

基于光流特征描述子的站点限流设施优化方法研究

王泽胜,董宝田,罗文慧

(北京交通大学交通运输学院,北京 100044)

摘要:针对现有限流设施与策略智能化程度不高,灵活性较差的问题,提出一种基于光流特征描述子的站点限流设施优化方法。首先,根据枢纽内场景特点,设置感兴趣区域(region of interest, ROI),从而降低后续操作的计算量,提高算法的执行效率;然后,在建立光流特征描述子的基础上,对图片序列进行特征分析;最后,基于人群聚集特征,对经典单分类支持向量机进行调整,并实现超负荷状态的检测。实验结果表明,提出的方法能够对站台人群状态进行准确检测,有效增强限流设施的自动化水平,为轨道交通站点客流组织与管理提供数据支撑和理论依据。

关键词:智能交通;状态检测;特征描述子;地铁限流;单分类支持向量机

中图分类号: U298.2 **文献标识码:** A doi: 10.3969/j.issn.0253-2778.2018.04.010

引用格式: 王泽胜,董宝田,罗文慧. 基于光流特征描述子的站点限流设施优化方法研究[J]. 中国科学技术大学学报,2018,48(4):341-346.

WANG Zesheng, DONG Baotian, LUO Wenhui, et al. Research on flow-limiting facility optimization in rail transit stations based on optical feature descriptor [J]. Journal of University of Science and Technology of China, 2018, 48(4):341-346.

Research on flow-limiting facility optimization in rail transit stations based on optical feature descriptor

WANG Zesheng, DONG Baotian, LUO Wenhui

(School of Traffic and Transportation, Beijing Jiaotong University, Beijing 100044, China)

Abstract: To address the problem of low intelligence and flexibility of existing flow limiting facilities, a new optimization method for flow-limiting facilities in rail transit stations based on optical feature descriptors, is proposed. First, the region of interest (ROI) is set according to the scene characteristics of rail transit stations to reduce the computation of subsequent operation. Then, the features of image sequence are analyzed by establishing optical feature descriptors. Finally, the one-class SVM is adjusted according to the clumped features of pedestrians to make condition detection possible. Experimental results demonstrate that the proposed method can detect the overload status accurately, improve the automatic level of flow-limiting facilities effectively, and provides data support and theoretical basis for organization and management of pedestrians in rail transit stations.

Key words: intelligent transportation; condition detection; feature descriptor; subway flow-limiting; one-class SVM

收稿日期: 2018-01-08; 修回日期: 2018-04-11

基金项目: 国家自然基金(61772065)资助。

作者简介: 王泽胜,男,1987 年生,博士生。研究方向:机器学习、计算机视觉、智能交通。E-mail:815345591@163.com

通讯作者: 董宝田,教授,E-mail:btdong@bjtu.edu.cn

0 引言

随着旺盛客流的井喷式增长,轨道交通作为城市交通的重要组成部分,日渐拥堵。这在北京、上海等大城市更是凸显^[1]。城市轨道交通站点多为地下较密闭的空间,短时且集中的大量客流造成的拥挤,易引发踩踏,车门夹人拖行的风险^[2]。为了降低客流拥挤造成的安全隐患,管理人员采取了一系列的措施,其中,限流作为一种切实可行的措施被广泛应用。近年来,限流站点逐渐增多,限流呈现出扩大化和常态化趋势,许多学者在限流管控方面做了研究。现有常态限流方案一般 3 个月更新 1 次(如北京),不能适应实时客流的波动变化,常需要配合现场的指导^[3]。站外限流是一种常用现场指导方法,通常需要地铁工作人员在进站口进行拦截,一批客流进站,根据经验经过一段时间后再允许下一批客流进站。目前北京的劲松、西二旗等一批站点在早晚高峰期就是采用的这种限流方式^[4]。这种方式缺乏规范的标准,难以科学地指导实际管理工作。对此,赵晓旭^[5]通过分析节假日期间广州火车站地铁站客运组织方式和硬件设施,针对性地提出了客流管控优化措施。吴君尚等^[6]分析了上海轨道交通站点站外限流栏杆在突发情况下对疏散效率的影响程度,从而对栏杆的设置进行了相应的优化。

