

基于视频的托辊异常检测方法研究

李占利 胡长斌* 靳红梅

(西安科技大学计算机科学与技术学院 陕西 西安 710600)

摘要 针对托辊卡死、阻塞、轴承故障等托辊异常现象检测准确率低及人工检测耗时长的问题,提出基于视频的托辊异常检测方法,对运动托辊进行实时异常检测和报警。分析异常托辊产生的原因,提出基于视频的异常托辊检测方案并设计托辊异常检测网络;实验测得异常托辊检测准确率 89.53%,检测速度 103 帧每秒;使用五个评价标准分析了方案的优劣。相比与基于声音信号的托辊异常检测方案,基于视频的检测方法降低了传感器安装和维护难度,将卡死托辊检测准确率提高至 94.57%,确定异常托辊的位置,降低了工人维修时二次定位异常托辊的难度和工作量。

关键词 托辊 带式输送机 异常检测 C3D 运动特征提取

中图分类号 TP3 **文献标志码** A **DOI**:10.3969/j.issn.1000-386x.2024.07.015

ANOMALY DETECTION METHOD OF ROLLER BASED ON VIDEO

Li Zhanli Hu Changbin* Jin Hongmei

(College of Computer Science and Technology, Xi'an University of Science and Technology, Xi'an 710600, Shaanxi, China)

Abstract Aimed at the problems of low detection accuracy and long manual detection time for abnormal phenomena such as stuck rollers, blockages, and bearing failures of the rollers, an image-based abnormal detection method of the idler is proposed to realize the real-time abnormal detection and early warning of the idler. We analyzed the causes of abnormal rollers, proposed a video based abnormal roller detection scheme, and designed an abnormal roller detection network. The experiments show that the abnormal roller detection accuracy rate of 89.53%, and the detection speed of 103 FPS. Five evaluation criteria and comparative experiments were used to verify the pros and cons of the C3D network abnormal roller detection scheme. Compared with the roller anomaly detection scheme based on sound signals, the detection method based on the C3D network reduces the difficulty and cost of sensor installation and maintenance, and increases the accuracy of stuck roller detection to 94.57%.

Keywords Roller Belt conveyor Abnormality detection C3D Motion feature extraction

0 引言

矿山运输中,带式输送机是煤炭工业广泛使用的运输设备,输送机起火所引起的火灾事故,给煤矿安全带来隐患,从带式输送机起火的原因来看,由于托辊异常导致托辊和皮带温度升高是引起输送机着火的主要原因之一^[1-3]。曹贯强^[4]提出了一种基于小波去噪和 BP-RBF 神经网络的托辊异常检测方法,使用软阈值和硬阈值折中法对音频信号进行小波去噪,提取异常特

征向量,最后使用 BP-RBP 神经网络对特征向量分类,实现异常托辊检测。孙维等^[5]利用相干脉冲光的后向瑞利散射对托辊的振动信号进行分析,检测异常并确定其位置。基于声音信号的托辊异常检测方法对声音质量要求较高,完全卡死托辊无法检测到故障特征信号,异常托辊漏检比较严重。谢苗等^[6]提出一种基于红外图像托辊异常检测方法,通过确定托辊和皮带接触点温升规律进而判断托辊是否异常。韩涛等^[7]基于信息融合的托辊异常检测方法,融合压力、温度和声音三种传感器接受的数据提高异常托辊检测准确率。这

些都属于接触式测量,传感器安装和维护复杂。已有的托辊异常检测系统存在检测准确率低、误报漏报问题,尤其是煤矿带式输送机具有运输距离长、运转时间久和运载负荷大的特点,提高托辊异常检测准确性成为研究的重点。针对基于声音信号异常托辊检测漏检严重、接触式测量传感器安装维修复杂的问题,本文提出基于视频的托辊异常检测办法,探索通过提取托辊图像中托辊运动特征判断托辊是否异常。张杰等^[8]开发设计了带式输送机远程集中监控系统,基本实现了对带式输送机的智能视频监控,为带式输送机 and 托辊的异常检测提供了数据来源。

