

DOI:10.19651/j.cnki.emt.2416061

基于融合纹理特征的轮胎磨损程度检测方法^{*}

欧阳杰¹ 张向文^{1,2} 刘沛钊³ 陈凯文³

(1. 桂林电子科技大学电子工程与自动化学院 桂林 541004; 2. 智能综合自动化广西高校重点实验室
(桂林电子科技大学) 桂林 541004; 3. 广东合微集成电路技术有限公司 东莞 523808)

摘要: 轮胎磨损直接影响汽车行驶的安全性和稳定性,通过检测轮胎磨损程度可以及时发现轮胎异常状态并进行处理,提高汽车行驶的安全性。基于胎内传感器的轮胎磨损程度检测方法成本较高且安装过程繁琐,基于图像的检测方法则需要较多样本且检测准确性不高,本文提出一种基于融合纹理特征的轮胎磨损程度检测方法。采集5种不同磨损程度的25张轮胎图像构建训练集,每一张图像均匀裁剪为12张子图像,对每一张子图像通过中值滤波后分别提取灰度共生矩阵和局部二值模式特征,使用主成分分析和拼接融合方法获得融合特征。基于融合特征通过麻雀搜索算法和随机森林方法建立磨损程度分类器。最后,利用采集的225张不同磨损程度的轮胎图像进行测试。结果显示,平均检测准确率达到97.33%,相比单一特征及其他分类方法下准确率明显提高,可以应用于轮胎磨损程度的快速准确检测。

关键词: 轮胎磨损; 纹理特征; 主成分分析; 麻雀搜索算法; 随机森林; 加权投票

中图分类号: TP391.41; TN929.5 文献标识码: A 国家标准学科分类代码: 510.405

Tire wear degree detection method based on fused texture features

Ouyang Jie¹ Zhang Xiangwen^{1,2} Liu Peizhao³ Chen Kaiwen³

(1. School of Electronic Engineering and Automation, Guilin University of Electronic Technology, Guilin 541004, China;
2. Key Laboratory of Intelligence Integrated Automation in Guangxi Universities, Guilin 541004, China;
3. Guangdong Hiway Integrated Circuit Technology Co., Ltd., Dongguan 523808, China)

Abstract: The vehicle safety and stability during the driving process is directly influenced by the tire wear, and the vehicle safety can be improved by detecting the degree of tire wear to find and process the abnormal state of the tire timely. The tire wear degree can be detected with the sensor installed in the tire or the tire image directly. However, the sensor installed method has high cost and cumbersome installation process, and the image-based detection method requires more samples and the detection accuracy is not high. Therefore, a tire wear detection method based on fused texture features is proposed in this paper. The training set was constructed with 25 tire images of 5 different wear degrees, and each image was uniformly cropped into 12 sub-images, and the gray level co-occurrence matrix and local binary patterns features were extracted by median filtering, and the fusion features were obtained by principal component analysis and stitching fusion method. Then, the classifier was trained by sparrow search algorithm and the random forest method with the fusion features. Finally, the algorithm was tested with 225 acquired images of different degrees of tire wear. The results show that the average detection accuracy reaches 97.33%, which is significantly higher than that of a single feature and other classification methods, so, the proposed method can be used to detect the tire wear quickly and accurately.

Keywords: tire wear; texture feature; principal component analysis; sparrow search algorithm; random forest; weighted voting

0 引言

据《中国统计年鉴》报告,2022年末,中国机动车总量

已达到4.15亿辆^[1]。随着机动车数量和公路里程的不断增加,交通事故的发生频率及其致死率也逐渐上升。其中,在高速公路上有高达46%的交通事故是由轮胎故障引起

的^[2]。通过对轮胎状态的检测,获取更多轮胎状态的信息,可以更好地预防由轮胎故障引起的交通事故,从而提高车辆行驶的安全性^[3]。

轮胎磨损是车辆行驶中难以避免的问题,随着磨损的加剧,轮胎的制动性能会显著降低。当车辆轮胎磨损程度低于轮胎磨损极限时,车辆将无法按照既定轨迹行驶,并出现失稳或失控现象^[4-6]。因此,对轮胎磨损程度进行检测,及时发现并更换达到磨损极限的轮胎对于保障行车安全至关重要。

受限于检测技术及准确性的问题,实际中轮胎磨损程度检测主要利用花纹深度尺直接测量胎面沟槽深度获得轮胎磨损程度,但检测过程繁琐,检测结果易受测量人员影响。为减少人为因素,出现了多种非接触式检测方法,主要包括激光三角法检测^[7]、传感器检测^[8-9]和纹理特征检测^[10-11]。激光三角法检测可以计算出轮胎具体磨损值,但需要外部激光发射器,成本较高,且检测精度受轮胎磨损均匀程度的影响^[12-13]。传感器检测需安装轮内传感器,检测成本较高且安装繁琐,检测结果易受传感器影响,检测精度存在差异^[14]。目前,基于图像的轮胎磨损检测技术尚处于起步阶段^[15],通过对胎面纹理区域特征的分析发现,胎面磨损会直接改变轮胎纹理上的形状及深度^[16-17]。基于轮胎图像的纹理特征进行不同轮胎磨损程度的检测是一种有前途的研究方向,然而,纹理特征检测往往需要大量轮胎图像训练。

