

基于 PCA-LDA 与 SVM 的 AGV 多分支 路径识别与跟踪

茅正冲, 陈强*

江南大学轻工过程先进控制教育部重点实验室, 江苏 无锡 214122

摘要 针对自动引导车(AGV)视觉引导过程中多分支路径识别与跟踪的实时性与稳健性要求,提出一种主成分分析(PCA)-线性判别分析(LDA)与支持向量机(SVM)相结合的路径识别算法。首先对 AGV 行驶过程中拍摄的图像进行预处理,并用 PCA 与 LDA 对处理后的图像进行降维和特征提取,再利用灰狼优化算法优化后的 SVM 分类器对图像进行识别。在路径跟踪方面,利用最小二乘拟合方法计算横向偏差与航向偏差。实验表明,PCA-LDA 与 SVM 相结合能够使路径识别率达到 99.3%,并且满足实时性要求,路径跟踪误差在 20 mm 以内,满足一般工业环境需求。

关键词 视觉引导; 自动导引车; 支持向量机; 主成分分析; 线性判别分析

中图分类号 TP391 **文献标识码** A

doi: 10.3788/LOP55.091005

Recognition and Tracking of AGV Multi-Branch Path Based on PCA-LDA and SVM

Mao Zhengchong, Chen Qiang*

*Key Laboratory of Advanced Process Control for Light Industry, Ministry of Education,
Jiangnan University, Wuxi, Jiangsu 214122, China*

Abstract An algorithm combining principal component analysis (PCA)-linear discriminant analysis (LDA) with support vector machine (SVM) is proposed for the real-time and robustness requirements of multi-branch path identification and tracking in the process of automated guided vehicle(AGV) visual guidance. Firstly, the image features are obtained by image preprocessing algorithm and PCA-LDA algorithm. Next, the image is identified by SVM classifier, which is optimized by gray wolf optimization algorithm. In the aspect of path tracking, the lateral deviation and course deviation are calculated by using the least square fitting method. The experimental results show that the rate of path recognition is 99.3% and real-time requirements are achieved by using the algorithm combining PCA-LDA with SVM, and the path tracking error is within 20 mm to meet the general industrial environmental needs.

Key words vision guidance; automated guided vehicle; support vector machine; principal component analysis; linear discriminant analysis

OCIS codes 100.3008; 100.2000; 100.5010

1 引言

AGV(Automated Guided Vehicle),即自动导引车,能够沿着规定的导向路线行驶,自动完成货物的装载和卸载,是自动化物流运输系统、柔性生产组织系统的核心设备^[1-2]。视觉引导主要是通过摄像

机采集到的图像进行处理,将处理信息返回给计算机,通过计算机来控制 AGV 的行驶。相比于电磁导引方式,视觉导引有着柔性好、可靠性高等特点;相比于激光导引方式,视觉导引具有成本低、维护简单等特点^[3-4]。

在视觉引导 AGV 多分支路径识别方面,刘海

收稿日期: 2018-03-27; 修回日期: 2018-04-12; 录用日期: 2018-04-17

基金项目: 国家自然科学基金(60973095)、江苏省产学研联合创新资金——前瞻性联合研究项目(BY2015019-29)

* E-mail: 2358041226@qq.com

芹^[5]制作了 6 类路径样本,采用 Canny 算法提取出的图像边缘轮廓作为形状特征,然后用支持向量机(SVM)进行多分类任务。这种方法对路径的完整度要求较高,如果路径上有遮盖物或者光照不均衡,会出现识别准确率大幅下降的情况。武星等^[6]同样制作了 6 类路径样本,将整幅二值图像作为特征,采用核主成分分析(KPCA)-反向传播(BP)模型,对样本进行分类。这种方法相比于传统的水平和垂直投影降维,保留了特征的结构细节,但是 KPCA 采用非线性的方法抽取主成分,不能保留特征物理意义并且投影计算也相对复杂,实际测试中识别准确率并不是很高。郑少华等^[7]对提取出的路径边缘采用行扫描的方式,按照扫描到的路径边缘个数进行分类。这种方法对于单纯的二叉路和三叉路有效果,但对于左直角转弯与右直角转弯路径来说将无法识别。喻俊等^[8]采用区域投影和边缘轮廓特征同时提取的方法,提取出形状特征作为样本数据。这种方法虽然可以降低维度,但同时也丢失了大量结构信息,导致分类困难。