视频运动特征提取方法有两大类,一类是以光流簇为代表的传统提取运动特征法,另外一类是基于深度学习的神经网络提取运动特征^[9-10]。光流刻画了运动物体在人眼视网膜上形成连续变化的信息,光流计算需要同时满足灰度不变假设和全局平滑性假设^[11-12],昏暗煤矿下高速转动的托辊无法保证两个假设同时成立,光流法无法有效提取托辊运动特征。双流网络(Two-stream Convolution Networks)^[13]、长短记忆网络(Long Short-Term Memory, LSTM)^[14]和 C3D^[15-17](3D Convolution Networks)在人体行为识别领域取得了很好的效果,本文将以行为识别神经网络为基础设计托辊运动状态检测网络。

本文创新点主要有两个,第一,提出基于视频的托辊异常检测方案,首先提取待测托辊运动特征,然后计算托辊速度,最后将托辊速度和参考皮带速度进行比较判断托辊运动状态,根据托辊运动状态判断托辊是否异常。第二,建立托辊运行检测数据集,并设计基于3D卷积的托辊速度预测网络,假设托辊运行速度范围为0 m/s ~ X m/s,先将托辊的速度划分为 n 个区间,然后使用行为识别网络对待测托辊速度进行区间分类。

1 托辊异常检测方案

引起托辊异常的原因可分为内因和外因两种,内部因素主要为滚轴损坏,外部灰尘进入到滚轴内部,破坏了滚轴的密闭性,导致滚轴内部润滑液氧化和消耗,失去润滑液保护的辊轴会加速磨损,轴承和滚筒连接处摩擦增大,托辊运动速度减慢。外部因素主要有异物阻塞,异物阻塞导致滚轴卡死,托辊速度变慢甚至减少为零。正常托辊和异常托辊时间速度变化曲线如图1所示。






图1 不同情况下托辊速度


图1中,①号线是正常托辊运行的时间速度曲线;②号、③号和④号线为托辊在时间 t 时刻出现异常后的时间速度曲线,其中不同异常程度托辊速度下降多少和快慢有所不同;⑤号线为托辊在 t 时刻卡死的时间速度曲线。根据带式输送机的安全标准,托辊速度大于等于皮带速度的70%为正常范围,否则认为托辊异常。由于运动模糊,不同速度拍摄所得图像的纹理不相同,图2为三幅相同直径大小、不同速度的托辊图像。



(a) 0 m/s



(b) 1.2 m/s



(c) 4.0 m/s

图2 不同旋转速度托辊图像

旋转速度低的托辊表面纹理清晰,灰度亮度较低,速度高的托辊表面纹理模糊度严重,灰度亮度高。综上所述,托辊视频能够反映出不同运动状态的特征。第一,同样大小、不同速度的托辊在单位时间内转过的弧度大小不同;第二,同样大小、不同速度的托辊灰度纹理存在明显差异,根据这两点可有效区分不同状态的托辊,进而对异常托辊进行识别。

