

DOI:10.16136/j.joel.2022.01.0291

# 基于灰度-梯度共生矩阵的车轮踏面缺陷聚类分析

刘二林<sup>1\*</sup>, 刘成刚<sup>1</sup>, 姜香菊<sup>2</sup>, 杨尚梅<sup>3</sup>

(1. 兰州交通大学 机电工程学院, 甘肃 兰州 730070; 2. 兰州交通大学 自动化与电气工程学院, 甘肃 兰州 730070; 3. 兰州工业学院 电气工程学院, 甘肃 兰州 730000)

**摘要:** 车轮作为列车走行部的关键部件之一, 其踏面产生缺陷后会直接影响到列车的运行安全。为了能够在检测时准确识别车轮踏面缺陷不同类型, 提出一种基于灰度-梯度共生矩阵的纹理特征提取方法, 对踏面图像的灰度和梯度特征分析之后, 根据灰度-梯度共生矩阵提取踏面图像纹理特征矢量, 再结合 K-均值(K-means)聚类优化算法对踏面缺陷特征量进行聚类, 从而将踏面缺陷类型进行分类, 并将分类结果用可视化数据显示。实验结果表明, 采用上述所提方法, 对车轮踏面缺陷不同类型的分类识别精度达 96% 以上。

**关键词:** 踏面缺陷; 灰度-梯度共生矩阵; 纹理特征; K-均值(K-means)聚类

**中图分类号:** TP391.41 **文献标识码:** A **文章编号:** 1005-0086(2022)01-0053-08

## Cluster analysis of wheel tread defects based on gray-gradient co-occurrence matrix

LIU Erlin<sup>1\*</sup>, LIU Chenggang<sup>1</sup>, JIANG Xiangju<sup>2</sup>, YANG Shangmei<sup>3</sup>

(1. School of Mechanical and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou, Gansu 730070, China; 2. School of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou, Gansu 730070, China; 3. School of Electrical Engineering, Lanzhou Institute of Technology, Lanzhou, Gansu 730000, China)

**Abstract:** Wheels are one of the key components of the running part of the train. Defects in its tread will directly affect the safety of train operation. In order to accurately identify different types of wheel tread defects during inspection, a texture feature extraction method based on gray-gradient co-occurrence matrix is proposed. After analyzing the gray and gradient features of the tread image, image texture feature vector is extracted according to the gray-gradient co-occurrence matrix. Then combined with the K-means clustering optimization algorithm to cluster the characteristics of tread defects, thereby classifying the types of tread defects, and displaying the classification results with visual data. The experimental results show that the accuracy of classifying and identifying different types of wheel tread defects is over 96% by using the above-mentioned algorithm.

**Key words:** tread defect; gray-gradient co-occurrence matrix; texture feature; K-means cluster

## 1 引言

随着我国高速列车和重载列车的快速发展, 铁路安全问题愈加引起广泛关注, 其踏面在长期与钢轨的接触过程中, 除了承受与钢轨的静动载荷之外, 还受到闸瓦制动造成的热应力和污水、油渍的腐蚀等, 容易引起轮对的各种损伤和接触疲

劳缺陷。带有缺陷的车轮若继续服役列车时, 将会对列车其他零部件和钢轨造成冲击, 严重时威胁到乘客的生命和财产安全<sup>[1]</sup>。因此, 对带有缺陷的车轮准确检测并及时维护, 是铁路安全运营的基本保障。

自 20 世纪 80 年代初期以来, 国内外研究者对车轮踏面的缺陷检测进行大量研究, 主要检测

\* E-mail: 64546147@qq.com

收稿日期: 2021-04-29 修订日期: 2021-06-01

基金项目: 甘肃省兰州市人才创新创业项目(2020-RC-105)资助项目

方法有振动加速度法<sup>[2,3]</sup>、电磁超声法、冲击载荷法、超声波探伤法等,上述检测方法由于对装置的安装精度要求高、技术难度大,所以呈现出不同的局限性。随着计算机技术的崛起,数字图像处理技术和数字信号处理技术为踏面缺陷检测提供了有效的技术支持,很大程度上提高了检测精度及检测效率<sup>[4,5]</sup>。文献[6]采用了一种改进的 Canny 算子对车轮踏面的损伤边缘进行提取,但没有判定出具体的损伤类型。文献[7]采用 Canny-YOLOv3 两步检测法,将边缘检测法与深度学习相结合,能够准确地检测出踏面损伤的位置和区域。文献[8]采用了平稳小波自适应阈值算法提取踏面区域,再根据踏面缺陷特征实现了对剥离和擦伤两种缺陷类型的识别。文献[9]采用自适应形态提升小波的方法对轴箱的垂向振动信号的周期性冲击成分进行提取和分析,对车轮踏面擦伤的识别率达 96.2%。文献[10]采用图像灰度共生矩阵提取踏面缺陷纹理特征,并通过支持向量机对损伤结果进行判定。文献[11]采用了高阶谱对擦伤车轮产生的振动信号进行提取,并结合粒子群与支持向量实现了对擦伤的识别及擦伤等级的确定。但上述文献将车轮踏面的缺陷类型简单地看作二分类问题,从而影响对缺陷判别的准确性。因此,本文提出一种基于灰度-梯度共生矩阵方

