

基于改进特征子集区分度的行为识别特征选择方法



王瑞杰¹ 李军怀^{1,2} 王侃^{1,2} 王怀军^{1,2} 商珣超¹ 徒鹏佳¹

¹ 西安理工大学计算机科学与工程学院 西安 710048

² 陕西省网络计算与安全技术重点实验室 西安 710048

(2191220007@stu.xaut.edu.cn)

摘要 基于传感器的人体行为识别方法在健康监测、运动分析和人机交互等方面得到了广泛应用。特征选择是准确识别人体行为的关键环节,其目的是在提高分类性能的基础上从高维特征空间中筛选出与分类相关的特征,以降低特征维数和计算复杂度。然而,传统的特征选择方法面临着未考虑所选特征冗余性的挑战。因此,针对基于特征子集区分度(Discernibility of Feature Subsets,DFS)衡量准则的特征选择方法仅考虑多个特征的相关性而忽视特征之间冗余性对分类结果影响等缺陷,提出一种基于冗余性的特征子集区分度衡量准则的特征选择方法(Redundancy and Discernibility of Feature Subsets,R-DFS),在特征选择的过程引入冗余性分析,删除冗余特征,以提高分类准确率和降低计算复杂度。实验结果表明,改进方法可有效降低特征维数并提高分类准确度。

关键词: 加速度传感器;行为识别;特征选择;特征子集区分度;特征相关性和冗余性

中图法分类号 TP3-05

Feature Selection Method for Behavior Recognition Based on Improved Feature Subset Discrimination

WANG Rui-jie¹, LI Jun-huai^{1,2}, WANG Kan^{1,2}, WANG Huai-jun^{1,2}, SHANG Xun-chao¹ and TU Peng-jia¹

¹ School of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China

² Shaanxi Key Laboratory for Network Computing and Security Technology, Xi'an 710048, China

Abstract Sensor-based human behavior recognition has been widely used in health monitoring, motion analysis and human-computer interaction. Feature selection acts a critical step when identifying human behaviors accurately, aiming to improve classification performance by selecting classification-related features, so as to reduce feature dimensions and computational complexity. The absence of feature redundancy, nevertheless, poses challenges to legacy feature selection methods. Therefore, to resolve the insufficiency that only feature correlation but not feature redundancy is involved in the Discernibility of Feature Subsets (DFS)-based feature selection method, a novel Redundancy and Discernibility of Feature Subsets (R-DFS)-based feature selection method is proposed to incorporate the redundancy analysis into feature selection process and remove redundant features, so as to improve classification accuracy rate and reduce computational complexity as well. Experimental results reveal that the improved method can efficiently reduce the feature dimension with the improved classification accuracy.

Keywords Acceleration sensor, Behavior recognition, Feature selection, Feature subset discrimination, Feature correlation, redundancy

1 引言

近年来,随着计算机科学和传感器技术^[1]的迅速发展,形态各异的传感器正逐渐影响人们生活的各个层面。根据传感器数据以识别和理解人的动作和行为构成未来以人为中心的计算中的关键任务。人体行为识别^[2]的研究可为人们提供更多人性化的服务,例如:老人监护^[3]、体感游戏^[4]、健康医疗^[5]。基于传感器的人体感知行为识别^[6]是行为识别中的新兴分支,相比于基于图像的行为识别更便捷、自由和安全,对外

界环境依赖度低、可以自由佩戴,且提升了用户数据隐私性。

在基于加速度传感器的人体行为识别研究中,研究者通常会提取时域^[7]和频域^[8]等特征。其中,小的特征子集可能会导致比较高的分类错误率,而大的特征子集会造造成比较低的分类错误率。需要注意,提取的特征不能过多,这是因为:随着特征个数的增加,计算量会呈指数级增长,导致维数灾难;此外,由于提取的特征存在无关和冗余的特性,因此需要对提取特征进行降维处理,选取相关特征,去除无关和冗余特征,最终实现较好的分类效果。

本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:科技部重点研发计划(2017YFB1402103);国家自然科学基金(61971347);西安市科技计划项目(201805037YD15CG21(4))

This work was supported by the National Key R&D Program of China (2017YFB1402103), National Natural Science Foundation of China (61971347) and Project of Xi'an Science and Technology Planning Foundation (201805037YD15CG21(4)).