基于视频的异常托辊检测功能流程如图 3 所示。首先带式输送机远程集中监控系统采集托辊视频,然后对采集视频进行托辊异常检测,最后对检测到的异常托辊进行报警。

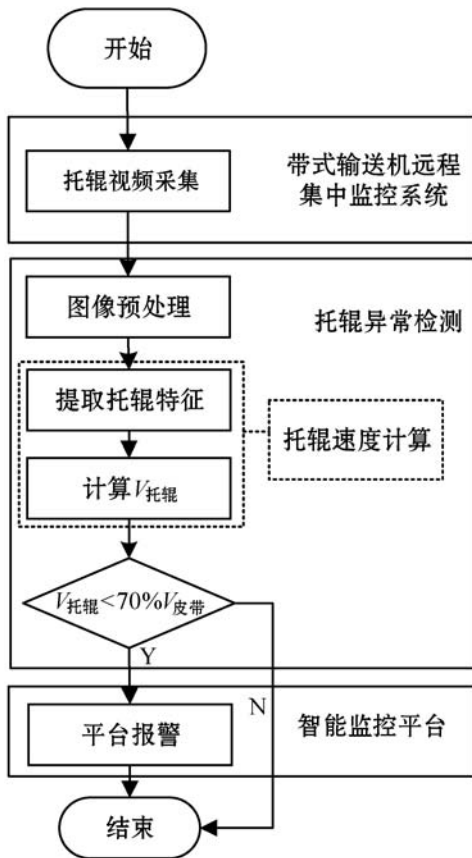


图 3 基于视频托辊异常检测功能流程

带式输送机远程监控系统通过巡检小车沿着带式输送机拍摄托辊运转视频,通过煤矿内的无线基站将视频传送到中央控制系统进行处理。对传送来的托辊图像进行预处理,提取托辊的运动特征并估算托辊速度,对待测托辊异常状态判断。最后将异常托辊的位置信息和对应视频段传送到煤矿智能监控平台进行报警,根据上传的异常托辊视频,维修工作人员可以对异常托辊再次确认,根据异常托辊的位置坐标,维修人员可以快速定位异常托辊的位置并进行托辊维修。

算法 1 托辊异常检测算法

输入:托辊视频(roller.mp4),皮带速度 V_1 。

输出:托辊状态(status:0,1,2)。

//0:托辊卡死,1:托辊异常,2:托辊正常

```

1. video <- videoCapture(filename) //读取待检测托辊视频
2. For img in video //提取视频中连续 16 帧图片
3.     Do S <- img
4. S' <- dataProcessing(S) //对图像进行归一化和区 //中心处理
5. model <- modelLoad() //加载托辊速度检测模型
6. V2 <- model.run(S') //调用模型 run 方法计算托辊速度
7. If V2 == 0 then //卡死托辊速度为 0
8.     Do status s <- 0
9. Else if V2 < 0.7V1 then //异常托辊 1
10.    Do status s <- 1
11. Else //正常托辊 2
12.    Do status s <- 2
13. Return status //返回托辊检测状态
  
```

在托辊异常检测系统,其中托辊速度估算是检测方案的核心。

2 托辊速度检测模型

托辊速度检测模型可以用传统特征提取和深度学习两种方法来设计。一种方法是先使用光流法提取托辊光流(托辊光流描述了托辊运动特征),再根据托辊光流间接计算托辊速度,而实验测得托辊光流计算准确率低,不适合煤矿下托辊运动特征的提取。另外一种方法是设计神经网络提取托辊运动特征直接估算托辊速度,使用神经网络估算托辊速度流程如图 4 所示。




图 4 估算托辊估算速度流程

首先对托辊图像进行标准化和去中心化处理,然后使用托辊检测网络,实现端到端的不同速度区间托辊分类。

相比于使用 2D 卷积核的长短记忆网络 LSTM 和双流网络,使用 3D 卷积网络可以更有效地提取运动物体的时空特征。3D 卷积核处理多帧图片示意图如图 5 所示。




图 5 3D 卷积核处理图像示意图

大小为 $k \times k \times d$ 的 3D 卷积核在 L 个大小为 $H \times W$ 的图像上进行卷积不仅可以提取物体的轮廓特征,还充分挖掘了图像帧之间的依赖关系,能同时提取图像上运动物体的时空特征。托辊检测网络的结构如图 6 所示。

