

基于时空特征挖掘的交通流量预测方法

孔繁钰¹ 周愉峰^{1,2} 陈 纲³

(重庆工商大学重庆市发展信息管理工程技术研究中心 重庆 400067)¹

(南京航空航天大学管理科学与工程博士后流动站 南京 210016)²

(重庆大学建筑城规学院 重庆 400045)³

摘 要 基于神经网络和大数据的交通流量预测方法层出不穷,但对交通流量预测的精度仍有待进一步提高。为了解决该问题,提出一种基于时空特征挖掘的交通流量预测方法。该方法使用改进的 CNN 来挖掘交通流量的空间特征,使用递归神经网络来挖掘交通流量的时间特征,能够充分利用交通流量的每周/每天的周期性和时空特征。此外,在该方法中还使用了一种基于相关性的模型,它可以根据过去的交通流量实现自动学习。实验结果表明,相比于其他几种较新的预测方法,所提方法具有较高的交通流量预测精度。

关键词 深度神经网络,改进卷积神经网络,交通流量预测,时空特征,大数据,自动学习

中图分类号 TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2019.07.049

Traffic Flow Prediction Method Based on Spatio-Temporal Feature Mining

KONG Fan-yu¹ ZHOU Yu-feng^{1,2} CHEN Gang³

(Chongqing Engineering Technology Research Center for Development Information Management,
Chongqing Technology and Business University,Chongqing 400067,China)¹

(Postdoctoral Research Station of Management Science and Engineering,Nanjing University of Aeronautics &
Astronautics,Nanjing 210016,China)²

(College of Architecture and Urban Planning,Chongqing University,Chongqing 400045,China)³

Abstract Traffic forecasting methods using neural networks and big data are emerging in an endless stream, but their prediction accuracy for traffic flow is usually inaccurate. In order to solve this problem, this paper proposed a traffic flow forecasting method based on spatio-temporal feature mining. This method makes use of improving convolutional neural network(CNN) to mine the spatial features of traffic flow, and utilizes recursive neural network to mine the temporal features of traffic flow, so that it can make full use of weekly/daily periodicity and spatial-temporal characteristics of traffic flow. In addition, the method also introduces a correlation-based model that can achieve automatic learning according to the past traffic flow. Experiment results show that the proposed method has higher prediction accuracy for traffic flow compared with some novel methods.

Keywords Deep neural network, Improved convolutional neural network, Traffic flow prediction, Temporal-Spatial features, Big data, Automatic learning

目前,交通流量预测已成为热门的研究课题。本质上来说,流量预测是根据相关历史数据提取的经验和知识来估计未来的状态。因此,数据收集、传输、存储和挖掘技术对预测方法有着重大影响^[1]。最近,科研人员将大数据的概念引入到交通运输的研究中^[2],以实现精确的交通流预测,同时也为交通流量预测的建模提出了新的方向。

大多数情况下,交通流预测模型都采用了浅层结构^[3]。

由于交通流量非常复杂,并且在空间和时间方面都具有丰富的特征^[4],开发一种能够有效捕捉交通流量特征的深度学习模型并不是一件容易的事。因此,科研人员也考虑将神经网络方法用于交通流量预测中,并对卷积神经网络(Convolutional Neural Network, CNN)^[5]和递归神经网络(Recurrent Neural Network, RNN)^[6]等深度神经网络结构进行研究。

文献[7]开发了一种时延回归小波神经网络模型来预测

到稿日期:2018-06-29 返修日期:2018-09-09 本文受国家自然科学基金(71702015),中国博士后科学基金(2017M611810),重庆市社科规划重大应用项目(2017ZDY51),重庆市发展信息管理工程技术研究中心开放基金项目(gczxkf201706),重庆工商大学科研平台开放课题(KFJJ2018078)资助。

孔繁钰(1976—),男,博士,高级工程师,主要研究领域为交通工程、复杂性网络等,E-mail:cqkfy2002@126.com(通信作者);周愉峰(1984—),男,博士,副教授,主要研究领域为应急物流与应急管理、物流系统优化研究等;陈 纲(1972—),男,博士,副教授,主要研究领域为交通运输管理等。

