

基于增量自适应学习的在线肌电手势识别

李 愚¹ 柴国钟² 卢纯福¹ 唐智川¹

(浙江工业大学工业设计研究院 杭州 310014)¹ (浙江工业大学机械工程学院 杭州 310014)²

摘 要 表面肌电信号由于个体差异性,在作为外设的控制源时,往往需要针对个体进行长时间的前期训练以获得精准分类辨识模型。针对该问题,在原有的 KKT-SVM 增量学习方法的基础上,提出了一种基于 DBSCAN 密度聚类的 SVM 增量学习算法(D-ISVM),并将该算法应用于在线肌电手势识别。首先,考虑新增样本和原非 SV 样本对新 SV 集的影响,通过 DBSCAN 对样本分布的紧密程度进行分析聚类,筛选出原 SV 集附近的新增样本以及原非 SV 样本;其次,结合核心对象以及各样本到超平面的距离进行二次筛选;最后,将筛选出的样本与原 SV 集一起训练以获得新 SV 集。实验结果表明,与传统算法相比,提出的 D-ISVM 增量学习算法能保持更高的识别准确率,同时进一步提高分类模型的学习速度,并有效解决了在线手势识别中表面肌电个体差异性的问题。

关键词 增量学习, SVM, 肌电, 手势识别

中图分类号 TP181 文献标识码 A DOI 10.11896/j.issn.1002-137X.2019.04.043

On-line sEMG Hand Gesture Recognition Based on Incremental Adaptive Learning

LI Yu¹ CHAI Guo-zhong² LU Chun-fu¹ TANG Zhi-chuan¹

(Industrial Design Institute, Zhejiang University of Technology, Hangzhou 310014, China)¹

(College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310014, China)²

Abstract Due to the individual difference of surface electromyography (sEMG), an individual person always needs long-time pre-training for obtaining his own accurate classification model when using sEMG as control source of external equipment. For solving this problem, on the basis of the original KKT-SVM incremental learning method, a new SVM incremental learning algorithm (D-ISVM) based on DBSCAN density clustering was proposed and it was applied in the on-line sEMG hand gesture recognition. Firstly, considering that the new samples and initial non-SV samples can affect new SV set, the closeness of sample distribution is analyzed and clustered according to DBSCAN, and the new samples and initial non-SV samples which are close to initial SV set are selected. Then, these samples are further selected based on core point and distance between samples and hyperplane. Finally, all selected samples and initial SV set are trained together to obtain new SV set. The experimental results show that, compared with general algorithms, the proposed D-ISVM incremental learning algorithm can achieve higher classification accuracy and further improve the learning speed of classification model. This method can effectively solve the individual difference problem during the on-line sEMG hand gesture recognition.

Keywords Incremental learning, SVM, sEMG, Hand gesture recognition

1 引言

表面肌电信号(sEMG)作为一种交互媒介手段,被广泛应用于假肢、外骨骼、矫形器等外设的控制中^[1-2]。sEMG能够实时反映肌肉活动程度,是人-机之间理想的控制源^[3]。但由于皮脂、用力方式、肌纤维组织等个体差异性因素,很难获

得一个通用的公共分类模型来进行肌电模式识别,因此往往需要针对个体用户进行长时间的前期训练以获得精准分类辨识模型,相对耗时耗力。并且在实际应用时,分类器经过初次训练后一般不会再改变,或较长的一段时间中固定不变^[4]。而 sEMG 的另一特性是具有时变特性,即时间推移、环境变化、电极位置的改变、疲劳等因素都会改变肌电特征^[5]。

到稿日期:2018-02-01 返修日期:2018-03-30 本文受国家自然科学基金项目(61702454),教育部人文社会科学研究项目(17YJC870018)资助。

李 愚(1982-),男,博士生,主要研究方向为机器学习和智能产品设计, E-mail: silent.lee@126.com;柴国钟(1957-),男,教授,博士生导师,主要研究方向为计算机辅助工程及机械强度;卢纯福(1970-),男,教授,博士生导师,主要研究方向为人机交互和智能产品设计;唐智川(1987-),男,博士,助理研究员,CCF 会员,主要研究方向为机器学习、模式识别和人机交互, E-mail: ztang@zjut.edu.cn(通信作者)。

