

基于速度矩阵和人工神经网络的行程 时间组合离线预测模型

蔡火荣,何利力

(浙江理工大学信息学院,杭州 310018)

摘要:根据行程中车辆运行状态的时空相关性,结合矩阵的空间结构,构建了路段-时段平均速度矩阵,以表示车辆在行程中不同时空中的运行状态,并提出了一种基于该矩阵模拟车辆运行的行程时间离线预测模型。在此基础上,为了进一步提高该矩阵预测效果,结合相邻行程间的非线性规律,将路段-时间平均矩阵预测模型与BP神经网络模型相结合,构建出一种行程时间组合预测模型。以湖南中烟工业有限责任公司物流配送数据为数据集进行实验,结果表明:该组合模型的预测效果优于单一模型。

关键词:行程时间预测;人工神经网络;智能交通;时空相关性

中图分类号: TP183

文献标志码: A

文章编号: 1673-3851(2017)06-0851-08

0 引言

行程时间是反映交通状况的一个重要因素^[1]。准确行程时间预测是构建动态路径诱导系统、动态交通信息服务系统及信号协调控制系统的关键技术^[2]。在物流系统中,准确的行程时间预测,可以帮助企业对物流配送各个环节进行高效地协调和规划,从而节约物流成本,提高服务质量。对出行者而言,准确的行程时间预测有助于合理地规划工作和生活。行程中,车辆在行驶时由于受到多种复杂因素的影响,车辆的速度会不断地随之变化,车辆运行速度的变化最终导致了行程时间的变化。行程中影响车辆行驶速度的因素有交通流量、占有率、车辆类型及比例、自然灾害、交通事故等。其中交通流量、占有率、车辆类型及比例为常规因素,自然灾害和交通事故为非常规因素。Xia等^[3]也指出,行程中车辆运行状态的动态变化使得行程时间预测的变得困难。因此,通过研究行程中车辆运行速度的变化规律或影响车辆运行速度的相关因素的变化规律可进行行程时间的预测,如:任千里等^[4]根据交通断面流量差、断面速度差与行程时间的相关性,分别使用历

史平均法、神经网络、支持向量机和非参数回归模型分别对行程时间进行预测,并比较不同预测模型在不同距离行程下的预测效果;丁宏飞等^[5]从视频车牌系统中提取与行程中速度相关的交通流量、车辆类型及其比例等数据,并基于这些数据构建BP神经网络和SVM组合行程时间预测模型;姜桂艳等^[6]使用悉尼自适应交通控制系统(Sydney so-ordinated adaptive traffic system, SCATS)及视频检测器收集的交通数据,提出了基于行程特征向量相似度K-近邻(K-nearest neighbors algorithm, K-NN)行程时间预测模型;Li等^[7]将K-Means、决策树和人工神经网络三种算法模型相结合,利用K-Means和决策树提取有用特征提出了一种组合预测模型。目前大多数的此类研究都是针对常规因素对行程中车辆运行速度的影响及最终对行程时间的影响,针对非常规因素对行程时间影响研究相对较少。由于这些相关因素的数据只有在行程进行时才能获取,因而以上模型主要用于实时预测或在线预测。而在很多时候人们需要在行程开始之前知道行程将花费的时间,此时需要对行程时间进行离线预测即在行程开始之前预测行程时间。

然而,行程中车辆运行状态在时间和空间上的变化并非毫无规律,如:柏丛等^[8]根据路段行程时间与时段的相关性构建 SVM 模型对行程时间进行预测;Zou 等^[9]根据行程时间的时空相关性提出了时空昼夜方法(space-time diurnal method,S-TD)进行行程时间预测;Yildirimoglu 等^[10]根据历史行程中拥塞现象在时空上的复发性构建时空拥塞图(space-time stochastic congestion maps)来进行行程时间预测。由此可见,行程中车辆运行状态具有时空相关性。在现实中不难发现这种相关性,例如:某些路段会在一定的时间段进入“高峰期”^[11],在路段的“高峰期”车辆一般需花费较长的时间才能通过该路段。

为解决行程时间离线预测问题,本文结合这种时空相关性和矩阵的空间结构,提出路段-时段平均速度矩阵(section-time average velocity matrix,STAVM),并基于该矩阵模型提出一种行程时间离线预测模型。丁宏飞等^[5]、Siripanpornchana 等^[12]及叶创鑫等^[13]基于相邻行程之间的非线性关系,结合人工神经网络构建组合模型来对行程时间进行预测,进一步提高预测效果。本文根据相邻行程之间的非线性关系和行程自身的时空相关性,将该矩阵模型与 BP 神经网络模型相结合,构建了一种新的