随着计算机视觉技术的发展,运用相关理论和方法对车站系统进行分析,提高交通信息化以及自动化水平,引起了许多学者的重视。通过密度检测和安全等级划分来形成限流决策^[7-9]是一种常用方法,然而拥挤、踩踏、跌倒等多出现在客流密度非常大,行人间遮挡率很高的情况,该种场景中密度统计常常失效。Wang 等^[10]通过分析图像的全局光流特征来进行特定场景检测。Li 等^[11]对图像的最大光流投影进行统计分析,来检测异常情况。Yi 等^[12]利用稀疏表示方法来检测异常场景。Chen 等^[13]在时间维度上利用邻域模糊均值的方法,将仿真场景与真实场景进行对比来分析拥挤状态。Zhao 等^[14]对视频图像的时空特征进行线性编码来分析场景异常。Wu 等^[15]利用子空间学习的方法对视频场景进行分析。Xian 等^[16]通过分析真实监控场景的底层特征来进行事件检测。该类方法在一定程度上解决了遮挡的问题,但大多需要进行编码和设置复杂的参数。

本文提出一种基于光流特征描述子的限流设施优化方法。该方法以光流稠密运动估计为基础,建立

特征描述子,从而避免了直接进行密度检测;对场景进行感兴趣区域提取,并针对地铁站台环境特征建立 3 帧光流特征描述子;通过动态实时的地铁超负荷状态检测,实现及时有效的现场限流控制。

1 基于光流特征的运动信息获取

图像序列的光流场涵盖了像素点的运动信息和表面结构信息,结合了物体的静态与动态时空域特征。光流分析法首先根据光约束条件,计算出相邻两幅图像之间的水平方向光流矢量 u 和竖直方向光流矢量 v 。对于图像上的任意一个运动的像素点,经过时间 Δt 后,其位置坐标从 (x, y) 变化为 $(x + \Delta x, y + \Delta y)$,根据亮度守恒假设,则有

$$I(x, y, t) = I(x + \Delta x, y + \Delta y, t + \Delta t) \quad (1)$$

等式两侧分别为前后两个时刻对应位置像素点的灰度值。将等式右侧进行一阶泰勒展开,同时令二阶无穷小为 0,则有

$$I_x u + I_y v + I_t = 0 \quad (2)$$

对于公式(2), u 和 v 存在无穷多个解使得等式成立。为了得到唯一解,引入 Horn-Schunck 算法^[17]来构造约束条件,即要求 $\nabla^2 u + \nabla^2 v$ 应尽可能小,则有

$$u^{n+1} = \overline{u^n} - \overline{I_x} [\overline{I_x} \overline{u^n} + \overline{I_y} \overline{v^n} + I_t] / (\alpha^2 + \overline{I_x}^2 + \overline{I_y}^2) \quad (3)$$

$$v^{n+1} = \overline{v^n} - \overline{I_y} [\overline{I_x} \overline{u^n} + \overline{I_y} \overline{v^n} + I_t] / (\alpha^2 + \overline{I_x}^2 + \overline{I_y}^2) \quad (4)$$

2 光流特征描述子的建立

光流特征的提取,是像素级操作,会耗费大量的时间。为了提高算法效率,首先对图像进行感兴趣区域(ROI)提取。由于超负荷状态主要关注客流在站台的聚集程度,列车本身和图像帧中记录的站内墙壁等区域与客流状态的关系较小,因此将该部分剔除掉,不会影响算法的精度。站台区域由于有客流存在,会产生大量的运动信息,图像帧中的对应区域则会记录对应的光流信息,因此将站台区域视为感兴趣区域。参照文献[18]中的方法,提取运动区域,并对运动区域执行并操作,计算合并结果的最小连接矩阵,将其定位为站台区,从而减小下一步特征学习的计算量。

