

DOI: 10.13382/j.jemi.B2104873

利用加速度信号时频域特征的枪击识别研究*

伍弘毅 陈志聪 吴丽君 何虔恩
(福州大学物理与信息工程学院 福州 350116)

摘要:当前枪支射弹可靠检测及精确计数是枪弹管控的难点之一。为提高基于加速度信号的射弹检测算法的精度和可靠性,提出一种新的射击信号时域特征提取方法——时域分段特征提取法,可避免时域特征过度依赖于加速度瞬时尖峰的问题。首先,提取了枪击加速度样本信号的时域和频域各类统计特征。然后,采用机器学习分类算法 K 近邻、逻辑回归、支持向量机以及决策树和随机森林进行枪击识别建模。最后,探索和比较各种单一特征对枪击事件识别模型性能的影响。实验结果表明,所提取的主波动域面积特征具有最优的区分度,能够在多数机器学习算法上达到 99% 以上的分类准确率。

关键词: 射击检测; 加速度传感器; 机器学习; 特征提取

中图分类号: TP391.4; E920.2 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Research on recognition of gun shooting using acceleration signal's features in both time and frequency domain

Wu Hongyi Chen Zhicong Wu Lijun He Qian'en
(College of Physics and Information Engineering, Fuzhou University, Fuzhou 350116, China)

Abstract: Currently, reliable detection and accurate counting of firearm projectiles is one of the difficult points of gun and ammunition management. To improve the accuracy and reliability of projectile detection algorithm based on acceleration signals, we propose a new time-domain feature extraction method for firearm firing signals: The time-domain segmental feature extraction method, which avoids the problem that time-domain features are overly dependent on acceleration transient spikes. Firstly, various statistical features of the sample signals of gunshot acceleration in the time and frequency domains have been extracted. Then machine learning classification algorithms K-nearest neighbors, logistic regression, support vector machines, decision trees and random forests are used for gunshot recognition modeling. Finally, the effects of various single features on the performance of gunshot recognition models are explored and compared. The experimental results show that the extracted main fluctuation domain area feature have the optimal discrimination and can achieve more than 99% classification accuracy on most machine learning algorithms.

Keywords: gun shooting detection; acceleration sensor; machine learning; feature extraction

0 引 言

当前,枪支滥用及缺乏有效的弹药使用实时监控手段给全球多个国家带来了枪支暴力的严峻挑战^[1]。为此,各国研究人员设计了多种枪弹射击检测技术来对枪支使用及耗弹量进行实时监控。按传感器工作原理不同,可采用的主要分如下几种:压电式压力传感器类型^[2]、红外传感器类型^[3-4]、磁传感器类型^[5-6]、紫外传感

器类型^[7]、声传感器类型^[8-11]、以及加速度传感器类型^[12-15]等。

在上述射击检测技术中,加速度传感器方案因易于微型化、可穿戴化而常用于人类活动识别等场景^[16-17],加上其不易破解和较好的可追溯性,用于射击检测技术具有较好实际应用前景和研究价值。Kasarda 等^[14]和 Wang 等^[18]两个团队通过检测射击时传导到地面上的震动给部署于地面上的加速度计带来数值变化来对射击活动进行识别和研究,存在部署成本高,适用

场景少的缺陷。Khan 等^[12]和 Loeffler^[13]则利用腕戴加速度计来收集射击时的动作信号。在数据集的特征提取阶段,Khan 提取了信号样本的均值、标准差、幅值面积、能量这些时域特征以及频域的能量值;Loeffler 则针对手枪加速度信号时域波形划分为尖峰前、尖峰、尖峰后 3 个时间窗口,并依据尖峰的定位来做特征的提取。在射击活动的识别上,前者试验了各类型枪支射击活动识别的精度;后者采用逻辑回归分类算法和多种时域特征组合设计出准确度达到 98.9% 的手枪射击事件分类器。

