

基于时间序列关系的 GBRT 交通事故预测模型



杨文忠¹, 张志豪^{1*}, 吾守尔·斯拉木¹, 温杰彬¹, 富雅玲¹, 王丽花², 王 婷²

(1. 新疆大学信息科学与工程学院 乌鲁木齐 830046; 2. 新疆大学软件学院 乌鲁木齐 830046)

【摘要】道路交通事故是道路交通安全水平的具体表现。在当前交通事故预测工作中, 存在对数据中时间序列关系的挖掘不充分、预测的周期宏观、交通事故相关的影响因素考虑不全等问题。该文提出一种基于时间序列关系的梯度提升回归树(GBRT)交通事故模型。该模型对英国 Leicester 的 2005–2015 年每天的交通事故数、死亡人数、涉事的车辆数进行预测。实验结果显示, 引入时间序列关系有助于提升模型预测精度。预测结果为交通管理部门的决策起到参考作用, 建模方式为同类型预测问题的建模工作带来了积极的参考意义。

关键词 梯度提升回归树; 预测; 时间序列; 交通事故

中图分类号 U495 **文献标志码** A **doi**:10.12178/1001-0548.2019151

GBRT Traffic Accident Prediction Model Based on Time Series Relationship

YANG Wen-zhong¹, ZHANG Zhi-hao^{1*}, WUSHOUER Silamu¹, WEN Jie-bin¹,
FU Ya-ling¹, WANG Li-hua², and WANG Ting²

(1. College of Information Science and Engineering, Xinjiang University Urumqi 830046; 2. School of Software, Xinjiang University Urumqi 830046)

Abstract Road traffic accidents are a concrete manifestation of road traffic safety levels. In the current traffic accident prediction work, there is an insufficient mining of the time series relationship in the data, the predicted time period is too macroscopic, and the influencing factors related to traffic accidents are missing. Aiming at the above problems, a gradient boosted regression tree (GBRT) traffic accident model based on time series relationship is proposed. The model predicts the number of daily traffic accidents, deaths, and the number of vehicles involved in Leicester, England, from 2005 to 2015. Experimental results show that adding the time series relationship helps to improve the prediction accuracy of the model. The prediction results serve as a reference for the decision-making of the traffic management department. The modeling method brings positive reference significance to the modeling work of the same type of prediction problems.

Key words gradient boosted regression tree (GBRT); prediction; time series; traffic accidents

到 2020 年, 将道路交通事故造成的全球伤亡人数减半是联合国 2015 年发布的可持续发展目标之一^[1]。国家在交通安全上的注意力不断增加, 十九大报告中提出建设“交通强国”的口号, 交通运输部又提出了建设“新型交通运输智库”的政策。将交通事故态势预测结果应用到交通规划中, 能提高交通安全水平。

研究者对交通事故的某些指标进行了预测, 研究方法主要分为 3 类: 统计回归法、灰色预测^[2]、神经网络模型方法。

统计回归方法包括时间序列预测和许多经典的交通事故经验模型。文献 [3] 采用结构时间序列方法对马来西亚 2001–2012 年道路交通事故趋势进行了建模。文献 [4] 采用时间序列分析方法对库尔德斯坦地区道路交通事故伤亡数据进行了表征和预测。文献 [5] 将逆模糊函数引入到模糊时间序列预测的研究中, 提高了时序预测工作的精度。文献 [6] 利用自回归综合移动平均线 (ARIMA) 和具有解释变量的自回归综合移动平均线 (ARIMAX) 建模技术, 建立预测尼日利亚阿南布拉州事故频率的预测

收稿日期: 2019-06-26; 修回日期: 2020-04-23

基金项目: 新疆维吾尔自治区自然科学基金 (2017D01C042)

作者简介: 杨文忠 (1971-), 男, 博士, 副教授, 主要从事网络舆情、情报分析、信息安全等方面的研究。

通信作者: 张志豪, E-mail: 1464501547@qq.com

模型。文献 [7] 采用季节自回归综合移动平均法 (SARIMA) 预测了伊朗 2005 年 3 月-2016 年 2 月月道路交通伤害 (RTI) 的时间趋势。文献 [8] 建立了基于 ARIMA 模型和 SVR 模型的混合预测模型, 用于交通事故统计指标的时间序列预测。回归模型具有计算简单方便的特点, 对短期的数据变化有一定的预测能力, 其实质是对数据的线性拟合。由于交通事故自身的随机性大, 影响因素众多, 且抗干扰能力弱, 所以该方法预测的结果具有片面性, 预测结果的可靠性得不到保证。

