

doi: 10.3969/j.issn.1002-0268.2025.04.002

基于向量机多分类模型的城市交通状态演化特性

张开文¹, 冯阳¹, 王岚¹, 朱云波¹, 王龙健^{*2,3}

(1. 云南省交通科学研究院有限公司, 云南 昆明 650011; 2. 宁波工程学院 建筑与交通工程学院, 浙江 宁波 315211;
3. 长安大学 运输工程学院, 陕西 西安 710064)

摘要:【目标】为实时准确识别城市路网交通流状态, 以期为缓解城市区域交通拥堵问题提供理论依据。【方法】采用支持向量机多分类算法 (SVM) 识别交通流状态, 基于马尔可夫链构建交通流状态迁移概率模型, 以西安市雁塔区的部分区域路网出租车 GPS 数据为基础, 通过工作日和节假日对比分析, 深入剖析交通流运行状态的定性定量特征及其时空变化规律。【结果】标定后的主干路 SVM 模型识别精确度为 96.875%, 次干路 SVM 模型识别精确度为 93.519%, 满足识别精度要求。工作日雁塔区部分区域主干路和次干路的拥挤流状态均更易向外迁移, 其内部迁移概率分别为 51.19% 和 43.95%, 小于其他交通流状态的内部迁移概率。而节假日主干路稳定流状态更易向外迁移, 其内部迁移概率为 50.87%, 小于其他交通流状态的内部迁移概率。工作日主干路主要处于稳定流状态, 占比 30.89%, 次干路主要处于畅通流状态, 占比 54.49%。节假日主干路和次干路主要处于畅通流状态, 占比分别为 30.43% 和 54.68%。【结论】在没有外界干扰的前提下, 研究区域的交通流状态较为稳定, 呈现逐步迁移, 较少发生跳跃迁移。当发生突发事件后研究区域的交通流状态发生明显的变化, 会产生跳跃迁移。该研究可用于判别常发性和偶发性交通拥堵, 为城市交通的控制、诱导、管理和决策提供有力支持。

关键词: 智能交通; 交通流状态; 支持向量机; 城市交通状态; 出租车 GPS

中图分类号: U121

文献标识码: A

文章编号: 1002-0268 (2025) 04-0008-09

Urban traffic state evolution characteristics based on vector machine multi-classification model

ZHANG Kaiwen¹, FENG Yang¹, WANG Lan¹, ZHU Yunbo¹, WANG Longjian^{*2,3}

(1. Yunnan Transportation Research Institute Co., Ltd., Kunming, Yunnan 650011, China;

2. School of Civil and Transportation Engineering, Ningbo University of Technology, Ningbo, Zhejiang 315211, China;

3. School of Transportation Engineering, Chang'an University, Xi'an, Shaanxi 710064, China)

Abstract: [Objective] Accurately identify the real-time traffic flow state of urban road networks, and provide the theoretical basis for alleviating traffic congestion in urban areas. [Method] The support vector machine (SVM) multi-classification algorithm was used to identify traffic flow state. A probability model of traffic flow state migration was constructed based on Markov chain. A comparative analysis on weekdays and holidays was carried out based on the taxi GPS data of some regional road networks in Yanta District, Xi'an, China. The qualitative and quantitative characteristics of traffic flow state and its spatio-temporal variation

收稿日期: 2024-05-28 修改日期: 2024-09-16

基金项目: 云南交投集团科技项目 (YNJTKFB2023-000499); 云南省交通科学研究院有限公司科研项目 (JKYZLX-2023-26)

作者简介: 张开文 (1976-), 男, 云南砚山人, 硕士, 研究方向为交通安全。(baishun@126.com)

* 通讯作者: 王龙健 (1991-), 男, 黑龙江木兰人, 博士, 研究方向为交通安全。(wanglj@nbut.edu.cn)

引用格式: 张开文, 冯阳, 王岚, 等. 基于向量机多分类模型的城市交通状态演化特性 [J]. 公路交通科技, 2025, 42 (4): 9-16.

ZHANG Kaiwen, FENG Yang, WANG Lan, et al. Urban traffic state evolution characteristics based on vector machine multi-classification model [J].

Journal of Highway and Transportation Research and Development, 2025, 42 (4): 9-16.

© The Author(s) 2025. This is an open access article under the CC-BY 4.0 License. (<https://creativecommons.org/licenses/by/4.0/>)

patterns were analyzed in depth. [**Result**] The calibrated SVM model recognition accuracy is 96.875% for arterial roads, and 93.519% for sub-arterial roads, which satisfies the recognition accuracy requirement. The congested flow states are both more likely to migrate outward on both arterial and sub-arterial roads in some areas of Yanta District on weekdays. Their internal migration probabilities are 51.19% and 43.95% respectively, which are smaller than the internal migration probabilities of other traffic flow states. While the steady flow state of arterial roads on holidays is more likely to migrate outward. Its internal migration probability is 50.87%, which is smaller than the internal migration probability of other traffic flow states. On weekdays, the arterial roads are mainly in a stable flow state, accounting for 30.89%; and the sub-arterial roads are mainly in a free flow state, accounting for 54.49%. On holidays, the arterial roads and sub-arterial roads are mainly in the free flow state, accounting for 30.43% and 54.68% respectively. [**Conclusion**] Under the premise of no external interference, the traffic flow state in the study area is more stable, showing gradual migration, and less jump migration. When an emergency occurs, the traffic flow state in the study area changes significantly, and jump migration occurs. The study result can be used to distinguish recurrent and incident traffic congestions, providing effective support for the control, guidance, management, and decision-making of urban transportation.

