

DOI: 10.19650/j.cnki.cjsi.J2006146

基于手势多特征融合及优化 Multiclass-SVC 的手势识别*

程淑红, 程彦龙, 杨镇豪

(燕山大学电气工程学院 秦皇岛 066004)

摘 要:深度相机的发展使得获取手势骨骼信息更加方便,为了从多维手势骨骼节点大数据中获取有用信息并在室内复杂环境和近距离条件下实现对常见双手静态交互动作的识别,提出一种基于多特征融合及生物启发式遗传算法优化多分类支持向量分类器(multiclass-SVC)的静态手势识别方法。利用手势骨骼数据设计了新的手势特征且通过特征组合策略建立更全面的手势特征序列,削弱了冗余特征产生的影响,提高了数据处理能力;采用生物启发式遗传算法优化 multiclass-SVC 的核函数与惩罚参数,得到最优核函数和惩罚参数,能够克服因随机选择核函数和惩罚参数导致手势识别准确度低的缺点;运用 P、R、F1、A 度量指标对手势识别模型进行综合评估,且通过与 KNN、MLP、MLR、XGboost 等模型的对比实验,验证了所提手势识别模型能有效提高手势识别准确度;通过迭代增加手势样本数据进行模型训练的方法分析了样本容量对手势识别准确度的影响,提供了一种提高手势识别准确度的有效方法。实验结果表明,手势识别准确率达到 98.4%,识别算法的查准率、查全率和 F1 性能评测指标均值不低于 0.98。

关键词:体感控制器; 手势特征序列; 多分类支持向量分类器; 遗传算法

中图分类号: TH701 **文献标识码:** A **国家标准学科分类代码:** 510.80

Hand gesture recognition based on multi-feature fusion and improved multiclass-SVC

Cheng Shuhong, Cheng Yanlong, Yang Zhenhao

(Institute of Electric Engineering, Yanshan University, Qinhuangdao 066004, China)

Abstract: The development of the depth camera makes it more convenient to achieve gesture skeletal information. To obtain useful information from the big data of multi-dimensional gesture skeletal nodes and realize the recognition of common two-handed static interactive actions in the complex indoor environment and close range conditions, a static gesture recognition method is proposed. It is based on multi-feature fusion and multi-classification support vector classifier (multiclass-SVC). To achieve better results, multiclass-SVC is optimized by the bioheuristic genetic algorithm. By using gesture skeletal data, a new gesture feature is designed and a more comprehensive gesture feature sequence is established through the feature combination strategy. In this way, the influence of redundant features is reduced and the ability of data processing is enhanced. The optimal kernel function and penalty parameters are obtained by optimizing the kernel function and penalty parameters of multiclass-SVC with the bioheuristic genetic algorithm. The issue of low gesture recognition accuracy is addressed, which is caused by the random selection of the kernel function and penalty parameters. Comprehensive evaluations of the gesture recognition model are carried out by using P, R, F1 and A. Comparison experiments with KNN, MLP, MLR, XGboost and other models verify that the proposed gesture recognition model can effectively improve the accuracy of gesture recognition. This paper analyzes the influence of sample size on gesture recognition accuracy through model training by adding gesture sample data iteratively. It provides an effective method to improve gesture recognition accuracy. Experimental results show that the gesture recognition accuracy can reach 98.4%. And the average precision rate, recall rate and F1 performance evaluation indexes of the recognition algorithm are not lower than 0.98.

Keywords: leap motion; gesture feature sequence; multiclass support vector classifier; genetic algorithm

收稿日期: 2020-03-03 Received Date: 2020-03-03

* 基金项目: “十三五”装备预研共用技术项目(41412040302)资助

0 引言

人机交互技术^[1]的目标是实现人与机器的自然交互,而传统的人机交互方式主要借助鼠标、键盘和操纵杆^[2]等装置完成。近年来,随着计算机视觉技术的快速发展,基于视觉的手势识别逐渐成为一种新的交互趋势,因其具有非接触、更自然和成本低等优势^[3],在智能家居、辅助驾驶及情感表达等领域具有重要的研究意义和应用价值^[4]。目前手势识别结合虚拟现实技术的发展已经取得了很大进步,有多款深度相机进入市场,如 Leap 公司的 Leap Motion^[5]和 Microsoft 的 Kinect^[6]等。深度相机可以直接提取手势骨骼信息,与普通 RGB 图像数据相比,可有效降低背景、光照强度及肤色差异在手势识别过程中存在的干扰。