在样本数量少的情况下, 灰色预测可以对具有光滑离散函数特性的数据建模进行预测。文献 [9] 提出了一种具有强指数规律的序列 GM(1,1) 模型来预测交通事故, 但该模型只能描述单调的变化过程。文献 [10] 采用灰色系统理论 MGM(1,4), 基于电子稳定程序 (ESP) 的市场扩散, 预测了德国 2025 年前道路交通事故的趋势。文献 [11] 提出了道路交通事故的灰色 Verhulst 预测模型, 适用于非单调摆动发展序列或具有饱和状态的 S 形序列。文献 [12] 基于灰色系统理论和马尔可夫链理论, 应用 SCGM(1,1)_c 拟合了道路交通时序数据的总体趋势。文献 [13] 提出了一种加权组合多种灰色预测方法的模型, 虽然预测精度有所提高, 但其实质是原始数据的线性组合, 中长期预测仍存在不足。

神经网络预测方法具有较强的非线性映射及自学习能力、高鲁棒性, 在许多领域得到了广泛的应用。文献 [14] 提出了一种基于 BP 神经网络的交通事故预测模型。文献 [15] 利用交通事故预测算法 (如时间序列法、灰色预测理论和神经网络方法) 预测 1981-2007 年中国交通事故总数。由于 BP 神经网络模型存在训练收敛速度慢、训练时间长、易陷入鞍点等缺点, 文献 [16] 提出了一种灰色神经网络模型。灰色理论弥补了小样本数据中失真数据挖掘的不足, 而神经网络弥补了灰色理论只能用于短期预测的不足。

本文的主要工作有:

1) 交通事故具有时间空间上的异构性, 而大多数学者的预测工作过于宏观, 空间上以国家为单位, 时间上以年为单位, 在应用层面, 对有关管理部门的指导意义不大。本文充分利用了与交通事故相关的人、车、路、环境等特征, 建立了基于 GBRT 方法的交通事故预测模型, 对英国城市每日的交通事故数据进行预测。

2) 在数据建模时, 针对离散类别特征, 传统

的 One-Hot Encoding 方式, 只能表达特征类别, 不能表达特征数量, 本文通过统计方法构造出离散类别特征的标签与事故数据之间的映射关系, 使用映射数据来进行预测工作。

3) 针对时序建模过程中, 对数据中时序关系挖掘不充分的问题, 本文在数据建模中同时考虑了长周期段、短周期段中的时间序列关系, 利用多种时间序列关系来构造数据集。

1 增强梯度回归树模型

GBRT 是 boosting^[17] 类型的集成学习算法^[18]。集成学习是一种技术框架, 它通过使用多个不同的基模型进行组合, 完成相应的工作, 以求更加高效、准确。目前常用的集成学习框架包括: bagging、stacking 和 boosting。其中 boosting 框架使用多组基模型分别进行训练, 所有基模型的结果经过线性组合得到鲁棒性更高的预测结果。图 1 为 boosting 集成学习框架的示意图。

基于 boosting 框架描述如下:

$$F(x) = \sum_i^m h_i(x) \quad (1)$$

式中, $h_i(x)$ 表示基模型。整体模型的训练目标是使预测值 $F(x)$ 逼近真实值 y , 专家学者们以贪心算法的思想让每个基模型分别承担部门预测任务, 分别逼近各自的预测任务, 对每个基模型所产生的误差进行重点攻克。

$$F^i(x) = F^{i-1}(x) + h_i(x) \quad (2)$$

通过引入任意损失函数, 拟合反向梯度, 有:

$$F^i(x) = F^{i-1}(x) + \arg \min_j \sum_j^n L(y_j, F^{i-1}(x_j) + h_i(x_j)) \quad (3)$$