相比于目前比较热门的利用声传感器记录枪声来监测识别射击信号或枪支类型的研究^[11,19-20],使用腕戴加速度计来检测枪支射击等活动部署更为便捷灵活,其不仅可以用于监控射击者的射击活动,也可以在合理的情况下经过简单修改集成于枪支上,从而监测武器使用情况。目前的研究虽然在射击场景下实现了较高的枪击识别精度^[12-13],但都是针对特定算法结合多种特征下进行实验得到的,并未就单一特征下射击活动识别模型的最大识别精度进行考察,在特征提取及射击活动识别算法模型上还有待更广泛和深入地进行对比研究,而这将给加速度计用于枪支射击检测及监控的设备系统开发中尽量做到低能耗、高精度、高可靠性和高效率带来较大的意义。

针对现有相关研究主要关注采集信号时域特征且多使用动作信号样本整体统计量的不足,提出一种新的枪支射击信号时域分段特征提取方法,着重对射击信号中间波动区域来进行特征提取,避免过度依赖于单轴瞬时尖峰的识别,以扩展适用场景。同时,提取加速度计信号的各种时频域特征,并使用机器学习分类算法 K 近邻、逻辑回归、支持向量机以及决策树和随机森林对获取的每种特征分别进行训练和参数调优实验,以对比各项特征对枪击事件识别性能的影响,从而获取对射击检测精度提升较大的特征及算法组合。

1 数据集介绍与预处理

本项目所采用的含枪支射击动作信号在内的加速度计采集数据集由 Loeffler 提供于 Harvard Dataverse (<https://doi.org/10.7910/DVN/25918>),该数据集是由受试者群体佩戴采样率 $f_s = 3.2$ kHz (每毫秒可采样 3 次),量程为 ± 16 G 的腕戴三轴加速度计分别从事目标射击、建筑施工及日常生活活动时采集的,既包含了 6 种不同型号手枪(型号代号为 1~6)的射击动作信号,也含有其他非射击动作信号。从该数据集中根据相应材料提取出 359 个射击信号的发生时刻和从事射击及非射击活动信号的原始数据,对该数据集进行预处理,其处理步骤如

下:1)针对采集的射击及非射击活动信号三轴加速度原始数据,分别对各轴进行差分处理,对差分处理后的信号各轴都设定阈值 $Th = 1.5$ G,同时根据研究^[11]可知手枪射击时在加速度计中检测到的显著动作波形持续时间约为 50 ms,结合采样率,对加速度时间序列数据采用阈值 Th 进行滑动窗口定位,并在定位点前截取 24 个采样点数据,在定位点后截取 144 个采样点数据,总共 169 个采样点数据构成初步筛选出的动作数据帧信号,即每段信号时间长度 T 约为 52.5 ms,窗口滑动步长设为 60。2)根据 359 个射击信号发生时刻的信息说明,对射击活动信号原始数据中筛出的数据帧信号中的真实射击动作信号进行提取作为射击信号样本,同时将其其他非射击活动信号原始数据中筛出的动作数据帧信号以及射击活动信号原始数据中除真实射击动作外的数据帧信号作为非射击信号样本(处理后总共获得样本数 981 个)。3)由于全部样本中射击信号样本与非射击信号样本数量相差较大,而数据样本不均衡会给之后的分类模型训练过程带来过拟合或欠拟合风险,从而影响模型的准确度,且考虑到手枪射击时的加速度信号不易模仿的特点,此处直接采用随机过采样方法先对偏少类别的射击信号样本进行处理以实现样本均衡,最终生成包含 1 962 个加速度信号样本的数据集,其中非射击信号和射击信号样本数各占 1/2。