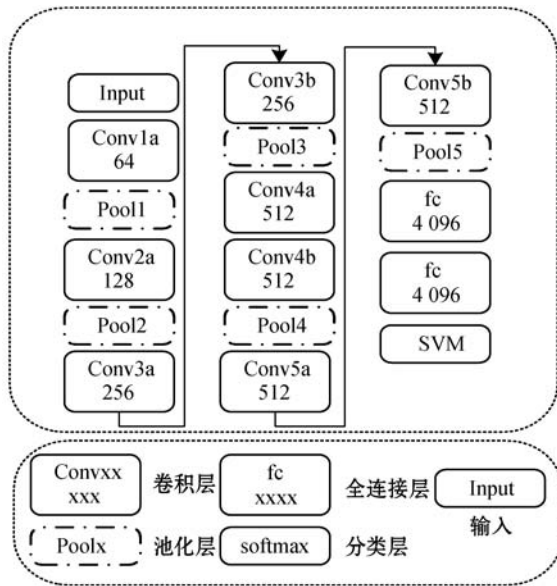


图 6 托辊检测网络

各卷积层输入通道数、输出通道数、尺寸大小、步长和填充具体值见表 1。

表 1 网络卷积层参数

卷积层	输入	输出	卷积核	步长	填充
Conv1	64	64	(3,3,3)	(1,2,2)	(0,0,0)
Conv2	128	128	(3,3,3)	(2,2,2)	(0,0,0)
Conv3a/b	256	256	(3,3,3)	(2,2,2)	(0,0,0)
Conv4a/b	512	512	(3,3,3)	(2,2,2)	(0,0,0)
Conv5a/b	512	512	(3,3,3)	(2,2,2)	(0,0,0)

异常托辊检测模型训练过程如下:

1) 对图像进行预处理。将原始图像缩放为 $122 \times$

122 统一大小,使用去中心化方法对图像进行处理移除图像的整体亮度,提高模型的训练速度和精度。

2) 对网络模型进行初始化,然后使用训练集对整个网络进行训练学习,直到模型收敛。

3 实验与分析

3.1 实验环境

Windows 10 操作系统, GPU 版本为 NVIDIA GeForce RTX 2080Ti, CUDA 版本 10.1, CUDNN 版本 7.6.4, 使用 Python 3.6.1 和 TensorFlow-GPU 1.13.1 进行深度学习模型的搭建和训练。

实验中将训练集、验证集和测试集按照 8:1:1 的比例进行划分,训练时采用随机梯度法 (Stochastic Gradient Descent, SGD) 对网络进行训练,学习率为 $1E-4$,卷积核大小为 $3 \times 3 \times 3$, Tran 等^[15] 在不同数据集上实验验证了卷积核大小为 $3 \times 3 \times 3$ 的 C3D 网络学习能力最强。为了确定最佳的 batch-size 大小,依次将网络中 batch-size 大小设为 10、15、20,分别在 126 组输入的小样本数据集上进行 20 次迭代训练,得到的模型准确率分别为 23.33%、46.7% 和 60%,其中开发电脑能加载的最大 batch-size 也是 20,因此实验中 batch-size 大小为 20。使用修正线性单元 (Rectified Linear Unit, ReLU) 作为激活函数,ReLU 计算公式如下:

$$f(x) = \begin{cases} 0 & x \leq 0 \\ x & x > 0 \end{cases} \quad (1)$$

式中: x 为神经元的输入。相比 Tanh 和 Sigmoid 激活函数,ReLU 可以使网络自行加入稀疏性,同时大大提高模型训练速度。

3.2 数据集制作

实验中所用托辊数据集拍摄于甘肃的东峡矿、红柳矿和华庭矿,使用迈德威视 MV-GE501GM-T 工业相机进行拍摄,采集到的原始托辊视频数量为 164 个,每个视频为长度 8~15 s、大小为 1224×1024 的灰度视频,视频帧率 11 帧/s,按照托辊速度对数据集打标签,数据集可分为六类,分别为 0、0.5、1.2、2.2、3.2 和 3.9 m/s。

托辊异常检测网络的一次输入为 L 帧图像,164 段原始托辊视频共 N 帧,将 N 帧托辊照片划为 $\frac{N}{L}$ 组输入得到数据集 roller0。为了提高训练模型准确率,采用两类方法对数据集进行扩充,将原始数据集扩充到原数据集 10 倍大小。第一类,对 roller0 中的图像进行垂直翻转、逆时针旋转 60 度和随机加入高斯或者椒盐

噪声得到数据集 roller1。第二类,考虑到从不同帧开始提取到的托辊运动特征不同,假设相邻分组之间没有重叠,长度为 N 视频可以划分为 $n_1 = \frac{N}{L}$ 组,设相邻分组之间的重叠数为 b ,此时长度为 N 的视频可以划分为 $n_2 = \frac{N-b}{L-b}$ 组。本文取 $b = 11$,将数据集 roller1 扩大到原来的 3 倍得到数据集 roller,数据集 roller 大小为 22 468 组,每组中的托辊图像数量为 16 帧。数据集 roller 图像中除了托辊,还包含了背景信息,为了验证背景对托辊速度估算的影响,在数据集 roller1 截取托辊图像得到数据集 rollerImage。创建的所有数据集见表 2。