GBRT 是基函数使用树结构的 boosting 集成学习模型。对于给定的 n 条记录的 m 个特征, 使用 K 个树函数累加来预测输出:

$$\hat{y}_i = \phi(x_i) = \sum_{k=1}^K f_k(x_i), f_k \in \Gamma \quad (4)$$

$$\Gamma = \{f(x) = w_{q(x)}\} (q: \mathcal{X}^m \rightarrow T, \omega \in \mathcal{R}^T) \quad (5)$$

式中, q 表示将记录映射到相应的叶索引的每个树的结构; T 是树上的叶子数; 每个 f 对应一个独立的树结构 q 和叶子权重 w ; w_i 表示第 i 个叶子上的得分。利用线性搜索估计叶节点区域的值, 使损失函数极小化, 然后更新回归树。

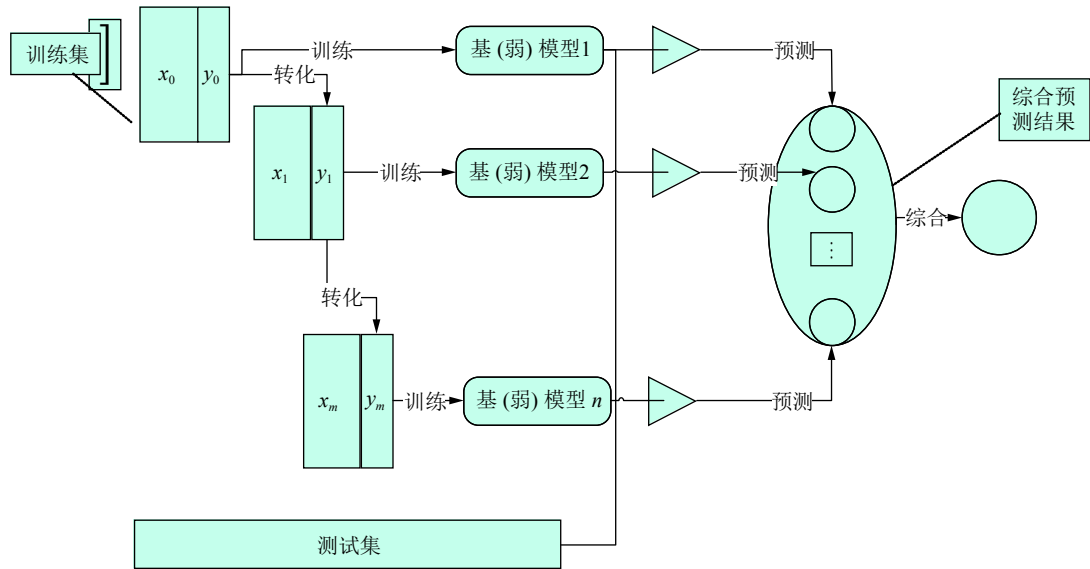


图 1 boosting 集成学习框架的示意图

2 数据处理

2.1 数据来源

本文使用了英国运输部公开的 2005–2015 年的交通事故数据“road-accidents-safety-data”。经过统计排序, 从 207 个城市筛选出了事故最多的城市 Leicester(编码: E1000016)作为数据样本。2005–2015 年, 这座城市发生了 49 209 起交通事故, 死亡人数为 67 039, 涉及事故车辆达到了 91 963 辆。

2.2 离散特征描述及标签映射

交通事故的发生由多种因素共同导致, 本文综合考虑了人、车、路、环境 4 方面因素, 选取的特征详细信息如表 1 所示。

表 1 中的 11 类离散类别特征, 在时间维度上使用传统 One-Hot Encoding 方法时, 只能表示出子类别, 不能对子类别的数值进行量化表示。原始数据是根据每一起交通事故进行记录的, 本文的目标是对某段时间周期内的事数量进行预测。

表 1 特征取值类型及子标签数量

特征名称	取值类型	子标签数
事故数	数值类型	/
死亡人数	数值类型	/
涉事的车辆数	数值类型	/
事故严重程度	离散类型	3
道路等级	离散类型	6
道路类型	离散类型	8
速度限制	离散类型	6
光线条件	离散类型	7
天气状况	离散类型	9
路面条件	离散类型	5
城市或农村地区	离散类型	3
现场是否出现警察	离散类型	4
驾驶员性别	离散类型	3
驾驶员年龄段	离散类型	12
特征子标签数合计	/	66

