



计算机科学

COMPUTER SCIENCE

基于 SVM 的类别增量人体活动识别方法

邢云冰, 龙广玉, 胡春雨, 忽丽莎

引用本文

邢云冰, 龙广玉, 胡春雨, 忽丽莎. [基于 SVM 的类别增量人体活动识别方法](#)[J]. 计算机科学, 2022, 49(5): 78-83.

XING Yun-bing, LONG Guang-yu, HU Chun-yu, HU Li-sha. [Human Activity Recognition Method Based on Class Increment SVM](#)[J]. Computer Science, 2022, 49(5): 78-83.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[单类支持向量机融合深度自编码器的异常检测模型](#)

Anomaly Detection Model Based on One-class Support Vector Machine Fused Deep Auto-encoder

计算机科学, 2022, 49(3): 144-151. <https://doi.org/10.11896/jsjcx.210100142>

[基于自反馈最优子类挖掘的视频异常检测算法](#)

Video Abnormal Event Detection Algorithm Based on Self-feedback Optimal Subclass Mining

计算机科学, 2021, 48(7): 199-205. <https://doi.org/10.11896/jsjcx.200800146>

[一种基于表面肌电信号的腕部肌力估计方法研究](#)

Study on Method for Estimating Wrist Muscle Force Based on Surface EMG Signals

计算机科学, 2021, 48(6A): 317-320. <https://doi.org/10.11896/jsjcx.200600021>

[噪声环境下的人脸防伪识别算法研究](#)

Face Anti-spoofing Algorithm for Noisy Environment

计算机科学, 2021, 48(6A): 443-447. <https://doi.org/10.11896/jsjcx.200900207>

[基于整车 EMC 标准测试和机器学习的反向诊断方法](#)

Reverse Diagnostic Method Based on Vehicle EMC Standard Test and Machine Learning

计算机科学, 2021, 48(6): 190-195. <https://doi.org/10.11896/jsjcx.200700204>

基于 SVM 的类别增量人体活动识别方法

邢云冰¹ 龙广玉^{1,2} 胡春雨³ 忽丽莎⁴

1 中国科学院计算技术研究所 北京 100190

2 湘潭大学计算机学院·网络空间安全学院 湖南 湘潭 411105

3 齐鲁工业大学计算机科学与技术学院 济南 250353

4 河北经贸大学信息技术学院 石家庄 050061

摘要 基于人体活动识别(Human Activity Recognition, HAR)的健康监护是发现健康异常的一种重要手段。然而,在日常活动识别中,很难提前获取包含所有可能活动类别的训练样本。当预测阶段出现新增类别时,传统的支持向量机(Support Vector Machine, SVM)会将其错误地分类为已知类别。一个鲁棒的分类器应该能够分辨出新增类别,以便后续区别于已知类别并对其进行处理。文中提出一种基于 SVM 的类别增量人体活动识别方法,引入超球面的思想,既能高精度地识别已知活动类别,又能检测出新增类别。通过训练得到的多个超球面将整个特征空间进行划分,使分类器具有对新增活动类别的检测能力。实验结果表明,与传统多分类 SVM 方法相比,该方法能够在不显著降低已知类别分类效果的前提下实现对新增类别的检测,从而提高分类器在开放环境下的人体活动识别能力。

关键词: 人体活动识别; 支持向量机; 超球面; 聚类可分; 类别增量

中图分类号 TP391.41

Human Activity Recognition Method Based on Class Increment SVM

XING Yun-bing¹, LONG Guang-yu^{1,2}, HU Chun-yu³ and HU Li-sha⁴

1 Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190, China

2 School of Computer Science & School of Cyberspace Science, Xiangtan University, Xiangtan, Hunan 411105, China

3 School of Computer Science and Technology, Qilu University of Technology, Jinan 250353, China

4 School of Information Technology, Hebei University of Economics and Business, Shijiazhuang 050061, China

Abstract Health monitoring based on human activity recognition (HAR) is an important means to discover health abnormalities. However, in daily activity recognition, it is difficult to obtain training samples containing all possible activity categories in advance. When new categories appear in the prediction stage, the traditional support vector machine (SVM) will incorrectly classify them as known category. A robust classifier should be able to distinguish the newly added categories so that they can be processed differently from the known categories. This paper proposes a human activity recognition method based on class increment SVM, and the idea of hypersphere is introduced, which can not only identify known activity categories with high accuracy, but also detect new categories. The multiple hyperspheres obtained through training divide the entire feature space, so that the classifier has the ability to detect newly added activity categories. The experimental results show that compared with the traditional multi-class SVM method, our method can realize the detection of new categories without significantly reducing the classification effect of known categories, thereby improving the classifier's ability to recognize human activity in an open environment.