为了有效降低图像在平移、旋转、缩放中产生错误估计的可能性,提高特征描述的稳定性,将图像分

割为若干个小的区块。在各区块中,将2维极坐标的极角取值范围划分为若干个角度区间,按照光流速度矢量的方向将矢量分类统计到各区间,每个区间都具有其自身的光点能量(optical flow kinetic energy, OFKE),各光点能量构成统计直方图,作为对应区块的光流特征描述子(optical flow feature descriptor, OFFD),从而直观地反映目标区域的主要运动趋势和混杂程度,在提供运动方向的同时反映区域运动的激烈程度。区域内特征描述子记为 H ,将 $0^\circ \sim 360^\circ$ 划分的区间个数记为 P ,则有

$$H = \{h(p)\}_{p=1,2,\dots,P} \quad (5)$$

$$h(p) = f(\text{scale}(\theta, p)) \quad (6)$$

式中, $h(p)$ 表示区间 p 的光点运动能量; $\text{scale}(\theta, p)$ 为某个像素点的光流角度与角度划分区间的对应关系判别函数; f 为某角度区间内复合条件的光流的统计方法。

$$\text{scale}(\theta, p) = \begin{cases} 1, & \theta \text{ 在对应的角度区间内} \\ 0, & \text{其他} \end{cases} \quad (7)$$

为了减小斑点和高亮噪声的影响,本文取该角度区间内光流值的均值作为对应角度区间的光点运动能量值,则有对应关系 f 运算如下:

$$f(O) = \frac{\sum_{i=1}^l O_i}{l} \quad (8)$$

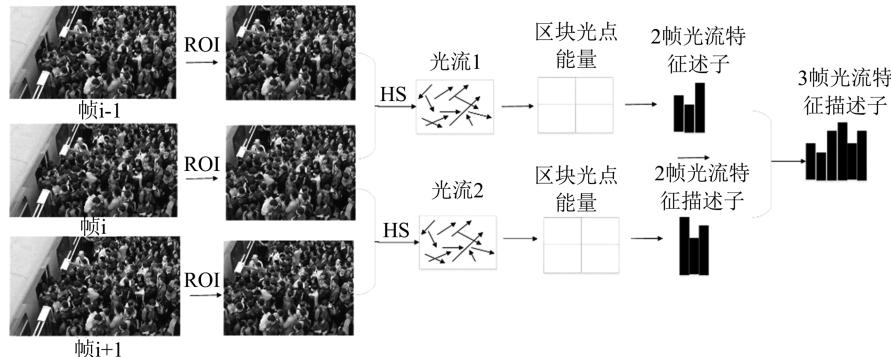


图1 光流特征描述子提取流程

Fig.1 The flowchart of optical feature descriptor extraction

3 One-class SVM

支持向量机(support vector machine, SVM)在分类问题上具有很好的效果。异常事件检测中,样本数据大多存在不平衡问题,甚至仅保有某一类样本,此时,传统的 SVM 会失效,而单分类支持向量机(One-class SVM)更适合解决该类问题。其核心思想是通过训练获取具有最大分类间隔的超平面,从而

式中, O 为某个角度区间内各光流组成的集合, l 为对应角度区间有效光流的数量。经过观察发现,在地铁环境中,当客流密度非常大时,平行于列车行驶方向的光流震荡性会明显增强。因此,在传统 2 帧光流统计方法的基础上,提出基于 3 帧连续图像的综合光流统计方法,从而更有效地提取客流的震荡特性,提高检测的精度。由于在实时系统中,2 帧光流会产生一系列光流特征描述子序列,而 3 帧光流中,只在 2 帧光流特征描述子的基础上做简单相加,因此在光流信息计算和特征描述子提取部分两种方法处理时间基本相同;在检测部分,由于增加了输入数据的维度,所以对检测速度产生一定的影响,但并不十分明显,实验中平均增加了约 0.17 秒;在训练阶段,需要对大量的训练集图片样本进行一次性统一处理,训练的时间从最初 2 帧光流的 7 个小时增加为约 9 个小时,有了明显的增加。实际的应用中,由于会采用事先训练,将分类器保存下来并载入检测系统的方式,所以训练阶段的时间增长,基本不会对最终检测模块的算法时间效率产生影响。光流特征描述子提取流程如图 1 所示。

将单分类问题转化为 2 分类问题,该方法的原理如图 2 所示,将原点设置为正常样本,然后求解最优分类超平面,最大化分隔开原点和异常样本的距离。

不同于常见的异常检测,本文解决的车站超负荷状态的数据特征明显,且能够获取大量的该状态样本序列,正常场景的序列反而变化多样,因此本文将超负荷状态作为分类集,即正样本。超负荷状态检测分为两个部分:模型训练部分和检测与识别部分。