法,首先分析踏面图像的灰度和梯度特征,并对踏面缺陷纹理特征进行提取,然后采用聚类分析方法对踏面缺陷类型进行分类识别。最后实验结果表明所提方法能够对车轮踏面缺陷的不同类型进行分类识别。

## 2 踏面图像灰度-梯度特征分析

以某铁路局检修作业车间拍摄到的车轮踏面图片为例,实际的车轮踏面可能包括正常区域、缺陷区域、阴影区域等,踏面图如图 1 所示。正常区域由于与钢轨踏面的长期接触表面比较光滑;缺陷区域由于高速运行时与钢轨的冲击造成对轮疲劳损伤形成掉块或点蚀等缺陷;阴影区域包括锈迹、油渍等,该区域往往靠近车轮轮缘处,因为该区域只有在列车通过曲线或道岔时才与钢轨内侧接触。

如图 2 所示为图 1 的灰度分区图,图中 A、B、C 3 条直线以纵向穿过踏面正常区域、缺陷区域、阴影区域;D、E 两条直线以横向穿过踏面阴影区域、正常区域和缺陷区域;图 3 为图 1 的踏面梯度图。图 4(a)和(b)为 5 条线(A、B、C、D、E)所在区域的缺陷灰度分布曲线,图 4(c)和(d)为五条直线所在区域的缺陷梯度分布曲线。

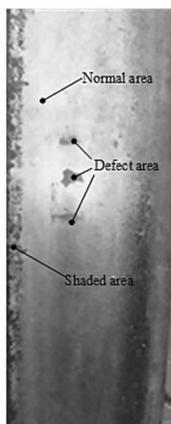


图 1 踏面图  
Fig. 1 Tread image

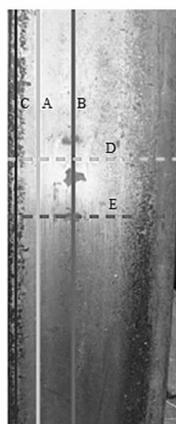


图 2 灰度分区图  
Fig. 2 Gray scale image



图 3 踏面梯度图  
Fig. 3 Tread gradient image

经过对不同区域图像的灰度和梯度分布曲线分析可知:对比图 4(a)和(b)得出正常踏面区域的灰度值最大,在含有缺陷区域的位置灰度值明显小于正常区域的灰度值,且在正常区域和缺陷区域的交界处图像的灰度值会骤变,对于阴影区域而言由于表面比较暗,一般情况下灰度值均小于正常区域和缺陷区域,在局部区域图 4(a)(175—183 行)由于没有锈迹或者油渍的干扰显示出局部的灰度值变化较

大;对比图 4(c)和(d)得出正常踏面区域的梯度值较小,阴影区域和缺陷区域梯度值较大(由于阴影区域正好处于轮缘附近,边缘特征比较明显,所以呈现出梯度值突然变大的情况如图 4(c)所示)。其次,在局部范围内图 4(d)(130—146 列)含有缺陷的区域由于缺陷部分与正常部分有明显的边界,所以梯度值变化均大于其他区域。车轮踏面灰度、梯度特征分布见表 1 所示。

