

# 改进卷积神经网络的动态手势识别<sup>①</sup>



付天豪, 于力革

(江南大学 轻工过程先进控制教育部重点实验室, 无锡 214122)

通讯作者: 付天豪, E-mail: 1198137392@qq.com

**摘要:** 针对现有的单目视觉下动态手势识别率低、识别手势种类少等问题提出一种联合卷积神经网络和支持向量机分类 (CNN-Softmax-SVM) 的动态手势识别算法. 首先采用一种基于 YCbCr 颜色空间和 HSV 颜色空间的快速指尖检测跟踪, 能在复杂背景下实时获取指尖运动轨迹; 其次将指尖运动轨迹作为联合 CNN-Softmax-SVM 网络的输入, 最终通过训练网络来识别动态手势. 测试结果显示, 采用联合 CNN-Softmax-SVM 算法能够很好地识别动态手势.

**关键词:** 动态手势识别; 肤色检测; 卷积神经网络; 支持向量机; 颜色空间

引用格式: 付天豪, 于力革. 改进卷积神经网络的动态手势识别. 计算机系统应用, 2020, 29(9): 225-230. <http://www.c-s-a.org.cn/1003-3254/7546.html>

## Improved Dynamic Gesture Recognition Method Based on Convolutional Neural Network

FU Tian-Hao, YU Li-Ge

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

**Abstract:** A dynamic gesture recognition algorithm based on convolutional neural network and support vector machine classification (CNN-Softmax-SVM) is proposed to solve the problems of low recognition rate and few gesture recognition types in monocular vision. Firstly, the fast fingertip detection and tracking algorithm based on YCbCr and HSV color space is employed, which can acquire fingertip trajectory in real time under complex background. Secondly, fingertip trajectory is used as input of joint CNN-Softmax-SVM network, and finally dynamic gesture trajectory is recognized by trained network. The test results show that the combined CNN-Softmax-SVM algorithm can identify the dynamic gesture trajectory well.

**Key words:** dynamic gesture recognition; skin color detection; Convolutional Neural Network (CNN); Support Vector Machine (SVM); color space

人机交互的方式有很多种, 如鼠标键盘交互、触摸屏交互、语音交互、体感交互等. 手势交互作为一种新型的人机交互方式, 目前已经成为人机交互的重要方式之一. 人手作为身体上最灵活的器官, 将它作为人机交互的方式, 可以使交互更加便利、通用性能更强.

非接触式的动态手势交互已经被应用到体感游戏、辅助驾驶以及手语识别等领域, 为人们带来了简洁方便的用户体验. 但是因为手势具有时间和空间上

的多样性和不确定性, 而且人手本身也是复杂的可变形体, 所以目前这种人机交互方式还处于实验阶段, 理论不是很成熟, 能够识别的范围比较小. 因此, 对动态手势的识别技术研究具有重要意义. 常用的动态手势识别方法有: 基于模板匹配的动态时间规整 (Dynamic Time Warping, DTW) 方法<sup>[1,2]</sup> 和基于模式识别的隐马尔科夫模型方法<sup>[3,4]</sup>. 其中, 采用 DTW 方法在解决大数据量、复杂手势、组合手势识别等问题比较其他方法

① 收稿时间: 2019-12-30; 修改时间: 2020-01-22, 2020-02-25; 采用时间: 2020-03-11; csa 在线出版时间: 2020-09-04

处于劣势<sup>[5]</sup>;采用隐马尔科夫模型识别手势,该方法复杂、需要大量的训练数据<sup>[2]</sup>并且识别总类少.由于深度学习模型具有强大的非线性建模能力,能够表达更高层次、更加抽象的内部特征等特点,近年来深度学习被用于动态手势识别<sup>[6,7]</sup>.文献[6]结合EgoHands手势数据集,改进深度卷积神经网络模型中的参数和网络结构,对深度卷积神经网络模型进行训练,得到高识别率动态手势识别模型,识别准确率能够达到85.9%,识别速度每秒钟可达到16.8帧.文献[7]利用改进的多维卷积神经网络提取手势的时空特征,融合多传感器信息并通过支持向量机实现微动手势识别,针对多类动态手势数据集能达到87%以上的识别准确率,并且对手势的背景和光照都具有较好的鲁棒性.目前动态手势识别仍存在以下问题:复杂背景干扰、指尖特征点识别和定位困难、光照环境的变化<sup>[8]</sup>,这些问题导致了动态手势识别识别率低.