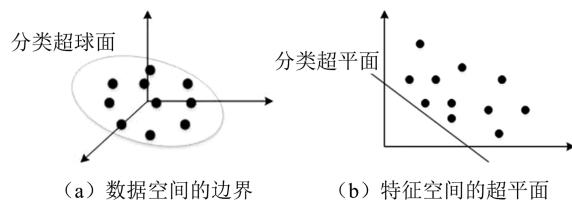


图 2 数据空间与特征空间对比图

Fig.2 The comparison of data space and feature space

模型训练阶段,给定训练样本集,并求解出决策函数,即分类超平面;在检测与识别阶段,将测试样本数据输入由第 1 阶段获得决策函数,从而得出判定结果。测试集样本序列的判定规则如下:如果输入图片序列的光点能量特征落在边界之内,则该序列被视为超负荷状态;否则,视为非超负荷状态。数据空间与特征空间之间的转换,需要通过核函数进行映射,本文选用径向基核函数(radial basis function, RBF)作为核函数,它具有更宽的收敛域,能够逼近任意的非线性函数,解析数据间复杂的规律,高效地根据样本集特性构建特性模型。RBF 描述如下:

$$k(\vec{x}_i, \vec{y}_i) = \exp(-\|\vec{x}_i - \vec{y}_i\|^2 / \sigma^2) \quad (9)$$

式中, \vec{x}_i 为样本序列中的点, \vec{y}_i 为核函数的中心; σ 是函数的宽度参数, 控制函数的作用范围。超平面计算公式如下:

$$\begin{aligned} \min_{w, \alpha, d} & \left(\frac{1}{2} \|w\|^2 + \frac{1}{np} \sum_i^n \alpha_i - d \right) \\ \text{s.t. } & d - (w \cdot k(x_i)) \leq \alpha_i, \alpha_i \geq 0, \forall i = 1, \dots, n \end{aligned} \quad (10)$$

式中, w 是高维空间分类超平面的法向量, α 是松弛变量, d 是异类样本中心及其空间点到分类超平面的距离, n 是样本集总量, p 为平滑因子。采用拉格朗日对偶求解计算得到 w 和 d , 从而得到决策函

数为

$$f(x) = \operatorname{sgn}((w \cdot k(x)) - d) \quad (11)$$

任意给定的特征向量 x , 计算其相应的 $f(x)$ 值, 如果 $f(x) \geq 0$, 则该特征向量代表的样本为正样本, 否则为负样本。

4 超负荷状态检测

对于一个给定的场景,会产生一组训练样本序列 $[f_1, \dots, f_t]$, 通过这个序列,可以获得超负荷状态下的光流特征,该特征反映了相应场景的客流行行为,整个计算过程如下。

Step1 分别计算一组图像序列中每两个相邻图片各像素的光流值。

$$[f_i, f_{i+1}]_{a \times b} \xrightarrow{HS} [OS_1, \dots, OS_{a \cdot b-1}, OS_{a \cdot b}] \quad (12)$$

式中, $a \times b$ 是图片的尺寸(以像素为单位), OS_i 为第 i 个像素的光流值。

Step2 对获得的 2 维光流值矩阵进行分块,计算各角度区间的光点能量,并最终获得的整幅图像的光流特征描述子集合。

$$[OS_1, \dots, OS_{a \cdot b}] \xrightarrow{\text{特征描述子生成}} [H_1, \dots, H_P] \quad (13)$$