获取大量不同磨损程度的轮胎图像难度较大,但是,轮胎磨损图像的局部子图像也可以反映轮胎的磨损程度变化,因此,通过对轮胎图像的裁剪,可以将一张轮胎图形裁剪为多张轮胎子图像,从而减少对轮胎图像数量的要求。另外,轮胎表面纹理特征存在显著差异,基于单一的纹理特征难以获得准确的检测结果。灰度共生矩阵(gray level co-occurrence matrix, GLCM)^[18]专注于整体的纹理特征,而局部二值模式(local binary pattern, LBP)^[19]则强调局部的纹理模式,将两类特征进行融合,可以获得更丰富、更具区

分度的特征,从而增强分类模型的判别能力,提高分类精度。

基于目前轮胎磨损检测方法研究现状和存在问题的分析,本文提出一种基于融合纹理特征的轮胎磨损程度检测方法。首先采集 5 种不同磨损程度的 25 张轮胎图像构建轮胎磨损程度数据集,然后对数据集中的轮胎图像进行裁剪等预处理获得 300 张子图像,提取子图像的 GLCM 和 LBP 纹理特征并进行主成分分析(principal component analysis, PCA)降维融合,利用得到的融合纹理特征训练随机森林(random forest, RF)分类器,并用麻雀搜索算法(sparrow search algorithm, SSA)对 RF 参数进行优化,获得训练好的优化的 SSA-RF 分类器。最后,利用 225 测试集图像验证了分类器的有效性和优越性。

1 轮胎磨损程度检测方法实现流程

轮胎磨损程度检测方法实现流程如图 1 所示。首先,通过采集 5 类不同磨损程度轮胎的正面图像各 50 张,构建轮胎磨损程度图像数据集。考虑到在实际中获取不同磨损程度的轮胎图像较为困难,仅用 5 张图像作为轮胎磨损程度的训练集,其余 45 张作为测试集验证最终检测结果。在训练阶段,将每张图像按固定比例均匀裁剪成 12 张子图像,并对子图像进行预处理以减少噪声干扰,在每张子图像上提取 GLCM 特征和 LBP 特征描述轮胎表面的全局及局部纹理信息,采用 PCA 对两类特征分别进行降维再拼接融合得到融合纹理特征,保留主要特征成分的同时减少冗余信息。利用融合纹理特征对 RF 分类器进行训练,同时用 SSA 对 RF 参数进行优化,得到训练好的 SSA-RF 分类器。在测试阶段,对测试图像进行同样的裁剪得到 12 张子图像,采用与训练阶段相同的预处理、特征提取和降维融合得到测试融合特征,通过训练后的 SSA-RF 分类器对测试融合特征进行分类,获得多个检测结果,设计了一种基于子图像位置的加权投票方法对多个检测结果进行集成,得到最终磨损程度的检测结果。

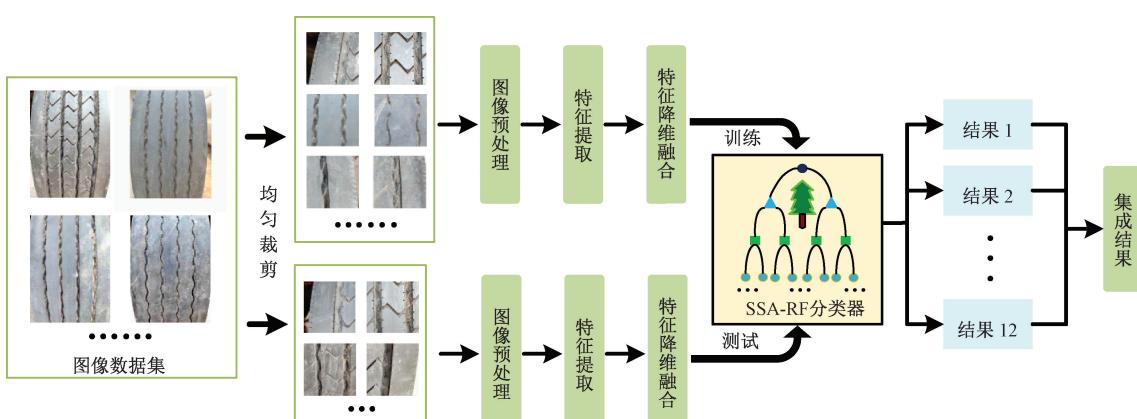


图 1 轮胎磨损程度检测方法实现流程

Fig. 1 Tire wear degree detection method implementation process

2 图像数据集构建和图像预处理

2.1 图像数据集

由于目前并没有轮胎磨损程度的公开图像数据集,实验中使用数据集均为现场采集图像。采集过程在白天室外光照环境下进行,胎面无阳光直射。采集摄像头与轮胎正面保持在 30 cm 左右,轮胎均为汽车轮胎,轮胎类型均为佳通 275/80R22.5。共采集 5 种不同磨损程度的轮胎正面图像,获得 250 张轮胎图像,其中,每类磨损程度的轮胎图像各 50 张。5 类不同磨损程度的轮胎图像如图 2 所示,按磨损的严重程度分为无磨损、轻微磨损、中度磨损、严重磨损和完全磨损。



