

自行车交通事故致因研究

李瑞¹, 杜建坤²

(1. 武汉设计咨询集团有限公司, 湖北 武汉 430014; 2. 武汉市规划研究院[武汉市交通发展战略研究院], 湖北 武汉 430014)

摘要: 与自行车相关的交通事故在各类碰撞事故中占比较高, 其诱因通常涉及多因素之间的复杂交互作用。然而, 既有研究多聚焦于单一风险因素对自行车碰撞的影响, 对事故诱因间的相互作用机制尚不明确。为此, 提出一种融合潜在类别聚类分析与关联规则挖掘的研究方法, 以深入探讨影响自行车交通事故的风险因素及其交互作用机制。首先, 采用潜在类别聚类分析将事故划分为具有明显不同特征的事故簇; 其次, 利用关联规则挖掘方法, 识别影响自行车交通事故的关键因素及其内在关联。研究结果表明, 社会人口特征、建筑环境、道路网络和土地利用等因素均对自行车交通事故产生影响, 且这些因素在不同事故簇中呈现出显著的异质性效应。

关键词: 自行车交通安全; 潜在类别聚类分析; 关联规则挖掘; 事故特征; 建成环境; 大伦敦地区
A Study on the Causes of Bicycle Accidents

Li Rui¹, Du Jiankun²

(1. Wuhan Design Consulting Group Co., Ltd., Wuhan Hubei 430014, China; 2. Wuhan Planning & Design Institute [Wuhan Institute of Transportation Development Strategy], Wuhan Hubei 430014, China)

Abstract: Bicycle-related traffic accidents account for a high share of all collision accidents. The causes often involve complex interactions among multiple factors. However, most existing studies focus on the effect of a single risk factor on bicycle collisions, while the interaction mechanism among contributing factors remain unclear. To address this gap, this paper proposes a method that combines latent class clustering analysis and association rule mining, aiming to examine risk factors for bicycle accidents and the interaction mechanism. First, latent class cluster analysis is adopted to group accidents into clusters with clearly different features. Secondly, the major factors and their internal relationships are identified through association rule mining method. The results indicate that sociodemographic characteristics, the built environment, road networks, and land use all affect bicycle accidents. These effects exhibit heterogeneity across different accident clusters.

Keywords: bicycle traffic safety; latent class cluster analysis; association rule mining; accident characteristics; built environment; Greater London

收稿日期: 2025-05-29

作者简介: 李瑞(1995—), 男, 湖北恩施人, 硕士, 工程师, 研究方向为交通规划, 电子邮箱 522062389@qq.com。

引用格式: 李瑞, 杜建坤. 基于关联分析的自行车交通事故致因研究[J]. 城市交通, 2026, 24(1): 56-62.

Li Rui, Du Jiankun. A study on the causes of bicycle accidents[J]. Urban transport of China, 2026, 24(1): 56-62.

1 研究背景

自行车是城市居民中短距离出行的主要交通方式, 这一方式在城市交通结构中占比较高, 更是解决公共交通出行“最后一公里”问题的关键环节。在国家深入推进“双碳”目标的背景下, 自行车作为一种低碳交

通方式, 不仅可以用于出行、健身, 还可以助力“碳中和”目标的实现, 推进交通领域节能降碳。然而, 自行车作为道路交通中的弱势交通工具, 更容易在交通事故中受到严重伤害。近几年, 电动自行车以其便捷、经济等特性迅速普及, 工信部数据显示, 2025年中国电动自行车产量达6316万辆, 社会

保有量超4亿辆,居世界首位。与此同时,电动自行车交通安全形势严峻,据公安部统计,2024年全国共报告涉及电动自行车的交通事故约3万起,造成数万人伤亡,年均增长率超5%,电动自行车骑行者伤亡人数占非机动车伤亡的近80%。因此,系统识别并评估自行车交通事故的潜在风险因素,对改善城市交通运行秩序与提升非机动车交通安全水平具有重要意义。