Keywords Human activity recognition, Support vector machine, Hyperspheres, Clustering separability, Class increment

1 引言

随着我国人口老龄化的快速发展,健康异常监护备受关
注。健康监护的基础是人体活动识别,其贯穿于日常行为追踪、个人健康监护和辅助康复等各个方面。人体活动反映了

人的身体状态和行为意图,通常包括步行、上下楼梯、平躺、站立等。人体活动识别旨在将个体日常活动进行识别分类,以便及时追踪和监测个体的状态。随着可穿戴传感设备的迅速发展,基于传感器的方法成为人体活动识别的一种新范式,相较于基于视觉图像的方法,基于传感器的方法存在数据量小、

到稿日期:2021-04-01 返修日期:2021-10-18

基金项目:国家重点研发计划(2018YFC2002603);国家自然科学基金(62002187);河北省高等学校科学技术研究资助项目(QN2018116)

This work was supported by the National Key Research and Development Program of China(2018YFC2002603), National Natural Science Foundation of China(62002187) and Science and Technology Project of Hebei Education Department(QN2018116).

通信作者:邢云冰(xingyunbing@ict.ac.cn)

推理简单以及成本低、可嵌入性强等优点,在人体活动识别的研究和应用中依然占据一席之地。

SVM 作为经典的机器学习方法,凭借其完善的理论基础以及松弛变量、核函数的引入,在小样本数据分类上具有足够的竞争力。SVM 通常要求预测样本和训练样本满足独立同分布假设,并且预测样本的类别结果一定是训练样本已知类别中的一种。

然而,人体的活动方式多种多样,除前文所列举的以外,还有跑步、跌倒、坐下等。在人体活动识别的实际应用中,难以获取所有活动类别的数据进行训练,当在预测阶段出现新增类别时,SVM 分类器会将其错误地划分为已知类别,从而降低整个系统的性能。对于新增活动或无效的随机运动,更理想的处理结果是输出一个新增类别来表示无效活动。在有人类参与的场合,该缺陷引起的问题并不明显,对于无效的动作行为,人类可以简单判别并忽略该识别结果。但在全自动场合,由于异常情况的存在,需要自动判断动作行为是否正常或有效。

针对上述问题,本文将类别增量纳入考量,提出一种新的基于 SVM 的人体活动识别方法。该方法引入超球面的思想,通过训练得到的多个超球面将整个特征空间进行划分,使分类器具有对新增活动类别的检测能力。实验结果表明,所提超球面 SVM 分类器在已知类别上不仅具有和传统 SVM 相当的查全率、查准率和精度,而且能检测出新增类别,使得分类模型的整体查准率和精度得到提高。

2 相关工作

人体活动识别的研究最早可追溯至上世纪 90 年代末,基于传感器的人体活动识别经过了一系列的探索和技术更迭。从数据采集到特征提取,再到提升识别的精确度和实时性等方面,大量研究者都进行了相关研究。早期文献^[1]对人体活动识别进行了阶段性综述,阐述了搭建人体活动识别系统面临的五大挑战,可归纳为:1)实用、便携以及便宜的数据采集设备;2)移动设备的支持;3)特征优选;4)活动识别的实时性;5)不需要重新训练系统就能灵活地支持新用户或新活动。文献^[2]详细阐述了基于传感器的人体活动识别的研究现状,并对系统结构和基本原理进行了详细的描述和总结。目前仅随身携带智能手机就能实现人体活动数据的采集和较高精度的识别^[3]。

在特征提取方面,文献^[4]提出了一种基于多分类器融合的人体活动识别模型,针对 5 种日常活动,使用 5 棵决策树作为基分类器,分别采用对每种活动最敏感的特征组合来训练单个基分类器,再对每个基分类器的输出结果进行融合处理,以获取最终的活动识别结果。实验结果表明,其平均识别准确率和可信度分别达到 96.84% 和 97.41%。针对多传感器同步测量存在的设备冗余问题,文献^[5]提出了一种基于实例动态选择传感器的方法,目的是为每个实例选择适当的传感器子集来预测人体活动,尽可能地在识别精度和传感器数量之间取得平衡。文献^[6]提出了一种基于肤色特征的手势识别模型。

