站时间预测不仅可以提高公交服务质量,吸引乘客选择公交出行,而且可以提高车辆运行效率,为车辆调度和管理提供决策依据。

公交车到站时间预测有很多代表性方法,从技术方面可

以分为6类:基于历史数据平均^[1-3]、基于卡尔曼滤波^[4-6]、基于支持向量机^[7-8]、时间序列回归^[9]、基于神经网络^[10-11]和组合模型^[12-15]。例如,Xu等^[1]用聚类方法来估计不同时隙各路径区段上的出行时间分布,形成路径截面图,根据路径截面图和实时GPS信息预测公交到达时间。Celan等^[3]在历史数据模型研究中将公交网络考虑在内,充分考虑公交车运行的

基金项目:重庆市院士牵头科技创新引导专项(cstc2020yszx-jcyjX0005, cstc2021yszx-jcyjX0005, cstc2022YSZX-JCX0011CSTB)

This work was supported by the Chongqing Academician-led Science and Technology Innovation Guidance Special Project (cstc2020yszx-jcyjX0005, cstc2021yszx-jcyjX0005, cstc2022YSZX-JCX0011CSTB).

通信作者:李轶(zm_liyi@163.com)

时间特性和空间特性,增强了预测模型的鲁棒性。Wang等^[5]在卡尔曼滤波模型中加入“遗忘因子”,消减久远数据的影响,提高了卡尔曼滤波模型的适应性。Yin等^[7]提出了一种基于支持向量机和人工神经网络的时间预测模型,用于预测多路线目标站点的公交车到达时间。Comi等^[9]将时间序列常用的自回归综合移动平均模型和基于季节的回归模型应用到公交到站时间预测。Petersen等^[10]使用卷积神经网络和长短期记忆神经网络对城市公交网络中存在的非静态时空相关性进行学习。Mazloumi等^[11]利用人工神经网络构建预测区间和量化每个不确定性源对总预测的不同贡献程度,提升了预测的鲁棒性。Bai等^[12]基于支持向量机和卡尔曼滤波,提出了一种适用于多条公交线路的公交车动态行驶时间预测模型,支持向量机模型根据历史公交出行数据预测基线公交出行时间,基于卡尔曼滤波的动态算法可以利用最新的公共汽车运行信息和估计的基线行驶时间来调整公共汽车行驶时间。Liu^[13]建立了一种基于门控循环单元和卡尔曼滤波的组合模型,门控循环单元利用历史数据得到基础时间到站序列,卡尔曼滤波利用公交车行驶过程中获取的实时信息,对到站时间的预测结果进行修正。Lai等^[14]将卷积神经网络和长短期记忆神经网络进行融合以对公交车辆的时空特征进行学习,实现对公交车辆全程花费时间的预测。Zhang等^[15]将公交运营时间进行切片处理,通过建立长短期记忆神经网络对公交车辆时空特征进行学习,实现对城市公交车的时间预测。

现有的公交车到站时间预测方法中,历史数据平均模型和传统的时间序列模型的实时性差,适合非高峰期的预测。支持向量机和人工神经网络可以解决非线性的问题,但网络结构简单,实时性预测差。卡尔曼滤波模型可以解决高维问题,实时性好,但针对不同输入特征对预测结果的影响,学习效果有限。门控循环单元和长短期记忆神经网络等循环神经网络对序列数据的学习只能按照顺序进行,不能很好地学习到输入序列之间的关系。

公交车到站时间预测存在时间和空间两方面的特点。从时间的角度看,公交车站点停留时间和站间运行时间都具有一定的时间规律,这种规律包括长期的历史规律,短期的周期规律和波动规律等。从空间的角度看,不同的站间道路有各自的空间特征:道路的等级、红绿灯的个数、距离等。本文从时间和空间两个方面对输入特征进行了细致的分析和挖掘。在

模型设计方面,卷积神经网络模型在空间特征提取方面有很好的效果,而基于注意力机制的 transformer 模型^[16]在序列数据学习中也有良好的表现,可以更好地从全局学习时间序列。在传统的信号处理中,傅里叶变换将时域信号转换成频域信号,有助于学习到信号的信息,过滤数据中的噪声。因此本文将傅里叶变换、卷积神经网络和 transformer 进行融合,提出 FCTNet(FFT-CNN-Transformer)深度学习算法,可以从时域和频域两个角度更好地学习挖掘到的时空特征,对公交车单个站的到站时间和多个站的到站时间进行更加准确的预测。