本文采用主成分分析(PCA)与线性判别分析(LDA)相结合的方式,对整幅二值图像进行降维与特征提取,再根据得出的主要特征信息,利用改进的 SVM 算法对路径进行有效识别。该方法减少了特征结构细节的丢失,并且有效地消除了冗余信息和噪声的干扰,可以得到精度较高的训练模型并能减少 SVM 对细节敏感的影响。在路径跟踪方面,利用最小二乘拟合的方式计算出路径的角度与距离偏差,让 AGV 根据偏差值来对路径进行跟踪。在文章的第 3 章节给出了实验与分析结果,实验结果表

明,该算法能够有效地识别路径,稳健性高,并且能够实时地跟踪路径。

2 路径识别与跟踪

2.1 图像预处理

在工业环境中,有曲线多分支路径以及直角多分支路径,曲线转弯在工作效率上比直角转弯好,但在跟踪精度上低于直角转弯,二者各有优劣。本文选取 9 种路径,包括曲线多分支路径和直角多分支路径。

在 AGV 行驶过程中,摄像机采集到的图像格式为 YCbCr 格式。首先对路径图像进行中值滤波,在消除噪声的同时尽量保证图像细节。基于处理速度与去噪效果的考虑,采用 5×5 大小的滤波算子进行中值滤波操作。在实验中采用的是蓝色导航标识带,所以通过 Cb 分量进行阈值分割效果较好,并采用最大类间方差算法(Otsu 算法)对 Cb 分量进行阈值分割。设一张图像中包含 N 个灰度级, N_1 是灰度级为 $\{0, 1, 2, \dots, m\}$ 的像素集合, N_2 是灰度级为 $\{m+1, m+2, \dots, N-1\}$,Otsu 算法的意义在于寻找某个灰度值 m 使得 N_1 与 N_2 两集合之间的方差最大。集合 N_1 与 N_2 之间的方差为

$$\sigma_B^2(m) = P_1(m) [a_1(m) - a_g]^2 + P_2(m) [a_2(m) - a_g]^2, \quad (1)$$

式中, $\sigma_B^2(m)$ 为方差, $P_1(m)$ 和 $P_2(m)$ 分别为集合 N_1 和 N_2 发生的概率, $a_1(m)$ 与 $a_2(m)$ 分别为集合 N_1 和 N_2 的平均灰度值, a_g 为整个图像的平均灰度。二值化效果如图 1(c) 所示。




图 1 预处理图像。(a)原图;(b)Cb通道;(c)二值图像

Fig. 1 Preprocessing image. (a) Original drawing; (b) Cb channel; (c) binary image

对选取的 9 种路径,分别采集 100 张样本图片,为了实验方便,随机筛选出 50 张图片作为训练样本,剩下的作为测试样本,如表 1 所示。每张图片的分辨率大小为 $640 \text{ pixel} \times 480 \text{ pixel}$ 。图像预处理后的样本模型如图 2 所示。

由路径模型可以看出,实际工作环境中导航线会有各种强光或者污染等,导致二值化后的图

像不够完整,这就要求分类器具有较强的稳健性,可以将这些有瑕疵的特征进行分类。将预处理过后的二值图像作为输入,数据维数高达 103681 维,显然如此大的维数不利于计算,而且样本数据中也含有大量噪声和不重要的特征向量。所以对数据进行降维并提取贡献值较大的特征作为分类识别的依据。

表 1 路径模型类别
Table 1 Path model category

Label	Path model	Number of samples
a	straight path	100
b	left-straight curve path	100
c	right-straight curve path	100
d	left-straight-right curve path	100
e	parking location	100
f	left quarter turn	100
g	right quarter turn	100
h	T-junction	100
i	crossroad	100




