

DOI: 10.19650/j.cnki.cjsi.J1905538

基于极坐标特征矩阵的多类对象排列结构描述方法*

陈国杰, 尤波

(哈尔滨理工大学自动化学院 哈尔滨 150080)

摘要:本文提出一种基于极坐标特征矩阵的多类对象排列结构检测方法。极坐标特征矩阵由极径矩阵和极角矩阵构成,它描述了多类对象排列结构中所包含的距离信息和方向信息。该方法在汽车保险盒检测应用上取得了显著的效果,针对于汽车保险盒检测,首先使用 CCD 工业相机采集保险盒图像,通过方向梯度直方图特征对汽车保险片的标识码进行表征,并结合支持向量机实现对图像中的保险片的定位与识别。然后依据定位和识别结果计算极坐标特征矩阵对汽车保险盒内汽车保险片的排列结构进行描述。最后以极坐标特征矩阵相似度为判断依据实现对汽车保险盒的检测。实验证明,依据极坐标特征矩阵相似度对汽车保险盒的检测准确率达 97.6%。

关键词:极坐标特征矩阵;多类对象排列结构;方向梯度直方图;支持向量机;汽车保险盒

中图分类号: TP391.4 TH39 **文献标识码:** A **国家标准学科分类代码:** 520.60

Arrangement structure description method of multi-class objects based on polar coordinate feature matrix

Chen Guojie, You Bo

(School of Automation, Harbin University of Science and Technology, Harbin 150080, China)

Abstract: In this paper, an arrangement structure description method of multi-class objects based on polar coordinate feature matrix (PCFM) is proposed. The polar coordinate feature matrix consists of polar radius matrix (PRM) and Polar Angle Matrix (PAM), which describes the distance and angle information contained in the arrangement structure of multi-class objects. This method was applied in the application of vehicle fuse box detection and achieved obvious effects. Aiming at the vehicle fuse box detection, the method firstly uses a charge coupled device (CCD) industrial camera to acquire the images of the vehicle fuse boxes, employs histogram of oriented gradient (HOG) feature to characterize the ID codes of the vehicle fuse chips and combines SVMs to achieve the localization and recognition of the fuse chips in the images. According to the localization and recognition results, the PCFM is calculated to describe the arrangement structure of vehicle fuse chips in vehicle fuse box. Finally, the PCFM similarity is taken as the judgment criterion to realize the detection of the vehicle fuse box. The experiment proves that using PCFM similarity to detect the vehicle fuse box, the detection accuracy reaches 97.6%.

Keywords: polar coordinate feature matrix; arrangement structure of multi-class objects; histogram of oriented gradient (HOG); support vector machine (SVM); vehicle fuse box

0 引言

汽车保险盒由保险片插装盒和汽车保险片组成,根据不同的需求,各类型的保险片按照一定的排列结构插在保险片插装盒内。汽车保险盒是汽车电子元件中的

关键部件,防止电路在发生故障或异常时,升高的电流损坏汽车电路中重要或贵重的器件,起到保护汽车电路安全运行的作用^[1-2]。因此,对汽车保险盒的检测具有重要的意义。

目前,在汽车保险盒的检测上绝大多数都是采用人工检测的方式,鲜有汽车生产企业使用自动化生产设备进

收稿日期:2019-08-30 Received Date:2019-08-30

* 基金项目:黑龙江省自然科学基金青年项目基金(QC2014C054)资助

行汽车保险盒检测。由于不同类型汽车保险片具有较强的相似性,采用人工方式进行汽车保险盒的检测需要较多的劳动力。此外,这类检测工作往往具有单调性,这使得检测员难以保持注意力集中,从而易导致检测错误。人工检测的准确率与检测效率通常成反比关系,如果检测员被限定在几秒内完成一个保险盒的检测,那么人工检测的准确率将急剧的降低。随着机器视觉技术愈发成熟,极大程度引起了学者的关注,并将这一技术广泛地应用于各类现代化的生产检测环节中^[3-6]。由此表明,利用机器视觉技术进行汽车保险盒检测的方案具备可行性。面向基于机器视觉的汽车保险盒检测系统设计,需要解决以下两个问题:汽车保险盒内保险片检测问题和汽车保险盒内保险片排列结构检测问题。

目标检测问题一直都是机器视觉技术研究的热点问题之一。随着计算机技术的迅猛发展,目标检测已在人脸识别、行人检测、车牌识别、无人驾驶等领域得到广泛的应用。优秀的目标检测方法有很多,如文献[7]提出的尺度不变特征变换(scale-invariant feature transform, SIFT)算法,通过获取特定关键点附近的梯度信息来描述目标,具有旋转、尺度不变等优良特性。文献[8]为解决静态图像中的行人检测问题而提出了方向梯度直方图特征(histogram of oriented gradient, HOG),通过计算空间分布区域的梯度强度及其方向信息来描述目标。文献[9]将HOG与支持向量机相结合(support vector machine, SVM),提出了可变形部件模型,是近几年被广泛应用的目标检测模型之一。文献[10]将局部二值模式(local binary patterns, LBP)用于人脸特征描述,实现了对人脸的识别。文献[11]提出了利用积分直方图快速计算 Haar-like 特征的方法,结合 Adaboost 实现了快速地目标检测,解决了静态图片中人脸检测的问题。近几年,利用卷积神经网络去学习图像特征,即基于深度学习的目标检测算法得到迅速发展,并成为机器学习领域的热点之一。代表性的算法包括卷积神经网络(convolutional neural networks, CNN)^[12],基于区域的卷积神经网络(region-based convolutional neural networks, R-CNN)^[13-15],YOLO(you only look once)^[16]模型,单次多盒检测器(single shot multibox detector, SSD)^[17]等。上述的研究内容为基于机器视觉的汽车保险片检测奠定了坚实的基础,因此,本文研究的主要问题在于汽车保险片排列结构的检测。

针对于汽车保险片排列结构检测问题,模板匹配是一种简单而有效的方法^[18],该方法利用检测到的保险片的位置和类别信息与标准模板逐一进行对比,最终确定保险盒内保险的排列结构。然而这种方法要求汽车保险盒在工业相机视野内的位置是固定的,往往都需要人为的位置矫正才能确保正确的检测。同时,这种方法不能对排列结构全局特征进行表征,因此缺乏泛化能力。

