



(12) 发明专利

(10) 授权公告号 CN 113037783 B

(45) 授权公告日 2021.08.06

(21) 申请号 202110561988.9

(22) 申请日 2021.05.24

(65) 同一申请的已公布的文献号
申请公布号 CN 113037783 A

(43) 申请公布日 2021.06.25

(73) 专利权人 中南大学
地址 410083 湖南省长沙市岳麓区麓山南路932号

(72) 发明人 郭克华 陶泽 奎晓燕 赵颖
胡斌

(74) 专利代理机构 长沙正奇专利事务所有限责任公司 43113
代理人 王娟 马强

(51) Int. Cl.

H04L 29/06 (2006.01)

(56) 对比文件

CN 109902640 A, 2019.06.18

CN 111914873 A, 2020.11.10

CN 111932027 A, 2020.11.13

US 2019041842 A1, 2019.02.07

审查员 王莉

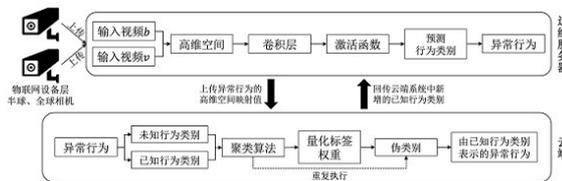
权利要求书2页 说明书7页 附图1页

(54) 发明名称

一种异常行为检测方法及系统

(57) 摘要

本发明公开了一种异常行为检测方法及系统,在使用深度学习技术的基础上,综合边缘服务器、云端的体系结构优势,保证了边缘服务器高响应、低延迟。边缘服务器上传开放场景出现的异常行为至云端和下载云端系统中新增的行为类别。云端通过主动标签学习将异常行为由已知行为进行表示。由此构建了完善的边缘服务器和云端的异常行为检测闭环,边缘服务器无需与云端保持长连接,减轻了网络传输压力,异常行为的行为类别支持更新也更加符合开放场景下的异常行为检测需要。



1. 一种异常行为检测方法,其特征在于,包括以下步骤:

在边缘服务器上执行包括以下步骤的操作:

1) 输入测试行为类别的视频序列**b**、已知行为类别的视频序列**v**;分别将两个序列拆分为若干个完整的子行为序列**b** = { b_1, b_2, \dots, b_n }、**v** = { v_1, v_2, \dots, v_m };其中,**n**表示视频序列**b**可拆分的子行为序列数量,**m**表示视频序列**v**可拆分的子行为序列数量, b_n 表示视频序列**b**的第**n**个子行为序列, v_m 表示视频序列**v**的第**m**个子行为序列;

2) 将子行为序列依次输入高维空间 ϕ 中进行映射,表示为**B** = $\phi(b)$ 、**V** = $\phi(v)$,并获得**B**与**V**的相似度矩阵,**B**、**V**分别为子行为序列**b**、**v**的高维空间映射值;

3) 通过相似度矩阵的最小化距离寻找出**B**与**V**的行为循环对齐点 B_k ,输入 B_k 与视频序列**b**到卷积层,获得所述测试行为类别的视频序列的特征向量,并将该特征向量输入Softmax激活函数,得到视频序列**b**的预测行为类别;若在当前已知行为类别中无法找到该预测行为类别时,则将视频序列**b**视为异常行为序列;

还包括在云端执行包括以下步骤的操作:

A) 获取各类已知行为类别的视频序列的高维空间映射平均值 \bar{B}_t 与**B**的距离**d** = { d_1, d_2, \dots, d_t },其中,**t**为当前已知行为类别的类别数量, \bar{B}_t 为第**t**类类别的已知行为类别的视频序列的高维空间映射值的平均值;

B) 若**d**中最小值 d_{min} 小于或者等于距离阈值,将第 min 类行为类别作为视频序列**b**的预测行为类别,并将该预测行为类别与视频序列**b**保存至已知行为类别中,结束;若**d**中最小值 d_{min} 大于距离阈值,则将视频序列**b**的预测行为类别设置为未知行为类别,并将该未知行为类别与视频序列**b**保存在未知行为类别中,进入步骤C); min 的取值范围为 $1 \sim t$;

C) 将已知行为类别和未知行为类别中视频序列聚类为**C** = { $c_1, \dots, c_j, \dots, c_k$ },其中**k**表示聚类后的行为类别的类别数量, c_j 表示聚类后的第**j**类已知行为类别;对于未知行为类别的视频序列,根据其于已知行为类别的视频序列的高维空间映射距离**d** = { $d_1, \dots, d_j, \dots, d_k$ }设置量化类别权重**W**;将未知行为类别量化为各类已知行为类别乘以量化类别权重**W**的集合,将量化后的未知行为类别称为伪类别;