本文以天为时间单位, 建立起每个离散类别特征子标签与事故数据的映射关系。对数值类型的特征处理是通过每天的数据进行统计求和操作。表 2 为 2005 年 1 月 1 日道路类别的不同子标签与 3 类事故数据所建立的映射关系。

表 2 道路类别子标签映射示例

日期	编码	道路类别子标签	事故数	死亡人数	涉事车辆数
2005/1/1	1	环状交叉路口 (roundabout)	1	1	1
2005/1/1	6	不分隔车路 (single carriageway)	5	9	7
2005/1/1	2	单行道 (one way street)	空值	空值	空值
2005/1/1	3	双线车道 (dual carriageway)	空值	空值	空值
2005/1/1	7	通往高速公路之交流道 (slip road)	空值	空值	空值
2005/1/1	9	未知 (unknown)	空值	空值	空值
2005/1/1	12	单向街/支路 (one way street/slip road)	空值	空值	空值
2005/1/1	-1	数据丢失或超出范围 (data missing or out of range)	空值	空值	空值

表 1 中, 特征道路类别的子标签有 8 种。表 2 中, 2005 年 1 月 1 日统计结果显示, 特征道路类别出现了两种子标签, 另外 6 种子标签为空值。使用上述方法, 统计出了 2005–2015 年间 4 017 天的离散特征的 66 个子标签的映射关系。最终的输入特征为 66 个子标签的映射结果和目标事故数据的上一个时间周期的历史值。

2.3 空值处理

交通事故的时间空间稀疏性导致了经过映射的离散特征产生了大量空值, 需要进行空值处理。

零值填充方法: 在模型学习过程中, 更容易学习到导致事故发生的高权重特征。均值填充方法: 在风险防范角度考虑的更周全, 虽然没有发生事故, 但事故的风险始终存在。为了更好地选择出空值处理方法, 本文使用零值填充和均值填充两类方法进行对比实验。

3 基于时间序列关系的 GBRT 交通事故预测模型

3.1 时间序列关系建模

一个过程随时间的演变是人口的变化、城市化和机动化的过程、医学的进步、道路的改善、更安全的车辆、对风险以及其他社会规范态度的变化等^[9]。所以, 本文利用时间序列中的周期关系, 在传统的建模方法基础上, 提出了周期时序关系 (*last_period*) 和多元周期时序关系 (*merge_period*) 建模方法。

1) 传统建模方法 (*one_by_one*): 使用第 $t-1$ 天的数据作为输入特征, 对第 t 天的目标数据进行预测。

2) 周期时序关系建模方法 (*last_period*): 利用数据中的周期性规律建模, 使用第 $t-(\text{period})$ 天的数据, 预测第 t 天的目标数据。

3) 多元周期时序关系建模方法 (*merge_period*): 使用第 $t-1$ 天、第 $t-(\text{period})$ 天的数据作为输入特征, 预测第 t 天的目标数据。

本文使用年作为时间周期, 来描绘相似的季节性环境特性; 使用星期作为时间周期, 描绘人们的工作生活规律特性。构造了 *last_week*、*last_year*、*merge_week*、*merge_year* 共 4 类数据。

因为预测目标无法验证, 在构造数据时需要剔除最后一个时间周期的数据记录, 由于平、闰年的问题, 数据存在缺失的情况。如 2008 年 2 月 29 日的上一年不存在 2007 年 2 月 29 日, 本文使用相邻

两天的平均值来填充。*last_year* 类别数据中, 填充了 2007 年 2 月 29 日、2011 年 2 月 29 日的两条记录。对 *merge_year* 类别数据, 填充了 2009 年 2 月 29 日、2013 年 2 月 29 日的两条记录。以星期作为时间周期不存在缺失的情况, 可以直接使用第 $t-7$ 天的数据预测第 t 天的数据。

最终利用不同的建模方法, 分别对事故数 (*accident*)、死亡人数 (*casualties*)、涉事的车辆数 (*vehicles*) 3 组目标特征构建了 15 组实验数据。由于空值处理分别使用了零值填充和均值填充, 所以本文的 30 组实验数据、数据集的信息如表 3 所示。