国内外已有很多学者使用基于增量学习 (Incremental Learning) 的自适应方法解决 sEMG 的时变问题。通过增量学习,分类器系统可以在已经学习并获得知识的基础上,不断从新样本中学习新的知识^[6-7]。张毅等^[8]采用增量 SVM 模型,克服了肌肉疲劳过程中 sEMG 的变化问题,以保持分类系统长时间工作的稳定性。Sensinger 等^[9]采用监督和非监督的增量自适应算法对手部、腕部和肘部运动的肌电信号进行分类以适应临床应用的肌电特征变化。Huang 等^[10]采用一种非监督的增量 SVM 算法解决长时间肌电信号性能退化的问题,包括电极移位、肢体位置改变、疲劳等引起的肌电特征变化。这些研究结果表明了基于增量学习的自适应方法对解决 sEMG 时变问题的有效性,但仍少有文献将增量学习的思想用于个体用户分类模型的前期训练,以解决 sEMG 的个体差异性问题。

在众多增量学习算法中,基于支持向量机(SVM)的增量学习由于其特有的优点,近年来逐渐成为研究的热点问题^[11-13]。最早由 Syed 等^[14]提出的 SVM 增量学习算法 Batch-ISVM,是将本次增量后的支持向量集(SV 集)与所有的新增样本在下次增量学习中一起训练学习,舍弃了非 SV 样本。该方法的问题在于新增样本中可能包含无用或糟糕的样本,不仅影响训练速度也会降低识别精度^[15]。基于此,有学者提出了基于 KKT 条件(Karush-Kuhn-Tucker)的 SVM 增量学习算法(KKT-ISVM)^[16],以获得有效的新增样本。虽然 KKT-ISVM 比 Batch-ISVM 更进一步,但仍存在以下问题:1)舍弃的非 SV 样本可能包含有用的分类信息;2)因满足 KKT 条件而舍弃的新增样本也可能包含有用的分类信息。

针对以上问题,文中在原有的 KKT-ISVM 增量学习方法的基础上,创新性地提出一种基于 DBSCAN 密度聚类的 SVM 增量学习算法(D-ISVM)。首先,考虑新增样本和原非 SV 样本对新 SV 集的影响,通过 DBSCAN 对样本分布的紧密程度进行分析聚类,并筛选出原 SV 集附近的原非 SV 样本以及新增样本;其次,结合核心对象以及各样本到超平面的距离进行二次筛选;最后,将筛选出的样本与原 SV 集一起训练以获得新的 SV 集。进一步地,将该方法应用于个体用户在线肌电手势识别,基于基础分类模型进行在线增量自适应学习,并将该方法与 SVM, Batch-ISVM, KKT-ISVM 3 种方法进行比较。

2 SVM 增量学习和 DBSCAN 密度聚类的理论基础

2.1 SVM 增量学习的理论基础

SVM 在分类问题中的核心思想是找到具有最大间隔的划分超平面,以获得训练样本的正确分类。若训练集为 $D = \{(x_1, y_1), \dots, (x_m, y_m)\}$, $y_i \in \{-1, +1\}$, 划分超平面可表示为 $\omega^T x + b = 0$, 其中 ω 为法向量, b 为位移项, 距离超平面最近的几个训练样本被称为支持向量(SV), 两类的 SV 到超平面的距离之和为:

$$\gamma = \frac{2}{\|\omega\|} \quad (1)$$

若欲找到最大间隔,即找到参数 ω 和 b 使得 γ 最大,等价于最小化 $\|\omega\|^2$, 于是:

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 \quad (2)$$

$$\text{s. t. } y_i (\omega^T x_i + b) \geq 1, i = 1, 2, \dots, m$$

式(2)作为一个凸二次规划问题,引入拉格朗日乘子法,可以得到分类模型:

$$f(x) = \omega^T x + b = \sum_{i=1}^m \alpha_i y_i x_i^T x + b \quad (3)$$

其中, α_i 为拉格朗日乘子。由于式(2)中的不等式约束,式(3)须满足 KKT 条件:

$$\begin{cases} \alpha_i \geq 0 \\ y_i f(x_i) - 1 \geq 0 \\ \alpha_i (y_i f(x_i) - 1) = 0 \end{cases} \quad (4)$$