Delaunay 三角剖分是一种有效表征排列结构全局特征的方法^[19-20]。对与一类点集进行 Delaunay 三角剖分的结果具有唯一性,这一性质被广泛的应用于机器视觉中运动场景跟踪、人脸对齐和目标识别等领域^[21-22]。使用 Delaunay 三角剖分能有效的识别出存在缺失和移位错误的保险盒,但是不能对存在置换或互换错误的保险盒进行识别。这是因为在保险盒内存在多种类别的汽车保险片,而 Delaunay 三角剖分缺乏表征不同类别点集排列结构间关系的能力。

因此,本文的创新点在于提出一种基于极坐标特征矩阵的多类对象排列结构描述方法,并在汽车保险盒检测上得到成功的应用。本文提出的极坐标特征矩阵检测法具有唯一性、平移不变性、尺度不变性和旋转不变性,并且在 PCB 通孔位置检测,集成电路表面元件检测等类似问题上也能有所应用,具有良好的泛化能力。

1 定位与识别

1.1 HOG 特征提取

汽车保险片标识码由数字和“.”组成,在保险盒内的标识码会随机的出现颠倒现象,难以通过传统的单个字符识别的方式实现标识码的识别提出依据不同汽车保险片标识码间全局的差异性,汽车保险盒结构如图1所示。因此,利用HOG对标识码全局特征进行表征,并结合支持向量机最终实现标识码的定位与识别。方向梯度直方图特征提取步骤如下:

1) 归一化处理。归一化操作是先将图像转化为灰度图像,再利用伽马矫正实现,伽马矫正定义如下:

$$I_{out} = A I_{in}^{\gamma} \quad (1)$$

式中: I_{out} 为输出灰度值; I_{in} 为输入灰度值; A 为常数; γ 为伽马系数。

2) 计算图像梯度 G_x 和 G_y 。通过对图像进行模板卷积可得到,水平模板为 $[-1 \ 0 \ 1]$, 竖直模板为 $[-1 \ 0 \ 1]^T$ 。

3) 统计梯度方向。将图像划分为 $m \times n$ 个细胞单元, $s \times s$ 个细胞单元组成一个块单元,块单元的梯度方向划分为 N 个等间距方向块;对块单元内每个像素梯度方向在直方图中进行加权投影,将其映射到对应的角度范围内,最终得到块单元的梯度方向直方图,即块单元对应的 N 维特征向量 \mathbf{v} 。

4) 块单元特征向量归一化。归一化函数定义如下:

$$\mathbf{v} = \frac{\mathbf{v}}{\sqrt{\|\mathbf{v}\|^2 + \varepsilon^2}} \quad (2)$$

其中, ε 为很小的常数。

5) 生成特征向量。将图像的每个块特征向量组合在一起,得到图像 HOG 特征。

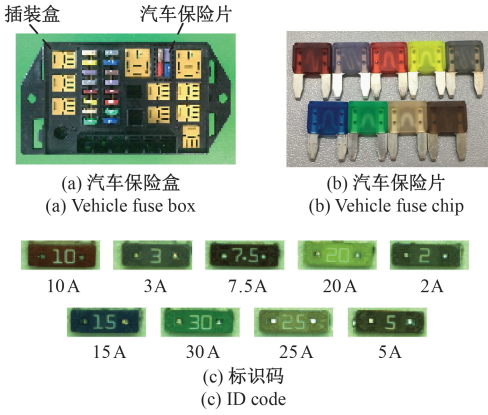


图 1 汽车保险盒结构

Fig.1 Structure of the vehicle fuse box

1.2 SVM

SVM 的基本思想是寻找满足分类要求的超平面将空间分成两个区域,每个区域对应一个类。将训练样本集分为标识码样本集 T 和背景样本集 B 两类,把样本特征向量与标签记为 $(x_i, y_i), i = 1, 2, \dots, n, y_i = \{ +1, -1 \}, n$ 为训练样本集总数,则样本与标签满足:

$$\begin{cases} x_i \in T \Rightarrow y_i = +1 \\ x_i \in B \Rightarrow y_i = -1 \end{cases} \quad (3)$$

选取适当的高斯径向核函数 $K(x, z)$ 和适当的参数 C , 构造并求解最优化问题:

$$\begin{aligned} \min & \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) - \sum_{i=1}^N \alpha_i \\ \text{s.t.} & \sum_{i=1}^N \alpha_i y_i = 0 \quad 0 \leq \alpha_i \leq C, i = 1, 2, \dots, N \end{aligned} \quad (4)$$

由式(4)求得最优解 $\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_N^*)^T$, 选择 α^* 的一个正分量 $0 < \alpha_j^* < C$, 计算:

$$b^* = y_j - \sum_{i=1}^N \alpha_i^* y_i K(x_i, x_j) \quad (5)$$

由 α^* 和 b^* 确定构造决策函数:

$$f(x) = \text{sign} \left(\sum_{i=1}^N \alpha_i^* y_i K(x, x_i) + b^* \right) \quad (6)$$

由于采集到的图像尺度固定,通过决策函数进行单尺度检测实现标识码的定位,单尺度定位方法如图 2 所示。对于定位后的标识码多分类问题,可以利用多个 SVM 二分类实现^[23]。

2 极坐标特征矩阵

2.1 极坐标特征矩阵定义

设平面内有点 A 与 B, 则 A 与 B 在平面上的位置关系可以通过极坐标进行描述, 点 A 与 B 间的关系如图 3 所示。则由 A 到 B 在平面上的位置关系可以使用极坐

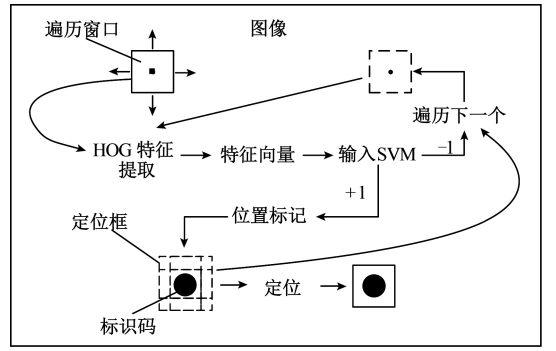


图 2 单尺度定位

Fig.2 Single-scale localization




图 3 点 A 与 B 间的关系

Fig.3 The relationship between points A and B

标向量 (ρ, θ) 描述, 表示 B 在 A 的 θ 方向上的 ρ 处。极径 ρ 与极角 θ 的满足:

$$\rho = \sqrt{(x_B - x_A)^2 + (y_B - y_A)^2} \quad (7)$$

$$\theta = \begin{cases} 0, & (x_A = x_B; y_A = y_B) \\ \arctan \frac{y_B - y_A}{x_B - x_A}, & (x_A < x_B; y_A < y_B) \\ \frac{\pi}{2}, & (x_A = x_B; y_A < y_B) \\ \arctan \frac{y_B - y_A}{x_B - x_A} + \pi, & (x_A > x_B) \\ \frac{3\pi}{2}, & (x_A = x_B; y_A > y_B) \\ \arctan \frac{y_B - y_A}{x_B - x_A} + 2\pi, & (x_A < x_B; y_A \geq y_B) \end{cases} \quad (8)$$

