

基于对比度和共识日的交通速度预测

孙秋霞,孙砚琦,李 劼

(山东科技大学 数学与系统科学学院,山东 青岛 266590)

摘要:交通速度预测是智能交通系统中研究热点内容之一,准确预测交通速度有助于为出行者提供可靠的出行决策。考虑到路网中交通速度变化的时空关联性和规律性,本研究提出一种基于对比度和共识日的交通速度预测方法。首先,为捕捉短小时内速度的变化特征,挖掘道路的空间关联性,构建对比度模型并根据其值更新历史数据的交通状态集;其次,采用 K-means 方法对更新后的数据集进行聚类,通过 Rand 指数识别出每簇的共识日,并根据其信息预测交通速度;最后,借助 RMSE、MAE 和 ACC 等指标分析了预测方法的有效性。分析结果表明,本研究方法预测准确率达 93.8%,预测精度较高,计算速度较快,具有更好的适用性。

关键词:智能交通;对比度;聚类分析;共识日识别;速度预测

中图分类号:U121

文献标志码:A

Traffic speed prediction based on contrast and consensus days

SUN Qiuxia, SUN Yanqi, LI Qing

(College of Mathematics and Systems Science, Shandong University of Science and Technology, Qingdao 266590, China)

Abstract: Traffic speed prediction is one of the hot topics in intelligent transportation system. Accurate prediction helps travelers to make reliable travel decisions. Considering the temporal and spatial correlation and regularity of traffic speed changes in road networks, this study proposed a traffic speed prediction method based on contrast and consensus days. Firstly, to capture the characteristics of speed changes in a short time and mine the spatial correlation characteristics of roads, a contrast model was constructed and the traffic state set of historical data was updated according to its value. Secondly, the updated data set was clustered by using K-means method and the best consensus day of each cluster was identified by adopting Rand index. Based on the obtained information, the traffic speed was predicted. Finally, the validity of the prediction model was analyzed by using RMSE, MAE and ACC. The results show that the proposed method, with a prediction accuracy of 93.8%, has higher prediction accuracy, faster calculation speed, and better applicability.

Key words: intelligent transportation; contrast; cluster analysis; recognition of consensus day; speed prediction

加快建设城市智能交通系统(intelligent transportation system, ITS)是改善交通拥堵、提高运行效率、减少空气污染等交通问题的有效途径。交通预测方法的研究既能够为 ITS 实现交通信息发布与诱导功能提供技术支撑,又可以帮助出行者提前规划路径。城市交通速度预测为出行者提供及时交通信息的同时,在一定程度上对提升道路通行能力、缓解拥堵具有重要作用。

目前,国内外学者针对交通速度预测方法做了大量研究,概括起来可分为三类:统计方法、机器学习方法

收稿日期:2022-06-02

基金项目:山东省自然科学基金项目(ZR2021MF113)

作者简介:孙秋霞(1976—),女,山东济宁人,副教授,博士,主要从事交通大数据分析建模研究。

孙砚琦(1998—),女,山东潍坊人,硕士研究生,主要从事交通大数据分析研究,本文通信作者。

E-mail:1028265119@qq.com

和深度学习方法。统计方法是根据历史交通信息进行分析,挖掘其统计规律,并据此进行预测,如 Chandra 等^[1]采用自回归移动平均模型(autoregressive integrated moving average model, ARIMA)进行交通速度预测,考虑上下游对中间位置的影响,得到较好的速度预测结果;王伟等^[2]利用灰色预测模型(gray forecast model, GM)对快速路点速度进行预测,并结合实例进行了验证,预测结果与实验数据吻合较好;为了进一步提高传统 ARIMA 模型的适用性、使用有限的输入数据进行预测, Kumar 等^[3]构建季节性差分自回归滑动平均模型(seasonal autoregressive integrated moving average, SARIMA)模型进行短期交通预测,但这些模型不能很好地处理复杂动态的时间序列。相对于统计方法,机器学习方法能够更好地处理复杂的交通数据,如 Sun 等^[4]根据拥堵程度将交通状况识别为多个状态组合,并将其纳入动态贝叶斯网络(dynamic Bayesian networks, DBN)中,提高了预测准确率; Satrinia 等^[5]采用地图匹配法得到更加准确的轨迹数据,利用支持向量回归(support vector regression, SVR)方法预测未来的交通速度,具有良好的预测性能; Agafonov 等^[6]提出一种基于 K 近邻法的分布式短期交通流预测方法,该方法同时考虑了交通流的时空分布与目标路段的特征向量,提高了预测精度,但仅使用机器学习,对数据特征的提取不足; Zheng 等^[7]提出一种基于长短时记忆(long-short term memory, LSTM)网络的交通预测方法,通过由多个存储单元组成的二维网络来考虑交通系统的时空相关性;为了提高 LSTM 网络的预测精度, Liu 等^[8]提出使用卷积神经网络(convolutional neural networks, CNN)提取数据的空间特征,该方法使用由流量、速度和占用率构成的三维数据矩阵,可以展现不同时空数据对预测任务的影响。为了进一步挖掘路网的时间特征,陈丹蕾等^[9]提出将图卷积神经网络(graph convolutional network, GCN)与门控循环单元(gate recurrent unit, GRU)组合的短时交通流预测方法,采用图卷积神经网络聚合空间特征和门控循环单元方法提取路网时间特征,具有相对较高的稳定性及预测精度。相对于前两种方法,深度学习方法能够较好地挖掘交通特性,往往具有更好的预测精度。上述研究旨在提高速度的预测精度,多对历史数据集进行训练,但未较好地考虑交通流数据本身的意义,忽视了方法的可解释性。

