

高精度移动目标位姿测量方法^①

胥 芳^② 丁信斌 占红武^③

(浙江工业大学特种装备制造与先进加工技术教育部/浙江省重点实验室 杭州 310023)

摘 要 研究了微小型机器人运动中高精度位姿测量方法。针对核相关滤波(KCF)算法对快速移动目标跟踪中由于边界效应导致误差跳动与跟踪丢失的问题,提出了基于核相关滤波的自适应(AKCF)跟踪算法。该算法融合卡尔曼滤波器作为目标的位置预测器,通过核相关滤波检测实现目标加速度方差和频率自适应,完成对卡尔曼位置预测器的校准,建立预测-检测-校准的跟踪机制;对跟踪目标形态学处理、最小二乘法圆度拟合高精度的提取特征点;利用单目视觉标定原理构建运动坐标系与图像坐标系之间的映射关系,完成高精度位姿测量。跟踪算法仿真测试实验中,AKCF 算法能够适应不同运动状态下目标的跟踪,解决 KCF 算法在跟踪过程中容易出现的目标漂移甚至丢失的问题;建立实验测试平台完成测量系统精度验证,在 400 mm × 300 mm 视场内,对半径约为 3 mm、帧间加速位移不超过 5.6 mm 的移动目标的位置检测的均方根误差达到 0.0856 mm,姿态角度检测的均方根误差达到 0.1246°。

关键词 核相关滤波(KCF), 卡尔曼滤波, 目标跟踪, 机器视觉, 位姿测量

0 引 言

随着近年来微机电系统(micro-electro-mechanical system, MEMS)技术的发展,具有体积小、运动速度快、定位精度高、结构简单、能耗低等特点的微小型机器人在微操作、微装配等精密作业领域有了越来越广泛的应用。如微型装配机器人、微型仿真机器人鱼以及用于大幅面数字打印的微小型移动机器人。微型机器人完成各种微操作的基础在于对其高精度的位姿测量,即运动分辨率要高。测量这些机器人的位姿变化对于其轨迹规划和控制效果检测有重要意义。

微型机器人的定位主要分为相对定位和绝对定位。相对定位如 Kelly 和 Pugh 等人^[1,2]提出的利用红外发送器、红外接收器实现微型移动机器人集群中机器人的相对定位算法,系统最大测距范围是 3 m,

最大误差是 8%,最大范围误差是 17.4°。Qazizada 等人^[3]采用陀螺仪、加速度计组成的惯性导航系统,通过测量机器人相对于初始位置的距离和方向确定机器人当前位姿,由于陀螺仪和加速度计存在静态漂移与积分累计误差越来越大的问题,不适合高精度定位。绝对定位常采用信标定位和全局视觉定位,张永顺等人^[4]利用超声波定位原理结合渡法和相位测量法实现了管内游动微型机器人的在线定位,能够在 1 m 的范围内实现 0.111 mm 测距精度。Diederichs 等人^[5]利用显微相机实现对微型移动机器人目标的检测、分类、定位和跟踪。该方法能实现纳米级操纵但对目标大小和运动速度有要求。视觉测量由于其非接触性和高精度特性被广泛用于对微型机器人的跟踪定位中,而实现高精度、高速度检测对目标跟踪算法有较高要求。

目标跟踪算法根据跟踪方式主要分为两大类:

① 国家自然科学基金(U1509212)和浙江省科技计划(2017C31028)资助项目。
② 女,1971 年生,博士,教授;研究方向:机电一体化控制,数字邮政装备;E-mail: fangx@zjut.edu.cn
③ 通信作者,E-mail: waltzhan@hotmail.com
(收稿日期:2018-07-06)

产生式模型方法和判别式模型方法。产生式模型方法在当前帧中对目标区域进行建模,在下一帧中寻找与模型最相似的区域就是检测区域。经典算法主要有粒子滤波^[6]、meanshift 算法^[7]、基于特征点的光流算法^[8]。产生式模型通过对每帧图像进行密集或稀疏搜索实现对目标区域的检测,对于像素多的图像,计算量太大,不适合快速检测。判别式模型利用当前帧中的目标区域作为正样本,背景区域作为负样本用来训练分类器,在下一帧中用训练好的分类器寻找最优的区域。例如 Kalal 等人^[9]提出的跟踪-学习-检测(tracking-learning-detection, TLD)长时间跟踪算法,通过离线学习完成对各种尺度,姿态变化和光照变化适应。该算法适合长时间的跟踪,但在算法跟踪速度、检测精度以及跟踪成功率方面比相关滤波跟踪算法低。相关滤波跟踪算法由于计算效率高,考虑运动目标的背景信息,采样密集实现了高精度高速度跟踪。Bolme 等人^[10]提出具有平均误差的一种相关滤波器,跟踪速度达到每秒数百帧。Henriques 等人提出基于核相关滤波的基于核检测的循环结构跟踪(circulant structure of tracking-by-detection with kernels, CSK)算法,利用循环矩阵解决密集采样问题,通过傅里叶变换实现频域中快速检测。后续又提出基于方向梯度灰度直方图特征^[12]的核相关滤波(kernelized correlation filter, KCF)跟踪算法^[13],进一步提高了算法跟踪精度。Wu 等人^[14]构建了一系列具有真实地理位置和范围的图像序列数据对各种跟踪算法进行性能分析,在相同的评价准则下得到各算法表现的优劣性。其中 KCF 跟踪算法对于跟踪对象没有先验性要求,通过自我学习可以更新分类器完成对目标的识别,在一定的误差阈值和重叠阈值内,检测精度高,检测速度快,适合对微型目标快速检测。然而 KCF 算法由于边界效应,当目标移动靠近或超过边界时,目标信息会被滤除,导致跟踪误差增大甚至丢失目标。