Key words: intelligent transport; traffic flow state; support vector machine; urban traffic state; taxi GPS

0 引言

当前,城市的交通拥堵问题已成为城市发展面临的重大挑战,根据《2022年西安城市发展年度报告》,西安市的核心区高峰拥堵指数为4.92,雁塔区的小寨路段位列最拥堵区域首位。西安市作为全国热门旅游目的地城市,对于旅游城市而言,拥堵会影响游客的感知体验质量^[1],导致车辆的油耗增加和尾气污染物排放^[2-3],也与城市的降碳治理密切相关^[4]。城市交通状态演化特性通过对交通流状态识别、演化规律的分析,揭示拥堵形成的机理,再运用智能交通技术进行拥堵疏散控制,成为缓解城市交通拥堵、改善交通环境的有效途径,也是研究热点问题之一^[5-8]。但分析城市交通状态演化特性还需要解决两个问题:(1)交通流状态实时准确识别^[7,9];(2)对交通流状态演化过程精准剖析^[9-10]。

交通流状态实时准确识别主要依靠数据和算法。部分文献是通过研究手机信令数据进行客流量预测^[11],但该方法前提要能够识别用户出行方式,在拥堵情况下,识别精度较低。还有部分文献是利用各类浮动车GPS数据进行分析^[6,12-13],该类数据具有实时性强、全天候、覆盖区域广、信息精度和可靠度高的特点,是识别交通流状态较好的数据选择,但大部分研究选取的参数单一,判别准确性还有待提高^[14-15]。当前,对于交通流状态演化规律及其特性的研究主要聚焦于交通拥堵情境下的聚集

与消散过程^[9]。城市道路交通流状态研究多是分析单点或路段,对路网整体交通流演化特性的研究还比较少^[16]。因此,如何利用海量数据精确识别交通流状态,精准剖析交通流演化过程是城市区域交通“缓堵保畅”的必要条件,也是亟待解决的问题。

基于上述分析,本研究利用出租车的GPS数据,构建城市交通流状态的识别方法,分析交通流状态演化特性,为城市的交通管理与控制提供理论依据,保障城市路网的交通安全、顺畅运行。

1 交通流状态识别方法的选取

识别城市区域路网交通流状态,本研究选用的多参数构建多维模型,采用模式识别算法中的支持向量机(Support Vector Machine, SVM)方法^[17],该方法由Vapnik提出用于解决非线性分类、估计问题的一种实用方法,也用于识别易引发交通事故的交通流状态^[18]。目前,针对多参数实测数据、基于非线性分类方法的城市快速路交通拥堵识别是该方法研究的重要方向^[19],本研究的交通流状态识别的步骤如下:

Step 1: 选取输入的参数。根据城市路段交通流特性演变规律,设计输入的变量 $x = (x_1, x_2, \dots, x_n)$, $x \in R^n$ 为输入参数集合, x_i 为第*i*个输入参数,参数可选择交通量、速度、占有率、延误和V/C等一个或几个交通参数。

基于出租车GPS数据识别交通流状态,本研究

选取路段平均速度、平均行程时间延误和出租车数量作为输入参数, 即 $x_i = [\bar{v}_i, \Delta T_i, q_i]$ 。利用出租车 GPS 数据估计路段平均速度, 设在时间间隔 T 内路段 L 上共有 q 辆出租车, 瞬时速度值分别为 v_1, v_2, \dots, v_i , 则该时间段内路段平均速度为:

$$\bar{v}_i = \frac{1}{q} \sum_{j=1}^q v_j, \quad (1)$$

式中, v_j 为出租车 j 的瞬时速度值; q 为出租车数量; \bar{v}_i 为路段 L 的平均速度。

拥堵会造成乘客的行程时间延误, 浮动车 j 的行程时间延误 (s) 表示为:

$$\Delta T_j = 3\,600 \times (L/v_j - L/v') = 3\,600 \times L \times (1/v_j - 1/v'), \quad (2)$$

式中, L 为浮动车 j 行驶的路段长度; \bar{v}_j 为浮动车 j 平均行程的速度; v' 为道路畅行速度, 设置道路设计车速设定为路段的畅行速度^[3]。

为消除路段长度对行程时间延误的影响, 行程时间延误与车辆行驶距离之比指的是路段的行程时间延误。路段行程时间延误表示为:

$$\Delta T'_j = \frac{\Delta T_j}{L} = \frac{3\,600 \times L \times (1/v_j - 1/v')}{L} = 3\,600 \times (1/v_j - 1/v'). \quad (3)$$

路段上全部的出租车通行平均行程时间延误表示为:

$$\Delta T = \frac{\sum_{j=1}^n \Delta T'_j}{n} = \frac{3\,600 \times \sum_{j=1}^n (1/v_j - 1/v')}{n}. \quad (4)$$

Step 2: 选取核函数 $K(x_i, x)$ 。高斯径向基核函数 (RBF) 具有较好的软化特性, 有任意阶导数; 结构简单, 函数识别率较高^[17]。因此, 选取 RBF 作为核函数,

$$K(x, x_i) = \exp(-\gamma \cdot \|x - x_i\|^2), \quad (5)$$

式中 γ 为核参数。

Step 3: 训练模型, 标定参数。利用 MATLAB 的 LIBSVM 工具箱, 输入样本数据, 通过交叉验证方法^[19]确定惩罚系数 c 。

Step 4: 利用训练好的 SVM 模型识别交通流状态, 输出识别结果 y 。

$$y = \text{sgn} \left[\sum_{i=1}^n \alpha_i y_i K(x_i, x) + b \right], \quad (6)$$

式中, y 为结果输出; y_i 为对应 x_i 的输出数据; α_i 为加权参数; b 为常数。

2 交通流状态演化特性分析模型

为描述交通流状态的迁移过程, 基于马尔可夫链^[20]的交通流状态迁移概率模型, 分析城市交通流状态迁移特征, 用于判别常发性和偶发性的交通拥堵。

2.1 交通流状态迁移概率

交通流状态转移不断地转变, 是一个随机变化的系统, 马尔可夫模型可表示交通流状态的迁移, 清晰地描述各交通流状态在一定时段内的迁移概率, 可用于分析交通流状态的迁移特性、稳定性、活跃性、活跃时间、跳跃迁移等特性^[21]。