交通流量,并强调了周期性对长期预测的重要性。文献[8]采用长短期记忆网络来预测交通速度,并证明了长短期记忆结构可以捕捉交通数据的长期时间依赖性。除了神经网络方法之外,还有许多其他不同的预测方法,如卡尔曼滤波器^[9]、支持向量回归^[10]、梯度提升回归树^[11]等。

上述方法的不足之处源于大型交通数据与浅层结构之间的矛盾。文献[12]使用深层信念网络来捕捉交通流的时空特征,并提出了一个多任务学习体系结构来执行出站流量和道路流量预测。文献[13]研究了卷积神经网络在交通流量预测中的不同预训练策略。这些方法都属于全连接结构方法。全连接体系结构中没有关于特征的假设,因此全连接的神经网络很难从特征丰富的数据集中捕获具有代表性的特征。这些深层架构各有优点和缺点,如何构建一个充分利用交通流特征的深层体系结构,是一个富有挑战性的问题。

本文提出了一种基于混合神经网络的新型交通流量预测方法,其使用深度卷积神经网络来挖掘交通流量数据的空间特征,同时采用递归神经网络来学习时间特征。

1 基于混合神经网络的交通流量预测方法

本节给出了基于混合神经网络的交通流量预测方法模型,如图 1 所示。考虑到交通流的周期性,将相似的前一天和前一一周的交通流量输入到具有近期交通流量数据的神经网络中。相关性模型侧重于交通流量传播的基本问题,即选择与未来交通流量高度相关的近期数据。全连接网络从近期交通速度中学习到相关性,用以考虑近期交通流量的权重,并揭示交通速度与交通流量之间的动态关系。由改进 CNN 来学习交通流的空间特征,由门控 RNN 来捕获交通流的时间特征,将所有特征连接在一起并将其输入到递归层来实现预测。



图 1 基于混合神经网络的交通流量预测模型

Fig. 1 Trafficflow prediction model based on hybrid neural network

1.1 相关性模型

相关性模型旨在确定过去时空位置的输入流量 s_t 与未来交通流量相关程度的得分。本文设计了一个完全连接的神经网络来学习权重,而不是直接使用基于规则的策略来确定权重值。由于交通速度是未来交通流量变化的关键因素,因此本文利用速度数据来学习这些权重。假设需要预测 $(t, t+1, \dots, t+h)$ 中的 p 个位置 $\{s_i\}_{i=1}^p$ 的交通流量,其中 h 是预测范围,将 $(t-n, t-n+1, \dots, t-1)$ 期间的 p 个位置 $\{s_i\}_{i=1}^p$ 的历史交通流量数据作为输入,产生下一时间范围 $(t, t+1, \dots, t+h)$ 的预测。汇总历史数据,获得近期交通流量矩阵:

$$\mathbf{S}^f = \begin{bmatrix} S_1 \\ S_2 \\ \vdots \\ S_p \end{bmatrix} = \begin{bmatrix} s_1(t-n) & s_1(t-n+1) & \cdots & s_1(t-1) \\ s_2(t-n) & s_2(t-n+1) & \cdots & s_2(t-1) \\ \vdots & \vdots & \vdots & \vdots \\ s_p(t-n) & s_p(t-n+1) & \cdots & s_p(t-1) \end{bmatrix} \quad (1)$$

相关性模型的目标是使用这些时空点的速度矩阵 \mathbf{S}^s 来学习具有相同 \mathbf{S}^f 大小的相关性权重矩阵 \mathbf{A} 。可以把相关性矩阵 \mathbf{A} 中的每个元素解释为该时空点的交通流信息引起未

来交通流的概率。本文直接使用一个隐藏层的全连接神经网络来学习这个相关性矩阵。输出层和隐藏层之间的激活函数是一个 sigmoid 函数。使用 sigmoid 函数的原因是该函数可以把输出限制在 0 和 1 之间。

$$\mathbf{A} = \phi(f(\mathbf{S}^s)) = \text{sigmoid}(\mathbf{W} * f(\mathbf{s}^s) + b) \quad (2)$$