本文第 2 章介绍了 FCTNet 模型;第 3 章介绍了数据挖掘;第 4 章展示所提算法与其他算法进行对比实验的结果;最后总结全文。

2 FCTNet 算法

2.1 问题的定义

本文将公交车到站时间预测问题归结为时间序列预测问题^[17],按照发车顺序和公交车站的顺序进行数据收集,得到时间序列:

$$X = \begin{bmatrix} x_{11} & \cdots & y_1 \\ \vdots & \ddots & \vdots \\ x_{n1} & \cdots & y_n \end{bmatrix}$$

X 中每一行是某辆车在两个相邻车站之间的数据, x_{ij} 是本文手工挖掘到的特征, y_i 是真实花费时间。按照发车班次,将某班车全程所有两站之间的数据按序排列之后,接着排列下一班车的两站之间的数据。本文输入时间窗口大小为 h 即输入历史长度为 h 的时间序列,对接下来的时间序列进行预测,设输入序列 $X \in R^{h \times n}$,经过深度学习算法 F ,得到接下来 m 个窗口真实值的预测序列 Y' ,即:

$$Y' = F(X), Y' \in R^{m \times 1}$$

当 $m=1$ 时,该算法是对车辆到下一个站点所需时间的预测,当 $m>1$ 时,是对车辆到达接下来的 m 个站点之间各需要花费时间的预测。如果 m 的长度超过了该预测车辆到终点站的站间数量,则超出的部分为下一班车从首站出发的几个站间花费时间的预测。

2.2 FCTNet 算法框架

本文提出神经网络算法 FCTNet 包含傅里叶变换、卷积神经网络、逆傅里叶变换和基于注意力机制的时间序列预测模块 4 个部分,如图 1 所示。

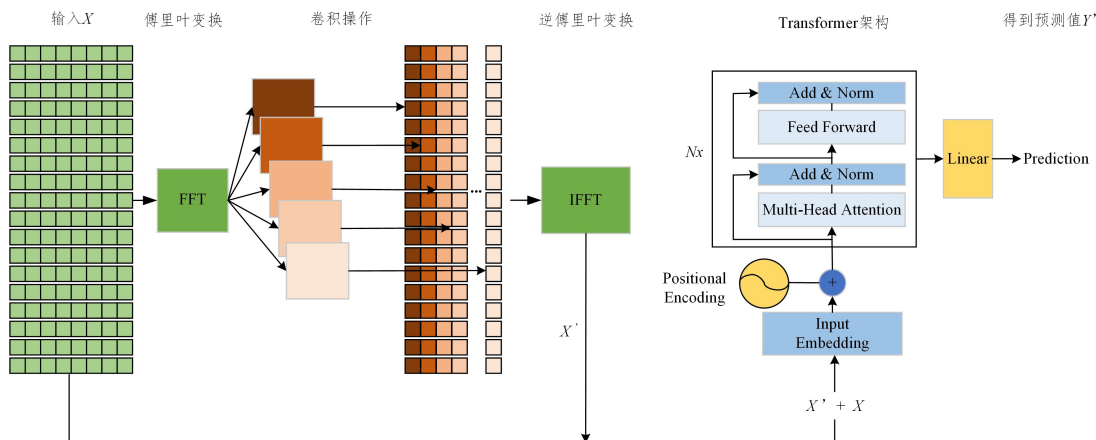


图 1 FCTNet 网络架构图

Fig. 1 Diagram of FCTNet network architecture

FCTNet的设计考虑到时空数据通常包含时间和空间的信息,在时域频域信号转换的过程中,应用傅里叶变换将时域数据转换为频域表示,以更好地捕捉信号的周期性和频谱信息。这样的转换有助于提取更丰富的特征并减少冗余信息。同时,引入卷积神经网络来处理空间维度的数据,因其在计算机视觉领域表现出色,能够有效地处理空间信息,所以通过卷积操作,可以捕捉数据中的局部相关性,识别有意义的空间模式,且通过卷积神经网络的学习可以避免简单地删除所有高频成分造成的信息丢失问题。为了更好地建模时序信息,并对不同时间步长的数据赋予不同的权重,引入了注意力机制的时间序列预测模块。该模块能够自适应地学习和聚焦于时间序列数据中最重要的部分,从而提高模型对未来数据的预测能力。

