

# TOF 相机的深度数据测量误差校正方法研究

王世程 于微波 杨宏韬\*

(长春工业大学电气与电子工程学院 吉林 长春 130012)

**摘要** 针对 TOF 相机获取的原始深度数据存在多种误差,导致成像出现畸变和偏差的问题,建立极限学习机(ELM)空间配准模型,对 TOF 相机深度数据测量过程中非系统性和系统性误差的叠加导致的深度数据偏移进行统一校正,并与基于 BP 算法建立的空间配准模型以及基于小孔成像原理校正的结果进行对比。实验结果表明,采用 ELM 算法所建立的 ELM 空间配准模型大幅减小了 TOF 相机测量深度数据的误差。在综合实时性、精确性和泛化能力方面,ELM 算法比其他两种方法的数据校正效果更优,能更好地复原真实场景中的深度数据,为 TOF 相机测量的深度数据的校正提供了一种新的思路和方法。

**关键词** TOF 深度相机 极限学习机 空间配准模型 误差校正

中图分类号 TP391 文献标志码 A DOI:10.3969/j.issn.1000-386x.2020.07.007

## A DEPTH DATA MEASUREMENT ERROR CORRECTION METHOD OF TOF CAMERA

Wang Shicheng Yu Weibo Yang Hongtao\*

(College of Electrical and Electronic Engineering, Changchun University of Technology, Changchun 130012, Jilin, China)

**Abstract** There are many kinds of errors in the original depth data obtained by the TOF camera, leading to the problems of distortion and deviation in imaging. This paper establishes the extreme learning machine (ELM) spatial registration model to uniformly correct the offset of depth data caused by superposition of non-systematic and systematic errors in the depth data measurement process of the TOF camera. The results were compared with the spatial registration model based on BP algorithm and the calibration results based on the pinhole imaging principle. The experimental results show that the ELM spatial registration model established by the ELM algorithm greatly reduces the error of the depth data measured by the TOF camera. Considering real-time, accuracy and generalization capabilities, ELM algorithm has better data correction effect than the other two methods and can better recover the depth data in the real scenes. It provides a new idea and method for the correction of depth data measured by the TOF camera.

**Keywords** TOF depth camera Extreme learning machine Spatial registration model Error correction

## 0 引言

三维数据可以直观反映场景或目标的全貌信息。TOF 深度相机具有结构紧凑、帧率高、对光照不敏感等优点,是一种效率较高的 3D 成像仪器,在三维视觉系统中应用广泛<sup>[1]</sup>。由于 TOF 相机自身成像特点影响以及外界不确定环境因素的扰动,导致其获得的原始深度信息附带抖动、漂移、畸变等误差<sup>[2]</sup>,最重要的深

度信息难以直接应用。所以,对 TOF 相机获取的原始深度数据的误差进行校正尤为必要。文献[3]提出采用多采集频率的方法,以提高 TOF 相机的深度数据质量;文献[4]提出为每一个像素点计算相应的修正系数的方法对原始深度数据的误差进行修正,但该方法由于计算复杂度高导致消耗时间较长;文献[5]提出一种基于小孔成像原理的深度数据校正方法对原始深度数据的误差进行修正,但该方法对非系统误差校正具有一定的局限性;更多校正方法详见文献[6-8],

但依然存在诸多缺点。本文提出一种建立极限学习机 (ELM) 空间配准模型的方法对 TOF 相机深度数据测量过程中随机误差导致的深度偏移和系统性误差导致的深度数据高估进行了统一校正, 并与基于 BP 算法<sup>[9]</sup> 建立的空间配准模型和基于小孔成像原理校正的结果进行对比实验。

## 1 TOF 相机的深度误差分析

TOF 相机测量目标深度信息的原理是基于测量光在目标物体表面和传感器之间的飞行时间来计算场景到探测器像元之间的深度信息<sup>[10]</sup>。由于 TOF 相机自身成像特点影响以及外界不确定环境因素的扰动, 导致其获取的原始深度信息存在误差。这些误差大致可分为非系统误差和系统误差。