其中, ϕ 是相关性学习网络, \mathbf{s}^s 是大小与 \mathbf{S}^f 相同的速度矩阵 \mathbf{S}^s 的向量化, \mathbf{W} 是隐藏层的权值, f 是输入与隐藏神经元之间的投影, b 是输出层的阈值。将交通流矩阵 \mathbf{S}^f 与相关性矩阵 \mathbf{A} 逐点相乘,以获得用于更深层学习过程的加权交通流矩阵 \mathbf{S}^A 。

1.2 空间特征的挖掘

交通流量通常在距离较近的位置具有较强的相关性,而 CNN 是处理具有地理位置结构的图像/视频数据的一个非常强大的工具。使用改进的 CNN 来挖掘交通流数据中的空间特征。

1.2.1 CNN 的改进

CNN 是一种神经网络模型,它由 3 个层组成:卷积层、子采样层、输出层。CNN 最初是为二维图像模式的识别而设计的,现已成为深度学习的主要方法之一。CNN 能够将特征提取和分类集成在一个结构中,并且是完全自适应的。在 CNN 中,激活函数起着非常关键的作用,它能够调整卷积层的输出,这样最终提取的特征就会更加令人满意。基于此,将 CNN 中的激活函数设置为修正线性单元(Rectified Linear Units, ReLU)。ReLU 的表达式如下所示:

$$h^{(i)} = \max(w^{(i)\top} x, 0) = \begin{cases} w^{(i)\top} x, & w^{(i)\top} x > 0 \\ 0, & w^{(i)\top} x \leq 0 \end{cases} \quad (3)$$

当计算出的卷积值小于 0 时,则令激活函数的值为 0;否则,令激活函数的值保持不变。

在 CNN 中,数据的训练通常是带有监督性质的,整个过程需要足够多的样本,而在 CNN 中获得如此庞大数量的样本数据是非常困难的。数据训练的无监督化正好可以解决这个问题。利用稀疏滤波(Sparse Filtering)算法构建特征分布矩阵,并利用归一化的方法对样本特征进行处理,即可得到样本分布矩阵,该矩阵的样本分布、激活时间都具有稀疏性。此外,改进后的 CNN 还能实现样本分布矩阵的级联,以形成无监督学习模型。

令 $\mathbf{F} = \mathbf{S}^T \mathbf{X}$ 为构建的特征分布矩阵,其中 $\mathbf{X} = [x_1, x_2, \dots, x_n] \in \mathbf{R}^{d \times n}$ 表示训练样本矩阵。 $\mathbf{F} \in \mathbf{R}^{i \times n}$ 表示 \mathbf{X} 的特征分布矩阵, \mathbf{S} 表示投影矩阵。稀疏滤波算法的目的是求出 \mathbf{S} 的最优解。

假设 $f_{(i,\Delta)} \in \mathbf{R}^{i \times n}$ 为 \mathbf{F} 的第 i 行, $f_{(\Delta,j)} \in \mathbf{R}^{i \times 1}$ 为 \mathbf{F} 的第 j 列,对 \mathbf{F} 的行和列实行二范数归一化:

$$\tilde{f}_{(i,\Delta)} = f_{(i,\Delta)} / \|f_{(i,\Delta)}\|_2 \quad (4)$$

$$\tilde{f}_{(\Delta,i)} = f_{(\Delta,i)} / \|f_{(\Delta,i)}\|_2 \quad (5)$$

对 \mathbf{F} 进行稀疏优化求解,就能够得到投影矩阵 \mathbf{S} :

$$\min_s \|\mathbf{F}\|_1 = \min_s \sum_{j=1}^n \|\tilde{f}_{(\Delta,j)}\|_1 = \sum_{j=1}^n \left\| \frac{\tilde{f}_{(\Delta,j)}}{\|\tilde{f}_{(\Delta,j)}\|_2} \right\|_1 \quad (6)$$