图 2 路径模型

Fig. 2 Path model

本文采用 PCA-LDA 算法对图像进行特征提取。PCA 基于方差最大化来进行数据降维,期望利用较少的数据维度,保留下更多的特征信息,而 LDA 是基于样本间距离与类内距离比值最大化来对数据进行降维的,保证样本在空间中有最佳的可分离性^[9-10]。将二者相结合并提取特征,不仅可以降低特征维度,保证实时性,也有较高的可分离性。根据采集到的路径样本,将其分为 9 类,每类 100 张图像。随机从每一类样本中选择 50 张作为训练样本,其他则为测试样本。将每一幅二值图像当作输入,可以得到一个 450×103681 大小的矩阵。首先对该矩阵进行 PCA 降维处理,PCA 利用的是最大方差理论。假设有 N 个样本,每个样本数据特征有 n 维, $\mathbf{X} = (\mathbf{x}_1 \ \mathbf{x}_2 \ \cdots \ \mathbf{x}_N)$ 为数据中心化后的样本矩阵,其中 $\mathbf{x}_i (i=1, 2, \dots, N)$ 为第 i 个样本的特征,构造协方差矩阵:

$$\mathbf{C} = \frac{1}{N} \mathbf{X} \mathbf{X}^T, \quad (2)$$

2.2 PCA-LDA 特征提取

图像特征提取的方法有很多,常见的有尺度不变特征转换 (SIFT)、加速稳健特征 (SURF) 以及方向梯度直方图 (HOG) 等。SIFT 与 SURF 复杂度较高,实时性较差,在嵌入式平台上很难实现,HOG 对噪点较为敏感且描述子生成过程较为冗长。文献 [5] 中采用 Canny 算法提取的路径轮廓特征作为输入特征,这种方法在路径没有破损的情况下,识别效果较好,但在路径被遮挡或者光照环境中,识别效果较差。文献 [8] 不仅提取了轮廓特征,也提取了区域投影特征,这种算法复杂度增加,同时在水平和垂直方向投影的过程中丢失了路径结构细节。

式中 \mathbf{C} 为 $n \times n$ 维的协方差矩阵。

将求最大方差问题转换为求特征问题,目标函数可表示为

$$\begin{cases} \mathbf{C} \mathbf{v} = \lambda \mathbf{v} \\ \|\mathbf{v}\| = 1 \end{cases}, \quad (3)$$

式中, λ 是特征值的集合, \mathbf{v} 是对应的特征向量集合。

将求出的特征值按降序排列,利用

$$\sum_{i=1}^m \lambda_i / \sum_{j=1}^m \lambda_j, \quad (4)$$

可以得出前 m 个特征的贡献度,贡献度与主成分个数的关系如图 3 所示。

由图 3 可以看出,前 100 个特征几乎包含了图像 99% 的信息,按照贡献值大于 95% 的原则,选择前 50 个特征,构造出一个 450×50 的矩阵。此时样本特征虽然包含了图像的大部分细节,但是类间相似度较高。在 PCA 降维的基础上利用 LDA 进一步特征提取。设 PCA 处理后的矩阵为 $\mathbf{Y} = (\mathbf{y}_1 \ \mathbf{y}_2 \ \cdots \ \mathbf{y}_N)$, $\mathbf{y}_i (i=1, 2, \dots, N)$ 为 m 维的列




图3 主成分个数与贡献度关系

Fig. 3 Relationship between the number of principal components and the contribution degree

表2 类间相似度

Table 2 Between-class similarity

Category	1	2	3	4	5	6	7	8	9
1	1	0.12	0.66	0.28	0.44	0.50	0	0.67	0.62
2		1	0.52	0.51	0.60	0.53	0.34	0.42	0.24
3			1	0.55	0.59	0.68	0	0.67	0.57
4				1	0.49	0.48	0	0.42	0.37
5					1	0.19	0.34	0.54	0.35
6						1	0	0.83	0.35
7							1	0.31	0.50
8								1	0.62
9									1