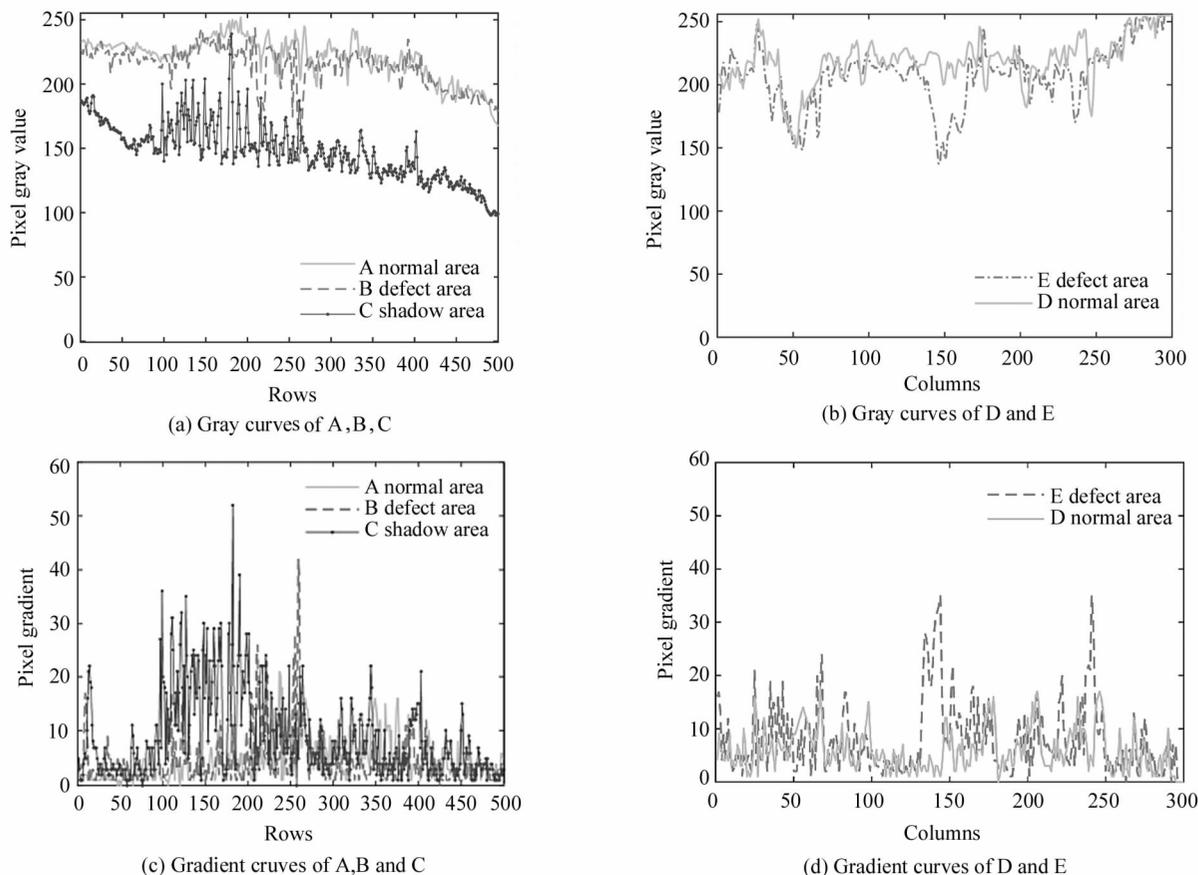


图 4 车轮踏面缺陷灰度、梯度分布曲线

Fig. 4 Grayscale and gradient distribution curve of wheelset tread defects

表 1 车轮踏面灰度、梯度特征分布

Tab. 1 Distribution of gray and gradient characteristics of wheelset tread

Tread image	Internal features		Edge feature	
	Gray value	Gradient value	Gray value	Gradient value
Normal area	high	low	—	—
Defect area	low	high	plummet	surge
Shadow area	lowest	medium	local enlargement	medium

### 3 灰度-梯度共生矩阵

#### 3.1 基本原理

灰度-梯度共生矩阵 (gray-gradient co-occurrence matrix, GGCM) 模型是 20 世纪 80 年代由洪继光首先提出<sup>[12]</sup>。GGCM 集中反应图像在灰度和梯度两方面的基本要素, 图像的灰度值是构成图像的基础, 能够描述图像具体内容, 而梯度值是构成图像边缘轮廓信息的关键要素, 提供图像的主要信息。因此, 采用灰度-梯度共生矩阵能够从像素点领域描述图像灰度和梯度之间的相互关系, 并全面反应图像的纹理特征信息。

GGCM 模型共生矩阵  $\mathbf{H}$  内的元素  $h(x, y)$  定义在归一化的灰度图像  $F(i, j)$  和归一化的梯度图像  $G(i, j)$  中共同含有灰度值为  $x$  和梯度值为  $y$  的像素点总数。统计归一化后的灰度图像  $F(i, j)$  和梯度图像  $G(i, j)$  中  $x=F(i, j)$  和  $y=G(i, j)$  的像素点对数, 得到共生矩阵  $\mathbf{H}$  内的元素  $h(x, y)$ , 为了减小计算量, 需要对灰度、梯度以及灰度-梯度共生矩阵做归一化处理。

设图像大小为  $M \times N$  的图像  $f(i, j)$ , 归一化的灰度图像定义为式(1):

$$F(i, j) = \frac{f(i, j) \cdot (L_{gy} - 1)}{f_{\max}} + 1, \quad (1)$$

式中,  $f(i, j)$  为原图像在点  $(i, j)$  处的灰度值,  $F(i, j)$

为变换后的图像在点 $(i, j)$ 处的灰度值,  $f_{\max}$ 为原图像的最大灰度值,  $L_{gy}$ 为归一化后的最大灰度值, 文中取  $L_{gy} = 16$ ;

