

# 基于改进 YOLOv3 的纽扣电池表面缺陷检测

李冬伟,丁力,梁栋

(江苏理工学院 机械工程学院,江苏 常州 213001)

**摘要:**针对目前纽扣电池表面缺陷检测易受外部因素干扰致使缺陷识别率低、速度慢的问题,提出一种改进 YOLOv3 的纽扣电池表面缺陷检测方法。通过图像采集系统和 HALCON 软件完成图像预处理;预处理数据集,对图像批量进行数据增强和标注;加入 K-means++ 聚类算法,建立优化后的 YOLOv3 网络结构,输入数据集进行训练,输出检测模型;以数据验证集作为测试对象,分别对聚类算法和综合性能进行对比实验。结果表明:所提方法聚类准确率为 91.54%,相比于 K-means 聚类算法提高了 6.37%;表面缺陷平均检测准确率为 95.28%,优于 SSD、Faster R-CNN 和原始 YOLOv3 等方法。该方法能够克服环境背景和主观因素对纽扣电池表面缺陷检测的影响,具有一定的工程参考价值。

**关键词:**纽扣电池;缺陷检测;YOLOv3;K-means++;网络结构优化

**中图分类号:**TP391.41 **文献标志码:**A **文章编号:**1671-5276(2022)05-0177-05

## Surface Defect Detection of Button Battery Based on Improved YOLOv3

LI Dongwei, DING Li, LIANG Dong

(College of Mechanical Engineering, Jiangsu University of Technology, Changzhou 213001, China)

**Abstract:** To address the problem that the detection of defects on the surface of button batteries is susceptible to interference from external factors, resulting in low defect-recognition rate and slow speed, a button battery surface defect detection method based on improved YOLOv3 is proposed. By the image acquisition system and HALCON software, image preprocessing is completed, the data set is preprocessed, and the image batch is enhanced and labeled. K-means++ clustering algorithm is applied to establish optimized YOLOv3 network structure, into which data set is input for training, and from which detection model is output. With the data validation set as the test object, comparative experiments are conducted respectively on the clustering algorithm and comprehensive performance. The results show that the clustering accuracy of the proposed method is 91.54%, 6.37% higher than that of the K-means clustering algorithm, and the average detection accuracy reaches 95.28%, better than that of SSD, Faster R-CNN and the original YOLOv3. The proposed method can overcome the influence of environmental background and subjective factors on the detection of surface defects of button batteries and has a certain engineering reference value.

**Keywords:** button battery; defect detection; YOLOv3; K-means++; network structure optimization

## 0 引言

纽扣电池是一种常用的电路元件,因其体积偏小且具有较好的经济适用性被广泛应用于微型电子产品中。在生产加工过程中,因工艺限制或操作失误,纽扣电池表面难免会出现划痕、凹坑等缺陷<sup>[1-2]</sup>。这些损伤除了会降低产品质量外,还有可能造成安全隐患。因此企业必须对纽扣电池的表面进行缺陷检测<sup>[3]</sup>。经调研,目前普遍的检测方式为人工检测,即依靠肉眼过滤出不合格产品。这种方法不仅受质检员主观因素的影响较大,也可能对其视力造成永久性损害。因此,提出一种检测准确率和速度满足需求的纽扣电池表面缺陷检测方法具有重要的意义。

为解决上述问题,学者们将传统机器视觉图像处理技

术引入至缺陷检测领域,其优势在于图像区域处理速度快和匹配检测精度高。例如,KONG Q M 等<sup>[4]</sup>根据螺栓的尺寸和形状特征,提出基于改进模板匹配算法的外螺纹表面缺陷检测方法,检测准确率为 96.15%。但该方法对硬件要求较高且易受光照条件、螺栓边缘提取程度等因素影响,检测速率不高。随着人工智能技术和计算机视觉算法的普及,目标检测算法逐渐取代了传统机器视觉在缺陷检测领域的地位。当前,深度学习目标检测算法<sup>[5]</sup>主要分为两类,一类是以 SSD<sup>[6]</sup>、YOLO<sup>[7]</sup>为代表的 one-stage 算法;另一类则是以 Mask R-CNN<sup>[8]</sup>、Faster R-CNN<sup>[9]</sup>为主的 two-stage 算法。在检测准确度相同的情况下,由于 one-stage 算法具有检测速度快、硬件依赖度低等优势,因此被广泛应用于检测行业。近年来,得益于算法通用性强和背景误检率低的优点,YOLO 及其改进算法受到市场的青