行程时间离线组合预测模型,并通过实验证明了 STAVM 和组合模型的有效性。

1 算法及模型介绍

1.1 基于时空相关性的 STAVM 矩阵构建

行程中车辆运行状态的时空相关性,意味着车辆在行程中的运行状态不仅与车辆所处的路段有关,也与车辆运行的当前时间有关。这种多维的相关性与矩阵的空间结构有共同之处,因此采用矩阵模型来表示这种时空相关性下的车辆运行状态。设整个行程的距离为 D ,划分行程的单位距离 d_u 。划分的距离区间数为 ds :

$$ds = \lceil D/d_u \rceil \quad (1)$$

以同样的方式将一天的时间 $T = 24$ h,按照单位时间 t_u 划分,对应的时间区间数为 ts :

$$ts = \lceil T/t_u \rceil \quad (2)$$

根据式(1)和式(2)计算得到路段-时段平均速度矩阵 STAVM 的行数 ds 和列数 ts 。 $\mathbf{D}_{\text{satvm}}(i)(j)$ (其中 $0 \leq i < ds, 0 \leq j < ts$)表示车辆一天中的第 j 个时间段内通过第 i 个路段行的平均速度。

确定了 $\mathbf{D}_{\text{satvm}}$ 矩阵的结构以后,构建 STAVM 矩阵的流程如图 1 所示。算法伪代码如下:

算法 1:STAVM 矩阵构建算法

输入: $travelList, d_u, t_u$

输出: $\mathbf{D}_{\text{satvm}}$

```

1: 初始化  $\mathbf{D}_{\text{satvm}}, \mathbf{D}_{\text{count}}$ 
2: for  $GPSInfoListofonetravel$  in  $travelList$  do
3:    $d_{\text{start}} = GPSInfoListofonetravel[0].driveDistance$ 
4:    $t_{\text{start}} = GPSInfoListofonetravel[0].GPSTime$ 
5:   for  $GPSinfo$  in  $GPSInfoListofonetravel$  do
6:      $d = GPSinfo.driveDist - d_{\text{start}}$ 
7:      $t = GPSinfo.GPSTime - t_{\text{start}}$ 
8:     if  $d \geq d_u$  or  $GPSinfoList.next() == null$  then
9:        $speed = d / t$ 
10:       $distKey = getDistKey(GPSinfo.driveDistance)$ 
11:       $timeKey = getTimeKey(GPSinfo.gpsTime)$ 
12:       $\mathbf{D}_{\text{satvm}}[distKey][timeKey].totalSpeed += speed$ 
13:       $\mathbf{D}_{\text{count}}[distKey][timeKey] += 1$ 
14:       $d_{\text{start}} = GPSinfo.driveDist$ 
15:       $t_{\text{start}} = GPSinfo.gpsTime$ 
16:    end if
17:  end for
18: end for
19: for  $i = 1; i \leq ds$  do
```

```

20:   for  $j=1; j \leq ts$  do
21:       if  $D_{satvm}[i][j] > 0$  then
22:            $D_{satvm}[i][j].avgSpeed = D_{satvm}[i][j].totalSpeed / D_{count}[i][j]$ 
23:       end if
24:   end for
25: end for
26: return  $D_{satvm}$ 

```

相关变量说明: $travelList$ 为行程信息列表, D_{count} 为计数矩阵, d_{start} 为基准距离(路段分界点相对起点的距离), t_{start} 为基准时刻, d 为相对基准距离

d_{start} 的距离, t 为相对基准时刻 t_{start} 的时间。伪代码中第一个 for 循环对应图 1 中的①②③步,第二个 for 循环对应图 1 中的第④步。