在自行车交通事故致因研究方面,国内外学者已开展广泛探讨,分析了包括人口特征、道路环境、交通量等因素与自行车碰撞事故之间的关联性^[1-5]。例如,老年和青少年骑行者因安全意识薄弱,更容易发生交通事故;男性骑行者往往因驾驶行为更为激进,发生事故的概率通常高于女性。在道路环境方面,路网拓扑结构、交叉口密度、自行车基础设施(如非机动车道)、光照条件及天气状况等均被证实对事故发生产生显著影响。此外,交通量、行驶速度等交通特征也与自行车碰撞风险密切相关。在事故建模方面,泊松-伽马模型、负二项回归模型和贝叶斯模型等被广泛应用,但这些模型常受限于事故数据中未被观察到的异质性,可能导致参数估计产生偏差并影响模型性能。因此,随机参数模型(如随机泊松模型、随机负二项模型)应运而生^[6-7]。

然而,自行车交通事故通常受到各种因素之间复杂的相互作用,导致事故诱因及其相互依存关系仍然不明确。近几年,关联规则挖掘(Association Rule Mining, ARM)被广泛用于交通安全研究中,以确定事故与各因素之间的关联关系^[8-12]。例如,Wu K. F.等^[8]利用ARM探究了驾驶人特征、安全相关事件与交通事故之间的关联;J. Y. Hong等^[9]利用ARM识别了2008—2017年韩国高速公路危险品车辆事故的诱因;S. Das等^[10]将该方法应用于美国致命行人交通事故的情景特征分析;A. Montella等^[11]通过分类树与ARM揭示了动力二轮车(Powered Two-Wheelers, PTWs)事故特征间的依存关系和差异;M. T. Ashraf等^[12]利用决策树和ARM提取了网联自动驾驶车辆事故的碰撞前规则。

基于以上背景,本文提出基于关联规则挖掘方法研究自行车交通事故诱因及其相互作用机理。研究结果可为自行车交通管控策略、道路环境设计和安全管理提供理论依据与决策支持,有助于推动以人为本的城市交

通发展,并提升自行车交通安全水平。

2 研究数据

本文的分析数据源于大伦敦地区管理局(Greater London Authority, GLA)编制的2017—2019年警方记录交通事故数据集。在剔除含有缺失值的记录后,共提取出2917条涉及自行车(含电动自行车)的有效碰撞事故记录。该数据集包含两个部分。第一部分提供事故本身的详细离散变量信息,涵盖骑行者性别、年龄、出行目的、事故具体时间及地点类型等。第二部分主要记录事故地点的交通与环境信息,包括道路限速、信号控制状况、天气和光线条件等。表1列出了所用变量的描述性统计。

除了事故本身的特征变量,本文还引入事故发生地点所属的低层超级输出区(Lower Layer Super Output Area, LSOA)作为交通分析单元。LSOA是由英国国家统计局(Office of National Statistics, ONS)为小区域统计分析而设计的地理单元,广泛应用于人口普查和公共管理。本研究的事记录分布于288个不同的LSOA。为了更全面地分析区域背景特征对事故的影响,本文整合了来自英国国家统计局人口普查数据集和英国运输部交通信息数据集的区域层面数据,从中提取每个LSOA在人口特征、土地利用、道路类型、交通网络和基础设施等方面的连续型变量。

为避免变量间高度相关对后续分析造成干扰,本文进行了多重共线性检测,采用方差膨胀系数(Variance Inflation Factor, VIF)衡量其严重程度。参照既有研究,以VIF值小于5作为不存在多重共线性的阈值。经过筛选后的变量构成本文的分析数据集,即事故所在交通分析单元数据集,其具体变量描述见表2。