将样本分布矩阵进行级联,并将 \mathbf{S} 看作卷积核,就能得到无监督学习模型。这种结构模型在训练过程中使用贪婪算法逐层求解,只有在当前层的优化结束后,才进行下一层次的优化求解。

1.2.2 利用改进的 CNN 进行空间特征的挖掘

为了挖掘空间特征,将从上游到下游的矩阵 \mathbf{S}^A 的矢量表

示为:

$$\mathbf{T}_q = [s_1^q(t-n+q), s_2^q(t-n+q), \dots, s_p^q(t-n+q)]^T \quad (7)$$

其中, q 的取值范围为 $[0, n-1]$ 。对该矢量进行一维卷积, 其中第 k 个特征映射如下:

$$\mathbf{h}_q^k = \mathbf{o}_c(\mathbf{w}_q^k * \mathbf{T}_q^k + \mathbf{b}_q^k) \quad (8)$$

其中, \mathbf{w}_q^k 是加权向量, \mathbf{b}_q^k 是偏差, \mathbf{o}_c 表示激活函数。

1.3 时间特征的挖掘

交通流的时间特征与其空间特征明显不同。由于交通系统具有动态特性, 交通流在短时间内表现出较强的相关性。此外, 长期时间依赖性也存在于交通流量数据中。因此, 建模时间特征应考虑到长期依赖性。有研究引入了长短期记忆(LSTM)网络来建模交通流的时间特征^[14]。LSTM 的优势在于它使用门控神经元捕捉交通流中的短期记忆和长期记忆, 并避免了梯度消失/梯度爆炸问题。

本研究使用更简单的 RNN 模型——门控递归神经网络(GRU), 因为它需要的神经元比 LSTM 更少。为了生成短期时间特征, 把 GRU 的输入表示为 $\mathbf{T} = (\mathbf{T}_0, \mathbf{T}_1, \dots, \mathbf{T}_{n-1})$, 在 \mathbf{S}^A 中, $\mathbf{T}_q = [s_1^q(t-n+q), s_2^q(t-n+q), \dots, s_p^q(t-n+q)]^T$, 将每个历史时间点中的第 k 层输出时间特征表示为 $\mathbf{H}^k = (\mathbf{H}_0^k, \mathbf{H}_1^k, \dots, \mathbf{H}_{n-1}^k)$, n 是时间窗口大小。通过以下等式的迭代计算生成时间特征:

$$\mathbf{Z}_q = \sigma_g(\mathbf{W}_z \mathbf{T}_q + \mathbf{U}_z \mathbf{H}_{q-1} + \mathbf{b}_z) \quad (9)$$

$$\mathbf{R}_q = \sigma_{g_r}(\mathbf{W}_r \mathbf{T}_q + \mathbf{U}_r \mathbf{H}_{q-1} + \mathbf{b}_r) \quad (10)$$

$$\mathbf{H}_q = (1 - \mathbf{Z}_q) \odot \mathbf{H}_{q-1} + \mathbf{Z}_q \odot \sigma_h(\mathbf{W}_h \mathbf{T}_q + \mathbf{U}_h(\mathbf{R}_q \odot \mathbf{H}_{q-1}) + \mathbf{b}_h) \quad (11)$$

其中, \odot 表示两个向量的点积, $\sigma(\cdot)$ 和 $\sigma_h(\cdot)$ 是激活函数。通常情况下, 把 $\sigma(\cdot)$ 设置在 $[0, 1]$ 的范围内, 以控制一定时间内的信息流。通常令 $\sigma_h(\cdot)$ 为中心激活函数。 \mathbf{R}_q 是复位阈值, \mathbf{Z}_q 是 q 时间点的更新阈值。很显然, 如果大多数 \mathbf{Z} 接近于 0, 且大多数 \mathbf{R} 接近 1, 则网络学习长期记忆, 反之则学习短期记忆。因为我们认为浅层单层 GRU 和 LSTM 仅捕获短期记忆, 所以将两个 GRU 叠加在一起, 以提取交通流量的长期记忆和短期记忆。