归一化后的梯度图像定义为式(2):

$$G(i, j) = \frac{g(i, j) \cdot (L_{gy} - 1)}{g_{\max}} + 1, \quad (2)$$

式中,  $g(i, j)$ 为原图像在点 $(i, j)$ 处的梯度值,  $G(i, j)$ 为变换后的图像在点 $(i, j)$ 处的梯度值,  $g_{\max}$ 为原图像的最大梯度值,  $L_{gy}$ 为归一化后的最大梯度值, 本文中取  $L_{gt} = 16$ ,  $g(i, j)$ 由 Sobel 算子在水平、垂直方向的梯度法人平方和求得, 如式(3):

$$g(i, j) = \sqrt{g_x^2 + g_y^2}, \quad (3)$$

其中,

$$\begin{aligned} g_x &= f(i + 1, j) - f(i, j), \\ g_y &= f(i, j + 1) - f(i, j). \end{aligned} \quad (4)$$

统计归一化的灰度矩阵  $F(i, j)$ 和归一化的梯度

矩阵  $G(i, j)$ 中含  $x = F(i, j)$ 和  $y = G(i, j)$ 的像素点对数。

$$x = F(i, j), x \in [1, L_{gy}], \quad (5)$$

$$y = G(i, j), y \in [1, L_{gt}]. \quad (6)$$

归一化的灰度-梯度共生矩阵为  $h'(x, y)$ :

$$h'(x, y) = \frac{h(x, y)}{\sum_{x=0}^{L_{gy}} \sum_{y=0}^{L_{gt}} h(x, y)}. \quad (7)$$

### 3.2 车轮踏面典型缺陷纹理特征提取

GGCM 含有 15 个纹理特征参数, 分别为小梯度优势、大梯度优势、灰度不均匀性、梯度不均匀性、能量、平均灰度、平均梯度、灰度均方差、梯度均方差、相关度、灰度熵、梯度熵、混合熵、惯性、逆差距<sup>[13]</sup>。灰度-梯度共生矩阵特征量如表 2 所示。

为了便于后续对车轮踏面缺陷类型进行分类, 选取踏面剥离、踏面擦伤、踏面裂纹、正常踏面 4 种

表 2 灰度-梯度共生矩阵特征量

Tab. 2 Features of gray-gradient co-occurrence matrix

Feature amount	Expression
Small gradient advantage	$T_1 = [\sum_i \sum_j \frac{h(x, y)}{j^2}] / [\sum_i \sum_j h(x, y)]$
Big gradient advantage	$T_2 = [\sum_i \sum_j h(x, y) j^2] / [\sum_i \sum_j h(x, y)]$
Inhomogeneity of gray distribution	$T_3 = \{ \sum_i [\sum_j h(x, y)^2] \} / [\sum_i \sum_j h(x, y)]$
Inhomogeneity of gradient distribution	$T_4 = \{ \sum_j [\sum_i h(x, y)^2] \} / [\sum_i \sum_j h(x, y)]$
Energy	$T_5 = \sum_i \sum_j [h'(x, y)]^2$
Mean Gray Value	$T_6 = \sum_i i [\sum_j h'(x, y)]$
Gradient mean	$T_7 = \sum_j j [\sum_i h'(x, y)]$
Gray standard deviation	$T_8 = \{ \sum_i (i - T_6)^2 [\sum_j h'(x, y)] \}^{1/2}$
Gradient standard deviation	$T_9 = \{ \sum_j (j - T_7)^2 [\sum_i h'(x, y)] \}^{1/2}$
Correlation	$T_{10} = \sum_i [\sum_j (i - T_6)(j - T_7) h'(x, y)]$
Gray Entropy	$T_{11} = - \{ \sum_i [\sum_j h'(x, y)] \log [\sum_j h'(x, y)] \}$
Gradient entropy	$T_{12} = - \{ \sum_j [\sum_i h'(x, y)] \log [\sum_i h'(x, y)] \}$
Mixed entropy	$T_{13} = - \sum_i \sum_j h'(x, y) \log h'(x, y)$
Inertia	$T_{14} = \sum_i \sum_j (i - j)^2 h'(x, y)$
Moment of inverse difference	$T_{15} = \sum_i \sum_j \frac{1}{1 + (i - j)^2} h'(x, y)$

类型各 20 张,共 80 个样本,每种踏面缺陷类型包含 15 个纹理特征量( $T_1-T_{15}$ ),通过归一化处理之后,对各自的纹理特征量进行提取,提取到踏面缺陷不