3 分析方法

3.1 潜在类别聚类分析

潜在类别聚类分析是一种基于无监督学习算法的数据分析方法,旨在从异质交通碰撞数据中识别同质数据并将其划分成簇聚类,以实现最大化簇内的同质性和簇间的异质性。不同于常见的基于数据元素间距离度的聚类算法,潜在类别聚类分析建立在概

率模型基础之上。其核心假设是：每个簇都具有不同的潜在概率分布，每个数据元素根据这些概率分布生成。因此，当概率分布已知时，簇的划分问题可转化为模型参数估计问题。该方法具有显著优点：无须预先确定簇的数量，能够同时处理计数、连续、分类等多种类型的变量，而且通常无须对数据进行标准化预处理^[13]。

本文使用Mplus软件识别潜在类别。假设碰撞数据集有 C 个潜在簇，每起事故包含 K 个分类变量。设 $Z_i = (Z_{i1}, \dots, Z_{iK})$ 为事故 i 对 K 个分类变量的响应向量，其中 Z_{ik} 的可能取值为 $\{1, 2, \dots, r_k\}$ 。令 $c_i = 1, 2, \dots, C$ 表示事故 i 的潜在类别簇组。事故 i 在给定其

所属类别 $c_i = c$ 时，对每个分类变量的完整响应概率计算方法为^[14]：

$$P(Z_i|c_i=c) = \prod_{k=1}^K \prod_{r_k=1}^{R_k} \rho_{k,r_k|c}^{I(z_k=r_k)}, \quad (1)$$

式中： $\rho_{k,r_k|c}$ 为在簇组 c 中，事故 i 的第 k 个分类变量取值为 r_k 的概率； $I(z_k=r_k)$ 为指示函数，当 $z_k=r_k$ 时， I 等于 1，否则等于 0。

使用最大似然算法估计参数后，再结合贝叶斯法则，事故 i 属于类别簇组 c 的后验概率计算方法为：

$$P(c_i=c|X_i) = \frac{e^{\alpha_c + X_i \gamma_c}}{\sum_{s=1}^C e^{\alpha_s + X_i \gamma_s}}, \quad (2)$$

式中： X_i 为自行车碰撞事故的属性向量； γ_c 和 γ_s 为待估计参数向量； α_c 和 α_s 分别为对应的截距项。

在潜在类别聚类分析中，由于最适于解释数据集的簇的数量未知，需通过拟合不同数量簇的模型并比较其优劣，以确定簇的最佳数量。为此，本文采用赤池信息标准 (Akaike Information Criterion, AIC)、贝叶斯信息标准 (Bayesian Information Criterion, BIC) 和经样本量调整的贝叶斯信息标准 (ABIC) 3 种信息标准进行聚类簇数选择。通常，使这些信息标准值最小的簇数为最优簇数。计算方法为

$$AIC = -2 \log(SSE/I) + 2l, \quad (3)$$

$$BIC = -2 \log(SSE/I) + \log(I) \times l, \quad (4)$$

$$ABIC = -2 \log(SSE/I) + l \times \log((I+2)/24), \quad (5)$$

式中： SSE 为误差平方和； l 为待估计参数数量/个。

同时，本文还采用基于熵的测度方法评价聚类效果。熵测度是个体后验概率的加权平均值，其取值范围为 0~1^[15]。熵测度值越大，表示潜在类别的区分效果越好。计算方法为：

$$Entropy = 1 - \frac{\sum_i \sum_c (-P(c_i=c|Z_i) \times \log P(c_i=c|Z_i))}{I \times \log C}. \quad (6)$$

3.2 关联规则挖掘

关联规则挖掘旨在从数据中挖掘潜在的关联关系，其主要目标是识别给定事件中频繁共同出现的一组项目^[16]。基于项目集在数据库中单独出现和组合出现的相对频率构建关联规则，通常以“ $A \rightarrow B$ ”的形式表示，用以揭示项目集之间的关联模式。