若 $\alpha_i = 0$, 由式(3)可知 α_i 不会对 $f(x)$ 有任何影响;若 $\alpha_i > 0$, 则必有 $y_i f(x_i) = 1$, 相对应的样本位于分类间隔上,该样本属于一个 SV。因此,可以得到 SVM 的一个重要特性,最终模型仅与 SV 集有关,非 SV 集无须保留。

对于 SVM 增量学习算法,新增样本(新的训练样本)可能会改变原 SV 集和原训练集的等价关系,获得新 SV 集和新的超平面^[17]。KKT-ISVM 方法则是将不满足 KKT 条件的新增样本(满足 KKT 条件的新增样本并不会对原 SV 集造成影响)和原 SV 集样本共同训练,以获得新 SV 集。但是,原非 SV 样本和满足 KKT 条件的新增样本都可能包含有用的分类信息,并可能转化为新 SV。如图 1 所示,实线和虚线分别表示原超平面和新超平面,圆形和方形代表两种样本类别,黑色和灰色代表原始样本和新增样本。原 SV 集为 $\{A_1, A_2, A_3, B_1, B_2, B_3\}$, 新增样本后新 SV 集为 $\{A_3, A_4, A_5, A_6, B_3, B_1, B_5, B_6\}$ 。新 SV 集中, A_4 和 B_4 为原非 SV 集样本, A_6 和 B_6 为满足 KKT 条件的新增样本。因此,直接舍弃这些样本,势必会影响分类模型的识别精度。




图 1 原 SV 集和新 SV 集的转化

Fig. 1 Transformation of initial SV set and new SV set

2.2 DBSCAN 密度聚类的理论基础

DBSCAN 密度聚类算法通过样本分布的紧密程度来确定聚类结构^[18-19]。它基于一组邻域参数 $(\epsilon, MINPts)$ 来分析样本之间的可连接性,并通过不断地扩展聚类簇获得聚类结果。 ϵ 表示邻域半径, $MINPts$ 为给定点在邻域内成为核心对象的最小邻域点数。给定数据集 $E = \{z_1, z_2, \dots, z_m\}$, 若距离其中一个样本 z_j 不大于 ϵ 的领域内至少包含 $MinPts$ 个样本,即 $|N_\epsilon(z_j)| \geq MinPts$, 则 z_j 为一个核心对象。

DBSCAN 密度聚类算法首先基于邻域参数找出核心对象集 $\Omega = \{z_a, z_b, z_c, \dots, z_n\}, a, b, c, \dots, n \in m$ 。其次,从核心对象集中随机选取一个“种子”核心对象,由此出发,找出所有密度可达的样本,构成第一个聚类簇。假设选出 z_a 作为种子,则第一个聚类簇为 $C_1 = \{z_a, z_c, \dots, z_p\}, a, c, \dots, p \in m$ 。然后将 C_1 中包含的核心样本从 Ω 中去除:

$$\Omega' = \Omega \setminus C_1 = \{z_b, \dots, z_m\} \quad (5)$$

再从新的集合 Ω' 中随机选取另一个核心样本生成第二个聚类簇,不断重复,直到核心样本集为空。

使用 DBSCAN 基于样本的紧密程度进行聚类的特性,有助于本文寻找原 SV 集附近的原非 SV 样本和新增样本。

3 基于 DBSCAN 密度聚类的 SVM 增量学习算法 (D-ISVM)

3.1 算法思想

基于上述分析, Batch-ISVM 由于对所有新增样本和原 SV 集进行共同训练,因此对于大规模新增样本的训练速度较慢; KKT-ISVM 虽然对新增样本进行了选择,但舍弃的非 SV 样本和因满足 KKT 条件而舍弃的新增样本可能包含有用的分类信息,并可能转化为新 SV。DBSCAN 能通过前一次训练得到的 SV 集,快速筛选出满足 KKT 条件的新增样本以及原非 SV 样本中与 SV 邻近的样本;同时,舍弃离分类超平面距离太远的样本,进一步减少训练集样本个数。筛选后的训练样本集包括原 SV 集样本、原 SV 集附近的原非 SV 样本、原 SV 集附近的满足 KKT 条件的新增样本和不符合 KKT 条件的新增样本。这样既保证了分类器的精度,又提高了训练速度。