**基金项目:**国家自然科学基金项目(52005231);常州市社会发展科技支撑项目(CE20215050);江苏省(校)研究生实践创新计划项目资助(XSJGX22\_33)

**第一作者简介:**李冬伟(1998—),男,江苏仪征人,硕士研究生,研究方向为深度学习与图像处理。

眯。例如,南虎等<sup>[10]</sup>制作高质量的原子图像数据集,使用 YOLOv3 实现了原子峰的位置检测,检测速率相比于高斯拟合等方法有了显著提升。王宸等<sup>[11]</sup>提出一种改进 YOLOv3 的轮毂焊缝缺陷检测方法,利用数据增强法扩充数据集,检测准确率达到 99.29%,检测速率满足企业生产线的节拍要求。JU M 等<sup>[12]</sup>为进一步提高网络的检测性能,扩展 YOLOv3 的特征图层至 4 层,提高了小目标的检测能力。在 YOLO 系列算法中,优秀聚类算法不仅可以提高模型训练速度,而且能够提高缺陷检测准确率和模型泛化性。例如,XU Y M 等<sup>[13]</sup>改进 YOLOv3 模型,采用 K-means++ 聚类算法选取初始聚类中心,使缺陷平均检测准确率提高了 3.02%。NING Z 等<sup>[14]</sup>提出一种改进 YOLOv3 的带钢表面缺陷检测算法,其使用 K-means++ 聚类算法进行聚类分析,使缺陷检测准确率达到 89.5%。

受上述分析启发,本文提出了一种改进 YOLOv3 的纽扣电池表面缺陷检测方法,即先联合 HALCON 软件和图像采集系统完成图像预处理和数据集预处理;然后引入 K-means++ 聚类算法,优化 YOLOv3 网络结构;最后训练模型并进行检测实验。

## 1 图像预处理

为避免因图像质量问题影响缺陷检测准确率,本文设计了基于 HALCON 的图像预处理方案,具体的预处理流程如图 1 所示,其中包括图像采集、图像灰度化、图像滤波、Blob 分析及结果输出。




图 1 图像预处理流程

### 1.1 图像采集

由于缺陷位置不固定,并且在不同光源角度下的成像效果差异较大,故仅在同一光源角度下连续拍摄图片无法完成图像采集任务。为此,本文搭建了如图 2 所示的图像采集系统,该系统由计算机、光电传感器、传输装置、支架、MV-CE050-30 UC 型 CMOS 传感器工业面阵相机、MVL-HF1228 M-6 MPE 型变焦镜头、24 V 电源适配器和白色同轴光源构成。为确保能够采集到可用的图像,本文通过可编程逻辑控制器和光电传感器提供拍摄信号。当纽扣电池样本被传输至指定位置时,工业相机间隔 50 mm 拍摄 3 张图片,完成图像采集工作。



图 2 图像采集系统

### 1.2 图像灰度化

为了使用更少的数据信息体现样本的特征,同时提高图像预处理和缺陷检测的速度,需要对图像进行灰度化处理。常用的图像灰度化方法有 3 种,分别是平均值法、最大值法和加权平均值法<sup>[15]</sup>。本文在这里选用加权平均值法对图像进行灰度化处理,即

$$I_{\text{grey}}(i,j) = 0.299R(i,j) + 0.587G(i,j) + 0.114B(i,j) \quad (1)$$

式中: $I_{\text{grey}}(i,j)$ 为灰度图像中像素点的灰度值; $R(i,j)$ 为彩色图像中像素点红色量; $G(i,j)$ 为彩色图像中像素点绿色量; $B(i,j)$ 为彩色图像中像素点蓝色量。

### 1.3 图像滤波

受拍摄环境和图像采集系统自身传感元件的影响,图像在采集过程中会夹杂噪声,导致图片成像质量不高,因此在图像灰度化处理后必须进行滤波消噪<sup>[16]</sup>。考虑到图像中缺陷尺寸较小,同时为了尽可能保留其总体灰度特征,本文在这里选用尺寸为 3×3 的高斯滤波器。如图 3 所示,经过高斯滤波处理,缺陷区域得到了增强。