为此国内外学者相继开展了有关基于深度相机进行手势识别方法的研究:Wang 等^[7]利用深度相机 Kinect 获取手势骨骼信息有效地进行无标记手部提取,将手形,相应的纹理和深度信息均以超像素的形式表示,基于此表示,提出了一种新颖的距离度量,即超像素推土铲距离用于测量手势之间的差异。Zeng 等^[8]借助 Leap Motion 获取代表手部运动动力学的手势特征,包括手指的空间位置和方向,利用径向基函数作为手势识别模型,实现对英文字母手势的识别。Ponraj 等^[9]采用 Leap Motion 体感控制器和 Flex 传感器采集手指关节坐标及角度等信息,并提出一种基于卡尔曼滤波的数据融合方法实现对点赞、OK 手势的识别。Liu 等^[10]提出一种融合 Kinect 和神经网络的手势识别方法,利用 Kinect 提取基于轨迹的手势特征,采用径向基函数神经网络对表示阿拉伯数字的不同手势特征进行建模与测试,实现对阿拉伯数字手势的识别。然而,上述手势识别研究方法存在以下不足:1) 研究对象集中于局部手势特征变化,特征序列的描述缺乏对手部运动整体性特征变化的综合考量;2) 仅依靠识别准确率难以有效衡量手势识别算法的泛化能力。

由于手势识别应用场景的多样性,对手势识别的精确性和要求各异,不同的手势识别方法并不适用于所有场景,而更多是一些特定场景。本文面向室内复杂环境,在 30.48~60.96 cm 的近距离条件下,以生活中常见的双手交互作为识别对象,并针对上述研究的不足,提出基于多特征融合及优化 multiclass-SVC 的手势识别。本文首先计算单个手势特征量并运用特征组合策略建立手势特征序列;然后将建立的手势特征序列输入到由生物启发式遗传算法优化的多分类支持向量机中,进行模型训练及性能的综合评测。在模型训练阶段通过迭代增加手势样本容量分析了样本容量对手势识别准确度的影响,

为提高手势识别准确度提供了一种可行方案。通过该项研究,以期获得一种可以有效识别手势的方法,为手势识别技术的实际应用提供理论支撑。

1 手势识别方法

本文借助体感控制器 Leap Motion 提取手部骨骼节点数据并进行手势特征量的计算,运用特征量组合策略建立手势特性序列,然后构建优化的多分类支持向量分类器作为手势识别模型并完成训练和性能度量,最后结合后验概率输出手势识别结果。本文提出的静态手势识别总体方案主要分为建立手势特征序列、搭建手势识别模型和模型训练及性能评测 3 个部分,如图 1 所示。

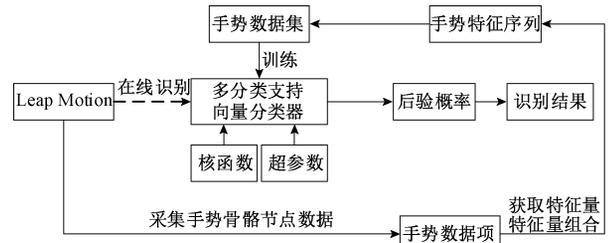


图 1 手势识别方案

Fig. 1 Scheme of hand gesture recognition

1.1 建立手势特征序列

手势骨骼信息的提取效率对后续计算特征量及进行分类至关重要。目前常用于提取手部骨骼信息的深度相机主要有 Kinect 和 Leap Motion^[11]。如图 2 所示,Leap Motion 内设两个高精度摄像头和 3 个红外 LED,在相机前方约 30.48~60.96 cm 的视场范围内可区分左右手且追踪手和手指^[12]。

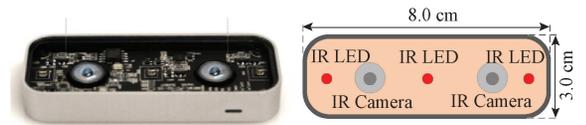


图 2 Leap Motion 实物和结构

Fig. 2 Leap motion physical map and structure diagram

相比于 Kinect 具有高灵敏度、高帧率及体积小和使用方便的优势^[13]。因此本文选择 Leap Motion 获取如表 1 所示的手势数据项,其对应的数据类型为 Leap Motion 返回参数的标准形式。各数据项如图 3 所示。其中,手掌法线方向是指与手掌平面所形成的垂直向量,手掌方向是指由手掌中心指向手指的方向,当手形发生变化,手掌球半径也会相应变化。

手势之间可以通过手势特征量进行区分,主要包括距离特征和角度特征。利用上述手势数据项就可以获取

表 1 手部数据项

Table 1 The data items of hand

手部各数据项	数据类型
手腕位置	三维坐标
掌心位置	三维坐标
手掌方向	向量
手掌平面法向量	向量
手掌球半径	数值
手指关节位置	三维坐标
指尖位置	三维坐标

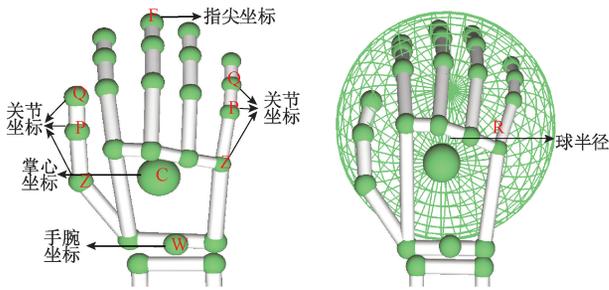


图 3 手势数据项

Fig. 3 Diagram of hand gesture data item

手势的各种距离和角度特征。目前常用的手势特征量^[14]如下所示:

