

半监督极限学习机用于 Android 手机活动识别的研究^①

王金甲^② 田佩佩

(燕山大学信息科学与工程学院 秦皇岛 066004)

摘要 基于对现有 Android 手机活动识别技术的分析,针对从不完全、不充分的移动传感器数据中推断人体活动的难题,将能根据无标签样本提高识别预测准确性和速度的半监督(SS)学习和体现模式分类回归的有效学习机制的极限学习机(ELM)相结合给出了解决 Android 手机平台的人体活动识别问题的半监督极限学习机(SS-ELM)方法,并进一步提出了主成分分析(PCA)和半监督极限学习机(SS-ELM)结合的 PCA + SS-ELM 新方法。实验结果表明,该方法对人体活动的识别正确率能达到 95%,优于最近提出的混合专家半监督模型的正确率,从而验证了该新方法是可行性。

关键词 活动识别, 半监督极限学习机(SS-ELM), 传感器, 加速度计, Android 手机

0 引言

活动识别是指对人体活动的识别,是指计算机自动检测、分析和理解人体各类活动和行为的过程,在人机交互、康复工程、教育、远程会议、体育运动等方面具有广泛的应用前景^[1]。人体活动包括一系列具有丰富含义的肢体运动,它表达了人的行为意图或者完成人与环境的信息传递方式。智能手机配置的加速度计能自动采集人们日常活动的加速度信号,一些高端手机还配有其他传感器如 GPS 接收器、光传感器、温度传感器等,这说明在移动环境下智能手机变成了强大的传感设备^[2]。操作系统是免费、开源的 Android 手机很有可能成为活动识别的又一个平台。

目前国内外学者对 Android 手机活动识别的研究主要集中在三个方面:(1)无监督学习,如 Ming 等提出了基于卷积神经网络算法的活动识别判别特征的自动提取^[3];Guo 等在熵和多类 Adaboost 算法构建行为识别模型的基础上,提出了一种新的特征

学习方法^[4];Capela 等基于智能手机挑选出了健康人、老年人和中风患者三个人群各自的特征子集,且特征子集的性能优于整个特征集^[5];Liao 等用经验模式分解(EMD)方法实现了特征提取^[6]。(2)监督学习,如 Kim 等设计了基于智能手机的二阶活动识别系统,该系统先使用决策树(DT)学习,然后基于第一阶段的序列分类结果执行隐马尔可夫模型(HMM)学习^[7];Acharjee 等用朴素贝叶斯分类器最小化特征向量的维度,并结合条件阈值框,提出了最小特征向量行为识别系统^[8];Reyesortiz 等将支持向量机连续活动预测的概率输出与一个启发式过滤方法相结合,提出了基于智能手机的过渡感知人体活动识别系统(TAHAR)^[9];Al 等学者用在线极限学习机(OSELM)方法训练单隐层前馈神经网络(SLFN),活动识别的整体精度达到了 82%^[10]。(3)半监督学习,如 Lee 等采用全局与局部协同训练(global-local co-training, GLCT)算法提升了混合专家(mixture-of-experts, ME)模型的性能,同时利用标签数据和无标签数据完成了基于安卓智能手机的活动识别^[11],对半监督学习的发展起到了一定的促

^① 国家自然科学基金(61273019, 61473339),河北自然科学基金(F2013203368),河北省青年拔尖人才支持计划([2013]17),河北省博士后专项(B2014010005)和中国博士后科学基金(2014M561202)资助项目。

^② 男,1978 年生,博士生,教授;研究方向:传感器,信号处理,模式识别;联系人,E-mail: wjj@ysu.edu.cn
(收稿日期:2016-10-08)

进作用。无监督学习的优点是可以充分利用搜集的数据,缺点是不能充分利用标签数据。监督方法的优点是能充分利用标签数据,但是不能利用大量无标签数据。半监督学习既能利用标签数据,又能利用无标签数据,是近年来的研究重点。极限学习机(extreme learning machines, ELM)是一种新的机器学习算法,不仅能用于无监督学习、监督学习,也能用于半监督学习。