2.3 SVM 分类器

2.3.1 SVM 算法

SVM算法是一种常见的机器学习算法,其实质就是求解一个超平面使得离超平面最近的数据点到平面的距离最大化,而这些数据点就是所谓的支持向量。

分类超平面可表示为

$$y = \mathbf{w}^T \mathbf{x} + b. \quad (7)$$

式中, \mathbf{x} 为分类超平面上的点, \mathbf{w} 为垂直于平面的法向量, b 为偏移量。

设数据样本为 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$, 欲使 \mathbf{x}_i 到平面的距离最长, 这样就得到了一个在约束条件下的极值问题:

$$\begin{cases} \max \frac{1}{\|\mathbf{x}\|} \\ y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1, i = 1, 2, \dots, n \end{cases}. \quad (8)$$

引入拉格朗日函数和松弛因子之后, 得到一个新的约束条件下的极值问题:

$$\begin{cases} \max \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j=1}^n a_i a_j y_i y_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle \\ 0 \leq a_i \leq C, i = 1, 2, \dots, n \\ \sum_{i=1}^n a_i y_i = 0 \end{cases}, \quad (9)$$

向量, m 为降维后的特征数, 经 LDA 变换后:

$$\mathbf{Y}_{\text{lda}} = \mathbf{W}^T \mathbf{Y}, \quad (5)$$

式中, \mathbf{Y}_{lda} 为变换后的矩阵, \mathbf{W} 由 $\mathbf{S}_w^{-1} \mathbf{S}_B$ 的特征向量组成, \mathbf{S}_B 为类间散度矩阵, \mathbf{S}_w 为类内散度矩阵, 得到的特征矢量大小为 450×20 , 根据表达式

$$s = \frac{\|\boldsymbol{\mu}_i + \boldsymbol{\mu}_j\|}{\|\mathbf{s}_i^2\| + \|\mathbf{s}_j^2\|}, i, j = 1, 2, \dots, n, \quad (6)$$

可以计算出类别之间相似程度, 将得到的值归一化后并与单位矩阵相减, 可得到表 2 所示类别间相似度。式中, $\boldsymbol{\mu}_i$ 为每类样本的均值向量, \mathbf{s}_i^2 为每类样本的方差, n 为类别个数。

式中, a_i 为拉格朗日乘子, C 是一个事先设定的常量, C 越大, 分类越严格。

若遇到线性不可分的数据, 则将数据映射到高维, 使得数据变得线性可分, 再利用核函数来减少高维度计算量, 如(10)式所示:

$$f(\mathbf{x}) = \sum_{i=1}^l a_i y_i K(\mathbf{x}_i, \mathbf{x}) + b, \quad (10)$$

式中 $K(\mathbf{x}_i, \mathbf{x})$ 为所选定的核函数, 则 SVM 分类器可以表示为

$$F(\mathbf{x}) = \text{sgn}[f(\mathbf{x})], \quad (11)$$

式中 sgn 为符号函数, $|f(\mathbf{x})|$ 越大, 预测确信度越高。

2.3.2 改进 SVM 分类器

对于多分类问题, 采用“一对一法”^[11]。对于 n 个类别的样本, 两两之间构建一个 SVM 分类器, 一共设计 $n(n-1)/2$ 个分类器。由于实际测试中径向基核函数(RBF)效果较好, 所以选择其为核函数, 决策函数变为

$$f(\mathbf{x}) = \sum_{i=1}^n W_i \exp(-g \|\mathbf{x}_i - \mathbf{x}\|^2 + b), \quad (12)$$

式中 g 是核函数宽度。

针对传统的 K-CV(K-fold Cross Validation)、

LOO-CV (Leave-One-Out Cross Validation) 等交叉验证的方法来选择最优惩罚系数 c 和 g 值计算量大、复杂程度高等缺点, 本文采用灰狼优化算法 (GWO 算法) 对 SVM 参数进行优化。