针对多个异构传感器在数据融合时存在不兼容的现象,

文献^[7]提出多传感器决策级数据融合的多任务深度学习模型。实验结果表明,相比 3 个基准模型,其识别准确率平均高出 8%,并且可以有效识别周期性活动、非周期性活动以及并发复杂活动。文献^[8]提出一种基于时间窗口的轻量级活动识别算法,该算法能实时识别日常活动,同时利用预置数据和聚类标记来解决训练数据不足的问题。在设备端用聚类方法建立人体活动识别模型,使用 SVM 分类器来实现实时识别。实验结果表明,该算法对各种日常活动的识别准确率为 87.45%,且算法运行时间相比其他算法缩短了 30%。文献^[9]将来自惯性传感器的原始数据聚合为一个时间序列作为输入,然后通过降维处理提取信号特征,再利用 SVM 进行分类。实现结果显示,该方法可以保证识别精度不受影响,并能有效提升识别效率。

卷积神经网络(Convolutional Neural Network, CNN)在基于传感器的人体活动识别中也有大量的应用。针对不同传感器的特征需要统一映射为公共输入的问题,文献^[10]提出一种新的 CNN 架构,这种深度架构主要采用卷积和池化操作,以捕获不同时间尺度下传感器信号的显著模式。针对新用户加入会导致模型识别性能显著下降的问题,文献^[11]开发了一个基于 CNN 的迁移学习框架,以此建立一个具有最少用户监督的个体活动识别模型。为了挖掘多位置三轴传感器相同轴向数据之间的空间依赖性,文献^[12]提出了 T-2DCNN 和 M-2DCNN 两种网络,并进一步提出卷积层参数优化方法。文献^[13]提出了一种新的双流卷积 Transformer 模型,该模型利用双流结构来同时捕获通道的时序特征和时间节点的通道特征,并使用多尺度卷积增强 Transformer 来捕获基于距离的模式。在 4 个数据集上的实验结果表明该模型在有效性和效率方面都优于当前的模型。

类别增量识别属于开放集识别^[14],目前主要应用在计算机视觉领域,最典型的案例是人脸检测和识别,前者检测输入是否为人脸,后者判断输入是否为人脸库中的某张脸。类别增量是人脸识别应用中重要的组成部分,同时在人体活动识别领域也有广泛应用。文献^[15]是 SVM 实现开放集识别的典型实例,引入了一种新的用于开放集识别的概率类关联形式化模型,称为紧凑衰减概率(Compact Abating Probability, CAP)。在 CAP 模型中,当样本数据从已知类别向新增类别移动时,类别成员的概率也将降低。这意味着该模型已经把类别增量纳入考量而不需要专门为其建模。此外,文献^[15]还介绍了一种新的威布尔校正支持向量机(W-SVM)技术,该技术结合了 CAP 和统计极值理论来改进开放集识别。文献^[16]提出了一种适合开放集的领域自适应方法,该方法将源域的特征空间映射到目标域(目标域是开放集),可应用于无监督或半监督环境,即目标域中的少数图像由已知类别进行注释。文献^[17]对开放集人脸识别进行了探索,结合哈希函数、偏最小二乘(PLS)和全连接网络(FCN),提出了 HPLS 和 HFCN 算法,并利用实验验证了所提方法的有效性。

本文使用的 SVM 方法相较于基于 CNN 等神经网络方法具有以下优势:一方面,CNN 为了避免训练发生过拟合,需要足够多的训练数据,而 SVM 方法需要的数据相对较少,因此可以通过对训练数据进行严格标注来提升模型性能;另一

方面,相比 CNN 方法,本文提出的分类模型简单,实现复杂度低。与传统 SVM 类似,最终的分类结果仅受少量位于超球壳界面或者错误侧的样本数据(即支持向量)影响。