通信作者:李军怀(lijunhuai@xaut.edu.cn)

根据特征选择方法与分类器的关系,特征选择方法一般可以分为4类:过滤式(Filter)、包装式(Wrapper)、嵌入式(Embedded)和混合式(Filter-Wrapper)。过滤式特征选择算法独立于分类器,一般使用距离、相关性、一致性或信息度量标准以衡量特征与分类类别之间的相关性以及特征之间的冗余性,不同的评价准则可能获得差异性的最优特征子集。其次,包裹式特征选择方法考虑了特征之间的交互作用,依赖于分类器的性能,算法完成后直接输出最优特征子集。此外,特征选择作为学习算法的构成要件,与分类同步进行,嵌入式特征选择算法可以将特征选择嵌入到分类器构造的算法中,从而有效选择特征子集。而混合式特征选择算法结合了过滤式和包裹式两种算法的优点,首先用过滤式算法产生某一特征子集,进而再用包裹式算法对特征子集作进一步压缩。

鉴于混合式具有较高分类正确率的优势,其获得了广泛的使用和研究^[9-10]。其中,谢娟英提出的基于子集区分度的特征子集(Discernibility of Feature Subset, DFS)衡量准则^[11]的特征选择方法考虑了特征之间相关性,通过计算多个特征对分类联合贡献的大小,结合搜索策略和分类器以优选特征子集。然而,在选择特征过程中,该方法未考虑特征之间的冗余性对分类结果的影响,优选出的特征子集存在冗余特征。因此,本文为降低特征之间冗余性,提出基于冗余度和特征子集区分度(Redundancy and Discernibility of Feature Subsets, R-DFS)衡量准则的特征选择方法。一方面,该方法在特征选择过程中加入了冗余性分析,删除冗余特征,在提高分类准确率的同时进一步降低了计算复杂度。另一方面,通过对最大相关和最小冗余的计算,既保证特征子集类别间区分能力的同时,又减少各个特征间的冗余度。在UCI HAR Dataset^[12]数据集上的实验结果表明,本文提出的R-DFS准则可有效区分类间类别,去除类内冗余性,具有较好的泛化能力。

2 基于R-DFS的特征选择方法

特征选择是机器学习、模式识别、数据挖掘等领域的重要研究内容。其从原始特征空间中挑选出满足某种特征子集评价准则的最优特征子集,删除与分类无关的、冗余的特征,以降低数据维数,避免维数灾难,从而减少运行时间以及降低数据空间的复杂度,进而保持或提高系统分类性能和运行效率。因此,特征选择可降低存储需要和计算开销,提高分类准确率。

2.1 基于DFS的特征子集性能评价准则

基于DFS的特征子集区分度衡量准则考虑了特征相关性对于分类的影响,即在考虑特征子集对分类贡献的基础上,通过计算多个特征之间的联合作用对于分类的贡献值,以优选特征子集。通过该准则挑选出与分类相关的特征,剔除无关特征,进而提高分类正确率。

考虑 m 维实空间 \mathbf{R}^m 中的多分类问题:对于任意的 $k(k \geq 2)$ 类别的分类问题,假设样本的总记录数为 n ,第 i 类样本总数为 n_i ,样本空间维数为 m ,则训练集可表示为:

$$T = \{(x_i, y_i) | x_i \in \mathbf{R}^m, y_i \in \{1, 2, \dots, k\}, i \in \{1, 2, \dots, n\}\}$$

因此,包含 k 种类别、 $|S|$ 个特征($|S|$ 表示表示特征集合 S 中元素个数且 $0 < |S| \leq m$)的特征子集区分度衡量公式 DFS_S ,可采用如下定义:

$$DFS_S = \frac{\sum_{i=1}^k \|\bar{x}^i - \bar{x}\|_2^2}{\sum_{i=1}^k \frac{1}{(n_i - 1)} \sum_{j=1}^{n_i} \|x_j^i - \bar{x}\|_2^2} \quad (1)$$