针对以上存在问题,提出的动态手势轨迹特征提取方法能够有效排除复杂背景的干扰、指尖特征点获取和定位困难;提出的联合CNN-Softmax-SVM的手势识别算法能够对动态手势进行有效识别,从而大大提高了动态手势识别率.本文中的动态手势识别系统主要流程如图1所示.

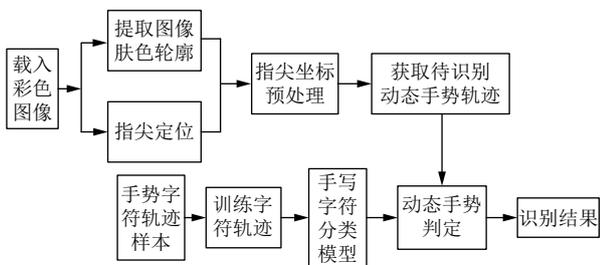


图1 动态手势识别系统流程

首先在 HSV 颜色空间下提取指尖贴纸坐标获取动态指尖重心坐标,通过肤色分割和射线法排除肤色轮廓外复杂背景的干扰,得到待识别的二值化轨迹图片;其次采用 CNN-Softmax 和 CNN-SVM 对手写轨迹样本训练分别得到轨迹样本训练模型,最后利用训练好的轨迹样本分类模型对动态手势识别.

## 1 动态手势特征提取

### 1.1 获取每帧图像指尖轨迹点

为了在复杂背景下很好地对动态手势指尖顺序轨

迹点进行采集,在指尖贴上便携式贴纸,通过检测每帧贴纸轮廓的质心坐标来定位指尖中心点,其中贴纸要被指尖完全覆盖.先把每帧图像从 RGB (Red, Green, Blue) 颜色空间转换到 HSV (Hue, Saturation, Value) 颜色空间:

$$\begin{cases} \theta = \arccos \left( \frac{\frac{1}{2}[(R-G)+(R-B)]}{\sqrt{(R-G)(R-G)+(R-G)(G-B)}} \right) \\ V = \frac{1}{3}(R+G+B); \quad V \in [0, 1] \\ S = 1 - \frac{3}{R+G+B}[\min(R, G, B)]; \quad S \in [0, 1] \\ H = \begin{cases} \theta, & G \geq B \\ 360^\circ - \theta, & G < B \end{cases}; \quad H \in [0, 360^\circ] \end{cases} \quad (1)$$

式中,  $H$  为色调,  $S$  为饱和度,  $V$  为明亮度. 利用式 (1), 将 RGB 颜色空间的图像 (图 2(a)) 转换成 HSV 颜色空间 (图 2(b)). 本文所选指尖贴纸为蓝色, 设置图 2(c) 的 HSV 各个分量的阈值范围为  $H \in [100^\circ, 124^\circ]$ 、 $S \in [0.169, 1]$ 、 $V \in [0.180, 1]$  得到图 2(c) 所示的指尖贴纸二值化图.



图2 指尖贴纸预处理

对图 2(c) 采用轮廓检测获得指尖贴纸轮廓在每一帧图上的坐标,通过轮廓的矩计算轮廓的质心并作为指尖中心点坐标.

### 1.2 剔除异常轨迹点

当复杂背景中存在类贴片颜色干扰时,仍然会被误判为指尖中心点,因此通过判断指尖中心点是否在肤色轮廓内部,来排除类贴片颜色的背景干扰.在 RGB 空间里人的肤色受亮度影响较大,把 RGB 转为 YCbCr 颜色空间提取肤色分量  $C_r$ 、 $C_b$  信息,在一定范围内可以忽略亮度分量  $Y$  的影响.

$$\begin{cases} Y = 0.299R + 0.578G + 0.114B \\ C_b = -0.169R - 0.331G + 0.5B \\ C_r = 0.5R - 0.419G - 0.081B \end{cases} \quad (2)$$

利用式 (2) 提取图 2(a) 的  $C_r$ 、 $C_b$  分量在  $C_r \in [127, 176]$  和  $C_b \in [85, 129]$  范围内的值,如图 3(a) 和图 3(b) 所示.利用大津法 (Otsu) 对图 3(a) 和图 3(b) 进行自适应阈值分割,得到相应的二值化图.然后将  $C_r$  和  $C_b$  分量

的二值图与操作,则得到二值化的肤色图.最后采用轮廓检测获取二值化肤色图的连通域轮廓坐标集合.