图 3 高斯滤波处理结果对比

### 1.4 Blob 分析

高斯滤波虽然去除了硬件对图片成像的影响,但图像背景和无关区域亦会对缺陷检测造成干扰。为提高缺陷检测的准确率,本文在这里采用机器视觉中常用的 Blob 分析<sup>[17]</sup>提取纽扣电池的特征,剔除图像中的干扰项和无关项,其处理结果如图 4 所示。




图 4 Blob 分析处理结果

## 2 数据集预处理

实现纽扣电池表面缺陷检测的基础是进行数据集预处理。首先,收集尽可能多的纽扣电池表面缺陷图像;然后,针对图像收集情况批量进行数据增强处理;最后,标注图像中的缺陷参数,生成标签文件。

### 2.1 图像收集

为了使检测结果更加准确,本文所用的纽扣电池皆来源于某纽扣电池生产企业。经第 1 节所述的图像预处理环节后共收集到 2 100 张纽扣电池表面缺陷图像,分辨率

为 416×416。该企业生产的纽扣电池主要包含两种类型的缺陷,分别是划痕和凹坑,图像样本如图 5 所示。




图 5 表面缺陷图像样本

## 2.2 图像增强

由于检测模型需要进行大量图像训练来降低偏差,避免出现过拟合现象,因此需要对图像进行增强处理以获取充足的数据。针对收集到的图像依次随机进行水平翻转和垂直翻转变换,并将变换后的图像加入训练集,变换后的图像如图 6 所示。经上述数据增强处理后共获取 4 200 张数据集图像,将其以 7:2:1 的比例划分为训练集、测试集和验证集,其中每张图像至少包含一种缺陷。




图 6 数据增强处理

## 2.3 图像标注

模型训练前需要标注图像中的缺陷类型,本文使用开源标注软件 Labellmg 对数据集图像进行标注。缺陷标注分为两类,分别是划痕类缺陷,标签为 scratch;凹坑类缺陷,标签为 fossette。标注流程如图 7 所示。首先在 Labellmg 中框选出缺陷区域,获取对应的坐标位置信息;然后注明对应标签;最后生成后缀为 xml 的标签文件,使文件名称和图像名称保持一致。通过标注软件 Labellmg 生成的标签文件中,包含图像所属路径、图像像素尺寸、缺陷标签类型以及缺陷边界框的位置信息。




图 7 缺陷区域标注

## 3 YOLOv3 改进策略

YOLOv3 是一种根据 YOLOv2<sup>[18]</sup> 改进而成的端到端的目标检测算法,被广泛运用于视频识别、图像辨识和实时检测领域。但其在缺陷检测方面依然存在检测准确率不足的问题,故本文以原始 YOLOv3 为基础,加入

K-Means++ 聚类算法<sup>[19]</sup>,优化其网络结构,增强了算法的缺陷检测能力。

### 3.1 加入 K-means++ 聚类算法

原始 YOLOv3 采用经典的 K-means 聚类算法对数据集图像进行维度聚类分析进而获取先验框(anchor box)。虽然此算法能够取得一定的聚类效果,但其局限性在于 K-means 聚类算法会随机选取初始聚类中心,导致聚类效果差异较大。因此,选择合理的初始聚类中心显得十分重要。

针对 K-means 聚类算法<sup>[20]</sup> 随机选取初始聚类中心的弊病,本文采用 K-means++ 聚类算法进行优化。K-means++ 聚类算法可以使不同的聚类中心分布在距离相差较远的位置,能够降低簇间的相似度,提高算法的聚类准确率和收敛速度。该算法首先会筛选出一个样本作为初始聚类中心  $O_1$ ,接着计算每个样本到当前聚类中心间的最短距离,依次计算每个样本成为聚类中心的概率,然后按照概率选取聚类中心,概率计算公式如下:

$$p = \frac{D(x)^2}{\sum_{i=1}^n D(x_i)^2} \quad (2)$$

式中:  $p$  为概率;  $D(x)$  为每个样本到当前聚类中心的最短距离。重复计算剩余样本成为下一个聚类中心的概率,直至选出所有的聚类中心。再针对聚类中心以外的样本,将它们划分至距离最短的聚类中心所对应的簇中。最后针对每个簇,重复计算其聚类中心坐标,直至聚类中心位置不再变化,最终筛选出  $K$  个初始聚类中心。

K-means++ 聚类算法能够从样本中发现显著的规律和集群,以相似度为标准将特征相似或相同的样本划分至同一类别。该方法极大地减小了  $K$  值对聚类效果的影响,有效解决了 K-means 聚类算法缺陷带来的问题。

