基于纵向时间序列的快速路交通事件检测算法

牛世峰¹, 姜桂艳^{1,2}, 李红伟¹, 姜卉¹

(1. 吉林大学 交通学院, 130022 长春; 2. 吉林大学 汽车动态模拟国家重点实验室, 130022 长春, jianggy@jlu.edu.cn)

摘要: 为了提高快速路交通事件检测算法的效率, 减少交通事件对快速路交通流的影响, 在提出交通参数数据纵向时间序列定义的基础上, 重新界定了异常交通状态的概念, 分析了异常交通状态与交通事件之间的关系, 利用增益放大原理设计了交通状态变异指数和以此为基础的交通事件检测算法, 在确定交通事件位置的同时, 给出事件的空间影响范围, 并以某城市快速路的实际交通数据为基础进行了对比分析. 结果表明, 所提出的交通事件检测算法的检测效果明显优于对比的经典算法, 且具有更好的鲁棒性.

关键词: 快速路; 交通事件; 异常交通状态; 自动检测

中图分类号: U491.2

文献标志码: A

文章编号: 0367-6234(2011)02-0144-05

Automated detection algorithm for traffic incident in urban expressway based on lengthways time series of traffic parameters

NIU Shi-feng¹, JIANG Gui-yan^{1,2}, LI Hong-wei¹, JIANG Hui¹

(1. Transportation and Traffic College, Jilin University, 130022 Changchun, China; 2. State Key Laboratory of Automotive Dynamic Simulation, Jilin University, 130022 Changchun, China, jianggy@jlu.edu.cn)

Abstract: In order to improve the efficiency of traffic incident detection algorithm in urban expressway and reduce the impact of incidents, basing on proposing the definition of lengthways time series of traffic parameters and defining abnormal traffic statuses clearly, the relation between abnormal traffic statuses and traffic incident is analyzed, the traffic status variability index is constructed using gain amplification principle, then automated detection algorithms for the traffic incident is designed. This method can not only detect the location of traffic incident but also the incidence of traffic incident, the result show that detection effect and robustness of this algorithms is better than classical algorithms.

Key words: urban expressway; traffic incident; abnormal traffic status; automatic detection

快速路作为城市交通的主干道, 在整个城市交通系统中占有重要的地位, 然而, 随着交通需求的不断增长, 交通事件频繁发生^[1]. 研究一种适合快速路的交通事件自动检测算法 (automated incident detection algorithms, AID) 对于快速展开救援、及时疏导交通拥挤具有重要意义.

自 20 世纪 60 年代以来, 发达国家对 AID 算法进行了持续研究, 取得了一系列有意义的成果,

如加利福尼亚算法^[2]、标准偏差算法^[3]、双指数平滑算法^[4]、贝叶斯算法^[5]、动态模型算法^[6]、McMaster 算法^[7]、低通滤波算法^[8]以及人工智能算法^[9-10]等. 从使用效果方面看, 已有成果存在的问题主要包括误警率较高、检测时间偏长、鲁棒性较低和难以检测引起交通数据渐变的交通事件.

本文将从分析动态交通数据的特性入手, 重新界定异常交通状态的概念及其与交通事件的关系, 运用放大原理设计基于纵向时间序列的快速路交通事件自动检测算法 (AID based on lengthways time series, LTS-AID), 并对其检测效果和鲁棒性进行对比分析.

收稿日期: 2009-09-18.

基金项目: 国家高技术研究发展计划 (2007AA11Z245);
高等学校博士学科点专项基金 (20070183129).

作者简介: 牛世峰 (1982—), 男, 博士研究生;
姜桂艳 (1964—), 女, 教授, 博士生导师.

1 异常交通状态与交通事件的关系

根据组织方式不同,本文将交通参数数据时间序列分为两类,第1类是交通参数数据的横向时间序列,第2类是交通参数数据的纵向时间序列.前者是指特定地点的交通参数数据按照一天24小时的先后顺序排列的数据序列;后者是指同一地点同一时刻的交通参数数据按照每周特定日期的先后顺序排列的数据序列.这两类数据序列如图1所示.