设平面上有一类点集 $L = \{p_1, p_2, \dots, p_n\}$, 在平面上的排列结构如图 4 所示。将平面上的点 p 记为 $p_i(x_i, y_i)$, 其中, i 表示 p 为点集中的第 i 个; (x_i, y_i) 表示 L 的第 i 个点在平面上的坐标。

在图 4 中, \bar{p} 表示 L 内点位的均值中心, 定义为:

$$\bar{p}(\bar{x}, \bar{y}) = \frac{1}{n} \sum_{i=1}^n p_i(x_i, y_i) \quad (9)$$

式中: n 为 L 内的点位总数; $(\rho(i), \theta(i))$ 表示从 \bar{p} 到 p_i 的位置关系; $(\rho(j), \theta(j))$ 表示从 \bar{p} 到 p_j 的位置关系, 二者描述的是点集内的位置关系。




图4 一类点集排列结构

Fig.4 Arrangement structure of a type of point set

L 内位置关系可以使用极径向量 ρ 和极角向量 θ 表征,记为 (ρ, θ) 。 ρ 定义为:

$$\rho = (\rho(1), \rho(2), \dots, \rho(n)) \quad (10)$$

其中, ρ 内的元素降序排列。 θ 与 ρ 相对应排列,定义为:

$$\theta = (\theta(1), \theta(2), \dots, \theta(n)) \quad (11)$$

将其在两类点集排列上推广,设平面上有两类点集 $L_1 = \{p_{1,1}, p_{1,2}, \dots, p_{1,n_1}\}$ 和 $L_2 = \{p_{2,1}, p_{2,2}, \dots, p_{2,n_2}\}$, 在平面上的排列结构如图5所示。类似地,将平面上的点 p 记为 $p_{i,j}(x_{i,j}, y_{i,j})$, 其中, i 表示 $p \in L_i, i = 1, 2; j$ 表示 p 为所属点集中的第 j 个; $(x_{i,j}, y_{i,j})$ 表示 L_i 的第 j 个点在平面上的坐标。




图5 两类点集排列结构

Fig.5 Arrangement structure of two kinds of point sets

在图5中, \bar{p}_i 表示 L_i 内点位的均值中心,定义为:

$$\bar{p}_i(x_i, y_i) = \frac{1}{n_i} \sum_{j=1}^{n_i} p_{i,j}(x_{i,j}, y_{i,j}), i = 1, 2 \quad (12)$$

式中: n_i 为 L_i 内的点位总数; $(\rho_{1,1}(i), \theta_{1,1}(i))$ 表示从 \bar{p}_1 到 $p_{1,i}$ 的位置关系; $(\rho_{2,2}(l), \theta_{2,2}(l))$ 表示从 \bar{p}_2 到 $p_{2,l}$ 的位置关系; $(\rho_{1,2}(j), \theta_{1,2}(j))$ 表示从 \bar{p}_1 到 $p_{2,j}$ 的位置关系; $(\rho_{2,1}(k), \theta_{2,1}(k))$ 表示从 \bar{p}_2 到 $p_{1,k}$ 的位置关系。特别地, $(\rho_{1,1}(i), \theta_{1,1}(i))$ 和 $(\rho_{2,2}(l), \theta_{2,2}(l))$ 描述的是点集

内的位置关系,而 $(\rho_{1,2}(j), \theta_{1,2}(j))$ 和 $(\rho_{2,1}(k), \theta_{2,1}(k))$ 描述的是点集间的位置关系。

因此, L_1 内位置关系可以使用极径向量 $\rho_{1,1}$ 和极角向量 $\theta_{1,1}$ 表征,记为 $(\rho_{1,1}, \theta_{1,1})$ 。 $\rho_{1,1}$ 定义为:

$$\rho_{1,1} = (\rho_{1,1}(1), \rho_{1,1}(2), \dots, \rho_{1,1}(n_1)) \quad (13)$$

其中, $\rho_{1,1}$ 内的元素降序排列。 $\theta_{1,1}$ 与 $\rho_{1,1}$ 相对应排列,定义为:

$$\theta_{1,1} = (\theta_{1,1}(1), \theta_{1,1}(2), \dots, \theta_{1,1}(n_1)) \quad (14)$$

同理得: L_2 内位置关系 $(\rho_{2,2}, \theta_{2,2})$ 、 L_1 到 L_2 位置关系 $(\rho_{1,2}, \theta_{1,2})$ 和 L_2 到 L_1 位置关系 $(\rho_{2,1}, \theta_{2,1})$ 。通过上述的4种位置关系构造极径矩阵 (polar radius matrix, PRM) P 和极角矩阵 (polar angle matrix, PAM) Θ 对 L_1 和 L_2 的在平面上的排列结构进行表征。设 $n_1 < n_2$, P 和 Θ 定义如下:

$$P = \begin{bmatrix} \rho_{11} & \theta \\ \rho_{12} & \theta \\ \rho_{21} & \theta \\ \rho_{22} & \theta \end{bmatrix} =$$

$$\begin{bmatrix} \rho_{1,1}(1) & \dots & \rho_{1,1}(n_1) & \overbrace{0 \dots 0}^{n_2-n_1} \\ \rho_{1,2}(1) & \dots & \rho_{1,2}(n) & \rho_{1,2}(n_1+1) \dots \rho_{1,2}(n_2) \\ \rho_{2,1}(1) & \dots & \rho_{2,1}(n_1) & \overbrace{0 \dots 0}^{n_2-n_1} \\ \rho_{2,2}(1) & \dots & \rho_{2,2}(n) & \rho_{2,2}(n_1+1) \dots \rho_{2,2}(n_2) \end{bmatrix} \quad (15)$$