表 3 数据集信息描述

数据类别	记录	特征数	预测目标
<i>one_by_one</i>	4 017	67	事故数
	4 017	67	死亡人数
	4 017	67	涉事的车辆数
<i>last_week</i>	4 010	67	事故数
	4 010	67	死亡人数
	4 010	67	涉事的车辆数
<i>last_year</i>	3 655	67	事故数
	3 655	67	死亡人数
	3 655	67	涉事的车辆数
<i>merge_week</i>	4 010	134	事故数
	4 010	134	死亡人数
	4 010	134	涉事的车辆数
<i>merge_year</i>	3 655	134	事故数
	3 655	134	死亡人数
	3 655	134	涉事的车辆数

3.2 GBRT 模型正则化

$$L(\phi) = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k) \quad (6)$$

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \|\omega\|^2 \quad (7)$$

式中, L 是一个可微凸损失函数, 用来度量预测值 I 和数据中真实预测目标值 y_i 之间的差异; \hat{y}_i 代表树模型得到的预测目标值; l 表示对 (y_i, \hat{y}_i) 计算损失函数; $\Omega(f_k)$ 表示第 k 个树函数的惩罚项; $\Omega(f)$ 代表惩罚项的详细表示, 惩罚了模型的复杂性, 平滑处理学习权重, 可以避免过拟合; λ 、 γ 是超参数, 用于控制正则化程度; T 代表 f 这个树函数的叶子数; ω 为叶子对应的权重; $\|\omega\|^2$ 代表 L2 范数, 通过权重的平方和来实现正则化。

3.3 超参选择

模型的超参主要包括: 学习率、估计器个数、树的最大深度、样本内部分裂节点数、叶子节点所

需的最小样本及损失函数。

本文利用 GridResearchCV 在训练集上自动寻找最优超参。设定学习率分别为 0.2、0.1、0.05。样本内部分裂节点和叶子节点所需的最小样本都设置为 1~10 之间, 树的最大深度为 1~15 之间, 估计器的个数取 10~150 之间 10 的倍数。表 4 为模型使用不同建模方法, 零值填充和均值填充寻找到的超参数据表。

表 4 模型超参信息表

建模方法	学习率	数据(零值填充/均值填充)			
		最大深度	最小样本	分裂节点	估计器数
one_by_one_accident	0.1/0.1	2/2	1/1	2/2	140/140
one_by_one_casualties	0.2/0.1	3/2	1/1	3/2	130/140
one_by_one_vehicles	0.1/0.1	2/2	1/1	5/4	100/120
last_week_accident	0.1/0.2	2/2	1/1	3/6	130/130
last_week_casualties	0.2/0.1	2/2	1/1	2/2	130/130
last_week_vehicles	0.1/0.2	2/2	1/1	2/2	120/140
last_year_accident	0.2/0.2	2/2	1/1	4/2	130/100
last_year_casualties	0.2/0.2	9/2	1/1	3/2	90/130
last_year_vehicles	0.2/0.1	2/2	1/1	2/2	90/110
merge_year_accident	0.2/0.1	3/2	1/1	3/3	40/140
merge_year_casualties	0.2/0.2	2/2	1/1	3/3	80/100
merge_year_vehicles	0.2/0.1	2/2	1/1	2/2	110/120
merge_week_accident	0.1/0.1	2/2	1/1	3/5	110/110
merge_week_casualties	0.2/0.2	2/2	1/1	3/2	90/100
merge_week_vehicles	0.2/0.1	2/2	1/1	2/6	40/140

4 实验对比分析

4.1 实验环境

本文实验的个人电脑, CPU: AMD Ryzen 2600X

Six-Core Processor@3.60 GHz, 内存为 16 GB, 开发环境为 python 3.5 语言的 PyCharm 集成开发工具, 使用 skit-learn 提供的 GBRT 模型。

4.2 预测模型性能评价指标

性能评价指标误差率公式如下: 本文使用均方根对数误差 (rmsle) 和决定系数 (R-square) 来衡量模型的拟合能力。均方根对数误差取值越小, 模型的拟合性能越好。决定系数的值越接近 1, 变量对预测值的解释能力越强。