3.2 算法描述

结合以上思路,本文创新性地提出一种基于 DBSCAN 密度聚类的 SVM 增量学习算法 (D-ISVM)。首先,考虑新增样本和原非 SV 样本对新 SV 集的影响,通过 DBSCAN 对样本分布的紧密程度进行分析聚类,筛选出原 SV 集附近的新增样本以及原非 SV 样本;其次,结合核心对象以及各样本到超平面的距离进行二次筛选;最后,将筛选出的样本与原 SV 集一起训练以获得新 SV 集。

假设原训练样本集为 D_{old} , 新增训练样本集为 D_{new} , 初步训练集为 D_{new1} , 最终训练集为 D_{new2} , 用原训练样本集训练得到的分类模型为 Ψ_{old} , 用最终训练集训练得到的分类模型为 Ψ_{new} , 原 SV 集为 D_{old-SV} , 原非 SV 集为 $D_{old-NSV}$, 新 SV 集为 D_{new-SV} , 满足 KKT 条件的新增训练样本集为 $D_{new-KKT}$, 不满足 KKT 条件的新增训练样本集为 $D_{new-NKKT}$, 原 SV 集附近的原非 SV 样本集为 $D'_{old-NSV}$, 原 SV 集附近的满足 KKT 条件的新增训练样本集为 $D_{new-KKT}$, 对 $D'_{old-NSV}$ 进行二次筛选得到 $D''_{old-NSV}$, 对 $D'_{new-KKT}$ 进行二次筛选得到 $D''_{new-KKT}$, 通过 DBSCAN 生成的聚类簇为 C_m 。算法的具体流程如图 2 所示, 算法描述如下:

1) 训练初始分类模型。使用 D_{old} 进行 SVM 训练, 得到

Ψ_{old} 和 D_{old-SV} 。SVM 是一种二分类器, 本文采用一对一法 (one-versus-one) 处理多分类问题^[20-21]。

2) 新增样本 KKT 判别。使用 Ψ_{old} 来检测 D_{new} , 将 D_{new} 分为 $D_{new-KKT}$ 和 $D_{new-NKKT}$ 。若无 $D_{new-KKT}$, 则步骤 3) 中的结果不包含 $D_{new-KKT}$ 中的样本。

3) 使用 DBSCAN 获得初步训练集。将 $D_{new-KKT}, D_{old-SV}$ 和 $D_{old-NSV}$ 放在一起, 使用 DBSCAN 进行密度聚类, 获得多个 C_m 。选出的核心对象为 D_{old-SV} 中样本的 C_m , 这些 C_m 中包含 $D'_{old-NSV}$ 和 $D'_{new-KKT}$, 即原 SV 集附近的原非 SV 样本集以及新增样本。 $D_{old-SV}, D'_{old-NSV}, D'_{new-KKT}$ 和 $D_{new-NKKT}$ 构成了初步训练集 D_{new1} 。若所有 C_m 中的核心对象都不包含 D_{old-SV} 中的样本, 则跳过步骤 4), 直接获得由 D_{old-SV} 和 $D_{new-NKKT}$ 构成的最终训练集 D_{new2} 。

4) 二次筛选获得最终训练集。对 $D'_{old-NSV}$ 和 $D'_{new-KKT}$ 进行二次筛选, 以减少训练集样本个数和训练时间。若样本与分类超平面距离太远, 则该样本成为 SV 的几率较小, 二次筛选规则为: 计算 $D'_{old-NSV}$ 和 $D'_{new-KKT}$ 中各个样本到分类超平面的距离, 记离超平面的最大距离为 δ , 选取这两个样本集中距离小于 $1/2\delta$ 的样本, 获得二次筛选后的 $D''_{old-NSV}$ 和 $D''_{new-KKT}$ 。由 $D_{old-SV}, D''_{old-NSV}, D''_{new-KKT}$ 和 $D_{new-NKKT}$ 构成最终训练集 D_{new2} , 用于训练 Ψ_{new} 。