1) 采用手指上相邻的两根关节组成的夹角来判断手指的弯曲幅度。计算公式如式(1)所示。

$$W_i = \arccos\left(\frac{\overline{PQ} \cdot \overline{PZ}}{|\overline{PQ}| \cdot |\overline{PZ}|}\right), i = 1, 2, \dots, 10 \quad (1)$$

式中: \overline{PQ} 与 \overline{PZ} 代表手指相邻关节组成的向量,如图3所示; $|\overline{PQ}|$ 与 $|\overline{PZ}|$ 均表示向量的模; i 表示手指索引。

2) 通过指尖到掌心距离辅助判断手指弯曲程度,计算公式如式(2)所示。

$$D_j = \frac{\|F_i - C\|}{2R}, j, i = 1, 2, \dots, 10 \quad (2)$$

式中: F_i 代表指尖空间坐标; C 代表手掌心坐标; R 代表手握球体半径。

3) 通过指尖角度特征,即手掌的方向向量与指尖在手掌平面投影之间的夹角来描述指尖变化,如图4所示。计算公式如式(3)所示。

$$A_k = \angle(F_i^\pi - C, h), k, i = 1, 2, \dots, 10 \quad (3)$$

式中: F_i^π 代表指尖在手掌平面上的投影; C 代表手掌掌心坐标; h 代表手掌的方向向量。

然而,上述手势特征量主要考虑了指尖与手掌间的耦合关系,对于相邻手指及手腕的耦合关系缺乏充分描

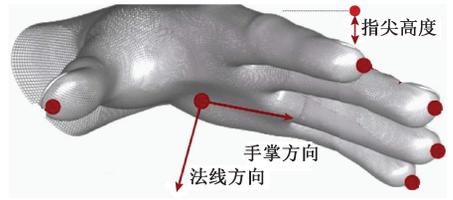


图 4 指尖角度特征

Fig. 4 Diagram of fingertip angle feature

述。如图5所示,本文通过新增指尖与手腕间的距离特征及相邻手指间的夹角特征来增强手指和手腕对手势特征的描述能力。计算公式分别如式(4)和(5)所示。再根据式(6)的归一化方案,将 L_x 归一化到 $[0, 1]$ 范围内。

$$L_x = \|F_i - w\|, x, i = 1, 2, \dots, 10 \quad (4)$$

式中: F_i 代表指尖坐标; w 代表手腕坐标。

$$B_e = \frac{\overline{P_m C} \cdot \overline{P_n C}}{|\overline{P_m C}| \cdot |\overline{P_n C}|} \quad (5)$$

式中: P_m 代表手指关节处坐标; C 代表手掌掌心坐标; $e \in [1, 6], m, n \in [1, 8]$ 。

$$l_x = \frac{l_h - \min(l_h)}{\max(l_h) - \min(l_h)}, x = 1, 2, \dots, 10 \quad (6)$$

式中: l_h 表示待归一化的欧式距离; $\min(l_h)$ 与 $\max(l_h)$ 分别是与手掌相关联的指尖到手腕距离的最小值和最大值; l_x 代表归一化之后的距离。

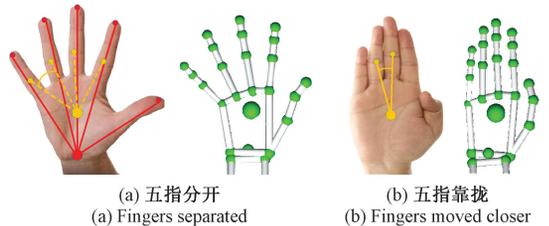


图 5 手指分开和靠拢时的二维图像和骨骼图像

Fig. 5 2D image fingers separated and moved closer and skeletal image

增加新的手势特征后,随着特征维度的增高实时性也会变差,且在這些特征中存在冗余特征,会对手势识别结果产生负作用。为提高实时性,削弱冗余特征带来的消极影响,将所有特征量经标准化处理到 $[0, 1]$ 范围内,通过对不同特征量进行组合并评测分类效果,最终得到最优手势特征序列 $S = [W, D, A, B]$ 。特征量组合方式和相应的评测效果见实验部分。

1.2 搭建手势识别模型

支持向量分类器(support vector classifier, SVC)是一种经典二类分类方法,具有良好的分类效果^[15],结合核

函数可以将手势从难以分类的输入空间映射到高维手势特征空间,然后在新空间中寻找可将手势最大程度正确分类的超平面。设训练手势集 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$, 其中 x_i 表示输入手势样本; y_i 代表手势的实际类标签。则使用 SVC 的分类过程如下所示:

$$\begin{aligned} \min_{\alpha} & \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) - \sum_{i=1}^N \alpha_i \\ \text{s. t.} & \sum_{i=1}^N \alpha_i y_i = 0, 0 \leq \alpha_i \leq C, i = 1, 2, \dots, N \end{aligned} \quad (7)$$