表 2 创建数据集

数据集名	大小	备注
roller0	2 389 组 x16 帧	原始数据集
roller1	7 169 组 x16 组	在 roller0 上扩充
roller	22 468 组 x16 帧	在 roller1 上扩充
rollerImage	22 468 组 x16 帧	在 roller 上截取托辊

3.3 评价标准

本文采用五个指标来定量评价托辊异常检测方案的优劣。这五类指标依次为单类托辊速度检测精确率 T (托辊预测速度和实际速度一致的概率)、单类托辊速度误检率 F 、托辊速度检测平均精确率 Q 、异常托辊 ($V_{\text{托辊}} < 0.7V_{\text{皮带}}$) 检测平均准确率 P 和最终异常托辊检测准确率 H ,计算公式如下:

$$T_i = \frac{S_i}{Z_i} \quad (2)$$

$$F_i = 1 - T_i \quad (3)$$

$$Q_j = \frac{\sum_{i=0}^j S_i}{\sum_{i=0}^j Z_i} \quad j=2,3,\dots,n \quad (4)$$

$$P_j = \frac{\sum_{i=0}^j M_i}{\sum_{i=0}^j Z_i} \quad j=2,3,\dots,n \quad (5)$$


$$H_j = Q_j \times P_j \quad (6)$$

式中: S_i 为第 i 类测试集样本中预测托辊速度和皮带速度一致的样本数; Z_i 为第 i 类测试集样本数量; M_i 为第 i 类异常托辊样本中异常托辊检测出来数量。 $j = 1$ 时, $V_{\text{皮带}} = 0$,带式输送机停机。


3.4 实验结果分析

(1) 模型训练结果分析。数据集 roller 和 roller-

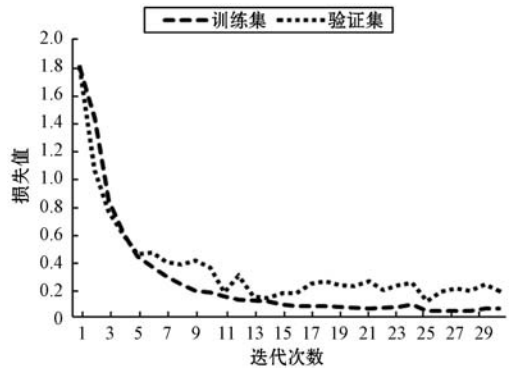
Image 在每轮迭代训练结束时训练集和测试集损失值和准确率如图 7 所示。




(a) roller 损失值



(b) roller 准确率



(c) rollerImage 损失值



(d) rollerImage 准确率

图 7 损失值和准确率

使用未去除背景数据集 roller 和去除背景 roller-Images 数据集训练检测网络均在 epoch 达到 11 之后模型开始收敛,对应测试准确率分别为 roller = 86.06%,

rollerImage 测得 97.30%。相比于包含背景的数据集 roller, 只包含托辊的数据集 rollerImage 最终训练所得模型检测准确率提高了 10 个百分点。

(2) 模型精确率分析。为了分析托辊速度对估算准确率的影响, 在数据集 roller 上不同速度托辊检测的准确率和误检率如图 8 所示。




图 8 托辊速度检测精确率和误检率

随着托辊的速度的增大, 托辊检测精确率在降低, 说明类间距离在减小。其中 0 m/s、0.5 m/s 和 1.2 m/s 的低速托辊平均检测准确率为 93.18%, 带式输送机高速转动时, 这些低速转动的托辊对高速运动的皮带摩擦最大, 属于严重异常托辊, 也是托辊异常检测中需要重点检测出来进行维修的托辊。