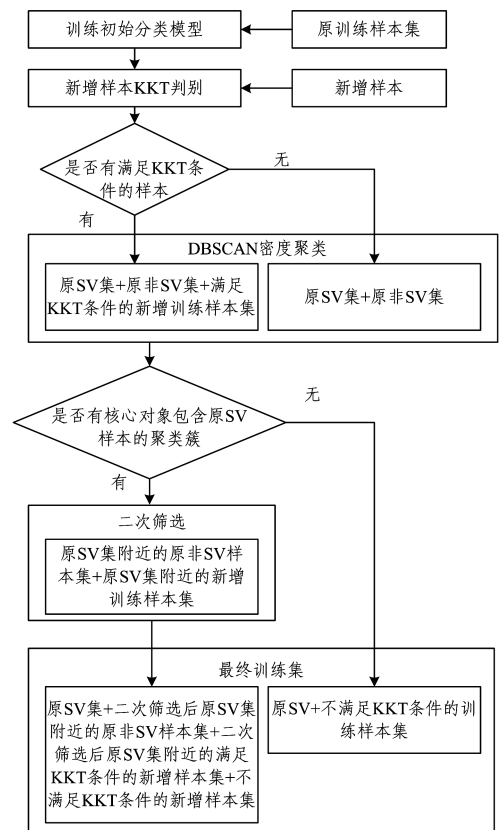


图 2 D-ISVM 算法流程图

Fig. 2 Flow of D-ISVM algorithm

4 实验

4.1 肌电信号采集

共 7 名男性被试 (年龄 25 ± 2.3 岁, 身高 171 ± 6.7 厘米)

参与实验,他们身体健康且无骨骼肌肉疾病。实验前,被试被告知实验过程并签署了知情同意书。需识别的手势包括日常生活中8种常见的手、腕部动作,分别为手张开、手握拳、手抓取、手放松、腕内收、腕外展、腕外旋、腕内旋,如图3所示。




图3 8种手势示意图

Fig. 3 Diagram of eight gestures

美国 BIOPAC 公司的 MP150 型多通道生理信号记录分析系统被用来采集被试右手 4 块目标肌肉(掌长肌、伸指肌、屈指浅肌和尺侧屈腕肌)的 sEMG 信号。贴上电极前须使用酒精去除死皮与皮肤油脂,以降低阻抗。实验中肌电的采样率为 1024 Hz,采用滑动窗的方式开窗,窗口长度设为 200 ms。对每个窗口进行 3 种时域特征提取,分别为均方根值(RMS)、平均绝对值(MAV)和积分肌电(iEMG),公式如下:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N X_i^2} \quad (6)$$

$$MAV = \frac{1}{N} \sum_{i=1}^N |X_i| \quad (7)$$

$$iEMG = \int_{N_2}^{N_1} X(t) dt \quad (8)$$

其中, N 为采样点数, X_i 为窗口中采样点的肌电幅值, N_1 为积分起点, N_2 为积分终点, $X(t)$ 为肌电曲线, $d(t)$ 为采样的时间间隔。一个窗口(样本)可获得一个 12 维(3(特征值)×4(通道))的特征向量 $[\{RMS_k, MAV_k, iEMG_k\}_{Ch}]$, 其中, k 为样本编号, Ch 为通道数。

4.2 实验过程

本文实验分为前期分类实验和在线增量实验两部分。

1) 前期分类实验。对各个被试采集不同手势的肌电数据,单独训练分类模型。对采集的数据进行离线分析,以验证 sEMG 的个体差异性,同时为在线增量实验提供初始数据。每个被试跟随屏幕中的提示,随机保持一种手势 5 s,每种手势出现 30 次,每个被试的数据集为:

$$Dataset = \frac{5s}{t_{window}} \times 8 \text{ 手势} \times 30 \text{ 次} \quad (9)$$

其中, t_{window} 为开窗时长(200 ms),则数据集样本总数为 6000。为防止疲劳,每 40 次手势后安排 5~10 min 休息,然后继续实验。去除伪迹样本,对于每位被试,剩下的 80% 样本作为训练样本,用来进行 SVM 分类模型的训练(包括训练集和检验集),其余 20% 的样本作为测试样本,用于模型测试。

2) 在线增量实验。对于每个被试,将前期分类实验中其余 6 个被试的所有训练样本用来训练该被试的初始分类模型。该初始分类模型针对单个被试没有该被试的样本信息,能较好地评估增量学习算法;同时,也赋予其作为公共模型的概念。