$$\Theta = \begin{bmatrix} \theta_{11} & \theta \\ \theta_{12} & \theta \\ \theta_{21} & \theta \\ \theta_{22} & \theta \end{bmatrix} =$$

$$\begin{bmatrix} \theta_{1,1}(1) & \dots & \theta_{1,1}(n_1) & \overbrace{0 \dots 0}^{n_2-n_1} \\ \theta_{1,2}(1) & \dots & \theta_{1,2}(n) & \theta_{1,2}(n_1+1) \dots \theta_{1,2}(n_2) \\ \theta_{2,1}(1) & \dots & \theta_{2,1}(n_1) & \overbrace{0 \dots 0}^{n_2-n_1} \\ \theta_{2,2}(1) & \dots & \theta_{2,2}(n) & \theta_{2,2}(n_1+1) \dots \theta_{2,2}(n_2) \end{bmatrix} \quad (16)$$

其中, θ 是补齐零向量。将极径矩阵 P 和极角矩阵 Θ 称为极坐标特征矩阵 (polar coordinate feature matrix, PCFM), 记做 (P, Θ) 。

将极坐标特征矩阵向多类点集推广,设平面上有点集 L_1, L_2, \dots, L_n , 每类点集包含的点位个数为 m_1, m_2, \dots, m_n , 各类点集的均值中心为 $\bar{p}_1, \bar{p}_2, \dots, \bar{p}_n$, 则平面上的点集所对应的极坐标特征矩阵 (P, Θ) 定义为:

$$(P, \Theta) = \begin{pmatrix} \begin{bmatrix} \rho_{1,1} \\ \vdots \\ \rho_{1,t} \\ \vdots \\ \rho_{1,n} \\ \vdots \\ \rho_{n,1} \\ \vdots \\ \rho_{n,t} \\ \vdots \\ \rho_{n,n} \end{bmatrix} & \begin{bmatrix} \theta_{1,1} \\ \vdots \\ \theta_{1,t} \\ \vdots \\ \theta_{1,n} \\ \vdots \\ \theta_{n,1} \\ \vdots \\ \theta_{n,t} \\ \vdots \\ \theta_{n,n} \end{bmatrix} \end{pmatrix} \quad (17)$$

$$\rho_{i,j} = \begin{cases} (\rho_{i,j}(1) \cdots \rho_{i,j}(m_j) \quad \overbrace{0 \cdots 0}^{m_i-m_j}), & j \neq t \\ (\rho_{i,j}(1) \cdots \rho_{i,j}(m_j)), & j = t \end{cases} \quad (18)$$

$$\theta_{i,j} = \begin{cases} (\theta_{i,j}(1) \cdots \theta_{i,j}(m_j) \quad \overbrace{0 \cdots 0}^{m_i-m_j}), & j \neq t \\ (\theta_{i,j}(1) \cdots \theta_{i,j}(m_j)), & j = t \end{cases} \quad (19)$$

其中, $m_i = \max\{m_1, m_2, \dots, m_n\}; i, j = 1, 2, \dots, n$ 。特别地, 当排列结构中不存在某类点集的元素时, 即在此排列结构中该类点集所有元素丢失, 为了保持在点集 L_1, L_2, \dots, L_n 下的排列结构对应的极坐标特征矩阵行维数一致, 将该类点集对应的极径和极角关系用 0 元素补齐。

2.2 极坐标特征矩阵相似度

为了能够定量的分析点集 L_1, L_2, \dots, L_n 下的两种排列结构间的相似程度, 进行如下定义:

$$\gamma_P = \sqrt{\sum_{i=1}^{n^2} \sum_{j=1}^m [I_{P_1}(i, j) - I_{P_2}(i, j)]^2} \quad (20)$$

$$\gamma_\Theta = \sqrt{\sum_{i=1}^{n^2} \min\left\{\sum_{j=1}^m |\angle [I_{\Theta_1}(i, j) - I_{\Theta_2}(i, x)]|^2\right\}} \quad (21)$$

$$|\angle [I_{\Theta_1}(i, j) - I_{\Theta_2}(i, x)]| = \begin{cases} \frac{|I_{\Theta_1}(i, j) - I_{\Theta_2}(i, j)|}{\pi}, & I_{\Theta_1}(i, x) - I_{\Theta_2}(i, x) < \pi \\ 2 - \frac{|I_{\Theta_1}(i, x) - I_{\Theta_2}(i, j)|}{\pi}, & I_{\Theta_1}(i, x) - I_{\Theta_2}(i, x) \geq \pi \end{cases} \quad (22)$$

其中, $x = 1, 2, \dots, m$ 且 x 取值互不相等; $(\gamma_P, \gamma_\Theta)$ 为 (P_1, Θ_1) 与 (P_2, Θ_2) 的相似度; $I_{P_i}(i, j)$ 为极径矩阵 P_i 内的第 (i, j) 个元素, $I_{\Theta_i}(i, j)$ 为极角矩阵 Θ_i 内的第 (i, j) 个元素; n^2, m 为极坐标特征矩阵的行列数, 特别地, 当 (P_1, Θ_1) 与 (P_2, Θ_2) 的列维数不一致时, m 取 (P_1, Θ_1) 与 (P_2, Θ_2) 列维数的最大值, 并用 0 元素将低维矩阵向高维矩阵进行列补齐。对于 $(\gamma_P, \gamma_\Theta), (\gamma_P, \gamma_\Theta)$ 越趋近

于 $(0, 0)$, 则说明两种极坐标特征矩阵越接近, 两种排列结构的相似程度越高。当 $(\gamma_P, \gamma_\Theta) = (0, 0)$, 则说明两种排列结构完全一致。