在实际应用中,交通流数据具有一定的规律性和时空关联性,充分挖掘数据的特征,可以更好地把握其变化趋势。文献[10-13]采用变权重组合模型分析短时交通流信息,结果表明组合模型发挥了各自的优势,提高了预测精度;刘新民等^[14]利用 Fisher 算法对客流数据聚类,选择 ARIMA 模型以及 SARIMA 模型开展公交客流量预测;王旭鹏等^[15]提出一种基于相似性聚类的交通流概率组合模型,对具有周期相似性的交通流数据进行分类,针对同类特征的数据集构建子组合模型进行加权预测,但融合多个模型需要较长的计算时间; Chiabaut 等^[16]提出一种基于拥堵图和共识日的预测方法,该方法定义 2 个交通状态集,使用拥堵图来演示速度的变化情况,从速度聚类后的每一簇中确定最具代表性的一天作为共识日,利用共识日的信息进行速度预测,但准确率不高。为了更好地捕捉短时间内速度的变化趋势, Zaki 等^[17]使用对比度指标挖掘 90 min 速度的变化趋势,定义 9 个交通状态集,并使用隐马尔可夫模型进行速度预测,取得较好的预测效果。

综上所述,现有研究在提高交通速度的预测精度时,往往忽略了方法的可解释性,而且在利用多模型融合进行预测时,增加了模型的运算时间。本研究提出一种基于对比度和共识日的交通速度预测方法,利用对比度指标挖掘路网交通速度在时间上的变化趋势及其上下游之间的空间关联性来识别共识日,并利用共识日中的交通状态信息实现交通速度的准确预测。该方法对训练数据集进行聚类,减少了数据的处理量,降低了预测方法的运算时间。

1 研究区域及数据处理

本研究选用美国加州交通性能测量系统(performance measurement system, PeMS)^[18]提供的数据集验证方法的有效性,数据集的探测器采用地图匹配方法对应到实际道路中。道路的交通状态具有一定的规律性,为了更好地捕捉道路的时空特征,本研究选取加州 I680 高速路某路段 13 个探测器的交通速度数据,时间区间为 2017 年 1 月 2 日—6 月 6 日,共 156 天;探测器每 5 min 抓取 1 次车道的速度数据,每个探测器每天从 6:00—22:00 观察交通速度 193 次,并以“天”为单位对数据进行分区。

1.1 地图与数据匹配

借助美国高速公路网络地图数据获得底图,其中包括高速公路的位置信息和属性信息。采用 ArcGIS 技术将 PeMS 提供的数据与美国加州 I680 高速公路网络地图进行匹配,实现探测器数据空间属性与实际地理位置相对应。

1.2 速度数据预处理

本研究中速度范围为 $0 \leq v \leq 90$ km/h,若将速度观测值直接引入,计算量较大。为了降低计算量,将速度值每 5 km/h 划分一个速度等级。由于 $0 \sim 10$ 、 $80 \sim 90$ km/h 的数据量较少,这两个区间不再进行细分,从而将速度划分为 16 个等级,如表 1 所示。用速度等级序号表示速度,例如速度为 $30 \sim 35$ km/h 用数字 6 表示。

表 1 根据速度范围划分速度等级

Table 1 Speed levels classified according to speed range

速度等级	速度值/(km/h)	速度等级	速度值/(km/h)
1	$0 < v \leq 10$	9	$45 < v \leq 50$
2	$10 < v \leq 15$	10	$50 < v \leq 55$
3	$15 < v \leq 20$	11	$55 < v \leq 60$
4	$20 < v \leq 25$	12	$60 < v \leq 65$
5	$25 < v \leq 30$	13	$65 < v \leq 70$
6	$30 < v \leq 35$	14	$70 < v \leq 75$
7	$35 < v \leq 40$	15	$75 < v \leq 80$
8	$40 < v \leq 45$	16	$80 < v \leq 90$

2 基于对比度和共识日的交通速度预测方法

2.1 对比度方法

为了探寻速度数据集中隐藏的交通变化规律,对每 5 min 的滚动时间窗口内速度数据进行统计分析。滚动窗口向前每滚动一次,将捕获一个新的速度数据并删除最早的一个数据,以此捕捉每个探测器 30 min 内的交通状态变化趋势。