(3) 异常托辊检测准确率分析。训练模型时采用了 6 类速度对模型进行训练, 但实际煤矿输送机速度会发生变化, 待测托辊的速度分类数会减少, 并且模型对不同速度托辊预测精确率不同, 这就需要分析在不重新训练网络的情况下, 测试速度类别对异常托辊检测准确率的影响。为了研究异常托辊检测准确率随测试速度类别的变化情况, 分别计算了托辊速度检测平均精确率 Q 、异常托辊检测平均准确率 P 和最终托辊检测准确率 H 三个指标。开始计算之前, 首先定义输送机不同速度下, 用于测试的异常托辊分类, 定义如表 3 所示。

表 3 测试异常托辊数据集

带速/ (m·s ⁻¹)	辊速/(m·s ⁻¹)					
	0	0.5	1.2	2.2	3.2	3.9
0	—	—	—	—	—	—
0.5	√	—	—	—	—	—
1.2	√	√	—	—	—	—
2.2	√	√	√	—	—	—
3.2	√	√	√	√	—	—
3.9	√	√	√	√	√	—

表 3 列表表示用于测试的运动带式输送集速度类型, 0 m/s 时带输送机处于待机状态, 无法进行异常托辊检测。表 3 行表示候选异常托辊。其中: “√” 表示该类托辊可作为对应带速度的异常托辊; “—” 表示不选, 例如当带速为 2.2 m/s 时, 用于测试的异常托辊有 0 m/s、0.5 m/s 和 1.2 m/s 三类。定义完用于不同带速类测试的异常托辊数据集之后, 在 roller 三个指标的计算结果如图 9 所示。




图 9 P 、 Q 和 F 检测结果

图 9 中横轴为当前参照带速, 纵轴表示小于当前带速各类异常托辊 P 、 Q 和 H 的计算准确率。异常检测根据异常托辊判定公式 ($V_{托辊} < 0.7V_{皮带}$), 有可能将预测速度大于当前皮带的速度的错误预测也归为正常托辊, 所以随着分类数增多, 虽然异常托辊平均检测准确率 P 在下降, 但异常托辊平均检测准确率 Q 基本保持不变, 甚至有点升高, P 显然没有真实反映模型异常托辊检测准确率随分类数的变化情况。如果将 Q 看作当前几类托辊速度预测的平均精确概率, P 作为当前几类样本异常托辊检测准确率, 结合了 P 和 Q 的 H 可以看成当前几类异常托辊检测准确率期望值, 更能真实反映该模型异常托辊检测的准确情况。 H 成中间高、两头低, 因此选择中间运行带速对托辊异常进行检测准确率会更高。

(4) 模型处理速度分析。模型处理托辊视频图像的速度, 可以达到 103 帧/s, 按每组测试托辊图像长度为 16, 则单帧托辊平均处理时间为 0.15 s, 而实际工业相机的拍摄帧率在 30 帧/s 左右, 检测网络处理托辊图像的速度远远大于相机的拍摄帧率, 完全可以达到实时处理的要求。

3.5 对照实验

选用长短记忆网络 LSTM 和双流网络在数据集 roller 进行了对比实验, 分别计算了三者异常托辊检测准确率, 结果如表 4 所示。

表4 不同模型托辊速度检测准确率(%)

模型名	准确率
LSTM	73.50
双流网络	67.20
3D 卷积	86.06

C3D 分类准确率更高,C3D 分类准确率分别比 LSTM 高 13 百分点,比双流网络高 20 百分点。

4 结 语

对托辊异常产生的原因进行分析,结合图像数据特点和煤矿带式输送机的安全生产标准,提出针对图像的异常托辊判定模型和托辊异常检测方案。实验托辊速度检测准确率达 86.06%,异常托辊检测准确率 89.53%,在只包含托辊数据集上估算托辊速度准确率为 97.30%。使用 5 个评价指标定量评价 C3D 托辊异常检测方案优劣,C3D 异常托辊检测准确率比 LSTM 和双流网络分别高了 13 百分点和 20 百分点。

基于视频的托辊异常检测实现了托辊异常的自动化检测,减少了煤矿托辊检修人员的工作量,及时发现卡死托辊,降低托辊卡死引起带式输送机着火的风险。相较于基于接触式异常托辊检测,减少了铺设和维修大量传感器的费用。相比于声音信号的托辊异常检测方法,更加有效检测托辊卡死,异常托辊定位的准确性更高。

参 考 文 献

[1] 焦贺彬. 煤矿带式输送机智能化安全监测系统研究[J]. 煤矿机械,2020,41(10):182-185.