D) 若相同伪类别的视频序列能再一次聚类到同一簇类别中,则将该伪类别作为视频序列的预测行为类别,并将该预测行为类别与视频序列保存至已知行为类别中。

2. 根据权利要求1所述的异常行为检测方法,其特征在于,所述距离阈值设置为0.3。

3. 根据权利要求1所述的异常行为检测方法,其特征在于,**W** = { $w_1, \dots, w_j, \dots, w_k$ },其中, $w_j = d_j / \bar{d}$,其中, $\bar{d} = d_{max}$,且当 $d_{max} \geq 2.0$ 时,设置 $\bar{d} = 2.0$ 。

4. 根据权利要求1~3之一所述的异常行为检测方法,其特征在于,循环对齐点 B_k 的计算公式为: $B_k = \arg \min \|\sum_{l=1}^m a_l v_l - B_i\|$,其中 $k \in [1, m]$, $B_i \in B$;

$$a_l = \frac{e^{-\|B_i - v_l\|^2}}{\sum_{i=1}^n \sum_{l=1}^m e^{-\|B_i - v_l\|^2}}, l \in [1, m], i \in [1, n], V_l = \phi(v_l), B_i = \phi(b_i), V_l, B_i \text{ 分别为子行为序列 } v_l, b_i \text{ 的高维空间映射值。}$$

为序列 v_l, b_i 的高维空间映射值。

5. 一种异常行为检测系统,其特征在于,包括计算机设备;所述计算机设备被配置或编

程为用于执行权利要求1~4之一所述方法的步骤。

6. 根据权利要求5所述的异常行为检测系统,其特征在于,所述边缘服务器输出异常行为序列的高维空间映射值 B 至所述云端;所述云端还被配置为用于执行权利要求2~4之一所述方法的步骤。

7. 根据权利要求6所述的异常行为检测系统,其特征在于,所述云端还用于将已知行为类别传送至所述边缘服务器。

一种异常行为检测方法及系统

技术领域

[0001] 本发明涉及深度学习领域,具体是一种异常行为检测方法及系统。

背景技术

[0002] 智慧城市的快速发展,监控设备和5G高速网络的大规模部署,造成了大量的安防视频数据呈指数增长,更严重的是,此类监视视频数据还包含异常行为数据,严重危害城市的安全。因此,如何有效地管理,分析和挖掘公共场所的异常行为已成为业界最关注的问题之一^[1]。过去,视频监控系统依赖大量的人工参与,并由于工作人员疲劳工作等原因,极易造成漏检、误检,无法保证异常行为检测的实时动态分析,使得对监控视频内容的自动化分析成为一项迫切需求。随着人工智能技术的发展,准确、有效地分析和挖掘视频数据中的行为模式已经成为可能。若将人工智能技术用于异常行为检测,不但可以减轻工作人员的工作压力,还能提高工作效率和异常检测准确率,为保障公共场所安全保驾护航。

[0003] 现有的异常行为检测研究主要是综合深度学习与云服务技术,它们为大规模的部署终端视频监视设备提供出色的数据分析、存储能力^{[2][3]}。但云端需要长时间保持与终端视频监控设备的连接,且云端在实时收集大量动态视频数据时,容易造成通信网络的堵塞^[4],给实时视频数据的传输带来了极大的隐患,导致视频数据中的异常行为无法及时识别^[5]。尽管当前边缘计算被视为云服务的一种有效补充,它通过将大量需要实时处理的视频数据迁移到网络边缘的本地服务器进行处理,无需长时间与云端保持连接,降低了网络传输的巨大压力,但它并不适用于大量计算和巨额存储消耗的深度学习模型^[6]。

[0004] 现有的异常行为检测系统通常是基于预设数量的行为类别数据进行监督学习,忽略了开放场景下异常行为的多样性和不可预测性,行为类别的更新主要依赖于技术人员定期地添加新行为类别至系统中,需要耗费巨大的人力成本去搜集行为数据。当此类系统无法识别某类行为类别时,只能等待下一次行为类别更新^[7]才能识别某类行为类别。并且,此类系统的监督学习过程整段输入完整的行为类别视频,但由于视频中往往重复会出现某种行为动作,粗粒度的输入导致最终获得预测行为类别仍不够准确^[8],识别结果也只能粗略地描述异常类型,无法显示异常行为的原因,其中包括行为发生时间及行为类型等^{[9][10]}。