与传统神经网络模型不同,极限学习机(ELM)只要求激活函数无穷阶可微,在输入权值和隐藏层偏置值随机设置的情况下,神经网络的所有参数就不必迭代调整,并且只通过一步计算即可解析求出网络的输出权值。该算法结构简单、计算速率快^[12]。支持向量机(SVM)作为一种通用的机器学习方法,在回归估计、概率密度函数估计、模式识别等领域均有其应用成果^[13]。与SVM相比,极限学习机(ELM)拥有更完善的理论体系,在训练前只需要设置网络隐层节点个数,参数选择容易、学习速度快且泛化性能好,可以直接应用于回归和多级分类应用程序。研究表明,ELM的预测精度甚至能高于SVM^[14-17]。2014年北京科技大学肖文栋教授将基于ELM的核判别分析算法应用到人体活动识别领域,结果表明基于ELM的核判别分析算法在精度和学习速率上都优于SVM和反向传播(BP)网络^[18]。尽管ELM方法已被应用到各个领域,但它主要用于监督学习分类和回归等任务。在Android手机活动识别问题中,标签数据和无标签数据同时存在,标签样本数据太少,无法用于监督学习,而仅仅使用无标签样本数据进行无监督学习又会使标签样本数据处于无用武之地的境界。因此,本文将ELM扩展到半监督学习并用于Android手机活动识别任务,并提出了主成分分析(principal component analysis, PCA)和半监督(semi-supervised, SS)ELM(SS-ELM)结合的新方法,即PCA+SS-ELM方法。在Android智能手机收集了真实传感器数据集,采用半监督极限学习机的新方法识别出人体活动。

1 半监督极限学习机(SS-ELM)

当极限学习机(ELM)应用于分类问题时,标签

样本训练得出的分类模型的分类正确率会随着标签样本数量的减少而降低。当获取标签数据较为困难,同时存在大量无标签数据时,利用极限学习机与半监督(SS)学习的优点,可用半监督极限学习机方法进行Android手机活动识别。

半监督极限学习机(SS-ELM)在机器学习领域是比较新兴的方法,适用于有标签样本数据相对较少、而无标签样本数据相对较多的情况。在半监督学习方法上,我们有大量的无标签数据和少量标签数据。我们把训练集中带标签数据表示为 $\{X_l, Y_l\} = \{X_i, Y_i\}_{i=1}^L$,无标签数据设为 $X_u = \{X_i\}_{i=1}^U$,其中 L 和 U 分别是标签样本和无标签样本的数量。

一般来说,ELM训练分两个阶段。第一阶段是使用固定数量的随机生成的映射神经元构造隐层,它可以是任何非线性分段连续函数,如Sigmoid函数:

$$g(x; \theta) = \frac{1}{1 + \exp(-(\alpha^T x + b))} \quad (1)$$

和高斯函数:

$$g(x; \theta) = \exp(-b \|x - a\|) \quad (2)$$

其中 $\theta = \{a, b\}$ 是映射函数的参数, $\|\cdot\|$ 表示欧几里得范数。

ELM的一个显著特点是,隐藏映射函数的参数可以根据任意连续概率分布(例如均匀分布(-1, 1))随机产生。这使得ELM不同于传统前馈神经网络和支持向量机。在训练过程需要优化的唯一自由参数是隐藏神经元和输出节点之间的输出权重。这样一来,训练ELM等价于求解一个正则最小二乘问题,这比支持向量机和反向传播学习更高效。

在第一阶段,隐藏神经元的数目是随机生成的,隐藏神经元能将数据从输入空间映射到一个 n_h 维特征空间(n_h 表示隐层神经元的数目)。我们用 $h(x_i) \in \mathbb{R}^{1 \times n_h}$ 表示隐藏层的输出向量, $\beta \in \mathbb{R}^{n_h \times n_o}$ 表示连接隐层与输出层的输出权重。网络输出由下式决定:

$$f(x_i) = h(x_i)\beta \quad (3)$$

在第二阶段,ELM目的是通过预测误差损失的最小平方值解决输出权值问题,优化公式如下:

$$\min_{\beta \in \mathbb{R}^{n_h \times n_o}} \frac{1}{2} \|\beta\|^2 + \frac{c}{2} \sum_{i=1}^N \|e_i\|^2$$

$$\text{s.t. } h(x_i)\beta = y_i^T - e_i^T, \quad i = 1, \dots, N \quad (4)$$

其中目标函数中的第一项是一个反过度拟合正则化项, $e_i \in \mathbb{R}^{n_o}$ 是相对于第 i 个训练模式的误差矢量, c 是训练误差惩罚系数。

通过修改 ELM 优化式(4), 将 SS-ELM 定义为

$$\min_{\beta \in \mathbb{R}^{n_h \times n_o}} \frac{1}{2} \|\beta\|^2 + \frac{1}{2} \sum_{i=1}^l c_i \|e_i\|^2 + \frac{\lambda}{2} \text{Tr}(F^T L F)$$

$$\begin{aligned} \text{s.t. } h(x_i)\beta &= y_i^T - e_i^T, \quad i = 1, \dots, l \\ f_i &= h(x_i)\beta, \quad i = 1, \dots, u+l \end{aligned} \quad (5)$$