3 极坐标特征矩阵检测法特性

3.1 唯一性

根据极坐标系特点, 对于平面上的两个点, 一个点到另一个点在平面上的位置关系有唯一的一个极坐标向量 (ρ, θ) 描述, 同时, 一个极坐标向量 (ρ, θ) 也只能描述唯一的一对点在平面上的位置关系, 即二者之间是一一对应的关系。因此, 对于平面上的点集 L_1 和 L_2 , 当 L_1 和 L_2 发生缺失、移位或置换时 (即 L_1 和 L_2 的在平面上的分布信息发生变化), 点集所对应的均值中心发生改变, 点位变换如图 6 所示, L_1 和 L_2 所对应的 4 种位置关系则都发生改变, 使对应的极径矩阵 P 与极角矩阵 Θ 内元素的排列顺序和数值发生变化。也就是说, L_1 和 L_2 在平面上的每种排列结构都有唯一的一个极坐标特征矩阵与之对应, 不同排列结构所对应的极坐标特征矩阵具有差异性。因此, 可以通过 (P, Θ) 来确定 L_1 与 L_2 在平面上的排列结构。




图 6 点位变换

Fig.6 Point position change

通过对比实验对极坐标特征矩阵的唯一性进行验证, 实验设置如下: 对如图 7 所示的保险盒模型进行随机抽样, 每种类型抽取 10 个样本, 进行交叉对比计算极坐标矩阵相似度, 对比实验如图 8 所示。




图 7 保险盒模型

Fig.7 The fuse box model

由图8可知,标准模型样本间的相似度高,标准模型样本与其他模型样本间的相似度,接近于(0,0)。这是因为当有保险片的位置发生变化时,根据极坐标矩阵的定义,这枚保险片与各类保险片对应的均值中心的位置关系发生变化,使得极坐标特征矩阵中包含的极径向量和极角向量发生顺序和数值变化,从而导致相似度降低。标准模型样本与其他模型样本相似程度依次为:移位 > 置换 > 缺失,这表明在本次的实验情况下,缺失对标准

模型样本排列结构产生的影响大于移位和置换。根据图8中 $(\gamma_P, \gamma_\theta)$ 的分布情况可知,两类模型样本间对应的极坐标特征矩阵间的 $(\gamma_P, \gamma_\theta)$ 呈现聚类现象,这表明从样本中提取到的极坐标特征矩阵是稳定的。样本间的误差则体现在 $(\gamma_P, \gamma_\theta)$ 的离散程度上,这也体现了极坐标特征矩阵对排列结构变化的灵敏反应。同时,这种聚类与发散的现象是极坐标特征矩阵具有唯一性的一种表现。

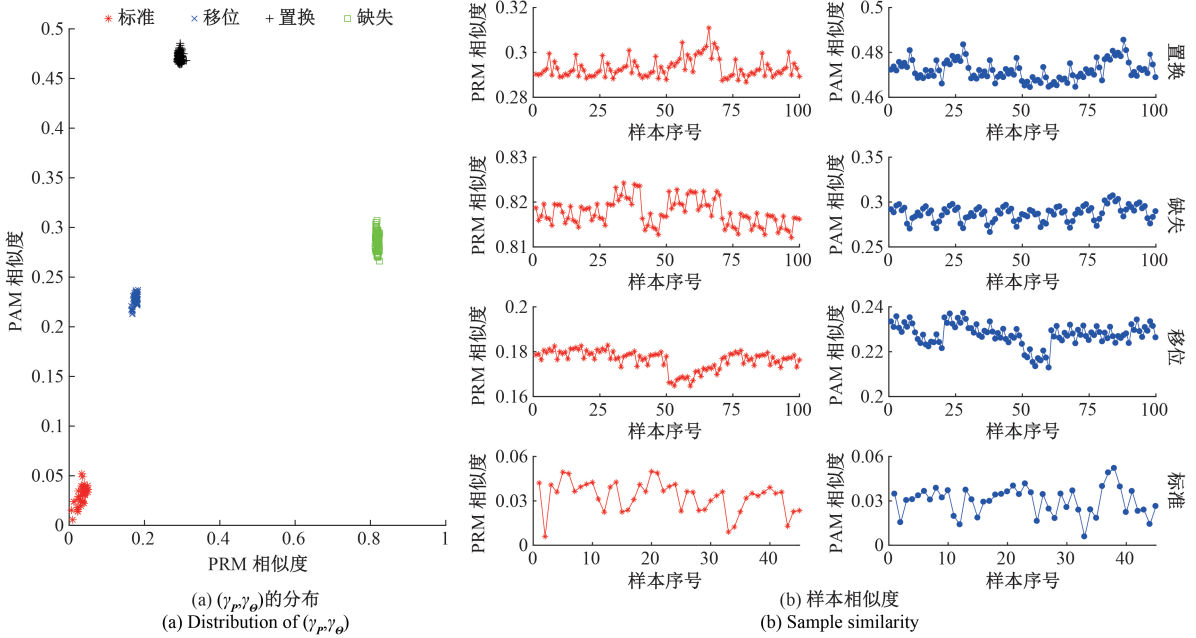


图8 对比实验

Fig.8 Comparison experiment

3.2 平移不变性

平面上点 A 与点 B 经过平移变换后的位置关系如图9所示。




图9 平移

Fig.9 Translation

由图9可知,点 A 与点 B 在经过平移后所对应的极坐标关系满足:

$$(\rho', \theta') = (\rho, \theta) \tag{23}$$

由式(13)~(16)可知,平面上的点集 L_1, L_2, \dots, L_n 在经过平移后所对应的极坐标特征矩阵满足:

$$(P', \Theta') = (P, \Theta) \tag{24}$$

由式(24)可知,极坐标特征矩阵具有平移不变性。一组平移样本如图10所示,平移样本间的极坐标特征矩阵相似度 $(\gamma_P, \gamma_\theta)$ 如图11所示。




图10 平移样本

Fig.10 Translational samples

由图11可知,平移样本间对应的 $(\gamma_P, \gamma_\theta)$ 接近于原点,这表明平移样本对应的极坐标特征矩阵相似度很




图 11 平移样本相似度

Fig.11 Similarity of the translational samples

高,而平移样本间的 $(\gamma_P, \gamma_\theta)$ 发散和不到达原点是由保险片定位过程中的误差引起的。综上可知,极坐标特征矩阵不受平移变化的影响,具有良好的平移不变性。

3.3 尺度不变性

平面上的点 A 和点 B 在不同尺度空间下的位置关系如图 12 所示。




图 12 尺度变换

Fig.12 Scale transformation

由图 12 可知,在不同尺度空间下,点 A 和 B 间的极角和极径满足:

$$\theta(1) = \theta(k) = \theta(l) \quad (25)$$

$$\rho(1) = \sqrt{\frac{S(k)}{S(1)}}\rho(k) = \sqrt{\frac{S(l)}{S(1)}}\rho(l) \quad (26)$$