与传统的统计方法相比，关联规则挖掘

表1 自行车碰撞事故变量描述性统计

Tab.1 Descriptive statistics of variables for bicycle accidents

变量	事故数量/起	比例/%
性别	男性	72.8
	女性	27.2
年龄/岁	0~15	1.1
	16~24	15.9
	25~59	81.0
	≥60	2.0
事故发生日类型	非工作日	14.6
	工作日	85.4
事故发生时段	午夜时段	8.1
	平峰时段	40.5
	高峰时段	51.4
事故地点限速/ (英里·h ⁻¹)	≤20	36.1
	30	62.6
	40	0.9
	50	0.3
	60	0.1
事故地点光照	明亮	74.5
	黑暗	25.5
事故地点天气	晴朗	87.0
	恶劣	13.0
事故地点类型	非交叉口	26.0
	交叉口	74.0
事故地点信号控制	无信号控制	70.4
	信号控制	29.6
出行目的	非通勤出行	46.6
	通勤出行	53.4

不需要预先定义因变量和自变量，因而具有挖掘隐藏、非预期但有价值关系数据的潜力。本文采用广泛使用的Apriori算法进行事故数据分析。该算法包括两个步骤：首先，通过迭代扫描数据库以识别所有频繁项集；然后，基于这些频繁项集生成具有较高置信度与支持度的强关联规则。

在Apriori算法中，支持度、置信度和提升度是识别关联规则的3个重要指标。支持度定义为前项A和后项B同时出现的事故数与数据库中的事故总数之比，用于衡量该规则在数据集中的覆盖程度。其计算方法为：

$$Support(A \rightarrow B) = \frac{n(AB)}{N}, \quad (7)$$

式中：N为事故总数/起；n(AB)为同时满足前项A和后项B的事故数/起。

置信度定义为在前项A发生的情况下，后项B也发生的概率。其计算方法为：

$$Confidence(A \rightarrow B) = \frac{Support(A \rightarrow B)}{Support(A)}, \quad (8)$$

$$Support(A) = \frac{n(A)}{N}. \quad (9)$$

提升度用于衡量前项A和后项B之间的相关性，定义为前项和后项同时出现的概率与假设二者独立时同时出现的概率之比。提升度大于1且数值越高，表示两项之间的正相关性越强、规则越有效。其计算方法为：

$$Lift(A \rightarrow B) = \frac{Confidence(A \rightarrow B)}{Support(B)}. \quad (10)$$

4 结果分析

4.1 潜在类别聚类分析结果

为分析自行车碰撞事故的内在异质性，本文基于事故数据集，将自行车事故聚类为不同的簇。为确定适当的簇数，测试了从1到6的不同聚类方案，并基于BIC, AIC和ABIC准则选择最终的簇数^[17-18]。这些准则不仅能有效评估模型拟合优度，还能对模型的复杂性进行校正^[19]。

如图1所示，随着簇数量的增加，各信息准则值整体呈下降趋势，仅BIC值在4个簇后出现轻微上升。既有研究采用以下标准来确定簇的数量：信息准则值的相对下降幅度小于1%，且熵值大于0.9^[17-20]。计算不同聚类簇数下3个信息准则值的百分比差异发现，当簇数从3增至4时，3个准则值的下降幅度均降至1%以下，说明继续增加簇数对模型改善有限。此外，3个簇的熵值为

0.932，表明所识别的簇之间具有较好的区分度。因此，本文将自行车碰撞事故本身的数据分为3个簇，用于后续分析。

3个簇的模型为每个变量提供依赖于聚类的单变量分布，从而可将每个簇识别为特定的交通事故类型。通过比较簇之间不同变量的分布差异，能够简洁地描述每个簇的主要特征。表3中列出了各变量在每个簇中的分布情况。若某个簇中某变量的占比显著高于其他簇，而该变量在其他簇中分布相对均衡，则可以将该簇定义为与该变量相关的事