设在 $t = \{t_1, t_2, \dots, t_M\}$ 时刻, 交通流状态集合: $S = \{s_1, s_2, \dots, s_M\}$, 其中, M 为交通流状态总数量。在 $1 \leq i, j \leq M$ 前提下, 若 t_i 与 t_j 是相邻时刻, 则 s_i 与 s_j 存在状态演化时序关系, 可视为两者之间存在迁移关系, 记为 $s_i \rightarrow s_j$ 。因此, 采用 1 周或几周内累计的交通流状态数据来搭建交通流状态迁移网络, 记为: $G = (S, E, \omega)$, 其中, 节点集合 S 表示交通流状态; 边的集合 E 表示交通流状态间的迁移; 边的权重集合 ω 表示状态间的迁移次数。

随着时间的推移, 当齐次马尔可夫链的 w 步迁移概率矩阵 $P(w)$ 存在极限矩阵, 会随状态不断地迁移, 形成稳定状态的迁移概率系统。因交通流状态的数量有限, 存在极限矩阵。

假设 p_{ij} 为从状态 s_i 迁移到状态 s_j 的概率, 第 w 步状态迁移后 $p_{ij}^{(w)} = r_{ij}^{(w)} / R_i$, $i, j = 1, 2, \dots, M$, 其中 $r_{ij}^{(w)}$ 为第 w 次从状态 s_i 迁移到状态 s_j 的频数, s_i 状态出现的次数用 R_i 表示, 迁移概率矩阵为:

$$P(w) = \begin{bmatrix} p_{11}^{(w)} & p_{12}^{(w)} & \cdots & p_{1M}^{(w)} \\ p_{21}^{(w)} & p_{22}^{(w)} & \cdots & p_{2M}^{(w)} \\ \vdots & \vdots & \vdots & \vdots \\ p_{M1}^{(w)} & p_{M2}^{(w)} & \cdots & p_{MM}^{(w)} \end{bmatrix}. \quad (7)$$

当 $w=1$ 时, 如果交通流状态迁移到第 i 种状态, 检查一步迁移概率矩阵 P 的第 i 行。当 $\text{Max } p_{ij}^{(1)} = p_{ik}$, ($k \in (1, 2, M)$) 时, 状态 s_k 可能是下一个迁移或预测的状态。当交通流状态经 w 步迁移, 路网状态的迁移概率矩阵如下:

$$P(w) = \begin{bmatrix} p_{11}^{(w)} & p_{12}^{(w)} & \cdots & p_{1M}^{(w)} \\ p_{11}^{(w)} & p_{12}^{(w)} & \cdots & p_{1M}^{(w)} \\ \vdots & \vdots & \vdots & \vdots \\ p_{11}^{(w)} & p_{12}^{(w)} & \cdots & p_{1M}^{(w)} \end{bmatrix}, \quad (8)$$

式中 $p_{11}^{(w)} + p_{12}^{(w)} + \cdots + p_{1M}^{(w)} = 1$, 并且各行的元素均相同,

则 $P(w)$ 达到极限。极限分布为 $Z = (p_{11}^{(w)}, p_{12}^{(w)}, \dots, p_{1M}^{(w)})$, 表明交通流状态迁移到 s_1, s_2, \dots, s_M 稳定的迁移概率分别为 $p_{11}^{(w)}, \dots, p_{12}^{(w)}, \dots, p_{1M}^{(w)}$ 。

2.2 交通流状态的稳定性

定义 1: 从 1 到 N 时段, 路网的交通流状态序列 $L = s_i, s_i, \dots, s_i$ (N 个状态为同一状态), 代表 s_i 状态连续 N 个时段 ($N > 3$) 保持不变, 表示 L 为 s_i 的稳定状态序列, 记作 L_{s_i} ; 则 L_{s_i} 的稳定时间记作 C_{s_i} , 可知 $C_{s_i} = N$ 。

交通状态稳定时间是指交通状态模式维持现状不变的持续时间, 可用来表征交通流状态的稳定性。交通流状态稳定时间段示意图如图 1 所示, 椭圆区域即为交通流状态稳定时间段。

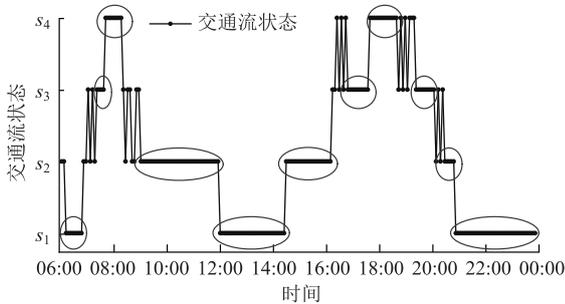


图 1 交通流状态稳定时间段

Fig. 1 Stability period in traffic flow state

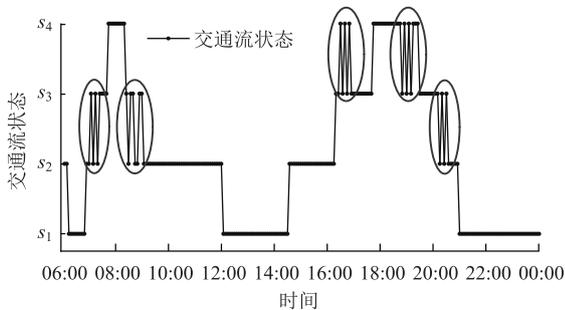


图 2 交通流状态活跃时间段

Fig. 2 Active period in traffic flow state

2.3 交通流状态的活跃性

定义 2: 活跃状态序列 (L) 是指在一定时间段内连续发生多次 (大于两次) 两类交通流状态的相互迁移, 记为 L_a 。从 1 到 N 时段, 路网经历交通流状态序列为 $L = s_i, s_j, s_i, s_j, \dots, s_i, s_j$ ($i \neq j$), L_a 的活跃时间记为 C_a , 可知 $C_a = N$ 。