式中:变量 α_i 代表拉格朗日乘子,对应于一个手势样本,变量的总数等于手势训练样本容量 N ; C 代表对误分类手势样本的惩罚力度。对式(7)进行求解获得最优解 $\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_N^*)^T$, 选择 α^* 的一个分量 $\alpha_j^* \in (0, C)$, 然后计算:

$$b^* = y_j - \sum \alpha_i^* K(x_i \cdot x_j) y_i \quad (8)$$

可得到构造函数:

$$f(x) = \text{sign}(\sum_{i=1}^N \alpha_i^* K(x \cdot x_i) y_i + b^*) \quad (9)$$

式中: $K(x \cdot x_i)$ 代表核函数, 本文选择高斯径向基函数(radial basis function, RBF)^[16]。

$$K(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / 2\delta^2) \quad (10)$$

式中:参数 δ 代表单一手势样本的影响作用。构造函数的解存在且可通过映射关系得到手势类标签。

单个 SVC 只能实现两类手势的分类,为实现多类手势的识别问题,本文将多个二分类 SVC 按照一对一组合策略^[17]进行组合,构成 multiclass-SVC 作为手势识别模型,如图6所示。设手势类别数目为 K , 记为 $\{y_1, y_2, \dots, y_K\}$, 则需要 $n = K(K-1)/2$ 个二值 SVC 构成,每个分类器负责预测输出两种手势识别结果,最后根据投票法统计票数最多的预测类别即为输入手势样本的所属类别。

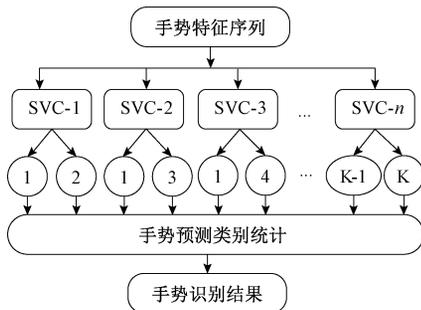


图6 多分类支持向量分类器构成

Fig. 6 The structure of Multiclass-SVC

使用 multiclass-SVC 作为手势识别模型,除了核函数 $K(x \cdot x_i)$ 的选择外,超参数 C 和 δ 的取值是影响手势识别效果的关键。 C 值作为准确性和泛化能力的调和系数,其值表示对误分类手势样本的惩罚力度。参数 δ 取

值过大易造成过拟合,反之导致欠拟合。

本文运用遗传算法^[18]和网格搜索法^[19]在手势数据集上对参数 C 和 δ 进行寻优,采用 10 折交叉验证的平均误差作为适应度函数。首先将手势集随机划分为 10 个互不相交且大小相同的子集,则共有 10 种选择,每次利用其中 9 个子集的手势数据训练模型,利用余下的 1 个手势子集测试识别效果并进行误差估计,将这一过程重复进行 10 次,最后选择 10 次误差的平均值作为测试结果。网格搜索时在有限范围 $10^0 \sim 10^3$ 内寻找参数 C 的最优取值, δ 取经验值 $1/n_features$, 即手势特征维度的倒数。如图 7 和 8 所示。

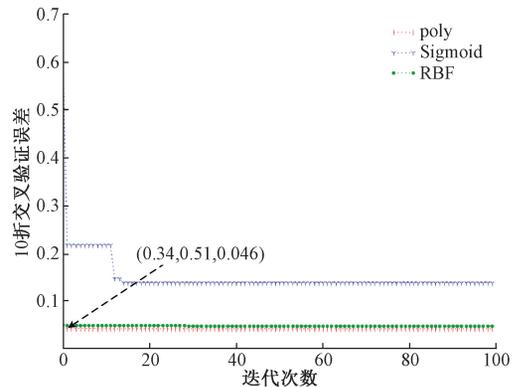


图7 遗传算法寻优

Fig. 7 Genetic algorithm optimization

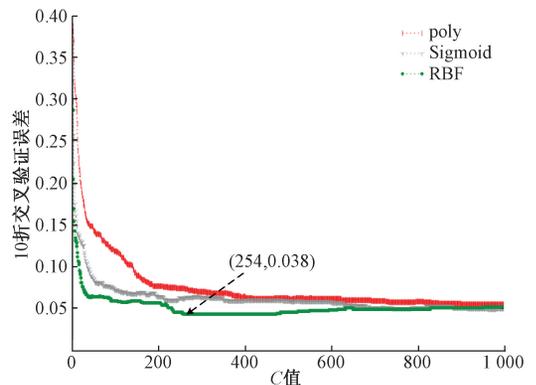


图8 网格搜索法寻优

Fig. 8 Grid search optimization

图7和8中, poly、sigmoid、RBF 分别表示多项式函数、sigmoid 函数和高斯径向基函数作为核函数时分别采用遗传算法和网格搜索法的寻优结果。通过图7和8可知,采用遗传算法进行参数寻优,当 $C=0.34, \delta=0.51$, 核函数为 poly 时,10 折交叉验证误差为 0.046。采用网格搜索法寻找最优值,当 $C=254$, 核函数为 RBF 时,10 折交叉验证误差为 0.038。因此本文最终确定的核函数为 RBF, 惩罚参数 $C=254, \delta$ 取值为 $1/n_features$ 。