图3 肤色分割

通过射线法判断指尖中心点是否在肤色轮廓坐标连通域内.以待判断点的坐标点开始,沿横坐标水平向右作射线,判断射线与肤色轮廓交点的个数,若为奇数则为指尖中心点如图4(a)所示,若为偶数则为异常干扰点如图4(b)所示.

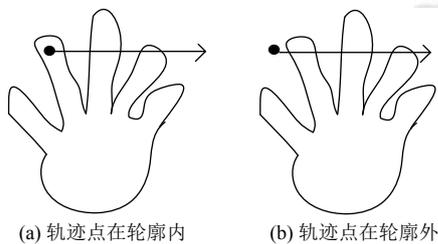


图4 射线法剔除异常指尖轨迹点

### 1.3 获取动态手势

首先获取每一帧图像的肤色轮廓和指尖中心点;其次剔除背景异常点之后将每帧指尖中心点按顺序保存至数组中;最后以第一个指尖中心点坐标为手势起始状态,以最后一个检测的指尖中心坐标为手势结束状态,将每一个指尖中心点按数组顺序相连,即可构成表示该手势的运动轨迹.如图5所示为获取数字字符“2”的动态手势,其中图5(b)的字符轨迹包含150帧的指尖中心顺序相连,待用于手势识别输入.

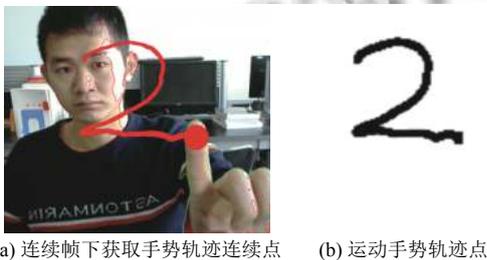


图5 获取动态手势

## 2 联合 CNN-Softmax-SVM 的手势识别

### 2.1 卷积神经网络

卷积神经网络(Convolutional Neural Networks,

CNN)是一种深度前馈人工神经网络,广泛应用于图像分类等计算机视觉问题.CNN模型主要包括卷积层、降采样层、全连接层<sup>[9]</sup>.卷积层由滤波器组成,用于“滑动”输入图像的宽度和高度,并计算输入区域的点积和权值学习参数,提取图像的纹理特征,实现图像特征的增强.第 $m$ 层特征图第 $j$ 个神经元的输入为<sup>[10]</sup>:

$$\begin{cases} x_j^m = f(h_j^m) \\ h_j^m = \sum_{i \in M_j} x_i^{m-1} * k_{ij}^m + b_j^m \end{cases} \quad (3)$$

式中, $h_j^m$ 称为下采样层 $m$ 的第 $j$ 通道的净激活,它由前一层输出特征图 $x_j^{m-1}$ 进行下采样加权、偏置后得到; $M_j$ 为选取的输入特征图子集; $x_i^{m-1}$ 为第 $m-1$ 卷积层的第 $i$ 个神经元的输出; $k_{ij}^m$ 是卷积核矩阵; $b_j^m$ 为第 $m$ 卷积层特征图第 $j$ 个神经元的偏置参数;“\*”是卷积符号; $f(\cdot)$ 为激活函数,通常可使用 Sigmoid, tanh, ReLU 等函数,文中采用 ReLU 函数:

$$f_{\text{ReLU}}(X) = \begin{cases} X, & \text{if } X > 0 \\ 0, & \text{if } X \leq 0 \end{cases} \quad (4)$$

当输入经过卷积层时,若得到的特征图仍然较大,可以通过下采样层来对每一个特征图进行降维操作.下采样层公式为<sup>[10]</sup>:

$$\begin{cases} x_j^m = f(h_j^m) \\ h_j^m = \beta_j^m \text{down}(x_j^{m-1}) + b_j^m \end{cases} \quad (5)$$

式中, $\beta$ 是下采样层的权重系数; $b_j^m$ 是下采样层的偏置项,符号 $\text{down}(\cdot)$ 表示下采样函数,它通过对输入特征图 $x_j^{m-1}$ 通过滑动窗口方法划分为多个不重叠的 $n \times n$ 图像块,然后对每个图像块内的像素求和、求均值或最大值.