### 3.2 网络结构优化

原始 YOLOv3 主要依靠 3 种不同尺度的特征图层实现目标检测,但纽扣电池表面缺陷的尺寸较小,而 YOLOv3 在检测中对小目标缺陷不敏感。因此,需要针对 YOLOv3 的网络结构进行改进,提高其检测准确率。

本文的改进方法是将 Darknet-53 主干网络中第 2 个残差块的浅层输出与 2 次采集后的网络深层输出融合,再经过卷积层(conv)构成一个新的特征图层。新的特征图层不仅继承了 Darknet-53 输出的深层特征,也充分利用了网络浅层特征,模型的特征提取能力得到加强。不同尺度的特征图层将图像划分为不同数量的网格,新的特征图层尺寸是数据集图像尺寸的 1/4。它将图像划分至 104×104 个网格,网格尺寸仅为 4×4,网格尺寸越小意味着对小目标缺陷越敏感。改进后的网络结构如图 8 所示,含有  $n$  个残差单元的残差块用  $res \times n$ <sup>[21]</sup> 表示,每个残差单元包含一个快捷链路与两个 DBL 结构。DBL 结构由批归一化层(BN)、卷积层(conv)和激活函数(leaky relu)构成。conv 是指卷积核为 1×1 的卷积层。Concat 是指张量拼接环节,用于扩充张量维度。维数  $D$  表示特征图层中每个网格包含的信息数量,其公式如下:

$$D = E \times (F + G + H) \quad (3)$$

式中:  $E$  为网格先验框的数量;  $F$  为边框坐标信息;  $G$  为边

框置信度;  $H$  为检测对象的类别数量。图 8 中虚线框内即为新增的特征图层。

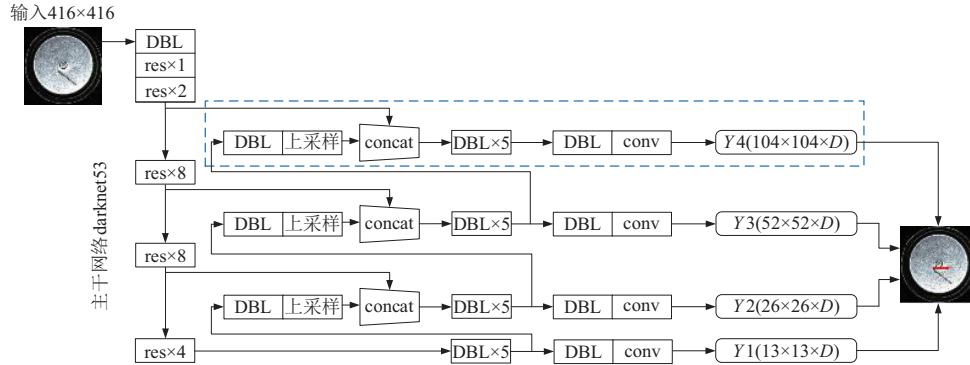


图 8 改进后的网络结构

优化后的网络结构将拥有 4 个特征图层,每个特征图层依然拥有 3 个先验框,使先验框总数增加至 12 个。图像中先验框数量的增加能够增大检测密度,降低缺陷误检和漏检的概率。叠加的特征图层可以更好地划分缺陷的尺寸层次,强化网络对不同尺寸缺陷的综合检测能力。

## 4 实验与结果分析

实验硬件环境为 Intel(R) Core(TM) i7-10870 H CPU @ 2.20 GHz CPU,内存 16 GB;GPU 为 NVIDIA GeForce RTX 2070,显存 8 GB。软件环境为 Windows10 操作系统,Anaconda 环境管理器。运行环境为 Python3.6, TensorFlow1.14 和 Keras2.1.5。编译环境为 PyCharm,利用 CUDA10.0 和 CUDNN7.6.5 加速 GPU 运算。

### 4.1 性能评价标准

本文选择缺陷检测中常用的性能评价标准对本次实验进行分析,模型性能评价标准包括准确率  $P$  (precision)、召回率  $R$  (recall)、表面缺陷精度均值  $A_p$  (average precision)、表面缺陷平均精度均值  $m_{AP}$  (mean average precision) 和检测速度  $F$ 。 $P$ 、 $R$ 、 $A_p$  和  $m_{AP}$  计算公式如下:

$$P = \frac{T_p}{T_p + F_p} \quad (4)$$

$$R = \frac{T_p}{T_p + F_N} \quad (5)$$

$$A_p = \int_0^1 P(R) dR \quad (6)$$

$$m_{AP} = \frac{\sum_{i=1}^n A_p(i)}{n} \quad (7)$$

式中:  $T_p$  为真正例;  $F_p$  为假正例;  $F_N$  为假反例;  $A_p(i)$  为第  $i$  类缺陷的精度均值;  $n$  为检测类型数量。