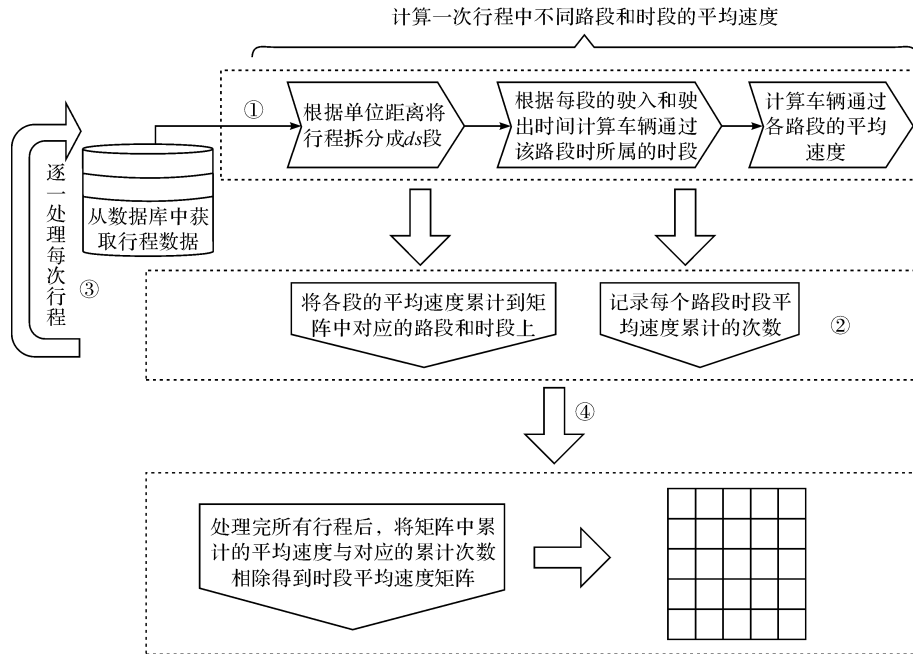


图 1 路段-时间平均速度矩阵流程

1.2 基于 STAVM 矩阵的行程时间离线预测模型

柏丛等^[8]和李进燕等^[14]在分时段对行程时间进行预测时,没有考虑车辆在经过某一路段的过程中可能会出现“跨时段”的现象。通过分析实际的行程发现,通常车辆经过一个路段会出现两种情况:第一种情况是车辆在通过某一路段时,始终处于同一时段。第二种情况为车辆在经过某一路段时会经历两个或两个以上的时段(当车辆某一时段的后半段进入新路段时,车辆还未通过该路

段而时刻已经进入了新的时段)。针对第二种情况柏丛等^[8]和李进燕等^[14]在确定车辆通过路段的时间时只选择其中一个时段对应行程时间作为预测值,未考虑跨时段的情况。本文根据路段-时段平均速度矩阵模拟车辆运行来进行行程时间预测,当车辆进入新的时段或新的路段时及时修正车辆的运行速度,矩阵预测算法的流程如图 2 所示。基于 STAVM 矩阵的行程时间离线预测算法伪代码如下:

算法 2:基于 STAVM 矩阵的行程时间离线预测模型

输入: t_{start} , D_{satvm} , d_{total}

输出: $t_{predict}$

```

1: 初始化  $d_{drive} = 0$ ,  $t_{drive} = currentTime()$ ,  $t_{start} = currentTime()$ 
2: while  $d_{drive} \leq distance$  do
3:      $d_{in} = getLeftDistInCurrentRoadSection(driveDist)$ 

```

```

4:    $t_{in} = \text{getLeftTimeInCurrentTimeSection}(\text{currentTime}())$ 
5:    $\text{distKey} = \text{getDistKey}(\text{driveDist})$ 
6:    $\text{timeKey} = \text{getTimeKey}(\text{currentTime}())$ 
7:    $\text{speed} = \mathbf{D}_{\text{satvm}}[\text{distKey}][\text{timeKey}].\text{avgSpeed}$ 
8:    $d = \text{speed} * t_{in}$ 
9:   if  $d_{in} > d$  then
10:     $d_{\text{drive}} = d_{\text{drive}} + t_{in} * \text{speed}$ 
11:     $t_{\text{drive}} = t_{\text{drive}} + t_{in}$ 
12:  else
13:     $d_{\text{drive}} = d_{\text{drive}} + d_{in}$ 
14:     $t_{\text{drive}} += t_{\text{drive}} + d_{in} / \text{speed}$ 
15:  end if
16: end while
17: if  $d_{\text{drive}} > \text{distance}$  then
18:    $t = (d_{\text{drive}} - \text{distance}) / \text{speed}$ 
19:    $t_{\text{drive}} = \text{driveTime} - t$ 
20: end if
21: return  $t_{\text{predict}} = t_{\text{drive}} - t_{\text{start}}$ 