其中, \bar{x} 表示对所有样本求平均后所得的均值向量, \bar{x}^i 表示对第 i 类样本求平均后所得的均值向量, x_j^i 表示第 i 类别的第 j 个样本的特征向量。上述三类向量均包含 $|S| < m$ 个特征。

分子值越大表示特征子集类间越疏,分母值越小则表示特征子集类内越聚。因此, DFS_S 的值越大,表明特征子集的类间区分度能力越强,类别辨识效果越好,进而对分类结果影响越大。

2.2 互信息

在信息论和概率论中,两个随机变量的互信息^[13-14]用来度量两个变量之间相互依赖的程度。更加具体地说,是通过观察另一随机变量来量化该随机变量获得的“信息量”。其不同于相关系数,且不局限于实值随机变量,决定着联合分布和各自边缘分布乘积的相似程度。利用互信息不仅可有效减少特征冗余性,而且能进一步提升分类准确率,在特征优选方面具有突出贡献^[15]。

互信息表示两个特征的相关程度,即冗余程度。考虑两个随机变量 X 和 Y ,其概率密度和联合概率密度分别为 $p(x)$ 、 $p(y)$ 和 $p(x, y)$ 。则这两个随机变量之间的互信息可定义如下:

$$I(X, Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \frac{p(x, y)}{p(x)p(y)} \quad (2)$$

此外,类内特征最小冗余性的计算公式为 $\min R(S)$, $R(S)$ 可采取如下定义:

$$R(S) = \frac{1}{|S|^2} \sum_{u \in S} \sum_{v \in S} p(u, v) \log \frac{p(u, v)}{p(u)p(v)} \quad (3)$$

其中, u, v 表示特征集合中的任意两个特征; $R(S)$ 表示集合 S 中所有特征之间的互信息值,即特征之间冗余性。

2.3 DFS方法的改进

特征选择的过程可看作是搜索最具代表性的特征子集过程,即:在最大化正确率的基础上,降低计算复杂度。因此,所选择出的特征子集不仅应与分类类别之间的相关性最大,而且须使特征之间的冗余性最小。

基于DFS的特征选择方法考虑了类间相关性,但并未考虑类内特征冗余性。因此,本文对DFS特征选择方法进行改进,提出联合考虑冗余性和特征子集相关度的特征选择方法,即:R-DFS特征选择方法。R-DFS方法联合考虑特征之间相关性和冗余性,则最大相关和最小冗余的联合函数可定义如下:

$$f(DFS_S, R'(S)) = DFS_S - R'(S) \quad (4)$$

其中, $R'(S)$ 的计算公式如下:

$$R'(S) = \frac{\sum_{i=1}^k \sum_{\alpha_1, \alpha_2 \in S} \sum_{j=1}^{n_i} p([x_j^i]_{\alpha_1}, [x_j^i]_{\alpha_2}) \log \frac{p([x_j^i]_{\alpha_1}, [x_j^i]_{\alpha_2})}{p([x_j^i]_{\alpha_1})p([x_j^i]_{\alpha_2})}}{|S|^2 * k} \quad (5)$$

其中, k 表示类别数目; $[x_j^i]_{\alpha_1}, [x_j^i]_{\alpha_2}$ 分别表示在第 i 个类别下特征 α_1 和 α_2 在第 j 个样本中的真实值;而 DFS_S 表示含有 $|S|$ 个特征的特征子集所对应的 DFS 值大小。

R-DFS特征选择方法的执行如表1所列:首先,从空集开始,加入类间区分能力最强的特征;其次,依次迭代加入与已选特征组合后最具类间区分能力的特征;然后,依据加入新特征后的特征子集所对应的随机森林(Random Forest, RF)分类器的正确率,判定新加入特征是否保留:若准确率上升,则保留新加入特征;反之,将其删除。该过程迭代执行,直至所有特征均被测试。