式中: $S(\cdot)$ 表示实际成像面积。同理可得,极角矩阵和极径矩阵在不同尺度空间下满足:

$$\Theta(1) = \Theta(k) = \Theta(l) \quad (27)$$

$$\mathbf{P}(1) = \sqrt{\frac{S(k)}{S(1)}}\mathbf{P}(k) = \sqrt{\frac{S(l)}{S(1)}}\mathbf{P}(l) \quad (28)$$

由式(27)和(28)可知,极角矩阵具有尺度不变性;不同尺度空间下的极径矩阵具有线性关系。

一组不同尺度空间下的样本如图 13 所示,以样本对应的极径矩阵元素和($\text{sum}(\text{PRM})$)作为 y 轴,相机成像面积的算数平方根($\text{sqrt}(S)$)作为 x 轴,结果如图 14 所示。

由图 14 可知,极径矩阵在不同尺度空间下存在着线性的变化趋势。因此,对极径矩阵进行归一化的处理能够克服尺度变化对极径矩阵的影响,使得极径矩阵在不




图 13 尺度样本

Fig.13 Scale samples




图 14 极径矩阵元素和-成像面积算数平方根

Fig.14 The sum of the elements of PRM vs. the arithmetic square root of the imaging area

同尺度空间下也能具有不变性,归一化函数定义为:

$$I = \begin{cases} \frac{I - I_{\min}}{I_{\max} - I_{\min}}, & I > I_{\min} \\ \varepsilon, & I = I_{\min} \\ 0, & I = 0 \end{cases} \quad (29)$$

式中: ε 是一个很小的常数; I 是极径矩阵内元素; I_{\max} 是极径矩阵内元素的最大值; I_{\min} 是非零最小值。经过归一化后的极径矩阵与尺度空间的关系如图 15 所示。




图 15 归一化处理

Fig.15 Normalization processing

由图 15 可知,样本对应的极径矩阵经过归一化后不再随尺度空间变化而变化,具有了良好的尺度不变性。对不同尺度下的样本进行交叉比较,计算样本间的相似度,尺度样本相似度如图 16 所示。




图16 尺度样本相似度

Fig.16 Scale sample similarity

由图16可知,经过归一化处理,不同尺度空间下的极坐标特征矩阵彼此间的相似度很高,这说明相同排列结构在不同尺度空间下对应的极坐标特征矩阵具有稳定性,经过归一化处理不再随尺度空间的变化而变化。综上可知,极坐标特征矩阵检测法具有良好的尺度不变性。

3.4 旋转不变性

平面上点A与点B经过旋转变换后的位置关系如图17所示。




图17 旋转变换

Fig.17 Rotation transformation

由图17可知,点A与点B在经过旋转变换后的极坐标关系满足:

$$\begin{cases} \rho' = \rho \\ \theta' = \theta + \varphi \end{cases} \quad (30)$$

式中: φ 为旋转角。极径不随旋转变换而变化,而极角随着旋转变换而变化。即极径矩阵具有旋转不变性,而极角矩阵不具有旋转不变性。这是因为,根据极坐标特征矩阵的定义,平面上点集的排列结构在发生旋转后,将会形成新的排列结构,旋转前后对应的极坐标矩阵不再一致。一组旋转样本(模型中包含9类汽车保险片,共计59枚保险片)如图18所示,样本对应的极角矩阵在发生旋转后的变化如图19所示。

在图19中, $\Theta(\varphi)$ 表示不同旋转角对应的极角矩阵; φ 为旋转角; y 轴刻画的是旋转后极角矩阵变化的总量。由图19可知,极角矩阵变化的总量随 φ 增加呈线性变化,变化的斜率由类别与数目的乘积决定。即平面内点集旋转 φ 后,对应的极角矩阵内的有效元素(对应的极径不为0)也随之增加 φ 。因此,为了使极角矩阵能

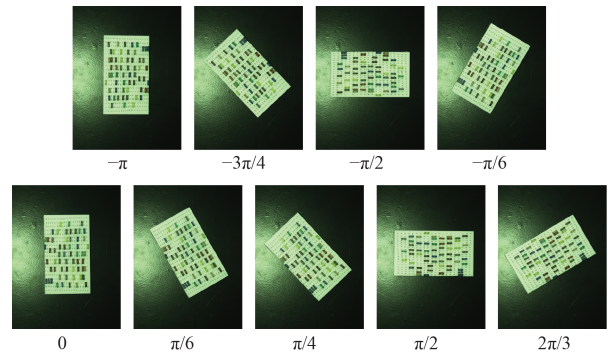


图18 旋转样本

Fig.18 Rotation samples




图19 旋转对极角矩阵的影响

Fig.19 The impact of rotation on PAM

具有旋转不变性,对极角矩阵 Θ 进行旋转矫正,矫正函数定义为:

$$\Theta = \Theta(\varphi) - \varphi(P \oplus \Theta) \quad (31)$$

式中: \oplus 为异或操作。旋转样本经过旋转矫正后的样本间的极坐标相似度如图20所示。




图20 旋转样本相似度

Fig.20 Rotation sample similarity

由图20可知,极径矩阵不随旋转变换而变化,具有良好的旋转不变性,通过旋转矫正函数能够消除旋转变换对极角矩阵的影响,使极角矩阵也能保持良好的旋转不变性。综上可知,极坐标特征矩阵检测法具有良好的旋转不变性。

4 实验与验证

实验平台如图21所示,利用极坐标特征矩阵相似度

进行保险盒检测的具体方法如下:

1) 构造标准极坐标特征矩阵 $(\mathbf{P}_{std}, \boldsymbol{\Theta}_{std})$ 。随机抽取 N 个合格的保险盒, 计算 N 个保险盒内保险片的极坐标特征矩阵, 将样本的均值作为标准极坐标特征矩阵 $(\mathbf{P}_{std}, \boldsymbol{\Theta}_{std})$, 计算公式如下:

$$(\mathbf{P}_{std}, \boldsymbol{\Theta}_{std}) = \frac{1}{N} \sum_{i=1}^N (\mathbf{P}_i, \boldsymbol{\Theta}_i) \quad (32)$$