对比度^[19]是一个二阶统计量,可用来研究交通状态短时间内的变化程度,高对比度代表短时间内交通状态变化剧烈,如速度急速升高形成自由流或急剧下降造成拥堵;低对比度代表交通状态在稳定条件下变化,如稳定的自由流或拥堵状态。对比度通过灰度共生矩阵(gray-level co-occurrence matrix, GLCM)进行计算。GLCM 是从图像处理领域发展起来的,通过研究图像灰度的空间相关特性来描述纹理的常用方法。

本研究中,令 c_i 、 c_j 分别为某探测器在 i 、 j 时刻测得的速度等级, d 表示 c_i 、 c_j 在速度序列中位置的距离,灰度共生矩阵可以表示为: $\mathbf{A} = (a_{c_i, c_j})_{M \times M}$ 。式中: $a_{c_i, c_j} = \frac{\text{num}\langle c_i, c_j \rangle}{N}$, $\text{num}\langle c_i, c_j \rangle$ 为速度等级对 $\langle c_i, c_j \rangle$ 出现的次数, N 为整个速度等级序列所包含的数据对总数量,则 a_{c_i, c_j} 表示速度等级对 $\langle c_i, c_j \rangle$ 出现的频率; M 为速度等级总数量。故对比度表示为:

$$C_{\text{CON}} = \sum_{c_i, c_j} |c_j - c_i| (c_j - c_i) \frac{\text{num}\langle c_i, c_j \rangle}{N} \tag{1}$$

以速度等级数为 6 的速度序列 $O = \{6, 6, 5, 6, 6, 4\}$ 为例,如图 1 所示。由于数据点是按时间测量的,所以本研究只考虑距离 $d = 1$ 的连续数据对,对比度的正、负值分别表示速度有增加或减少的趋势。图 1 中相邻数据点的值为 6 的成对数为 2,序列总的成对数为 5,可计算出 $a_{6, 6} = 0.4$ 。每两个连续的数据序列组成一对,根据式(1)可计算序列对比度 $C_{\text{CON}} = (6 - 5)^2 \times 0.2 - (6 - 4)^2 \times 0.2 - (6 - 5)^2 \times 0.2 + (6 - 6)^2 \times 0.4 = -0.8$ 。

2.2 基于聚类结果确定共识日

交通状态具有一定的规律性,挖掘历史的交通状态,从历史数据中获得有用的信息,对于预测交通速度和状态具有重要意义。为有效利用历史数据,本研究利用 K -means 聚类方法对具有相似模式的“天”进行聚类,以减少状态的随机性。




图 1 交通速度序列的灰度共生矩阵
Fig. 1 GLCM of traffic speed sequence

为了减少预测模型的运算时间,根据聚类结果确定簇中最具代表性的“天”,将共识日学习方法^[16]引入本研究。共识日学习方法是根据聚类日之间速度等级的相似程度确定每簇的共识日,利用共识日的历史数据进行速度预测。本研究采用 Rand 指数计算聚类日之间速度等级的相似程度,第 d 天和第 p 天相似度为:

$$R(d, p) = \frac{\text{num}\{V_{d,l}(t) - V_{p,l}(t) = 0\}}{M}, l = 1, 2, \dots, 13. \quad (2)$$

式中: $V_{d,l}(t)$ 表示探测器 l 在第 d 天 t 时段内的速度等级, $\text{num}\{V_{d,l}(t) - V_{p,l}(t) = 0\}$ 表示探测器 l 在第 d 天和第 p 天 t 时段内速度等级相同的时段数量, M 表示一天中所有的时段数量。

定义簇 C_k 中的共识日 d_k 为簇内 Rand 指数之和最大的一天,即:

$$d_k = \arg \max_{d \in C_k} \left\{ \sum_{p \in C_k} R(d, p) \right\}. \quad (3)$$

因此,根据全部历史数据集确定共识日 d_k 的集合,记作 D_k 。

2.3 速度预测

速度预测的基本思路是利用共识日实时预测交通速度的变化,考虑一个新观测日 d_i ,在 t 时段内确定最接近该观测日的最佳共识日 $d_i^*(t)$ 。为预测 $t+1$ 时段的速度等级,利用式(4)分别计算新观测日与 D_k 中每一共识日 $t+1$ 时段前内速度等级的 Rand 指数,计算 Rand 指数值最大的共识日 $d_i^*(t)$ 作为最佳共识日。

$$d_i^*(t) = \arg \max_{d_k \in D_k} \{R(d_i, d_k)\}. \quad (4)$$

确定最佳共识日后,利用 $d_i^*(t)$ 中的 $t+1$ 时段的历史数据 $V_{d \in D_k, l}(t+1)$ 预测 d_i 天 $t+1$ 时段内的速度等级,即第 d_i 天的交通速度等级 $V_i^*(t+1)$ 预测值为:

$$V_i^*(t+1) = V_{d_i^*(t), l}(t+1). \quad (5)$$

最后,根据速度等级值 $V_i^*(t+1)$,预测 $t+1$ 时段的平均速度。

3 实验分析

3.1 对比度映射与速度等级更新

本研究使用对比度和平均速度构建一个 2D 空间表示不同的速度等级。用探测点 30 min 内的连续 6 个速度值构成一个速度序列计算对比度,且每 30 min 计算一次平均速度,如果短时间内速度变化很小,对比度应该为 0 或绝对值比较小。图 2 为选取 10% 历史数据绘制的速度与对比度的散点图,图中对比度值为 0 的点表示速度等级无变化。