引起非系统误差的因素一般是使用环境的差异, 其中有环境的噪声、光的散射、运动模糊以及多光接收等<sup>[11]</sup>。激光是 TOF 相机接收的光源, 由其本身提供, 因此, 在相同的曝光时间内, 靠近相机的点容易产生过饱和现象, 远离相机的点容易造成曝光不足。同时, 相机发出的部分激光通过多次反射才被相机收到的现象是由于激光的散射以及漫反射造成, 并且与相机距离越近, 散射现象越严重。而且相机工作时间不同, 芯片的温度发生变化等都可能引起深度上的漂移<sup>[2,12]</sup>。

系统误差主要是由 TOF 相机自身硬件系统产生的实测深度距离高于实际距离的情况。相机的球面坐标系示意如图 1 所示, 同一物体平面  $\Pi_1$  上有三个点  $A$ 、 $B$ 、 $C$ , TOF 相机采集到的深度数据仅  $A$  点最接近实际深度值  $d$ 。而 TOF 相机采集到的其他位置的深度数据如被测点  $B$  和  $C$  到相机  $O$  的直线距离分别为  $r_B$  和  $r_C$ 。通常, 这种直线距离  $r_B$  或  $r_C$  总是大于垂直实际距离  $d$ , 即被测点  $B$  和  $C$  的深度信息被过高估计。同理, 对于平面  $\Pi_2$  上测得的类似位置的深度数据情况也是如此。




图 1 TOF 相机的球面坐标系示意图

令相机平面与物体平面的真实距离为  $D$ , 每个像素点实测深度数据位置和相机光心连接的直线与相机

平面所成角度为  $\theta$  ( $\theta \in (0, \frac{\pi}{2}]$ ), 则过高估计的偏差为:

$$\Delta D = \frac{D(1 - \sin\theta)}{\sin\theta} \quad (1)$$

由式(1)得出, 当角度  $\theta$  一定时, 随着真实距离的增加, 偏差  $\Delta D$  与  $D$  存在一种线性递增的关系; 当真实距离为  $D$  一定时, 随着角度  $\theta$  的增加, 偏差  $\Delta D$  与角度  $\theta$  存在一种非线性递增的关系。

在实际测量中, 当相机以光轴垂直物体平面的方式拍摄时, 越靠近镜头的光轴中心对应的物体平面待测位置的点时, 则越接近实际的垂直距离  $d$ 。而远离镜头的光轴中心对应的物体平面待测位置的点, 即处在镜头视角边缘处的点, 就会被系统性地高估。这种高估对后续图像的三维重建以及处理都会产生很大影响。

## 2 深度误差修正的 ELM 空间配准模型

TOF 相机非系统和系统误差的叠加导致的数据偏移与真值之间存在某种非线性的规律, 且很难用精确的数学模型进行描述, 因此可以采用机器学习算法对其进行处理。本文使用建立极限学习机 (ELM) 空间配准模型的方法对 TOF 相机的深度误差进行校正。

### 2.1 点云数据采集

用 TOF (tof640-20gm\_850nm) 深度相机垂直照射墙面, 实验设备环境图如图 2 所示。



图 2 实验设备环境图

为了降低随机误差的影响, 开机 40 min 预热后, 在保持相机平面与墙面平行, 且相机平面与墙面垂直距离的 1.0 ~ 4.5 m 范围内的状态下, 每隔 10 cm 采集 10 幅相应位置的深度数据并过滤掉非 0 的像素后, 求平均深度值  $z_m$ , 而该位置到墙的实际距离  $z_c$  已知。以  $z_m$  和  $z_c$  为依据, 确定采样间隔为 1 cm 对相邻深度数

据帧各个对应像素位置的  $z_m$  和  $z_c$  的值分别在  $z$  轴方向进行三次样条插值<sup>[13]</sup>处理。 $z$  轴方向样条函数如下所示:

$$S(z) = \begin{cases} S_0(z) & z \in [z_0, z_1] \\ S_1(z) & z \in [z_1, z_2] \\ S_2(z) & z \in [z_2, z_3] \\ \vdots & \vdots \\ S_{n-1}(z) & z \in [z_{n-1}, z_n] \end{cases} \quad (2)$$

进而得到近似连续又满足实际要求的离散空间照片的深度数据  $p(x_m, y_m, z_m)$  和相应的实际垂直距离信息  $z_c$ , 为后续 TOF 相机深度数据 ELM 空间配准模型的建立做好数据准备。