1.4 周期性特征

上班族在工作日通常早上上班、晚上回家, 而到了周末其出行路线又不一样了, 这就是为什么在交通流量中可以观察到很强的周期性。影响交通流量预测的主要因素为交通流量的周期性。为了对交通流量的每日周期性和每周周期性进行建模, 给出时间 t 处的周期性输入如下:

$$\mathbf{S}^d = \begin{bmatrix} s_1(t^d - n^d) & s_1(t^d - n^d + 1) & \dots & s_1(t^d + h + n^d) \\ s_2(t^d - n^d) & s_2(t^d - n^d + 1) & \dots & s_2(t^d + h + n^d) \\ \vdots & \vdots & \ddots & \vdots \\ s_p(t^d - n^d) & s_p(t^d - n^d + 1) & \dots & s_p(t^d + h + n^d) \end{bmatrix} \quad (12)$$

$$\mathbf{S}^w = \begin{bmatrix} s_1(t^w - n^w) & s_1(t^w - n^w + 1) & \dots & s_1(t^w + h + n^w) \\ s_2(t^w - n^w) & s_2(t^w - n^w + 1) & \dots & s_2(t^w + h + n^w) \\ \vdots & \vdots & \ddots & \vdots \\ s_p(t^w - n^w) & s_p(t^w - n^w + 1) & \dots & s_p(t^w + h + n^w) \end{bmatrix} \quad (13)$$

其中, t^d 和 t^w 分别表示前一天和前一周与预测时刻 t 相同的时间点; n^d 和 n^w 分别表示每日周期性和每周周期性的时滞;

h 是预测范围。

在近期数据上使用改进的 CNN 和 GRU 来分别挖掘每日周期性输入和每周周期性输入的时空特征; 然后将所有特征拼接在一起并输入递归层, 以执行未来时间点 $(t, t+1, \dots, t+h)$ 上的交通流量预测。使用式(3)所示的 ReLU 作为递归层的激活函数, 因为 ReLU 保证了交通流数据的非负性并且易于收敛。

$$f(x) = \max(0, x) \quad (14)$$

将上述所有结构分组在一起, 本研究提出的基于混合神经网络的交通流量预测模型是以端到端的方式进行训练的。使用随机梯度下降(SGD)方法^[15]来训练本文模型, 将式(15)所示的均方误差作为目标函数:

$$\text{error} = E[(\theta^p - \theta')^2] \quad (15)$$

其中, θ^p 表示模型的预测值或输出。

2 实验结果及分析

2.1 实验设置

本文使用的是 2014 年 4 月 1 日至 2014 年 6 月 30 日之间沿着国内某公路的数据, 公路两侧放置有 33 个探测器。实验中, 每间隔 5 min 记录一次交通流量。因此, 一台探测器每天保存 288 个数据点的数据。在本文方法中, \mathbf{S}^f 的时间窗口大小 n 设置为 21。预测范围 h 设置为 9, 使用了 105 min 的历史数据来执行接下来 45 min 的交通流量预测。使用 2014 年 4 月 1 日凌晨 0 点至 2014 年 6 月 20 日 18 点 30 分的过去和未来的交通流量来训练预测模型, 将 2015 年 6 月 20 日 18:30 至 2015 年 6 月 30 日 24:00 的其余数据用于评估。表 1 列出了部分时间点的平均交通流量, 表 2 列出了一周内每日交通流量的平均值。交通流量数据显示, 每天早晨和傍晚是出行高峰期, 工作日交通流量高于周末流量。

表 1 部分时间点的平均交通流量

Table 1 Average traffic flow of some time

时间点	1:45	5:15	8:30	12:15	15:45	19:30	21:00	22:45
每 5 min 的交通流量	62	175	481	537	528	392	274	139