其中 $L \in \mathbb{R}^{(l+u) \times (l+u)}$ 是根据标签数据和无标签数据建立的图拉普拉斯算子, $F \in \mathbb{R}^{(l+u) \times n_o}$ 是网络输出矩阵, 它的第 i 行是 $f(x_i)$, λ 是权衡参数。

值得注意的是, 与加权 ELM(W-ELM)相似^[19], 这里考虑了来自不同类的特征预测误差的惩罚系数 c_i , 这是因为当数据倾斜时, 即有些类的训练样本比其他类多时, 传统的 ELM 适用于拥有大量样本的类, 而不太适合其他样本少的类, 这通常会导致方法在测试集上的泛化性能较差。因此, 本文建议调整不同类别的权重来缓解这一问题。假设 x_i 属于类 t_i , t_i 具有 N_{t_i} 个训练模式, 然后将 e_i 与 $c_i = c_o/N_{t_i}$ 相结合, 其中 c_o 是 ELM 中用户定义的一个参数。这样一来, 占统治地位的模式样本将不会超过拟合程度, 而且不会忽略样本数较少的类。

本文用目标函数替代约束, 以矩阵形式改写上面的式(5), 可得

$$\begin{aligned} \min_{\beta \in \mathbb{R}^{n_h \times n_o}} \frac{1}{2} \|\beta\|^2 + \frac{1}{2} \sum_{i=1}^l \|C^{\frac{1}{2}}(\tilde{Y} - H\beta)\|^2 \\ + \frac{\lambda}{2} \text{Tr}(\beta^T H^T L H \beta) \end{aligned} \quad (6)$$

其中 $\tilde{Y} \in \mathbb{R}^{(l+u) \times n_o}$ 表示强化的训练目标, 它的前 l 行相当于 Y_l , 其他为零。 C 是 $(l+u) \times (l+u)$ 维的矩阵, 它的前 l 个对角线元素为 $[C]_{ii} = C_i$, 其他元素均为零。

计算目标函数对 β 的导数:

$$\nabla L_{SS-ELM} = \beta + H^T C (\tilde{Y} - H\beta) + \lambda \cdot H^T L H \beta \quad (7)$$

将导数值设为零, 可得 SS-ELM 的解:

$$\beta^* = (I_{n_h} + H^T C H + \lambda H^T L)^{-1} H^T C \tilde{Y} \quad (8)$$

在 Android 手机活动识别任务中, 半监督学习

可能碰到这种情况: 标签数据的数量少于隐藏神经元的数量。这种情况下, 有下面的替代解决方案:

$$\beta^* = H^T (I_{l+u} + C H H^T + \lambda L H H^T)^{-1} C \tilde{Y} \quad (9)$$

其中, I_{l+u} 是 $l+u$ 维的单位阵。

综上所述, SS-ELM 算法步骤如下:

SS-ELM 算法

输入: 有标签模式, $\{X_l, Y_l\} = \{x_l, y_l\}_{l=1}^l$; 无标签模式: $x_u = \{x_i\}_{i=1}^u$;

输出: SS-ELM 的映射函数: $f: \mathbb{R}^{n_i} \rightarrow \mathbb{R}^{n_o}$;

第一步: 构造 X_l, X_u 的图拉普拉斯算子 L ;

第二步: 根据随机输入的权重和偏差, 启动 n_h 个隐藏神经元的 ELMs 网络, 并计算隐层神经元的输出矩阵 $H \in \mathbb{R}^{(l+u) \times n_h}$;

第三步: 选择跟踪参数 C_0 和 λ ;

第四步: 如果 $n_h \leq N$, 按照式(8)计算输出权重 β ; 否则, 按照式(9)计算输出权重 β ;

返回值: 映射函数 $f(x) = h(x)\beta$ 。

需要说明的是, 通过将置零、 C_i ($i = 1, \dots, l$) 的对角线元素设为相同的常数, 式(8)和(9)可以分别化简到传统 ELM 方法。

SS-ELM 方法流程图如图 1 所示。

2 PCA + SS-ELM

主成分分析(PCA)方法是一种被广泛用来进行特征提取的代数方法, 其目的是将高维数据投影到较低维的空间中, 即对高维数据进行降维, 在不丢失主要信息的前提下选择较少的数据来代替原来的高维数据。

PCA 主要步骤如下:

步骤 1: 设有 n 个数据样本, 每个数据样本有 p 个特征, 得到原始数据矩阵

$$\mathbf{X} = \begin{bmatrix} X_{11} & \cdots & X_{1p} \\ \vdots & \ddots & \vdots \\ X_{n1} & \cdots & X_{np} \end{bmatrix} \quad (10)$$

步骤 2: 对式(10)的矩阵进行标准化处理, \bar{X}_j 为各个特征参数的样本均值, S_j 为各个特征参数的样本标准差, 样本参数的相关系数矩阵为:

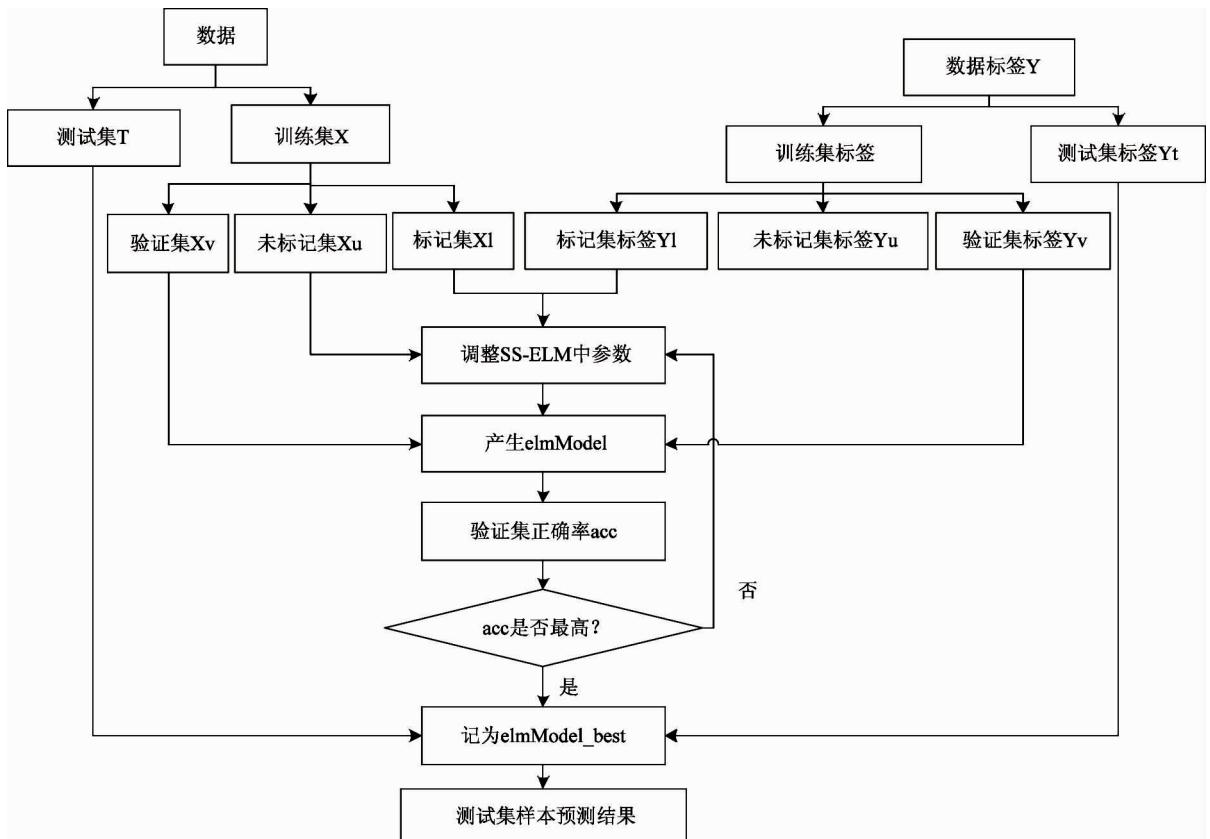


图1 半监督极限学习机方法的流程图

$$Y_{ij} = \frac{X_{ij} - \bar{X}_j}{S_j} \quad (11)$$

根据式(11)得到特征参数的标准化数据矩阵

$$\mathbf{Y} = (Y_{ij})_{n \times p} = \begin{bmatrix} Y_{11} & \cdots & Y_{1p} \\ \vdots & \ddots & \vdots \\ Y_{n1} & \cdots & Y_{np} \end{bmatrix} \quad (12)$$

步骤3:根据式(12)得到特征参数标准化矩阵

\mathbf{Y} 的特征值 $\lambda_1, \lambda_2, \dots, \lambda_p$, 并且使得 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$, 以及单位化特征向量 $e_1, \lambda e_2, \dots, e_p$ 。

步骤4:计算特征参数得到第 i 个主成分的贡献

率为 $\frac{\lambda_i}{\sum_{i=1}^p \lambda_i}$, 前 m 个主成分累计贡献率为

$$\frac{\sum_{i=1}^m \lambda_i}{\sum_{i=1}^p \lambda_i}.$$

步骤5:设定阈值,确定 m 值,使得前 m 个主成分累计贡献率超过阈值。

为了尽可能降低样本数据间的冗余度以提高活动识别效果,我们提出了PCA与SS-ELM结合的方

法,记为PCA+SS-ELM方法,其流程图如图2所示。该方法首先对训练集数据进行主成分分析,确定PCA步骤5中的 m 值,然后将测试集按照主成分映射公式进行子空间投影,最后采用半监督极限学习机方法进行学习。