式中, H 为光流特征描述子, P 为每一幅光流图像中所划分的区块的数量。

Step3 基于 Step2 中计算得到的结果,采用单分类支持向量机来计算样本序列的最优边界,从而建立特征空间的分类超平面。

Step4 基于 Step3 训练得到的模型结果,对测试样本序列进行检测。

超负荷状态检测算法流程,如图 3 所示。

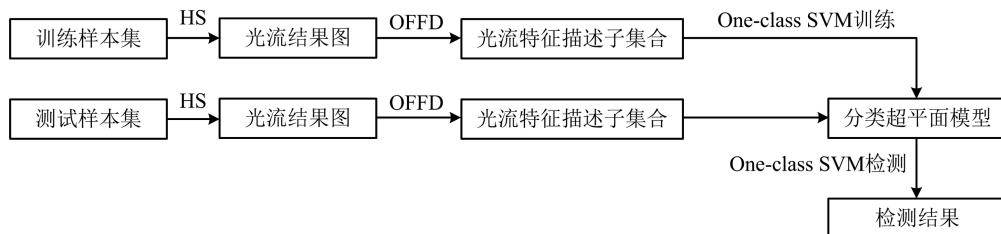


图 3 超负荷状态检测算法流程图

Fig.3 The flowchart of proposed overload status detection algorithm

5 实验结果与分析

为了验证算法的合理性和有效性,取北京市西二旗地铁站的视频数据作为样本,进行测试实验,统

计检测结果,并与文献[10]中经典光流直方图方法(histogram of optical flow orientation, HOFO)和文献[11]中光流投影最值方法(histogram maximal optical flow projection, HMOFP)进行对比。西二旗

站是地铁13号线与昌平线的换乘站,在高峰时段客流量非常大,是采用限流策略的一个典型交通枢纽。视频数据采集时间为在2017年4月26日的上午6点至中午11点,图像尺寸为 632×352 (以像素为单位),在实验中被划分为30个块,将 360° 划分为20个角度区间,即每一个特征描述子由20个特征矩构成,每一组特征有600个关键值。在日常的交通枢纽



图4 典型场景

Fig.4 typical scenes

图4(a)为上午6:15左右的样本,客流密度较小,记为场景1;图4(b)为上午7:15左右的样本,客流密度较大但并不十分拥挤,记为场景2;7点以后,客流逐渐进入高峰状态,图4(c),为上午7:45左右客流高峰的样本,客流拥挤严重并造成上下车存在推搡,甚至屏蔽门多次无法关闭的场景,记为场景3,场景3中的客流状态被视为超负荷状态。取场景3中的2000幅图片作为训练样本集,进行训练并获得分类器。测试样本集的构成如下:前两个场景,均视为正常状态并分别取300帧,共600帧作为负样本;在场景3中取600帧作为正样本,并随机均分为2份,从而保证在测试样本中,正负样本的数量相同。将测试集的3种场景4份样本按照场景1,场景3,场景2,场景3的顺序进行存储,并依次对1200幅样本图像进行测试。图5为4份样本的检测结果,图6为最终的统计结果。



图5 各个场景检测结果

Fig.5 Detection results in different scenes

如图5和6所示,算法在各场景中检测准确率均较高,但随着客流密度的增大,拥挤程度的不断增加,算法效果受到一定的影响。如表1所示,本文方法与对比方法,随着干扰因素的增加,检测准确率均有所下降,但各场景中,本文方法的检测准确率均较

中,客流状态会随着时间的推移呈现出潮汐式的更替:初期客流较少;进入上班出行早高峰时间,客流拥挤程度逐渐增加,并呈现出超负荷状态;随着时间的推移,客流逐渐减少;在晚高峰时间来临时客流进入下一轮变化。这种变化中大致呈现如图4所示的3种常见场景。