## 2.2 ELM 算法原理

极限学习机 (ELM) 的网络结构<sup>[14]</sup> 如图 3 所示。设输入层的输入变量个数为  $n$ , 隐含层的神经元个数为  $l$ , 输出层的  $m$  个神经元则对应  $m$  个输出变量,  $w$  为输入层与隐含层间的连接权值,  $\beta$  为隐含层与输出层间的连接权值,  $b$  为隐含层神经元的阈值。




图3 单隐层前馈神经网络结构

将输入层第  $i$  个神经元与隐含层第  $j$  个神经元之间的连接权值表示为  $w_{ij}$ , 隐含层第  $j$  个神经元与输出层第  $k$  个神经元间的连接权值表示为  $\beta_{jk}$ , 则:

$$\mathbf{w} = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1n} \\ w_{21} & w_{22} & \cdots & w_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ w_{l1} & w_{l2} & \cdots & w_{ln} \end{bmatrix}_{l \times n} \quad \boldsymbol{\beta} = \begin{bmatrix} \beta_{11} & \beta_{12} & \cdots & \beta_{1m} \\ \beta_{21} & \beta_{22} & \cdots & \beta_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ \beta_{l1} & \beta_{l2} & \cdots & \beta_{lm} \end{bmatrix}_{l \times m} \quad \mathbf{b} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_l \end{bmatrix}_{l \times 1} \quad (3)$$

假设训练集有  $Q$  个样本, 其输入矩阵  $\mathbf{X}$  和输出矩阵  $\mathbf{Y}$  分别为:

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1Q} \\ x_{21} & x_{22} & \cdots & x_{2Q} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nQ} \end{bmatrix}_{n \times Q} \quad \mathbf{Y} = \begin{bmatrix} y_{11} & y_{12} & \cdots & y_{1Q} \\ y_{21} & y_{22} & \cdots & y_{2Q} \\ \vdots & \vdots & \ddots & \vdots \\ y_{m1} & y_{m2} & \cdots & y_{mQ} \end{bmatrix}_{m \times Q} \quad (4)$$

设  $g(x)$  为隐含层神经元的激活函数, 则网络的输

出  $\mathbf{T}$  为:

$$\mathbf{T} = (t_1, t_2, \cdots, t_Q)_{m \times Q}$$

$$\mathbf{t}_j = \begin{bmatrix} t_{1j} \\ t_{2j} \\ \vdots \\ t_{mj} \end{bmatrix}_{m \times 1} = \begin{bmatrix} \sum_{i=1}^l \beta_{i1} g(w_i x_j + b_i) \\ \sum_{i=1}^l \beta_{i2} g(w_i x_j + b_i) \\ \vdots \\ \sum_{i=1}^l \beta_{im} g(w_i x_j + b_i) \end{bmatrix}_{m \times 1} \quad (5)$$

式中:  $j = 1, 2, \cdots, Q$ ,  $w_i = [w_{i1}, w_{i2}, \cdots, w_{in}]$ ,  $x_j = [x_{1j}, x_{2j}, \cdots, x_{nj}]^T$ , 则式(5)可表示为:

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T}' \quad (6)$$

式中: 矩阵  $\mathbf{T}'$  为  $\mathbf{T}$  的转置;  $\mathbf{H}$  为隐层输出矩阵。

$$\mathbf{H}(w_1, w_2, \cdots, w_l, b_1, b_2, \cdots, b_l, x_1, x_2, \cdots, x_Q) = \begin{bmatrix} g(w_1 x_1 + b_1) & g(w_2 x_1 + b_2) & \cdots & g(w_l x_1 + b_l) \\ g(w_1 x_2 + b_1) & g(w_2 x_2 + b_2) & \cdots & g(w_l x_2 + b_l) \\ \vdots & \vdots & \ddots & \vdots \\ g(w_1 x_Q + b_1) & g(w_2 x_Q + b_2) & \cdots & g(w_l x_Q + b_l) \end{bmatrix}_{Q \times l} \quad (7)$$