交通状态活跃时间可表征交通流状态的活跃性, 交通状态活跃时间是指交通状态模式不断迁移的持续时间, 从图 2 可以看出, 椭圆区域代表了交通流状态活跃时间段。

2.4 交通流状态跳跃迁移

交通流状态跳跃代表交通流状态的突变过程, 可判断突发状况和偶发性交通拥堵情况, 为交通管理者掌握交通状况异常情况提供参考。

当 $j > i + 1$ 或 $j < i - 1$, 并维持该交通流状态超过单位个时间间隔后又迁移回交通流状态 s_i , 设定交通流状态 s_i 迁移到下一交通流状态 s_j , 作为本次交通流状态迁移是跳跃迁移。交通流状态迁移在部分时间段内存在的波动, 但大体上表现为连续变化特性, 较少出现隔级迁移。

3 实例分析

3.1 研究地点

选取西安市雁塔区的部分区域路网为本研究的试验路网, 项目区以相邻交叉口为节点, 划分为 46 个路段, 编号分别为 1~46。区域内包含主干路 6 条、次干路 2 条, 均为双向交通, 如表 1 所示。其中支路由于数据样本量过少, 不满足最小样本量, 在构建路网拓扑时已经删除, 研究区域路网拓扑示意图如图 3 所示。

3.2 试验数据

为避免网约车对数据的影响, 本研究选取的是西安网约车未大规模运行的 2015 年西安市出租车 GPS

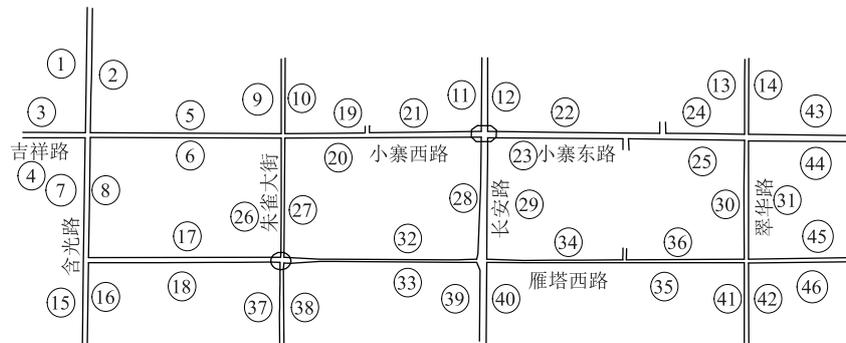


图 3 研究区域路网拓扑图

Fig. 3 Topological map of road network in study area

表1 研究区域内道路网

Table 1 Road network in study area

| 序号 | 道路等级 | 名称 | 合计道路数量/条 |
|----|------|------|----------|
| 1 | 主干路 | 长安路 | 6 |
| | | 朱雀大街 | |
| | | 含光路 | |
| | | 小寨东路 | |
| | | 小寨西路 | |
| | | 吉祥路 | |
| 2 | 次干路 | 翠华路 | 2 |
| | | 雁塔西路 | |

数据,使得出租车样本更具有代表性。试验从2015年1月12日至2015年1月18日共7天,从早6:00至晚24:00,时间间隔(5 min),期间共收集 $7 \times 18 \times 12 = 1512$ 个时段的数据样本,46个路段共有 $46 \times 1512 = 69552$ 个样本数据,在分析数据之前对数据进行预处理:过滤样本量少的支路数据。从图4中可知,出租车载客状态和空驶状态速度差异较大,当出租车空载时,其车速明显低于载客车速。参考谭川豫^[22]对移动对象轨迹的研究。只保留载客数据,同时过滤掉速度、方向角和经纬度异常的数据。

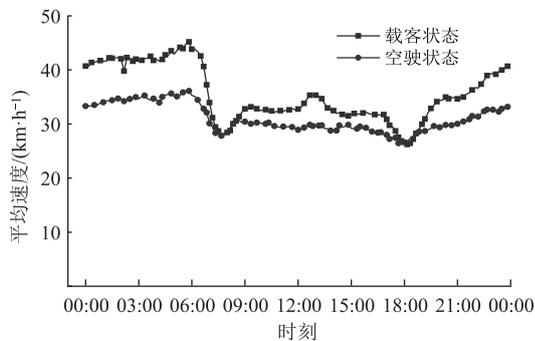


图4 西安市出租车在载客和空驶状态下的速度对比
Fig. 4 Taxi passenger-carrying speed v. s. deadhead speed in Xi'an

3.3 交通流状态识别分析

3.3.1 基于SVM的交通流状态识别

为避免单指标的随机性误差,提高交通流状态识别的准确性,采用路段平均行程速度、平均行程时间延误和出租车数量3个交通参数作为模型的输入数据。将交通流状态归为畅通流状态 s_1 、稳定流状态 s_2 、拥挤流状态 s_3 和堵塞流状态 s_4 。

选取6个主干路双向路段共4h的出租车GPS数据,共 $12 \times 4 \times 12 = 576$ 组数据作为主干路样本数据,按5:1的比例,取其中480组样本数据作为训

练数据,剩余96组样本数据作为验证数据。选取3次干路双向路段共9h的出租车GPS数据,共 $6 \times 9 \times 12 = 648$ 组数据作为次干路样本数据,按照5:1的比例,利用MATLAB的LIBSVM工具箱对540组样本数据进行训练和识别,并将剩余108组样本数据作为验证数据。训练结果如图5所示。通过训练标定主干路模型参数 $c = 8.5742$, $\gamma = 3.7321$ 时,模型识别精确度为96.875%;次干路模型参数 $c = 7.4643$, $\gamma = 7.4643$ 时,模型识别精确度为93.5185%,识别率较高,满足识别精度要求。研究区域共有69552组数据样本,其中有5d的工作日样本数据,共计49680组样本(主干路33480组样本,次干路16200组样本),2d的节假日样本数据,共计19872组样本(主干路13392组样本,次干路6480组样本)。利用训练好的SVM模型对数据样本进行交通流状态识别。