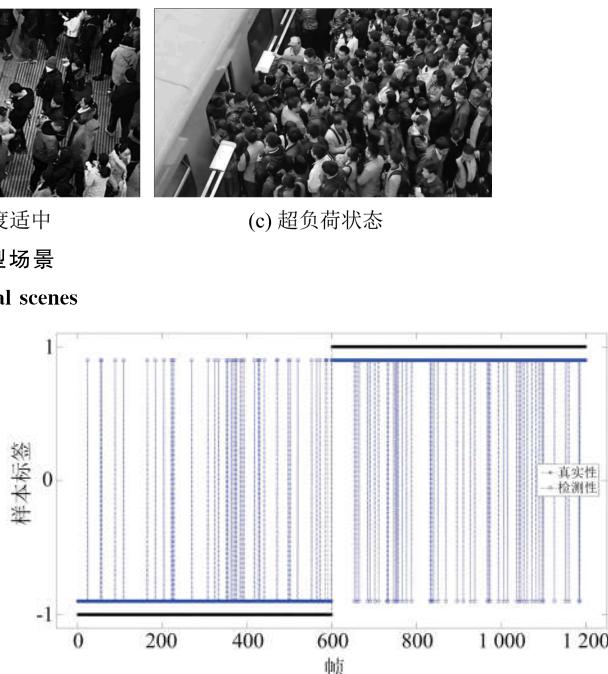


图6 检测统计结果

Fig.6 The statistical detection result

高,检测效果更好,并且在拥挤程度较高的场景中,本文提出算法的优势更加明显。

表1 各个场景检测准确率对比
Tab.1 Comparison of detection precision in different scenes

	场景1	场景2	场景3
HOFO	87%	82%	78%
HMOFP	94%	89%	84%
本文方法	96%	92%	91%

6 结论

如何保证交通安全,特别是行人密集的枢纽的运营安全,一直是备受关注的问题。鉴于传统方法的局限性,本文提出了基于光流特征描述子的超负荷状态检测方法,通过引入机器学习技术,对枢纽内多帧光流进行特征分析,有效解决了枢纽内客流密度大、遮挡严重、图像非高清情况下,密度无法测算,客流状态难以准确估计的问题,提高了站点限流设施

的自动化水平,为交通运营安全提供了保障.

参考文献(References)

- [1] 尹来盛, 张明丽. 我国超大城市交通拥堵及其治理对策研究—以广州市为例[J]. 城市观察, 2017, 1(2): 73-84.
- [2] 胡亚楠. 地铁屏蔽门、车门夹人成因分析及防范措施研究[J]. 科技创新与应用, 2017, (10): 82-83.
- [3] 朱正玲. 城市轨道交通网络高峰时段常态限流问题研究[J]. 铁路通信信号工程技术, 2017, 14(02): 71-74.
- [4] 肖慧雅, 姚丽亚, 曾伟, 等. 城市轨道交通站点限流设施优化方法研究[J]. 道路交通与安全, 2016, 16(6): 46-50.
- [5] 赵晓旭. 广州地铁换乘车站节假日客流组织与管控研究[J]. 科技资讯, 2015, 13(6): 211-212.
- [6] 吴君尚, 张碧纯, 胡漫, 等. 轨交车站站外限流栏杆设置方案优化研究[J]. 地下工程与隧道, 2013, (1): 38-41.
- [7] 张月坤. 北京地铁客流密度自动检测技术研究[J]. 中国铁路, 2017, (4): 96-100.
- [8] 张月坤. 北京地铁视频监测客流告警阈值的针对性和准确性研究[J]. 中国铁路, 2017, (5): 78-81.
- [9] 赵保锋, 邹晓磊, 屈晓宜. 基于仿真的城市轨道交通站台客流滞留分级预警方法[J]. 城市轨道交通研究, 2017, 20(9): 107-110, 115.
- [10] WANG T, SNOUSSI H. Detection of abnormal visual events via global optical flow orientation histogram[J]. IEEE Transactions on Information Forensics and Security, 2014, 9(6): 988-998.
- [11] LI A, MIAO Z J, CEN Y G, et al. Histogram of maximal optical flow projection for abnormal events detection in crowded scenes[J]. International Journal of Distributed Sensor Networks, 2015, 11(6): 1-11.
- [12] YI Y G, LI X H, ZHAO R, et al. A constrained sparse representation approach for video anomaly detection[C]// Advanced Information Management, Communicates, Electronic and Automation Control Conference. Xi'an, China: IEEE Press, 2016: 45-49.
- [13] CHEN L X, GUO H W, WU X Y, et al. Detecting anomaly based on time dependence for large scenes [C]// 2016 IEEE International Conference on Information and Automation. Piscataway, NJ, USA: IEEE Press, 2016: 1376-1381.
- [14] ZHAO Y, ZHOU L, FU K, et al. Abnormal event detection using spatio-temporal feature and nonnegative locality-constrained linear coding [C]// International Conference on Image Processing. Piscataway, USA: IEEE Press, 2016: 3354-3358.
- [15] WU F, JING X Y, LIU Q, et al. Large-scale image recognition based on parallel kernel supervised and semi-supervised subspace learning [J]. Neural Computing and Applications, 2017, 28(3): 483-498.
- [16] XIAN Y, RONG X, YANG X, et al. Evaluation of Low-Level Features for Real-World Surveillance Event Detection [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2017, 27(3): 624-634.
- [17] 张强, 王正林. 精通 Matlab 图像处理[M]. 电子工业出版社, 2009.
- [18] 王爱丽, 董宝田, 王泽胜, 等. 融合光流速度场自适应背景建模的交通场景中运动行人检测算法[J]. 长安大学学报, 2015, 1, 35(S): 184-188.