同类型归一化后的纹理特征值如表 3 所示。从表中可以看出在同一个特征量下,不同的踏面缺陷类型在数值上具有不同的区间范围,因此可以通过不同

表 3 踏面缺陷不同类型归一化后的纹理特征值  
Tab. 3 Normalized texture feature values of different types of treads

Type	No.	Textur feature														
		$T_1$	$T_2$	$T_3$	$T_4$	$T_5$	$T_6$	$T_7$	$T_8$	$T_9$	$T_{10}$	$T_{11}$	$T_{12}$	$T_{13}$	$T_{14}$	$T_{15}$
Normal	1	0.109 5	27.11 5	20.83 2	0.000 7	0.177 2	15.02 3	4.733 5	25.94 7	50.51 5	155.5 4	-861.2 6	-36.06 1	1.012 0	110.8 4	0.012 4
	⋮	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---
	20	0.106 2	25.15 7	21.91 4	0.000 8	0.171 7	14.55 8	4.305 8	24.12 0	48.72 8	152.8 4	-758.0 5	-59.93 8	1.009 3	108.9 4	0.012 6
Crack	1	0.309 0	18.45 5	0.433 2	0.007 1	0.078 9	12.52 5	30.55 9	50.53 6	86.90 6	930.9 9	-9.581 6	-106.4 9	1.634 6	28.13 9	0.028 5
	⋮	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---
	20	0.286 4	19.16 4	0.402 6	0.002 8	0.137 4	10.59 7	4.015 2	54.27 6	87.16 9	904.6 9	-44.56 9	-120.2 6	1.888 8	22.57 4	0.097 3
Peel off	1	0.177 0	21.89 8	2.027 0	0.027 6	0.035 6	13.22 0	3.969 6	57.076 0	90.699 0	1.401. 2	-33.632	-243.5 9	1.645 3	84.905	0.030 5
	⋮	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---
	20	0.171 1	23.991 6	2.920 7	0.013 3	0.021 4	13.662 8	4.425 3	57.936 0	85.387 9	1.450.8 7	-37.096	-246.2 8	1.849 0	90.153 2	0.074 6
Bruise	1	0.227 6	19.004 5	0.006 5	0.015 6	0.052 7	12.310 8	3.877 4	45.709 4	79.287 1	659.12 4	-34.76 4	-125.9 5	1.533 0	57.739 1	0.026 1
	⋮	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---
	20	0.260 5	17.176 4	0.087 0	0.016 4	0.065 8	11.396 4	3.627 2	44.106 1	70.561 1	506.04 9	-37.58 6	-148.2 5	1.648 3	59.540 4	0.057 0

数值区间范围即可确定出踏面缺陷类型。

## 4 聚类分析

### 4.1 传统 K-均值聚类算法

聚类分析是无监督学习技术,它能够在无先天知识经验的情况下挖掘数据内部结构对数据进行分类<sup>[14]</sup>。K-均值(K-means)聚类是无监督学习算法的一种,主要原理是采用最小化误差函数将数据划分成预定的 K 类,使得同一类数据中相似程度较高,不同类数据中差异较大。K-均值聚类算法的实现步骤如下:

- 1) 初始化聚类个数和聚类中心。
- 2) 遍历所有的数据,并计算各数据到每个聚类中心的欧氏距离  $dist$ ,确定出各聚类中心的位置。

假设给定数据集  $D = \{x_i | x_i \in R^p, i = 1, 2, \dots, n\}$ ,  $p$  为数据维数,则聚类准则目标函数为式(8)所示:

$$SSE = \sum_{i=1}^k \sum_{x_j \in C_i} dist(c_i, x)^2, \quad (8)$$

式中,  $k$  为聚类中心的个数,  $c_i$  表示第几个聚类中心,  $dist$  为欧氏距离,表达式为:

$$dist(x_i, x_j) = \sqrt{(x_i - x_j)^T(x_i - x_j)}. \quad (9)$$

3) 更新聚类中心,将每个类别中所包含对象的对应值作为聚类中心,进而获得目标函数值。

4) 判定目标函数与聚类中心是否相同,若相同,输出结果;若不相同,返回步骤 2) — 3)。

### 4.2 K-均值初始聚类中心优化算法

由于传统的 K-均值聚类算法中初始聚类中心的选择是随机的,而这种随机性会导致聚类结果陷入局部最优解,使聚类效果达不到预期。为此,提出一种基于样本数据密度和最远距离的方法,去确定初始聚类中心<sup>[15]</sup>。在确定聚类中心之前要选择聚类个数,由于文中的聚类个数非常明确,即为车轮踏面的缺陷故障类型(裂纹、剥离、擦伤)和正常踏面等 4 种情况,故聚类个数  $k=4$ 。K-均值聚类改进算法步骤如下:

- 1) 确定聚类个数( $k=4$ )。
- 2) 选择初始聚类中心。
  - a) 计算样本数据间的欧式距离  $dist$ ,如式(9)所示。假设给定聚类数据集  $D = \{x_i | x_i \in R^p, i = 1, 2, \dots, n\}$ ,  $p$  为数据维数,本文中  $p=2$ 。
  - b) 计算样本数据间的平均距离  $avgdist$ ,如式(10)所示:

$$avgdist = \frac{1}{C_n^2} \sum_{i=1}^n \sum_{j=1}^i dist(x_i, x_j), \quad (10)$$

式中,  $n$  为聚类样本数量,  $C_n^2$  为样本数据集中任意两点的随机组合。

c) 计算以任意数据样本  $x_i$  为中心, 以平均距离  $avgdist$  为半径的  $\alpha$  领域内所含样本数据  $dist_1, dist_2 \dots dist_i$  的个数, 并定义所含样本数据最多的集合为  $D$ 。

d) 在集合  $D$  中遍历找出样本密度最高的点作为第一个聚类中心点  $c_1$ , 将距离  $c_1$  最远的点  $c_2$  作为第二个聚类中心点。

e) 按照步骤 d) 依次求取, 直到找到第  $k$  个聚类中心为止。

3) 遍历所有的数据, 并计算各数据到每个聚类中心的欧氏距离  $dist$ , 确定出各聚类中心的位置。

4) 更新聚类中心, 将每个类别中所包含对象的对应值作为聚类中心, 进而获得目标函数值。

5) 判定目标函数与聚类中心是否相同, 若相同, 输出结果; 若不相同, 返回步骤 3) — 4)。

### 4.3 聚类效果分析

对表 2 中已经提取的车轮踏面纹理特征量数据, 选取纹理特征参数 ( $T_1, T_5, T_{14}$ ) 进行数据分类。在提取到的踏面纹理特征量数据中含有踏面剥离、踏面擦伤、踏面裂纹和正常踏面等各 20 张, 每种缺陷类型含 15 个纹理特征量 ( $T_1-T_{15}$ ), 特征量  $T_1, T_5, T_{14}$  聚类可视化数据如图 5(a)、(b)、(c) 所示。

通过 3 个特征量 ( $T_1, T_5, T_{14}$ ) 对踏面 4 种类型共 80 个样本进行聚类分析, 聚类结果图 5(a) 为纹理特征量  $T_1$  对样本数据的聚类效果图, 图中可以看出踏面擦伤的一个样本数据被错分到踏面裂纹样本数