2.2.1 傅里叶变换

傅里叶变换是一种将信号从时域转换到频域的技术,它将一个时间域函数分解为一系列正弦和余弦函数的加权和,这些正弦和余弦函数的频率是连续的,并且可以用复数形式表示。时间序列数据可以利用傅里叶变换进行时域到频域的转换,复杂的时域数据在频域下可以更好地观察到规律。快速傅里叶变换是计算离散傅里叶变换的快速方法,它将一组离散时域信号转换成长度相同的频域信号,因此本文使用快速傅里叶变换对我们挖掘到的多维时间序列数据进行时域频域转换。将时域中复杂的数据转换到频域,有助于更好地提取有关信号的特征信息。快速傅里叶变换公式为:

$$FFT(\cdot): X[k] = \sum_{n=0}^{N-1} x_n e^{-i2\pi kn/N}, 0 \leq k \leq N$$

本文的输入信号为 \mathbf{X} , $\mathbf{X} \in R^{h \times n}$ 经过快速傅里叶变换 $FFT(\cdot)$, 得到 $FFT(\mathbf{X}) \in C^{h \times n}$ 。

2.2.2 卷积神经网络

经过傅里叶变换之后要分析保留哪个频率分量子集来表示时间序列,一个普遍的做法是保留低频部件,删除高频部件,但不适用于时间序列预测。因为时间序列中的一些趋势变化与重要事件有关,如果简单地删除所有高频成分,这条信息可能会丢失,所以本文使用多个卷积核的单层卷积神经网络^[18]对频域数据进行特征提取。一方面,卷积神经网络已经被证明可以很好地学习到数据的空间特征,本文的输入数据与相同班次数据在空间上相邻,卷积神经网络可以捕获局部的空间特征和模式。另一方面,卷积神经网络可以通过学习来对频域数据进行筛选,以避免信息丢失。卷积操作的表示如下:

$$C^k = \omega^k * FFT(\mathbf{X})$$

其中, ω^k 为第 k 个卷积核, C^k 是相应的卷积结果。

在卷积神经网络中,通常使用多个卷积核 w^1, w^2, \dots, w^n 形成多个通道的特征结果 $C^1, C^2, \dots, C^n, C^k \in C^{h \times 1}$ 。考虑到模型后续操作需要残差相加,因此卷积核的个数 $k=n$, 使经过卷积之后数据的规格不发生变化,得到的多通道特征结果 $RELU(C^1, C^2, \dots, C^n) \in C^{h \times n}$ 仍然保留着原有的时序关系。

2.2.3 傅里叶逆变换

本文对时间序列进行预测,最终还是在时域上进行处理,因此需要使用快速傅里叶逆变换 $IFFT(\cdot)$ 将上一步频域处理的结果转换成时域信号,得到 \mathbf{X}' :

$$IFFT(\cdot): x_n = \frac{1}{N} \sum_{k=0}^{N-1} X[k] e^{-i2\pi kn/N}$$

$$\mathbf{X}' = IFFT(RELU(C^1, C^2, \dots, C^k))$$

为了保留原始输入的时域信息,本文设计残差结构对时域信号和频域特征进行融合,得到时间序列模块的输入,即: $\mathbf{X}' + \mathbf{X}$ 。

2.2.4 基于注意力机制的时间序列预测模块

在2017年,谷歌公司提出了基于注意力机制的Transformer模型^[16],该模型架构完全依赖于注意力机制来学习输入和输出之间的全局依赖关系,具有更高的并行化能力。因此,在时间序列预测问题上,Transformer显示出了很大的潜力。典型的Transformer架构包含编码器和解码器两部分。编码器用于提取输入数据的特征,而解码器则将编码器提取的特征翻译为我们的目标序列。随着研究的不断发展,已经有很多在Transformer基础上进行改进的工作,特别是针对长时间序列预测的问题。这些改进方法已经取得很好的结果^[19-21]。

本文基于注意力机制的时间序列预测模块在Transformer模型的基础上保留了原来编码器的整体结构,使用多头注意力机制对输入序列进行特征的学习。简化其解码器的结构,使用一层全连接神经网络对编码器学习到的知识和输出序列进行拟合,如图2所示。在数据进入编码器之前需要对数据进行编码和位置编码,然后含有 N 个相同结构的编码器 Encoder 对输入进行多头注意力机制的操作。输入序列 $\mathbf{X}' + \mathbf{X}$ 可通过一个可训练的线性模块生成3个权重矩阵 $\mathbf{W}^q, \mathbf{W}^k, \mathbf{W}^v$, 由输入序列和权重矩阵可以得到查询向量 q 、键向量 k 、值向量 v 所对应的矩阵 $\mathbf{Q}, \mathbf{K}, \mathbf{V}$:

$$\mathbf{Q} = \mathbf{W}^q (\mathbf{X}' + \mathbf{X})$$

$$\mathbf{K} = \mathbf{W}^k (\mathbf{X}' + \mathbf{X})$$

$$\mathbf{V} = \mathbf{W}^v (\mathbf{X}' + \mathbf{X})$$

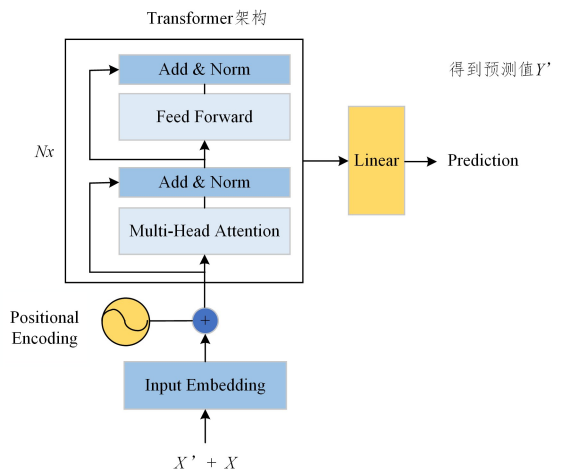


图2 基于注意力机制的时间序列预测模块

Fig.2 Time series forecasting module based on attention mechanism

将 \mathbf{Q} 和 \mathbf{K} 相乘得到全局相似度得分,然后经过 softmax 处理后和 \mathbf{V} 进行加权,得到最后输出,整个自注意力计算过程为:

$$Attention(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V}$$

自注意力计算在时间序列中的物理意义即每一个时间步都有一个查询向量 q 、键向量 k 、值向量 v ，查询向量包括了当前时间步的特征向量或隐藏状态，类似提出问题，哪些时间步应该受到更多关注。键向量提供了时间步的重要特征或特征表示，用于比较查询与时间序列中各个时间步骤的相似性。值向量则表示与各个时间步相关联的信息。通过 Q, K, V 的自注意计算可以确定不同时间步对当前时间步的预测的重要性，建立了时间序列各时间步之间的关联性，可以更好地理解和预测时间序列中的模式和变化。

为了学习不同子空间的特征，使用多头自注意力机制，即用 p 个 Q, K, V 矩阵并行计算：

$$Q_i = W_i^q (X' + X)$$

$$K_i = W_i^k (X' + X)$$

$$V_i = W_i^v (X' + X)$$

$i \in [1, 2, \dots, p]$ ，最终多头自注意力的结果为：

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{Attention}(Q_i, K_i, V_i)) W_{\text{out}}$$

编码器中 Add&Norm 层是对数据进行残差计算和层归一化处理，Feed Forward 的设计为两层全连接层加非线性的 ReLU 激活函数，对数据进行更深层次的学习。

本文设计了一层全连接层作为解码器来将编码器学习到的结果转化为预测序列 Y' ：

$$Y' = \text{Linear}(\text{Encoder}(X + X'))$$

通过基于自注意力机制的时间序列学习模块，可以从全局去学习时域数据和经过卷积神经网络学习到的频域数据的依赖关系，取得很好的预测效果。

具体算法流程如算法 1 所示。

算法 1 公交到站时间预测 FCTNet 算法

输入：历史时间序列 $X = [X_1, \dots, X_n]^T \in \mathbb{R}^{h \times n_{\text{feature}}}$ ，预测步长 N

输出：预测结果 $Y' \in \mathbb{R}^{N \times 1}$

- $X \rightarrow \text{FFT}(X) \in \mathbb{C}^{h \times n} / *$ 将输入数据 X 进行快速傅里叶变换转换为频域数据。 $*/$
- $\text{FFT}(X) \rightarrow \text{Conv}(\text{FFT}(X)) \in \mathbb{C}^{h \times n} / *$ 对频域数据进行卷积操作 $*/$
- $\text{Conv}(\text{FFT}(X)) \rightarrow X' / *$ 对上一步的结果进行快速傅里叶逆变换转换成时域数据。 $*/$
- $X' + X / *$ 进行残差计算 $*/$
- $\text{Encoder}(X + X') / *$ 对 $X' + X$ 进行基于自注意力机制的编码器学习 $*/$
- $Y' = \text{Linear}(\text{Encoder}(X + X')) / *$ 通过全连接层拟合编码器学习到的结果，得到预测值 $Y' / *$
- return Y'