图 2 5 种不同磨损程度的轮胎图像

Fig. 2 Five images of tires with different wear degree

由于实际应用时难以采集到大量不同磨损程度的轮胎图像,因此每类磨损程度仅用 5 张轮胎图像作为训练,其余 45 张图像用于测试,每张图像的大小为 1024×768 。

2.2 图像预处理

由于训练集仅 5 张图像,训练时容易过拟合,导致测试效果较差。考虑到拍摄图像的长宽比均为 4 : 3,因此本文将每张图像按 4 : 3 的比例进行均匀裁剪,裁剪后图像大小均为 256×256 。为了减小计算量,便于轮胎图像纹理特征的提取及处理,本文采用加权平均灰度算法对图像进行灰度化处理。加权平均灰度算法通过对图像中各个像素的红绿蓝 3 个分量加权平均,得到图像各个像素的灰度值,3 种颜色成分的每个成分均用 255 个值来描述,具体计算公式为:

$$Gray = 0.299R + 0.587G + 0.114B \quad (1)$$

式中: $Gray$ 为像素处理后的灰度值, R, G, B 分别为图像各个像素中的红、绿、蓝分量值。随后对灰度图像采用中值滤波,保留边缘信息的同时减少噪声干扰。图 3 为部分裁剪图像及其预处理图像,预处理后图像在纹理结构和视觉效果上与原图十分相似,大大减少了后续提取特征的计算量。

3 融合纹理特征提取

首先,提取图像的 GLCM 纹理特征,有利于捕捉轮胎

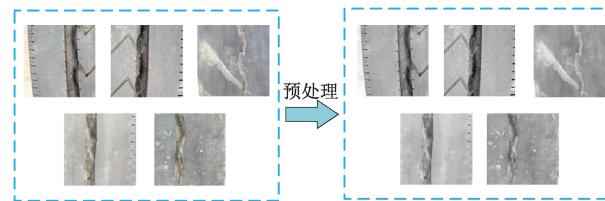


图 3 部分裁剪图像及其预处理图像

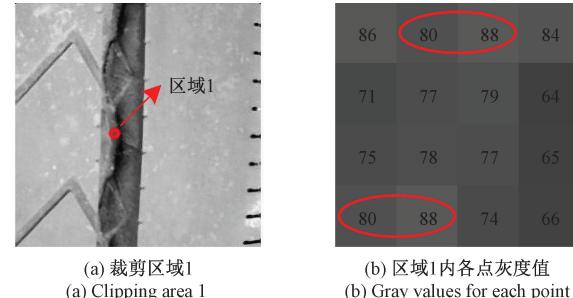
Fig. 3 Partially cropped images and their preprocessed images

磨损图像中的整体纹理变化。然后,提取图像的 LBP 局部纹理特征,从而增强对轮胎表面磨损特征的识别能力。最后,为了有效整合 GLCM 和 LBP 提取的高维特征并减少数据维度,采用 PCA 进行降维处理,并融合两类特征以提高最终分类器的性能。

3.1 CLCM 特征

GLCM 是基于成对像素灰度值的统计分析,用于描述图像的纹理特征,能够描述出相邻间隔、方向和变化幅度上的空间信息,有助于区分不同磨损程度的轮胎。

如图 4 所示,为了获得轮胎表面的纹理特征,从灰度值为 a 的某像素点 A 出发,计算与 A 方向为 φ 、相距为 d 、灰度为 b 的像素 B 同时出现的概率 $P_{\varphi,d}(a,b)$ 。假设像素 A 与 B 的灰度值分别为 80 和 88,则它们在 0° 方向上、间距为 1 时出现次数就是 $P_{0^\circ,1}(80,88) = 2$ 。



(a) 裁剪区域 1
(a) Clipping area 1

(b) 区域 1 内各点灰度值
(b) Gray values for each point

图 4 GLCM 计算示意图

Fig. 4 Schematic diagram of GLCM calculation

对于每张轮胎胎面图像,分别计算步距为 $1 \sim 10$ 的灰度共生矩阵的能量、对比度、同质性和相关性这 4 个特征值,计算特征在 φ 的取值为 $0^\circ, 45^\circ, 90^\circ, 135^\circ$ 的 4 个角度方向上的均值和均方根值,构成一个长度为 80 的特征向量。其中,4 个特征值的定义如下:

能量(Energy)是描述图像灰度分布均匀程度和纹理粗细的一个度量,其公式为:

$$Energy = \sum_{a,b} P_{\varphi,d}^2(a,b) \quad (2)$$

对比度(Contrast)反映了图像的清晰度和纹理的沟纹深浅,其公式为:

$$Contrast = \sum_{a,b} (a - b)^2 P_{\varphi,d}(a,b) \quad (3)$$

同质性(Homogeneity)是对图像纹理局部均匀程度的度量,衡量图像中局部的一致性。其公式为:

$$\text{Homogeneity} = \sum_{a,b} \frac{P_{\varphi,d}(a,b)}{1+(a-b)^2} \quad (4)$$

相关性(Correlation)是对图像灰度线性关系的度量,反映了图像灰度值沿水平或垂直方向的相似程度,其公式为:

$$\text{Correlation} = \sum_{a,b} \frac{(a-\mu_a)(b-\mu_b)P_{\varphi,d}(a,b)}{\sigma_a\sigma_b} \quad (5)$$