GWO 算法是一种群体智能算法, 它是通过模拟狼群的组织系统和捕猎策略来达到寻优的目的^[12-13]。将狼群按照适应度的高低依次分为 $\alpha, \beta, \delta, \omega$ 四组, 由 α, β, δ 三组引导 ω 向着目标搜索。灰狼个体的更新方式可表示为

$$D = |C \cdot X_p(t) - X(t)|, \quad (13)$$

$$X(t+1) = X_p(t) - A \cdot D, \quad (14)$$

式中, t 表示迭代次数, X 表示一只灰狼的位置向量, X_p 表示猎物的位置向量, D 表示个体之间的距离, A 和 C 是系数向量。

在迭代的过程中, 保存当前获得的最好的 3 组 α, β, δ , 根据它们的位置信息来更新其他搜索代理的位置, 公式如下:

$$D_\alpha = |C \cdot X_\alpha(t) - X(t)|,$$

$$D_\beta = |C \cdot X_\beta(t) - X(t)|,$$

$$D_\delta = |C \cdot X_\delta(t) - X(t)|, \quad (15)$$

$$X_1 = X_\alpha - A_1 \cdot D_\alpha, X_2 = X_\beta - A_2 \cdot D_\beta,$$

$$X_3 = X_\delta - A_3 \cdot D_\delta, \quad (16)$$

$$X(t+1) = (X_1 + X_2 + X_3) / 3. \quad (17)$$

在不断迭代过程中, 找到最佳参数, 其优化参数流程图如图 4 所示, 其中 t 为当前迭代次数, X_i 是第 i 只灰狼个体位置, N 为狼群个数, T_{\max} 是最大迭代次数。

经过参数优化后, 选取能够达到样本分类最高精度中惩罚系数最小的那一对参数。经实际验证, 样本分类准确率最高可达 99%。

2.4 路径跟踪

路径跟踪过程中, AGV 主要通过计算得到的距离偏差与角度偏差来调整^[14-17]。采用最小二乘拟合中心线的方法, 首先将曲线也看成直线, 通过行扫描

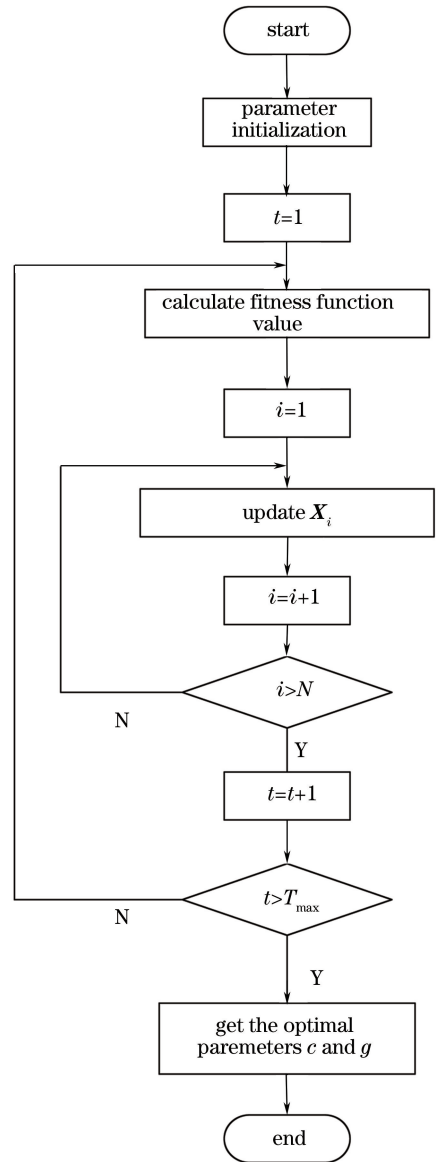


图 4 参数优化流程图

Fig. 4 Parameter optimization flowchart

得出路径边缘像素点的位置, 并由此计算出中心点的像素坐标, 再利用最小二乘直线拟合的方式得到中心线的方程:

$$k = \begin{cases} \frac{n \cdot \sum_{i=0}^{n-1} (x_i \cdot y_i) - \sum_{i=0}^{n-1} x_i \cdot \sum_{i=0}^{n-1} y_i}{n \cdot \sum_{i=0}^{n-1} x_i^2 - \left(\sum_{i=0}^{n-1} x_i\right)^2}, & x_i \neq x_j (i, j = 0, 1, \dots, n-1, i \neq j) \\ 0, & x_i = x_j (i, j = 0, 1, \dots, n-1, i \neq j) \end{cases}, \quad (18)$$

$$b = \frac{1}{n} \cdot \left(\sum_{i=0}^{n-1} y_i - k \cdot \sum_{i=0}^{n-1} x_i\right), i = 0, 1, \dots, n-1. \quad (19)$$