图 2 速度与对比度的散点图
Fig. 2 Scatter plot of speed and contrast

从图 2 可以看出,对比度值 (C_{CON}) 多分布在 $-2 \sim 2$ 内,因此以 $-2 \leq C_{CON} \leq 2$ 为边界,边界以内的区域表示交通状态变化不大,边界以外的区域对比度较大,代表交通状态有较大的变化。引入对比度后,最初划定的速度等级(表 1)不能很好地反映短时间内速度的变化趋势,所以根据对比度值将速度等级进行更细致地划分。重新划分后的速度等级见表 2。

3.2 确定最佳聚类数

对数据集进行聚类之前,首先需确定聚类的数目 k 。本研究采用轮廓系数(silhouette coefficient, SC)和簇内误方差(sum of squares for error, SSE)两个指标来确定最佳聚类数。

轮廓系数是评价聚类效果的评价指标之一,综合考虑了内聚度和分离度两种因素,可以得到较优的聚类数目。轮廓系数值越接近 1,说明样本聚类结果越合理;越接近 -1,说明样本更应该被分类到另外的簇。SSE 的核心思想是计算簇内误方差和,其值越小,表示聚类效果越好。轮廓系数和簇内误方差随聚类数目的变化情况如图 3 所示。

表2 更新后的速度等级集
Table 2 Updated set of speed levels

速度/(km/h)	速度等级			速度/(km/h)	速度等级		
	$C_{CON} < -2$	$-2 \leq C_{CON} \leq 2$	$C_{CON} > 2$		$C_{CON} < -2$	$-2 \leq C_{CON} \leq 2$	$C_{CON} > 2$
$0 \leq v \leq 10$	1	2	3	$45 < v \leq 50$	25	26	27
$10 < v \leq 15$	4	5	6	$50 < v \leq 55$	28	29	30
$15 < v \leq 20$	7	8	9	$55 < v \leq 60$	31	32	33
$20 < v \leq 25$	10	11	12	$60 < v \leq 65$	34	35	36
$25 < v \leq 30$	13	14	15	$65 < v \leq 70$	37	38	39
$30 < v \leq 35$	16	17	18	$70 < v \leq 75$	40	41	42
$35 < v \leq 40$	19	20	21	$75 < v \leq 80$	43	44	45
$40 < v \leq 45$	22	23	24	$80 < v \leq 90$	46	47	48




图3 利用轮廓系数和簇内误差方差确定最佳聚类数目

Fig. 3 Optimal number of clusters determined by silhouette coefficient and sum of squares for error

从图3(a)可以看出,聚类数目 k 在区间 $[15, 20]$ 内轮廓系数值逐渐变大,可得到一个局部最优值,当 $k > 20$ 时,轮廓系数值下降并且逐渐趋于稳定。从图3(b)可以看出,当 $k = 18$ 时,SSE出现了最小值。因此,综合考虑轮廓系数和簇内误差方差,本研究聚类数目取18,既保证了簇的多样性,也保证了每个簇中有足够的天数(平均超过5天),具有可接受的簇内同质性和簇间相异性。

3.3 聚类后分析

历史数据完成聚类后,对簇中的“每天”进行 Rand 指数计算,确定每簇的共识日。为了直观看出每簇共识日交通状态变化趋势,呈现各簇的速度等级变化趋势差异,描绘共识日 d_k 的速度等级热力图。图4展示了包含天数最多的前6个簇的共识日速度等级热力图,其顺序按照簇大小进行排列。

图4中,颜色越浅,速度等级值越小,代表道路越拥堵;颜色越深,速度等级值越大,代表道路越通畅。可以看出,图4(a)簇1和图4(d)簇4中的浅色区域较少,速度等级值基本都在30以上,没有明显的早高峰拥堵现象,属于自由流日;而图4(b)、4(c)、4(e)、4(f)簇2、3、5、6中的浅色区域较多,且集中分布在6:30—9:00和16:30—19:00时段,具有较明显的早晚高峰现象,且每个簇又呈现出不同于其他簇的特征,如6:30—9:00时段内簇2在6号探测器处较为拥堵,而簇3在1、6、8、9、10号探测器处较为拥堵。