```

相关变量说明： t_{start} 为行程开始时刻， t_{drive} 为当前时刻， t_{predict} 为预测的行程时间； $\mathbf{D}_{\text{satvm}}$ 为路段-时段平均速度矩阵， distance 为行程的总距离。伪代码第1步初始化数据， d_{drive} 为累计行驶距离。

其中，伪代码3—8行对应图2中的第①步，伪代码9—15行对应图2中的第②步，while循环对应图2中的第③步，伪代码17—21行对应图2中的第④步。

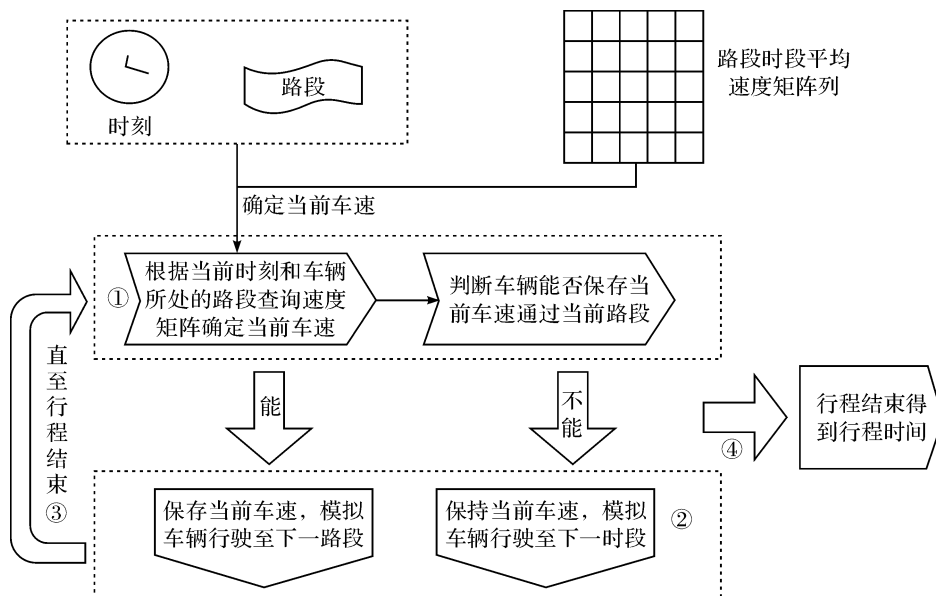


图2 基于STAVM矩阵的行程时间离线预测流程

1.3 STAVM矩阵与BP神经网络组合模型

人工神经网络 (artificial neural network, ANN) 是一种自适应非线性动态网络结构算法模型^[15]。人工神经网络通过模仿人脑的神经元的组织结构和活动机制获得学习能力。丁宏飞等^[5]、Siripornpornchana 等^[12]及叶创鑫等^[13]都通过构建

神经网络模型学习相邻行程之间非线性规律对行程时间进行预测。其中丁宏飞等^[5]先通过SVM模型对行程时间进行初步预测得到行程时间 t_1 ，然后通过BP神经网络学习相邻 k 次SVM模型预测误差之间的关系预测下一次SVM模型的预测误差时间 t_d ，最后将 t_1 与 t_d 相加得到组合预测时间。

STAVM 矩阵依据行程中车辆运行状态的时空相关性对行程时间进行预测。为了进一步提高预测灵活性和预测精度,同时利用行程中的时空相关性和行程间的非线性规律。本文将该矩阵预测模型与 BP 神经网络预测模型相结合,构建一种新的行程时间预测组合模型。模型的组合方式参考丁宏飞等^[5]采用的分步预测方式。第一步,使用历史行程数据构建 STAVM 矩阵,并使用 STAVM 矩阵模拟车辆运行来对行程时间进行初步预测,此时得到的时间为基础时间 t_s 。第二步,计算真实时间与基础时间的差值 t_d 如表 1 所示。差值 t_d 代表了行程时间相对基础时间的波动。第三步,使用 BP 神经网络的学习能力来预测相邻行程时间的这种波动。以相邻的 k 次的 t_d 为 BP 神经网络模型的输入,预测第 $k+1$ 次行程时间与基础时间的差值 $t_{(k+1)d}$ 。最终的行程时间通过式(3)计算:

$$t_i = t_{is} + t_{id} \quad (3)$$

其中 i 为行程编号。

表 1 真实时间、基础时间及对应的基础时间与真实时间差

行程编号	真实行程时间	矩阵预测基础时间	基础时间与真实时间差
1	t_1	t_{1s}	t_{1d}
2	t_2	t_{2s}	t_{2d}
...
n	t_n	t_{ns}	t_{nd}