3 实验及结果

SS-ELM算法与Lee和Cho提出的全局与局部协同训练(GLCT)算法同属于半监督学习方法,所以本文将提出的方案用于延世大学Cho教授提供的两个Android手机数据集上。两个数据集的具体情况如表1所示,这两个数据集都是用户进行日常活动时通过谷歌Android智能手机获取的,数据包括加速度、方向、磁场等信息。其中,数据集dataset1包含跑步、走路、停留三类活动,dataset2则包含跑步、走路、停留、骑自行车、坐地铁五类活动。

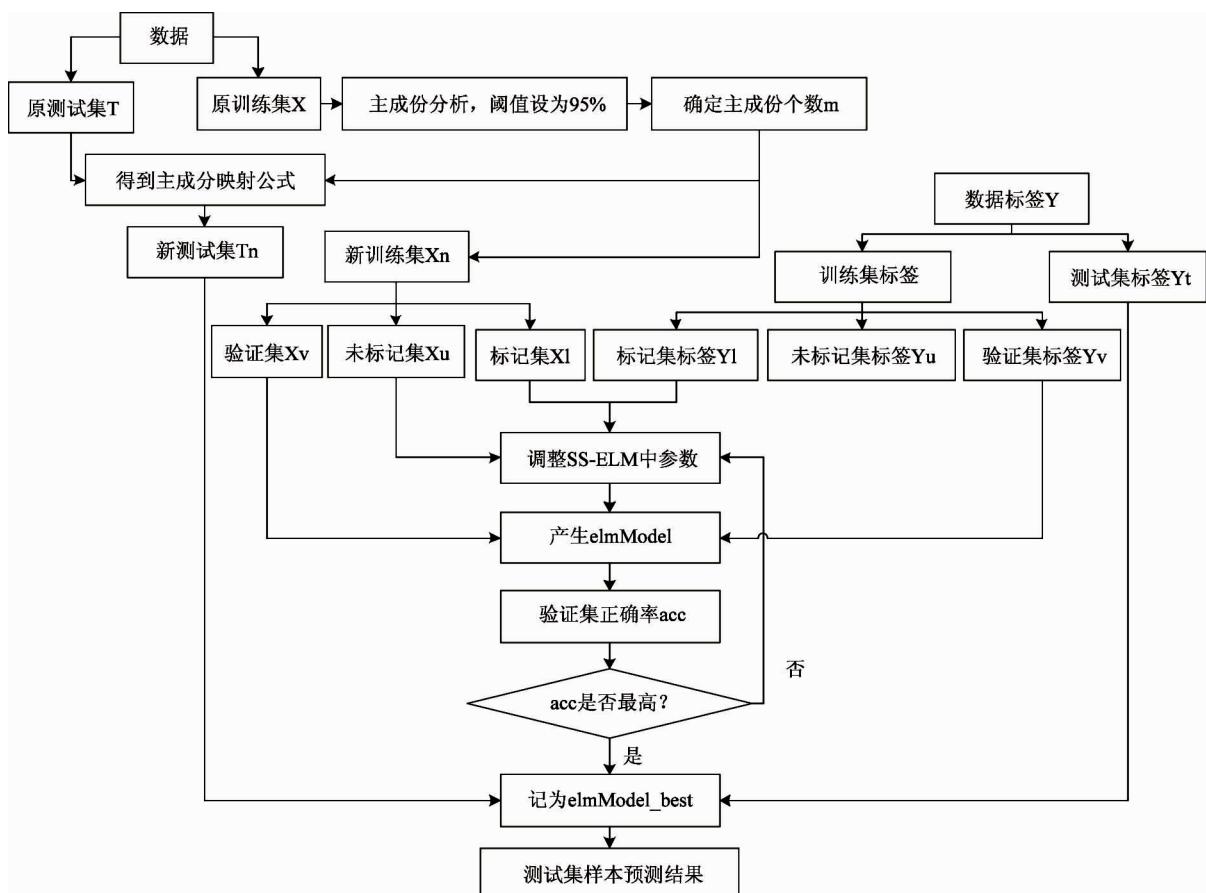


图 2 PCA + SS-ELM 方法的流程图

数据集可从以下网址下载并进行验证 (<http://sclab.yonsei.ac.kr/movingstatus.csv> 和 http://sclab.yonsei.ac.kr/movingstatus_2.csv)。需要说明的是,为了便于衡量实验方法的正确率,实验中用到的所有数据都带有标签。