1.3 手势识别模型训练

SVC 的损失函数为合页损失^[20],即当训练的手势样本被正确分类且函数间隔大于 1 时,损失值才是 0,否则损失就是 $1 - y_i(\omega \cdot x_i + b)$ 。其中, (x_i, y_i) 代表手势训练样本; (ω, b) 表示手势特征空间分离超平面的法向量和截距。训练策略是最小化合页损失,即通过迭代训练当误差值达到预期的阈值后停止训练。

论文运用 Sigmoid 函数将 SVC 标准输出值映射到 $[0, 1]$ 范围内,从而得到 SVC 后验概率^[21],如式(11)所示,从而在手势识别时,对于输入每个手势样本,不但输出预测的手势类标签,且输出对应的概率值,可用于后续对手势识别结果的辅助判断。

$$P(y = 1 | f(x)) = \frac{1}{1 + \exp(af(x) + b)} \quad (11)$$

式中: $P(y = 1 | f(x))$ 表示在输出为 $f(x)$ 的条件下输入手势为目标类的概率;参数 a 和 b 影响 Sigmoid 函数形态,运用最小化手势训练样本的负对数似然值的方法进行优化:

$$\min_{(a,b)} - \sum_{i=1}^N [\mu_i \log(v_i) + (1 - \mu_i) \log(1 - v_i)] \quad (12)$$

$$\mu_i = 1 / (1 + \exp(af(x) + b))$$

$$v_i = (y_i + 1) / 2, \quad i = 1, 2, \dots, N$$

式中: N 代表训练手势样本容量。

2 实验结果与分析

2.1 手势数据集采集

用于实验的电脑配置: Intel i7 6 700 K 处理器、8G 运行内存、GTX 1080 显卡,软件在 Ubuntu 16.04 环境下运行。为验证本文所提方法的可行性,定义了 10 种双手静态手势,如图 9 所示,其中手势编号即对应的类标签。通过 Leap Motion 采集 10 人的手势数据项,每种手势采集 10 次,最后总共获取 1 000 个手势样本,手势特征序列具体的结构如图 10 所示。

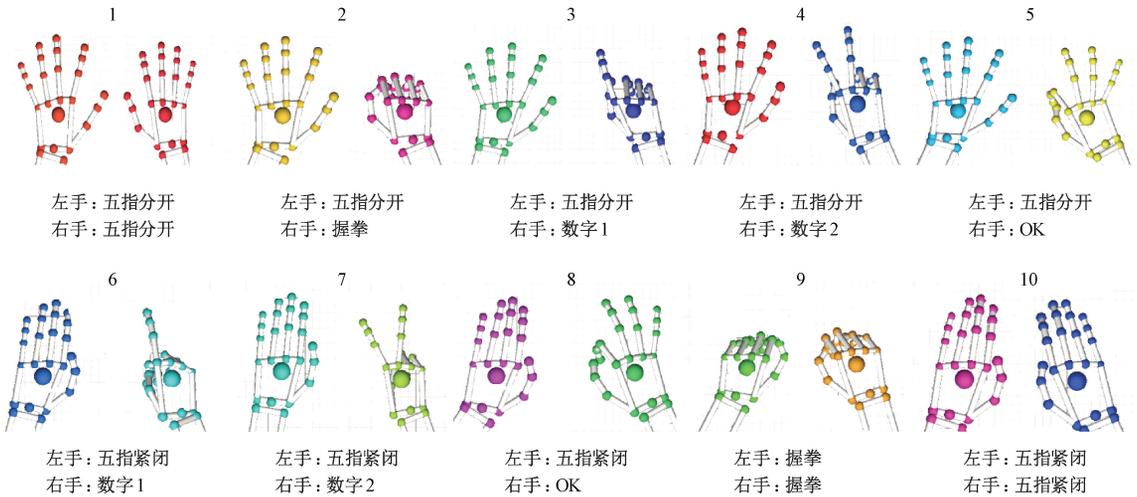


图 9 手势集样本示例

Fig. 9 Samples of hand gesture dataset

关节角(W)				指尖掌心距离(D)				指尖角度特征(A)				相邻手指夹角(B)			
$W1$	$W2$...	$W10$	$D1$	$D2$...	$D10$	$A1$	$A2$...	$A10$	$B1$	$B2$...	$B8$

图 10 手势特征序列

Fig. 10 The structure of hand gesture feature sequence

本文运用主成分分析法 (principal components analysis, PCA)^[22]对手势集数据进行直观可视化理解,如图 11 所示。通过 PCA 方法,将 38 维手势特征向量映射到 3 维空间,10 类手势通过不同颜色进行区分,可以看到每种手势都大致聚集在一起,即具有可分性,但也有少部分样本相互渗透,这与手势样本特征自身的复杂性有关,说明手势集数据是一个非线性可分问题。