由于微型机器人移动精度高,移动范围较大,尺寸小等特点,设计一种基于单目视觉的位姿测量平台,针对 KCF 算法对快速移动的微小目标存在的边界效应,提出了基于核相关滤波的自适应(adaptive kernelized correlation filters, AKCF)算法。该算法通

过自适应的卡尔曼滤波器对不同运动状态下的目标位置进行有效预测,在预测位置基础上利用核相关滤波器对目标位置进行检测,使用检测结果对目标运动状态做自适应校正。该算法降低了原 KCF 算法的核响应值,提高了检测精度,保持了跟踪的稳定性。采用形态学处理方法和最小二乘法提取出跟踪区域的特征点,进一步提高了跟踪精度。利用相机标定原理实现图像坐标与运动坐标间的变换完成目标的位姿测量。该方法能够对尺寸微小的圆形移动目标进行快速有效的位姿检测,检测精度高。

1 移动机器人位姿测量原理

对于二维平面内移动的微小型机器人,位姿检测要求确定目标在运动平面内的位置信息和运动方向角。依据移动机器人检测精度要求设计视觉检测平台,建立运动平面与图像平面之间的映射关系,通过跟踪视场中机器人特征点坐标,得到微型移动机器人在运动平面中的坐标位置以及方向角。

1.1 高精度视觉测量平台

针对移动速度不大于 0.4 m/s 的微小型移动机器人在 400 mm × 300 mm 区域内的轨迹规划,要求运动分辨率达到 0.1 mm。设计视觉检测平台(图 1)保证实现在目标移动速度不超过 0.4 m/s 的情况下对目标的稳定跟踪且坐标检测精度至少为 0.1 mm。




图 1 视觉检测平台

针对目标检测要求选用 IO-Flare 系列 12M125C 相机,相机采用 Coms 全局快门,分辨率为 $4\,096 \times 3\,072$,像素误差为 0.1 mm ,帧率为 124 fps ,曝光时间可由触发信号脉宽调节。AS-FBD-2XCLD-2PE8 型号采集卡,通过 Camera link 串行总线实现对图像的采集,满足相机高帧率要求。条形 LED 灯匀光源,采用两侧打光的方式,通过外部触发控制满足实验对光照要求和保证成像时目标位移不超过一个像素。 $XY\theta$ 三轴移动平台模拟小车在二维平面的随机移动,用于对检测算法的精度验证和对视场的调整。

1.2 视觉平台标定

检测系统标定包含外部参数和内部参数的标定,内部参数的标定指对相机固有参数进行标定,得到图像坐标系到相机坐标系之间的转换关系。外部参数的标定指相机坐标系与标定目标之间的相对位姿关系,如图 2 所示为相机成像模型。




图2 相机成像模型

根据相机成像模型可知图像坐标与世界坐标转换关系如式(1)所示:

$$Z_c \begin{pmatrix} u \\ v \\ 1 \end{pmatrix} = \begin{pmatrix} \frac{f}{dx} & 0 & u_0 & 0 \\ 0 & \frac{f}{dy} & v_0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix} \begin{pmatrix} \mathbf{R} & \mathbf{T} \\ 0 & 1 \end{pmatrix} \begin{pmatrix} X_w \\ Y_w \\ Z_w \\ 1 \end{pmatrix} \quad (1)$$

式(1)中, (u, v) 为图像坐标, (X_w, Y_w, Z_w) 为世界坐标。 f 为相机焦距, dx, dy 为像元尺寸, u_0, v_0 为相机的光心坐标, $\mathbf{R}$ 为旋转矩阵, $\mathbf{T}$ 为移动矩阵, Z_c 为相机镜头到目标之间的距离。

令相机内参矩阵为 $\mathbf{M}_1$, 外参矩阵为 $\mathbf{M}_2$ 。

$$\mathbf{M}_1 = \begin{pmatrix} \frac{f}{dx} & 0 & u_0 & 0 \\ 0 & \frac{f}{dy} & v_0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix} \quad \mathbf{M}_2 = \begin{pmatrix} \mathbf{R} & \mathbf{T} \\ 0 & 1 \end{pmatrix}$$

相机的标定主要是解决相机成像平面到目标平面之间透视投影矩阵 $\mathbf{M}_1, \mathbf{M}_2$ 。若求得矩阵 $\mathbf{M}_1, \mathbf{M}_2$, 则通过图像坐标可以求得世界坐标, 已知世界坐标也可以求得图像坐标。

移动目标在二维平面内的位姿(图3)需计算目标在运动平面内的位置坐标和运动姿态角。为方便观察移动目标的运动情况, 以移动机器人的起始点为原点建立坐标系 xoy 。




图3 目标二维运动位姿

移动机器人运动偏转角度的确定至少需要 2 个特征点 P_0, P'_0 , 选这两个特征点的中点为移动机器人的位置坐标。如式(2)所示, 为移动机器人位姿 (x, y, θ) 计算表达式。

$$\begin{cases} x = \frac{x_{11} + x_{10}}{2} - \frac{x_{01} + x_{00}}{2} \\ y = \frac{y_{11} + y_{10}}{2} - \frac{y_{01} + y_{00}}{2} \\ \theta = \tan^{-1} \frac{y_{11} - y_{10}}{x_{11} - x_{10}} - \tan^{-1} \frac{y_{01} - y_{00}}{x_{01} - x_{00}} \end{cases} \quad (2)$$

式(2)中, $(x_{00}, y_{00}), (x_{01}, y_{01})$ 为机器人上特征点 P_0, P'_0 的初始运动坐标, $(x_{10}, y_{10}), (x_{11}, y_{11})$ 为机器人运动中对特征点 P_1, P'_1 的坐标。