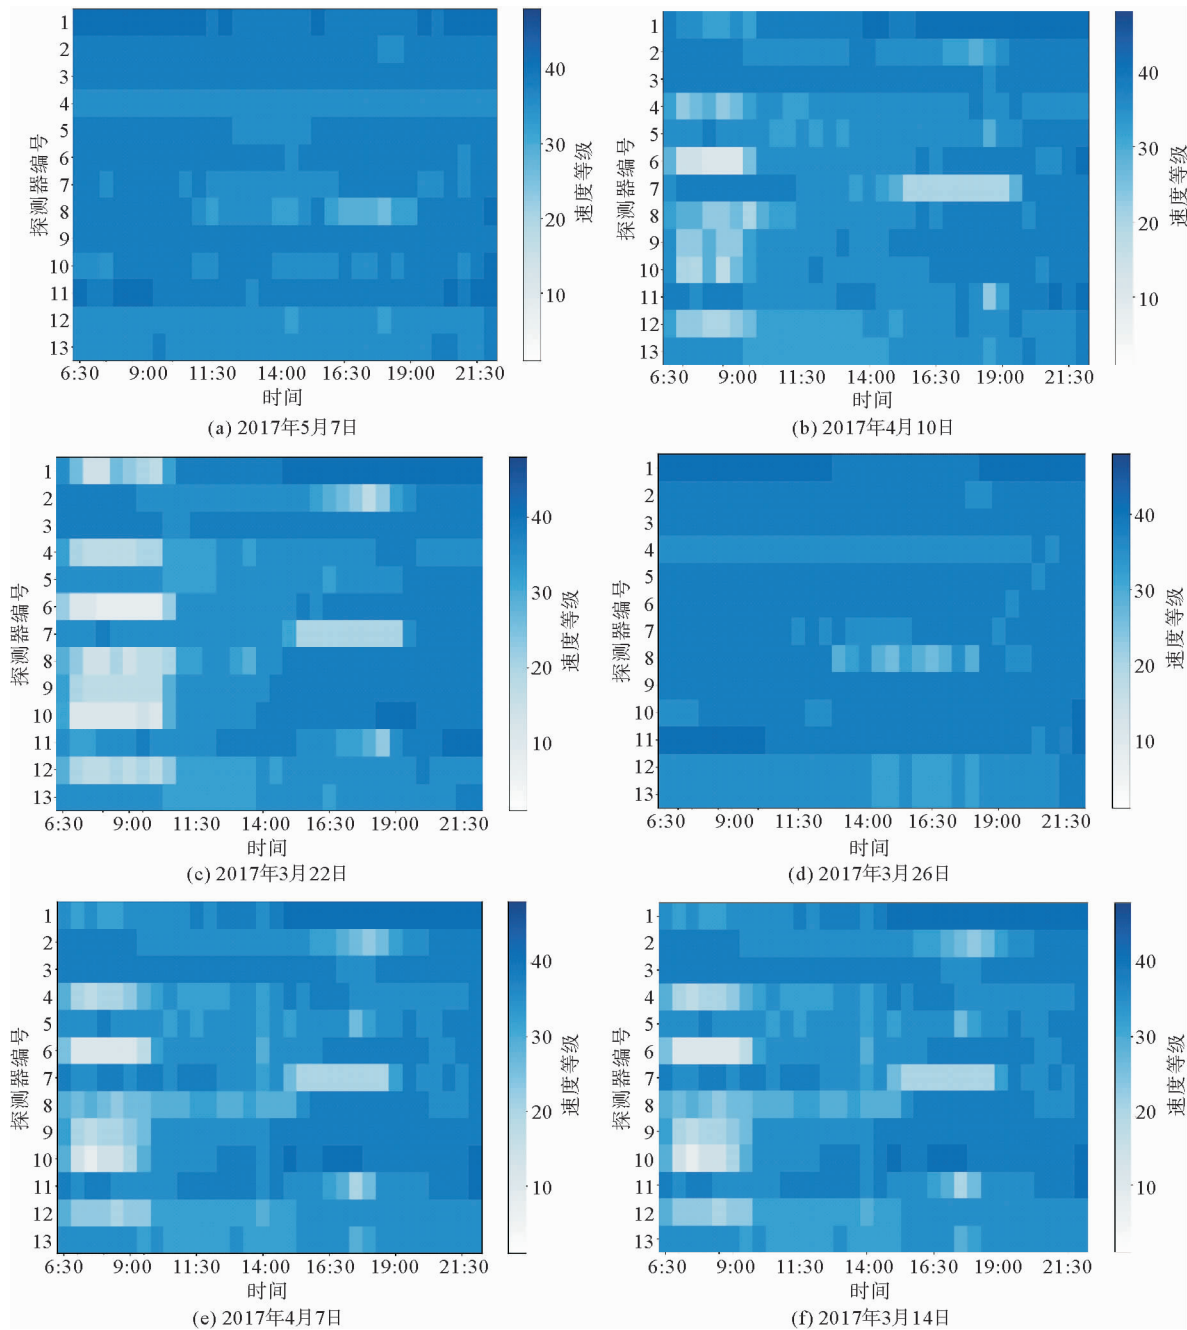


图 4 包含天数最多的前 6 个簇的共识日速度等级热力图

Fig. 4 Thermodynamic diagram of consensus day traffic levels for the top 6 clusters with the most days