提取的特征向量首先通过全连接层,然后再通过 Softmax 层得到分类权重,Softmax 层的函数为:

$$PS_j = \frac{e^{a_j}}{\sum_{k=1}^n e^{a_k}} \quad (6)$$

式中, $a_j$ 表示通过全连接层之后的向量里的第 $j$ 个值,由于 $a_j$ 没有范围大小,通过 Softmax 函数之后得到的 $P_j$ 为类别的概率,范围在 0-1 之间; $n$ 为待输出总类数; $e$ 为欧拉常数.

### 2.2 支持向量机

支持向量机(Support Vector Machine, SVM)<sup>[11]</sup>是

一种机器学习算法, 通过将输入向量映射到一个高维的特征空间, 在这个空间中构造最优分类面, 从而达到两类或者多类的样本划分, 在多数情况下, SVM 比 CNN 全连接层的线性分类泛化能力好<sup>[12]</sup>.

设样本集为  $(u_i, v_i), i = 1, 2, \dots, n, u_i \in R^d, v_i \in \{1, -1\}$ , 其中  $v_i$  是类别标签; 设  $M$  为分类间距: 过各类样本中离分类平面最近且平行于分类面的平面之间距离; 设所求最优超平面方程为:

$$u \cdot w + s = 0 \quad (7)$$

式中,  $w$  为超平面法向量, 决定了超平面的方向,  $s$  为位移量, 决定了超平面与原点的距离. 对式 (7) 进行归一化处理使得满足式 (8):

$$v_i[(w \cdot u_i) + s] - 1 \geq 0 \quad (8)$$

若使  $M$  最大, 即求  $\|w\|^2$  最小. 以式 (9) 为约束条件求  $\|w\|^2$  最小是一个二次规划问题, 可以转为对偶问题求解.

$$\sum_{i=1}^n v_i a_i = 0, a_i \geq 0 \quad (9)$$

以式 (9) 为约束条件, 对  $a_i$  求解式 (10) 的最大值:

$$f(u) = (w \cdot u) + s = \sum_{i=1}^n a_i v_i (u_i \cdot u) + s \quad (10)$$

其中,  $a_i$  为所求问题的 Lagrange 乘子. 则最优超平面分类问题可表示为:

$$Q(a) = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j=1}^n a_i a_j v_i v_j (u_i \cdot u_j) \quad (11)$$

由于基于 RBF 核函数的支持向量机识别精度高, 稳定性强<sup>[13]</sup>. 因此文中采用基于 RBF 核函数  $K(u, v) = \exp\left[\frac{-\|u-v\|^2}{(2\sigma^2)}\right]$  的支持向量机, 即令  $K(u_i, u_j) = u_i \cdot u_j$ , 则式 (10) 的分类函数可表示为:

$$f(u) = (w \cdot u) + s = \sum_{i=1}^n a_i v_i K(u_i, u_j) + s \quad (12)$$

若支持向量机需要识别  $k$  类, 采用 1-v-r 算法使用  $k$  个支持向量机独立训练, 每个分类器表示 1 个类别<sup>[14]</sup>. 若  $k$  个分类的预测结果中存在多个二分类的正样本类, 将精确率作为分类的置信度, 精确率定义如下:

$$PC = \frac{TP}{TP + FP} \quad (13)$$

其中,  $TP$  是测试的样本预测为正样本, 并且测试的样

本实际也为正样本的样本数;  $FP$  是测试的样本预测为正样本, 并且测试的样本实际为负样本的样本数. 最后将置信度最大的正样本类作为最终的预测类别:

$$\arg \max_{i=1,2,\dots,k} [PC_i] \quad (14)$$

其中,  $PC_i$  是第  $i$  类的精确率.

### 2.3 联合 CNN-Softmax-SVM 算法

联合 CNN-Softmax-SVM 算法是同时采用在原 CNN 模型的基础上添加了 SVM 分类过程和权重判定层, 其算法结构如图 6 所示.