2) 计算相似度阈值。计算样本 $(\mathbf{P}, \boldsymbol{\Theta})$ 与 $(\mathbf{P}_{std}, \boldsymbol{\Theta}_{std})$ 的相似度 $(\gamma_P, \gamma_\Theta)$, 将阈值设为样本相似度的标准差 σ 的 3 倍, 计算公式如下:

$$\sigma = \sqrt{\frac{\sum_{i=1}^N [(\gamma_P(i) - \bar{\gamma}_P)^2 + (\gamma_\Theta(i) - \bar{\gamma}_\Theta)^2]}{N - 1}} \quad (33)$$

式中: $(\bar{\gamma}_P, \bar{\gamma}_\Theta)$ 表示样本相似度的均值中心。




图 21 实验平台

Fig.21 Experiment platform

3) 利用阈值进行检测。对新检测到的汽车保险盒提取极坐标特征矩阵 $(\mathbf{P}, \boldsymbol{\Theta})$, 计算与 $(\mathbf{P}_{std}, \boldsymbol{\Theta}_{std})$ 的相似度 $(\gamma_P, \gamma_\Theta)$, 判定依据定义如下:

$$\begin{cases} \text{ture; } \sqrt{(\gamma_P - \bar{\gamma}_P)^2 + (\gamma_\Theta - \bar{\gamma}_\Theta)^2} < 3\sigma \\ \text{false; } \sqrt{(\gamma_P - \bar{\gamma}_P)^2 + (\gamma_\Theta - \bar{\gamma}_\Theta)^2} \geq 3\sigma \end{cases} \quad (34)$$

在本实验部分, 通过 20 个合格保险盒极坐标特征矩阵求得 $(\mathbf{P}_{std}, \boldsymbol{\Theta}_{std})$, 各个样本的 $(\mathbf{P}, \boldsymbol{\Theta})$ 与 $(\mathbf{P}_{std}, \boldsymbol{\Theta}_{std})$ 的相似度 $(\gamma_P, \gamma_\Theta)$ 如图 22 所示。

利用上述得到的 $(\mathbf{P}_{std}, \boldsymbol{\Theta}_{std})$ 和阈值对 1 000 个汽车保险盒进行检测(其中包含 800 个合格样本和 200 个不合格样本), 实验的目的在于验证利用极坐标特征矩阵相似度进行保险盒检测的准确率和可行性, 实验结果如图 23 所示。

由图 23 可知, 绝大多数合格样本的极坐标特征矩阵与标准特征矩阵的相似度落在阈值边界内, 并且呈现

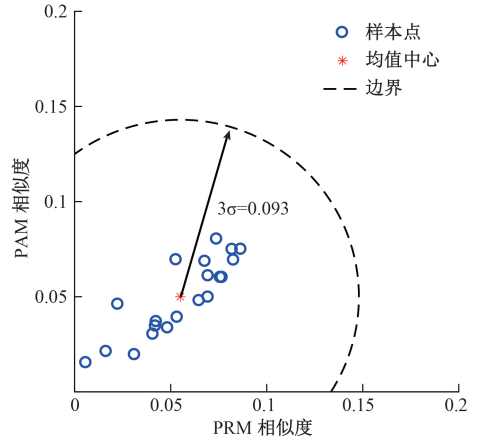
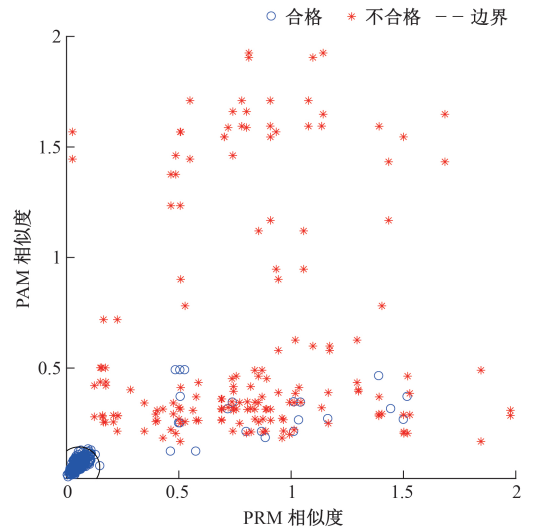



图 22 $(\mathbf{P}, \boldsymbol{\Theta})$ 与 $(\mathbf{P}_{std}, \boldsymbol{\Theta}_{std})$ 间的相似度

Fig.22 Similarity between $(\mathbf{P}, \boldsymbol{\Theta})$ and $(\mathbf{P}_{std}, \boldsymbol{\Theta}_{std})$



(a) 全局 PCFM 相似度
(a) Global PCFM similarity



(b) 局部 PCFM 相似度
(b) Local PCFM similarity

图 23 实验结果

Fig.23 Experiment result

聚类现象;不合格样本的极坐标特征矩阵与标准特征矩阵的相似度分散地落在阈值边界外。对于图 23(a)中混杂在不合格样本中的合格样本,是因为在对保险盒内的保险片进行定位与分类时出现了错误,导致提取的极坐标特征矩阵与标准极坐标特征矩阵的相似度大大降低,通过选取更优质的定位分类算法可以提高检测的准确率。对于图 23(b)中落在阈值边界外,接近于阈值边界的样本点,是因为抽样的随机性带来的代表性误差,可以通过增加抽样总体用于计算标准极坐标特征矩阵和阈值,减小代表性误差的影响,提高检测准确率。上述实验分类结果对应的混淆矩阵如表 1 所示。

表 1 分类结果混淆矩阵

Table 1 Confusion matrix of the classification result

(个)

实际情况	预测情况	
	合格	不合格
合格	776	24
不合格	0	200

由表 1 可知,利用极坐标相似度检测的准确率达到 97.6%,说明该方法对保险盒检测的应用上是有效可行的,能很好满足流线上自动化检测的需求。同时,在实际工程应用中,将不合格的汽车保险盒误判为合格带来的损失要远大于将合格保险盒判定为不合格,而这种方法保持有极高的查准率,接近 100%。

5 结 论

极坐标特征矩阵是一种多类对象排列结构的描述方法。极坐标特征矩阵由极径矩阵和极角矩阵组成,对多类对象排列结构中包含的距离与和方向信息具有很好的描述能力。通过理论分析和实验证明,所提出的极坐标特征矩阵检测法具有唯一性、平移不变性、尺度不变性和旋转不变性。极坐标特征矩阵能够对汽车保险盒内汽车保险片的排列结构进行准确的描述,通过实验证明,以极坐标特征矩阵相似度为判定依据对汽车保险盒的检测准确率达 97.6%,同时能够保持极高的查准率,接近于 100%。

参考文献

[1] YA L, ZHANG Z H. Circuit testing system of vehicle fuse box based on LabVIEW[C]. CJCM, China, 2010, 43: 132-136.