表2 事故所在交通分析单元数据集的变量描述性统计

Tab.2 Statistics of the dataset for traffic units where accidents occurred

分类	变量	平均值	标准差	最小值	最大值	
社会人口特征	人口密度/(人·km ²)	17.53	9.30	1.74	78.95	
	性别	男性比例/%	51	3	44	64
		女性比例/%	49	3	36	56
	年龄	老年人比例 ¹⁾ /%	11	5	2	29
		其他年龄组比例/%	89	5	71	98
土地利用	家庭收入/万英镑	26.21	11.76	6.06	57.94	
	商业区比例/%	0.21	0.13	0.01	0.56	
道路网络	绿化比例/%	0.32	0.16	0.03	0.83	
	A等级道路(类似主干路)比例/%	4.75	3.80	0	20.75	
	B等级道路(类似次于干路)比例/%	1.10	1.94	0	11.72	
	生活性道路比例/%	1.10	1.79	0	9.82	
	道路网平均连通度	2.24	0.83	0.12	4.00	
	道路网平均可达性	2.80	0.06	2.62	2.93	
	交叉口密度/(个·km ²)	0.11	0.09	0	0.72	
建成环境	非机动车道密度/(km·km ²)	0.06	0.10	0	0.84	
	年平均日交通量(对数 ²⁾)	4.14	0.32	2.46	5.02	
	公共汽车站平均密度/(个·km ²)	0.47	0.36	0.07	2.83	

1) 指年龄高于60岁的人口。

2) 为了更科学地处理数据，实现可视化或建模，将原始单位为“pcu·d⁻¹”的交通量数值进行了对数运算。

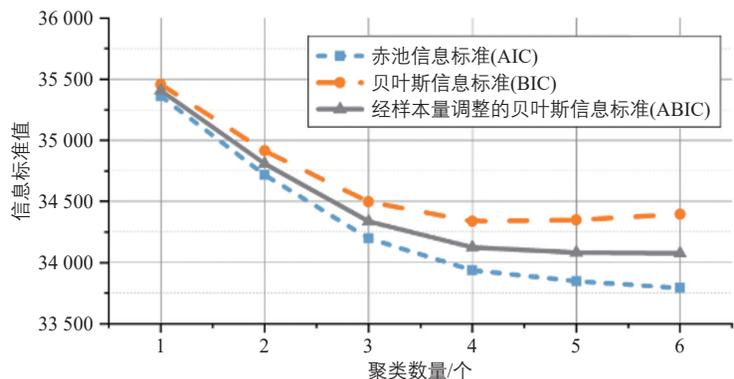


图1 自行车碰撞事故聚类分析结果

Fig.1 Results of the cluster analysis for bicycle accidents

故簇。

在全部事故中，簇1的事故占比最高，为63.8%。该簇中，58.1%的事故发生于高峰时段(7:00—10:00, 16:00—19:00)，82.2%的事故发生在明亮光照条件下，且所有事故均位于无信号控制区域。这表明，无信号控制区域对自行车骑行者具有较高风险。因此，将簇1命名为“白天高峰时段无信号控制区域自行车碰撞事故”。

相比之下，簇2的事故仅占总事故的8.7%，但特征最为突出。其中，69.7%的事故发生于午夜时段(22:00—6:00)，且95.9%的事故发生在黑暗光照条件下。因此，将簇

2命名为“午夜时段黑暗条件下自行车碰撞事故”。

簇3在事故发生时段和光照条件上与簇1相似，其区别于簇1的主要特征是所有事故均发生在信号控制交叉口。因此，将簇3命名为“白天高峰时段信号控制交叉口自行车碰撞事故”。

4.2 关联规则挖掘结果

由于表2中均为离散型变量，为适应关联规则的分析要求，将各变量按数值大小降序排列，取前50%的样本标记为“变量-大”，后50%的样本标记为“变量-小”。表4详细列出了所有数据以及各事故簇的二元关联规则，涵盖支持度、置信度和提升度等重要指标。表格内容按提升度降序排列，有助于深入理解影响自行车安全风险的变量之间的相互作用关系。