图1 交通量数据时间序列

在通常情况下,特定空间位置的交通参数数据序列具有长期趋势性、短期现势性和随机波动性.其中,长期趋势性是指同一空间位置、同一时刻的同一交通参数在相邻各周内相同日期(星期一、星期二……)的横向时间序列具有相似性的特点;短期现势性是指交通参数数据的横向时间序列受各种突发事件的影响,在特定时间段内出现偏离长期趋势的现象;随机波动性则是指交通参数时间序列随机波动的现象.在本文中,将异常交通状态定义为在相同的时空条件下,道路交通流参数数据的横向时间序列偏离长期趋势,并表现出明显短期现势性的现象.

根据偏离长期趋势的快慢,异常交通状态可以分为渐变性异常交通状态和突变性异常交通状态.前者通常是由天气、道路、交通管制条件和出行需求等因素的变化所导致;后者主要是指由交通事故、故障停车和货物散落以及交通流运行环境突然变化等原因所导致.为了叙述方便,在本文中称引起突变性异常交通状态的交通事件为A类交通事件,引起渐变性异常交通状态的交通事件为B类交通事件.如图2所示,在正常交通状态和异常交通状态下,交通流的运行质量都可能表现为顺畅、阻滞和拥堵3种不同的拥挤程度.在非高峰期发生的严重交通事件也可能不导致交通拥挤,而在高峰期发生的轻微交通事件却可能导致严重的交通拥堵.在通常情况下,一个交通事件可以导致较大范围内的多个交通检测器数据异常.其中,位于事发地点上游的路段因受到压缩波的影响而表现得相对拥挤,位于事发地点下游的

路段由于受到扩展波的影响而表现得相对顺畅.因此,在本文中,将交通事件检测分解为异常交通状态识别和交通事件位置确定两个部分.

图2 各类交通状态之间的关系

2 LTS - AID 算法设计

2.1 LTS - AID 算法的思想

交通事件和异常交通状态具有高度相关性,可以通过识别异常交通状态来检测交通事件的存在.由异常交通状态的定义可知,交通参数数据的长期趋势性表征了交通流的正常状态,其短期现势性表征了交通流的异常状态,所以只要将某时刻的实际交通状态与该时刻的正常交通状态进行比较,就可判断交通流是否表现出短期现势性,即交通流是否处于异常状态.因此,如果能够设计合适的正常交通状态的表达方法以及交通状态变异程度的量测指标,当交通状态变异程度超过一定阈值时,则可认为该地点在该时刻出现了异常交通状态.

2.2 正常交通状态的表达方法

在正常交通状态下,交通参数纵向时间序列具有良好的稳定性,可据此建立正常交通状态下交通参数的估计方法,以获取每天正常交通状态下每个时刻各交通参数的估计值.

在交通流理论中,交通参数可分为地点交通参数和区间交通参数两类,前者主要包括特定地点的流量、速度、时间占有率等,后者包括行程速度、行程时间.各交通参数均可从不同角度、不同程度上体现交通流的运行状态,因此,综合运用多个交通参数可以更好地刻画交通流的运行状态.

交通数据序列的长期趋势性体现了交通流的正常运行状态,而这种趋势性受到经济、技术以及社会等因素的影响,将随着时间的推移逐渐发生变化.因此,本文以纵向时间序列的历史数据为基础对正常状态下的交通参数数据进行估计.由于

交通参数数据的纵向时间序列具有良好的稳定性,可以通过移动平均法、指数平滑法、求和自回归移动平均法等经典预测方法进行估计,考虑到计算的简便性,本文以移动平均法为例进行说明.

正常交通状态下交通参数的估计值为

$$\hat{x}_{jk}^p(t) = \frac{1}{n} \sum_{k=j-n}^{j-1} x_{ik}^p(t). \quad (1)$$

式中: $\hat{x}_{jk}^p(t)$ 为第 j 周、第 k 天、 p 地点、 t 时刻正常交通状态下交通参数 x 的估计值, x 可以是流量、地点速度、时间占有率、区间速度等, $x_{ik}^p(t)$ 为第 i 周、第 k 天、 p 地点、 t 时刻正常交通状态下交通参数 x 的历史交通数据; t 为检测器上传数据时间间隔的结束时刻, j 为纵向时间序列数据的第 j 周,或者当前周; p 为采集地点交通参数数据的检测器所在位置编号或者采集行程时间数据的路段编号, k 为周内的特定日期,如星期一,或星期二、星期三等, n 为纵向时间序列的时间窗口尺度.