[0005] 具体来说,异常行为检测系统^[11]尽管作为边缘服务器与云端结合的先进技术,但该系统存在以下技术缺陷:1)系统获得的输入视频序列的预测行为类别、循环一致点不作为卷积层输入,导致异常行为识别准确率低;2)该系统运行过程中完全依赖于系统内部的自动调整,未添加外界的人工可干预参数,进一步导致异常行为识别准确率低;3)该系统云端最终提供给边缘服务器的是主动学习训练后的异常行为检测模型,边缘服务器需要替换之前的异常行为检测模型,操作便利性差。

[0006] 综上,一方面,现有的异常行为检测由于网络传输延迟、基于预设数量的行为类别数据进行监督学习,无法满足开放场景下的异常行为检测需求。另一方面,异常行为检测系统^[11]尽管同时使用到边缘服务器、云端和主动学习过程,但由于其仍存在大量的技术缺陷,导致其在开放场景下异常行为识别准确率、操作便利性上效果不佳。因此,如何在保证

高响应、低延迟的情况下,操作人员可调整异常行为检测系统的运行状态,异常行为检测系统又能够自我监督地主动学习未知行为类别,并符合开放场景下的检测需求是亟待解决的技术问题。

发明内容

[0007] 本发明所要解决的技术问题是,针对现有技术不足,提供一种异常行为检测方法及其系统,提高异常行为检测精度。

[0008] 为解决上述技术问题,本发明所采用的技术方案是:一种异常行为检测方法,包括以下步骤:

[0009] 1) 输入测试行为类别的视频序列***b***、已知行为类别的视频序列***v***;分别将两个序列拆分为若干个完整的子行为序列 **$b = \{b_1, b_2, \dots, b_n\}$** 、 **$v = \{v_1, v_2, \dots, v_m\}$** ;其中,***n***表示视频序列***b***可拆分的子行为序列数量,***m***表示视频序列***v***可拆分的子行为序列数量,***b_n***表示视频序列***b***的第***n***个子行为序列,***v_m***表示视频序列***v***的第***m***个子行为序列;

[0010] 2) 将子行为序列依次输入高维空间 **ϕ** 中进行映射,表示为 **$B = \phi(b)$** 、 **$V = \phi(v)$** ,并获得***B***与***V***的相似度矩阵,***B***、***V***分别为子行为序列***b***、***v***的高维空间映射值;

[0011] 3) 通过相似度矩阵的最小化距离寻找出***B***与***V***的行为循环对齐点***B_k***,输入***B_k***与视频序列***b***到卷积层,获得所述测试行为类别的视频序列的特征向量,并将该特征向量输入Softmax激活函数,得到视频序列***b***的预测行为类别;若在当前已知行为类别中无法找到该预测行为类别时,则将视频序列***b***视为异常行为序列。

[0012] 与现有技术相比,本发明基于行为循环对齐点表征行为类型的特征向量,能充分反映不同行为类别之间的差异,使得获得的预测行为类别更加准确,从而提高了异常行为检测精度。因为不同行为类别在高维空间 **ϕ** 映射,进一步放大了不同行为类别的数据差异性,使得原本数据相互耦合的不同行为类别是可划分的,因此,由本发明的方法获得的行为循环对齐点***B_k***能够准确表征当前行为类别的数据信息。同时,本发明将***B_k***与视频序列***b***输入到卷积层,获得测试行为类别的视频序列的特征向量,该特征向量具备了行为类别之间差异信息,能够准确表征视频序列***b***与视频序列***v***的关联,极大地提高了异常行为识别的准确性,即提高了异常行为的检测精度。

[0013] 本发明的方法还包括以下步骤(即主动学习过程):

[0014] A) 获取各类已知行为类别的视频序列的高维空间映射平均值 **\bar{B}_t** 与***B***的距离 **$d = \{d_1, d_2, \dots, d_t\}$** ,其中,***t***为当前已知行为类别的类别数量, **\bar{B}_t** 为第***t***类类别的已知行为类别的视频序列的高维空间映射值的平均值;

[0015] B) 若***d***中最小值 **d_{min}** 小于或者等于距离阈值,将第***min***类行为类别作为视频序列***b***的预测行为类别,并将该预测行为类别与视频序列***b***保存至已知行为类别中,结束;***min***的取值范围为 **$1 \sim t$** ;若***d***中最小值 **d_{min}** 大于距离阈值,则将视频序列***b***的预测行为类别设置为未知行为类别,并将该未知行为类别与视频序列***b***保存在未知行为类别中,进入步骤C);