[2] 赵仁渔,朱波,张小松,等. 智能带式输送机巡检机器人的研究与应用[J]. 中国煤炭,2020,46(10):40-43.

[3] 白宏磊,张明泽,王克成. 长距离带式输送机托辊的故障检测[J]. 辽宁科技大学学报,2015,38(1):41-45.

[4] 曹贯强. 带式输送机托辊故障检测方法[J]. 工矿自动化,2020,46(6):81-86.

[5] 孙维,刁冬梅. 基于 φ -OTDR 技术的带式输送机托辊故障检测[J]. 工矿自动化,2016,42(8):9-12.

[6] 谢苗,朱振,卢进南. 基于红外图像处理技术的托辊卡阻检测方法[J]. 机械设计与研究,2020,36(5):152-157.

[7] 韩涛,胡英贝,张蕾,等. 信息融合技术在托辊轴承故障诊断中的应用[J]. 轴承,2012(6):57-59.

[8] 张杰,李浙昆,翟守忠. 带式输送机远程集中监控系统的研究与开发[J]. 矿业研究与开发,2013,33(6):100-

102,117.

[9] 张会珍,刘云麟,任伟建,等. 人体行为识别特征提取方法综述[J]. 吉林大学学报(信息科学版),2020,38(3):360-370.

[10] 祁大健,杜慧敏,张霞,等. 基于上下文特征融合的行为识别算法[J]. 计算机工程与应用,2020,56(2):171-175.

[11] 邵绪强,杨艳,刘艺林. 流体运动估计光流算法研究综述[J]. 中国图象图形学报,2021,26(2):355-367.

[12] 林宇凌,金晓宏,王中任. 基于 LK 光流法的微流控芯片中流体速度检测[J]. 激光与红外,2020,50(8):1014-1019.

[13] Simonyan K, Zisserman A. Two-stream convolutional networks for action recognition in videos[C]//Neural Information Processing Systems,2014:568-576.

[14] Varol G, Laptev I, Schmid C. Long-term temporal convolutions for action recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2018,40(6):1510-1517.

[15] Tran D, Bourdev L, Fergus R, et al. Learning spatiotemporal features with 3D convolutional networks[EB]. arXiv:1412.0767,2014.

[16] 徐访,黄俊,陈权. 基于 3D 卷积神经网络的动态手势识别模型[J]. 计算机工程,2021,47(11):283-291.

[17] 何景琳,梁正友,孙宇,等. 结合 C3D 与光流法的微表情自动识别[J]. 计算机系统应用,2021,30(1):221-227.

(上接第 81 页)

[18] Zhang H, Zhou X, Wang Z P, et al. Adaptive consensus-based distributed target tracking with dynamic cluster in sensor networks[J]. IEEE Transactions on Cybernetics,2019,49(5):1580-1591.

[19] Zhang Z, Li Q D, Han L, et al. Consensus based strong tracking adaptive cubature Kalman filtering for nonlinear system distributed estimation[J]. IEEE Access,2019(7):98820-98831.

[20] 田凡凡,崔宝同,楼旭阳. 分布式传感网络的自适应一致性算法[J]. 计算机工程与应用,2016,52(6):86-89,98.

[21] 杨文,侍洪波,汪小帆. 卡尔曼一致滤波算法综述[J]. 控制与决策,2011,26(4):481-488.

[22] 娄柯,崔宝同,李纹. 基于蜂拥控制的移动传感器网络目标跟踪算法[J]. 控制与决策,2013,28(11):1637-1642.

[23] 裴惠琴,陈世明,孙红伟. 动态环境下可扩展移动机器人群体的围捕控制[J]. 信息与控制,2009,38(4):437-443.

[24] Olfati-Saber R, Murray R M. Consensus problems in networks of agents with switching topology and time-delays[J]. IEEE Transactions on Automatic Control,2004,49(9):1520-1533.