表 1 Android 手机数据集详情

数据集	特征数	活动类数	样本数	采集数据时用到的传感器
dataset1	6	3	1107	加速度传感器
dataset2	22	5	661	加速度传感器, 方向传感器, 磁场传感器等

本研究分别在十倍交叉验证和五倍交叉验证两种情况下对两个数据集进行实验。对于每一个训练集,又将其细分为标记集、验证集、未标记集,标记集和验证集的数据都带有相应的标签。本文用标记集与未标记集训练 SS-ELM 方法,用验证集进行模型选择(比如,寻找 SS-ELM 方法中的最优参数 C_0 和 λ)。

3.1 SS-ELM 方法结果与分析

首先,本研究以 dataset1 为例验证了 SS-ELM 方法处理 Android 手机数据活动识别的可行性。随后为了探索 SS-ELM 方法与数据集标记率(数据集标记率是指实验中用到的带标签数据的数量占该数据集数据总量的百分比)的关系,又分别在标记率为 5%、10%、15% 的情况下进行了实验。实验结果总结在了表 2 中,需要说明的是,表中的每一个实验结果都是取自十次实验的平均值和方差。

表2 不同标记率下 SS-ELM 算法的实验结果

		5%	10%	15%
dataset1	测试集 T	95.00(\pm 2.54)	94.82(\pm 1.87)	96.46(\pm 2.03)
	未标记集 U	94.42(\pm 0.92)	94.57(\pm 0.83)	94.11(\pm 0.72)
	验证集 V	99.63(\pm 1.17)	99.82(\pm 0.58)	99.41(\pm 0.62)
dataset2	测试集 T	66.64(\pm 11.85)	68.86(\pm 6.20)	73.43(\pm 5.63)
	未标记集 U	62.77(\pm 8.90)	70.14(\pm 3.72)	74.54(\pm 2.65)
	验证集 V	69.67(\pm 7.06)	69.68(\pm 5.08)	67.45(\pm 3.79)

由表2可以看出,SS-ELM方法在不同标记率下对于dataset1的识别正确率基本一致,这就说明以后有希望用少量的带标签数据得到较高的活动识别正确率,从而大大减少获得带标签样本所需投入的时间、精力、资金等。SS-ELM方法对于dataset2的识别正确率则随着标记率的降低有所下降。这说明