上述方法以纵向时间序列的历史数据为基础,历史数据的质量将直接决定估计的准确性,选取遵照以下原则:1) 历史数据为没有发生交通事件时的实测数据,最好选取全天都没有发生交通事件时的实测数据;2) 历史数据与估计目标处在相似的时空条件下,一般选择相同一周内相同日期、相同检测器或相同路段的实测数据;3) 应选择距离目前最近的实测数据;4) 选取个数应适中,不宜太多也不宜太少,一般选取 4 ~ 8 个为宜.

为了适应交通数据序列长期趋势的渐变过程,提高正常交通状态下交通参数估计值的精度,需要对历史数据进行持续更新. 由于在实际应用中很难获得距离当前较近的多个全天都没有发生交通事件的历史数据,本文提出了如下的历史数据更新方法:1) 根据历史数据选取原则获得初始历史数据序列;2) 如果当前日前特定地点的交通流在当前时刻处于正常状态,则将距离当前日期最远的该时刻的历史数据删除,并把当前时刻交通流参数数据计入历史数据序列,否则不更新历史数据序列;3) 重复执行第 2 步操作,直到当日所有地点 24 h 内各时刻的历史数据更新完毕.

在获得更新后历史数据的基础上,利用式 (1) 可以在下一天开始之前通过离线计算一次性获得全天正常交通状态下交通参数的估计值.

2.3 交通状态变异指数设计

当发生交通事件时,事件上游的交通流运行状态会发生异常变化,流量和速度将减小,占有率将增大. 为了体现实时交通状态和正常交通流状态的差异,本文提出了交通状态变异指数的概念.

交通状态变异指数应包含所有可能获得的、具有时空可比性的交通参数. 以感应线圈采集的数据为例,本文利用增益放大原理设计的交通状态变异指数为

$$I^p(t) = \frac{30 \cdot \hat{q}^p(t) \cdot \hat{v}^p(t) \cdot o^p(t)^2}{q^p(t) \cdot v^p(t) \cdot \delta^p(t)^2 + 0.0001}. \quad (2)$$

式中: $I^p(t)$ 为 t 时刻 p 地点的交通状态变异指数; $q^p(t)$ 为 t 时刻 p 地点的实测流量; $v^p(t)$ 为 t 时刻 p 地点的实测速度; $o^p(t)$ 为 t 时刻 p 地点的实测占有率; $\hat{q}^p(t)$ 为基于纵向时间序列估计的正常状态下 t 时刻 p 地点的交通流量; $\hat{v}^p(t)$ 为基于纵向时间序列估计的正常状态下 t 时刻 p 地点的速度; $\delta^p(t)$ 为基于纵向时间序列估计的正常状态下 t 时刻 p 地点的占有率.

当交通流处于异常状态时,交通状态变异指数会发生明显的变化,如图 3 所示.

图3 城市快速路特定地点的交通状态变异指数

2.4 LTS - AID 算法设计

在获得正常交通状态下各交通参数估计值和实时交通参数的基础上,首先计算当前时刻交通状态变异指数,并将其与特定阈值进行比较,即可初步判断该地点在当前时刻是否处于异常交通状态. 在此基础上,为了降低误警率,通过多次确认对异常交通状态进行判别. 最后,运用交通事件判别算法确定交通事件的发生位置.