3 数据处理和特征挖掘

3.1 线路的选取

本文收集了重庆市 3 条公交线路(465, 506, 262)的历史数据作为实验对象。重庆市的特殊地形地貌给研究带来了挑战，且这 3 条线路各自具有代表性。465 线路从两江半岛中心出发，经过渝中区，具有复杂地形的江北区，特别是江北区人流量极多的观音桥商圈。506 线路较为平缓，从北碚出发沿嘉陵江行驶，进入城乡交界地区。262 线路从大学城区出发，经过各个学校区域，沿江行驶，最终抵达渝中区的闹市区。这些选取的线路将为研究提供代表性的数据。

3.2 数据处理

本文所获得的原始数据分别为 2021—2022 年公交车行驶过程中传回的 gps 数据、运行过程中公交打卡的数据和公交线路所设站点的 gps 数据。我们需要对数据进行处理，然后从中找到影响公交车到站时间的各种因素，处理流程如图 3 所示。

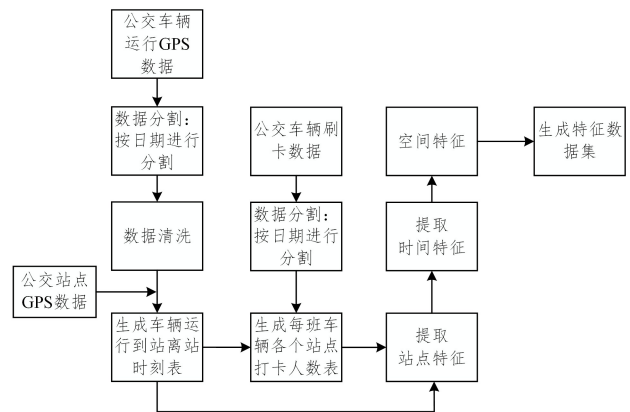


图 3 数据处理流程图

Fig. 3 Flow chart of data processing

3.3 影响因素的挖掘

1) 时间方面的特征挖掘。因为公交车行驶过程中存在多种周期性，所以本文选取了当前班次的前三班次运行时间的均值、当前班次的前三星期中相同班次的运行时间均值。公交车运行时间处于一天内的高峰期或平峰期是一个特征，运行时间是工作日还是节假日也是一个重要特征。公交车在公交车站的停留时间也总对公交到站时间预测的一个十分重要的因素，因此我们对公交车在公交车站的停留时间也有一个刻画，即在该站点的实时打卡人数、历史平均打卡人数、在该站点停留时间的历史均值、经过该公交站点设置的公交线路数、轨道交通数量，以及通过这几个特征聚类得到对公交车站的分类，都是影响公交车到站时间预测的特征。

2) 空间方面的特征挖掘。我们收集了该条线路所经过各个站间路段的道路等级、两站之间的距离、经过的交叉口数量、红绿灯数量和桥梁数量 5 个特征。

表 1 列出了本文所找到的对公交车到站时间预测有影响的所有特征。

表 1 特征及含义

Table 1 Features and meanings

符号	含义
T_i^{pre}	前三班车车辆花费时间的均值
T_i^{his}	前三星期相同班次车辆花费时间的均值
t_i	第 i 条数据所处的时间类别
p_i	第 i 条数据实时上车打卡人数
h_i	第 i 条数据所处时间是否是节假日
l_i	第 i 条数据所经过的车站共设置的公交线路数量
tr_i	第 i 条数据所经过的车站共设置的轨道交通数量
mt_i	第 i 条数据所经过的车站停留时间的历史均值
mp_i	第 i 条数据所经过的车站上车打卡人数的历史均值
st_i	第 i 条数据所经过的车站的类别
dis_i	第 i 条数据需要行驶的距离
rl_i	第 i 条数据行驶道路等级
rb_i	第 i 条数据行驶过程中经过的桥梁数量
ri_i	第 i 条数据行驶过程中经过的交叉口数量
rl_i	第 i 条数据行驶过程中经过的红绿灯数量

4 实验与分析

4.1 环境设置

本次实验基于 2021 年 3 月 22 日至 2022 年 8 月 18 日的重庆市 465 线路、506 线路和 262 线路 3 条公交线路的公交车辆传回的坐标数据和刷卡数据,以及公开的道路环境信息。在进行预处理后得到数据量如表 2 所列。在实验中,我们将数据划分为训练集、验证集和测试集,比例为 8:1:1,用于模型的训练和性能评估。在实现过程中使用 python3.9 和 Pytorch1.11 进行数据处理和算法编写。