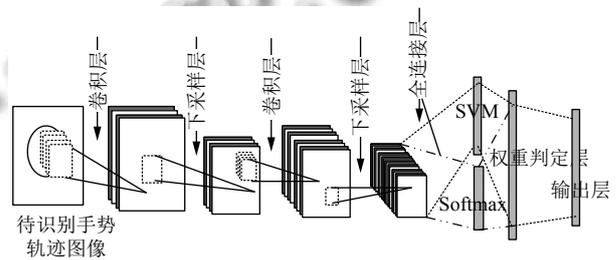


图 6 算法模型结构

将待识别轨迹特征输入卷积层、降采样层、全连接层得到一维形式的特征向量之后, 分别通过 CNN 网络的全连接层的 Softmax 层和用 SVM 分类函数代替 CNN 网络的全连接层的分类函数, 得到两种预分类结果, 将两种预分类结果输入权重判定层, 通过权重判定决定最终输出. 联合 CNN-Softmax-SVM 算法的实现步骤如算法 1.

算法 1. 联合 CNN-Softmax-SVM 算法

输入:

- 1) 待识别手势轨迹图  $\bar{M}$ ;
- 2) 采用 CNN-SVM 训练样本后的每种类别识别正确率的平均值集合  $P_{\text{CNN-SVM}} = \{p_1(\bar{x}_1), p_1(\bar{x}_2), p_1(\bar{x}_3), \dots, p_1(\bar{x}_n)\}$ , 其中  $\bar{x}_i$  是采用 CNN-SVM 训练测试集的第  $i$  类,  $p_1(\bar{x}_i)$  是采用 CNN-SVM 训练样本后的第  $i$  类平均测试正确率;
- 3) 采用 CNN-Softmax 训练样本后的每种类别识别正确率的平均值集合  $P_{\text{CNN-Softmax}} = \{p_2(\bar{y}_1), p_2(\bar{y}_2), p_2(\bar{y}_3), \dots, p_2(\bar{y}_n)\}$ , 其中  $\bar{y}_i$  是采用 CNN-Softmax 训练测试集的第  $i$  类;  $p_2(\bar{y}_i)$  是采用 CNN-Softmax 训练样本后的第  $i$  类平均测试正确率;

输出: 识别类别  $Class\_x$

- 1  $\bar{M}$  经过卷积层、降采样层、全连接层得到一维特征向量  $\bar{m}$ .
- 2 根据式 (6) 获取  $\bar{m}$  的类别  $y_{\text{CNN-Softmax}}$ ; 根据式 (14) 获取  $\bar{m}$  的类别  $x_{\text{CNN-SVM}}$ .
- 3 获取 CNN-SVM 测试样本识别正确率的平均值  $\bar{P}_{\text{CNN-SVM}} = \frac{\sum_{i=1}^n p_1(\bar{x}_i)}{n}$ ;  
获取 CNN-Softmax 测试样本识别正确率的平均值  $\bar{P}_{\text{CNN-Softmax}} = \frac{\sum_{i=1}^n p_2(\bar{y}_i)}{n}$
- 4 if  $y_{\text{CNN-Softmax}} = x_{\text{CNN-SVM}}$  then

```

5  Class_x=yCNN-Softmax
6  else
7  if  $\bar{P}_{CNN-SVM} \geq \bar{P}_{CNN-Softmax}$  then
8  if  $p_1(x_{CNN-SVM}) \geq p_2(y_{CNN-Softmax})$ 
9  Class_x=xCNN-SVM
10 else
11 Class_x=yCNN-Softmax
12 end if
13 else
14 if  $p_1(x_{CNN-SVM}) \leq p_2(y_{CNN-Softmax})$ 
15 Class_x=yCNN-Softmax
16 else
17 Class_x=xCNN-SVM
18 end if
19 end if
20 end if

```

### 3 实验分析

实验环境的硬件: intel(R) Core(TM) i5-9400 CPU @ 2.90 Hz 2.90 GHz; 内存: 8.00 GB; 系统类型: 64 位操作系统, 基于 x64 的处理器; 便携式手贴纸: 贴纸形状为圆形, 贴纸直径为 1 cm, 贴纸颜色采用蓝色 (在 HSV 颜色空间下贴纸颜色范围:  $100 \leq H \leq 124$ ,  $43 \leq S \leq 255$ ,  $46 \leq V \leq 255$ ); 摄像头: 罗技 (Logitech) C270i IPTV 高清网络摄像头 720P.