式中: μ_a, μ_b 分别是像素值为 a 所在的行均值和像素值为 b 所在的列均值, σ_a, σ_b 分别表示像素值为 a 所在的行标准差和像素值为 b 所在的列标准差。

3.2 LBP 特征

LBP 是一种描述图像局部纹理的特征算子。如图 5 所示,在 3×3 的区域内,以区域中心像素灰度值 g_c 为阈值,将周围相邻 8 个像素的灰度值 $g_i (i \leq 8)$ 分别与 g_c 进行比较,若周围像素灰度值大于 g_c , 则该像素点的位置被标记为 1, 否则为 0。在进行矩阵编码后将这个数作为区域中心像素的 LBP 值,其数学表达式为:

$$\text{LBP}_{N,R}(x_c, y_c) = \sum_{i=0}^{N-1} s(g_i - g_c) \cdot 2^i \quad (6)$$

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (7)$$

式中: (x_c, y_c) 为中央像素,在以中心像素为圆心,半径为 R 的圆区域称为中心像素点的邻域, N 为邻域像素点的个数, g_i 为邻域第 i 个像素点的灰度值。通过分别提取每个 3×3 区域块的 LBP 特征进行级联,得到了整个轮胎图像的 LBP 特征向量。

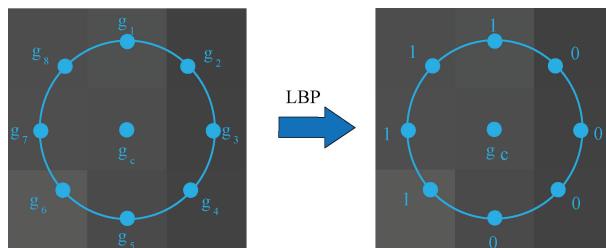


图 5 LBP 计算示意图

Fig. 5 Schematic diagram of LBP calculation

3.3 PCA 降维及融合

PCA 可以降低数据的维度,并尽可能保留原始数据的关键特征。PCA 的核心思想是将多维数据转换到一个新坐标系统中,新坐标系统的主成分按照方差递减的顺序排列。在这个新的坐标系统中,第一个坐标轴上的方差最大,依次递减,这使得 PCA 能够识别并保留数据中最重要的结构特征,从而消除冗余信息。

以二维特征 $\mathbf{X} = (a_i, b_i)^T$ 为例, a_i, b_i 为不同的特征维度, \mathbf{X} 的协方差矩阵为:

$$\mathbf{Cov}(\mathbf{X}) = \frac{1}{m} \mathbf{X} \mathbf{X}^T = \begin{bmatrix} \frac{1}{m} \sum_{i=1}^m a_i^2 & \frac{1}{m} \sum_{i=1}^m a_i b_i \\ \frac{1}{m} \sum_{i=1}^m a_i b_i & \frac{1}{m} \sum_{i=1}^m b_i^2 \end{bmatrix} \quad (8)$$

式中: $\sum_{i=1}^m a_i^2$ 为特征的方差,表示特征值; $\sum_{i=1}^m a_i b_i$ 为特征之间的协方差,表示特征之间的相关性。为了实现特征之间相互无关,要使各特征之间相互正交,即协方差为 0。对公式(8)中的协方差矩阵进行特征分解,可得到该矩阵的特征向量和对应的特征值 $\lambda_i (i \leq n)$, 将特征向量按照其所对应的特征值 λ_i 从大到小重新排序,并取前 k 个向量($k < n$)作为主成分,就得到了空间映射矩阵 \mathbf{P} 。假设 λ 中的特征值 $\lambda_1 > \lambda_2 > \dots > \lambda_n$, 则保留前 k 维所包含的原数据信息比例 η 按照下式求解:

$$\eta = \frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^n \lambda_i} \quad (9)$$

在得到 GLCM 特征和 LBP 特征后,对两类特征向量分别采用 PCA 降维,再将降维后的两类特征向量拼接融合。拼接融合将多个特征向量串行连接在一起组合成一个更长的特征向量,能保留所有原始信息,且通过 PCA 降维使得拼接融合的特征向量更加紧凑有效。在降维后需要尽量高的精度,本文中选取保留对主成分贡献度累计在 99.5% 以上的特征维度,两类特征向量的主成分贡献率如图 6 所示。

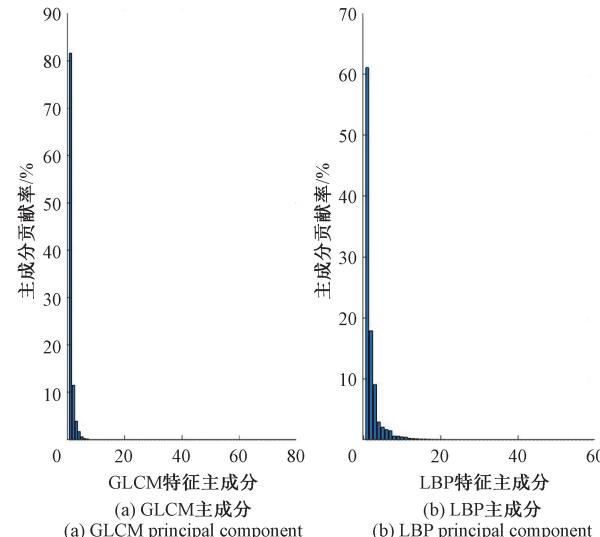


图 6 主成分贡献率

Fig. 6 Principal component contribution rate

将两类特征向量经过 PCA 降维后直接连接实现拼接融合,如图 7 所示,在保留 99.5% 的 PCA 主成分贡献率下,降维后 GLCM 特征向量长度为 6, LBP 特征向量长度为 23, 拼接融合后的特征向量长度为 29。