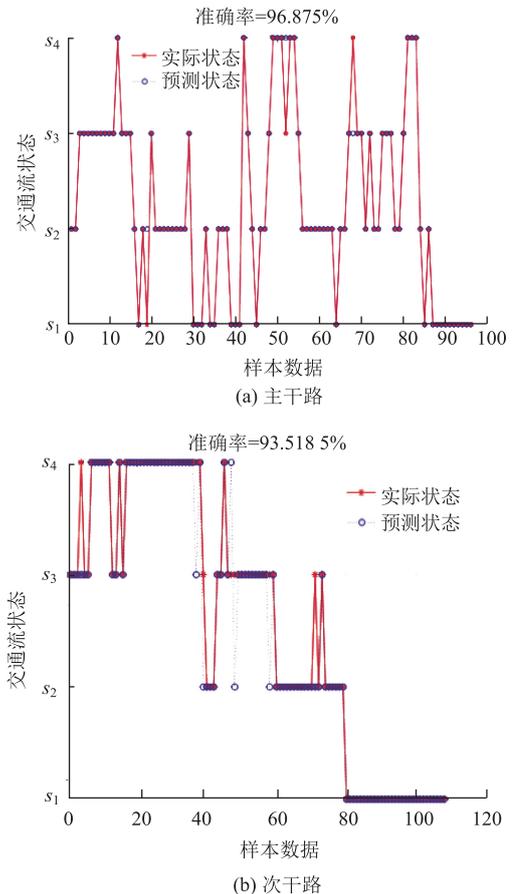


图5 SVM模型识别结果

Fig. 5 Recognition result with SVM model

3.3.2 交通流状态演化特性分析

统计识别后的交通流状态,得到的工作日主干路状态转移矩阵 S_{wm} 和工作日次干路状态转移矩阵 S_{ws} 。

$$S_{wm} = \begin{bmatrix} 6\ 634 & 2\ 118 & 463 & 225 \\ 2\ 111 & 5\ 276 & 2\ 459 & 411 \\ 436 & 2\ 438 & 4\ 447 & 1\ 366 \\ 241 & 447 & 1\ 321 & 2\ 932 \end{bmatrix}, \quad (7)$$

$$S_{ws} = \begin{bmatrix} 7\ 579 & 850 & 251 & 105 \\ 865 & 1\ 909 & 619 & 167 \\ 246 & 624 & 992 & 395 \\ 95 & 177 & 396 & 855 \end{bmatrix}. \quad (8)$$

工作日主干路交通流状态转移概率矩阵 P_{wm} 和工作日次干路交通流状态转移概率矩阵 P_{ws} :

$$P_{wm} = \begin{bmatrix} 0.702\ 8 & 0.224\ 4 & 0.049\ 0 & 0.023\ 8 \\ 0.205\ 8 & 0.514\ 4 & 0.239\ 7 & 0.040\ 1 \\ 0.050\ 2 & 0.280\ 7 & 0.511\ 9 & 0.157\ 2 \\ 0.048\ 8 & 0.090\ 5 & 0.267\ 3 & 0.593\ 4 \end{bmatrix}, \quad (9)$$

$$P_{ws} = \begin{bmatrix} 0.862\ 7 & 0.096\ 8 & 0.028\ 6 & 0.012\ 0 \\ 0.243\ 0 & 0.536\ 2 & 0.173\ 9 & 0.046\ 9 \\ 0.109\ 0 & 0.276\ 5 & 0.439\ 5 & 0.175\ 0 \\ 0.062\ 4 & 0.116\ 2 & 0.260\ 0 & 0.561\ 4 \end{bmatrix}. \quad (10)$$

工作日主干路交通流状态转移概率矩阵 P_{wm} 在 30 步转移后达到极限值, 极限矩阵 $P_{wm}^{(30)}$:

$$P_{wm}^{(30)} = \begin{bmatrix} 0.282\ 2 & 0.308\ 9 & 0.261\ 0 & 0.147\ 9 \\ 0.282\ 2 & 0.308\ 9 & 0.261\ 0 & 0.147\ 9 \\ 0.282\ 2 & 0.308\ 9 & 0.261\ 0 & 0.147\ 9 \\ 0.282\ 2 & 0.308\ 9 & 0.261\ 0 & 0.147\ 9 \end{bmatrix}. \quad (11)$$

工作日主干路交通流状态极限分布为 $Z_{wm} = (0.282\ 2\ 0.308\ 9\ 0.261\ 0\ 0.147\ 9)$, 显示交通流状态转移到 s_1, s_2, s_3, s_4 , 转移率分别是 0.282 2, 0.308 9, 0.261 0 和 0.147 9。工作日路网的次干路交通流状态转移概率矩阵 P_{ws} 在 41 步转移后达到极限值, 极限矩阵 $P_{ws}^{(41)}$:

$$P_{ws}^{(41)} = \begin{bmatrix} 0.544\ 9 & 0.220\ 8 & 0.140\ 0 & 0.094\ 3 \\ 0.544\ 9 & 0.220\ 8 & 0.140\ 0 & 0.094\ 3 \\ 0.544\ 9 & 0.220\ 8 & 0.140\ 0 & 0.094\ 3 \\ 0.544\ 9 & 0.220\ 8 & 0.140\ 0 & 0.094\ 3 \end{bmatrix}. \quad (12)$$

工作日次干路交通流状态极限分布为 $Z_{ws} = (0.544\ 9\ 0.220\ 8\ 0.140\ 0\ 0.094\ 3)$, 表明交通流状态转移到 s_1, s_2, s_3, s_4 稳定的转移率分别为 0.544 9, 0.220 8, 0.140 0, 0.094 3。

对比工作日主干路交通流状态极限分布 Z_{wm} 和次干路交通流状态极限分布 Z_{ws} 可以发现: 工作日主干路主要处于稳定流状态 s_2 , 占了 30.89%, 而后依次为畅通流状态 s_1 、拥挤流状态 s_3 和堵塞流状态 s_4 。而工作日次干路主要处于畅通流状态 s_1 , 占 54.49%, 而后依次为稳定流状态 s_2 、拥挤流状态 s_3 和堵塞流状态 s_4 ; 次干路的交通压力小于主干路。工作日主干路处于 s_1, s_2 的概率为 59.11%, 而次干路为 76.57%, 因而, 次干路的交通压力小于主干路。

从式 (11) 和式 (12) 可以得出工作日交通流状态特性如下:

(1) 内部迁移是试验路网的主要迁移趋势。工作日各交通流状态的内部迁移占主要地位, 说明在大部分时间段内路段交通流状态在迁移到某一状态后, 会稳定维持在该状态一段时间后会向其他状态迁移。王芹^[23]利用百度地图提取西安市实时路况数据, 对 2014 年 10 月 24 日至 30 日西安市实时路况数据进行分析也发现西安市交通拥堵在时间和空间上表现出一定规律性。

(2) 当交通流状态向外部迁移时, 主要是向相邻状态迁移, 跳跃迁移出现较少。在图 6 和图 7 中各出现一次跳跃迁移, 表明该时间段内交通状况出现异常, 需要引起交通管理部门的注意, 提醒出行者该路段的异常情况。

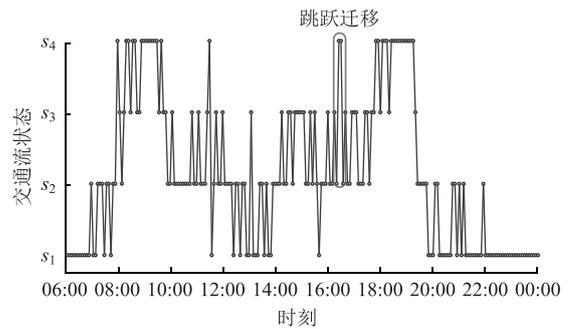


图 6 工作日 26 号主干路的交通流状态演化
Fig. 6 Evolution of traffic flow state of arterial road No. 26 on weekday

(3) 工作日主干路拥挤流状态 s_3 表现最活跃, 其次为稳定流状态 s_2 和堵塞流状态 s_4 , 畅通流状态 s_1 表现最稳定。工作日主干路拥挤流状态 s_3 的内部迁移概率为 51.19%, 小于其他交通流状态的内部迁移概率, 相比于其他交通流状态拥挤流状态 s_3 更易向外迁移。拥挤流状态 s_3 的外部迁移概率中, 迁移到稳定流状态 s_2 的概率为 28.07%, 大于迁移到畅通

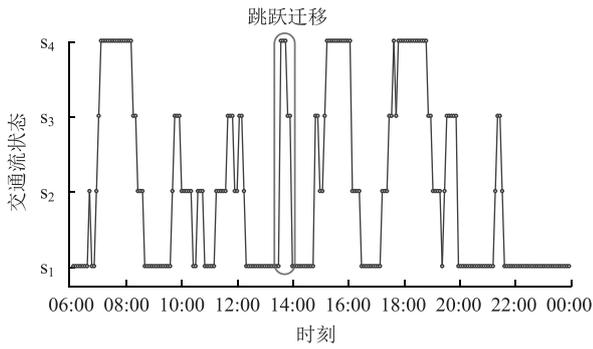


图7 工作日31号次干路的交通流状态演化

Fig. 7 Evolution of traffic flow state of main road No. 31 on weekday

流状态 s_1 和堵塞流状态 s_4 的概率, 该状态趋于迁移到稳定流状态 s_2 。主干路畅通流状态 s_1 内部迁移比例为 70.28%, 说明当路段处于 s_1 时, 交通流状态相对稳定。畅通流状态 s_1 的外部迁移概率中, 迁移到稳定流状态 s_2 的概率最高为 22.44%, 证实该状态趋向于迁移到稳定流状态 s_2 。这与王芹于 2016 年 4 月 28 日—5 月 4 日, 对实时路况的西安交通拥堵研究结果相符: 拥堵路段多为主干道, 西安市交通压力主要来自干路系统的交通出行需求^[24]。

同时还得到了节假日主干路状态转移矩阵 S_{em} 和节假日次干路状态转移矩阵 S_{es} :

$$S_{em} = \begin{bmatrix} 2\ 918 & 874 & 179 & 107 \\ 863 & 1\ 895 & 811 & 156 \\ 188 & 816 & 1\ 569 & 485 \\ 99 & 149 & 501 & 1\ 720 \end{bmatrix}, \quad (13)$$

$$S_{es} = \begin{bmatrix} 2\ 942 & 480 & 85 & 26 \\ 494 & 793 & 213 & 52 \\ 71 & 240 & 370 & 122 \\ 24 & 40 & 136 & 362 \end{bmatrix}。 \quad (14)$$

则节假日主干路交通流状态转移概率矩阵 P_{em} 和节假日次干路交通流状态转移概率矩阵 P_{es} 为:

$$P_{em} = \begin{bmatrix} 0.715\ 6 & 0.214\ 3 & 0.043\ 9 & 0.026\ 2 \\ 0.231\ 7 & 0.508\ 7 & 0.217\ 7 & 0.041\ 9 \\ 0.061\ 5 & 0.266\ 8 & 0.513\ 1 & 0.158\ 6 \\ 0.040\ 1 & 0.060\ 4 & 0.202\ 9 & 0.696 \end{bmatrix}, \quad (15)$$

$$P_{es} = \begin{bmatrix} 0.832\ 7 & 0.135\ 9 & 0.024\ 0 & 0.007\ 4 \\ 0.318\ 3 & 0.511\ 0 & 0.137\ 2 & 0.033\ 5 \\ 0.088\ 4 & 0.298\ 9 & 0.460\ 8 & 0.151\ 9 \\ 0.042\ 7 & 0.071\ 2 & 0.242\ 0 & 0.644\ 1 \end{bmatrix}。 \quad (16)$$

节假日主干路交通流状态转移概率矩阵 P_{em} 经 35 步转移后达到极限值, 极限矩阵 $P_{em}^{(35)}$:

$$P_{em}^{(35)} = \begin{bmatrix} 0.304\ 3 & 0.280\ 4 & 0.230\ 0 & 0.185\ 2 \\ 0.304\ 3 & 0.280\ 4 & 0.230\ 0 & 0.185\ 2 \\ 0.304\ 3 & 0.280\ 4 & 0.230\ 0 & 0.185\ 2 \\ 0.304\ 3 & 0.280\ 4 & 0.230\ 0 & 0.185\ 2 \end{bmatrix}。 \quad (17)$$