均方根对数误差和决定系数公式分别为:

$$rmsle = \sqrt{\frac{1}{n \sum_{i=1}^n (\log(Y_0 + 1) - \log(Y_p + 1))^2}} \quad (8)$$

$$R\text{-square} = 1 - \frac{\sum_{i=1}^n (Y_0 - Y_p)^2}{\sum_{i=1}^n (Y_0 - Y_{\text{mean}})^2} \quad (9)$$

式中, Y_0 表示真实预测目标值; Y_p 表示模型预测目标值; Y_{mean} 表示真实预测目标值的平均数。

4.3 实验结果及分析

对上述 30 组数据, 本文采用训练集与测试集 7:3 的比例进行划分, 再使用 GBRT 模型对训练集进行拟合, 最后对测试集的预测性能进行分析。

对比实验为比较离散特征标签映射中的空值在两类填充方法下的实验结果。表 5 为模型在零值填充和均值填充方法下的测试集实验结果。

表 5 不同建模方法在测试集上预测结果表

建模方法	零值填充		比较结果	均值填充	
	rmsle	R-square		rmsle	R-square
one_by_one_accident	0.010 694 4	0.989 643 6	<	0.009 400 1	0.990 108 2
one_by_one_casualties	0.076 180 1	0.142 487 8	<	0.069 511 2	0.177 686 4
one_by_one_vehicles	0.056 437 0	0.302 941 7	<	0.055 705 5	0.318 687 7
last_week_accident	0.002 954 9	0.999 589 9	>	0.003 012 2	0.999 588 6
last_week_casualties	0.019 512 6	0.906 438 4	>	0.023 288 0	0.889 549 4
last_week_vehicles	0.018 403 9	0.944 819 6	<	0.016 416 4	0.958 028 6
last_year_accident	0.005 764 7	0.999 830 0	<	0.007 508 6	0.999 861 5
last_year_casualties	0.011 052 8	0.999 984 6	<	0.010 696 4	0.999 340 0
last_year_vehicles	0.033 843 5	0.998 134 4	<	0.027 991 2	0.998 747 2
merge_year_accident	0.007 009 0	0.999 965 4	>	0.009 347 4	0.999 854 4
merge_year_casualties	0.024 341 1	0.997 904 2	<	0.013 775 0	0.999 091 9
merge_year_vehicles	0.033 320 1	0.998 114 0	<	0.033 062 0	0.997 947 4
merge_week_accident	0.003 047 0	0.999 618 1	>	0.003 068 3	0.999 578 0
merge_week_casualties	0.027 697 0	0.851 847 8	<	0.018 820 9	0.944 924 2
merge_week_vehicles	0.038 087 2	0.926 162 4	<	0.023 322 3	0.896 847 1

表5中的实验结果显示, one_by_one 类型数据使用均值填空的方法整体好于零值填充方法。Last 和 merge 类型数据中均值填充方法的模型效果较好, 因此本文使用均值填充方法处理离散特征标签映射中的空值。

表5中3组预测目标的实验结果显示, 事故数的预测精度整体比死亡人数及涉事的车辆数的预测效果明显要高, rmsle 误差更小, R-square 的值更接近1, 变量对预测值的解释能力强。说明模型更容易拟合到交通事故的发生频率, 但表征交通事故危害程度的死亡人数和涉事车辆数更难预测。

比较不同建模方法的预测结果, 本文提出的 last_period 和 merge_period 方法比传统的 one_by_one 建模方法预测精度要高。其中传统建模方法在死亡人数和涉事车辆数的预测误差分别为 0.069 5 和 0.055 7, R-square 的值为 0.177 6 和 0.318 6, 说明传统建模方法在死亡人数和车辆数的预测能力较差。last_week 建模方法在事故数和涉事车辆数的预测结果最佳, last_year 建模方法对死亡人数的预测结果最佳。merge_period 所考虑的因素更加全面, 但实验结果却没有获得最佳的预测结果, 本文考虑, 该方法增加的特征表征是不同时间的数据, 特征类别存在冗余。