表 2 每日交通流量的平均值

Table 2 Average value of daily traffic flow

时间	周一	周二	周三	周四	周五	周六	周日
每 5 min 的交通流量	367	382	379	391	386	347	318

将本文方法和传统的浅层反向传播神经网络(BPNN)算法、文献[3]提出的堆叠自动编码算法(SAE)、文献[16]提出的 LASSO 算法相比较。利用 Adamax 优化器训练上述模型方法, 样本数为 300。使用其中 10% 的训练数据作为验证集。使用 ReLU 激活的 3 个一维卷积层来提取本文模型的空间特征。特征映射的数量越大, 训练和预测时间越长。将改进 CNN 每层的特征映射数量设为 30, 以平衡计算成本和预测精度。采用 2 层叠加的 GRU 来提取时间特征。所有 GRU 的隐藏状态的维度设置为 50。使用 ReLU 激活的具有 600 个隐藏神经元的单层神经网络作为相关性模型。为了平衡计算成本和预测精度, 选择 50 个状态和 600 个隐藏的神经元。为了比较的公平性, 根据文献中的结果和本文所提模型的实验

结果来选择参数。关键参数包括:BPNN 方法使用 ReLU 激活的具有 1 900 个隐藏神经元的单层神经网络^[17]。对于 SAE,使用三层深度的深度神经网络。将上述所有输入组合在一起,并将它们输入到 SAE 和 BPNN,所有隐藏层的隐藏神经元为 300,并且使用 sigmoid 函数激活,每层都使用自动编码器方式进行预训练。在 LASSO 模型中, l_1 范数损失的权重设置为 0.02。所有的神经网络方法均建立在 keras 框架上,LASSO 模型在 scikit-learn 框架上实现。将交通流量和速度归一化到 0 到 1 之间。

2.2 所提方法的拟合能力分析

采集从 2014 年 4 月 1 日到 2014 年 6 月 30 日连续 90 天在下游位置时(探测点为 26)2:30 的交通流量,一共可获得 90 个交通流量数据,如图 2 所示。




图 2 各个数据点的数据

Fig.2 Data for individual data point

将前 72 个数据作为训练样本集,其余数据作为验证集,在本文模型中输入训练集进行拟合,图 3 给出数据拟合结果。

可以看出,本文方法得到的拟合值与实际值非常接近。




图 3 本文方法的拟合结果

Fig.3 Fitting results of our method

2.3 交通流量预测精度的比较及分析

使用平均相对误差(MRE)、平均绝对误差(MAE)和均方根误差(RMSE)来比较不同预测方法的准确度。MAE,MRE 和 RMSE 的定义如下:

$$MAE = \frac{\sum_i |P_i - T_i|}{I} \quad (16)$$

$$MRE = \frac{\sum_i \frac{|P_i - T_i|}{T_i}}{I} \quad (17)$$

$$RMSE = \sqrt{\frac{\sum_i |P_i - T_i|^2}{I}} \quad (18)$$

其中, I 表示预测点的总数, P_i 表示预测值, T_i 表示真值。

表 3 列出了在未来不同时间点上不同方法的误差指标。

表 3 不同预测时间上的 MAE,MRE 和 RMSE($h=9$)

Table 3 MAE,MRE and RMSE for different prediction time points($h=9$)

时间点	误差指标	1	2	3	4	5	6	7	8	9
本文方法	MAE	21.352	23.166	24.524	24.663	25.867	25.883	26.391	26.844	27.426
	MRE	0.082	0.089	0.091	0.091	0.092	0.095	0.097	0.099	0.099
	RMSE	28.826	31.034	32.959	33.561	34.802	34.987	35.614	35.862	36.771
文献[16]方法	MAE	24.514	26.832	27.376	28.354	28.962	29.437	30.021	31.150	32.064
	MRE	0.095	0.102	0.109	0.117	0.125	0.131	0.140	0.147	0.149
	RMSE	32.561	35.012	37.361	38.763	40.257	41.344	42.659	44.035	44.880
BPNN 方法	MAE	23.664	24.526	25.261	25.678	26.032	26.865	27.073	27.936	28.253
	MRE	0.086	0.091	0.093	0.094	0.094	0.099	0.106	0.107	0.109
	RMSE	32.793	34.221	34.868	35.963	36.515	37.376	37.830	38.528	38.904
文献[3]方法	MAE	23.829	25.065	25.864	26.157	27.293	27.672	28.336	28.914	29.153
	MRE	0.091	0.095	0.096	0.101	0.105	0.108	0.108	0.113	0.115
	RMSE	32.793	34.273	35.758	36.663	38.032	38.748	39.551	39.892	40.668