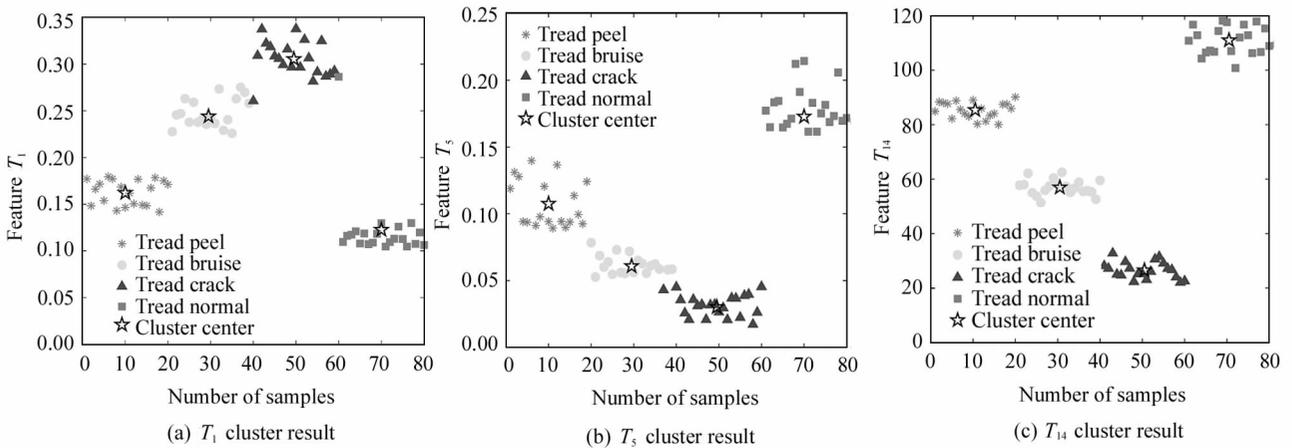


图 5 特征量  $T_1, T_5, T_{14}$  聚类可视化数据

Fig. 5 Cluster visualization data of feature  $T_1, T_5, T_{14}$

据中, 踏面裂纹的一个样本数据被错分到正常踏面样本数据中, 其他两类数据能够很好地被聚类, 并且达到了较高的聚类精度。图 5(b) 为纹理特征量  $T_5$  对样本数据的聚类效果图, 图中依据样本数量可以看出, 踏面剥离的一个样本数据被错分到踏面擦伤数据样本中, 踏面剥离的一个样本数据被错分到踏面裂纹数据样本中, 正常踏面样本数据被完全聚类, 上述样本之间存在错分的原因在于 K-均值聚类算法本身是依据样本到聚类中心的距离分类的, 所以在样本数据间相似程度非常大时会存在错分类情况。图 5(c) 为纹理特征量  $T_{14}$  对样本数据的聚类效果图, 从样本数据特征上可以看出, 该类样本数据间的差异性较大, 因此在算法迭代到第 10 次时, 样本数据被准确完全聚类。

踏面缺陷类型聚类识别精度如表 3 所示, 其聚类识别精度图如图 6 所示。采用  $T_1, T_5, T_{14}$  这 3 种纹理特征量对踏面剥离、踏面擦伤、踏面裂纹和正常踏面的平均聚类识别精度分别达到了 98.33%、96.6%、96.97%、98.41%。

表 3 踏面缺陷类型聚类识别精度

Tab. 3 Clustering recognition accuracy of tread defect types

Texture feature	Clustering accuracy/%			
	Tread peel	Tread bruise	Tread crack	Tread normal
$T_1$	100	95	100	95.24
$T_5$	95	95	90.9	100
$T_{14}$	100	100	100	100

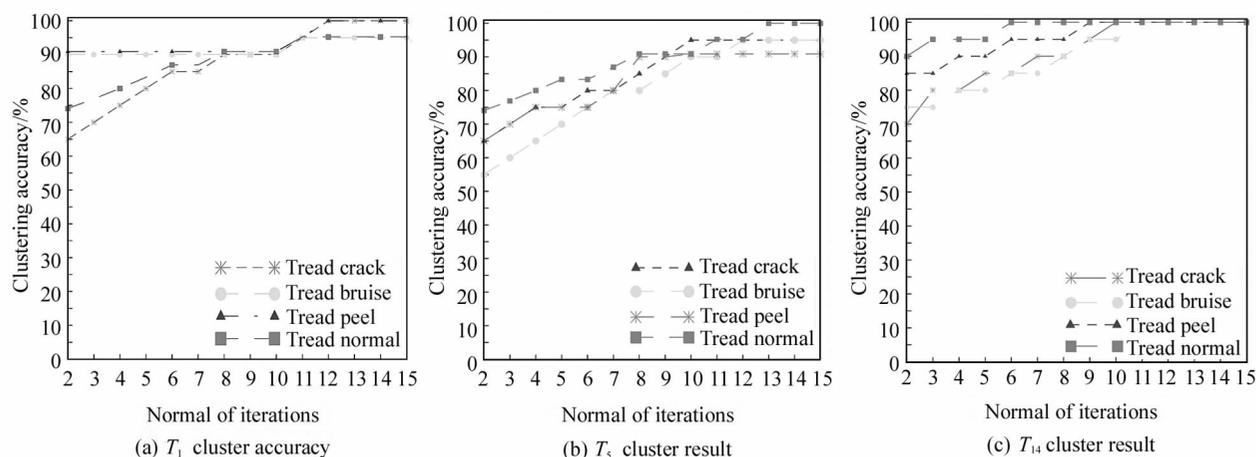


图 6 聚类识别精度图

Fig. 6 Cluster recognition accuracy image

## 5 结 论

本文从灰度、梯度两方面对车轮踏面图像进行特征分析之后,采用灰度-梯度共生矩阵对踏面纹理进行综合描述,避免了用单一纹理特征描述时的对踏面缺陷细节特征表达不完整问题,并提取出了 15 个典型的纹理特征量,用于对踏面缺陷的识别分析;通过 K-均值聚类算法,对初始聚类中心进行优化,有效的避免因聚类中心的选取不佳导致对聚类效果的影响,通过优化后的算法能够对正常踏面、踏面擦伤、踏面剥离、踏面裂纹等 4 种类型的踏面进行聚类,借助可视化数据显示证明了具有较高的聚类识别精度。本文中所提出的方法应用于车轮理想化的正常踏面和踏面擦伤、踏面剥离、踏面裂纹等 4 种类型的识别,对于踏面其他的缺陷类型的识别未做继续研究,在后续研究中应采用更加贴合实际的踏面图像,此外,该方法为车轮踏面缺陷的分类识别研究提供了新思路。