由于图像分辨率为 640×480 , 所以 AGV 的中轴线为 $x=320$ 。根据所得到直线方程, 可以求得距离偏差 e 与角度偏差 α :

$$e = \begin{cases} \left| 320 + \frac{b}{k} \right|, & k \neq 0 \\ |320 - x_a|, & k = 0 \end{cases}, \quad (20)$$

$$\alpha = \begin{cases} \frac{\pi}{2} + \arctan k, & k < 0 \\ \frac{\pi}{2}, & k = 0 \\ \frac{\pi}{2} - \arctan k, & k > 0 \end{cases}, \quad (21)$$

式中 x_a 为 $k=0$ 时的路径中心点横坐标。

3 实验与分析

为了验证算法的分类效果, 首先在 PC 机上用测试样本对训练好的模型进行测试, 处理器使用 i5-6300HQ, 仿真软件使用 Matlab2012a。9 类样本, 每类样本各 50 幅图像, 分类效果如图 5 所示。

由图 5 可以看出, 仅第 9 类样本有 3 个被错分成第 7 类, 识别率高达 99.3%。并且对用传统交叉




图 5 测试样本分类效果图

Fig. 5 Test sample classification renderings

验证方式优化的 SVM 器分别在训练时间与识别精度上进行比较, 如表 3 所示, 可以看出, 在保证精度的同时 GWO 算法在训练时间上大大缩短。

表 3 参数优化算法对比

Table 3 Comparison of parameter optimization algorithms

Algorithm	Training time / s	Accuracy rate / %
GWO	3.75	99.3
K-CV	66.14	99.3

另外, 本文还用文献[5]与文献[6]中的算法进行对比研究, 用之前的测试样本在其他算法上运行, 识别效果如表 4 所示。

表 4 不同算法识别效果

Table 4 Recognition effect of different algorithms

Algorithm	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Rate / %	Time / s
PCA	49/50	35/50	0/50	42/50	0/50	45/50	24/50	46/50	50/50	66.4	0.020
This paper	50/50	50/50	50/50	50/50	50/50	50/50	50/50	50/50	47/50	99.3	0.021
Method in Ref.[5]	50/50	45/50	47/50	50/50	46/50	46/50	50/50	50/50	46/50	95.5	0.027
Method in Ref.[6]	50/50	50/50	48/50	50/50	48/50	50/50	50/50	50/50	49/50	98.8	0.036

表 4 中 Rate 为测试样本的识别率, Time 是单帧图像的识别时间。由表 4 可知, 只用 PCA 来进行降维, 没有考虑到特征之间的相关性, 识别率不高; 文献[5]中, 提取路径边缘轮廓作为输入特征, 分类效果一般, 当路径有破损时, 识别率不高; 文献[6]采用 KPCA 降维, 并利用 BP 神经网络进行分类, 识别率较高, 但是单帧图像识别时间是四种算法中最多的, 当 AGV 提高运行速度时, 不能保证图像处理的实时性。本文算法用 PCA 进行数据降维, LDA 进行特征提取, 消除了噪声干扰和一些冗余信息, 并利用 GWO 算法对 SVM 进行优化, 对于图 2 中一些破损的路径图像依然有较好的分类效果, 且满足实时性要求。

为了保证 AGV 行驶中处理图片的实时性, 采用 OV7725 作为摄像头, 内置 stm32f765vit6 作为图像处理芯片, 用来识别路径, 计算偏差。AGV 主