SS-ELM方法对比较复杂的活动识别系统的适用性还比较低,有待进一步研究。

3.2 PCA + SS-ELM 方法结果与分析

本文将PCA的阈值设为95%,dataset1和dataset2的最低主成分个数分别为 $m=2$ 和 $m=11$,实验结果如图3与图4所示。

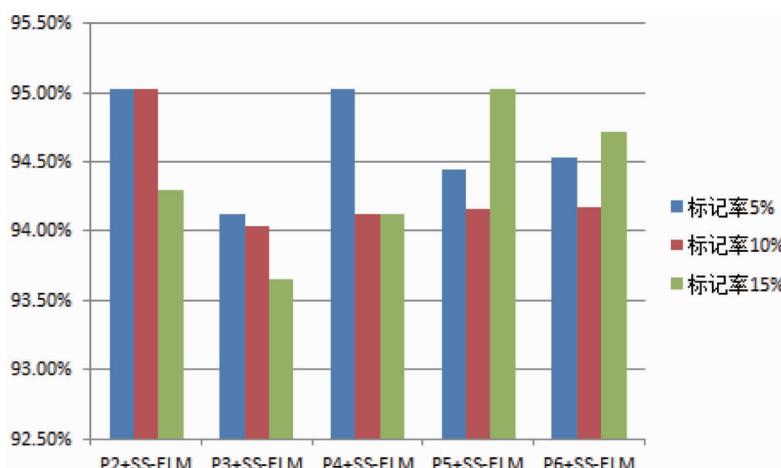


图3 不同标记率下 PCA + SS-ELM 对 dataset1 数据的识别正确率

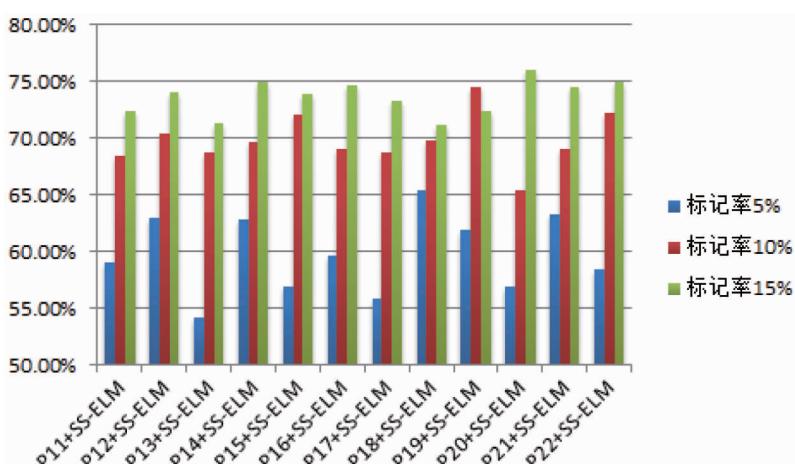


图4 不同标记率下 PCA + SS-ELM 对 dataset2 数据的识别正确率

图中 P_i ($i = 2, 3, 4, 5, 6, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22$) 表示选取了前 i 个主特征。由图 3 与图 4 可以看出, 不同标记率下, 选取不同数量的主特征会在不同程度上影响新方法的活动识别正确率。对此, 本文在实验过程中又以主成分的数量为变量增加了一层循环, 将主成分贡献率在 95% 以

上的不同数量的主成分情况都进行了研究, 从而达到最优活动识别。

由于选用了 Cho 教授提供的 Android 数据集, 所以本研究将 PCA + SS-ELM、SS-ELM 方法与 Lee 和 Cho 提出的全局与局部协同训练(GLCT)方法进行了比较, 如表 3、表 4 所示。

表 3 PCA + SS-ELM、SS-ELM、GLCT 识别正确率的比较

数据集	标记率(%)	PCA + SS-ELM	SS-ELM	GLCT
dataset1	5	95.03 (± 1.24)	94.98 (± 1.07)	86.34 (± 11.11)
dataset2	5	65.46 (± 7.45)	66.82 (± 8.85)	68.09 (± 3.69)
dataset1	10	95.03 (± 1.82)	94.58 (± 1.50)	90.17 (± 5.42)
dataset2	10	74.56 (± 4.12)	68.75 (± 5.62)	61.85 (± 2.94)
dataset1	15	95.03 (± 0.82)	93.94 (± 1.58)	90.81 (± 2.96)
dataset2	15	76.12 (± 3.04)	71.65 (± 5.39)	68.10 (± 2.63)

表 4 PCA + SS-ELM、SS-ELM、GLCT 训练时间的比较

数据集	标记率(%)	PCA + SS-ELM	SS-ELM	GLCT
dataset1	5	0.8585	0.9615	---
dataset2	5	0.3102	0.3363	---
dataset1	10	0.7866	0.8853	---
dataset2	10	0.2768	0.3006	---
dataset1	15	0.7135	0.7869	---
dataset2	15	0.2457	0.2687	---

从识别正确率和训练时间两方面比较 PCA + SS-ELM 和 SS-ELM, 可以发现: 使用 PCA 降维后, 活动识别正确率有了小幅度的提升, 而且训练时间缩短了 10% 左右。对于 dataset1, PCA + SS-ELM 方法的识别正确率较高, SS-ELM 次之, 二者识别正确率皆高于 GLCT。对于 dataset2, 当标记率较高(标记率为 10% 和 15%) 时, PCA + SS-ELM 方法和 SS-ELM 方法的活动识别效果都优于 GLCT, 但当标记率较低(标记率为 5%) 时, PCA + SS-ELM 方法和 SS-ELM 方法的活动识别效果却不及 GLCT 方法, 这一现象值得继续研究。此外, 同一方法对 dataset1 的识别效果都远远高于 dataset2 的识别效果, 原因可能有以下两个: dataset1 的样本数量几乎是 data-

set2 样本数量的 2 倍, dataset1 的活动样本更加充足; dataset1 涉及的活动类型少, 活动间相似性较低。

4 结论

ELM 是模式分类与回归的有效学习机制, 但它主要用于监督学习分类和回归等任务。许多现实问题中又同时存在标签数据和无标签数据, 例如 Android 手机活动识别任务, 促使人们研究半监督学习及其改进方法。本文提出了主成分分析与半监督极限学习机相结合的方法, 即 PCA + SS-ELM 方法, 并将其应用到了移动环境下的活动识别问题。实验用到了 dataset1 和 dataset2 两个数据集, dataset1 的识

别正确率达到了95%,这就表明PCA+SS-ELM方法足以准确识别简单的活动;且与其他方法相比,该方法结构简单、训练速率快、易于泛化。而dataset2的识别正确率仅达到76.12%,这表明PCA+SS-ELM方法对较复杂的活动的识别效果仍有待提高,对此,今后将从复杂活动之间的相似性、过渡性或者采用分层分类系统等角度进一步研究。

移动环境下用Android手机平台进行活动识别仍有以下局限性:(1)手机传感器角度的变化会使收集到的数据与真实数据有偏差;(2)手机不可能长时间存储大量的传感器数据;(3)手机配置不高会限制可用传感器的数目。针对第一个局限性,可以将手机置于身体的某个部位;针对第二个局限性,则可以将手机数据传送到云平台,在云平台完成特征提取、模型建立、模型优化等步骤;针对第三个局限性,则需要进一步挖掘不同类型的活动数据的内部结构及其有效特征。