实验中,每个被试跟随屏幕中的提示,随机保持一种手势 5 s,每种手势出现 3 次后进行一次 D-ISVM 在线增量学习(即每 120 s),增量样本为 $600(\frac{5s}{t_{window}} \times 8 \text{ 手势} \times 3 \text{ 次})$ 个。DB-SCAN 密度聚类中的 ϵ 和 $MinPts$ 两个参数由经验试错法(trial and error)^[5] 确定,本实验中 $\epsilon = 0.11$, $MinPts = 4$ 。在算法比较中, Batch-ISVM 和 KKT-ISVM 的实验流程与 D-ISVM 相同; SVM 方法则无增量学习过程,每次新增的样本通过初始分类模型进行分类测试。

4.3 实验结果与分析

4.3.1 前期分类实验结果与分析

在前期分类实验中,为分析 sEMG 的个体差异性,对于每个被试,将使用各自训练数据训练好的分类模型对所有人的测试数据分别进行测试,得到所有被试的含混矩阵,如图 4 所示。其中,主对角线的数值表示该被试使用自己的训练模型和自己的测试数据得到的 8 种手势的识别率;非主对角线的数值表示该被试使用别人的训练模型和自己的测试数据得到的 8 种手势的识别率。由图可知,主对角线的平均识别率(94.43% ± 3.06%) 远高于非主对角线的平均识别率(70.05% ± 6.35%)。因此,对于一个新的被试,使用别人的训练模型或先前的公共模型,由于并不包含自身的样本信息,会大大降低分类识别率,并不适用于实际应用。

		训练数据						
		被试1	被试2	被试3	被试4	被试5	被试6	被试7
被试	被试1	95.26	72.32	65.25	73.02	59.93	68.51	65.34
	被试2	75.34	98.33	63.56	63.44	68.34	69.32	81.44
	被试3	63.23	72.17	97.18	72.70	63.69	75.71	76.45
	被试4	62.43	64.30	81.36	92.83	77.78	68.91	67.93
	被试5	72.58	67.92	67.34	61.82	89.04	59.03	70.46
	被试6	81.33	69.88	65.32	79.66	67.39	94.91	72.16
	被试7	67.56	57.39	62.72	60.04	75.50	73.38	93.45

图4 识别率含混矩阵/%

Fig. 4 Accuracy confusion matrix/%

4.3.2 在线增量实验结果与分析

基于前期分类实验的数据,对于每个被试,将前期分类实验中其余 6 个被试的所有训练样本用于训练该被试的初始分类模型。所有被试使用 Batch-ISVM, KKT-ISVM 和 D-ISVM 3 种算法的前 10 次增量学习的平均分类识别率如图 5 所示。其中, SVM 算法由于无增量学习过程,每次增量学习时间点的平均分类识别率通过两次增量学习之间(2 min)的新增样本分类获得。对图 5 的结果进行统计后,每次的平均识别率数据如表 1 所列。图 5 和表 1 的结果表明, 3 种增量学习算法的平均识别率远高于 SVM 算法,在此实验中, SVM 算法相当于前期分类实验含混矩阵中的非主对角线识别方式(具有个体差异的问题)。3 种增量学习算法中, D-ISVM 算法具有最高的平均识别率,在第 5 次增量学习后即达到最高识别

率(94.43%),之后保持稳定;Batch-ISVM 算法具有最低的平均识别率,在第7次增量学习后达到最高识别率(88.28%),但之后的性能稳定性不佳;KKT-ISVM 算法介于两者之间,在第6次增量学习后达到最高识别率(92.26%)。这是由于D-ISVM 算法相对于KKT-ISVM 算法,考虑了舍弃的非SV 样本和因满足KKT 条件而舍弃的新增样本可能带有有用分类信息的情况,从而得到了更高的分类识别率;而Batch-ISVM 算法则由于可能包含新增样本中无用或糟糕的样本,导致识别率下降。




图5 不同算法分类表现的对比

Fig. 5 Comparison of classification performance of different algorithms

表1 不同算法的分类识别率

Table 1 Classification accuracies of different algorithms (单位: %)