算法 1 R-DFS 特征选择方法

1. 基于式(1), 挑选出 DFS 值最大的特征, 将其加入到初始为空的最优特征子集 X 。
2. 选择分类器, 用测试集进行数据测试, 记下分类正确率, 记为 \max 。
3. for $l=1, 2, \dots, m$ do
4. Repeat
5. 根据式(1)和式(5), 在所有特征中挑选出一个从未参与评价的特征 m' , 执行 $X=X \cup \{m'\}$ 。
6. 用 X 训练分类器, 获得分类模型; 用测试集数据测试分类模型, 记下分类正确率 temp 。
7. if ($\max < \text{temp}$)
8. $\max = \text{temp}$
9. else
10. $X = X \setminus \{m'\}$
11. end if
12. until m 个特征均参与计算
13. end for

3 实验结果及分析

本文实验采用 UCI HAR Dataset^[16]数据集。实验者通过让 30 名不同年龄、身高和体重的试验者在腰部携带智能手机, 然后以恒定的速率(50 Hz)采集到 6 种人体行为动作加速度传感器数据, 分别为: 步行、上楼梯、下楼梯、坐下、站立以及躺下。

使用滑动窗口技术(窗口大小为 110, 覆盖率为 50%)^[16]对去噪后的数据集进行特征提取, 所提取到的特征共 15 种, 分别为: 均值、方差、均方根、平均绝对偏差、四分位间距、轴间相关系数、峰度、偏度、能量、最大值、最小值、绝对中位差、信号幅度域、峰峰值以及中位数。其特征编号分别为 1 到 15。

为得到可靠稳定的分类模型, 采用十折交叉验证实验^[17]。为得到均匀的实验数据, 首先将样本顺序随机打乱, 把每一类样本依次逐个加入到 10 个初始为空的样本集合中, 直至这一类的每一个样本均被加入, 实现将样本随机均匀划分为 10 份的目的。然后, 使用其中 1 份样本作为测试样本集, 其余 9 份作为训练样本集, 依次轮询, 最终实现十折交叉验证。

3.1 数据预处理

智能手机加速度传感器由于自身硬件存在的噪声和外界环境的影响, 导致采集到的原始数据偏离真实值。本文采用平滑去噪的滑动平均滤波方法, 其计算公式如下所示:

$$Result[i] = \frac{1}{n} \sum_{j=0}^{n-1} Original[i+j] \quad (6)$$

其中, $Original$ 表示加速度传感器采集到的原始数据, $Result$ 表示计算结果, i 表示第 i 时刻, n 表示进行平滑处理的窗口长度。

3.2 实验结果分析

为验证 R-DFS 算法的有效性, 本文采用召回率 R (Recall)、准确率 P (Precision) 和 $F1 = \frac{2PR}{P+R}$ 这三种度量标准。

首先, 依次采用 K 近邻(K-Nearest Neighbors, KNN)、支持向量机(Support Vector Machine, SVM)、决策树(Decision Tree, DT)、朴素贝叶斯(Naive Bayes, NB)和 RF 等 5 种分类器分别对其进行十折交叉验证。其次, 在最优特征子集下混淆矩阵中对此 5 种分类器进行比较, 实验结果如图 1—图 6 所示。