[0016] C) 将已知行为类别和未知行为类别中视频序列聚类为 **$C = \{c_1, \dots, c_j, \dots, c_k\}$** ,其中***k***表示聚类后的行为类别的类别数量,***c_j***表示聚类后的第***j***类已知行为类别;对于未知行为类别的视频序列,根据其于已知行为类别的视频序列的高维空间映射距离 **$d = \{d_1, \dots, d_j, \dots, d_k\}$** 设

置量化类别权重 $W = \{w_1, \dots, w_j, \dots, w_k\}$; 将未知行为类别量化为各类已知行为类别乘以量化类别权重 W 的集合, 将量化后的未知行为类别称为伪类别;

[0017] D) 若相同伪类别的视频序列能再一次聚类到同一簇类别 C 中, 则将该伪类别作为视频序列的预测行为类别, 并将该预测行为类别与视频序列保存至已知行为类别中。

[0018] 与现有技术相比, 本发明无需额外补充已知行为类别至系统中, 通过主动标签学习将未知行为类别表示为当前系统中已知行为类别的集合, 实现了行为类别间的自我补充, 降低了搜集行为数据的人力成本, 更加适用于开放场景下异常行为检测的使用需求, 并且通过实验证明, 本发明产生的预测行为类别能够有效表示未知行为类别的数据信息。产生上述优势的原因是本发明构建了完整的行为表示过程, 包括: 1) 将异常行为类别转换为未知行为类别; 2) 通过未知行为类别与系统中已知行为类别的高维空间 ϕ 映射距离 d 获得各类行为类别间的量化类别权重 W ; 3) 依据量化类别权重 W 表示预测行为类别; 4) 将预测行为类别新增到已知行为类别中使用。本发明获得最后由已知行为类别表示的视频序列的过程施加了人工可干预参数 (距离阈值), 使得已知行为类别表示过程更加准确, 进而提高了异常行为检测系统的异常行为识别准确率。人工可干预参数使得系统运行过程是操作人员可人为干预的, 操作人员可依据当前异常行为检测系统的状态 (如: 预测输入的预测行为类别的结果是否准确, 当前系统内的已知行为类别、未知行为类别的数量比例) 动态地调整人工可干预参数, 使系统处于预期运行状态。同时, 本发明只需要更新已知行为类别, 无需更新异常行为检测模型, 使用时直接将已知行为类别导入边缘服务器即可, 无需重新配置本地环境, 因此极大地提高了操作便利性。

[0019] 本发明中, 所述距离阈值设置为 0.3。该距离阈值的设置能够充分地将未知行为类别与已知行为类别划分开, 降低二者之间数据信息的耦合程度。

[0020] 本发明中, $w_j = d_j / \bar{d}$, 其中, $\bar{d} = d_{max}$, 且当 $d_{max} \geq 2.0$ 时, 设置 $\bar{d} = 2.0$ 。 d_{max} 是 d 中的最大值。 d_{max} 值的设置是一种平均性的考虑结果, 它是实验过程中调整的最佳值, d_{max} 值的设置能够避免部分未知行为类别与已知行为类别的差异性过大, 导致量化类别权重 W 值整体偏小, 进而影响表示后的预测行为类别的有效性。

[0021] 循环对齐点 B_k 的计算公式为: $B_k = \arg \min \|\sum_{l=1}^m a_l v_l - B_i\|$, 其中, $k \in [1, m]$, $B_i \in B$

$$; a_l = \frac{e^{-\|B_i - v_l\|^2}}{\sum_{i=1}^n \sum_{l=1}^m e^{-\|B_i - v_l\|^2}}, l \in [1, m], i \in [1, n], V_l = \phi(v_l), B_i = \phi(b_i), V_l, B_i \text{ 分别为子}$$

行为序列 v_l, b_i 的高维空间映射值。循环对齐点 B_k 由输入干个子行为类别的高维空间 ϕ 映射获得。与整段的输入完整的行为类别对比, 本发明考虑到了完整的行为类别序列中可能重复出现某行为类别动作, 精细划分能够解耦原本数据相互耦合的行为类别, 并且上述计算公式中使用到了每一项子行为类别的高维空间 ϕ 映射值, 使得获得循环对齐点 B_k 更加准确。

[0022] 相应的, 本发明还提供了一种异常行为检测系统, 其包括计算机设备; 所述计算机设备被配置或编程为用于执行上述方法的步骤。

[0023] 本发明的异常行为检测系统中, 所述计算机设备包括边缘服务器和云端; 所述边缘服务器被配置为用于执行以下步骤:

[0024] 1) 输入测试行为类别的视频序列 b 、已知行为类别的视频序列 v ; 分别将两个序列

拆分为若干个完整的子行为序列 $\mathbf{b} = \{b_1, b_2, \dots, b_n\}$ 、 $\mathbf{v} = \{v_1, v_2, \dots, v_m\}$ ；其中， n 表示视频序列 \mathbf{b} 可拆分的子行为序列数量， m 表示视频序列 \mathbf{v} 可拆分的子行为序列数量， b_n 表示视频序列 \mathbf{b} 的第 n 个子行为序列， v_m 表示视频序列 \mathbf{v} 的第 m 个子行为序列；

[0025] 2) 将子行为序列依次输入高维空间 ϕ 中进行映射，表示为 $\mathbf{B} = \phi(\mathbf{b})$ 、 $\mathbf{V} = \phi(\mathbf{v})$ ，并获得 \mathbf{B} 与 \mathbf{V} 的相似度矩阵， \mathbf{B} 、 \mathbf{V} 分别为子行为序列 \mathbf{b} 、 \mathbf{v} 的高维空间映射值；

[0026] 3) 通过相似度矩阵的最小化距离寻找出 \mathbf{B} 与 \mathbf{V} 的行为循环对齐点 B_k ，输入 B_k 与视频序列 \mathbf{b} 到卷积层，获得所述测试行为类别的视频序列的特征向量，并将该特征向量输入 Softmax 激活函数，得到视频序列 \mathbf{b} 的预测行为类别；若在当前已知行为类别中无法找到该预测行为类别时，则将视频序列 \mathbf{b} 视为异常行为序列。

[0027] 边缘服务器最终输出异常行为序列的高维空间映射值 \mathbf{B} 至所述云端。所述云端被配置为用于执行以下步骤：

[0028] A) 获取各类已知行为类别的视频序列的高维空间映射平均值 \bar{B}_t 与 \mathbf{B} 的距离 $\mathbf{d} = \{d_1, d_2, \dots, d_t\}$ ，其中， t 为当前已知行为类别的类别数量， \bar{B}_t 为第 t 类类别的已知行为类别的视频序列的高维空间映射值的平均值；

[0029] B) 若 \mathbf{d} 中最小值 d_{min} 小于或者等于距离阈值，将第 min 类行为类别作为视频序列 \mathbf{b} 的预测行为类别，并将该预测行为类别与视频序列 \mathbf{b} 保存至已知行为类别中，结束； min 的取值范围为 $1 \sim t$ ；若 \mathbf{d} 最小值 d_{min} 大于距离阈值，则将视频序列 \mathbf{b} 的预测行为类别设置为未知行为类别，并将该未知行为类别与视频序列 \mathbf{b} 保存在未知行为类别中，进入步骤 C)；

[0030] C) 将已知行为类别和未知行为类别中视频序列聚类为 $\mathbf{C} = \{c_1, \dots, c_j, \dots, c_k\}$ ，其中 k 表示聚类后的行为类别的类别数量， c_j 表示聚类后的第 j 类已知行为类别；对于未知行为类别的视频序列，根据其于已知行为类别的视频序列的高维空间映射距离 $\mathbf{d} = \{d_1, \dots, d_j, \dots, d_k\}$ 设置量化类别权重 \mathbf{W} ；将未知行为类别量化为各类已知行为类别乘以量化类别权重 \mathbf{W} 的集合，将量化后的未知行为类别称为伪类别；

[0031] D) 若相同伪类别的视频序列能再一次聚类到同一簇类别 \mathbf{C} 中，则将该伪类别作为视频序列的预测行为类别，并将该预测行为类别与视频序列保存至已知行为类别中。

[0032] 所述云端还用于将已知行为类别传送至所述边缘服务器。

[0033] 本发明中，边缘服务器上传开放场景出现的异常行为至云端和下载云端系统中新增的行为类别。云端通过主动标签学习将异常行为由已知行为进行表示。由此构建了完善的边缘服务器和云端的异常行为检测闭环，边缘服务器无需与云端保持长连接，减轻了网络传输压力，异常行为的行为类别支持更新也更加符合开放场景下的异常行为检测需要。

[0034] 与现有技术相比，本发明所具有的有益效果为：本发明在使用深度学习技术的基础上，综合边缘服务器、云端的体系结构优势，保证了边缘服务器高响应、低延迟。边缘服务器上传开放场景出现的异常行为至云端和下载云端系统中新增的行为类别。云端通过主动标签学习将异常行为由已知行为进行表示。由此构建了完善的边缘服务器和云端的异常行为检测闭环，边缘服务器无需与云端保持长连接，减轻了网络传输压力，异常行为的行为类别支持更新也更加符合开放场景下的异常行为检测需要。实验证明，上述方案增强了异常行为检测算法的异常行为分类准确率，本发明的可行性高，能有效的降低目前视频监控系统的人工参与程度，解决了基于恒定种类的异常行为检测方法在开放场景下的难适用问