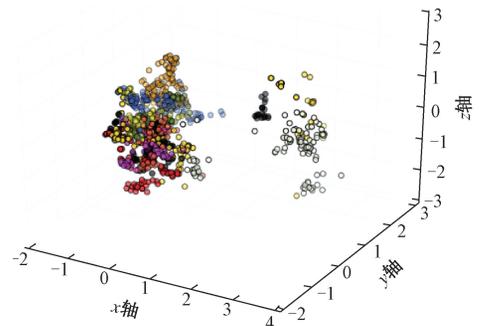


图 11 PCA 可视化手势集

Fig. 11 Visualization of hand gesture sets by PCA

2.2 识别算法性能度量指标

为评估本文方法的识别效果及手势识别模型的泛化能力,将手势数据集划分为训练集和测试集两个互斥的子集,训练集和测试集样本容量比例为3:1,使用查准率 (precision, P)、召回率 (recall, R)、F1 及准确率 (accuracy, A) 作为性能度量指标。计算方式如式(13)所示。

$$\begin{aligned}
 P &= \frac{TP}{TP + FP} \\
 R &= \frac{TP}{TP + FN} \\
 F1 &= \frac{2PR}{P + R} \\
 A &= \frac{TP + TN}{TP + FP + TN + FN}
 \end{aligned}
 \tag{13}$$

根据真实手势类别与预测手势类别的组合将其分为真正例、假正例、真反例和假反例4种情况,如图12所示,上式中 TP、FP、TN、FN 分别代表其对应的手势样本数目。

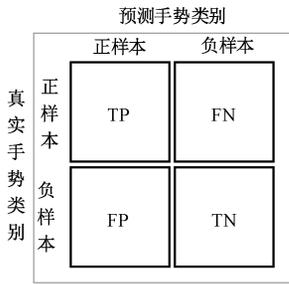


图12 手势类别情况

Fig. 12 Hand gesture category situation

2.3 手势识别结果及分析

通过手势数据集中的训练集训练模型,然后使用测试集评估模型对手势的识别效果。本文通过对上述5种手势特征量进行组合,依据准确率最高原则选择最优的手势特征序列。如表2所示,经过组合形成6种可选特征序列。

表2 不同特征融合时的准确率

Table 2 Accuracy of feature combination

序号	特征量组合	准确率/%
a	W+D+A+L+B	0.973
b	W+D+A+L	0.945
c	W+D+B+L	0.953
d	B+D+A+L	0.972
e	W+B+A+L	0.977
f	W+D+A+B	0.984

由表2可知,当5个特征量组成手势特征序列时准确率为0.973,高于b、c、d项的准确率,但由于存在冗余特征影响,低于f项的准确率0.984,其混淆矩阵如图13所示,因此本文最终确定准确率最高的f项为手势特征序列。由确定的特征序列对手势数据集进行测试,结果如图14所示。

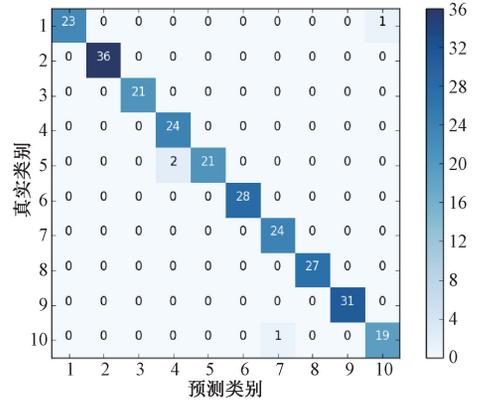


图13 W+D+A+B 混淆矩阵

Fig. 13 Confusion matrix of W+D+A+B

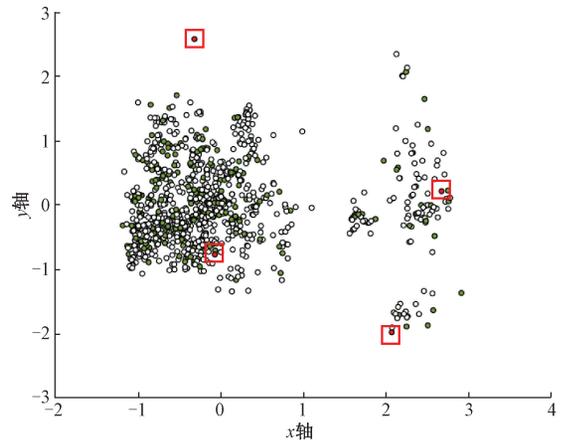


图14 手势训练集和测试集样本可视化

Fig. 14 Visualization of gesture training and test samples

图14中,分别用白色、绿色和红色圆点代表训练手势样本、正确分类和错误分类的测试样本。由图14可知,测试集中有4个手势样本错误分类,具体如表3所示。

表3 错误识别的手势样本

Table 3 The hand gesture samples with untrue label

真实手势样本标签	识别手势样本标签
1	6
2	9
2	9
6	3

通过表 3 可知,在测试集中出现了手势 1 被错误识别为手势 6,手势 2 被误识别为手势 9 和手势 6 被识别为手势 3 的情况,这是由于个别样本的特征向量之间区分度低,导致识别错误。