2 高速移动目标跟踪算法

针对跟踪目标尺寸较小,移动精度高以及移动速度较快的特点,基于 KCF 目标跟踪算法原理,实现对选择目标的实时在线跟踪。KCF 跟踪算法,利用循环矩阵采样样本训练分类器,在保证密集采样的同时根据循环矩阵的特性降低了计算复杂度,引进核函数将特征空间映射到更高维的空间中增强了模型的表示能力,因此该算法有较高的跟踪精度和运算速度。然而该算法未涉及目标的运动状态信息,因此当目标移动速度过快时,会发生目标跟踪框漂移导致跟踪误差突变甚至发生目标丢失情况。针对 KCF 跟踪算法存在的以上问题,提出 AKCF 算法完成在高速移动下目标自适应检测跟踪。在 AKCF 算法中通过对跟踪目标运动信息分析,依据核相关检测自动修正卡尔曼预测器的运动状态实现加速度方差和频率的自适应,完成对运动目标位置的有效预测,防止当目标移动速度过快时跟踪不稳定导致跟踪误差增大甚至跟踪丢失的情况。

2.1 核相关滤波跟踪算法

(1) 岭回归分类器

KCF 跟踪算法目标是训练一个分类器 $f(\mathbf{z}) = \mathbf{w}^T \mathbf{z}$, 使得样本方向梯度直方图 (histogram of oriented gradient, HOG) 特征 x_i 与其回归期望输出 y_i 之间误差最小。该优化问题最优解可以表示为

$$\min \sum_i (f(x_i) - y_i)^2 + \lambda \|\mathbf{w}\|^2 \tag{3}$$

式(3)中, λ 为固定正则化参数。引入核函数将样本空间映射到非线性空间 $\varphi(\mathbf{x})$, 定义核相关函数为 $k(\mathbf{x}, \mathbf{x}') = \varphi^T(\mathbf{x})\varphi(\mathbf{x}')$, 设 $\mathbf{w} = \sum_{i=1}^n \alpha_i \varphi(\mathbf{x}_i)$ 为样本的线性组合, 回归分类器表示为

$$f(\mathbf{z}) = \mathbf{w}^T \mathbf{z} = \sum_{i=1}^n \alpha_i k(\mathbf{z}, \mathbf{x}_i) \tag{4}$$

对回归分类器参数 $\mathbf{w}$ 求解变为对 $\boldsymbol{\alpha}$ 求解。岭回归问题解为

$$\boldsymbol{\alpha} = (\mathbf{K} + \lambda \mathbf{I})^{-1} \mathbf{y} \tag{5}$$

式(5)中, $\mathbf{K}$ 为核相关矩阵, $K_{ij} = k(\mathbf{x}_i, \mathbf{x}_j)$ 表示所有训练样本的核相关值, $\mathbf{y}$ 为所有样本回归输出, $\mathbf{I}$

为单位矩阵, $\boldsymbol{\alpha}$ 为需要优化的参数矩阵。

(2) 循环矩阵

$\mathbf{x}$ 为 $n \times 1$ 的样本特征向量, 对 $\mathbf{x}$ 进行移位后得到移位样本的回归循环 $\mathbf{X}$ 矩阵。

$$\mathbf{X} = C(\mathbf{x}) = \begin{bmatrix} x_1 & x_2 & x_3 & \cdots & x_n \\ x_n & x_1 & x_2 & \cdots & x_{n-1} \\ x_{n-1} & x_n & x_1 & \cdots & x_{n-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_2 & x_3 & x_4 & \cdots & x_1 \end{bmatrix} \tag{6}$$

式(6)中, $C(\mathbf{x})$ 第 1 行为向量 $\mathbf{x}$, 第 2 行为向量向右移一位, 其余的行依此类推。 $P^i \mathbf{x}$ 表示元素向量 $\mathbf{x}$ 第 i 次循环移位结果, 循环矩阵 $\mathbf{X}$ 通过离散傅里叶变换将其对角化表示如下:

$$\mathbf{X} = \mathbf{F} \text{diag}(\hat{\mathbf{x}}) \mathbf{F}^H \tag{7}$$

式(7)中, $\mathbf{F}$ 为离散傅里叶变换矩阵, $\hat{\mathbf{x}}$ 为对 $\mathbf{x}$ 的离散傅里叶变换, 下文中都用“ $\wedge$ ”表示离散的傅里叶变换, $\mathbf{H}$ 为矩阵的共轭转置。利用循环矩阵的特性可以将矩阵运算转换到频域中, 大大降低了运算量。

(3) 目标快速检测

根据文献[13]中提出的定理 1, 式中 $\mathbf{K}$ 为循环矩阵, 根据循环矩阵的特性将其对角化可以得到在频域下的解为

$$\hat{\boldsymbol{\alpha}} = \frac{\hat{\mathbf{y}}}{\hat{\mathbf{k}}^{xx} + \lambda} \tag{8}$$

式(8)中 $\mathbf{k}^{xx}$ 为核矩阵 $\mathbf{K}$ 的第 1 行元素向量, 利用当前帧中的目标模型对回归器参数 $\boldsymbol{\alpha}$ 进行训练, $\mathbf{k}^{xx}$ 中的元素 $k_i^{xx} = k(\mathbf{x}, \mathbf{x}_i)$ 。

$$\mathbf{k}^{xx'} = \exp\left(-\frac{1}{\sigma^2}(\|\mathbf{x}\|^2 + \|\mathbf{x}'\|^2 - 2f^{-1}(\sum_c \hat{\mathbf{x}}^* \odot \hat{\mathbf{x}}'))\right) \tag{9}$$

式(9)中核相关计算以高斯核作为基核, $\mathbf{k}^{xx'}$ 表示 $\mathbf{x}$ 与 $\mathbf{x}'$ 之间的核相关性, $\mathbf{x}$ 和 $\mathbf{x}'$ 是 C 通道 HOG 特征集合 $\mathbf{x} = [x, \cdots, x_c]$, $\mathbf{x}^*$ 表示 $\mathbf{x}$ 共轭复数。