4 分类器训练与测试

分类问题及其算法是机器学习中的重要分支,相关算法包括支持向量机(support vector machines, SVM)、K-近

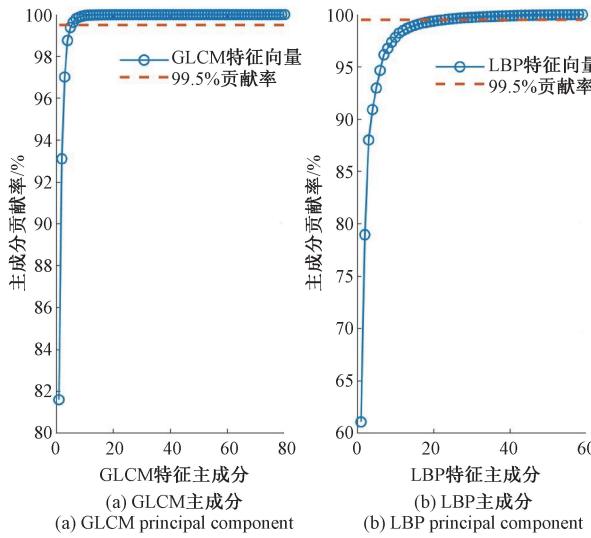


图 7 主成分累计贡献率

Fig. 7 Cumulative contribution rate of principal components

邻算法(k-nearest neighbor, KNN)、RF 等,不同的机器学习算法对结果的预测精度及泛化能力会产生不同的影响。SVM 在处理高维特征数据时需要选取合适的核函数,对于多分类问题容易造成过拟合。KNN 对噪声和异常值敏感且在数据不平衡时预测偏差较大。RF 由多个决策树集合而成,相比于单个分类器具有更高的泛化能力,在处理高维复杂的特征时效果较好。考虑到 RF 的决策树数量和叶子节点最小样本数两个参数会影响分类效果,因此本文选择 SSA 对 RF 分类器参数进行优化,建立 SSA-RF 分类器。

4.1 SSA-RF 分类模型

SSA 模拟麻雀在觅食和避免天敌过程中的行为实现寻优目标函数过程。在算法思想中,麻雀种群被分为发现者和加入者两类。发现者的搜索范围广,负责提供觅食区域和方向,加入者利用发现者来获取食物,同时为提高捕食率,加入者会争夺高摄取量同伴的食物资源。

设麻雀种群中有 n 只麻雀,种群中一般有接近 20% 的麻雀为发现者,发现者位置更新公式如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(-\frac{i}{\alpha \cdot iter_{max}}\right) & R < ST \\ X_{i,j}^t + Q \cdot \mathbf{L} & R \geq ST \end{cases} \quad (10)$$

式中: $X_{i,j}^t$ 为第 i 只麻雀在第 j 维的位置信息; t 为当前迭代次数; α 是 $[0,1]$ 内的随机数; $iter_{max}$ 为最大迭代次数; R 为 $[0,1]$ 内的随机数,表示预警值; ST 为 $[0.5,1]$ 内的常数,表示安全值; Q 为服从正态分布的随机数; \mathbf{L} 表示元素为 1 的 $1 \times d$ 矩阵。当 $R < ST$ 时,预警值在安全值范围内,种群相对安全,发现者搜索范围较大;当 $R \geq ST$ 时,捕食者增多,种群需要移动到安全的区域。

加入者的位置更新公式如下:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{worst} - X_{i,j}^t}{i^2}\right) & i > n/2 \\ X_p^{t+1} + |X_p^{t+1} - X_{i,j}^t| \cdot \mathbf{A}^+ \cdot \mathbf{L} & i \leq n/2 \end{cases} \quad (11)$$

式中: i 为遍历的加入者; n 为麻雀总数量; X_p^{t+1} 为 $t+1$ 轮迭代时发现者占据的最优位置; X_{worst} 为目前全局最差的位置; \mathbf{A} 表示元素随机赋为 1 或 -1 的 $1 \times d$ 矩阵。

当种群发现危险时,警报者位置更新公式如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{best}^t + \beta \cdot |X_{i,j}^t - X_{best}^t| & f_i > f_{max} \\ X_{i,j}^t + K \cdot \left(\frac{|X_{i,j}^t - X_{worse}^t|}{(f_i - f_{min}) + \epsilon} \right) & f_i = f_{max} \end{cases} \quad (12)$$

式中: X_{best}^t 和 X_{worse}^t 分别表示第 t 次迭代中最优和最差的个体; f_i 为当前个体的适应度值; f_{max} 和 f_{min} 为当前最大和最小的适应度值; β 为步长控制参数,服从标准正态分布的随机数; K 表示麻雀的移动方向,为 $[-1, 1]$ 内的随机数; ϵ 是极小常数,防止分母为 0。 $f_i > f_{max}$ 时,当前麻雀易被捕食者攻击; $f_i = f_{max}$ 时,种群中麻雀已意识到危险且这部分麻雀需靠近其他麻雀来降低被捕风险。