节假日主干路交通流状态极限分布为 $Z_{em} = (0.304\ 3\ 0.280\ 4\ 0.230\ 0\ 0.185\ 2)$, 表明交通流状态转移到 s_1, s_2, s_3, s_4 , 其转移率分别是 0.304 3, 0.280 4, 0.230 0 和 0.185 2。节假日的次干路交通流状态转移概率矩阵 P_{es} , 经 41 步转移达到极限值, 极限矩阵 $P_{es}^{(41)}$:

$$P_{es}^{(41)} = \begin{bmatrix} 0.546\ 8 & 0.241\ 0 & 0.124\ 9 & 0.087\ 3 \\ 0.546\ 8 & 0.241\ 0 & 0.124\ 9 & 0.087\ 3 \\ 0.546\ 8 & 0.241\ 0 & 0.124\ 9 & 0.087\ 3 \\ 0.546\ 8 & 0.241\ 0 & 0.124\ 9 & 0.087\ 3 \end{bmatrix}。 \quad (18)$$

节假日次干路交通流状态极限分布为 $Z_{es} = (0.546\ 8\ 0.241\ 0\ 0.124\ 9\ 0.087\ 3)$, 表明交通流状态转移到 s_1, s_2, s_3, s_4 转移率分别为 0.546 8, 0.241 0, 0.124 9 和 0.087 3。对比节假日主干路交通流状态极限分布 Z_{em} 和次干路交通流状态极限分布 Z_{es} : 节假日主干路和次干路主要处于畅通流状态 s_1 , 依次为稳定流状态 s_2 、拥挤流状态 s_3 和堵塞流状态 s_4 ; 次干路的交通压力小于主干路。节假日主干路处于 s_1, s_2 的概率为 58.47%, 而次干路为 78.78%。

此外, 节假日主干路稳定流状态 s_2 表现最活跃, 其次为拥挤流状态 s_3 , 堵塞流状态 s_4 和畅通流状态 s_1 表现相对稳定。节假日主干路稳定流状态 s_2 的内部迁移概率为 50.87%, 小于其他交通流状态的内部迁移概率, 相比于其他交通流状态稳定流状态 s_2 更易向外迁移。稳定流状态 s_2 的外部迁移概率中, 迁移到畅通流状态 s_1 的概率为 23.17%, 大于迁移到拥挤流状态 s_3 和堵塞流状态 s_4 的概率, 说明该状态偏向于迁移到畅通流状态 s_1 。这与工作日主干路不一致, 是由于节假日出行次数下降, 导致交通量减少, 交通更为通畅, 交通流状态大多时间处于畅通流状态 s_1 和稳定流状态 s_2 。出行目的也由工作和上学转变为购物和旅游, 在商业中心和景点附近道路交通压力较大, 其余区域交通压力较小, 使得该区域整体交通压力较小。主干路畅通流状态 s_1 内部迁移比例为 71.56%, 堵塞流状态 s_4 内部迁移比例为

69.66%, 稳定性高。在外部迁移中, 畅通流状态 s_1 趋向于迁移到稳定流状态 s_2 , 拥挤流状态 s_3 趋向于迁移到稳定流状态 s_2 , 堵塞流状态 s_4 趋向于迁移到拥挤流状态 s_3 。对比工作日和节假日主干路交通流状态, 节假日主干路相对拥堵, 堵塞流状态 s_4 占 18.52%, 多于工作日的 14.79%。小寨西路与长安路交叉口位置的小寨片区为商业中心区, 周末吸引了较多顾客、游客来此购物、旅游、休闲娱乐。并且在该区域西侧为著名景点大雁塔, 是客流主要吸引点, 而小寨西路、雁塔西路是去该景点的主通道, 也会造成这些路段的长时间拥堵。

4 结论

本研究基于 SVM 多分类模型, 对出租车的 GPS 数据, 深入剖析西安市雁塔区的部分区域路网的交通流状态演化特性, 工作日和节假日对比分析得出基于出租车 GPS 数据交通流运行状态的定性定量特征及其随时间、空间变化而变化的一般规律。并得出如下结论:

(1) 通过马尔可夫链的交通流状态模式迁移概率模型可以得出研究区域的稳定交通流状态分布概率。

(2) 在没有外界干扰的前提下, 工作日主干路拥挤流状态更易向外迁移 (内部迁移概率为 51.19%, 小于其他交通流状态), 研究区域的交通流状态较为稳定, 且呈现逐步迁移, 较少发生跳跃迁移。

(3) 当发生突发事件后交通流状态会产生跳跃迁移, 研究区域的交通流状态发生明显的变化, 引起交通管理者的注意。

(4) 构建的交通流状态演化特性分析指标能够准确、详细地分析研究区域内路网交通流状态的演化过程及特性。

本研究仍存在以下不足: 没有对比不同城市交通热点区域, 仅用出租车 GPS 数据, 数据类型单一, 采用的数据时间较早, 不能全面反映当前西安市雁塔区的部分区域路网的交通流状态演化特性。此外, 还应考虑多源数据融合识别交通流状态, 进一步提高模型识别精度; 实际中的交通流状态种类多样、变化丰富, 本研究的交通流状态分类较少, 与实际还存在一定差异。在后续的研究中, 还应结合路网的实际, 将交通流状态划分得更细致, 同时结合人工智能识别技术, 优化提升效果, 便于实时动态地揭示交通流状态演化特性。

参考文献:

References:

- [1] 陈方, 于森, 戢晓峰, 等. 交通拥堵感知对节假日自驾游满意度与忠诚度影响 [J]. 公路交通科技, 2023, 40 (11): 246-254.
CHEN Fang, YU Miao, JI Xiaofeng, et al. Influence of traffic congestion perception on satisfaction and loyalty of holiday self-driving tour [J]. Journal of Highway and Transportation Research and Development, 2023, 40 (11): 246-254.
- [2] BEAUDOIN J, LAWELL C. The effects of public transit supply on the demand for automobile travel [J]. Journal of Environmental Economics and Management, 2018, 88: 447-467.
- [3] ROSTAMI-SHAHRBABA M, SAFAVI A A, PAPAGEORGIOU M, et al. State estimation in urban traffic networks: A two-layer approach [J]. Transportation Research Part C: Emerging Technologies, 2020, 115: 102616. doi: <http://doi.org/10.1016/j.trc.2020.102616>.
- [4] 陈袁彬, 申永刚. 城市交通拥堵与交通降碳协同治理研究 [J]. 交通节能与环保, 2023, 19 (5): 86-90.
CHEN Yuanbin, SHEN Yonggang. Research on the collaborative governance of urban traffic congestion and traffic carbon reduction [J]. Transport Energy Conservation & Environmental Protection, 2023, 19 (5): 86-90.
- [5] LU Huapu, SUN Zhiyuan, QU Wencong. Big data-driven based real-time traffic flow state identification and prediction [J]. Discrete Dynamics in Nature and Society 2015; 2015: 1-11.
- [6] KONG X J, XU Z Z, SHEN G J, et al. Urban traffic congestion estimation and prediction based on floating car trajectory data [J]. Future Generation Computer Systems, 2016, 61: 97-107.
- [7] CHEN Z Y, WANG W, LU J, et al. Classifying the traffic state of urban expressways: A machine-learning approach [J]. Transportation Research Part A: Policy and Practice, 2020, 137: 411-428.
- [8] XIE P, LI T R, LIU J, et al. Urban flow prediction from spatiotemporal data using machine learning: A survey [J]. Information Fusion, 2020, 59: 1-12.
- [9] LI L, SU X N, ZHANG Y, et al. Trend modeling for traffic time series analysis: An integrated study [J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16 (6): 3430-3439.
- [10] KHAN S M, DEY K C, CHOWDHURY M. Real-time

- traffic state estimation with connected vehicles [J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18 (7): 1687-1699.
- [11] 李志强, 陈来荣, 刘冬梅, 等. 疫情防控措施影响下的春运客运量预测方法研究 [J]. 公路交通科技, 2023, 40 (5): 237-246.
- LI Zhiqiang, CHEN Lairong, LIU Dongmei, et al. Study on prediction method of passenger volume of Spring Festival transport under influence of epidemic prevention and control measures [J]. Journal of Highway and Transportation Research and Development, 2023, 40 (5): 237-246.
- [12] MA Q L, ZOU Z, ULLAH S. An approach to urban traffic condition estimation by aggregating GPS data [J]. Cluster Computing-the Journal of Networks Software Tools and Applications, 2019, 22: 5421-5434.
- [13] ZHANG J D, XU J, LIAO S S. Aggregating and sampling methods for processing GPS data streams for traffic state estimation [J]. IEEE Transactions on Intelligent Transportation Systems, 2013, 14 (4): 1629-1641.
- [14] SEO T, KUSAKABE T, ASAKURA Y. Estimation of flow and density using probe vehicles with spacing measurement equipment [J]. Transportation Research Part C: Emerging Technologies, 2015, 53: 134-150.
- [15] YANG Y J, XU Y B, HAN J Y, et al. Efficient traffic congestion estimation using multiple spatio-temporal properties [J]. Neurocomputing, 2017, 267: 344-353.
- [16] SHAHRBABA M R, SAFAVI A A, PAPAGEORGIOU M, et al. A data fusion approach for real-time traffic state estimation in urban signalized links [J]. Transportation Research Part C: Emerging Technologies, 2018, 92: 525-548.
- [17] YUAN R X, I Z, GUAN X H, et al. An SVM-based machine learning method for accurate internet traffic classification [J]. Information Systems Frontiers, 2010, 12 (2): 149-156.
- [18] 孙然然, 张静萱, 朱广宇. 基于SVM的危险交通流状态实时识别模型 [J]. 公路交通科技, 2021, 38 (10): 120-128.
- SUN Ranran, ZHANG Jingxuan, ZHU Guangyu. A real-time recognition model of dangerous traffic flow state based on SVM [J]. Journal of Highway and Transportation Research and Development, 2021, 38 (10): 120-128.
- [19] 李宇轩, 韦凌翔, 陈红, 等. 基于支持向量机的城市快速路交通拥堵识别方法 [J]. 交通工程, 2018, 18 (1): 43-47.
- LI Yuxuan, WEI Lingxiang, CHEN Hong, et al. Traffic congestion pattern recognition in urban expressway based on support vector machine [J]. Traffic Engineering, 2018, 18 (1): 43-47.
- [20] KEERTHI S S, LIN C J. Asymptotic behaviors of support vector machines with Gaussian kernel [J]. Neural Computation, 2003, 15 (7): 1667-1689.
- [21] 王龙健. 基于出租车GPS数据的区域路网交通流状态演化识别方法研究 [D]. 西安: 长安大学, 2017.
- WANG Longjian. Research on the traffic flow state evolution and identification method of regional road network based on taxi GPS data [D]. Xi'an: Chang'an University, 2017.
- [22] 谭川豫. 移动对象轨迹分析技术研究 [D]. 长沙: 国防科学技术大学, 2010.
- TAN Chuanyu. Research on moving object trajectory analysis technology [D]. Changsha: National University of Defense Technology, 2010.
- [23] 王芹, 谢元礼, 段汉明, 等. 基于实时路况的西安交通拥堵研究 [J]. 西北大学学报 (自然科学版), 2017, 47 (4): 622-626.
- WANG Qin, XIE Yuanli, DUAN Hanming, et al. On Xi'an traffic congestion based on real-time traffic data [J]. Journal of Northwest University (Natural Science Edition), 2017, 47 (4): 622-626.
- [24] 王芹. 基于实时路况的西安交通拥堵时空分布特征研究 [D]. 西安: 西北大学, 2017.
- WANG Qin. Research on the spatiotemporal distribution characteristics of traffic congestion in Xi'an based on real-time traffic conditions [D]. Xi'an: Northwest University, 2017.