核矩阵 $\mathbf{K}^Z$ 由目标模型 $\mathbf{X}$ 和检测样本 $\mathbf{Z}$ 核相关计算所得, 由于目标模型 $\mathbf{X}$ 和检测样本 $\mathbf{Z}$ 是由元素向量基目标 $\mathbf{x}$, 基样本 $\mathbf{z}$ 移位变换得到的循环结构矩阵, $\mathbf{K}^Z$ 为循环矩阵, $\mathbf{K}^Z$ 中的每个元素由核运算

$k(P^{i-1}\mathbf{z}, P^{i-1}\mathbf{x})$ 组成。

$$\mathbf{K}^z = C(\mathbf{k}^{xz}) \quad (10)$$

式(10)中, $\mathbf{k}^{xz}$ 为 $\mathbf{K}^z$ 第一行, 基于 $\mathbf{k}^{xz}$ 就可以得到所有循环测试样本 $P^{i-1}\mathbf{z}$ 的核相关值。回归分类器函数可以表示为

$$\mathbf{f}(\mathbf{z}) = (\mathbf{K}^z)^T \boldsymbol{\alpha} \quad (11)$$

式(11)中, $\mathbf{f}(\mathbf{z})$ 为一个向量, 表示元素向量 $\mathbf{z}$ 的所有循环移位向量响应输出值。由于 $\mathbf{K}^z$ 为循环矩阵, 将其对角化, 回归分类器转化为频域中计算:

$$\hat{\mathbf{f}}(\mathbf{z}) = \hat{\mathbf{k}}^{xz} \odot \hat{\boldsymbol{\alpha}} \quad (12)$$

式(12)中 $\odot$ 表示矩阵的点乘。取最大响应位置作为相对检测基样本点的移位输出, 可以得到目标在当前帧中的位置。

(4) 核相关滤波跟踪算法边界效应分析

核相关滤波跟踪算法利用循环移位特性保证样本的密集采样, 同时利用其对角化转化到频域计算大大降低了运算量。但由于循环矩阵特性, 可检测范围不超过样本区域大小, 如图 4 所示。




图 4 目标样本循环移位示意图

图 4 中对跟踪的目标区域进行循环移位, 得到循环移位样本。所有目标移位样本就构成对回归器参数 $\boldsymbol{\alpha}$ 的训练样本集合 $\mathbf{X}$ 。直接对目标进行循环移位得到训练样本目标不完整, 为保证训练样本目标的完整性, 对目标区域加余弦窗滤波, 经过余弦窗滤波, 得到具有完整目标的移位训练样本。

由式(8)可知, 利用目标模型 $\mathbf{X}$ 训练回归器参数 $\boldsymbol{\alpha}$, 针对每一个循环移位样本均有一个回归期望输出标签 y_i , 回归器期望输出参数 y_i 服从高斯分布:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2+y^2)}{2\sigma^2}} \quad (13)$$

式(13)中 x, y 分别为循环样本相对基样本沿 x, y 方向上循环移动距离。根据高斯模型可知离基样本移位距离越远 y_i 越小, 即离中心越远的非完整循环样本权重越小。

利用式(9)计算检测样本 $\mathbf{z}$ 和目标模型 $\mathbf{x}$ 之间的核相关性。每帧中检测样本的采样是以上一帧中最大响应位置作为基样本并循环移位得到, 而循环移位范围超过样本大小。因此当检测目标移动速度

快, 两帧之间目标中心移动接近检测框边界时, 由于余弦窗滤波作用导致目标信息被滤除, 如图 5 所示。



图 5 检测基样本图

如图 5 所示, 由于 KCF 算法的边界效应, 检测基样本 $\mathbf{z}$ 中目标信息被滤除, 当利用式(12)中的分类器对检测样本检测时, 无法正确检测目标响应最大位置导致误差变大甚至跟踪丢失。

2.2 基于核相关滤波的 AKCF 算法

对于 KCF 跟踪算法, 由于目标尺寸较小且移动速度较快, 当目标帧间位移超过算法核相关检测范围时就很容易发生跟踪目标丢失的情况, 为此提出基于核相关滤波的 AKCF 算法, 通过对目标的运动状态信息进行分析, 在核相关滤波检测前对检测样本位置进行预测, 保证检测样本在核相关检测范围

之内。

(1) 目标位置预测器

设目标状态向量表示为 $S = \{x, y, v_x, v_y\}$, (x, y) 为目标中心位置坐标, (v_x, v_y) 为目标在 x 轴、 y 轴的速度分量。由卡尔曼基本原理,根据递归运算,得到目标离散动力系统状态方程。

$$\begin{aligned} s_{k|k-1} &= As_{k-1|k-1} + Bu_{k-1} \\ p_{k|k-1} &= Ap_{k-1|k-1}A^T + Q_{k-1} \end{aligned} \tag{14}$$

式(14)中, $s_{k|k-1}$ 为目标在 k 时刻预测状态, $s_{k-1|k-1}$ 为目标在 $k-1$ 时刻状态, A 为目标的状态转移常数矩阵, B 为目标的状态控制常数矩阵, u_{k-1} 为目标的控制向量, $p_{k|k-1}$ 为 k 时刻预测协方差矩阵, $p_{k-1|k-1}$ 为 $k-1$ 时刻协方差矩阵, Q_{k-1} 为状态转移过程中误差矩阵。