实验从 NIST 数据集<sup>[15]</sup>中整理出 0-9 数字字符样本图片各 2000 张用于改进卷积神经网络训练和测试, 实验样本数据的训练和预测都是仅在 CPU 下运行. 训练相关参数如表 1.

表 1 参数分配表

参数	CNN-Softmax	CNN-SVM
训练批量图大小	128×128	128×128
学习率	$e^{-3}$	$e^{-3}$
迭代次数	8000	8000
SVM惩罚系数C	—	1

CNN 中所有网络各层的参数设置如表 2 所示, 其中  $F$ 、 $S$ 、 $P$  分别表示卷积池化窗的大小、窗口滑动的步长、图像的边界填充,  $K_f$  表示在当前网络层中卷积池化窗的个数,  $D_f$  表示当前网络层输出特征的维度.

表 2 CNN 各层参数设置

网络层类型	$K_f$	$F$	$S$	$P$	$D_f$
卷积层1	32	5×5	1	0	124×124×32
下采样层1	—	2×2	2	0	62×62×32
卷积层2	64	5×5	1	0	58×58×64
下采样层2	—	2×2	2	0	29×29×64

CNN-Softmax 和 CNN-SVM 在训练过程中的误差下降散点图如图 7 所示, 训练过程的精度折线图如图 8 所示. 其中 CNN-Softmax 的测试平均精确度为 98.23%. 另一方面, CNN-SVM 的测试平均精确度为 98.04%.

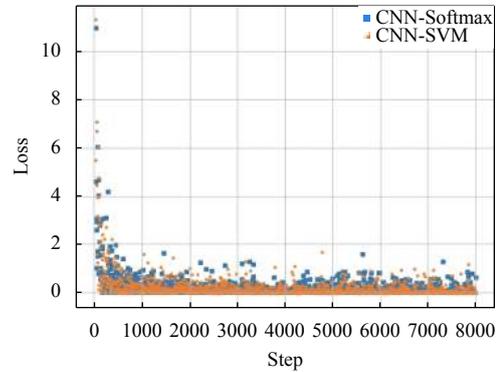


图 7 训练误差下降散点图

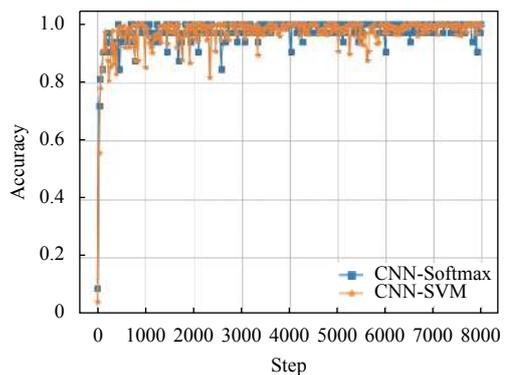


图 8 训练精度折线图

实验邀请 8 名长期使用台式电脑的志愿者进行简单的互动, 每位志愿者每个数字字符累计实验 15 次. 其中手与摄像头距离阈值设置在 0~60 cm 范围内; 手指与摄像头中心之间角度阈值设置在 0~18.3° 范围内. 采用联合 CNN-Softmax-SVM 算法对动态手势进行识别, 识别结果如图 9 手势识别混淆矩阵所示, 识别混淆矩阵中第一横轴为识别出的结果, 第一纵轴为识别的类别.

由图 9 混淆矩阵可知, 本文方法对于动态手势轨迹具有较高的识别准确率. 在识别大部分数字字符上准确率可达到 95% 以上.

由于数字“0”和“6”、“2”和“3”、“4”和“6”、“5”和“6”、“5”和“8”在基于单目视觉下书写轨迹具有一定的相似性, 容易存在一定程度误判的情形. 单独采用 CNN-Softmax 算法在书写并识别“5”和“6”时识别率小

于93%;单独采用CNN-SVM算法在识别数字字符轨迹“2”、“3”、“4”时识别率小于93%;采用本文提出的联合CNN-Softmax-SVM算法对0~9数字字符识别平均准确率能达到95%以上,提高了相似字符识别的准确率。

	0	1	2	3	4	5	6	7	8	9
0	116					1	2			1
1		116	1					3		
2		1	116	2				1		
3			2	117						1
4					115		5			
5	1					112	4		3	
6					4	3	113			
7		1	1					115		3
8						3	1		116	
9				1				4		115