3 解决问题的思路

传统 SVM 假设样本数据在特征空间是线性可分的,传统二分类 SVM 的目标可以描述为利用样本数据 \vec{x}_i 在特征空间中寻找一个线性超平面 $f(x) = \vec{w}^T \varphi(\vec{x}) + b = 0$, 其中 \vec{w} 是线性超平面的法向量, b 是偏移量, 如果 $f(x_i) > 0$, 则 $y_i = +1$ 表示该样本数据属于正类别, 如果 $f(x_i) < 0$, 则 $y_i = -1$ 表示该样本数据属于反类别。这表明每一类别的样本数据在特征空间的分布是开放的, 分布范围是发散的。例如, 两个在特征空间中相距很远的样本数据, 只要保证其位于线性超平面的同一侧, 就归为同一类别。同类别样本数据在特征空间的开放分布导致任意样本数据均可以在已知类别的所属空间范围内找到位置, 即任意样本数据均划分为已知类别。

如果每一类别的样本数据在特征空间的分布是聚集的, 可以被一个封闭的曲面包裹, 那么每一类别在特征空间的分布范围将是有限的, 对于一个样本数据, 如果不在所有已知类别的所属空间范围内, 即可认定其为新增类别。

4 基于超球面分类的 SVM 模型

为了解决传统 SVM 分类器无法有效区分新增类别的问题, 本文提出一种基于超球面的 SVM 分类器, 在保证有效识别已知类别的前提下, 实现对新增类别的检测。

基于传感器的人体活动识别模型架构如图 1 所示, 整体分为数据采集、特征提取以及活动识别 3 个阶段。

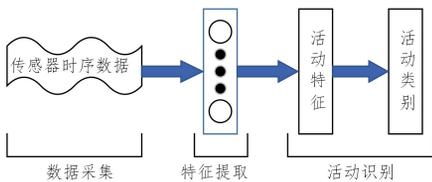


图 1 模型整体架构

Fig. 1 Model architecture

在特征提取阶段, 对输入传感器时序数据采用现有的特征提取方法得到维度统一的活动特征。在活动识别阶段, 给定一个包含 M 个样本数据的训练集 $T = \{(\vec{x}_1, y_1), (\vec{x}_2, y_2), \dots, (\vec{x}_M, y_M)\} \in (X \times Y)^M$, 其中 $\vec{x}_i \in X = R^n$ 表示样本数据(提取后的特征), $y_i \in Y = \{+1, -1\}$, 且 $i = 1, 2, \dots, M$ 。和传统 SVM 类似, 假设样本数据 \vec{x}_i 在原始空间不是聚类可分的, 可以将样本数据 \vec{x}_i 从原始空间映射到新特征空间(新特征空间一般是更高维的), 样本数据 \vec{x}_i 在新特征空间的对应点为 $\varphi(\vec{x}_i)$, 在新特征空间是聚类可分的。如图 2 所示, /// 表示正例, //// 表示反例。 $\{x-y\}$ 特征空间下聚类不可分(线性不可分), $\{u-v\}$ 特征空间下聚类可分, 特征空间变换公式如式(1)所示:

$$u = x^{-1}; v = y^{-1} \quad (1)$$

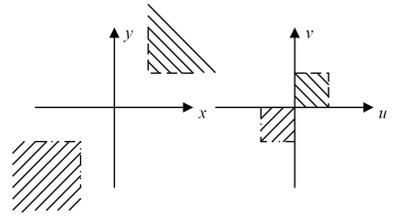


图 2 聚类可分

Fig. 2 Clustering separability

在新特征空间中通过最大间隔及最小化超球面表面积的原则寻找最优超球面 $\|\varphi(\vec{x}) - \vec{O}\|^2 = R^2$, 使样本数据完全正确地分开, 这是基于超球面分类的硬间隔 SVM; 如果允许训练集在新特征空间中是近似聚类可分的, 即允许有错分点, 则通过综合考虑间隔最大化、超球面表面积最小化和错分程度最小化这 3 个原则来寻找最优超球面 $\|\varphi(\vec{x}) - \vec{O}\|^2 = R^2$, 使样本数据大体上能够正确地分开, 这就是本文提出的基于超球面分类的 SVM 模型。