对于目标状态的最优估计,利用目标观测值对目标转移状态进行校正,目标离散动力系统的状态校正方程如下:

$$\begin{aligned} K_k &= p_{k|k-1}H^T(Hp_{k|k-1}H^T + R)^{-1} \\ s_{k|k} &= s_{k|k-1} + K_k(y_{k-1} - Hs_{k-1|k-1}) \\ p_{k|k} &= (I - K_kH)p_{k|k-1} \end{aligned} \tag{15}$$

式(15)中, K_k 为状态增益矩阵, H 为观测转移矩阵, y_{k-1} 是 $k-1$ 时刻的目标观测值, $p_{k|k}$ 是目标更新校正后的协方差矩阵, R 为系统的观测误差,由于成像系统噪声较小,所以该矩阵为常数矩阵, I 为单位矩阵。

(2) 目标位置核相关滤波检测

在预测器优化输出的目标位置上,提取检测基样本,利用训练好的核相关分类器 $f(z)$ 对目标位置进行检测,响应最大位置即为目标所在位置。

(3) 目标位置预测器自适应校准

在传统的卡尔曼跟踪算法中,假设目标加速度变化不大,状态误差矩阵设为常矩阵。但实际跟踪中目标的运动状态实时可变,需要对目标的加速度状态进行统计以实时更新状态转移误差矩阵 Q_{k-1} 。对于图像观测跟踪系统而言,由于跟踪目标机动性并不高,直接以加速度变化频率 α 和方差 σ^2 来更新 Q_{k-1} , $Q_{k-1} = 2\alpha\sigma^2I$ 。

加速度变化频率 α 的自适应公式,以相邻三帧间加速度表示:

$$\alpha = \left| \frac{a_{k-1|k-1} + a_{k-3|k-3} - 2a_{k-2|k-2}}{T} \right| \tag{16}$$

式(16)中, $a_{k-1|k-1}$ 、 $a_{k-2|k-2}$ 、 $a_{k-3|k-3}$ 表示 $k-1$ 、 $k-2$ 、 $k-3$ 三个相邻时刻的加速度, α 为 $k-1$ 时刻的加速度变化频率, T 表示采样间隔数,一般为 1。由式(16)可知,当目标做匀速或匀加速运动时,加速度变化频率不发生变化,状态误差不更新。

文献[15]中,以观测位置与实际位置之间的变化同加速度扰动之间的物理关系,实现加速度方差的自适应。式(12)中核相关值的最大响应输出,表示相对检测样本基点的相对移位距离,也代表在经过卡尔曼预测器对位置预测后,从 $k-1$ 时刻到 k 时刻目标加速度扰动增量对目标位置检测的影响。

$$\Delta a = \frac{2 \times \max(f(z))}{T^2} \tag{17}$$

由于加速度方差与加速度扰动增量的绝对值成线性关系^[16],利用核响应输出值可以得到加速度方差的自适应估计公式。

$$\sigma^2 = \eta \times \left| \frac{2 \times \max(f(z))}{T^2} \right| \tag{18}$$

式(17)、(18)中, η 为线性因子, $f(z)$ 为核响应检测值。当加速度扰动变化时,目标预测位置与实际位置不符,核响应值也会发生相应变化,根据核响应值可以知道加速度方差的变化。

利用 KCF 检测算法的最大响应输出值更新目标 k 时刻的观测值如式(19)所示。

$$y_k = s_{k|k} + \max(f(z)) \tag{19}$$

对于目标状态速度,由于以核响应观测值近似作为加速度扰动值,修正目标速度状态如式(20)所示。

$$\begin{aligned} s_{k|k} \cdot v_x &= s_{k-1|k-1} \cdot v_x + \max(f(z)) \cdot x \times T \\ s_{k|k} \cdot v_y &= s_{k-1|k-1} \cdot v_y + \max(f(z)) \cdot y \times T \end{aligned} \tag{20}$$

基于核相关滤波 AKCF 算法,针对原 KCF 算法存在的边界效应,通过卡尔曼自适应滤波器在目标检测前对目标位置进行优化预测,使检测基样本在核相关检测边界之内。

3 高精度特征点提取

由于目标快速运动容易出现目标缺失和累计误

差增大的情况,直接以目标区域的中心作为特征点影响检测精度,采用目标圆形特征的圆心作为特征点。如图 6 所示,选择移动微型机器人上半径为 3 mm 的圆柱作为跟踪目标。




图 6 微型跟踪目标

(1) 跟踪目标轮廓提取

目标轮廓提取先要对目标进行图像分割,根据目标区域灰度值相似性选择区域生长法对目标区域进行分割。如图 7(a) 所示选取圆形特征中的一点作为种子,通过判断种子点领域灰度值的相似度开始生长直至将目标全部分割出来。




图 7 目标分割图

利用 Canny 算子对分割后的图像提取目标轮廓点如图 8 所示。




图 8 目标轮廓提取图

(2) 目标边缘优化

分割得到的目标非光滑的圆形,提取的边缘点容易出现“毛刺点”,利用边缘点的相邻三点 $Q_1(x_1, y_1), Q(x_2, y_2), Q_2(x_3, y_3)$, 计算边缘点的曲率,根据曲率可以剔除边缘点中的“毛刺点”, Q 点曲率 k 表示为

$$k = \frac{1}{r} = \frac{1}{\sqrt{(x_0 - x_2)^2 + (y_0 - y_2)^2}} \quad (21)$$

式(21)中, x_0, y_0 为相邻三点计算的圆心坐标,设定曲率阈值,当边缘点的曲率大于该阈值,则认为是“毛刺点”,需要剔除,边缘优化以后如图 9 所示。




图 9 边缘优化图

(3) 目标特征圆度拟合

由于跟踪会出现目标特征缺失的情况,轮廓提取则会提取只有部分轮廓点的圆形轮廓。为得到该轮廓的圆心,采用最小二乘法拟合圆的原理对轮廓点进行圆拟合。设拟合圆方程为

$$(x - x_c)^2 + (y - y_c)^2 = R^2 \quad (22)$$

式(22)中, (x_c, y_c) 为拟合圆的圆心, R 为拟合圆半径。

最小二乘拟合要求轮廓点到圆心距离平方和最小,如式(23)所示。

$$f = \sum_{i=0}^n (\sqrt{(x_i - x_c)^2 + (y_i - y_c)^2} - R)^2 \quad (23)$$

通过式(23)对轮廓点进行圆拟合,拟合圆如图 10 所示。

针对选择的特征尺寸未知和跟踪中特征部分缺失的情况,利用区域生长法和 Canny 算子提取特征轮廓点,优化轮廓边缘,采用最小二乘法原理对轮廓点进行拟合可以较高精度地提取目标区域的特征点。