### 参考文献:

- [1] LI W. Discussion on the method of determining wheel tread defects and their causes[J]. Science and Technology Information, 2016, 14(15): 45-46+48.  
李伟. 车轮踏面缺陷的判定方法及其产生原因的探讨[J]. 科技资讯, 2016, 14(15): 4546+48.
- [2] KRUMMENACHER G, CHENG S O, KOLLER S, et al. Wheel defect detection with machine learning[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 19(4): 1176-1187.
- [3] NENOV N, DIMITROV E, VASILEV V, et al. Sensor system of detecting defects in wheels of railway vehicles running at operational speed[C]//34th International Spring Seminar on Electronics Technology, May 11-15, 2011, Tratan-ska Lomnica, Slovakia. New York: IEEE, 2011.
- [4] YAO S C, CAI L Y, LIU Z. Multi-scale rotating face detection method based on cascade regression network[J]. Journal of Electronic Measurement and Instrument, 2019, 33(5): 32-38.  
姚树春, 蔡黎亚, 刘正. 基于级联回归网络的多尺度旋转人脸检测方法[J]. 电子测量与仪器学报, 2019, 33(5): 32-38.
- [5] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [6] ZHANG Z T, HOU T. Train wheel tread damage edge extraction based on improved Canny algorithm[J]. Railway Standard Design, 2018, 62(1): 148-150.  
张志腾, 侯涛. 基于改进 Canny 算法的列车车轮踏面损伤边缘提取[J]. 铁道标准设计, 2018, 62(1): 148-150.
- [7] HE J, YU H Y, ZHANG C F, et al. Train wheel tread damage detection based on Canny-YOLOv3[J]. Journal of Electronic Measurement and Instrument, 2019, 33(12): 25-30.  
何静, 余昊宇, 张昌凡, 等. 基于 Canny-YOLOv3 的列车车轮对踏面损伤检测[J]. 电子测量与仪器学报, 2019, 33(12): 25-30.
- [8] ZHAO Y, FANG Z D, TIAN L L. Image area extraction of

- train wheel tread defects[J]. Optics and Precision Engineering, 2009, 17(4): 901-908.
- 赵勇, 方宗德, 田丽丽. 列车车轮踏面缺陷的图像区域提取[J]. 光学精密工程, 2009, 17(4): 901-908.
- [9] DENG W H, JIN W D. A new method of wheel tread scratch recognition based on adaptive shapelifting wavelet[J]. Vibration and Shock, 2015, 34(21): 45-48.
- 邓文豪, 金炜东. 一种基于自适应形态提升小波的车轮踏面擦伤识别新方法[J]. 振动与冲击, 2015, 34(21): 45-48.
- [10] LV H B. Research on locomotive wheelset damage detection under machine vision system[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2017.
- 吕洪波. 机器视觉系统下的机车轮对踏面损伤检测研究[D]. 南京: 南京航空航天大学, 2017.
- [11] ZHAO R, SHI H M. Research on high-speed train wheel scratch recognition algorithm based on high-order spectral feature extraction[J]. Chinese Journal of Mechanical Engineering, 2017, 53(6): 102-109.
- 赵蓉, 史红梅. 基于高阶谱特征提取的高速列车车轮擦伤识别算法研究[J]. 机械工程学报, 2017, 53(6): 102-109.
- [12] HONG J G. Gray-gradient co-occurrence matrix texture analysis method[J]. Acta Automatica Sinica, 1984, (1): 22-25.
- 洪继光. 灰度-梯度共生矩阵纹理分析方法[J]. 自动化学报, 1984, (1): 22-25.
- [13] FENG B, LI Z T, HUA G L. Image spam recognition method based on gray-gradient co-occurrence matrix [J]. Journal on Communications, 2013, 34(S2): 1-4.
- 冯兵, 李芝棠, 花广路. 基于灰度-梯度共生矩阵的图像型垃圾邮件识别方法[J]. 通信学报, 2013, 34(S2): 1-4.
- [14] DAI G, CUI W, ZHANG Y, et al. Cluster analysis of weld defects based on gray-gradient cooccurrence matrix [J]. China Safety Science Journal, 2013, 23(3): 79-85.
- 戴光, 崔巍, 张颖, 等. 基于灰度-梯度共生矩阵的焊缝缺陷聚类分析[J]. 中国安全科学学报, 2013, 23(3): 79-85.
- [15] ZHANG S J, ZHAO H C. Research on the optimal clustering number and initial clustering center point selection algorithm[J]. Computer Application Research, 2017, 34(6): 1617-1620.
- 张素洁, 赵怀慈. 最优聚类个数和初始聚类中心点选取算法研究[J]. 计算机应用研究, 2017, 34(6): 1617-1620.

#### 作者简介:

刘二林 (1977—), 男, 硕士, 副教授, 硕士生导师, 主要从事检测技术、机电一体化设计、计算机控制方面的研究。