表 2 各公交线路的数据量

Table 2 Data volume of each bus line

线路	数据量
465	1 072 512
506	491 257
262	958 580

4.2 模型设置

本文算法中,可以修改的网络结构包括卷积神经网络中卷积核的大小、卷积核的个数、Transformer 编码器中的网络层数等。卷积核的大小和个数应与输入向量的维度相等,这样进行残差相加时保证时域频域两个数据形状相同。因此卷积大小为 17×17 ,卷积核个数为 17,激活函数为 ReLU,在 Transformer 架构中编码器的网络层数 $N=5$ 时结果最优,多头设置为 8,每次训练的学习率为 0.001,损失函数为均方误差,优化器为随机梯度下降。

4.3 评价指标

本文采用几种常用的用于公交车到站时间预测的机器学习方法进行平均绝对百分比误差 (Mean Absolute Percentage Error) 和平均绝对误差 (Mean Absolute Error) 两个方面的比较。两个评估指标的定义如下。

平均绝对百分比误差:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_r - y_p|}{y_r}$$

平均绝对误差:

$$MAE = \frac{1}{n} \sum_{i=0}^n |y_r - y_p|$$

其中, (y_r, y_p) 分别为真实值和预测值。

4.4 对比方法

本文选择的对比方法如下。

多层感知机模型 MLP:由输入层、输出层和隐藏层组成,可以很好地学习非线性关系。

LSTM:由输入门、输出门、遗忘门组成的长短时记忆网络。

LSTNet:文献[22]提出的一个由卷积神经网络、门控神经网络、跳过循环网络和全连接神经网络组成的神经网络模型。该网络模型可以更好地学习时序数据的周期性、线性关系和非线性关系。

Informer:文献[19]提出的一个基于 transformer 改进的对长时间序列具有很好学习效果的网络模型。

Transformer:使用 transformer 架构的时间序列预测模型。

Cnn-transformer:由卷积神经网络和 transformer 架构组成的网络模型。

4.5 不同输入长度对 FCTNet 性能的影响

因为在时间序列预测模型中输入序列的长度会对结果有很大的影响,所以本文对 465 线路数据设置不同输入长度在 FCTNet 中进行实验。由表 3 可知,输入长度为 180 时,FCTNet 模型的准确率最好,因此本文将输入序列长度定为 180,并对 3 条线路进行了实验。

表 3 不同输入长度在 FCTNet 中的结果

Table 3 Results of different input lengths in FCTNet

输入长度	平均绝对百分误差/%	平均绝对误差/s
150	16.33	29.94
180	14.64	28.01
200	14.93	29.07
230	15.38	29.36

因为公交线路站点设置多为 20 站左右,且公交预测多为短期预测,所以我们的预测实验步长分别设置为 1,5,10,15 和 20。

4.6 实验结果分析

从表 4—表 6 所列的这 3 条线路的实验结果中可以看出,FCTNet 的平均绝对百分比误差和平均绝对误差基本都达到了最优的效果,并且 FCTNet 在不同预测长度的实验中,预测效果都十分稳定。

表 4 465 线路实验结果

Table 4 Experimental results of bus No. 465

方法	指标	预测长度				
		1	5	10	15	20
MLP	MAPE/%	19.40	18.30	17.77	17.74	17.75
	MAE/s	33.21	32.38	32.96	33.17	34.46
LSTM	MAPE/%	16.68	18.40	19.39	20.04	19.70
	MAE/s	39.65	44.26	45.12	45.81	46.44
LSTNet	MAPE/%	12.69	13.18	13.82	16.85	17.15
	MAE/s	19.44	20.48	21.18	24.94	26.55
Informer	MAPE/%	17.74	17.53	17.55	17.53	17.68
	MAE/s	32.83	32.47	32.49	32.47	32.77
Transformer	MAPE/%	12.24	13.09	13.85	13.69	13.64
	MAE/s	21.27	21.08	22.23	21.64	21.74
Cnn-transformer	MAPE/%	11.94	12.9	13.73	13.39	13.09
	MAE/s	21.00	21.52	22.60	21.484	21.00
FCTNet	MAPE/%	11.78	10.42	10.59	10.31	10.34
	MAE/s	20.73	15.53	15.79	15.05	15.98