图 10 轮廓拟合圆

4 高精度目标跟踪仿真实验

采用 3D Max 软件建立目标的运动模型,检测改进后算法在目标大小、目标移动速度和目标运动

状态等不同的情况下跟踪效果,并与原算法进行比较。为更加直观地表示跟踪效果,定义 Δ 为跟踪误差,即 $\Delta = \sqrt{(x' - x)^2 + (y' - y)^2}$, 其中 (x, y) 为目标中心的实际坐标,而 (x', y') 为算法检测到的目标中心坐标。

4.1 匀速运动目标跟踪实验

对于匀速运动状态,设置不同目标大小、不同移动速度的运动模型,目标移动速度等于相邻两帧间的移动位移。在相同的移动速度和相同大小的目标情况下,对目标运动进行检测,计算各个算法的检测误差,结果如图 11 所示。




图 11 匀速状态算法检测误差

计算各算法的平均误差可知,原 KCF 算法检测均方根误差为像素,AKCF 算法检测均方根误差为 $\Delta_2 = 0.9523$ 像素。由图 11 可知,对匀速运动的目标,AKCF 算法相比 KCF 算法提高了跟踪精度。

速运动目标位置的预测效果,统计 AKCF 算法,KCF 算法的核响应输出值 $f = \sqrt{f(z)_x^2 + f(z)_y^2}$, 统计结果如图 12 所示。

为观测改进算法中自适应卡尔曼滤波算法对匀




图 12 匀速状态核响应值

如图 12 所示,AKCF 算法核响应值快速收敛为 0,表明算法中的卡尔曼预测器对检测目标位置进行了有效的预测,使其在进行核相关检测时不超过检测边界并几乎处于检测中心,提高了检测精度。由式(20)可知 AKCF 算法自动对预测跟踪的初始速度进行修正,并保持在目标实际移动速度附近。根据式(18),目标加速度增量扰动几乎为 0,符合目标实际运动情况。




图 13 匀速状态检测误差与速度

由图 13 可知,KCF 算法由于边界效应,当目标运动速度超过核相关响应检测范围 $3v$ 时,就会丢失跟踪目标,导致跟踪失败。而对于 AKCF 算法,因为检测前对目标运动状态信息进行分析,在给定的预测初速度下,只要设定初速度与实际目标速度的误差值不超过核相关检测范围就能自动修正设定的预测初速度,从而保持对匀速运动目标的持续跟踪,跟踪误差不超过 2 个像素。

设置目标大小为 $r = 3\text{ mm}$,移动速度为 $\{v, 2v, 3v, 4v, 5v, 6v, 7v, \dots\}, v = \sqrt{v_x^2 + v_y^2}, v_x = 1\text{ mm/s}, v_y = 0.5\text{ mm/s}$,以目标选择框的长、宽作为 AKCF 算法中自适应卡尔曼滤波预测在 $x、y$ 方向上的初始速度。计算在不同运动速度下各算法的平均检测误差,检测结果如图 13 所示。

4.2 匀加速度运动目标跟踪实验

对于匀加速度运动状态,设计加速度 $a_x = 0.21\text{ mm}^2/\text{s}, a_y = -0.1\text{ mm}^2/\text{s}$ 和初速度 $v_x = 0.1\text{ mm/s}, v_y = -0.4\text{ mm/s}$ 、目标大小为 $r = 3\text{ mm}$ 的运动模型,利用改进前后的算法对目标进行跟踪。比较算法检测误差和状态核响应值,结果如图 14 和图 15 所示。




图 14 匀加速状态算法检测误差

图 14 中,KCF 算法在第 42 帧由于跟踪目标丢失导致误差陡然上升,在跟踪丢失后原 KCF 没有纠正机制,无法再进行后续跟踪。而对于 AKCF 算法,

始终保持检测样本不超过核相关检测边界,实现稳定的跟踪,跟踪的均方根误差为 0.8756 像素。

图 15 中,由于目标加速运动,目标帧间位移随

时间增加越来越大,而 KCF 算法中每帧检测样本的初始位置是上帧检测响应最大的位置,当目标帧间位移过大导致目标超出检测边界时,就无法再对目

标进行检测。AKCF 算法,由于自适应滤波算法在核响应检测前对目标位置进行了预测,降低并保持稳定的核响应值,保证了目标持续跟踪。




图 15 匀加速状态核响应值

对 AKCF 后算法设定不同的检测初速度,观察算法中自适应滤波器对跟踪初速度修正效果,结果如图 16 所示。

图 16 中,对于给定初速度与目标实际初速度不相符的情况,自适应滤波器会进行一定程度上的自动修正,误差越大修正花费时间越长,最终会逐渐收

敛于实际速度。但若设定误差太大,超过滤波器修正范围,也会无法进行修正而跟踪失败。由式(21)可知滤波器修正范围与核响应检测范围相关,对于不同大小的目标由于训练样本大小不同,核响应检测范围不同。