[2] 尤波,陈国杰,梁强,等.基于色度向量聚类的保险片识别及插接方法[J].仪器仪表学报,2018,39(7): 191-199.

YOU B, CHEN G J, LIANG Q, et al. Recognition and insertion method of automobile insurance tablets based on color vector clustering[J]. Chinese Journal of Scientific Instrument, 2018, 39(7): 191-199.

[3] 尹宏鹏,陈波,柴毅,等.基于视觉的目标检测与跟踪综述[J].自动化学报,2016,42(10):1466-1489.

YIN H P, CHEN B, CHAI Y, et al. Vision-based object detection and tracking: A review[J]. Acta Automatica Sinica, 2016, 42(10):1466-1489.

[4] CHI R, LU Z M, JI Q G. Real-time multi-feature based fire flame detection in video[J]. IET Image Processing, 2017, 11(1):31-37.

[5] 刘磊,王冲,赵树旺,等.基于机器视觉的太阳能电池片缺陷检测技术的研究[J].电子测量与仪器学报,2018,32(10):47-52.

LIU L, WANG CH, ZHAO SH W, et al. Research on solar cells defect detection technology based on machine vision[J]. Chinese Journal of Scientific Instrument, 2018,32(10):47-52.

[6] 闵永智,岳彪,马宏锋,等.基于图像灰度梯度特征的钢轨表面缺陷检测[J].仪器仪表学报,2018,39(4): 220-229.

MIN Y ZH, YUE B, MA H F, et al. Rail surface defects detection based on gray scale gradient characteristics of image[J]. Chinese Journal of Scientific Instrument, 2018, 39(4):220-229.

[7] LOWE D G. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision, 2004, 60(2): 91-110.

[8] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection[C]. 2005 IEEE Computer Society Conf. Computer Vision and Pattern Recognition, USA, 2005:886-893.

[9] FELZENSZWALB P F, GIRSHICK R B, MCALLESTER D, et al. Object detection with discriminatively trained part-based models[J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, 2010, 32(9): 1627-1645.

[10] AHONEN T, HADID A, PIETIKAINEN M. Face recognition with local binary patterns[C]. 8th European Conf. Computer Vision, Prague, Czech Republic, 2004, 3021:469-481.

[11] VIOLA P, JONES M J. Robust real-time face detection[J]. International Journal of Computer Vision, 2004, 57(2): 137-154.

[12] 王洋,余祖俊,朱力强,等.基于 CNN 的高速铁路侵限异物特征快速提取算法[J].仪器仪表学报,2017,38(5):1267-1275.

- WANG Y, YU Z J, ZHU L Q, et al. Fast feature extraction algorithm for high-speed railway clearance intruding objects based on CNN[J]. Chinese Journal of Scientific Instrument, 2017, 38(5):1267-1275.
- [13] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. 27th IEEE Conf. Computer Vision and Pattern Recognition (CVPR), 2014: 580-587.
- [14] HE K, ZHANG X Y, REN S Q, et al. Spatial Pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.
- [15] REN S Q, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6):1137-1149.
- [16] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. 2016 IEEE CVPR, 2016:779-788.
- [17] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. 14th ECCV, Netherlands, 2016, 9905:21-37.
- [18] 王耀南,刘良江,周博文,等.一种基于混沌优化算法的PCB板元件检测方法[J].仪器仪表学报,2010,31(2):410-415.
WANG Y N, LIU L J, ZHOU B W, et al. Detection method of printed circuit board components based on chaotic optimization algorithm [J]. Chinese Journal of Scientific Instrument, 2010,31(2):410-415.
- [19] TERESHCHENKO V, TARAN D. Optimal algorithm for constructing the Delaunay triangulation in Ed [J]. Proceedings of World Academy of Science, Engineering and Technology, 2012, 6(5): 536-541.
- [20] VON HUNDELSHAUSEN F, SUKHANKAR R. D-nets: Beyond patch-based image descriptors[C]. IEEE CVPR, USA, 2012:2941-2948.
- [21] 闫自庚,蒋建国,郭丹.基于 SURF 特征和 Delaunay 三角网格的图像匹配[J].自动化学报,2014,40(6): 1216-1222.
- YAN Z G, JIANG J G, GUO D. Image matching based on SURF feature and Delaunay triangular meshes [J]. Acta Automatica Sinica, 2014, 40(6):1216-1222.
- [22] KHODADOUST J, KHODADOUST A M. Fingerprint indexing based on expanded Delaunay triangulation[J]. Expert Systems with Applications, 2017, 81:251-267.
- [23] 徐科,王磊,王璟瑜.基于 Tetrolet 变换的热轧钢板表面缺陷识别方法[J].机械工程学报,2016,52(4):13-19.
XU K, WANG L, WANG J Y. Surface defect recognition of hot-rolled steel plates based on tetrolet transform[J]. Journal of Mechanical Engineering, 2016, 52(4): 13-19.

作者简介



陈国杰,2017年于哈尔滨理工大学获得学士学位,现为哈尔滨理工大学硕士研究生,主要研究方向为图像处理与模式识别。

E-mail:Chen_Guoj@163.com

Chen Guojie received his B. Sc. degree in 2017 from Harbin University of Science and technology. he is now a M. Sc. candidate at Harbin University of Science and technology. His main research interests include image processing and pattern recognition.



尤波(通信作者),1982年于哈尔滨工业大学获得学士学位,1988年于哈尔滨科学技术大学获得硕士学位,1995年于哈尔滨工业大学获得博士学位,现为哈尔滨理工大学教授,主要研究方向为智能机器人与机电控制。

E-mail:youbu@hrbust.edu.cn

You Bo (Corresponding author) received his B. Sc. degree from Harbin Institute of Technology in 1982, M. Sc. degree from Harbin University of Science and Technology in 1988, and Ph. D. degree from Harbin Institute of Technology in 1995. He is now a professor in Harbin University of Science and Technology. His main research interests include intelligent robot and mechatronic control.