从表中可以看出,本文方法在第 1 个时间点获得的预测结果最好,相比于 BPNN 方法,本文方法的 MAE 和 RMSE 分别提升了 2.312 和 3.967。由表 3 可知,与其他方法相比,本文模型方法的 MAE, RMSE 和 MRE 都有所提高。实验结果证实,本文方法可以学习交通流中的时空特征。另外,从表 3 中能明显看出,每种方法在靠近未来的时间点时表现出了更好的性能,因为预测较近的未来交通流量会更容易。所有基于神经网络的方法都比 LASSO 表现得更好,因为 LASSO 是一个简单的线性模型,它不能充分捕获交通流内的非线性特征。

MAE, MRE 和 RMSE 用于测量预测值与实际值之间的误差。预测精度在空间和时间上的分布也是重要的指标。因此,定义平均相关性(AC)来测量空间和时间分布的预测性能:

$$AC(t) = \frac{1}{n_t} \sum_{i=1}^{n_t} Corr(P_{it}, T_{it}) \quad (19)$$

$$ACE(s) = \frac{1}{n_s} \sum_{i=1}^{n_s} Corr(P_{si}, T_{si})$$

其中, P_{it} 和 P_{si} 分别表示预测时间点 t 和空间点 s 处的交通流量向量; T_{it} 和 T_{si} 表示实际的交通流量向量; n_t 和 n_s 分别是在时间维度和空间维度上的预测向量数。图 4 给出了所有方法在时间和空间维度上的平均相关性。结果表明,本文方法在交通流量的空间和时间分布上可以提供可靠预测。




图 4 4 种方法在时间和空间维度上的平均相关性

Fig.4 Average correlation of four methods on time dimension and spatial dimension

图5给出2015年5月14日2:00到2015年5月14日2:40在下游位置(探测点为24)时上述4种方法的预测结果,图6给出在第二个预测时间点处上述4种方法的预测结果。可以看出,在整个预测期间,本文算法在时间和空间维度上都更准确。




图5 不同时间点的预测结果

Fig. 5 Prediction results for different time points




图6 第二个预测时间点的结果

Fig. 6 Results of second prediction time point

结束语 本文提出了一种新的交通流量预测模型,该模型利用了各种深度学习架构(包括全连接神经网络、递归神经网络和CNN)的优点以提高预测性能。使用改进的CNN来挖掘交通流量的空间特征,使用递归神经网络来挖掘交通流量的时间特征。另外,本文将相关性模型引入到了交通流的建模中,相关性模型可以根据过去的交通流量实现自动学习。本文不仅提出了具有可靠精度的预测模型,而且分析了神经网络在交通流数据处理过程中的内在机制。实验结果表明,基于混合神经网络的交通流量预测模型具有更高的预测精度。

参考文献

[1] RUI L L, LI Q M. Short-term Traffic Flow Prediction Algorithm Based on Combined Model [J]. Journal of Electronics & Information Technology, 2016, 38(5): 1227-1233. (in Chinese)
芮兰兰, 李钦铭. 基于组合模型的短时交通流量预测算法[J]. 电子与信息学报, 2016, 38(5): 1227-1233.

[2] ZHENG X, CHEN W, WANG P, et al. Big Data for Social Transportation [J]. IEEE Transactions on Intelligent Transportation Systems, 2016, 17(3): 620-630.

[3] LV Y, DUAN Y, KANG W, et al. Traffic Flow Prediction With Big Data: A Deep Learning Approach [J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(2): 865-873.