基于上述基本思想,本文设计的 LST - AID 算法流程为:1) 获得各交通参数纵向时间序列的历史数据,并对正常交通状态下各参数进行估计;2) 获得交通流各参数的实测数据,计算当前时刻的交通状态变异指数,并确定是否出现异常交通状态;3) 为了降低误警率,对异常交通状态检测结果进行多次确认,不同的情况需要采用不同的确认方法;4) 确定交通事件的发生位置,判别公式为

$$u^p(t) = \begin{cases} 1, & z^p(t) = 1 \text{ 且 } z^{p-1}(t) = 0; \\ 0, & \text{其他.} \end{cases} \quad (3)$$

式中 $u^p(t)$ 为 t 时刻 p 地点的下游路段是否发生

交通事件,1 代表发生事件,0 代表未发生事件, $z^p(t)$ 为 t 时刻 p 地点的检测器数据是否处于异常交通状态,1 代表处于异常交通状态,0 代表处于正常交通状态。

LTS - AID 算法的具体流程如图 4 所示。

图 4 LTS - AID 算法流程图

3 实证分析

3.1 数据来源

本文的验证数据来源于某城市长约 10 km 快速路上的所有主线和匝道检测器,包括 2008 年 9 月到 10 月间连续 5 个星期一的交通流参数数据,其时间尺度为 20 s. 该路段共包括 24 个主线检测截面,88 个主线检测器,30 个匝道检测截面,60 个匝道检测器. 在所获得的交通流数据中,运用人工手段识别出了 60 个 A 类交通事件,包括 10 个主线交通事件, 50

个匝道交通事件,24 个 B 类交通事件。

3.2 交通事件检测效果对比分析

作为一种经典 AID 算法,加州算法的应用效果已经在实际应用中得到充分证明,本文选取加州算法作为 LTS - AID 算法的对比算法,对交通事件的检测效果和算法的鲁棒性进行对比分析。

目前,常用的交通事件检测算法评价指标主要有判别率 (identification rate, IR)、误判率 (false identification rate, FIR) 和平均判别时间 (mean time to identification, MTTI). 由于实际数据的限制,无法获得交通事件发生的准确时间,在对比分析时只能采用 IR、FIR 和平均判别时间差 3 个指标对 AID 算法进行比较. 其中平均判别时间差包括不同算法之间的平均判别时间差和不同时间尺度下的平均判别时间差两个具体指标. 前者主要用于对比 LTS - AID 算法与加州算法的检测效果,而后者主要用于对比 LTS - AID 算法在不同时间尺度下的检测效果. 这两个指标分别定义为

$$CMTTI_s = \frac{\sum_{p=1}^u (t_L^p - t_c^p)}{u}; \quad (4)$$

$$CMTTI_j = \frac{\sum_{p=1}^u (t_L^p - t_{L,5\min}^p)}{u}. \quad (5)$$

式中: $CMTTI_s$ 为不同 AID 算法的平均判别时间差, t_L^p 为 LTS - AID 算法检测到第 p 个事件的时刻, t_c^p 为加州算法检测到第 p 个事件的时刻, u 为交通事件个数; $CMTTI_j$ 为不同时间尺度的平均判别时间差, $t_{L,5\min}^p$ 为 LTS - AID 算法在时间尺度为 5 min 时检测到第 p 个事件的时刻。

LTS - AID 算法和加州算法在 3 种时间尺度下对交通事件的检测效果如表 1 和表 2 所示。

表 1 交通事件检测效果对比分析表

事件种类	t/s	阈值		IR/%		FIR/%	
		LTS - AID	加州	LTS - AID	加州	LTS - AID	加州
A 类	20	130	28.5 0.6 10.11	100	100	0.24	1.16
	60	90	30 0.79 10.02	100	100	0.19	0.31
	300	60	17.1 10.35 10.15	85	100	0.64	2.57
B 类	60	5	—	79	0	0.54	0
	300	5	—	83	0	0.20	0
	60	5	—	93	0	0.12	0

表 2 平均检测时间对比分析表

事件种类	t/s	$CMTTI_s/s$	$MTTI_j/s$
A 类	20	70	-750
	60	-380	-390
	300	-350	0
B 类	20	—	-630
	60	—	-350
	300	—	0

对 LTS - AID 算法与加州算法在 3 种时间尺度下的效果进行对比分析,可以得到如下结论: 1) LTS - AID 算法可以检测到 B 类交通事件,而加州算法不能; 2) 从对 A 类交通事件的检测效果来看, LTS - AID 算法的判别率与加州算法相差不多,而误判率和平均判别时间明显优于加州算法,