RF 是一种基于 bagging 策略的集成学习方法,它结合了多个决策树的预测结果来提高整体的分类性能。每棵决策树都独立地对输入样本进行分类,称为弱分类器。RF 融合多个这样的弱分类器,通过多数投票机制形成一个强分类器,有效地提高了预测的准确性和泛化能力。

RF 分类器原理如图 8 所示,由许多树形结构的决策树构成,包括根节点、内部节点和叶节点。根节点代表融合特征数据集,内部节点代表对融合特征的判别条件,而叶节点则代表决策树的分类结果。其中,每棵决策树都是基于分类与回归树算法(classification and regression tree, CART)构建。每棵 CART 树会独立评估特征样本,最终的分类结果是基于所有决策树投票结果的综合,选取该样本多数投票的类别作为 RF 的预测类别。

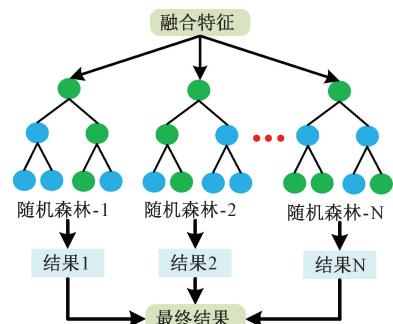


图 8 RF 分类器

Fig. 8 RF classifier

决策树数量和叶子节点最小样本数是 RF 中的两个关键参数,决策树数量通常会提高模型的性能和稳定性,但会增加计算成本和训练时间。叶子节点最小样本数可以

增加模型的泛化能力,但可能会降低训练数据的拟合度。在训练 SSA-RF 分类模型时,需要对两个参数进行优化。SSA 算法中,选择种群数量为 20,最大迭代次数为 30,误识率为适应度函数,迭代过程的适应度曲线如图 9 所示。通过 SSA 优化后的决策树数量和叶子节点最小样本数分别为 160 和 9。

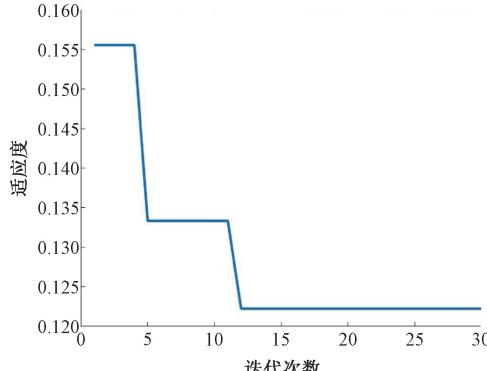


图 9 适应度曲线

Fig. 9 Fitness curves

4.2 测试集成过程

在分类器训练好之后,利用 5 种磨损程度的 225 张图像进行测试,测试图像通过与训练时相同的图像裁剪和预处理,提取融合特征,采用训练好的 SSA-RF 分类器对融合特征进行分类,则每一张裁剪子图像对应一个分类结果,每一张测试图像对应 12 个分类结果。为了提高分类准确性,通过加权投票方法进行分类结果的集成。

加权投票法通过给予不同视角和细节的裁剪图像不同的权重值,使得分类过程更适应图像中多样的特征变化,有效地利用分类器对同一图像的多个裁剪图像所提供的综合信息,获得更高的分类性能。

考虑到中心位置的图像包含的特征信息更多,因此,本文设计了一种根据裁剪图像位置的权重选取方法,其关系如下:

$$weight = \frac{1}{1 + distance} \quad (13)$$

式中: $weight$ 为加权值, $distance$ 为裁剪图像的位置与图像中心点的距离。

加权投票示意图如图 10 所示,左图为裁剪图像,右图为区域划分。整张图像按 3×3 的网格划分,将 12 张裁剪子图像分成 9 块区域,红色部分为中心区域,该区域裁剪图像的距离为 0,橙色部分为相邻区域,该区域裁剪图像的距离取为 1,则黄色区域裁剪图像的距离值为 $\sqrt{2}$, 对应权重值如右图所示。

计算得到裁剪子图像的权重值后,对子图像对应的分类类别给予相应权重值,最后统计所有类别的权值和,选取权重和最大的类别作为测试图像的分类结果。选取方式如下:

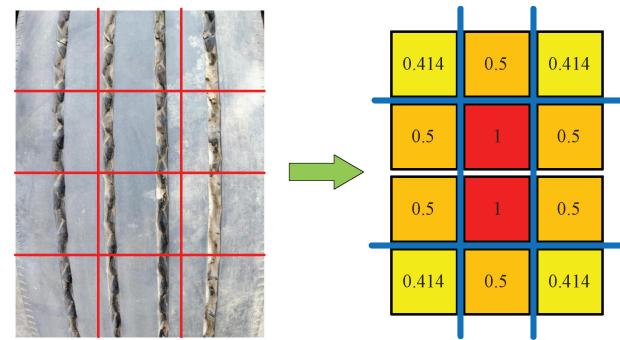


图 10 加权投票示意图

Fig. 10 Schematic diagram of weighted voting

$$W_n = \max\{\sum W_1, \sum W_2, \sum W_3, \sum W_4, \sum W_5\} \quad (14)$$

其中, W_1, W_2, W_3, W_4, W_5 分别为 5 个磨损程度类别的权重和, W_n 为其中最大权重和, 对应的类别 n 则为最终的分类结果。

5 实验结果与分析

本实验使用 inter Core(TM) i7-12700H CPU 平台搭配 16 G 的运行内存作为硬件平台,室外通过相机对轮胎正面图像进行采集,采集图像分辨率大小均为 1024×768 , 轮胎类型为佳通 275/80R22.5。采集图像时相机距离胎面 30 cm,对 5 种不同磨损程度的轮胎分别采集 50 张作为数据集。其中,每类磨损程度随机选取 5 张图像作为训练集,其余 45 张作为测试集。