表 5 506 线路实验结果

Table 5 Experimental results of bus No. 506

方法	指标	预测长度				
		1	5	10	15	20
MLP	MAPE/%	21.06	17.96	15.56	15.51	14.93
	MAE/s	22.41	18.95	17.86	17.99	18.09
LSTM	MAPE/%	14.00	14.86	14.96	14.96	14.62
	MAE/s	21.67	22.16	22.72	22.77	22.15
LSTNet	MAPE/%	17.06	16.00	17.59	21.14	20.09
	MAE/s	19.12	18.86	21.95	25.78	26.28
Informer	MAPE/%	13.32	13.32	13.38	13.40	13.41
	MAE/s	19.91	19.99	20.06	20.08	20.11
Transformer	MAPE/%	14.20	13.89	14.20	13.78	13.20
	MAE/s	18.83	16.97	17.18	17.78	17.43
Cnn-transformer	MAPE/%	15.31	14.24	14.50	13.89	13.26
	MAE/s	21.57	17.94	17.62	18.01	17.72
FCTNet	MAPE/%	12.87	13.17	13.48	13.07	12.59
	MAE/s	18.20	16.89	16.88	17.15	16.94

表 6 262 线路实验结果

Table 6 Experimental results of bus No. 262

方法	指标	预测长度				
		1	5	10	15	20
MLP	MAPE/%	15.96	13.46	12.575	14.41	15.38
	MAE/s	34.15	22.70	20.27	21.37	22.35
LSTM	MAPE/%	22.09	19.30	19.50	21.64	23.55
	MAE/s	29.15	40.45	44.55	47.09	49.96
LSTNet	MAPE/%	19.71	20.54	22.57	22.69	22.81
	MAE/s	38.20	39.63	42.51	42.01	41.44
Informer	MAPE/%	17.07	17.75	17.34	17.25	17.24
	MAE/s	28.76	29.51	29.25	29.17	29.20
Transformer	MAPE/%	10.74	11.51	12.21	12.25	11.50
	MAE/s	14.63	16.60	18.14	18.40	17.46
Cnn-transformer	MAPE/%	10.25	10.95	11.63	12.00	11.74
	MAE/s	13.80	15.70	17.09	17.52	17.19
FCTNet	MAPE/%	9.99	10.38	10.96	10.99	10.45
	MAE/s	13.91	15.02	16.26	16.50	15.92

相比 MLP 模型, FCTNet 在时间和空间两个领域对数据进行学习, 因此更加复杂, 同时也获得了更好的效果。

与 LSTM 相比, FCTNet 的 transformer 架构利用了自注意力机制进行全局学习, 而不是按照序列顺序进行学习, 从而更好地捕捉时间序列中的知识。

与 LSTNet 相比, FCTNet 通过傅里叶变换进行时域到频域的转换, 能够更好地学习序列的特征, 从而提高了预测性能。

与 Informer 相比, FCTNet 同样基于注意力机制, 但 Informer 做了稀疏处理, 只学习关联度最高的几个时间点, 而 FCTNet 学习全部的时间点, 且 FCTNet 加入了时频转换和卷积神经网络, 学习效果更好。

FCTNet 与其他模型比较显示了 FCTNet 相对于不同模型的优势, 其在时空数据学习和特征提取方面的设计, 使其在时间序列预测任务中表现更为出色。

4.7 消融实验

为了证明 FCTNet 模型的效率, 删除模型中的某些部分来进行验证。在 FCTNet 模型中, Transformer 是对时间序列进行学习和预测必不可少的部分, 因此我们使用单独的 Transformer 模型进行了实验。然后, 在 Transformer 的基础上加入卷积神经网络 (Cnn-transformer) 对输入数据进行实验。从以上实验的结果中可以看出, FCTNet 相比原始 Transformer, 增加了卷积神经网络对频域的学习, 相比 Cnn-

transformer, 增加了傅里叶变换, 使得卷积神经网络可以从频域学习知识, 因此 FCTNet 获得了更好的效果, 也说明本文算法的每个部分都是必不可少的, 并且每个部分都对最后的准确率做出了贡献。

通过上述实验, 我们验证了 FCTNet 模型的有效性, 表明其中的每个部分在整个模型中都起着关键的作用, 从而提高了时间序列预测的性能。这些实验结果进一步验证了本文设计的综合模型的有效性。

结束语 本文通过对公交数据进行时空特征挖掘, 构建融合傅里叶变换、卷积神经网络和基于注意力机制的序列学习模块的深度学习公交车到站时间预测算法 FCTNet。该算法通过对公交数据进行频域和时域、空间和时间多方面的学习, 可在交通环境复杂的状况下对公交车单站和多站的到站时间进行实时准确的预测。实验结果表明, 本文提出的 FCTNet 可显著提升公交到站时间预测的准确率。在算法局限性方面, 因为算法比较复杂, 在实际应用时需要找到输入数据和对输入数据进行计算, 这两部分可能需要花费一定时间。