参考文献

- [1] 刘斌,刘宏建,金笑天,国德峰. 基于智能手机传感器的人体活动识别. *计算机工程与应用*, 2016, 52(4): 188-193
- [2] Kwapisz J R, Weiss G M, Moore S A. Activity recognition using cell phone accelerometers. *Acm Sigkdd Explorations Newsletter*, 2011, 12(12):74-82
- [3] Zeng M, Neuyen L T, Yu B, et al. Convolutional neural networks for human activity recognition using mobile sensors. In: Proceedings of the 6th International Conference on Mobile Computing, Applications and Services (MobiCASE), Austin, USA, 2014. 197-205
- [4] Guo D F, Liu B, Jin X T, et al. Human activity recognition using smart-phone sensors. *Applied Mechanics & Materials*, 2014, 571-572:1019-1029
- [5] Capela N A, Lemaire E D, Baddour N. Feature selection for wearable smartphone-based human activity recognition with able bodied, elderly, and stroke patients. *Plos One*, 2015, 10(4):e0124414
- [6] Liao M, Guo Y, Qin Y, et al. The application of EMD in activity recognition based on a single triaxial accelerometer. *Bio-medical materials and engineering*, 2015, 26(s1):3395-3400
- [7] Kim J H, Kim I C. Design and implementation of a two-phase activity recognition system using smartphone's accelerometers. *KIPS Transactions on Software and Data Engineering*, 2014, 3(2):87-92
- [8] Acharjee D, Mukherjee A, Mandal J K, et al. Activity recognition system using inbuilt sensors of smart mobile phone and minimizing feature vectors. *Microsystem Technologies*, 2016, 22(11):2715-2722
- [9] Reyes Ortiz J L, Oneto L, Samà A, et al. Transition-aware human activity recognition using smartphones. *Neurocomputing*, 2015, 171(C):754-767
- [10] Al J Y, Ali M A, Latief M, et al. Online sequential extreme learning machine algorithm based human activity recognition using inertial data. In: Proceedings of the 2015 10th Asian. Control Conference (ASCC), Kota Kinabalu, Malaysia, 2015. 1-6
- [11] Lee Y S, Cho S B. Activity recognition with android phone using mixture-of-experts co-trained with labeled and unlabeled data. *Neurocomputing*, 2014, 126(3): 106-115
- [12] 付华. 基于极限学习机的半监督分类:[硕士学位论文]. 西安电子科技大学电子工程学院, 2013. 9-16
- [13] 汪海燕,黎建辉,杨凤雷. 支持向量机理论及算法研究综述. *计算机应用研究*, 2014, 31(5):1281-1286
- [14] Shi L C, Lu B L. EEG-based vigilance estimation using extreme learning machines. *Neurocomputing*, 2013, 102(2):135-143
- [15] Huang G B, Zhou H, Ding X, Zhang R. Extreme learning machine for regression and multiclass classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2012, 42(2):513-529
- [16] Rong H J, Huang G B, Sundararajan N, et al. Online sequential fuzzy extreme learning machine for function approximation and classification problems. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2009, 39(4):1067-1072
- [17] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: Theory and applications. *Neurocomputing*, 2006, 70(1):489-501
- [18] Xiao W, Lu Y. Daily human physical activity recognition based on kernel discriminant analysis and extreme learning machine. *Mathematical Problems in Engineering*, 2015, 2015:1-8. doi: 10.1155/2015/790412

- [19] Zong W, Huang G B, Chen Y. Weighted extreme learning machine for imbalance learning. *Neurocomputing*, 2013, 101(3):229-242

Study of applying semi-supervised extreme learning machines to activity recognition using Android phones

Wang Jinjia , Tian Peipei

(School of Information Science and Engineering, Yanshan University, Qinhuangdao 066004, China)

Abstract

Based on the analysis of the existing techniques for activity recognition using Android phones, the semi-supervised (SS) learning capable of raising the recognition accuracy and speed based on unlabeled samples was combined with the extreme learning machine (ELM) reflecting the effective learning mechanism of pattern classification regression to give a SS-ELM method to solve the activity recognition on the Android mobile platform to solve the difficult problem of extrapolating human activity from incomplete, inadequate mobile sensor data. Furthermore, based on combining principal component analysis (PCA), a new method, called the SS-ELM, was proposed. The experimental results show that the novel method is feasible and its recognition accuracy can reach 95%, better than that of the recently proposed method of mixture-of-experts.

Key words: activity recognition, semi-supervised extreme learning machine (SS-ELM), sensor, accelerometer, Android phone