图 16 初速度自适应图

4.3 非匀加速度运动目标跟踪实验

在实际运动中,由于系统噪声干扰,理想的匀速或匀加速度运动状态难以实现。目标实际的运动状态都是受不同加速度干扰的非匀加速度运动,设计加速度与速度不断变化的螺旋线运动模型,以此检测算法对非匀加速度运动目标的跟踪效果,检测结果如图 17 和图 18 所示。

图 17 和图 18 可知,由于目标速度不断变化,相

邻两帧间目标移动位移也不断变化,KCF 算法的核响应值也在不断变化,而当目标帧间移动速度过快,超过核响应检测边界时,KCF 算法对目标跟踪就会失效。在 AKCF 算法中,因为自适应滤波器不断对目标的预测运动状态进行修正,在核检测前有效地预测了目标位置,降低核响应输出值,保证对目标的持续跟踪,跟踪均方根误差达到 1.1534 像素。




图 17 非匀加速状态检测误差图




图 18 非匀加速度状态核响应值

5 高精度平台位姿测试实验

5.1 相机系统标定实验

根据张正友标定算法原理,利用规格为 $63\text{ mm} \times 63\text{ mm} \times 6\text{ mm}$,精度为 $2\text{ }\mu\text{m}$ 的陶瓷棋盘格标定板对相机进行标定。如图 19 所示为相对相机以不同姿态拍摄得到的标定板图片。




图 19 相机系统标定图样

利用标定图片对相机内参进行计算,得到内参矩阵和外参旋转矩阵以及平移矩阵为式(24)所示。

$$\begin{aligned} M1 &= \begin{bmatrix} 10313.8 & 0 & 2006.7 \\ 0 & 10313.9 & 1565.8 \\ 0 & 0 & 1 \end{bmatrix} \\ R &= \begin{bmatrix} 0.0003 & 0.9997 & -0.0217 \\ 0.9975 & -0.0018 & -0.0694 \\ -0.0694 & -0.0217 & -0.9974 \end{bmatrix} \\ T &= [-24.3039 \quad -18.7007 \quad 467.3700] \end{aligned} \quad (24)$$




图 20 坐标转换误差图

根据解算得到的旋转矩阵与平移向量建立图像坐标平面与运动坐标平面之间转换关系,利用世界坐标已知的棋盘格,提取角点,并进行坐标映射,计算坐标转换的误差如图 20 所示。

根据提取的角点计算坐标转换的均方根误差为: $e_x = 0.056\text{ mm}$, $e_y = 0.042\text{ mm}$ 。

5.2 平台位姿检测精度测试实验

为测试实验平台对微型移动机器人的位姿检测精度,采用 $XY\theta$ 三轴微型高精度手动调节平台模拟

目标在二维平面内的随机移动,该平台移动精度为 $10\text{ }\mu\text{m}$,旋转精度为 0.1° 。由于相机自动采样时帧率固定为 52 fps,将机器人与移动平台固定,调节移动平台设置不同的采样帧间位移和帧间旋转角度可以模拟跟踪目标不同的移动速度和旋转速度。选择移动微型机器人上半径为 3 mm 的圆柱作为跟踪目标,当目标移动速度加快时,利用 KCF 算法和 AKCF 算法检测,结果如图 21 和图 22 所示。




图 21 KCF 算法检测效果图




图 22 AKCF 算法检测效果图

比较图 21 和图 22 可知,KCF 算法对于移动速度过快的目标,当目标帧间移动位移越来越大超过核响应检测范围时,容易发生跟踪框漂移失去对目标的跟踪。采用 AKCF 算法对快速运动目标进行检测时,因为对目标运动状态进行了分析,保证在进行核响应检测时目标在检测范围之内,实现了对目标持续跟踪,提高了跟踪的稳定性和精度。

根据仿真实验结果可知,AKCF 算法针对核相关滤波算法中存在的边界效应,利用卡尔曼滤波算法作为目标位置预测器。卡尔曼滤波器对目标跟踪初速度具有一定修正效果使核相关滤波跟踪算法能适应不同运动状态下的目标,避免因其边界效应导致的跟踪误差增大甚至丢失的情况。卡尔曼预测器修正能力与核相关检测范围有关,目标因加速度干扰会导致帧间位移相对前一帧位移增加,当加速位

移的增量大于核响应检测范围时就会导致跟踪目标丢失。

采样不同的帧间加速位移 s 下的图片, $s = \sqrt{x^2 + y^2}$, 其中 $x = x_i - x_{i-1}$ 、 $y = y_i - y_{i-1}$ 为在 x 、 y 方向上的加速位移。利用 AKCF 算法对目标进行检测,检测误差为 $e = \sqrt{(\Delta x)^2 + (\Delta y)^2}$, 其中 Δx 、 Δy 为 x 、 y 方向上的误差。

由图 23 可知,当目标移动的帧间加速位移超过 5.6 mm 时,跟踪误差增大,失去对目标的跟踪。在帧间加速位移不超过 5.6 mm 情况下目标最大帧间位移可达到 8 mm,满足对微型移动机器人位姿检测需求。通过对微型移动机器人的实际位姿进行检测,得到位置误差 s 和姿态误差 θ , n 为检测帧数。




图 23 帧间加速位移与检测误差图




图 24 平台位置检测误差图




图 25 平台姿态角检测误差图

由图 24 和 25 可知,实验平台对微型移动机器人位置检测均方根误差为 0.0856 mm,角度检测的均方根误差为 0.1246°,满足精度要求。

6 结 论

针对微小型移动目标在二维平面内的高精度位

姿测量问题,本文利用单目视觉成像模型和相机标定原理,建立目标运动平面坐标系和图像平面坐标系之间的映射关系。基于核相关算法融合卡尔曼滤波原理,建立自适应滤波跟踪模型。利用区域生长算法提取特征区域中的圆形特征,采用 Canny 算子提取特征轮廓。通过对边缘点优化和最小二乘法实现特征点高精度提取。针对核相关 KCF 算法存在