参考文献

- [1] XU H, YING J. Bus arrival time prediction with real-time and historic data [J]. Cluster Computing, 2017, 20(4): 3099-3106.
- [2] GONG J, LIU M, ZHANG S. Hybrid dynamic prediction model of bus arrival time based on weighted of historical and real-time GPS data[C]// 2013 25th Chinese Control and Decision Confe-

- rence(CCDC). IEEE,2013;972-976.
- [3] ČELAN M,LEP M. Bus-arrival time prediction using bus network data model and time periods [J]. Future Generation Computer Systems,2020,110:364-371.
- [4] BO C,PENG Z R. Bus travel time prediction based on dynamic model[J]. Computer Engineering and Application,2016,52(3):103-107.
- [5] WANG B,WANG W,YANG M,et al. An approach to bus travel time prediction based on the adaptive fading Kalman filter algorithm [C] // Multimodal Transportation Systems—Convenient, Safe, Cost-Effective, Efficient(CICTP 2012). 2012:1652-1661.
- [6] ABIDIN A F,KOLBERG M. Towards Improved Vehicle Arrival Time Prediction in Public Transportation: Integrating SUMO and Kalman Filter Models [C]// 2015 17th UKSim-AMSS International Conference on Modelling and Simulation(UKSim). 2015:147-152.
- [7] YIN T,ZHONG G,ZHANG J,et al. A prediction model of bus arrival time at stops with multi-routes [J]. Transportation Research Procedia,2017,25:4623-4636.
- [8] REDDY K K,KUMAR B A,VANAJAKSHI L. Bus travel time prediction under high variability conditions [J]. Current Science,2016:700-711.
- [9] COMI A,ZHUK M,KOVALYSHYN V,et al. Investigating bus travel time and predictive models: a time series-based approach [J]. Transportation Research Procedia,2020,45:692-699.
- [10] PETERSEN N C,RODRIGUES F,PEREIRA F C. Multi-output bus travel time prediction with convolutional LSTM neural network [J]. Expert Systems with Applications, 2019, 120: 426-435.
- [11] MAZLOUMI E,ROSE G,CURRIE G,et al. Prediction intervals to account for uncertainties in neural network predictions: Methodology and application in bus travel time prediction [J]. Engineering Applications of Artificial Intelligence, 2011, 24 (3): 534-542.
- [12] BAI C,PENG Z R,LU Q C,et al. Dynamic Bus Travel Time Prediction Models on Road with Multiple Bus Routes [J]. Comput Intell Neurosci,2015;432389.
- [13] LIU Z Z. Research on Bus Arrival time Prediction Method based on GRU and Kalman Filter combination model [J]. China-arab States Science and Technology Forum(Chinese and English), 2022,(9):100-104.
- [14] LAI Y X,ZHANG L,YANG F,et al. Bus Arrival Time Prediction Algorithm Based on Spatio-temporal Correlation Attribute Model [J]. Journal of Software,2020,31(3):648-662.
- [15] ZHANG X H,LIU H J,SHI J Q,et al. Urban Bus Travel Time Prediction Based on Long and Short Term Memory Artificial Neural Network Based on Spatial-temporal Feature Vector [J]. Journal of Computer Applications,2021,41(3):875-880.
- [16] VASWANI A,SHAZEER N,PARMAR N,et al. Attention Is All You Need[J]. arXiv:1706.03762,2017.
- [17] YANG H M,PAN Z S,BAI W. Review of time series prediction methods [J]. Computer Science,2019,46(1):21-28.
- [18] LECUN Y,BOTTOU L,BENGIO Y,et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE,1998,86(11):2278-2324.
- [19] ZHOU H,ZHANG S,PENG J,et al. Informer: Beyond efficient transformer for long sequence time-series forecasting[C]// Proceedings of the AAAI Conference on Artificial Intelligence, 2021.
- [20] WU H,XU J,WANG J,et al. Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting [J]. Advances in Neural Information Processing Systems,2021, 34:22419-22430.
- [21] ZHOU T,MA Z,WEN Q,et al. Fedformer: Frequency enhanced decomposed transformer for long-term series forecasting[C]// Proceedings of the International Conference on Machine Learning. PMLR,2022.
- [22] LAI G,CHANG W C,YANG Y,et al. Modeling long-and short-term temporal patterns with deep neural networks[C]// Proceedings of the The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval, 2018.



ZHANG Mingze, born in 1997, master. His main research interests include time series prediction and deep learning.



LI Yi, born in 1980, Ph.D, associate professor. His main research interests include program verification, symbolic computation and intelligent transportation.