基于超球面的新增类别多分类方法可以分解为多个二分类方法。

二分类方法的目标可以描述为利用样本数据在特征空间中寻找一个超球面。

$$f(x) = \|\varphi(\vec{x}) - \vec{O}\|^2 = R^2 \quad (2)$$

其中, \vec{O} 是超球面的球心, R 是超球面的半径, 如果 $f(x) < R$, 则 $y_i = +1$ 表示该样本属于正类别, 如果 $f(x) > R$, 则 $y_i = -1$ 表示该样本属于反类别。最优的超球面应该使得表面积最小化并且样本数据离该超球面的最小距离最大化, 即原超球面的表面积尽量小, 正反类别样本数据离原超球面的最小距离分别形成两个同心超球面, 同心超球面组成的超球壳的壳厚度尽量大, 如图 3 所示, 数学形式表达为:

$$\min_{\vec{O}, R, d, \xi} R^2 - C_1 d + C_2 \sum_{i=0}^M \xi_i \quad (3)$$

满足约束条件:

$$y_i \|\varphi(\vec{x}_i) - \vec{O}\|^2 \leq y_i R^2 - d^2 + \xi_i, \xi_i \geq 0 \quad (4)$$

其中, C_1 和 C_2 是经验系数, d 相当于满足约束条件的样本数据离超球面的最小距离, M 为样本数据的数量, ξ_i 为松弛变量, 对少数不满足硬性约束条件的样本数据放松约束(代价是目标函数被惩罚)。

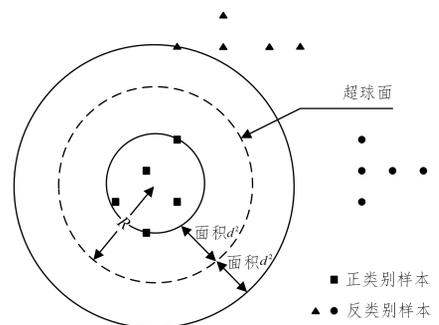


图 3 二分类原理

Fig. 3 Principle of binary classification

式(3)的本质是一个凸二次规划问题, 使用拉格朗日乘子法可得到其对偶问题。具体来说, 对式(3)的每条约束添加

拉格朗日乘子,则该问题的拉格朗日函数可写为:

$$L(\vec{O}, R, d, \vec{\alpha}, \vec{\xi}, \vec{\mu}) = R^2 - C_1 d + C_2 \sum_{i=1}^M \xi_i + \sum_{i=1}^M \alpha_i (y_i \|\varphi(\vec{x}_i) - \vec{O}\|^2 - y_i R^2 + d^2 - \xi_i) - \sum_{i=1}^M \mu_i \xi_i \quad (5)$$

其中, $\alpha_i \geq 0, \mu_i \geq 0$ 是拉格朗日乘子。

令 $L(\vec{O}, R, d, \vec{\alpha}, \vec{\xi}, \vec{\mu})$ 对 \vec{O}, R, d 和 $\vec{\xi}$ 的偏导为零可得:

$$\sum_{i=1}^M \alpha_i y_i (\varphi(\vec{x}_i) - \vec{O}) = 0 \quad (6)$$

$$R - \sum_{i=1}^M \alpha_i y_i R = 0 \quad (7)$$

$$-C_1 + 2 \sum_{i=1}^M \alpha_i d = 0 \quad (8)$$

$$C_2 - \alpha_i - \mu_i = 0 \quad (9)$$

将式(6)~式(9)代入式(5)即可得到式(3)的对偶问题。

$$\max_{\vec{\alpha}} \sum_{i=1}^M \sum_{j=1}^M \alpha_i \alpha_j y_i y_j K(\vec{x}_i, \vec{x}_j) - \sum_{i=1}^M \alpha_i y_i K(\vec{x}_i, \vec{x}_i) + \frac{C_1^2}{4} \left(\sum_{i=1}^M \alpha_i \right)^{-1} \quad (10)$$

满足约束条件 $\sum_{i=1}^M \alpha_i y_i = 1, 0 \leq \alpha_i \leq C_2$, 其中 $K(\vec{x}_i, \vec{x}_j) = \varphi(\vec{x}_i)^T \varphi(\vec{x}_j)$ 表示核函数,如高斯核。

$$K(\vec{x}_i, \vec{x}_j) = \exp\left(-\frac{\|\vec{x}_i - \vec{x}_j\|^2}{2\sigma^2}\right) \quad (11)$$

式(10)是一个典型的二次规划问题,可以使用通用的二次规划算法来求解,也可以使用序列最小化优化(SMO)算法来求解,通过样本数据训练得到参数 \vec{O} 和 R ,即得到一个分类器。

对于每个新的样本数据,根据分类器预测 $f(x) = \|\varphi(\vec{x}) - \vec{O}\|^2$,如果 $f(x) < R$,则表示该样本属于正类别,如果 $f(x) > R$ 则表示该样本属于反类别。