在全样本数据中，显著的关联规则主要涉及商业区比例、绿化比例与道路密度(即表2中A等级道路、B等级道路及生活性道路比例之和)等变量。例如，全样本中规则2表明，具有“商业区比例小、道路密度小以及绿化比例大”特征的区域更容易发生自行车碰撞事故。其原因可能在于，商业区比例小或道路密度低的区域，机动车驾驶人可能更倾向于以较高速度行驶，且对自行车的警觉性较低，因而增加自行车碰撞风险。此外，绿化比例大的街区可能吸引大量休闲骑行人群，其骑行速度及技能差异可能导致事故发生概率上升。同时，绿化区域内的树木、灌木丛等植被可能遮挡骑行者对交通信号、标志及其他车辆的视线，使其在交叉口或路段中难以及时发现潜在危险，进一步增加碰撞风险。

与全样本关联规则相比，簇1的关联规则呈现明显异质性。具体而言，结合表3中簇1的特征分布，在光照条件良好的高峰时段，无信号控制区域、男性比例较低或公共汽车站平均密度较低的区域，发生自行车碰撞事故更为频繁。男性骑行者通常具备更好的骑行技能与应急反应能力，因此在无信号控制区域更可能规避事故。较低的公共汽车站平均密度则意味着该街区公共交通不够便利，可能促使更多人在高峰时段选择私人小汽车或自行车通勤出行，加剧道路交通拥堵，进而提升碰撞风险。

簇2关联规则的异质性主要体现在两个

表3 各事故簇特征分布

Tab.3 Distribution of characteristics across accident clusters

变量		簇1	簇2	簇3
性别	男性	0.714	0.785	0.739
	女性	0.286	0.215	0.261
年龄/岁	0~15	0.012	0.006	0.010
	16~24	0.166	0.209	0.123
	25~59	0.804	0.770	0.840
	≥60	0.018	0.015	0.027
事故发生日类型	非工作日	0.125	0.309	0.130
	工作日	0.875	0.691	0.870
事故发生时段	午夜时段	0.005	0.697	0.008
	平峰时段	0.414	0.303	0.426
	高峰时段	0.581	0	0.566
事故地点限速/(英里·h ⁻¹)	≤20	0.375	0.390	0.318
	30	0.612	0.595	0.666
	40	0.009	0.010	0.008
	50	0.003	0.005	0.004
	60	0.001	0	0.004
事故地点光照	明亮	0.822	0.041	0.849
	黑暗	0.178	0.959	0.151
事故地点天气	晴朗	0.874	0.825	0.879
	恶劣	0.126	0.175	0.121
事故地点类型	非交叉口	0.376	0.239	0
	交叉口	0.624	0.761	1
事故地点信号控制	无信号控制	1	0.761	0
	信号控制	0	0.239	1
出行目的	非通勤出行	0.464	0.599	0.415
	通勤出行	0.536	0.401	0.585

注：粗体数值为每个簇的特征变量。

方面。首先，非机动车道密度的影响凸显，成为最重要的关联因素。较低的非机动车道密度可能导致自行车与机动车混行，引发路权竞争，加之夜间光照条件差，机动车驾驶人可能难以充分注意到共享车道上的自行车，从而增加碰撞风险。其次，老年人比例较高且家庭收入较低的区域更易发生事故。老年人受感知能力与反应能力下降的影响，骑行时风险较高；而在家庭收入较低的区域，交通安全教育可能相对不足，导致骑行安全意识薄弱，违法行为增多。这些因素在夜间黑暗环境中会被进一步放大。

簇3的关联规则与其他簇存在部分相似性，但其首要规则具有显著特征。家庭收入较高的区域通常自行车和小汽车普及率较高，两者在高峰时段更易发生冲突，从而提升碰撞风险。同时，该区域老年人比例较低，意味着年轻人居多。年轻人整体驾驶风