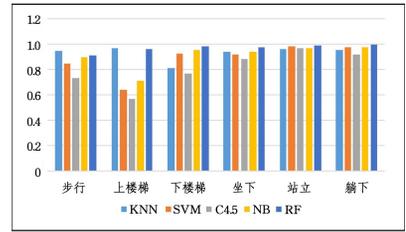


图 1 基于 DFS 的 5 种算法的召回率对比
Fig. 1 DFS-based recall rate of five algorithms

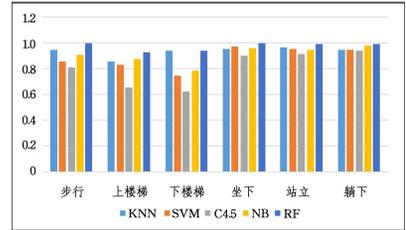


图 2 基于 DFS 的 5 种算法的准确率对比
Fig. 2 DFS-based accuracy of five algorithms

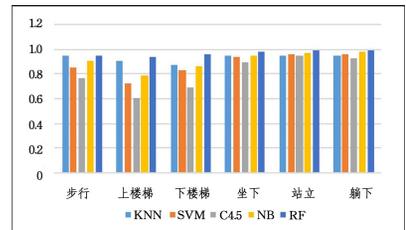


图 3 基于 DFS 的 5 种算法的 F1 值对比
Fig. 3 DFS-based F1 score of five algorithms

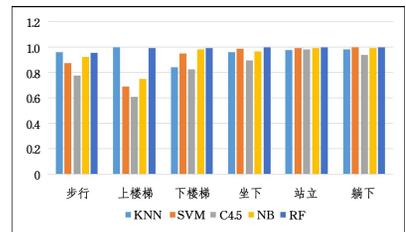


图 4 基于 R-DFS 的 5 种算法的召回率对比
Fig. 4 R-DFS-based recall rate of five algorithms

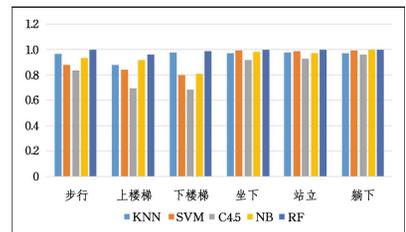


图 5 基于 R-DFS 的 5 种算法的准确率对比
Fig. 5 R-DFS-based accuracy of five algorithms

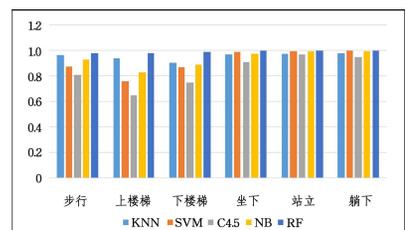


图 6 基于 R-DFS 的 5 种算法的 F1 值对比
Fig. 6 R-DFS-based F1 score of five algorithms

由图1—图6的对比结果可知,R-DFS特征选择方法在精确率、召回率和F1分数3个评价指标下均普遍优于原方法,即DFS方法。此外,RF算法在5种分类器中的效果最优。

表2显示了在DFS特征子集优选准则下,RF分类器在最优特征子集{1,2,3,9,15}下的混淆矩阵。表3显示了在R-DFS特征子集优选准则下,RF分类器在最优特征子集{3,4,9,15}下的混淆矩阵。

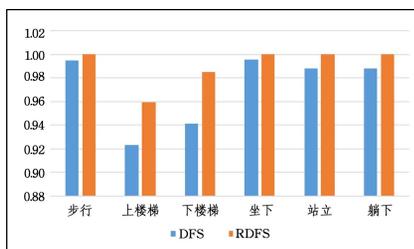
表2 基于DFS的RF混淆矩阵
Table 2 DFS-based RF confusion matrix

分类动作	步行	上楼梯	下楼梯	坐下	站立	躺下
步行	201	13	6	0	0	0
上楼梯	1	205	6	0	0	1
下楼梯	0	3	193	0	0	0
坐下	0	0	0	219	3	2
站立	0	1	0	1	246	0
躺下	0	0	0	0	0	256

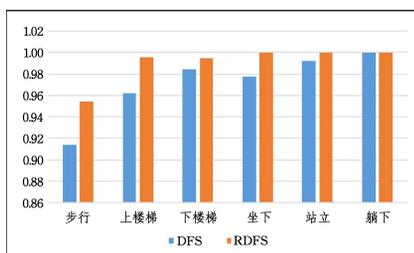
表3 基于R-DFS的RF混淆矩阵
Table 3 R-DFS-based RF confusion matrix

分类动作	步行	上楼梯	下楼梯	坐下	站立	躺下
步行	210	8	2	0	0	0
上楼梯	0	211	1	0	0	0
下楼梯	0	1	195	0	0	0
坐下	0	0	0	224	0	0
站立	0	0	0	0	248	0
躺下	0	0	0	0	0	256

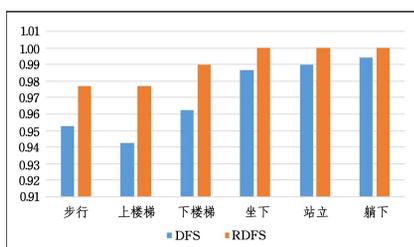
为进一步比较R-DFS和DFS在RF分类器中的性能,我们分别揭示其召回率、精确率和F1值等3种性能指标,如图7所示。