对于包含新增类别的多分类方法,选取其中一种类别作为正类别,其余类别作为反类别,采用上述二分类方式进行训练,分别得到分类器(超球面),新样本数据根据每个分类器分别进行预测,最终可以判断其是否属于已知类别以及属于哪个已知类别。

如果3个二分类问题选取相同的核函数以及相关参数,相当于3个超球面将整个特征空间划分为4个部分,如图4所示。如果新样本数据位于所有3个超球面的外部,则认为该样本属于新增类别;如果新样本数据位于一个以上超球面的内部(多个超球面相交),通过计算该样本距离每个超球面球心的相对距离(绝对距离除以超球面的半径),则将相对距离最小的超球面所属的类别认定为该样本的最终类别。除此之外,也可以直接认为该样本属于新增类别。

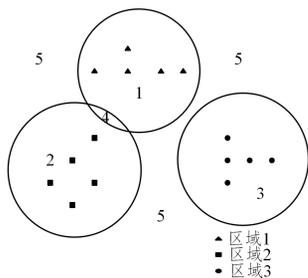


图4 三分类示意图

Fig. 4 Example of three-type classification

5 实验验证与结果分析

为了验证超球面 SVM 分类器的有效性,在 HAR^[18], Physiological^[19] 和 INFRARED^[20] 这3个常用的人体活动识别基准数据集上进行对比实验。在训练数据、验证数据和测试数据相同的条件下,传统 SVM 和超球面 SVM 均采用投票机制。实验直接使用这3个数据集默认已提取后的特征,重现结果的代码可以在 Github¹⁾ 下载。实验环境为 WIN10, Matlab2018, 优化算法 SMO 使用 CVX 工具。

传统 SVM 的参数配置为:线性核函数(无特征空间映射),以验证集精度为目标搜索经验参数 C , 范围为 $1 \sim 100$, 步进为 1。

超球面 SVM 的参数配置为:线性核函数(无特征空间映射),以验证集精度为目标采用交叉法搜索经验参数 C_1 和 C_2 , 范围为 $2 \sim 64$, 步进为 2。

HAR 数据集包含 6 个类别,分别是行走(walking)、上楼(upstair)、下楼(downstair)、坐(sitting)、站立(standing)、躺(laying),其中训练样本 7 352 个,测试样本 2 497 个,每个样本数据为 561 维。将训练样本按 9:1 分成训练集和验证集,且仅选择前 5 类样本,不选择类别为“躺”的样本。测试样本组成测试集,并将第 6 类(“躺”)作为新增类别。测试集基于传统 SVM 和超球面 SVM 的分类结果混淆矩阵如表 1 和表 2 所列。

表1 基于传统 SVM 的 HAR 分类结果

Table 1 Results of HAR classification based on traditional SVM

C=2	预测活动						查全率/%
	行走	上楼	下楼	坐	站立	新增	
行走	491	2	3	0	0	0	98.99
上楼	27	442	2	0	0	0	93.84
下楼	3	6	411	0	0	0	97.86
坐	0	3	0	440	48	0	89.61
站立	0	0	0	19	513	0	96.43
新增	0	1	6	526	4	0	0
查准率/%	94.24	97.36	97.39	44.67	90.80	NaN	77.94

表2 基于超球面 SVM 的 HAR 分类结果

Table 2 Results of HAR classification based on hyperspheres SVM

C ₁ =26 C ₂ =28	预测活动						查全率/%
	行走	上楼	下楼	坐	站立	新增	
行走	454	5	7	0	0	30	91.53
上楼	2	393	11	7	0	58	83.44
下楼	12	1	348	0	0	59	82.86
坐	0	2	0	406	38	45	82.69
站立	0	0	0	9	495	28	93.05
新增	0	0	0	2	0	535	99.63
查准率/%	97.01	98.00	95.08	95.75	92.87	70.86	89.28

在 HAR 数据集上,传统 SVM 的分类精度为 77.94%,超球面 SVM 的分类精度为 89.28%,由于超球面 SVM 具有对新增类别的检测能力,因此分类精度明显提高。

Physiological 数据集包含 4 个类别,分别是中立(neutral)、情绪(emotional)、心理(mental)和生理(physical),样本 4 480 个,每个样本数据为 533 维。将样本按 8:1:1 分成训练集、验证集和测试集。训练集和验证集仅选择后 3 类样本,