格更加激进，在高峰时段为追求通行效率，可能出现闯红灯等违法行为，进而增加事故发生概率。

5 结束语

本文以大伦敦地区为例，运用潜在类别聚类分析与关联规则挖掘相结合的方法，分析自行车交通事故与社会人口特征、土地利用、道路网络及建筑环境的关联性。通过探讨自行车交通事故的异质性，深入分析了不同特征变量与自行车交通事故之间的关系。

本文将自行车交通事故划分为三类：1)光照良好、高峰时段、发生于无信号控制区域的自行车碰撞事故；2)光照较差、夜间时段发生的自行车碰撞事故；3)光照良好、高峰时段、发生于信号控制交叉口的自行车碰撞事故。人口特征、建筑环境、道路网络

表4 各组别数据的关联规则挖掘结果

Tab.4 Results of association rule mining for each dataset group

组别	规则ID	关联规则		支持度	置信度	提升度
		前项	后项			
全部	1	绿化比例-大&公共汽车站平均密度-小	商业区比例-小	0.23	0.88	2.33
	2	商业区比例-小&道路密度-小	绿化比例-大	0.22	0.87	2.25
	3	绿化比例-大&男性比例-小	商业区比例-小	0.20	0.85	2.24
	4	商业区比例-小&非机动车道密度-小	绿化比例-大	0.21	0.84	2.18
	5	商业区比例-小&人口密度-小	绿化比例-大	0.20	0.79	2.05
	6	人口密度-小&道路密度-小	绿化比例-大	0.21	0.76	1.96
簇1	1	绿化比例-大&公共汽车站平均密度-小	商业区比例-小	0.27	0.90	2.20
	2	商业区比例-小&道路密度-小	绿化比例-大	0.25	0.87	2.11
	3	男性比例-小&绿化比例-大	商业区比例-小	0.24	0.86	2.09
	4	男性比例-小&公共汽车站平均密度-小	商业区比例-小	0.23	0.83	2.03
	5	商业区比例-小&人口密度-小	绿化比例-大	0.23	0.81	1.97
	6	男性比例-小&公共汽车站平均密度-小	绿化比例-大	0.22	0.79	1.93
	7	男性比例-小&道路密度-小	绿化比例-大	0.22	0.79	1.93
	8	公共汽车站平均密度-小&道路密度-小	绿化比例-大	0.25	0.79	1.91
簇2	1	商业区比例-小&非机动车道密度-小	绿化比例-大	0.22	0.92	2.62
	2	绿化比例-大&公共汽车站平均密度-小	商业区比例-小	0.21	0.87	2.51
	3	老年人比例-大&人口密度-少	家庭收入-小	0.24	0.79	1.73
	4	老年人比例-大&交叉口密度-小	家庭收入-小	0.23	0.77	1.69
簇3	1	家庭收入-大&交叉口密度-小	老年人比例-小	0.21	0.71	1.49
	2	人口密度-小&绿化比例-大	非机动车道密度-小	0.21	0.81	1.48
	3	绿化比例-大&交叉口密度-小	非机动车道密度-小	0.21	0.78	1.41

和土地利用等因素均对自行车交通事故的发生产生影响,且这些因素在不同事故聚类中表现出显著的异质性。具体而言,男性比例、老年人比例、家庭收入、绿化比例、商业区比例、非机动车道密度、道路密度和公共汽车站平均密度等变量在不同簇组中的影响程度与模式存在明显差异。这些研究结论对道路基础设施优化、交通管理政策制定以及执法策略设计具有重要参考价值,可为降低自行车骑行者的道路安全风险提供针对性依据;同时,也为开展交通安全教育和宣传提供了科学参考,有助于提高骑行者的安全意识和自我保护能力。