控采用 stm32f103zet6 芯片, 根据图像处理芯片传来的路径偏差来控制 AGV 正常行驶。摄像机采样频率设为 10 frame/s, 速度控制在 $0.4 \sim 0.6$ m/s, AGV 可以有效跟踪路径行驶, 其在曲线路径与直线上跟踪效果如图 6 所示。

本文选择三种路径进行跟踪研究, 分别是直行线、左曲线转弯以及右曲线转弯。由图 6 可知, 在 AGV 跟踪直线路径行驶时, 可以让横向偏移保持在 ± 5 mm, 航向偏差在 $\pm 3^\circ$ 左右。当 AGV 跟踪曲线路径时, 横向偏差与角度偏差随之增大, 横向偏差在 ± 20 mm, 角度偏差在 $\pm 15^\circ$, 主要是由于 AGV 摄像头是倾斜安装在车头位置, 其视野较远且不是小车重心位置, 当 AGV 行驶过程中摄像头视野中出现了曲线路径, 控制器便会直接根据偏差来进行校正, 所以在曲线转弯时会出现较大的误差。在面对跟踪精度较高的环境中, 可以选择设置直角转弯路径, 避

免转弯时出现误差;当精度要求不高时,可以设置曲线路径,提高工作效率。

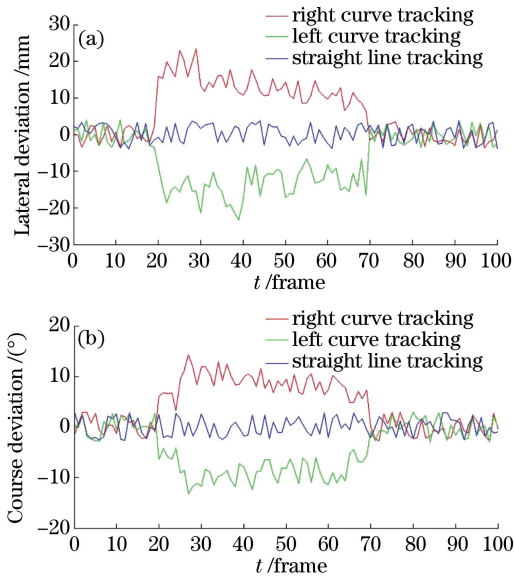


图6 跟踪误差曲线。(a)横向偏差;(b)航向偏差

Fig. 6 Tracking error curves. (a) Lateral deviation;
(b) course deviation

4 结 论

针对 AGV 多分支路径识别问题,提出了 PCA-LDA 与 SVM 相结合的方式,对预处理后的图像进行 PCA 变换,再用 LDA 进行特征提取,利用 GW0 算法优化过后的 SVM 分类器对图像进行识别。实验结果表明,相比于传统方法通过形状特征来进行分类,利用 PCA 与 LDA 结合提取的图像特征具有较高的识别率,对于光照下或者破损的图像具有识别稳健性,平均识别率达到 99.3%。在路径跟踪方面,采用最小二乘拟合的方式,满足实时性和误差要求。

参 考 文 献

[1] Verma N K, Nama P, Kumar G, *et al.* Vision based object follower automated guided vehicle using compressive tracking and stereo-vision [C] // 2015 IEEE Bombay Section Symposium, September 10-11, 2015, Mumbai, India. New York: IEEE, 2016: 1-6.

[2] Yu J, Chen Y, Ouyang L, *et al.* An image enhancement method for non-uniform illumination with illumination constraints for vision-guided AGV [C] // 2016 IEEE International Conference on Advanced Mechatronic Systems, November 30-

December 3, 2016, Melbourne, VIC, Australia. New York: IEEE, 2017: 148-153.