¹⁾ <https://github.com/xingyunbing/hypersphere-svm>

不选择类别为“中立”的样本,测试集将第 1 类(“中立”)作为新增类别。测试集基于传统 SVM 和超球面 SVM 的分类结果混淆矩阵如表 3 和表 4 所列。

表 3 基于传统 SVM 的 Physiological 分类结果

Table 3 Results of Physiological classification based on traditional SVM

C=16	预测活动				查全率/%
	情绪	心理	生理	新增	
真实活动	情绪	112			100
	心理		89	23	79.46
	生理		29	83	74.11
	新增	2	53	57	0
查准率/%	98.25	52.05	50.92		63.39

表 4 基于超球面 SVM 的 Physiological 分类结果

Table 4 Results of Physiological classification based on hyperspheres SVM

C ₁ =14 C ₂ =46	预测活动				查全率/%
	情绪	心理	生理	新增	
真实活动	情绪	110		2	98.21
	心理		74	29	66.07
	生理	1	26	69	61.61
	新增		4	7	101
查准率/%	99.10	71.15	65.71	78.91	79.02

Physiological 数据集上,传统 SVM 的分类精度为 63.39%,超球面 SVM 的分类精度为 79.02%,由于超球面 SVM 具有对新增类别的检测能力,因此分类精度明显提高。

INFRARED 数据集包含 6 个类别,分别是行走(walking)、下楼(downstair)、上楼(upstair)、跑(running)、站立(standing)、原地走(walking inplace),样本 3372 个,每个样本数据为 38 维。将样本按 8:1:1 分成训练集、验证集和测试集,且仅选择前 5 类样本,不选择类别为“原地走”的样本,测试集将第 6 类(“原地走”)作为新增类别。测试集基于传统 SVM 和超球面 SVM 的分类结果混淆矩阵如表 5 和表 6 所列。

表 5 基于传统 SVM 的 INFRARED 分类结果

Table 5 Results of INFRARED classification based on traditional SVM

C=1	预测活动						查全率/%
	行走	上楼	下楼	坐	站立	新增	
真实活动	行走	72		2			97.47
	下楼	2	40	1			93.02
	上楼			46			100
	跑				53		100
	站立					56	100
	新增		59			4	0
查准率/%	97.47	40.40	93.38	100	93.33		80.00

表 6 基于超球面 SVM 的 INFRARED 分类结果

Table 6 Results of INFRARED classification based on hyperspheres SVM

C ₁ =2 C ₂ =28	预测活动						查全率/%
	行走	上楼	下楼	坐	站立	新增	
真实活动	行走	72		1		6	91.14
	下楼	2	41				95.35
	上楼			44		2	95.65
	跑			1	52		98.11
	站立					53	94.64
	新增					63	100
查准率/%	97.30	100	93.62	100	100	86.30	95.59

在 INFRARED 数据集上,传统 SVM 的分类精度为 80.00%,超球面 SVM 的分类精度为 95.59%,由于超球面 SVM 具有对新增类别的检测能力,因此分类精度明显提高。

此外,如果不考虑新增类别,HAR,Physiological 和 INFRARED 测试集基于传统 SVM 的分类精度分别为 95.31%,84.52%和 98.19%,均略优于基于超球面 SVM 的分类精度。

实验结果表明,传统的多分类 SVM 模型不具有对新增类别的检测能力,只能识别训练数据中存在的类别。当测试数据中存在新增类别时,分类器会将其划分到已知类别中,从而拉低了整个模型的性能。这也意味着模型的抗干扰能力差,不能适应开放环境下的分类任务。在使用相同训练数据的条件下,所提出的超球面 SVM 分类器在已知类别上不仅具有和传统 SVM 相当的查全率、查准率和精度,而且分类器具有对新增类别的检测能力,因此在新增类别上的查准率明显提高,从而使得分类的整体查准率和精度也得到提高,具有重要的实际应用意义和价值。

结束语 本文提出了一种新的基于 SVM 的类别增量人体活动识别方法,与传统 SVM 方法相比,在不影响已知活动类别分类效果的前提下,实现了对新增类别的检测,大幅提高了模型在开放环境下的分类能力,拓展了人体活动识别方法的应用场景。对于更复杂的情况,如新增类别数据分布不一定均衡,或者需要识别多种新增活动类别,是我们未来的研究方向。