然而,本文仍存在一定的局限性。自行车出行受季节影响显著,既有研究指出,5—10月的自行车使用率明显高于11月至次年4月,因此后续研究有必要进一步探讨风险因素对不同事故类型在时间维度上的影响机制。此外,在未来获取更完备数据的基础上,还可进一步开展骑行者安全感知、行为模式与碰撞风险之间关系的研究,从而更系统地识别并解释影响自行车安全的多维因素。

参考文献:

References:

- [1] Ding Hongliang, Sze N N. Effects of road network characteristics on bicycle safety: a multivariate Poisson-lognormal model[J]. *Multimodal transportation*, 2022, 1(2): 100020.
- [2] 王卫杰, 沈轩霆, 王贵彬, 等. 电动自行车骑行者事故伤害程度影响因素分析[J]. *中国安全科学学报*, 2019, 29(2): 20-25.
Wang Weijie, Shen Xuanting, Wang Guibin, et al. Analysis of factors affecting injury to electric bicycle rider in crash[J]. *China safety science journal*, 2019, 29(2): 20-25.
- [3] 王菁, 董春娇, 李鹏辉, 等. 考虑建成环境的电动自行车事故严重程度致因分析[J]. *交通运输系统工程与信息*, 2024, 24(1): 179-187.
Wang Jing, Dong Chunjiao, Li Penghui, et al. Causal analysis of e-bike traffic accident severity considering built environment[J]. *Journal of transportation systems engineering and information technology*, 2024, 24(1): 179-187.
- [4] 吴良伟, 邹铁方, 刘阳阳, 等. 基于视频的自行车事故特征及控制人致伤因素观察[J]. *汽车工程学报*, 2021, 11(6): 393-403.
Wu Liangwei, Zou Tiefang, Liu Yangyang, et al. Observation on characteristics of bicycle accidents and injury factors for bicycle riders based on video recordings[J]. *Chinese journal of automotive engineering*, 2021, 11(6): 393-403.
- [5] 王涛, 黎文皓, 李文勇. 电动自行车交通事故严重程度影响因素分析[J]. *广西大学学报(自然科学版)*, 2017, 42(6): 2080-2088.
Wang Tao, Li Wenhao, Li Wenyong. Influence factors and injury severity in electric bicycles traffic crashes[J]. *Journal of Guangxi University (natural science edition)*, 2017, 42(6): 2080-2088.
- [6] 陈昭明, 徐文远. 基于负二项分布的高速公路交通事故影响因素分析[J]. *交通信息与安全*, 2022, 40(1): 28-35.
Chen Zhaoming, Xu Wenyuan. An analysis of factors influencing freeway crashes with a negative binomial model[J]. *Journal of transport information and safety*, 2022, 40(1): 28-35.
- [7] Mannering F L, Shankar V, Bhat C R. Unobserved heterogeneity and the statistical analysis of highway accident data[J]. *Analytic methods in accident research*, 2016, 11: 1-16.
- [8] Wu Kunfeng, Aguero-valverde J, Jovanis P P. Using naturalistic driving data to explore the association between traffic safety-related events and crash risk at driver level[J]. *Accident analysis & prevention*, 2014, 72: 210-218.
- [9] Hong Jungyeol, Tamakloe R, Park Dongjoo. Application of association rules mining algorithm for hazardous materials transportation crashes on expressway[J]. *Accident analysis & prevention*, 2020, 142: 105497.
- [10] Das S, Dutta A, Sun Xiaoduan. Patterns of rainy weather crashes: applying rules mining[J]. *Journal of transportation safety & security*, 2020, 12(9): 1083-1105.
- [11] Montella A. Identifying crash contributory factors at urban roundabouts and using association rules to explore their relationships to different crash types[J]. *Accident Analysis & Prevention*, 2011, 43(4): 1451-1463.
- [12] Ashraf M T, Dey K C, Rahman M T, et al. Extracting rules from autonomous-vehicle-involved crashes by applying decision tree and association rule methods[J]. *Transportation research record: journal of the Transportation Research Board*, 2021, 2675(11): 522-533.

(下转第31页)