2 实验过程及分析

本文以湖南中烟工业有限责任公司物流配送业务中车载 GPS 设备记录的历史数据为基础数据,数据时间范围为从 2016 年 1 月 23 日到 2016 年 9 月 29 日,选择其中配送较为频繁且数据相对完整的两条运输线路进行实验。运输线路一为从石家庄到长

沙,线路二为汉中到长沙。其中线路一行程数为 158 次,实验中训练集大小为 128,测试集为 30;线路二的行程数为 133 次,实验中训练集大小为 103,测试集为 30。GPS 设备定位采集的时间间隔为 4 min。实验中假设车辆在这 4 min 内行驶的线路为直线。采用的距离计算方式为测地距离,该计算方式由 Thaddeus Vincenty 于 1975 年提出的,采用 Vincenty 完全椭球公式^[16]进行计算。将经纬度转换为距离后的数据如表 2 所示。

表 2 Vincenty 完全椭球公式转换后的数据样本

行程编号	累计行驶距离/m	GPS 时间
HGPC601	1119.173836	2016-05-24 12:29:03
HGPC601	1503.002529	2016-05-24 12:33:03
HGPC601	2726.484108	2016-05-24 12:37:03

根据算法 1 计算得到的 STAVM 矩阵,为了直观地显示速度的分布,本文将 STAVM 矩阵转化成了在对应时段和路段上的速度热力图,图 3 为线路一的速度热力图。该图表示的是单位路段长度为 80 km、单位时段时长为 1 h 时对应的热力图,其中横轴表示时段,纵轴表示路段。由于 GPS 设备精度有限,因此根据 GPS 数据计算每次行程中车辆行驶的距离并非完全相等。为了让矩阵能够保证所有的历史行程都能完整的映射到 STAVM 矩阵中,扩大了 STAVM 矩阵在距离上的表示表示范围,因此图 3 中会出现最上面几行显示的颜色对应的速度为 0。STAVM 矩阵的每一列中格子的颜色深浅变化,表示在该路段不同时间段内车辆的平均行驶速度变化。从热力图来看,最下面的一行表示行程开始时不同时间区间内的速度,速度为非 0 的位置主要集中在中间偏右的位置,且这些色块对应的速度相对较小,与行程开始是车辆在非高速路上行驶时速度相对较低的事实相符。图 4 为线路二的速度热力图。其中单位路段的长度为 75 km、单位时段长为 1 h。




图 3 线路一 STAVM 速度热力图




图4 线路二 STAVM 热力图

将 STAVM 预测模型、简单 BP 神经网络模型和 STAVM 与 BP 神经网络组合模型分别进行实验预测。以均方误差根 (root mean squared error, RMSE) 和平均绝对误差百分比 (mean absolute percentage error, MAPE) 为实验结果的评价标准, 其计算公式分别为式(4)和式(5):

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (t_{\text{real}} - t_{\text{predict}})^2}{N}} \quad (4)$$

$$MAPE = \frac{100}{N} \sum \frac{|t_{\text{real}} - t_{\text{predict}}|}{t_{\text{real}}} \quad (5)$$

其中: t_{real} 为真实时间; t_{predict} 为模型预测时间; N 为测试集的大小。

MAPE 可以直观的表现预测值与真实之间偏差的程度, MAPE 越小则预测时间与真实时间的误差越小。而 RMSE 由于对大误差和小误差敏感, 所以 RMSE 可侧重比较不同模型预测的稳定性。经过实验, 在线路一中, 当单位距离设置为 80 km 单位时间设置为 1 h 时得到的 RMSE 达到最小为 4.36。在线路二中, 当单位距离为 75 km、但那位时间为 1 h 是得到最小 RMSE 为 4.12。本实验的神经网络模型设计为经典的 3 层模型, 将输入层神经元个数范围设定为^[2,15], 隐藏层神经元个数范围设置为^[2,30], 通过穷举各层神经元个数的组合设计不同的神经网络模型, 然后逐一进行实验。最终的使用结果显示当输入层和隐藏层的神经元个数均为 7 时组合模型预测结果的 RMSE 达到最低为 4.03。组合模型输入层神经元个数与其对应的最低 RMSE 变化过程如图 5。柏丛等^[8]使用 SVM 模型对行程时间进行离线预测, 作为对比本文以行程进行的时间段及在一周中对应的天构建 SVM 模型对路段行程时间进行预测。通过交叉验证 (cross validation) 和 grid search 进程参数选择, 以