- [3] Draganjac I, Miklič D, Kovačić Z, *et al.* Decentralized control of multi-AGV systems in autonomous warehousing applications [J]. IEEE Transactions on Automation Science and Engineering, 2016, 13(4): 1433-1447.
- [4] Ye A, Zhu H, Xu Z, *et al.* A vision-based guidance method for autonomous guided vehicles [C] // 2012 IEEE International Conference on Mechatronics and Automation, August 5-8, 2012, Chengdu, China. New York: IEEE, 2012: 2025-2030.
- [5] Liu H Q. Research on path tracking of visual navigation AGV based on Bessel trajectory[J]. China Measurement & Test, 2017, 43(8): 113-118.
刘海芹. 基于贝塞尔轨迹的视觉导引 AGV 路径跟踪研究[J]. 中国测试, 2017, 43(8): 113-118.
- [6] Wu X, Shen W L, Lou P H, *et al.* Robust feature recognition and precise path tracking for vision-guided AGV [J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(7): 48-56.
武星, 沈伟良, 楼佩煌, 等. 视觉导引 AGV 鲁棒特征识别与精确路径跟踪研究[J]. 农业机械学报, 2016, 47(7): 48-56.
- [7] Zheng S H, Li W G, Liu W M, *et al.* The research of fast multi-path detection algorithm for visual AGV [J]. Electronic Design Engineering, 2016, 24(11): 177-180.
郑少华, 李伟光, 刘维民, 等. 视觉导航 AGV 多路径快速检测算法研究[J]. 电子设计工程, 2016, 24(11): 177-180.
- [8] Yu J, Lou P H, Wu X, *et al.* Automated guided vehicle cross path recognition based on rough set and hierarchical support vector machine [J]. Journal of Nanjing University of Aeronautics & Astronautics, 2013, 45(1): 62-69.
喻俊, 楼佩煌, 武星, 等. 基于粗糙集和分层支持向量机的 AGV 多分支路径识别[J]. 南京航空航天大学学报, 2013, 45(1): 62-69.
- [9] Wang Z J, Yu Z J, Ma K, *et al.* An image filtering algorithm based on adaptive median and gradient inverse weight [J]. Laser & Optoelectronics Progress, 2017, 54(12): 121001.
王志军, 于之靖, 马凯, 等. 一种自适应中值梯度倒数加权的图像滤波算法[J]. 激光与光电子学进展, 2017, 54(12): 121001.
- [10] Yu Z J, Wang S B. Improved PCA-SIFT algorithm for matching stereo system [J]. Laser &

- Optoelectronics Progress, 2016, 53(3): 031501.
- 于之靖, 王韶彬. 改进 PCA-SIFT 算法的立体匹配系统[J]. 激光与光电子学进展, 2016, 53(3): 031501.
- [11] Wu J, Yang H. Linear regression-based efficient SVM learning for large-scale classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2015, 26(10): 2357-2369.
- [12] Guo Z Z, Liu R, Gong C Q, *et al.* Study on improvement of gray wolf algorithm[J]. Application Research of Computers, 2017, 34(12): 3603-3606, 3610.
- 郭振洲, 刘然, 拱长青, 等. 基于灰狼算法的改进研究[J]. 计算机应用研究, 2017, 34(12): 3603-3606, 3610.
- [13] Guo K Y, Guo X L, Wang Y W. Analysis and strategy for parameter optimization methods of SVM [J]. Computer Measurement & Control, 2016, 24(6): 255-259.
- 郭克友, 郭晓丽, 王艺伟. SVM 参数优化方法分析与决策[J]. 计算机测量与控制, 2016, 24(6): 255-259.
- [14] Park J, Park Y, Kim S W. AGV parking system using artificial visual landmark [J]. International Conference on Control, Automation and Systems 2008, Oct. 14-17, 2008, Seoul, Korea. Seoul: Institute of Control, Robotics and Systems, 2008, 1579-1582.
- [15] Wang B X, Song B, Wang S A, *et al.* The research on visual navigation of AGV in outdoor environment [J]. Applied Mechanics and Materials, 2014, 536/537: 993-998.
- [16] Lu S P, Xu C, Zhong R Y. An active RFID tag-enabled locating approach with multipath effect elimination in AGV [J]. IEEE Transactions on Automation Science and Engineering, 2016, 13(3): 1333-1342.
- [17] Tang H, Liu Y H. A fully automatic calibration algorithm for a camera odometry system [J]. IEEE Sensors Journal, 2017, 17(13): 4208-4216.