### 4.2 模型训练

模型训练采用随机梯度下降法,动量因子为 0.9。图像输入尺寸为 416x416,颜色通道数为 1。为防止过拟合现象发生,权重衰减系数设定为 0.000 5。初始学习率为

0.001,最终学习率为 0.000 001,学习率衰减策略为 steps。采用 K-means++ 聚类算法进行维度聚类分析获取的聚类准确度 (accuracy) 为 91.54%。为防止计算机因显卡内存容量不足而崩溃,每批输入 4 张图像进行训练 (batch 为 4)。通过预训练发现,模型的损失在迭代 400 次左右能实现收敛,因此将训练迭代次数设置为 2 500。模型的损失变化情况如图 9 所示,在迭代 1 000 次前后达到极小值,直至训练结束都保持稳定,达到了训练模型的目的。




图 9 损失函数变化曲线

### 4.3 验证集检测结果与分析

从模型训练部分可以得出结论,该模型训练结果收敛较快,其权重文件可以用于检测实验。验证集部分检测结果如图 10 所示,表明模型能够完成缺陷检测任务。验证集总体检测效果如图 11 所示,scratch 类缺陷  $A_p$  为 95.15%, fossette 类缺陷  $A_p$  为 95.40%,缺陷  $m_{AP}$  为 95.28%。从各项性能评价标准可以看出该模型在训练阶段和检测阶段均较为理想,能够胜任纽扣电池表面缺陷检测任务。


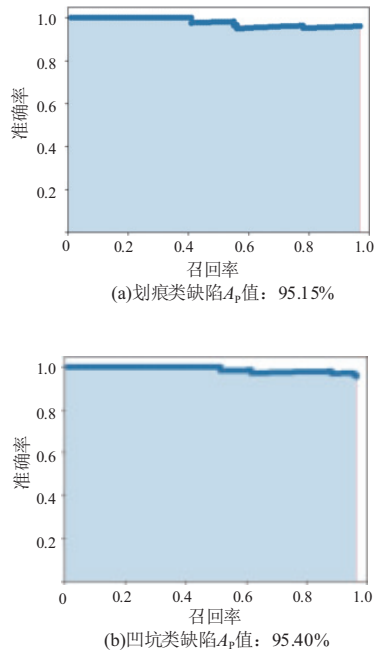


图 10 测试集检测结果

图 11 缺陷类型  $P-R$  曲线

#### 4.4 实验结果与对比分析

本文分别运用 K-means 和 K-means++ 两种聚类算法对数据验证集进行聚类,使用  $A_{accuracy}$ 、 $m_{AP}$  和  $F_{PS}$  对算法进行评估,其结果如表 1 所示。采用 K-means++ 进行实验并得到的  $A_{accuracy}$  和  $m_{AP}$  分别为 91.54% 和 95.28%,相比于使用 K-means 分别提高了 6.37% 和 3.97%,表明 K-means++ 聚类算法不仅能够优化初始聚类中心的选取,也提高了缺陷检测的准确率。

表 1 聚类算法对比

聚类算法	$A_{accuracy}/\%$	$m_{AP}/\%$	$F_{PS}/(\text{帧}/\text{s})$
K-means	85.17	91.31	38
K-means++	91.54	95.28	35

为验证本文方法的综合检测性能,在这里使用原始 YOLOv3、SSD 和 Faster R-CNN 方法对数据训练集进行训练。此次采用  $A_p$ 、 $m_{AP}$  和  $F_{PS}$  三项指标作为性能评估标准,表 2 罗列了上述各方法对数据验证集的检测结果。

表 2 不同方法性能对比

方法	$A_p/\%$		$m_{AP}/\%$	$F_{PS}/(\text{帧}/\text{s})$
	scratch	fossette		
原始 YOLOv3	93.13	89.49	91.31	38
SSD	81.52	91.18	86.35	30
Faster R-CNN	91.74	94.68	93.21	17
本文方法	95.15	95.40	95.28	35