RMSE 为优化目标, 线路一最终得到 SVM 模型的径向基函数惩罚系数 $C=3$, 径向基函数参数 $\gamma=0.07262$, 线路二最终得到的 SVM 模型的径向基函数惩罚系数 $C=3$, 径向基函数参数 $\gamma=0.07132$ 。




图5 输入层神经元个数与 RMSE 的对应关系

表 3 和表 4 分别为线路一和线路二简单历史平均模型、SVM 模型、STAVM 模型、BP 神经网络模型和组合模型预测结果。

表3 线路一各模型实验结果对应 RMSE 和 MAPE

模型	RMSE/h	MAPE/%
简单历史平均模型	6.38	20.47
SVM	5.92	22.97
STAVM	4.36	17.06
BP 神经网络	6.32	22.29
组合模型	4.03	15.44

表4 线路二各模型实验结果对应 RMSE 和 MAPE

模型	RMSE/h	MAPE/%
简单历史平均模型	6.43	21.93
SVM	6.03	21.96
STAVM	4.52	18.93
BP 神经网络	6.46	23.71
组合模型	3.99	16.20

由表 3 和表 4 可知, 组合模型预测效果优于简单历史平均模型、STAVM、BP 神经网络模型和 SVM 模型。

在线路一中,从 RMSE 来看,简单 BP 神经网络模型、简单历史平均模型和 SVM 模型的预测效果比较相近,分别为 6.32、6.38 h 和 5.92 h。STAVM 预测模型与以上三种模型的 RMSE 相比分别降低了 1.96、2.02、1.56 h。由此可见 STAVM 预测组合模型的有效性。组合模型的 RMSE 与简单 BP 神经网络模型、简单历史平均模型、SVM 模型和 STAVM 模型相比分别降低了 2.29、2.35、1.89 h 和 0.33 h,由此可见组合模型可以进一步提高 STAVM 模型预测的稳定性。从 MAPE 来看,简单 BP 神经网络模型、简单历史平均模型和 SVM 模型的预测结果的平均绝对误差百分比分别为 22.29%、20.47%和 22.97%。STAVM 预测模型 MAPE 为 17.06%,明显低于以三种模型,与以上三种模型相比分别降低了 5.23%、3.41%、5.91%。组合模型的 MAPE 为 15.44%,与简单 BP 神经网络模型、简单历史平均和 SVM 模型三种模型相比分别降低了 6.85%、5.03%和 7.53%。与 STAVM 模型相比降低了 1.62%进一步减少了平均绝对误差,提高了预测效果。

在线路二中,简单 BP 神经网络模型、简单历史平均模型和 SVM 模型的 RMSE 分别为 6.46、6.43 和 6.03。STAVM 预测模型与以上三种模型的 RMSE 相比分别降低了 1.94、1.91、1.51。组合模型的 RMSE 与简单 BP 神经网络模型、简单历史平均模型、SVM 模型和 STAVM 模型相比分别降低了 2.47、2.44、2.04 和 0.53。从 MAPE 来看,简单 BP 神经网络模型、简单历史平均模型和 SVM 模型的预测结果的平均绝对误差百分比分别为 23.71%、21.93%和 21.96%。STAVM 预测模型 MAPE 为 18.93%,与以上三种模型相比分别降低了 4.78%、3.00%、3.03%。组合模型的 MAPE 为 16.20%,与简单 BP 神经网络模型、简单历史平均和 SVM 模型三种模型相比分别降低了 7.51%、5.73%和 5.76%。与 STAVM 模型相比降低了 2.73%。

通过与简单 BP 神经网络模型、简单历史平均和 SVM 模型的预测效果相比较,可见 STAVM 模型能够利用了行程时间的时空相关性可以对行程时间进行有效的离线预测,而 STAVM 模型和 BP 神经网络模型的组合模型能够进一步提高对行程时间的离线预测效果。