为有效评估本文识别算法的泛化能力,利用 P 、 R 和 $F1$ 进行度量,如表 4 所示。

表 4 性能度量
Table 4 Evaluation for performance

手势类标签	P	R	$F1$
1	1.00	0.96	0.98
2	1.00	0.91	0.95
3	0.96	1.00	0.98
4	1.00	1.00	1.00
5	1.00	1.00	1.00
6	0.95	0.95	0.95
7	1.00	1.00	1.00
8	1.00	1.00	1.00
9	0.92	1.00	0.96
10	1.00	1.00	1.00
均值	0.98	0.98	0.98

通过表 4 可知,大部分手势的查准率达到 1.00,表明本文所提方法对测试集中的该类手势能够正确分类,然而手势 1 和 6 的召回率低于其他手势,表明分类时由于区分度低忽略了测试集中的部分该类手势。除手势 2、6、9 之外,其它类别的手势 $F1$ 值均较高,表明本文方法对查准率和召回率综合考量,识别算法泛化性好。

为分析手势样本容量对识别效果的影响和比较所提手势识别算法的优越性,在本文数据集上将本文的手势识别模型 multiclass-SVC 同 K 近邻 (K-nearest neighbor, KNN),多层感知机 (multilayer perceptron, MLP),多类别逻辑回归 (multinomial logistic regression, MLR) 和提升方法 (XGboost) 的手势识别方法进行比较,采用迭代增加手势样本的方式进行训练,即每增加 50 个手势样本便计算一次准确率。结果如图 15 所示。

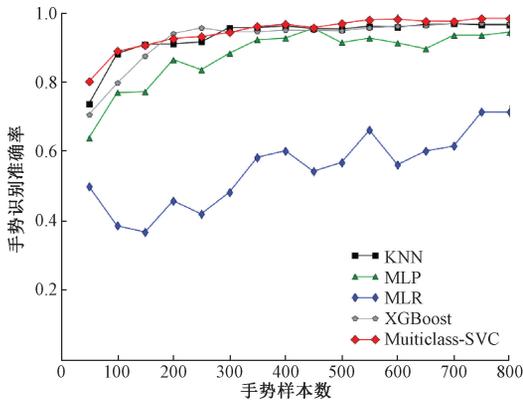


图 15 手势识别方法准确率比较

Fig. 15 Accuracy comparison of different hand gesture recognition methods

通过图 15 可以看出本文所提方法相比 KNN、MLP、MLR 和 XGBoost 的手势识别具有更高的准确率,且在手势样本数据较少的情况下也具有很好的识别效果,随着手势样本的增加,识别准确率也呈递增趋势。

3 结 论

本文基于深度相机提出了一种静态手势识别方法,利用手势骨骼节点数据设计了新的手势特征,建立了更加全面的手势特征序列。与传统的手势特征序列相比,在局部手势特征变化的基础上加入了对手势运动整体性变化的考虑,并通过特征组合策略削弱了冗余特征的影响,解决了数据结构复杂度高和数据计算量大的问题。基于生物启发式遗传算法优化的多分类支持向量分离器,克服了因随机选择模型参数造成手势识别准确度低的缺点,利用 P 、 R 、 $F1$ 和 A 性能度量指标,对识别效果进行了综合评估,且通过与其他模型的对比验证了本文手势识别模型的优越性。运用迭代增加手势样本容量进行训练的方法证明了合理的样本容量可提高手势识别准确度。利用自定义的 10 种双手静态手势进行实验分析,结果表明,该方法能够有效识别多类手势,为人机交互领域的进一步发展提供了理论支撑。

参考文献

[1] 易靖国,程江华,库锡树. 视觉手势识别综述[J]. 计算机科学, 2016, 43(Z6): 103-108.
 YI J G, CHENG J H, KU X SH. Overview of visual gesture recognition [J]. Computer Science, 2016, 43(Z6): 103-108.

[2] FANG B, WEI X, SUN F CH, et al. Skill learning for human-robot interaction using wearable device [J]. Tsinghua Science & Technology, 2019, 24 (6): 654-662.

[3] SHERIDAN T B. Human-robot interaction: Status and challenges [J]. Human Factors, 2016, 58 (4): 525-532.

[4] HASAN H S, KAREEM S. Human computer interaction for vision based hand gesture recognition: A survey [J]. Artificial Intelligence Review, 2015, 43(1): 1-54.

[5] MARIN G, DOMINIO F, ZANUTTIGH P. Hand gesture recognition with jointly calibrated leap motion and depth sensor [J]. Multimedia Tools & Applications, 2016, 75(22): 14991-15015.

[6] XIAO Y F, HUANG H, ZHENG J, et al. Obstacle detection for robot based on kinect and 2d lidar [J]. Journal of University of Electronic Science & Technology of China, 2018, 47(3): 337-342.