其总体检测效果优于加州算法。

对 LTS - AID 算法在 3 种时间尺度下的检测效果进行对比分析,得到如下结论:1)从对 A 类交通事件的检测效果看,LTS - AID 算法在时间尺度为 1 min 的情况下判别率最高,误判率最低,平均检测时间略低于在时间尺度为 20 s 的情况,考虑到算法在不同时间尺度下的计算量问题,本文认为该算法在时间尺度为 1 min 的情况下检测效果最好;2)从对 B 类交通事件检测效果看,算法在时间尺度为 5 min 的情况下判别率最高,误判率最低,但是平均判别时间最长.考虑到 B 类交通事件变化较和缓,持续时间较短的 B 类事件对交通影响较小,可以不对其进行检测,其对平均判别时间要求较低,因此本文所提出的算法在时间尺度为 5 min 的情况下检测效果最好。

为了评价本文所提出算法的鲁棒性,对上述两种 AID 算法进行敏感性分析.主要对比分析 LTS - AID 算法和加州算法的判别率和误判率相对于检测阈值的敏感性,结果如图 5、6 所示。

图 5 判别率对阈值的敏感性

图 6 误判率对阈值的敏感性

对两种 AID 算法的判别率和误判率对阈值敏感性进行对比分析,得到如下结论:1)从两种 AID 算法的判别率对阈值敏感性看,在阈值上升过程中,加州算法的判别率在 3 种时间尺度下的下降率明显大于 LTS - AID 算法. LTS - AID 算法判别率对阈值的敏感性明显小于加州算法.2)从两种 AID 算法的误判率对阈值敏感性看,加州算法误判率在阈值下降过程中的上升率和在在阈值上升过程中的下降率在 3 种时间尺度下都明显大于 LTS - AID 算法. LTS - AID 算法误判率对阈值

的敏感性明显小于加州算法.综上所述,LTS - AID 算法的鲁棒性明显优于加州算法。

4 结 论

1)基于增益放大理论构建了 LTS - AID 算法,利用某城市快速路实测数据的对比分析表明该算法可以同时检测 A 类和 B 类两类交通事件,而加州算法无法检测 B 类交通事件。

2)LTS - AID 算法对 A 类交通事件检测率较高,误判率较低,而且具有良好的鲁棒性。

3)对 LTS - AID 算法在 20 s、1 min 和 5 min 3 种时间尺度下的检测效果进行对比分析,给出算法的最优检测时间尺度。

参考文献:

[1] 刘洋,冯树民,陈洪仁. 城市快速道路系统规划的交通预测方法研究[J]. 哈尔滨工业大学学报, 2004,36(3):348 - 351.

[2] 姜桂艳. 道路交通状态判别技术与应用[M]. 北京:人民交通出版社,2004:163 - 165.

[3] DUDEK C L, MESSER C J, NUCKLES N B. Incident detection on urban freeways[C]//Transportation Research Board. Washington D C: TRB, 1974, 12 - 24.

[4] PETTY K F, OSTLAND M, KWON J, et al. A new methodology for evaluating incident detection algorithms[J]. Transportation Research Part C: Emerging Technologies, 2002, 10(3):189 - 204.

[5] LEVIN M, KRAUSE G M. Incident detection: a bayesian approach[J]. Transportation Research Record,1978, 682: 52 - 58.

[6] WILLISKY S, CHOW E, GERSHWIN S, et al. Dynamic model-based techniques for the detection of incident on freeways[J]. IEEE Trans Autom Control, 1980, 25: 347 - 360.

[7] PERSAUD B N, HALL F L. Catastrophe theory and patterns in 30-second freeway traffic data-implication for incident detection[J]. Transportation Research Part A, 1990, 23(2): 103 - 113.

[8] STEPHANEDES Y J, CHASSIAKOS A P. Application of filtering techniques for incident detection[J]. Journal of Transportation Engineering,1993, 119 (1):13 - 26.

[9] SRINIVASAN D, SHARMA V, TOH K A. Reduced multivariate polynomial-based neural network for automated traffic incident detection[J]. Neural Networks, 2008, 21: 484 - 492.

[10] CHEN S Y, WANG W. Decision tree learning for freeway automatic incident detection[J]. Expert Systems with Applications, 2009, 36: 4101 - 4105.

(编辑 魏希柱)