对表 2 分析可知,原始 YOLOv3 对 scratch 类缺陷较为敏感,其检测准确率为 93.13%。SSD 和 Faster R-CNN 对 fossette 类缺陷检测效果较好,相较于原始 YOLOv3 分别提

高了 1.69% 和 5.19%。本文方法对纽扣电池表面各类缺陷的检测准确率皆优于上述方法,在数据验证集上的  $m_{AP}$  值为 95.28%,相比于原始 YOLOv3、SSD 和 Faster R-CNN 分别提高了 3.97%、8.93% 和 2.07%。同时本文方法的  $F_{PS}$  达到 35 帧/s,优于 SSD 和 Faster R-CNN。虽然检测速率比原始 YOLOv3 稍逊一筹,但本文方法胜在缺陷检测准确率,这是图像预处理、数据集预处理、K-means++ 聚类算法和网络结构优化共同作用的效果。因此结合上述性能评价标准,本文方法的综合性能优于原始 YOLOv3、SSD 和 Faster R-CNN,具有一定的工程参考价值。

## 5 结语

本文为解决纽扣电池表面缺陷易受外部因素干扰导致检测准确率不足的问题,提出一种基于改进 YOLOv3 的纽扣电池表面缺陷检测方法,首先搭建了图像采集系统,设计了基于 HALCON 的图像预处理方案;然后制作了实验数据集;最后针对原始 YOLOv3 的不足,加入 K-means++ 聚类算法优化聚类中心的选取,新增一个特征图层强化缺陷检测能力。以性能评价标准作为参考指标,本文方法在验证集上检测两类缺陷的平均准确率达到 95.28%,优于原始 YOLOv3、SSD 和 Faster R-CNN 等对比方法,进一步证明了其有效性。该模型在检测过程中的实时性尚有提升空间,在后续研究中将着重于优化检测流程和权重文件,提升检测速率。

### 参考文献:

- [1] 肖阔华,刘羽. 纽扣电池表面缺陷检测算法的研究[J]. 表面技术,2013,42(1):127-130.
- [2] CZIMMERMANN T, CIUTI G, MILAZZO M, et al. Visual-based defect detection and classification approaches for industrial applications—a survey[J]. Sensors (Basel, Switzerland), 2020, 20(5):1459.
- [3] 李维创,尹柏强. 工业金属板带材表面缺陷自动视觉检测研究进展[J]. 电子测量与仪器学报,2021,35(6):1-16.
- [4] KONG Q M, WU Z H, SONG Y T. Online detection of external thread surface defects based on an improved template matching algorithm[J]. Measurement, 2022, 195:111087.
- [5] DENG J, XUAN X J, WANG W F, et al. A review of research on object detection based on deep learning[J]. Journal of Physics: Conference Series, 2020, 1684(1):012028.
- [6] WANG Y B, WANG Y J, DANG L F. Video detection of foreign objects on the surface of belt conveyor underground coal mine based on improved SSD[J]. Journal of Ambient Intelligence and Humanized Computing, 2020:1-10.
- [7] LI J Y, SU Z F, GENG J H, et al. Real-time detection of steel strip surface defects based on improved YOLO detection network[J]. IFAC-PapersOnLine, 2018, 51(21):76-81.
- [8] XU Y Y, LI D W, XIE Q, et al. Automatic defect detection and segmentation of tunnel surface using modified Mask R-CNN[J]. Measurement, 2021, 178:109316.
- [9] SUN X H, GU J N, HUANG R, et al. Surface defects recognition of wheel hub based on improved faster R-CNN[J]. Electronics, 2019, 8(5):481.

(下转第 202 页)

车辆的运动稳定性。对转向架的构架端部测点数据进行 0.5 Hz~10 Hz 带通滤波,可以得到以下结果:Mc1 车和 T 车在最高试验速度 70 km/h 下,构架横向振动加速度幅值小于标准规定的限值,转向架未出现失稳现象,满足标准要求。




图7 转向架的构架端部振动加速度(AW0)




图8 转向架的构架端部振动加速度(AW3)

### 3 结语

该型有轨电车在运行时头尾车和中间车的动力学指标是存在差异的,即中间车的运行品质高于头尾车。在中

间车当中,动车的运行品质优于拖车。加载之后,车辆的稳定性得到明显的提升,除轮轴横向力有所上升外,其他指标均下降,车辆运行更加安全稳定。Mc1 车前端以及后端稳定性较差,中段车体较为稳定。新车设计时虽然要考虑车体轻量化,但不可使车体过轻造成相应动力学指征恶化,影响行车品质。