测试集中,同样先将图像按照 $4:3$ 进行裁剪,子图像的像素大小为 256×256 , 提取裁剪子图像上的 GLCM-LBP 特征,通过对两类特征分别进行 PCA 降维并融合后得到融合纹理特征。训练好的 SSA-RF 分类器对融合纹理特征进行测试得到子图像的磨损检测结果,最后将对应裁剪后的子图像结果进行集成,得到最终的检测结果。225 张测试集图像的混淆矩阵检测结果如图 11 所示。

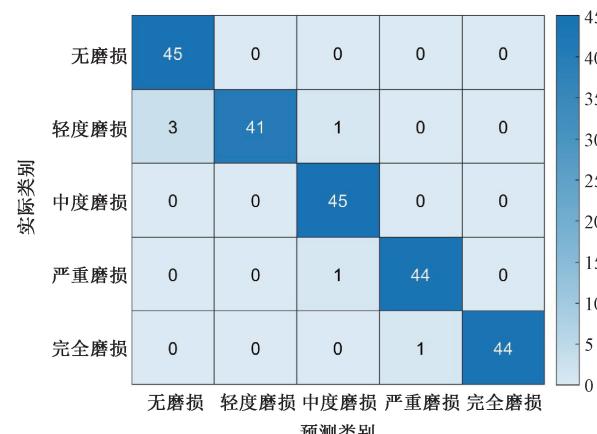


图 11 测试结果混淆矩阵

Fig. 11 Confusion matrix of test results

由混淆矩阵可以看出,250个测试结果中仅有6个预测错误,且预测错误类别与实际类别均相邻,平均准确率达到97.33%,充分证明了该方法对轮胎磨损程度检测的优势。

为进行对比实验,分别提取轮胎图像的GLCM特征、LBP特征、HOG特征、SIFT四类特征,分别利用四类特征及融合GLCM与LBP特征进行SSA-RF分类器的训练和测试,得到不同特征选取下的准确率结果如表1所示。

表1 不同特征选取对比

Table 1 Comparison of the different feature selection

选取特征	GLCM	LBP	HOG	SIFT	GLCM-LBP
准确率/%	94.8	92.76	87.48	84.74	97.33

由表可以看出,融合GLCM-LBP特征后的准确率相比单一特征显著提高,通过对整体及局部纹理细节部分特征信息的结合,可以增强模型对轮胎磨损程度的判别能力。

基于本文的融合纹理特征,RF分类器在轮胎磨损程度识别任务中表现出了显著的优势,其识别准确率高达97.33%。同时对比了目前分类方法中常用的SVM以及KNN分类器,经过实验测试,经过SSA优化后SVM和KNN分类准确率分别为87.56%和83.56%,均低于本文中SSA-RF方法下的分类准确率。

6 结 论

针对基于图像的轮胎磨损程度检测技术中,所需样本数较多,选择纹理特征单一且检测精度较低的问题,本文提出了一种基于融合纹理特征的轮胎磨损程度检测方法。通过对少量样本图像进行裁剪获得大量子图像,融合子图像的GLCM与LBP特征,通过PCA降维构成融合纹理特征,强化了特征描述并提高了模型在不同尺度下的适应能力。建立了SSA-RF分类器模型,减少分类器过拟合或欠拟合风险。通过裁剪子图像分类结果的加权投票集成,赋予不同位置子图像不同的权重,有效利用图像中心区域对磨损程度检测的重要性,进一步提高了模型的分类准确性与泛化性能。最终在测试集上平均准确率达到97.33%,相比单一纹理特征和SVM与KNN分类方法,准确率明显提高,验证了本文方法的有效性和优越性。