5 结束语

本文挖掘了数据中的时间关系进行建模, 提出基于时间序列关系的 GBRT 的交通事故预测模型。较传统方法在预测精度上有一定的提升, 模型对道路交通安全水平的趋势具有很好的拟合能力。交通管理部门在制定决策、人员调度的过程中能从本文工作中得到有益的参考信息。另一方面, 本文提出的时序建模方法可以在相似建模问题上进行推广, 为同类型的预测工作提供了一种新的建模思路。

进一步的工作, 将测试月、季度等更多类别的时间序列关系和更多的组合方式的 merge_period 建模方法; 将测试更大数据量下, merge_period 建模方法的预测效果。

参 考 文 献

- [1] United Nations. Transforming our world: The 2030 agenda for sustainable development[EB/OL]. [2019-01-08]. <https://sustainabledevelopment.un.org/post2015/transformingourworld>.
- [2] DENG J L. Control problems of grey systems[J]. Systems & Control Letters, 1982, 1(5): 288-294.
- [3] JUNUS N W M, ISMAIL M T. Modelling road accidents: An approach using structural time series[C]//Statistics and Operational Research International Conference. Sarawak, Malaysia: [s.n.], 2014: 228-238.
- [4] PARVAREH M, KARIMI A, REZAEI S, et al. Assessment and prediction of road accident injuries trend using time-series models in Kurdistan[J]. Burns & Trauma, 2018, 6(1): 55-62.
- [5] EFENDI R, DERIS M M. Non-probabilistic inverse fuzzy model in time series forecasting[J]. International Journal of Uncertainty Fuzziness and Knowledge-Based Systems, 2018, 26(5): 855-873.
- [6] IHUEZE C C, ONWURAH U O. Road traffic accidents prediction modelling: An analysis of Anambra State, Nigeria[J]. Accident Analysis and Prevention, 2018, 112: 21-29.
- [7] FOROUTAGHE M D, MOGHADDAM A M, FAKOOR V. Time trends in gender-specific incidence rates of road traffic injuries in Iran[J]. PloS One, 2019, 14(5): e0216462.
- [8] SUN Y, SHAO C, JI X, et al. Urban traffic accident time series prediction model based on combination of ARIMA and information granulation SVR[J]. Journal of Tsinghua University (Science and Technology), 2014, 54(3): 348-353, 359.
- [9] TONGYUAN H, YUE W. Forecasting model of urban traffic accidents based on Grey Model-GM(1,1)[C]//Second Workshop on Digital Media and Its Application in Museum & Heritage. [S.l.]: IEEE, 2008, DOI: 10.1109/DMMH.2007.81.
- [10] HOSSE R S, BECKER U, MANZ H. Grey systems theory time series prediction applied to road traffic safety in Germany[J]. Ifac Papersonline, 2016, 49(3): 231-236.
- [11] LIU S B, WU C W. Road traffic accident forecast based on optimized grey verhulst model[C]//Proceedings of the 2016 Joint International Information Technology, Mechanical and Electronic Engineering. [S.l.]: [s.n.], 2016, 59: 546-551.
- [12] 赵玲, 许宏科. 基于灰色加权马尔可夫 SCGM(1,1)c 的交通事故预测[J]. 计算机工程与应用, 2012, 48(31): 11-15, 145.
ZHAO Ling, XU Hong-ke. Traffic accident prediction based on gray weighted Markov SCGM (1, 1)c[J]. Computer Engineering and Application, 2012, 48(31): 11-15, 145.
- [13] 赵玲, 许宏科, 程鸿亮. 基于最优加权组合模型的道路交通事故预测[J]. 计算机工程与应用, 2013, 49(24): 11-15.
ZHAO Ling, XU Hong-ke, CHENG Hong-liang. Road traffic accidents prediction based on optimal weighted combined model[J]. Computer Engineering and Applications, 2013, 49(24): 11-15.
- [14] HE M, GUO X C. The application of BP neural network principal component analysis in the forecasting the road traffic accident[C]//ICICTA: 2009 Second International Conference on Intelligent Computation Technology and Automation, Vol I. [S.l.]: IEEE, 2009: 107-111.
- [15] SHEN J, ZHENG C, WANG T, et al. Analysis on the