图9 志愿者字符手势识别混淆矩阵

表3给出了本文所提出的联合CNN-Softmax-SVM算法和单独采用CNN-Softmax和CNN-SVM算法的对比结果。由表3可知,尽管本文算法的平均识别时间略长,但还是能满足实时性;另外,采用本文方法在识别率上相比其他几种方法有了较明显的提升。

表3 不同动态手势识别方法的对比

识别方法	平均识别率	平均识别时间/frame (s)
CNN-Softmax	0.944	0.026
CNN-SVM	0.937	0.017
CNN-Softmax-SVM	0.959	0.045

#### 4 结论与展望

基于单目视觉的特征轨迹提取方法,有效地解决了复杂背景的干扰,增强了手势数据的有效性并且能够适应大部分动态手势变换。联合CNN-Softmax-SVM动态手势识别算法能够有效提取动态手势的轨迹特征,在识别率上也有一定的提高。但由于部分数字字符在基于单目视觉下书写轨迹具有相似性,容易存在一定程度误判的情形。在今后研究中应该进一步提高相似字符轨迹的识别率和识别时间。除此之外,本文研究是针对数字字符轨迹分类的手势识别,也可以尝试对字母字符轨迹的手势识别进行实验研究,以便更好地满足人机交互的需求。

#### 参考文献

- Plouffe G, Cretu AM. Static and dynamic hand gesture recognition in depth data using dynamic time warping. *IEEE Transactions on Instrumentation and Measurement*, 2016, 65(2): 305–316. [doi: 10.1109/TIM.2015.2498560]
- 李凯, 王永雄, 孙一品. 一种改进的DTW动态手势识别方法. *小型微型计算机系统*, 2016, 37(7): 1600–1603. [doi: 10.3969/j.issn.1000-1220.2016.07.045]
- 陈国良, 葛凯凯, 李聪浩. 基于多特征HMM融合的复杂动态手势识别. *华中科技大学学报(自然科学版)*, 2018, 46(12): 42–47. [doi: 10.13245/j.hust.181208]
- 马正华, 李雷, 乔玉涛, 等. 基于多传感器融合的动态手势识别研究分析. *计算机工程与应用*, 2017, 53(17): 153–159. [doi: 10.3778/j.issn.1002-8331.1603-0279]
- 陈甜甜, 姚璜, 左明章, 等. 基于深度信息的动态手势识别综述. *计算机科学*, 2018, 45(12): 42–51, 76.
- 王健, 朱恩成, 黄四牛, 等. 基于深度学习的动态手势识别方法. *计算机仿真*, 2018, 35(2): 366–370. [doi: 10.3969/j.issn.1006-9348.2018.02.078]
- 李玲霞, 王羽, 吴金君, 等. 基于改进型多维卷积神经网络的微动手势识别方法. *计算机工程*, 2018, 44(9): 243–249. [doi: 10.19678/j.issn.1000-3428.0048138]
- Jian CF, Xiang XY, Zhang MY. Mobile terminal gesture recognition based on improved FAST corner detection. *IET Image Processing*, 2019, 13(6): 991–997. [doi: 10.1049/iet-ipr.2018.5959]
- LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 1998, 86(11): 2278–2324. [doi: 10.1109/5.726791]
- 常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络. *自动化学报*, 2016, 42(9): 1300–1312. [doi: 10.16383/j.aas.2016.c150800]
- Astorino A, Fuduli A. The proximal trajectory algorithm in SVM cross validation. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 27(5): 966–977. [doi: 10.1109/TNNLS.2015.2430935]
- 彭清, 季桂树, 谢林江, 等. 卷积神经网络在车辆识别中的应用. *计算机科学与探索*, 2018, 12(2): 282–291. [doi: 10.3778/j.issn.1673-9418.1704055]
- 朱树先, 李芸, 祝勇俊, 等. RBF支持向量机用于多类混叠的人脸识别研究. *控制工程*, 2019, 26(4): 773–776. [doi: 10.14107/j.cnki.kzgc.C3.0593]
- 李亦滔. 基于支持向量机的改进分类算法. *计算机系统应用*, 2019, 28(10): 145–151. [doi: 10.15888/j.cnki.csa.007080]
- Grother PJ. NIST special database 19. <https://www.nist.gov/srd/nist-special-database-19>. (2010-08-27)[2019-04-27].