(a) 准确率



(b) 召回率



(c) F1 分数

图7 基于DFS和基于R-DFS的RF分类模型

Fig. 7 DFS-based and R-DFS-based RF classification model

由图7的对比结果可知,相较于DFS特征选择方法,

R-DFS在精确率上有1.9%的平均性能提升,在召回率上有1.8%的平均性能提升,而在F1分数上则平均提升了1.9%。特定地,在步行状态下,3种指标均有近4%的性能改善。

结束语 特征优选是关联特征与数据的纽带,能够在去除无关特征的基础上选取相关度高的特征,从而将高维数据特征降低为较低维数据特征。本文提出了一种基于冗余性的特征子集区分度方法。该方法从提取特征冗余性出发,基于特征之间的互信息对冗余特征进行删除,进而降低特征维数,减少后续计算量和机器运行时间。本文使用UCI HAR Dataset数据集进行实验分析,结果表明:相较于DFS方法,提出的方法在删除冗余性方面可进一步提升分类性能;此外,在5类分类器中,RF分类器正确率最高。未来工作中,我们将进一步探索基于信息论的数据特征冗余性降低算法,并采取CNN等神经网络分类器,以取得更好分类效果。

参考文献

- [1] CHEN P, TU Y, TONG J, et al. Design of Wearable Fall Detection Intelligent System [J]. *Sensors and Microsystems*, 2017, 36(2): 114-116.
- [2] MUHAMMAD S, STEPHAN B, OZLEM D I, et al. A Survey of Online Activity Recognition Using Mobile Phones [J]. *Sensors*, 2015, 15(1): 2059-2085.
- [3] GOMES D, MENDES-MOREIRA J, SOUSA I, et al. Eating and Drinking Recognition in Free-Living Conditions for Triggering Smart Reminders [J]. *Sensors*, 2019, 19(12): 2803.
- [4] YUAN J G. Design and Implementation of Educational VR Games Based on UE4 [C] // Southwest Petroleum University. Southwest Petroleum University, 2019: 249-254.
- [5] CERO D E, BARAKOVI H J, BARAKOVI S. Step by Step Towards Effective Human Activity Recognition: A Balance between Energy Consumption and Latency in Health and Wellbeing Applications [J]. *Sensors*, 2019, 19(23): 5206.
- [6] ZHENG Z W, DU J J, HUO M M, et al. Review of Research on Human Activity Recognition Based on Wearable Sensors [J]. *Computer Applications*, 2018, 38(5): 1223-1229.
- [7] SHARMILA A, GEETHANJALI P. Evaluation of Time Domain Features Using Best Feature Subsets Based on Mutual Information For Detecting Epilepsy [J]. *Journal of Medical Engineering & Technology*, 2018, 42(7): 487-500.
- [8] AHMAD J, MUHAMMAD K, BAIK S W. Medical Image Retrieval with Compact Binary Codes Generated in Frequency Domain Using Highly Reactive Convolutional Features [J]. *Journal of Medical Systems*, 2017, 42(2): 3-24.
- [9] WU Q S, LIU C Y, LIN L H. Hybrid Feature Selection Algorithm Fusion Sequence Backward Selection and Support Vector Machine [J]. *Computer System Applications*, 2019, 28(7): 174-179.
- [10] HUI H H, CHENG W H, MING D L. Hybrid Feature Selection by Combining Filters and Wrappers [J]. *Expert Systems with Applications*, 2011, 38(7): 8144-8150.
- [11] XIE J Y, XIE W X. Feature Selection Algorithm Based on Feature Subset Discrimination and Support Vector Machine [J]. *Chinese Journal of Computers*, 2014, 37(8): 1704-1718.
- [12] DAVIDE A, ALESSANDRO G, LUCA O, et al. A Public Do-

main 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.