为了更直观地观察聚类结果,图 5 展示了相同簇和不同簇在“周”和“月”中的分布情况。由图 5 可以看出,簇 1 和簇 4 中只包含周六、周日,结合图 4 可知,周六和周日主要为自由流日,簇 1 集中分布在 3、4 月份,而簇 4 集中分布在 1、2 月份;簇 2 中包含周一和周四,主要分布在 1 至 4 月份;簇 3 和簇 5 中聚类周二和周三,且簇 3 中周三居多,簇 5 中周二居多;簇 6 只包含了周五。上述只分析了 6 个天数最多的簇,在其余簇中周分布和月分布也有明显的分布特征,例如簇 17 和簇 18 只分布在 5 月。

3.4 预测结果及分析

本研究使用全局预测的方法,主要预测速度指标。将数据集分为训练集(150 天)和测试集(6 天)。在预测过程中,为了捕捉历史速度变化的规律,设置持续学习时间 $\Delta t = 3$ h,用于学习历史时间序列中包含的 36 个速度值,同时利用对比度指标挖掘每 30 min 的速度变化趋势特征;设置预测的时间范围 $\sigma_t = 0.5$ h。通过

对比实验发现,更新预测速度的时间范围阈值设置 $\delta_t = 4$ h 时,预测效果最好。




图 5 每簇周和月贡献的桑基图

Fig. 5 Sankey diagram of daily and monthly contribution of each cluster

采用平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)作为度量模型预测误差的指标,用 M_{AE} 表示预测值和观测值之间绝对误差的平均值, R_{MSE} 表示预测值和观测值之间残差的样本标准偏差,分别为:

$$M_{AE} = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i|, \tag{6}$$

$$R_{MSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2}. \tag{7}$$

式中: y_i 为真实值, \hat{y}_i 为预测值, m 为样本数量。

另外,采用准确率(accuracy, ACC)作为度量模型准确率的指标,通过构建混淆矩阵来计算准确率为:

$$A_{CC} = \sum_i \frac{T_{P,i}}{T_{P,i} + F_{N,i}}. \tag{8}$$

式中: A_{CC} 为准确率; $T_{P,i}$ 为实际速度区间为 i 、预测区间为 i 的速度个数; $F_{N,i}$ 为实际速度区间不是 i 、预测区间为 i 的速度个数。

为了验证本方法的有效性,分别与捕捉线性关系效果比较好的 ARIMA^[1]、适于指数型增长预测的 GM^[2]、适用非线性分类回归问题的 SVR^[5]、能够捕捉路网络时空相关性的 LSTM^[7] 以及共识日^[16] 等预测方法进行对比,预测效果如表 3 所示。

由表 3 可以看出,相较于其他预测方法,本研究提出的方法具有更高的预测精度,达到 93.8%,并且与 ARIMA、GM、SVR、LSTM 等 4 种方法相比,本方法的运算时间更短,预测速度更快。这是由于引入共识日学习方法,将训练数据集由 150 天聚类成 18 个簇,每个簇确定一个最具代表性的“天”作为共识日,利用共识日的历史数据进行速度预测,与上述 4 种方法相比,减少了数据的处理数量,降低了计算时间。

表 3 实验结果对比

Table 3 Comparison of experimental results

方法	RMSE	MAE	ACC/%	运算时间
ARIMA	8.392 8	4.150 7	90.3	25'41"
GM	9.653 6	6.257 5	88.4	20'27"
SVR	6.408 7	3.630 3	91.5	31'32"
LSTM	5.769 2	3.443 0	92.8	18'14"
共识日	12.574 4	7.237 8	83.4	10'25"
本方法	5.713 2	3.086 2	93.8	11'34"