3 结 论

本文根据行程中车辆运行状态的时空相关性构

建路段-时段平均速度矩阵,以此来表示车辆运行状态在整个行程中不同路段和不同时段这个二维空间上的变化规律。并基于该矩阵模型提出一种行程时间预测算法对行程时间进行离线预测。为进一步提高预测效果,结合车辆运行状态的时空相关性和相邻行程的非线性规律构建组合模型对行程时间进行离线预测。并通过实验证明了该组合模型的有效性。该组合模型相对单一模型在准确率上虽然有明显的提升,但依然有大约 15%的平均绝对误差,因此还有一定的提升空间。下一步工作将通过扩大数据源的信息维度或进一步优化模型来研究提高预测精度的方法。

参考文献:

- [1] 唐少虎,刘小明,陈兆盟,等. 基于计算实验的城市道路行程时间预测与建模[J]. 自动化学报,2015,41(8): 1516-1527.
- [2] 于德新,高学英,杨兆升. 基于 GPS 数据及车辆运行特性分析的单车路段行程时间估计[J]. 吉林大学学报:工学版,2010,40(4):965-970.
- [3] XIA J, CHEN M, HUANG W. A multistep corridor travel-time prediction method using presence-type vehicle detector data[J]. Journal of Intelligent Transportation Systems,2011,15(2):104-13.
- [4] 任千里,刘恒,雷晓斌,等. 基于车牌照数据的城市快速路行程时间短时预测方法研究[J]. 交通与运输,2011,27(B12):61-65.
- [5] 丁宏飞,李演洪,刘博,等. 基于 BP 神经网络与 SVM 的快速路行程时间组合预测研究[J]. 计算机应用研究,2016,33(10):2929-2932.
- [6] 姜桂艳,李琦,董硕. 基于 k-NN 和 SCATS 交通数据的路段行程时间估计方法[J]. 西南交通大学学报,2013,2:025.
- [7] LI C S, CHEN MC. A data mining based approach for travel time prediction in freeway with non-recurrent congestion[J]. Neurocomputing,2014,133(8):74-83.
- [8] 柏丛,彭仲仁. 基于动态模型的公交车行程时间预测[J]. 计算机工程与应用,2016,52(3):103-107.
- [9] ZOU Y, ZHU X, ZHANG Y, et al. A space-time diurnal method for short-term freeway travel time prediction[J]. Transportation Research Part C: Emerging Technologies, 2014,43:33-49.
- [10] YILDIRIMOGLU M, GEROLIMINIS N. Experienced travel time prediction for congested freeways [J]. Transportation Research Part B: Methodological, 2013,53(4):45-63.
- [11] 许丽,朱庆,陈崇泰,等. 自动预测通勤高峰期交通流量

- 的方法[J]. 地理信息世界, 2016, 23(2):16-20.
- [12] SIRIPANPORNCHANA C, PANICHPAPIBOON S, CHAOVALIT P. Travel-time prediction with deep learning [C]//Region 10 Conference (TENCON). IEEE, 2016:1859-1862.
- [13] 叶创鑫, 谭满春. 基于 SVM 与人工神经网络组合模型的物流规划车辆行程时间预测[J]. 暨南大学学报(自然科学与医学版), 2010, 31(5):451-456.
- [14] 李进燕, 朱征宇, 刘琳, 等. 基于简化路网模型的卡尔曼滤波多步行程时间预测方法[J]. 系统工程理论与实践, 2013, 33(5):1289-1297.
- [15] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6):1229-1251.
- [16] VINCENTY T. Direct and inverse solutions of geodesics on the ellipsoid with application of nested equations [J]. Survey review, 1975, 23(176):88-93.

A Combined Offline Travel Time Prediction Model Based on Speed Matrix and Artificial Neural Network

CAI Huorong, HE Lili

(School of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: According to the temporal and spatial correlation of the driving state of the vehicle in the itinerary and the spatial structure of matrix, a section-time average velocity matrix was proposed to express the driving state of the vehicle at different time and space in the itinerary. Besides, an offline travel time prediction model based on the matrix was presented to simulate the driving of the vehicle. In order to improve the prediction effect of the matrix, the section-time average velocity matrix and BP neural network model were combined to construct a combined travel time prediction model by combining nonlinear rules of adjacent itineraries. The experimental results based on actual logistics system data from China Tobacco Industrial CO., LTD. showed that the predicting effect of the combined model is better than that of single model.

Key words: travel time prediction; artificial neural network; intelligent transportation system; spatial and temporal correlation

(责任编辑: 康 锋)