在训练前, 随机选取输入层和隐含层之间的连接权值  $w$  以及隐含层神经元的阈值  $b$ , 并且训练过程中它们保持不变。  $\mathbf{H}^+$  为  $\mathbf{H}$  的广义 Moore-Penrose 逆矩阵, 利用它可以求得满足零误差逼近的  $\boldsymbol{\beta}$ 。

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \cdot \mathbf{T} \quad (8)$$

ELM 算法的建模步骤如下:

- 1) 随机产生神经网络的输入层和隐含层之间的连接权值  $w$  以及隐含层神经元的阈值  $b$ ;
- 2) 计算隐含层输出矩阵  $\mathbf{H}$ ;
- 3) 通过输出矩阵  $\mathbf{H}$  的广义逆矩阵  $\mathbf{H}^+$  求得输出连接权值  $\boldsymbol{\beta}$ 。

## 2.3 ELM 配准模型建立步骤

应用 ELM 算法建立 TOF 相机深度数据空间配准模型步骤如图 4 所示。




图4 ELM 建模步骤

- 1) 以三次样条插值函数得到的  $p(x_m, y_m, z_m)$  和  $z_c$  为依据, 将 TOF 深度相机在各个空间位置上对应的像

素深度值  $p(x_m, y_m, z_m)$  和理想深度值  $z_c$  作为训练集, 任意选取几幅不同空间位置的深度图像的原始深度数据  $p(x_m, y_m, z_m)$  和对应的  $z_c$ , 并加入随机噪声信号作为测试集。

2) 构造 ELM 模型结构, 确定输入层的 3 个输入变量  $p(x_m, y_m, z_m)$ , 根据训练样本数确定隐含层神经元个数, 确定 1 个输出变量  $z_c$ 。通过训练建立测量值  $p(x_m, y_m, z_m)$  和实际深度值  $z_c$  之间的非线性映射模型。对于建立成功的 ELM 空间配准模型, 将对近似连续空间内所有像素的深度数据起到相应的校正作用。

3) 将测试集数据  $p(x_m, y_m, z_m)$  加入随机噪声信号输入到 ELM 模型中, 得到相应的输出变量  $z'_c$ 。并与 BP 算法构建的空间配准深度数据校正模型以及基于小孔成像原理校正的方法进行实验并对比, 对模型进行性能评价。

### 3 实验结果与分析

#### 3.1 实验仿真结果

本实验使用 ELM 算法和 BP 算法分别构建的空间配准深度数据校正模型以及基于小孔成像原理校正的三种方法进行实验并对比。实验数据采集范围为 1.0 ~ 4.5 m, 选取深度相机实际测量得到的 2.0 m 的深度数据图像作为实验展示。原始数据点云如图 5 所示; 基于 ELM 算法空间配准模型校正后数据点云如图 6 所示; 基于 BP 算法空间配准模型校正后数据点云如图 7 所示; 基于小孔成像原理校正后数据点云如图 8 所示。直观上来说, 图 5 中的原始数据点云很凌乱, 而图 6 - 图 8 中校正后的数据点云相对平整, 说明三种方法对原始数据点云都有大幅度的校正, 而各方法之间的校正结果并不明显。故需要对各方法之间的校正结果做进一步比较分析。