学习次数	SVM	Batch-ISVM	KKT-ISVM	D-ISVM
1	68.30	70.45	67.35	69.32
2	70.34	75.34	72.39	75.29
3	71.35	78.23	80.21	83.36
4	67.29	82.04	86.34	87.34
5	72.44	85.42	87.23	94.43
6	74.29	84.61	92.26	92.34
7	70.92	88.28	91.33	92.23
8	66.25	80.52	88.34	93.9
9	72.59	82.48	84.04	89.45
10	69.34	87.43	90.82	94.22

为了对本文算法进行训练时间评估,计算了3种增量学习算法前10次增量学习的单次训练学习时间、平均训练学习时间以及最高分类识别率达到时间(前10次增量学习中的最高分类识别率),如表2所列。

表2 不同算法训练学习时间和最高分类识别率达到时间

Table 2 Training time and highest classification accuracy reaching time of different algorithms

	次数	Batch-ISVM	KKT-ISVM	D-ISVM
训练学习时间/s	1	26.64	23.74	23.46
	2	25.98	24.25	24.65
	3	26.34	21.97	25.82
	4	27.89	22.65	23.14
	5	26.98	23.81	23.24
	6	26.82	23.64	22.64
	7	25.42	22.87	21.55
	8	25.91	21.13	23.93
	9	27.74	23.82	24.03
	10	26.88	21.89	22.04
	平均	26.66	22.98	23.45
最高分类识别率达到时间/min		14	12	10

其中,训练时间是指筛选新增样本、原非SV 样本的时间

和进行学习训练的时间之和。因为Batch-ISVM 未对新增样本、原非SV 样本进行筛选,所以没有筛选时间,只有训练时间;KKT-ISVM 只包括新增样本的筛选时间和训练时间。结果表明,D-ISVM 算法和KKT-ISVM 算法的平均训练时间接近(23.45s 和22.98s),D-ISVM 算法耗时略大,但少于Batch-ISVM 算法的平均用时(26.66s),D-ISVM 算法最快达到最高分类识别率,耗时10min(第5次增量学习后)。这是由于D-ISVM 算法和KKT-ISVM 算法在保留原有样本的同时,舍弃了一部分无用的新增样本,加快了训练时间;D-ISVM 算法因为多保留了一部分原非SV 样本和满足KKT 条件的新增样本,耗时略大于KKT-ISVM 算法,但通过t-test 统计分析,两种算法的耗时并无显著性差异($p > 0.05$)。

结束语 本文针对面肌电信号的个体差异性问题,在原有的KKT-SVM 增量学习方法的基础上,提出了一种基于DBSCAN 密度聚类的SVM 增量学习算法(D-ISVM),并将其应用于在线肌电手势识别。首先,通过DBSCAN 对样本分布的紧密程度进行分析聚类,筛选出原SV 集附近的新增样本以及原非SV 样本;其次,结合核心对象以及各样本到超平面的距离进行二次筛选;最后,将筛选出的样本与原SV 集一起训练以获得新SV 集。实验结果表明,与传统算法相比,提出的D-ISVM 增量学习算法能保持更高的识别准确率,同时进一步提高了分类模型的训练学习速度,并有效解决了在线手势识别中表面肌电个体差异性的问题。

参考文献

- [1] AL-TIMEMY A H, KHUSHABA R N, BUGMANN G, et al. Improving the performance against force variation of EMG controlled multifunctional upper-limb prostheses for transradial amputees[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2016, 24(6): 650-661.
- [2] YOUNG A J, KUIKEN T A, HARGROVE L J. Analysis of using EMG and mechanical sensors to enhance intent recognition in powered lower limb prostheses[J]. Journal of Neural Engineering, 2014, 11(5): 1-12.
- [3] FARINA D, VUJAKLIJA I, SARTORI M, et al. Man/machine interface based on the discharge timings of spinal motor neurons after targeted muscle reinnervation[J]. Nature Biomedical Engineering, 2017, 1(2): 1-12.
- [4] ZHAO Y N, ZHANG H S, XU L S, et al. A study of different linear discriminant analysis methods in myoelectric prosthesis control[J]. Journal of Integration Technology, 2013, 2(4): 20-26. (in Chinese)
赵曜楠, 张浩诗, 徐礼胜, 等. 几种自适应线性判别分析方法在肌电假肢控制中的应用研究[J]. 集成技术, 2013, 2(4): 20-26.
- [5] GU Y, YANG D, HUANG Q, et al. Robust EMG pattern recognition in the presence of confounding factors: features, classifiers and adaptive learning[J]. Expert Systems with Applications, 2018, 96: 208-217.
- [6] HENDERSON J, TITOV I. Incremental Sigmoid Belief Net-