参考文献

- [1] 公安部交通管理局. 中华人民共和国道路交通事故统计年报(2022)[R]. 北京:公安部交通管理局, 2023.
- [2] 庞博维, 崔敏, 杨琨, 等. 轮胎胎面磨损检测技术研究进展[J]. 无损检测, 2021, 43(7): 83-89, 94.
- [3] PANG B W, CUI M, YANG K, et al. Research development of tire tread wear detection technology[J]. Nondestructive Testing, 2021, 43(7): 83-89, 94.
- [4] 刘卫东, 韩宗志, 高镇海, 等. 基于智能轮胎系统的实时路面辨识技术[J]. 汽车工程, 2024, 46(4): 617-625.
- [5] LIU W D, HAN Z ZH, GAO ZH H, et al. Real-time pavement recognition technology based on intelligent tire system [J]. Automotive Engineering, 2024, 46(4): 617-625.
- [6] 《中国公路学报》编辑部. 中国汽车工程学术研究综述·2023[J]. 中国公路学报, 2023, 36(11): 1-192.
- [7] Editorial Department of China Journal of Highway and Transport. Review on China's automotive engineering research progress: 2023 [J]. China Journal of Highway and Transport, 2023, 36(11): 1-192.
- [8] NGUYEN V H, ZHENG D, SCHMERWITZ F, et al. An advanced abrasion model for tire wear[J]. Wear, 2018, 396: 75-85.
- [9] KARKARIA V, CHEN J, SIUTA C, et al. A machine learning-based tire life prediction framework for increasing life of commercial vehicle tires [J]. Journal of Mechanical Design, 2023, 146(2): 020902.
- [10] 王希波, 李爱娟, 高金胜, 等. 基于机器视觉的轮胎花纹深度测量系统研究[J]. 国外电子测量技术, 2019, 38(4): 66-70.
- [11] WANG X B, LI AI J, GAO J SH, et al. Study on tire tread depth measurement method based on machine vision [J]. Foreign Electronic Measurement Technology, 2019, 38(4): 66-70.
- [12] CHANG W H, JUANG R T, HUANG M H, et al. Estimation of tire mileage and wear using measurement data[J]. Electronics, 2021, 10(20): 2531.
- [13] 张峰瑞, 张峰, 张越, 等. 汽车智能轮胎磨损检测系统设计[J]. 电气自动化, 2022, 44(3): 72-74, 78.
- [14] ZHANG F R, ZHANG F, ZHANG Y, et al. Design of intelligent tire wear detection system for automobile[J]. Electrical Automation, 2022, 44(3): 72-74, 78.
- [15] 崔敏, 杨怀斌, 谢盛珍, 等. 基于机器视觉的汽车轮胎磨损检测系统设计[J]. 制造业自动化, 2020, 42(1): 10-14.
- [16] CUI M, YANG H B, XIE SH ZH, et al. Design of automobile tire wear detection system based on machine vision[J]. Manufacturing Automation, 2020, 42(1): 10-14.
- [17] ZHU J CH, HAN K X, WANG SH L. Automobile tire life prediction based on image processing and

- machine learning technology [J]. Advances in Mechanical Engineering, 2021, 13(3): 168781402110027.
- [12] KIM K J, PARK H, KIM T, et al. Comparison of performance of predicting the wear amount of tire tread depending on sensing information[J]. Sensors, 2023, 23(1): 459.
- [13] MEENA K K, ARIEF I, GHOSH A K, et al. 3D-printed stretchable hybrid piezoelectric-triboelectric nanogenerator for smart tire: Onboard real-time tread wear monitoring system [J]. Nano Energy, 2023, 115: 108707.
- [14] 陶亮, 唐钰, 戚文杰, 等. 基于轮内加速度的乘用车胎面磨损程度分类试验 [J]. 中国机械工程, 2023, 34(22): 2737-2745.
- TAO L, TANG Y, QI W J, et al. Classification test of tire tread wear of passenger cars based on in-wheel acceleration[J]. China Mechanical Engineering, 2023, 34(22): 2737-2745.
- [15] 李颖, 吴仕虎, 杨鑫杰, 等. 基于 GLCM-HOG 和 WOA-ELM 的往复压缩机气阀故障诊断方法 [J]. 电子测量技术, 2023, 46(20): 156-163.
- LI Y, WU SH H, YANG X J, et al. Fault diagnosis method based on GLCM-HOG and WOA-ELM for reciprocating compressor valve [J]. Electronic Measurement Technology, 2023, 46(20): 156-163.
- [16] LIU H B, JIA X H, SU CH H, et al. Tire appearance defect detection method via combining HOG and LBP features [J]. Frontiers in Physics, 2023, 10: 1099261.
- [17] 王泽, 任安虎, 李珊. 汽车轮胎胎面磨损程度检测系
统[J]. 计算机系统应用, 2021, 30(6): 88-93.
- WANG Z, REN AN H, LI SH. Tread wear detection system for automobile tires[J]. Computer Systems & Applications, 2021, 30(6): 88-93.
- [18] 李宏玲, 董玉德, 黄智豪, 等. 基于相似性理论的轮胎花纹相似度检测与分析 [J]. 中国机械工程, 2021, 32(14): 1646-1652.
- LI H L, DONG Y D, HUANG ZH H, et al. Similarities detection and analysis of tire patterns based on similarity theory [J]. China Mechanical Engineering, 2021, 32(14): 1646-1652.
- [19] 张瀚丹, 吴一全. 基于视觉的汽车装配件缺陷检测研究进展 [J]. 仪器仪表学报, 2023, 44(8): 1-20.
- ZHANG H D, WU Y Q. Research progress of vehicle assembly defect detection methods based on vision[J]. Chinese Journal of Scientific Instrument, 2023, 44(8): 1-20.

作者简介

欧阳杰,硕士,主要研究方向为智能轮胎技术。

E-mail: 1339173980@qq.com

张向文(通信作者),博士,教授,博士生导师,主要研究方向为电动汽车再生制动控制、电动汽车电池管理、智能轮胎技术。

E-mail: zxw@guet.edu.cn

刘沛钊,硕士,高级工程师,主要研究方向为智能轮胎芯片、算法及系统开发。

E-mail: pzliu@hiway.hk

陈凯文,本科,工程师,主要研究方向为智能轮胎算法开发。

E-mail: kelvinchen@hiway.hk