题。相对于现有的异常行为检测系统而言,本发明提高了异常行为识别准确率和操作便利性。

附图说明

[0035] 图1为本发明实施例系统架构图。

[0036] 图2为本发明实施例异常行为检测和主动标签学习阶段原理图。

具体实施方式

[0037] 如图1所示,本发明实施例1的体系结构由三部分组成:(1)物联网设备层:半球、全球相机等物联网设备录制实时视频序列,并传输到边缘服务器执行异常行为检测。(2)边缘服务器:边缘服务器对物联网设备层中出现的视频序列进行识别,若当前边缘服务器系统中已知行为类别中。若识别为异常行为,则将该行为数据上传至云端,并等待云端答复。边缘服务器保存云端回传的新增行为类别至边缘服务器系统中,再次执行当前视频序列的异常行为检测,完成行为识别。(3)云端:由于云端具有分布式边缘服务器的全局知识和更强大的计算功能,因此它可以帮助边缘服务器检测异常行为类别数据。具体为,通过主动标签学习将异常行为由当前云端系统中的已知行为类别进行表示,并回传云端系统中新增的已知行为类别至边缘服务器。

[0038] 异常行为检测算法监督训练步骤如下:

[0039] 第一步:输入测试行为类别的视频序列***b***、异常行为检测系统的已知行为类别的视频序列***v***,由于视频序列***b***、***v***中可能会重复出现该行为类别的动作,将依据整个行为序列的总帧数以及完成该行为类别的动作所需帧数,将整个行为序列拆分为若干个完整的子行为序列 **$b = \{b_1, b_2, \dots, b_n\}$** 、 **$v = \{v_1, v_2, \dots, v_m\}$** 。其中,***n***表示视频序列***b***可拆分的子行为序列数量,***m***表示视频序列***v***可拆分的子行为序列数量, **b_n** 表示视频序列***b***的第***n***个子行为序列, **v_m** 表示视频序列***v***的第***m***个子行为序列。

[0040] 第二步:由第一步获得的子行为序列 **$b = \{b_1, b_2, \dots, b_n\}$** 、 **$v = \{v_1, v_2, \dots, v_m\}$** ,将子行为序列依次输入高维空间 **$\phi$** 中进行映射,表示为 **$B = \phi(b)$** 、 **$V = \phi(v)$** ,***B***、***V***分别为子行为序列***b***、***v***的高维空间映射值,并获得***B***与***V***的相似度矩阵 **$a = \{a_1, \dots, a_l, \dots, a_m\}$** ,其中

$$a_l = \frac{e^{-\|B_i - v_l\|^2}}{\sum_{i=1}^n \sum_l^m e^{-\|B_i - v_l\|^2}}, \text{其中 } l \in [1, m], i \in [1, n], v_l \text{ 取值等于 } \phi(v_l), B_i \text{ 取值等于 } \phi(b_i)。$$

[0041] 第三步:由第二步获得的相似度矩阵 **$a = \{a_1, \dots, a_l, \dots, a_m\}$** ,通过相似度矩阵的最小化距离寻找出***B***与***V***的行为循环对齐点 **B_k** ,具体过程为: **$B_k = \arg \min \|\sum_{l=1}^m a_l v_l - B_i\|$** ,其中 **$k \in [1, m]$** , **$i \in [1, n]$** , **$B_i \in B$** 。循环对齐点 **$B_k$** 可以表征视频序列***b***与视频序列***v***的行为类别的相似程度,输入 **B_k** 与视频序列***b***到卷积层获得该测试行为类别的视频序列的特征向量,并将该特征向量输入Softmax激活函数,Softmax激活函数将依据输入与当前已知行为类别的相似程度得到视频序列***b***的预测行为类别。若在当前已知行为类别中无法找到该预测行为类别时,则将视频序列***b***视为异常行为序列,并将其高维空间映射值***B***输出到主动标签学习算法中,等待进一步操作。

[0042] 主动标签学习算法自监督学习步骤如下：

[0043] 第一步：获得测试行为类别的视频序列 b 的高维空间映射值 B 后。比较各类已知行为类别的视频序列的高维空间映射平均值 \bar{B}_t 与 B 的距离 $d = \{d_1, d_2, \dots, d_t\}$ ，其中， t 为当前已知行为类别的类别数量， \bar{B}_t 为第 t 类类别的已知行为类别的视频序列的高维空间映射值的平均值。