图 5 原始数据点云图




图 6 基于 ELM 算法空间配准模型校正后数据点云图

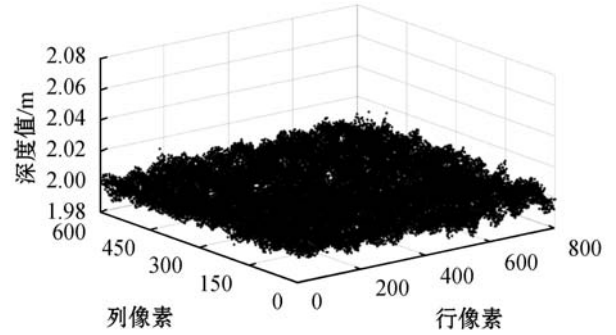


图 7 基于 BP 算法空间配准模型校正后数据点云图

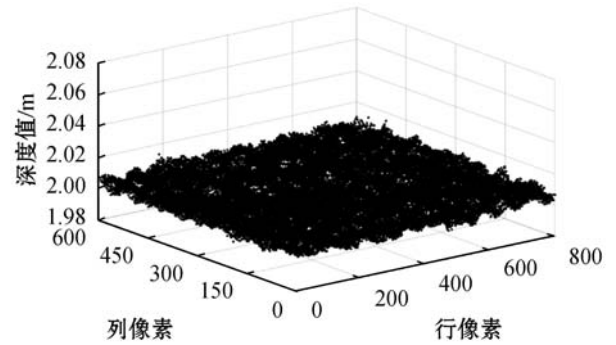


图 8 基于小孔成像原理校正后数据点云图

#### 3.2 实验结果分析

对上述三种方法的校正结果进行分析, 校正结果验证对比如图 9 所示。可以看出, 基于 ELM 算法空间配准模型校正后的深度值曲线更加收敛于实际理想深度值曲线。

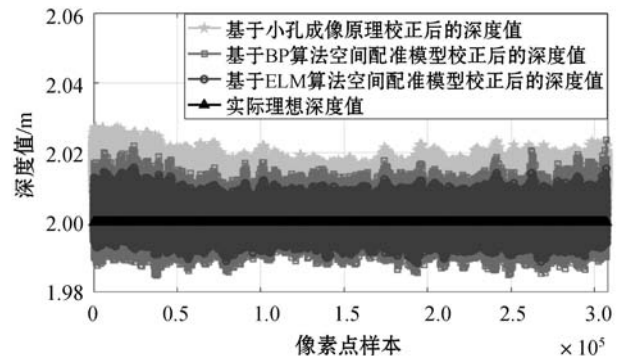


图 9 校正结果验证对比图

相对误差对比如图 10 所示。可以看出, 基于小孔成像原理、基于 BP 算法空间配准模型和基于 ELM 算

法空间配准模型校正后的深度值相对误差曲线在零值附近的振荡幅度与原始相对误差相比都大幅减小,说明三种方法对原始误差都有较大幅度的改善,并且基于 ELM 算法空间配准模型校正后的深度值相对误差曲线在零值附近的振荡幅度更小。

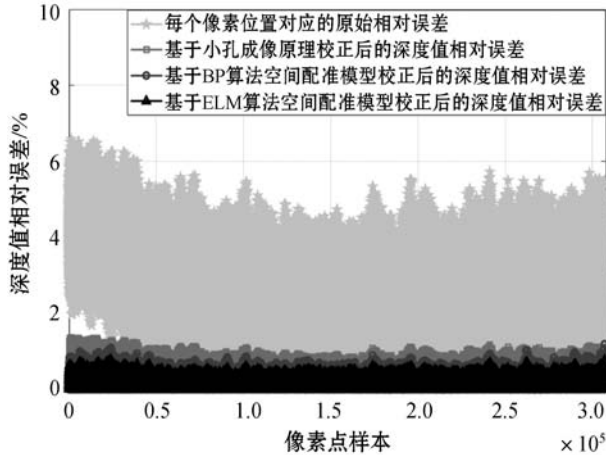


图 10 相对误差对比图

对测量距离为 2.0 m 的一幅深度数据的各像素进行定量分析,三种方法对单幅深度数据处理效果对比结果如表 1 所示。其中:基于 ELM 算法空间配准模型校正后的平均绝对误差是基于 BP 算法空间配准模型校正后的 69% 左右,是基于小孔成像原理校正的 31% 左右;均方根误差是基于 BP 算法空间配准模型校正后的 70% 左右,是基于小孔成像原理校正的 34% 左右。ELM 算法空间配准模型、BP 算法空间配准模型和基于小孔成像原理校正的平均相对误差分别为 0.13%、0.18% 和 0.41%。而且基于 ELM 算法建立的空间配准模型对单帧各像素深度数据的处理速度比基于 BP 算法建立的空间配准模型速度更快,与基于小孔成像原理校正方法耗时相当。因此,基于 ELM 算法建立的 TOF 相机深度数据空间配准模型校正效果更好。

表 1 三种方法对单幅深度数据处理效果对比列表

算法类型	平均绝对误差/m	平均相对误差/%	均方根误差	每帧处理时间/s
基于小孔成像校正	0.008 2	0.41	0.009 4	0.606
基于 BP 算法校正	0.003 6	0.18	0.004 6	9.246
基于 ELM 算法校正	0.002 5	0.13	0.003 2	0.657