- [13] HYUNKI L, DAE-W K. MFC: Initialization method for multi-label feature selection based on conditional mutual information [J]. *Neurocomputing*, 2019, 22(6): 1-12.
- [14] PENG X B, ZHU Y Q. Weighted SVM Algorithm Based on Intra-feature Correlation and Mutual Information [J]. *Computer Science*, 2018, 45(12): 182-186.
- [15] ZHANG L, WANG C. Multi-label Feature Selection Algorithm Based on Maximum Correlation and Minimum Redundant Joint Mutual Information [J]. *Journal of Communications*, 2018, 39(5): 111-122.
- [16] YANG Y J, LIU S, CHANG D X. A Method for Network Event Correlation Pattern Drift Detection Based on Relation Entropy and J Measure [J]. *Computer Science*, 2016, 43(1): 259-263.

- [17] YANG L, WANG Y. Review of Various Cross-Validation Estimation Methods for Generalized Errors [J]. *Application Research of Computers*, 2015, 32(5): 1287-1290.



WANG Rui-jie, born in 1997, postgraduate, is a member of China Computer Federation. His main research interests include machine learning and action recognition.



LI Jun-huai, born in 1969, Ph.D, professor, Ph. D supervisor, is a member of China Computer Federation. His main research interests include network computing, internet of things and cloud computing technology.

(上接第 187 页)

- [10] LIN S F, CHEN J Y, CHAO H X. Estimation of number of people in crowded scenes using perspective transformation [J]. *IEEE Transactions on Systems, Man & Cybernetics Part A (Systems & Humans)*, 2001, 31(6): 645-654.
- [11] VIOLA P, JONES M, SNOW D. Detecting pedestrians using patterns of motion and appearance [J]. *International Journal of Computer Vision*, 2005, 63(2): 153-161.
- [12] CHAN A B, LIANG Z S J, VASCONCELOS N. Privacy preserving crowd monitoring: counting people without people models or tracking [C]// *Proceedings of the 2008 IEEE Conference on Computer Vision and Pattern Recognition*. IEEE Computer Society, 2008; 1-7.
- [13] CHAN A B, VASCONCELOS N. Bayesian poisson regression for crowd counting [C]// *2009 IEEE 12th International Conference on Computer Vision*. IEEE, 2009; 545-551.
- [14] RYAN D, DENMAN S, FOOKES C B, et al. Crowd counting using multiple local features [C]// *2009 Digital Image Computing: Techniques and Applications*. IEEE, 2009; 81-88.
- [15] LEMPITSKY V, ZISSERMAN A. Learning to count objects in images [C]// *In Advances in Neural Information Processing Systems*, 2010; 1324-1332.
- [16] OJALA T, PIETIKAINEN, M, MAENPAA, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2002, 24(7): 971-987.
- [17] PARAGIOS N, RAMESH V. A MRF-based approach for real-time subway monitoring [C]// *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR 2001)*. IEEE, 2001; 1034-1040.
- [18] PHAM V Q, KOZAKAYA T, YAMAGUCHI O, et al. Count Forest: Covoting Uncertain Number of Targets using Random Forest for Crowd Density Estimation [C]// *International Conference on Computer Vision (ICCV 2015)*. IEEE, 2015; 3253-3261.

- [19] ZHANG Y, ZHAN D, CHEN S, et al. Single-image crowd counting via multi-column convolutional neural network [C]// *IEEE Conference on Computer Vision and Pattern Recognition*. IEEE, 2016; 589-597.
- [20] SAM D B, SURYA S, BABU R V. Switching Convolutional Neural Network for Crowd Counting [C]// *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2017; 4031-4039.
- [21] LI Y, ZHANG X, CHEN D. CSRNet: dilated convolutional neural networks for understanding the highly congested scenes [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2018; 1091-1100.
- [22] KANG K, WANG X. Fully convolutional neural networks for crowd segmentation [J]. *Computer Science*, 2014, 49(1): 25-30.
- [23] KINGMA D P, BA J. Adam: A method for stochastic optimization [J]. *arXiv*; 1412. 6980, 2014.
- [24] ZHANG C, LI H, WANG X, et al. Cross-scene crowd counting via deep convolutional neural networks [C]// *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2015; 833-841.
- [25] CAO X, WANG Z, ZHAO Y, et al. Scale aggregation network for accurate and efficient crowd counting [C]// *Proceedings of the European Conference on Computer Vision (ECCV)*. 2018; 734-750.



CHEN Xun-min, born in 1995, postgraduate. His main research interests include deep learning and image communication.