参考文献

- [1] LARA O D, LABABRADOR M A. A Survey on Human Activity Recognition Using Wearable Sensors[J]. IEEE Communications Surveys & Tutorials, 2012, 15(3): 1192-1209.
- [2] ZHANG C X, ZHAO C L, CHEN C, et al. Review of Human Activity Recognition Based on Mobile Phone Sensors[J]. Computer Science, 2020, 47(10): 1-8.
- [3] DAVIDE A, ALESSANDRO G, LUCA O, et al. A Public Domain Dataset for Human Activity Recognition Using Smartphones[C]// 21th European Symposium on Artificial Neural Networks Computational Intelligence and Machine Learning (ESANN 2013). Bruges, Belgium, 2013: 24-26.
- [4] WANG Z M, WANG K, HE Y. Human Motion Activity Recognition Model Based on Multi-classifier Fusion[J]. Computer Science, 2016, 43(12): 297-301.
- [5] YANG X, CHEN Y, YU H, et al. Instance-Wise Dynamic Sensor Selection for Human Activity Recognition[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2020: 1104-1111.
- [6] YANG W B, YANG H C, LU C, et al. Gesture Recognition Based on Skin Color Features and Convolutional Neural Network[J]. Journal of Chongqing Technology and Business University(Natural Science Edition), 2018, 35(4): 75-81.
- [7] SONG X R, ZHANG X Q, ZHAN Z, et al. Multi-Sensor Data Fusion for Complex Human Activity Recognition[J]. Journal of

- Tsinghua University(Science and Technology), 2020, 60(10): 814-821.
- [8] DONG L H, LIU Q, CHEN H M, et al. A Lightweight Real-Time Motion Recognition Algorithm Based on Time Window [J]. Journal of Computer Research and Development, 2017, 54(12): 2731-2740.
- [9] SHAAFI A, SALEM O, MEHAOUA A. Improving Human Activity Recognition Algorithms Using Wireless Body Sensors and SVM[C] // 2020 International Wireless Communications and Mobile Computing (IWCMC). IEEE, 2020.
- [10] YANG J B, NGUYEN M N, SAN P P, et al. Deep Convolutional Neural Networks on Multichannel Time Series for Human Activity Recognition[C] // International Conference on Artificial Intelligence. 2015: 3995-4001.
- [11] ROKNI S A, NOUROLLAHI M, GHASEMZADEH H. Personalized Human Activity Recognition Using Convolutional Neural Networks[C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2018.
- [12] DENG S Z, WANG B T, YANG C G et al. Convolutional Neural Networks for Human Activity Recognition Using Multi-location Wearable Sensors[J]. Journal of Software, 2019, 30(3): 718-737.
- [13] LI B, CUI W, WANG W, et al. Two-Stream Convolution Augmented Transformer for Human Activity Recognition[C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2021.
- [14] GENG C, HUANG S J, CHEN S. Recent Advances in Open Set Recognition: A Survey[J]. arXiv:1811.08581, 2020.
- [15] SCHEIRER W J, JAIN L P, BOULT T E. Probability Models for Open Set Recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(11): 2317-2324.
- [16] BUSTO P P, GALL J. Open Set Domain Adaptation[C] // IEEE International Conference on Computer Vision. IEEE Computer Society, 2017: 754-763.
- [17] VARETOR, SILVA S, COSTA F, et al. Towards Open-Set Face Recognition Using Hashing Functions[C] // 2018 IEEE International Joint Conference on Biometrics (IJCB). IEEE, 2018.
- [18] ANGUITA D, GHIO A, ONETO L, et al. A Public Domain Dataset for Human Activity Recognition Using Smartphones [C] // Proceedings of the 21th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN). 2013: 437-442.
- [19] DUA D, GRAFF C. UCI Machine Learning Repository[EB/OL]. <https://archive.ics.uci.edu/ml/datasets/Activity+recognition+using+wearable+physiological+measurements>.
- [20] JIANG X, CHEN Y, LIU J, et al. AIR: Recognizing Activity Through IR-Based Distance Sensing on Feet[C] // Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing: Adjunct. ACM, 2016: 97-100.



XING Yun-bing, born in 1982, master, senior engineer. His main research interests include sign language interaction, pervasive computing and health surveillance.

(责任编辑:柯颖)