对测量范围为 1.0~4.5 m 的采样间隔为 1 cm 的 351 帧深度数据图像进行分析。图 11 显示了深度空间方向对应空间位置原始数据的平均绝对误差与三种方法校正结果的平均绝对误差。




图 11 平均绝对误差对比图

由图 11 的局部放大图可以看出,经三种方法校正后的深度值的平均绝对误差值与原始误差相比都大幅减小,说明这三种方法对原始误差都有较大幅度的改善。从图 11 全局来看,基于 ELM 算法校正后的深度值的平均绝对误差值曲线在零值附近的振荡幅度更小。

三种方法处理各深度空间位置对应深度数据的平均绝对误差如表 2 所示。从表中数据很容易得出,ELM 算法空间配准模型校正后的平均绝对误差是基于 BP 算法空间配准模型校正后的 71% 左右,是基于小孔成像校正的 33% 左右。所以,基于 ELM 算法空间配准模型比基于 BP 算法空间配准模型和基于小孔成像原理校正方法对实验范围的深度数据校正的总体效果都好,其总体结果更接近实际理想深度值。

表 2 平均绝对误差对比列表 m

算法类型	最大平均误差	最小平均误差	平均绝对误差
基于小孔成像校正	0.010 1	0.004 2	0.008 9
基于 BP 算法校正	0.005 3	0.002 4	0.004 1
基于 ELM 算法校正	0.004 2	0.001 3	0.002 9

## 4 结 语

本文提出的基于极限学习机 (ELM) 空间配准模型的方法对 TOF 相机深度数据测量过程中非系统性和系统性误差的叠加导致的深度数据偏移进行了统一校正,并与基于 BP 算法建立的空间配准模型和基于小孔成像原理校正的结果进行对比,分析得出 ELM 算法空间配准模型校正的平均绝对误差是基于 BP 算法空间配准模型校正的 71% 左右,是基于小孔成像原理校正的 33% 左右。实验结果表明,采用 ELM 算法建立

的 ELM 空间配准校正模型大幅减小了 TOF 相机测得的实验范围内的深度数据帧的误差。基于 ELM 算法建立的空间配准模型比基于 BP 算法建立的空间配准模型和基于小孔成像原理校正方法对实验范围的深度数据帧校正的总体效果都好,能更好地复原真实场景中的深度数据。

## 参 考 文 献

- [ 1 ] 张旭东,吴国松,胡良梅,等. 飞行时间 3 维相机的多视角散乱点云优化配准[J]. 中国图象图形学报,2018,18(11):1445-1451.
- [ 2 ] 卢纯青,宋玉志,武延鹏,等. 基于 TOF 计算成像的三维信息获取与误差分析[J]. 红外与激光工程,2018,47(10):160-166.
- [ 3 ] Freedman D, Smolin Y, Krupka E, et al. SRA: Fast removal of general multipath for ToF sensors [J]. Lecture Notes in Computer Science, 2014, 8689:234-249.
- [ 4 ] Hussmann S, Holtorf T, Knoll F. Investigation of different polar to Cartesian coordinate system conversion methods for ToF-cameras in the close-up range[C]//2015 IEEE International Instrumentation and Measurement Technology Conference (I2MTC) Proceedings. 2015.
- [ 5 ] 王乐,罗宇,王海宽,等. ToF 深度相机测量误差校正模型[J]. 系统仿真学报,2017,29(10):2323-2329.
- [ 6 ] He Y, Liang B, Zou Y, et al. Depth errors analysis and correction for time-of-flight (ToF) cameras[J]. Sensors, 2017, 17(1):92-110.
- [ 7 ] Lambers M, Hoberg S, Kolb A. Simulation of time-of-flight sensors for evaluation of chip layout variants[J]. IEEE Sensors Journal, 2015, 15(7):4019-4026.
- [ 8 ] Chudinov A V, Gao W, Huang Z, et al. Interpolational and smoothing cubic spline for mass spectrometry data analysis [J]. International Journal of Mass Spectrometry,2016,396:42-47.
- [ 9 ] 张开生,黄谦. 基于粒子群优化 BP 神经网络的脉象识别方法[J]. 现代电子技术,2018,41(3):96-100.
- [ 10 ] 梁斌,何英,邹瑜,等. ToF 相机在空间非合作目标近距离测量中的应用[J]. 宇航学报,2016,37(9):1080-1088.
- [ 11 ] 涂义福,张旭东,张骏,等. 基于边缘特征引导的深度图像超分辨率重建[J]. 计算机应用与软件,2017,34(2):220-225.
- [ 12 ] 李兴东,李满天,郭伟,等. TOF 激光相机六自由度位姿变换估计[J]. 红外与激光工程,2015,44(7):2231-2238.
- [ 13 ] 强宁,高洁,康凤举. 基于 PSO 和三次样条插值的多机器人全局路径规划[J]. 系统仿真学报,2017,29(7):1397-1404.
- [ 14 ] 杨毅,卢诚波. 一种基于极限学习机的缺失数据填充方法[J]. 计算机应用与软件,2016,33(10):243-246.