[0044] 第二步：若 d 中最小值 d_{min} 小于或者等于距离阈值0.3时，说明测试行为类别与第 min 类的已知行为类别相同。则将第 min 类行为类别作为视频序列 b 的预测行为类别，并将该预测行为类别与视频序列 b 保存至已知行为类别中，此时，主动标签学习算法结束。其中， min 的取值范围为1至 t ，并且距离阈值可人为调整。

[0045] 第三步：若 d 中最小值 d_{min} 大于距离阈值0.3时，说明测试行为类别与各类已知行为类别均不相同。则将视频序列 b 的预测行为类别设置为未知行为类别。并将该未知行为类别与视频序列 b 保存在未知行为类别中。其中， min 的取值范围为1至 t ，并且距离阈值可人为调整。

[0046] 第四步：使用DBSCAN聚类算法将已知行为类别和未知行为类别中视频序列聚类为 $C = \{c_1, \dots, c_j, \dots, c_k\}$ ，其中 k 表示使用DBSCAN聚类后的行为类别的类别数量， c_j 表示聚类后的第 j 类已知行为类别。对于未知行为类别的视频序列，根据其于已知行为类别的视频序列的高维空间映射距离 $d = \{d_1, \dots, d_j, \dots, d_k\}$ 设置量化类别权重 $W = \{w_1, \dots, w_j, \dots, w_k\}$ ，量化类别权重 w_j 等于 d_j 除以 \bar{d} ，其中， \bar{d} 一般等于 d_{max} ，但当 d_{max} 大于或者等于2.0时，将导致部分量化类别权重过小，此时，人为调整 \bar{d} 为2.0。进而，将未知行为类别表示各类已知行为类别乘以量化类别权重 W 的集合，并将量化后的未知行为类别称为伪类别。考虑到伪类别种类仍然十分丰富，因此，需要对伪类别再次执行DBSCAN聚类以进一步减少伪类别种类。

[0047] 第五步：若相同伪类别的视频序列再一次聚类到同一簇类别 C 中，则将该伪类别作为视频序列的预测行为类别，并将该预测行为类别与视频序列一起保存至已知行为类别中。此时，主动标签学习算法结束。综上，主动标签学习算法实现了测试行为类别到已知行为类别的转换，使得当前系统新增了部分的已知行为类别。

[0048] 本发明使用到的参考文献如下：

[0049] [1] Li M, Gao J, Zhao L, and Shen X, “Deep reinforcement learning for collaborative edge computing in vehicular networks,” IEEE Transactions on Cognitive Communications and Networking, 2020, vol. 17, no. 6(4), pp:1122-1135.

[0050] [2] Khan LU, Yaqoob I, Tran NH, Kazmi SA, Dang TN, and Hong CS, “Edge-Computing-Enabled Smart Cities: A Comprehensive Survey,” IEEE Internet of Things Journal, 2020, vol. 7, no. 10, pp:10200-10232.

[0051] [3] W. Shi, J. Cao, Q. Zhang, Y. Li, and L. Xu, “Edge computing: Vision and challenges,” IEEE Internet of Things Journal, 2016, vol. 3, no. 5, pp.637-646.

[0052] [4] S. Y. Nikouei, Y. Chen, S. Song, R. Xu, B.-Y. Choi, and T. R. Faughnan, “Real-time human detection as an edge service enabled by a

lightweight cnn,”arXiv preprint, 2018,arXiv:1805.00330.

[0053] [5] Premsankar G, Di Francesco M, and Taleb T, “Edge computing for the Internet of Things: A case study,” IEEE Internet of Things Journal, 2018, vol. 5, no. 2, pp:1275-84.

[0054] [6] Rafique W, Qi L, Yaqoob I, Imran M, Rasool RU, and Dou W, “Complementing IoT services through software defined networking and edge computing: A comprehensive survey, ” IEEE Communications Surveys & Tutorials, 2020, vol. 26, no. 22(3), pp:1761-804.

[0055] [7] N. Chen, Y. Chen, Y. You, H. Ling, P. Liang, and R. Zimmermann, “Dynamic urban surveillance video stream processing using fog computing,” in Multimedia Big Data (BigMM), 2016 IEEE Second International Conference on. IEEE, 2016, pp:105-112.

[0056] [8] Chen G, Liu P, Liu Z, Tang H, Hong L, Dong J, Conradt J, Knoll A, “NeuroAED: Towards Efficient Abnormal Event Detection in Visual Surveillance With Neuromorphic Vision Sensor,” IEEE Transactions on Information Forensics and Security, 2020, vol. 14, no. 16, pp:923-936.