[7] WANG C, LIU Z, CHAN S, et al. Superpixel-based

- hand gesture recognition with kinect depth camera [J]. IEEE Transactions on Multimedia, 2015, 17(1): 29-39.
- [8] ZENG W, WANG C, WANG Q, et al. Hand gesture recognition using leap motion via deterministic learning [J]. Multimedia Tools & Applications, 2018, 77(21): 28185-28206.
- [9] PONRAJ G, REN H. Sensor fusion of leap motion controller and flex sensors using Kalman filter for human finger tracking [J]. IEEE Sensors Journal, 2018, 18(5): 2042-2049.
- [10] LIU F, ZENG W, YUAN C, et al. Kinect-based hand gesture recognition using trajectory information, hand motion dynamics and neural networks [J]. Artificial Intelligence Review, 2019, 52(1): 563-583.
- [11] CHANG X, MA Z, LIN M, et al. Feature interaction augmented sparse learning for fast Kinect motion detection [J]. IEEE Transactions on Image Processing, 2017, 26(8): 3911-3920.
- [12] MARIN G, DOMINIO F, ZANUTTIGH P. Hand gesture recognition with jointly calibrated leap motion and depth sensor [J]. Multimedia Tools & Applications, 2016, 75(22): 14991-15015.
- [13] SUN Y, LI C, LI G, et al. Gesture recognition based on Kinect and SMEG signal fusion [J]. Mobile Networks & Applications, 2018, 23(4): 797-805.
- [14] LU W, TONG Z, CHU J. Dynamic hand gesture recognition with leap motion controller [J]. IEEE Signal Processing Letters, 2016, 23(9): 1188-1192.
- [15] VAPNIK V, IZMAILOV R. Knowledge transfer in SVM and neural networks [J]. Annals of Mathematics & Artificial Intelligence, 2017, 81(1-2): 3-19.
- [16] 谢平, 刘欢, 王磊磊, 等. 基于脑肌电反馈的虚拟康复训练系统设计 [J]. 仪器仪表学报, 2018, 39(1): 250-257.
- XIE P, LIU H, WANG L L, et al. Design of virtual rehabilitation training system based on brain electromyography feedback [J]. Chinese Journal of Scientific Instrument 2018, 39(1): 250-257.
- [17] THASEEN I S, KUMAR C A. Intrusion detection model using fusion of chi-square feature selection and multi class SVM [J]. Journal of King Saud University-Computer & Information Sciences, 2017, 29(4): 462-472.
- [18] 滕峰成, 林晓乐, 郝宇, 等. 基于非线性 GA 算法的 MFF 透射模型的参数辨识与优化 [J]. 仪器仪表学报, 2016, 37(2): 286-293.
- TENG F CH, LIN X L, HAO Y, et al. Parameter identification and optimization of MFF transmission model based on nonlinear GA algorithm [J]. Journal of Instrumentation, 2016, 37(2): 286-293.
- [19] KONG X, SUN Y, SU R, et al. Real-time eutrophication status evaluation of coastal waters using support vector machine with grid search algorithm [J]. Marine Pollution Bulletin, 2017, 119(1): 307-319.
- [20] WANG Y, ZHU X, WU B. Automatic detection of individual oil palm trees from UAV images using hog features and a SVM classifier [J]. International Journal of Remote Sensing, 2019, 40(19): 7356-7370.
- [21] 洪丽平, 覃锡忠, 贾振红, 等. 基于后验概率支持向量机在客户流失中的预测 [J]. 计算机工程与设计, 2016, 37(2): 429-432.
- HONG L P, TAN X ZH, JIA ZH H, et al. Prediction of customer churn based on posterior probability support vector machine [J]. Computer Engineering & Design, 2016, 37(2): 429-432.
- [22] BACKENROTH D, GOLDSMITH J, HARRAN M D, et al. Modeling motor learning using heteroscedastic functional principal components analysis [J]. Journal of the American Statistical Association, 2018, 113(523): 1003-1015.

作者简介



程淑红(通信作者), 2001年、2007年和2012年于燕山大学分别获得学士、硕士和博士学位, 现为燕山大学教授, 主要研究方向为计算机视觉、物联网等。

E-mail: shhcheng@ysu.edu.cn

Cheng Shuhong (Corresponding author) received her B. Sc. degree, M. Sc. degree and Ph. D. degree all from Yanshan University in 2001, 2007, and 2012, respectively. She is currently a professor at Yanshan University Her main research interests include computer vision, internet of things, etc.



程彦龙, 2018年于辽宁科技大学获得学士学位, 现为燕山大学检测技术与自动化装置专业在读硕士研究生。主要研究方向为手势识别。

E-mail: 17717153347@163.cn

Cheng Yanlong received his B. Sc. degree from Liaoning University in 2018. He is currently a M. Sc. candidate in the major of detection technology and automation at Yanshan University. His main research interest includes hand gesture recognition.