[4] LI L, LI Y, LI Z. Efficient missing data imputing for traffic flow by considering temporal and spatial dependence [J]. Transportation Research Part C Emerging Technologies, 2013, 34(9): 108-120.

[5] YU H B, SHEN Q, FENG G C. Introduce Numerical Solution to Visualize Convolutional Neuron Networks Based on Numerical

Solution [J]. Computer Science, 2017, 44(S1): 146-150. (in Chinese)

俞海宝, 沈琦, 冯国灿. 在反卷积网络中引入数值解可视化卷积神经网络 [J]. 计算机学报, 2017, 44(S1): 146-150.

[6] LUO J, JIANG Y, LIU X, et al. Multi-scale convolutional-recurrent neural networks for RGB-D object recognition [J]. Application Research of Computers, 2017, 34(9): 2834-2837. (in Chinese)

骆健, 蒋旻, 刘星, 等. 多尺度卷积递归神经网络的RGB-D物体识别 [J]. 计算机应用研究, 2017, 34(9): 2834-2837.

[7] JIANG X, ADELI H. Dynamic Wavelet Neural Network Model for Traffic Flow Forecasting [J]. Journal of Transportation Engineering, 2005, 131(10): 771-779.

[8] MA X, TAO Z, WANG Y, et al. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data [J]. Transportation Research Part C, 2015, 54(3): 187-197.

[9] QIAN W, YANG H H, SUN Y J. Kalman filtering traffic flow prediction research based on phase space re-construction [J]. Computer Engineering and Applications, 2016, 52(14): 37-41. (in Chinese)

钱伟, 杨慧慧, 孙玉娟. 相空间重构的卡尔曼滤波交通流预测研究 [J]. 计算机工程与应用, 2016, 52(14): 37-41.

[10] CAO C T, LIN X H, XU L H. Short-term Traffic Flow Prediction Algorithm Based on FCM and Optimized SVR with Social Spider Optimization Algorithm [J]. Journal of China Academy of Electronics and Information Technology, 2017, 12(1): 52-59. (in Chinese)

曹成涛, 林晓辉, 许论辉. 联合FCM与群集蜘蛛优化SVR的短时交通流量预测 [J]. 中国电子科学研究院学报, 2017, 12(1): 52-59.

[11] ZHANG Y, HAGHANI A. A gradient boosting method to improve travel time prediction [J]. Transportation Research Part C, 2015, 58(2): 308-324.

[12] HUANG W, SONG G, HONG H, et al. Deep Architecture for Traffic Flow Prediction: Deep Belief Networks with Multitask Learning [J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(5): 2191-2201.

[13] YU D, LIU Y, YU X. A Data Grouping CNN Algorithm for Short-Term Traffic Flow Forecasting [J]. Web Technologies and Applications, 2016, 9931: 92-103.

[14] DUAN Y, LV Y, WANG F Y. Travel time prediction with LSTM neural network [C] // IEEE International Conference on Intelligent Transportation Systems, IEEE, 2016: 1053-1058.

[15] CHEN Z H, LAN Y Y, GUO J F, et al. Distributed Stochastic Gradient Descent with Discriminative Aggregating [J]. Chinese Journal of Computers, 2015, 38(10): 2054-2063. (in Chinese)

陈振宏, 兰艳艳, 郭嘉丰, 等. 基于差异合并的分布式随机梯度下降算法 [J]. 计算机学报, 2015, 38(10): 2054-2063.

[16] WEI S, WYNTER L. Rejoinder: real-time road traffic forecasting using regime-switching space-time models and adaptive lasso [M]. John Wiley and Sons Ltd, 2012: 297-315.

[17] HAO Y, BAI Y P, ZHANG X F, et al. Application of Convolution Neural Network in SAR Target Recognition [J]. Journal of Chongqing University of Technology (Natural Science), 2018, 32(5): 210-215. (in Chinese)

郝岩, 艳萍, 张校非, 等. 卷积神经网络在SAR目标识别中的应用 [J]. 重庆理工大学学报(自然科学), 2018, 32(5): 210-215.