- algorithm and reliability of traffic accident forecast[C]// Proceedings of the 2nd International Conference on Modelling and Simulation. [S.l.]: IEEE Computer Society, 2009: 11-16.
- [16] 胡立伟, 张婷, 郭凤香, 等. 基于灰色 BP 神经网络的道路交通事故车型分担率预测及其预防策略研究[J]. 武汉理工大学学报(交通科学与工程版), 2018, 42(3): 388-392, 397.
HU Li-wei, ZHANG Ting, GUO Feng-xiang, et al. Traffic accident split rate of vehicle types prediction based on gray BP neural network and prevention strategies study[J]. Journal of Wuhan University of Technology (Transportation Science & Engineering), 2018, 42(3): 388-392, 397.
- [17] FRIEDMAN J H. Greedy function approximation: A gradient boosting machine[J]. The Annals of Statistics, 2001, 29(5): 1189-1232.
- [18] 李航. 统计学习方法[M]. 北京: 清华大学出版社, 2012: 21-35.
LI Hang. Statistical learning methods[M]. Beijing: Tsinghua University Press, 2012: 21-35.
- [19] HAUER E. On prediction in road safety[J]. Safety Science, 2010, 48(9): 1111-1122.
- 编辑 漆蓉
-
- (上接第 608 页)
- [3] SUMIO Y, SHI I, TETSUO M, et al. A study of visual fatigue and visual comfort for 3d hdtv/hdtv images[J]. Displays, 2002, 23(4): 191-201.
- [4] OSTBERG. Accommodation and visual fatigue in display work[J]. Displays, 2015, 2(2): 81-85.
- [5] CHO H, KANG M K, YOON K J, et al. Feasibility study for visual discomfort assessment on stereo images using EEG[C]//International Conference on 3D Imaging (IC3D). [S.l.]: IEEE, 2012, 1-6.
- [6] ZUO Bo-chao, LIU Yue, GUO Mei, et al. EEG-based assessment of stereoscopic 3D visual fatigue caused by vergence accommodation conflict[J]. Journal of Display Technology, 2015, 11(12): 1076-1083.
- [7] ALEXANDER B. Thickness: Cross-sectional areas and depth of invasion in the prognosis of cutaneous melanoma[J]. Annals of Surgery, 1970, 172(5): 902-908.
- [8] MASAKI E, TAKAGIRO N, FUMIO O. Repeated vergence adaptation causes the decline of visual functions in watching stereoscopic television[J]. Journal of Display Technology, 2005, 1(2): 328-340.
- [9] JEREMY F, LEONARD P, FABIEN L, et al. Assessing the zone of comfort in stereoscopic displays using EEG[C]// 32nd Annual ACM Conference on Human Factors in Computing Systems. Toronto, Canada: ACM, 2014, 2041-2046.
- [10] HSU B W, WANG M J. Evaluating the effectiveness of using electroencephalogram power indices to measure visual fatigue[J]. Perceptual and Motor Skills, 2013, 116(1): 235-252.
- [11] DU S P, MASIA B, HU S M, et al. A metric of visual comfort for stereoscopic motion[J]. ACM Transactions on Graphics, 2013, 32(6): 1-9.
- [12] LI W, HE Q C, FAN X M, et al. Evaluation of driver fatigue on two channels of EEG data[J]. Neuroscience Letters, 2012, 506(2): 235-239.
- [13] GE S, SH Y H, WANG R M. Sinusoidal signal assisted multivariate empirical mode decomposition for brain-computer interfaces[J]. IEEE Journal of Biomedical and Health Informatics, 2018, 22(5): 1373-1384.
- [14] LESLIE G U, JAMES V H. What and where in the human brain[J]. Current Opinion in Neurobiology, 1994, 4(2): 157-165.
- [15] 孙伟鹏. 基于 EEG 的 3D 显示中的立体深度运动认知研究[D]. 天津: 天津大学, 2018.
SUN Wei-peng. Research on stereoscopic deep motion cognition in 3D display based on EEG[D]. Tianjin: Tianjin University, 2018.
- [16] ALICE R, ZITA M, GABOR B, et al. Visual pathways serving motion detection in the mammalian brain[J]. Sensors, 2010, 10(4): 3218-3242.
- 编辑 刘飞阳