## (上接第 13 页)

- [ 3 ] Chen T Y, Tse T H, Zhou Z Q. Fault-based testing without the need of oracles[J]. Information and Software Technology, 2002, 44(15): 923-931.
- [ 4 ] Chen T Y, Huang D H, Tse T H, et al. Case studies on the selection of useful relations in metamorphic testing [C]//Proceeding of the 4th Ibero-American Symposium on Software Engineering and Knowledge Engineering (JIISIC), Spain, 2004:569-583.
- [ 5 ] 董国伟,徐宝文,陈林,等. 蜕变测试技术综述[J]. 计算机科学与探索,2009,3(2):130-143.
- [ 6 ] Mayer J, Guderlei R. An empirical study on the selection of good metamorphic relations [C]//Proceedings of the 30th Annual International Computer Software and Applications Conference. New York: IEEE, 2006: 475-484.
- [ 7 ] 张晶,胡学钢,张斌. 基于蜕变关系的聚类程序测试方法[J]. 电子测量与仪器学报,2011,25(8):688-694.
- [ 8 ] 刘艳平. 旅行商问题求解程序的蜕变测试研究[J]. 电脑知识与技术,2017,13(32):80-82.
- [ 9 ] 董国伟,聂长海,徐宝文. 基于程序路径分析的有效蜕变测试[J]. 计算机学报,2009,32(5):1002-1013.
- [ 10 ] Chen T Y, Kuo F C, Tse T H, et al. Metamorphic testing and beyond[C]//Proceeding of the 11th Annual International Workshop on Software Technology and Engineering Practice (STEP2003). California: IEEE, 2004:94-100.
- [ 11 ] 徐晓艳. 基于 K 近邻算法的中文文本分类研究[D]. 合肥:安徽大学,2012.
- [ 12 ] Seni G, Elder J F. Ensemble methods in data mining: improving accuracy through combining predictions[M]. Morgan and Claypool Publishers, 2010.
- [ 13 ] Zhang H, Berg A C, Maire M, et al. SVM-KNN: discriminative nearest neighbor classification for visual category recognition [C]//2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06). IEEE, 2006:2126-2136.
- [ 14 ] Rish I. An empirical study of the native bayes classifier[J]. Journal of Universal Computer Science, 2001,1(2):127.
- [ 15 ] Gotlieb A, Botella B. Automated metamorphic testing[C]//Proceeding of the 27th Annual International Computer. Los Alamitos, California: IEEE Computer Society Press, 2003.
- [ 16 ] 马闯,吴涛,段梦雅. 基于 K-近邻隶属度的聚类算法研究[J]. 计算机工程与应用,2016,52(10):55-58.
- [ 17 ] 王煜. 基于决策树和 K 最近邻算法的文本分类研究[D]. 天津:天津大学,2014.
- [ 18 ] 王璐,贾可荣. 蜕变关系构造基本准则与策略研究[J]. 计算机科学,2012,39(1):115-119.
- [ 19 ] Harrington P. 机器学习实战[M]. 李锐,李鹏,曲亚东,等译. 北京:人民邮电出版社,2013.