#### 参考文献:

- [1] 贾璐,曾京,池茂儒. 车辆系统横向运动稳定性评判的数值仿真研究[J]. 铁道车辆,2011,49(9):1-7.
- [2] 李玉青. 100%低地板轻轨车辆动力学性能研究[D]. 成都:西南交通大学,2016.
- [3] 曹志礼. 铁道车辆振动性能评定方法与自动数据处理[J]. 铁道车辆,1981,19(3):10-18.
- [4] 徐士恒,王勇,石俊杰.“车-货”耦合的高速货运动车组动力学性能分析[J]. 机械制造与自动化,2021,50(2):22-24,28.
- [5] MA Y W, MARKINE V L, MASHAL AA, et al. Effect of wheel-rail interface parameters on contact stability in explicit finite element analysis[J]. Proceedings of the Institution of Mechanical Engineers. Part F, Journal of Rail and Rapid Transit, 2018, 232(6):1879-1894.
- [6] POLACH O. Characteristic parameters of nonlinear wheel/rail contact geometry [J]. Vehicle System Dynamics, 2010, 48(Suppl.1):19-36.
- [7] WILSON N, WU H M, TOURNAYH, et al. Effects of wheel/rail contact patterns and vehicle parameters on lateral stability [J]. Vehicle System Dynamics, 2010, 48(suppl.1):487-503.
- [8] 周劲松,赵洪伦,王福天. 铁道车辆蛇行运动稳定性最优化研究[J]. 铁道车辆,1995(1):3-9.
- [9] KO E S, NOH I C, LEE H S. A critical speed test of high speed train by small - scaled derailment simulator [J]. International Journal of Advanced Railway, 2015, 3(1):193-199.
- [10] 罗仁,石怀龙. 铁道车辆系统动力学及应用[M]. 成都:西南交通大学出版社,2018.
- [11] GB 5599—1985 铁道车辆动力学性能评定和试验鉴定规范[S].
- [12] UIC518—2009 铁路车辆动态性能角度对铁路车辆的测试和验收、安全性、轨道疲劳、运行性能[S].

收稿日期:2021-05-17

(上接第181页)

- [10] 南虎,麻晓晶,赵海博,等. 基于YOLOv3框架的高分辨率电镜图像原子峰位置检测[J]. 物理学报,2021,70(7):076803.
- [11] 王宸,张秀峰,刘超,等. 改进YOLOv3的轮毂焊缝缺陷检测[J]. 光学精密工程,2021,29(8):1942-1954.
- [12] JU M, LUO H, WANG Z, et al. The application of improved YOLO V<sub>3</sub> in multi-scale target detection[J]. Applied Sciences, 2019, 9(18):3775.
- [13] XU Y M, ZHANG K, WANG L. Metal surface defect detection using modified YOLO[J]. Algorithms, 2021, 14(9):257.
- [14] NING Z, MI Z W. Research on surface defect detection algorithm of strip steel based on improved YOLO V<sub>3</sub> [J]. Journal of Physics:Conference Series, 2021, 1907(1):012015.
- [15] KUMAR K, LI J P, ZAIN-UL-ABIDIN, et al. Content based image retrieval using gray scale weighted average method [J]. International Journal of Advanced Computer Science and Applications, 2016, 7(1):1-6.
- [16] FAN L W, ZHANG F, FAN H, et al. Brief review of image

denoising techniques [J]. Visual Computing for Industry, Biomedicine, and Art, 2019, 2(1):7.

- [17] MOESLUND T B. BLOB analysis[M]//Undergraduate Topics in Computer Science. London, Springer London; 2012:103-115.
- [18] CHANG Y L, ANAGAW A, CHANG L N, et al. Ship detection based on YOLOv2 for SAR imagery[J]. Remote Sensing, 2019, 11(7):786.
- [19] SOLAK S, ALTINIUK U. A new method for classifying nuts using image processing and k-means++ clustering [J]. Journal of Food Process Engineering, 2018, 41(7):12859.
- [20] AHMED M, SERAJ R, ISLAM S M S. The k-means algorithm: a comprehensive survey and performance evaluation [J]. Electronics, 2020, 9(8):1295.
- [21] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016:770-778.

收稿日期:2022-05-11