与文献[16]的共识日预测方法相比,由于对比度指标的引入,尽管本研究方法的运算时间增加了,但预

测结果准确率提高了 10.4%,能更好地捕捉短时间速度变化趋势,增加的运算时间在可接受范围内。

为进一步验证引入对比度指标的有效性,图 6 分别展示了 6 天未加入对比度指标和加入对比度指标的速度预测结果折线图。

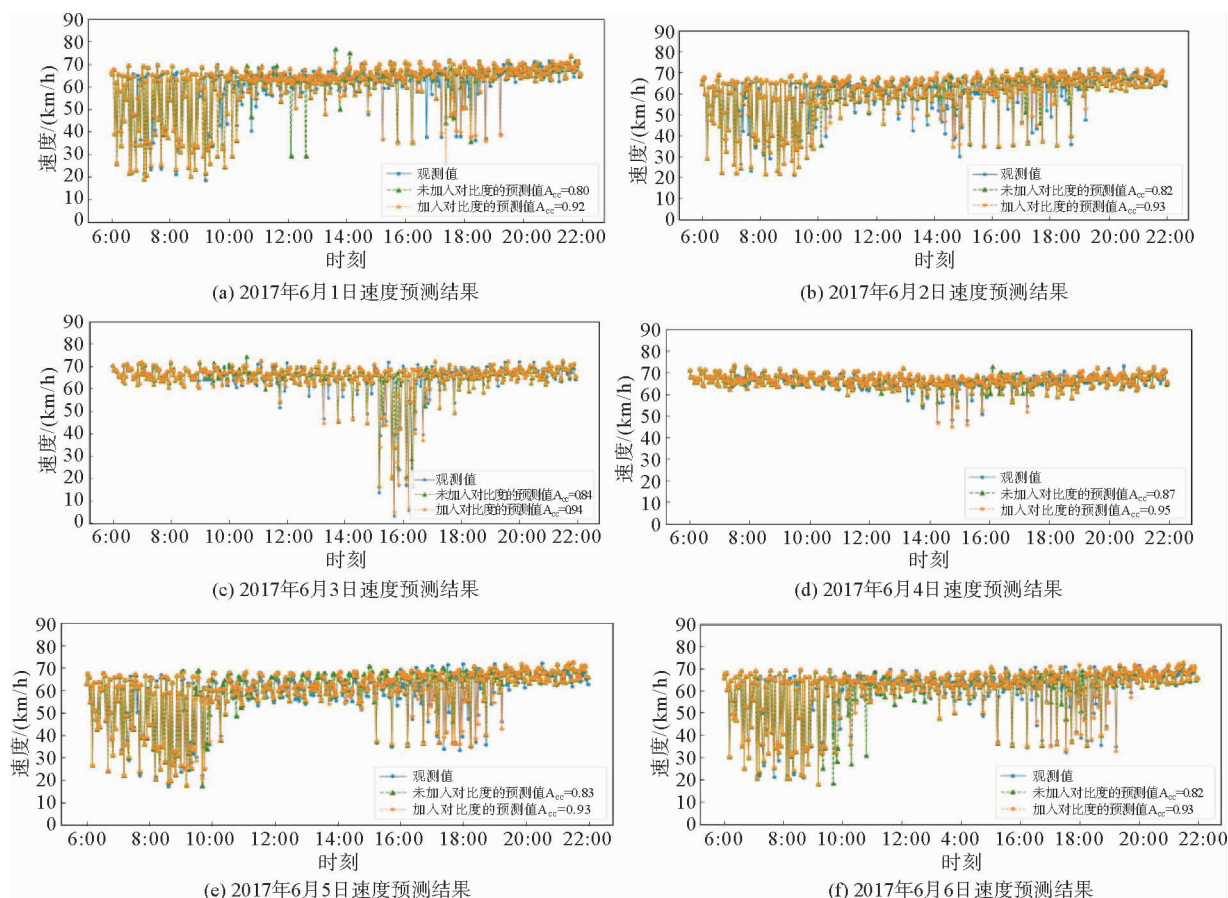


图 6 单共识日和本研究方法的预测效果对比

Fig. 6 Comparison of prediction effect between single consensus day and the proposed method

由图 6 可以看出,未引入对比度指标时,单共识日预测方法对自由流日的预测效果较好,但预测早晚高峰的速度时误差较大,不能较好地捕捉短时间内速度的变化趋势;引入对比度指标后,对早晚高峰的预测效果有了明显改善,6 天的平均预测准确率提高了 10%。

4 结论

本研究利用历史交通数据信息,深入挖掘其规律特征,提出一种基于对比度和共识日的交通速度预测方法。首先利用对比度指标捕捉城市路网交通状态的变化趋势,挖掘道路间交通速度存在的空间关联性,并根据对比度和速度值划分速度等级,使聚类结果更加合理;然后引入共识日方法,根据 Rand 指数确定最佳共识日,以此进行交通速度预测,提高了预测准确率。与传统的统计方法、机器学习和深度学习方法相比,本方法具有更高的准确率和更快的预测速度,可为提升道路通行能力、优化出行路线、缓解拥堵提供方法借鉴。

参考文献:

- [1] CHANDRA S R, AL-DEEK H. Predictions of freeway traffic speeds and volumes using vector autoregressive models[J]. Journal of Intelligent Transportation Systems, 2009, 13(2): 53-72.
- [2] 王伟,董德存.基于灰色理论的点速度预测模型分析[J].交通科技与经济,2010,12(2):1-4.
WANG Wei, DONG Decun. Research of spot speed forecast model based on grey forecast theory[J]. Technology & Econ-