[0057] [9] R. Xu, S. Y. Nikouei, Y. Chen, E. Blasch, and A. Aved, “Blendmas: A blockchain-enabled decentralized microservices architecture for smart public safety,” arXiv preprint, 2019, arXiv:1902.10567.

[0058] [10] Nakao T, Hanaoka S, Nomura Y, Murata M, Takenaga T, Miki S, Watadani T, Yoshikawa T, Hayashi N, and Abe O, “Unsupervised Deep Anomaly Detection in Chest Radiographs,” Journal of Digital Imaging, 2021, pp:1-10.

[0059] [11] Guo K, Hu B, Ma J, Ren S, Tao Z, and Zhang J, “Toward Anomaly Behavior Detection as an Edge Network Service Using a Dual-Task Interactive Guided Neural Network,” IEEE Internet of Things Journal, 2020.

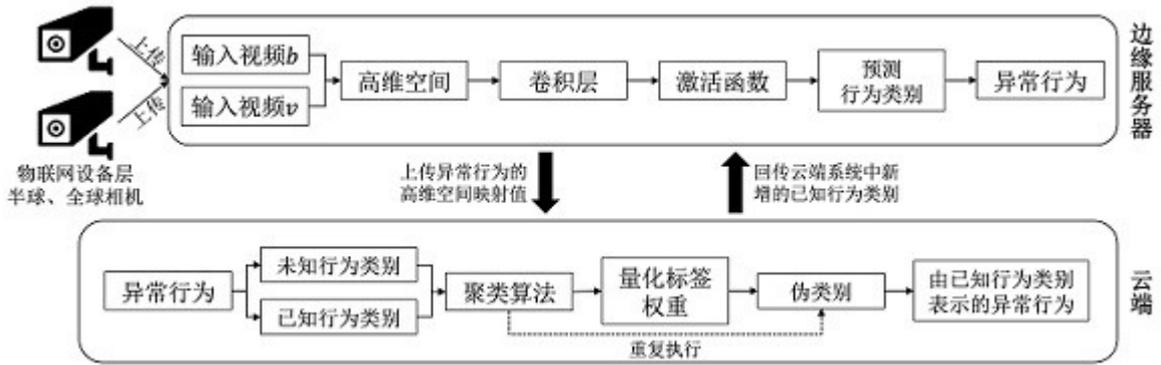


图1

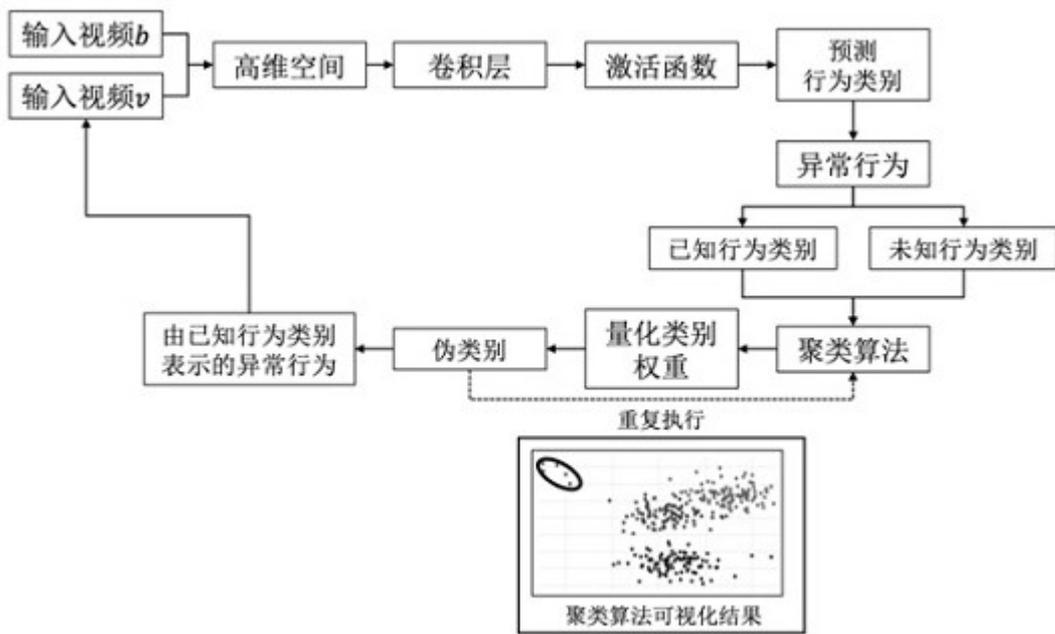


图2