的边界效应,设计对检测位置进行预测保证检测样本在边界之内的 AKCF 算法。仿真结果表明,AKCF 算法能够适应不同运动状态下目标的跟踪,对设定的跟踪预测初速度误差能在一定程度上进行修正。通过对实验平台检测精度分析,该算法对于半径约为 3 mm、帧间加速位移小于 5.6 mm 的微型目标定位检测的均方根误差为 0.0856 mm,角度检测的均方根误差为 0.1246°。本文提出的微型移动目标位姿检测系统对微型移动机器人的轨迹规划奠定了基础,且提出的快速目标跟踪算法具有一定的通用性,可实现高精度稳定的实时跟踪。

但是对于实际移动目标的跟踪,由于目标遮挡、尺度变换等问题,保证对目标长时间稳定高精度的跟踪存在一定难度。设计可解决目标遮挡、尺度变换并能够保持长时间稳定高精度的跟踪是将来需要进一步研究的内容。

参考文献

- [1] Kelly I, Martinoli A. A scalable, on-board localisation and communication system for indoor multi-robot experiments[J]. *Sensor Review*, 2004, 24(2):167-180
- [2] Pugh J, Martinoli A. Relative localization and communication module for small-scale multi-robot systems[C]. In: Proceedings of the 2006 IEEE International Conference on Robotics and Automation, Orlando, USA, 2006. 188-193
- [3] Qazizada M E, Pivarčiová E. Mobile robot controlling possibilities of inertial navigation system[J]. *Procedia Engineering*, 2016, 149:404-413
- [4] 张永顺, 郭锐, 刘煜, 等. 管内游动微型机器人的在线定位方法. 哈尔滨工业大学学报[J], 2004, 36(10): 1382-1384
- [5] Chu H K, Mills J K, Cleghorn W L. Dynamic tracking of moving objects in microassembly through visual servoing [C]. In: Proceedings of the 2010 IEEE International Conference on Mechatronics and Automation, Xi'an, China, 2010. 1738
- [6] Chu H, Xie Z, Nie X, et al. Particle filter target tracking method optimized by improved mean shift[C]. In: Proceedings of the 2010 IEEE International Conference on

Information and Automation, Yinchuan, China, 2014. 991-994

- [7] Du K, Ju Y, Jin Y, et al. MeanShift tracking algorithm with adaptive block color histogram[C]. In: Proceedings of the International Conference on Consumer Electronics, Communications and Networks, Yinchuan, China, 2012. 2692-2695
- [8] Dowson N, Bowden R. Mutual information for Lucas-kanade tracking (MILK): an inverse compositional formulation[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2007, 30(1):180-185
- [9] Kalal Z, Mikolajczyk K, Matas J. Face-TLD: tracking-learning-Detection applied to faces[C]. In: Proceedings of the 2010 IEEE International Conference on Image Processing, Hong Kong, China, 2010. 3789-3792
- [10] Bolme D S, Beveridge J R, Draper B A, et al. Visual object tracking using adaptive correlation filters[C]. In: Proceedings of the Computer Vision and Pattern Recognition, San Francisco, USA, 2010. 2544-2550
- [11] Henriques J F, Rui C, Martins P, et al. Exploiting the circulant structure of tracking-by-detection with kernels [C]. In: Proceedings of the European Conference on Computer Vision, Florence, Italy, 2012. 702-715
- [12] Dalal N, Triggs B. Histograms of oriented gradients for human detection[C]. In: Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, San Diego, USA, 2005. 886-893
- [13] Henriques J F, Rui C, Martins P, et al. High-speed tracking with kernelized correlation filters [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2015, 37(3):583-596
- [14] Wu Y, Lim J, Yang M H. Object Tracking Benchmark [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2015, 37(9):1834-1848
- [15] 崔彦凯, 梁晓庚, 贾晓洪, 等. 改进的机动目标当前统计模型自适应跟踪算法[J]. 计算机仿真, 2013, 30(3):42-44
- [16] 巴宏欣, 何心怡, 方正, 等. 机动目标跟踪的一种新的方差自适应滤波算法[J]. 武汉理工大学学报(交通科学与工程版), 2011, 35(3):448-452

The method of pose measurement for high precision of moving target

Xu Fang, Ding Xinbin, Zhan Hongwu

(Key Laboratory of E&M, Ministry of Education & Zhejiang Province,
Zhejiang University of Technology, Hangzhou 310023)

Abstract

This study focuses on the method of high-precision pose measurement for moving micro-robot. In order to solve the problem of error runout and tracking loss caused by boundary effect of kernelized correlation filter (KCF) algorithm when tracking the fast moving target, an adaptive kernelized correlation filter (AKCF) algorithm is proposed. To establish a prediction-test-calibration tracking mechanism, the Kalman filter is combined as the target position predictor and through the kernel correlation filter detection, acceleration variance and frequency of target is adapted to correct the position predictor. By processing the morphology of the tracking target, the least square method is used to fit the high precision feature points. Based on the principle of monocular vision calibration, the mapping relationship between the moving coordinate system and the image coordinate system is constructed to complete high precision pose measurement. The simulation results validate that AKCF algorithm can track the target in different states and solve the problem that the KCF algorithm is prone to drift or even lose the target in the tracking process. An experimental test platform is established to verify the accuracy of the measurement system. In the $400\text{ mm} \times 300\text{ mm}$ field of view, for the radius of target about 3 mm and the acceleration displacement between frames not exceeding the 5.6 mm , the root-mean-square error of position is 0.0856 mm , and the root-mean-square error of attitude angle is 0.1246° .

Key words: kernelized correlation filter (KCF), Kalman filter, target tracking, machine vision, pose measurement