- my in Areas of Communications, 2010, 12(2):1-4.
- [3] KUMAR S V, VANAJAKSHI L. Short-term traffic flow prediction using seasonal ARIMA model with limited input data [J]. European Transport Research Review, 2015, 7(3):1-9.
- [4] SUN J, SUN J. A dynamic Bayesian network model for real-time crash prediction using traffic speed conditions data [J]. Transportation Research Part C, 2015, 54:176-186.
- [5] SATRINIA D, SAPTAWATI G A P. Traffic speed prediction from GPS data of taxi trip using support vector regression [C/OL]// International Conference on Data and Software Engineering, Palembang, 2017. DOI:10.1109/ICODSE.2017.8285869.
- [6] AGAFONOV A, YUMAGANOV A. Spatial-temporal K nearest neighbors model on map reduce for traffic flow prediction [C]// Proceedings of International Conference on Intelligent Data Engineering and Automated Learning, Cham; Springer, 2018:253-260.
- [7] ZHENG Z, CHEN W, WU X, et al. LSTM network: A deep learning approach for short-term traffic forecast [J]. IET Intelligent Transport Systems, 2017, 11(2):68-75.
- [8] LIU Q C, WANG B C, ZHU Y Q. Short-term traffic speed forecasting based on attention convolutional neural network for arterials [J]. Computer-aided Civil and Infrastructure Engineering, 2018, 33(11):999-1016.
- [9] 陈丹蕾, 陈红, 任安虎. 考虑时空影响下的图卷积网络短时交通流预测 [J]. 计算机工程与应用, 2021, 57(13):269-275.
CHEN Danlei, CHEN Hong, REN Anhu. Short-time traffic flow prediction of graph convolutional network considering influence of space and time [J]. Computer Engineering and Applications, 2021, 57(13):269-275.
- [10] 刘国林, 高放, 李俊芬. 最优组合预测及其在短时交通流预测中的应用 [J]. 山东科技大学学报(自然科学版), 2009, 28(1):9-13.
LIU Guolin, GAO Fang, LI Junfen. The optimal combination forecast method and its application in the short-time traffic flow prediction [J]. Journal of Shandong University of Science and Technology (Natural Science), 2009, 28(1):9-13.
- [11] 顾晨阳, 罗熹, 程文龙. 变权重组合预测模型在短时交通流预测中的应用 [J]. 统计与决策, 2010(6):168-169.
GU Chenyang, LUO Xi, CHENG Wenlong. Application of variable weight combination prediction model in short time traffic flow prediction [J]. Statistics & Decision, 2010(6):168-169.
- [12] 李颖宏, 刘乐敏, 王玉全. 基于组合预测模型的短时交通流预测 [J]. 交通运输系统工程与信息, 2013, 13(2):34-41.
LI Yinghong, LIU Lemin, WANG Yuquan. Short-term traffic flow prediction based on combination of predictive models [J]. Journal of Transportation Systems Engineering and Information Technology, 2013, 13(2):34-41.
- [13] 孙秀娟, 陆新秀, 刘法胜, 等. 基于熵权法的交通流组合预测模型研究 [J]. 山东科技大学学报(自然科学版), 2018, 37(4):111-117.
SUN Xiujuan, LU Xinxu, LIU Fasheng, et al. Research on combination prediction model of traffic flow based on entropy weight method [J]. Journal of Shandong University of Science and Technology (Natural Science), 2018, 37(4):111-117.
- [14] 刘新民, 王琪, 孙秋霞. 基于 Fisher 聚类的公交客流量时间序列预测及对比 [J]. 山东科技大学学报(自然科学版), 2019, 38(2):73-81.
LIU Xinmin, WANG Qi, SUN Qiuxia. Prediction and comparison of bus passenger flow time series based on Fisher cluster [J]. Journal of Shandong University of Science and Technology (Natural Science), 2019, 38(2):73-81.
- [15] 王旭鹏, 王梦灵. 基于相似性聚类的交通流概率组合预测模型 [J]. 华东理工大学学报(自然科学版), 2022, 48(3):381-387.
WANG Xupeng, WANG Mengling. Combination forecast model of traffic flow probability based on similarity clustering [J]. Journal of East China University of Science and Technology, 2022, 48(3):381-387.
- [16] CHIABAUT N, FAITOUT R. Traffic congestion and travel time prediction based on historical congestion maps and identification of consensual days [J/OL]. Transportation Research: Part C, 2021, 124. DOI:10.2929/10.1016/j.trc.2020.102920.
- [17] ZAKI J F, ALI-ELDIN A, HUSSEIN S E, et al. Traffic congestion prediction based on hidden Markov models and contrast measure [J]. Ain Shams Engineering Journal, 2019, 11(3):535-551.
- [18] ZHENG C P, FAN X L, WANG C, et al. GMAN: A graph multi-attention network for traffic prediction [C/OL]// The 34th AAAI Conference on Artificial Intelligence. New York, Feb. 7-12, 2020. DOI:10.1609/aaai.v34i01.5477.
- [19] QI Y. Probabilistic models for short term traffic conditions prediction [J]. Journal of Differential Equations, 2010, 250(9):3740-3771.