- works for Grammar Learning[J]. *Journal of Machine Learning Research*, 2010, 11(11): 3541-3570.
- [7] LASKOV P, GEHL C, KRUEGER S, et al. Incremental support vector learning: analysis, implementation and applications[J]. *Journal of Machine Learning Research*, 2006, 7(3): 1909-1936.
- [8] ZHANG Y, ZHU X, LUO Y. An SVM algorithm for overcoming the influence of muscle fatigue in sEMG based human-machine interaction[J]. *Control Engineering of China*, 2014, 21(4): 467-471. (in Chinese)
张毅, 祝翔, 罗元. 一种克服 sEMG 人机交互中肌肉疲劳的 SVM 算法[J]. *控制工程*, 2014, 21(4): 467-471.
- [9] SENSINGER J W, LOCK B A, KUIKEN T A. Adaptive pattern recognition of myoelectric signals: exploration of conceptual framework and practical algorithms[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2009, 17(3): 270-278.
- [10] HUANG Q, YANG D, JIANG L, et al. A Novel Unsupervised Adaptive Learning Method for Long-Term Electromyography (EMG) Pattern Recognition[J]. *Sensors*, 2017, 17(6): 1-28.
- [11] DIEHL C P, CAUWENBERGHS G. SVM incremental learning, adaptation and optimization[C]// *Proceedings of the International Joint Conference on Neural Networks*. IEEE, 2003. IEEE, 2003: 2685-2690.
- [12] RISTIN M, GUILLAUMIN M, GALL J, et al. Incremental Learning of Random Forests for Large-Scale Image Classification[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(3): 490-503.
- [13] MITRA P, MURTHY C A, PAL S K. A probabilistic active support vector learning algorithm[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2004, 26(3): 413-418.
- [14] SYED N A, LIU H, SUNG K K. Handling concept drifts in incremental learning with support vector machines[C]// *Proceedings of the Fifth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM, 1999: 317-321.
- [15] YAO M H, LIN X M, WANG X B. Fast incremental learning algorithm of svm with locality sensitive hashing[J]. *Computer Science*, 2017, 44(S2): 88-91. (in Chinese)
姚明海, 林宣民, 王宪保. 一种基于局部敏感哈希的 SVM 快速增量学习算法[J]. *计算机科学*, 2017, 44(S2): 88-91.
- [16] SHILTON A, PALANISWAMI M, RALPH D, et al. Incremental training of support vector machines[J]. *IEEE transactions on Neural Networks*, 2005, 16(1): 114-131.
- [17] LI Y F, SU B, LIU G S. An incremental learning algorithm for SVM based on combined reserved set[J]. *Journal of Shanghai Jiao Tong University*, 2016, 50(7): 1054-1059. (in Chinese)
李妍坊, 苏波, 刘功申. 一种基于组合保留集的 SVM 增量学习算法[J]. *上海交通大学学报*, 2016, 50(7): 1054-1059.
- [18] BIRANT D, KUT A. ST-DBSCAN: An algorithm for clustering spatial-temporal data [J]. *Data & Knowledge Engineering*, 2007, 60(1): 208-221.
- [19] CHEN Y, TANG S, PEI S, et al. DHeat: A Density Heat-Based Algorithm for Clustering With Effective Radius [J]. *IEEE Transactions on Systems Man Cybernetics-Systems*, 2018, 48(4): 649-660.
- [20] HSU C W, LIN C J. A comparison of methods for multiclass support vector machines[J]. *IEEE Transactions on Neural Networks*, 2002, 13(2): 415-425.
- [21] ZHANG Z L, LUO X G, GONZALEZ S, et al. DRCW-ASEG: One-versus-One distance-based relative competence weighting with adaptive synthetic example generation for multi-class imbalanced datasets[J]. *Neurocomputing*, 2018, 285: 176-187.