对数据集进行上述预处理的实验环境为 MATLAB R2018b。

2 特征提取

2.1 加速度信号的时域特征提取

加速度传感器采集的枪支射击数据帧信号通常在时域波形上表现出较为明显的特点,如图 1 所示,由于子弹击发瞬间弹药燃烧产生的爆炸波会在传感器 X 轴(后坐力方向)上产生一个持续时间极短但幅值较大的瞬时尖峰,同时也会在另外两轴上检出相应的动作波形,一般情况下要完整记录枪支射击时的加速度信号变化细节,需要加速度计的最大采样率大于该爆炸波导致的加速度尖峰脉冲频率,但如果为了信号的完整性而追求过高的采样率,通常会给信号采集设备带来更高的功耗和更大的数据处理量,因此特征提取如果仅针对该尖峰特点来处理识别射击动作信号在某些场景下并不合理。图 2 展示了来自图 1(a)的一次典型手枪型号为 1 型的射击信号波形细节,观察 Y 、 Z 两轴和 X 轴位于尖峰后的信号,可以发现中间区域加速度有波动持续时间相对较长且幅值波动较大的特点,之后因子弹射出,信号的振动也趋于平稳,因此,可以根据这一特点来提取手枪射击时的较显著特征。

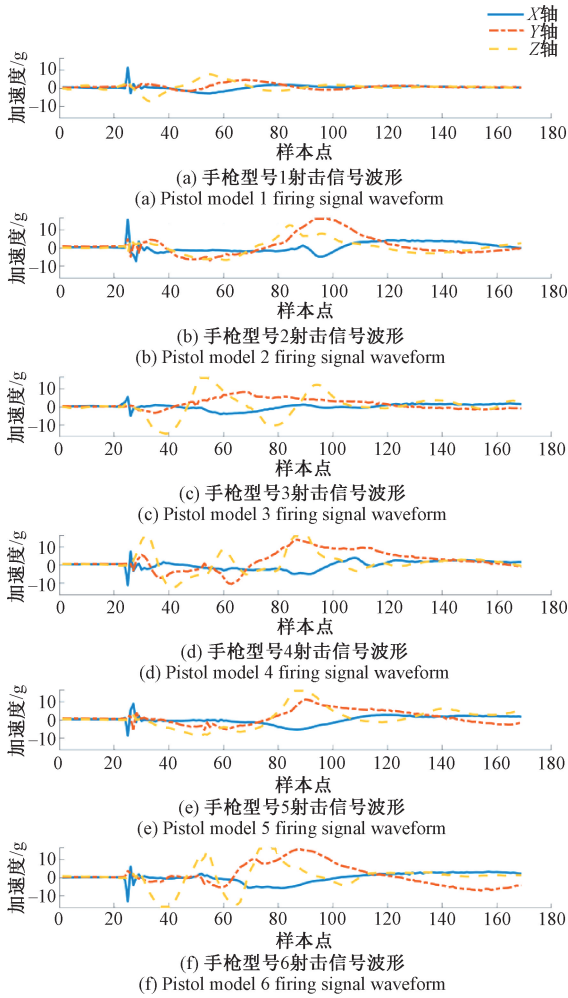


图1 三轴加速度计采集的6种不同手枪类型射击信号

Fig. 1 6 different pistol types shooting signals collected by three-axis accelerometer

针对手枪射击时的各轴加速度信号能量区域集中于X轴尖峰出现后的特点,设计时域分段特征提取方法。首先,由于射击事件检测中最重要的检测射击时导致的加速度的波形变化趋势,因此先进行去均值处理以去除观察数据帧中的直流偏移量,而后采取过零点检测对时间段进行划分,以探测出图2中间区域的持续时间较长、波动较为剧烈的活动区间,最后在该区间中提取具有代表性的特征如最大子片段长度、波形区间面积等,具体的计算步骤如算法1所示,图3展示了对射击信号数据帧的Y轴进行时域分段的效果。

此外,为实验时域各项特征对最终枪击事件检测的效果,也对常用的信号时域统计量如均值、方差、最大及最小幅值、信号幅值面积、总能量特征进行了提取。其中信号幅值面积(SMA)计算公式为:




图2 三轴加速度计采集的手枪射击信号细节
Fig. 2 Detail of pistol shooting signal collected by three-axis accelerometer

算法1:时域分段特征提取算法

步骤1:对动作数据帧样本各轴向量 S_i 先进行去均值处理;

$$S_{M_i} = S_i - \text{mean}(S_i) \quad i = X/Y/Z \quad (1)$$

步骤2:检测去均值后信号 S_{M_i} 的过零点对应横轴采样点坐标 zc_k , 根据数据帧信号的两端点和提取的过零点将其划分为多个子片段 Li_1, Li_2, \dots, Li_n , 其中 $n=k+1, k$ 为信号 S_{M_i} 的过零点个数, 并令 $zc_0 = 0, zc_n = 169$, 并将子片段数记为 fra_Count_i , 最大子片段长度为 ZCL_i ;

$$\text{fra_Count}_i = n \quad (2)$$

$$ZCL_i = \max(zc_j - zc_{j-1}) \times \frac{1}{f_s} \quad j = 1, 2, \dots, n \quad (3)$$

步骤3:近似计算各子片段内的面积绝对值 Area_{im} (m 取1到 n), 并对子片段面积绝对值 Area_{im} 序列按值降序排序;

$$\text{Area}_{im} = \sum_{m=zc_{k-1}}^{zc_k} |L_{im}| \times \frac{1}{f_s} \quad (4)$$

$$\text{sorted_Area}_{ip} = \text{sort}(\text{Area}_{im}, 'descend') \quad (5)$$

步骤4:对降序后得到的 sorted_Area_{ip} 序列, 令 main_Area_i 为其前3个值之和, 如果 sorted_Area_{ip} 序列中值个数小于3, 则缺失值以0填充;

$$\begin{aligned} \text{main_Area}_i &= \text{sorted_Area}_{ip}(1) + \\ &\text{sorted_Area}_{ip}(2) + \text{sorted_Area}_{ip}(3) \end{aligned} \quad (6)$$

步骤5:提取样本各轴的子片段数 fra_Count_i 、最大子片段长度 ZCL_i 及子片段面积绝对值 Area_{im} 降序数组前3个值之和 main_Area_i (主波动域面积) 作为时域分段提取特征。

$$\begin{aligned} \text{SMA} &= \frac{1}{T} \times \left(\sum_{j=1}^{169} |X_j| \times \frac{1}{f_s} + \sum_{j=1}^{169} |Y_j| \times \right. \\ &\left. \frac{1}{f_s} + \sum_{j=1}^{169} |Z_j| \times \frac{1}{f_s} \right) \end{aligned} \quad (7)$$

总能量特征(T_{energy}) 计算公式为:

$$T_{\text{energy}} = \sum_{j=1}^{169} (X_j^2 + Y_j^2 + Z_j^2) \quad (8)$$

2.2 加速度信号的频域特征提取

加速度信号频域特征的提取往往伴随着计算量大、




图3 对三轴加速度计采集的Y轴信号进行去均值及时域分段

Fig. 3 Subtracting the mean and framing in the time domain of the Y-axis signal collected by the three-axis accelerometer

在底层硬件上部署难度较高的特点,但其对信号的组成频率分量特性反映更为直观简洁,因此,对采集的加速度信号样本进行了频域的特征提取。提取的频域特征主要有对样本片段先进行FFT处理,为处理方便,变换点数取各轴信号片段截取掉最后一个数值的长度默认值168,获取信号的单边频谱如图4所示,然后提取该信号频域的幅度均值,此外还提取了FFT频谱图中最大幅值对应频率分量值,由于信号样本该特征在3个轴上体现的取值不同,选取了3个轴中各轴取得最大幅值对应频率分量的最大值作为该信号的集中频率特性,该特征体现了信号中占主要地位的频率成分。




图4 手枪射击时加速度计采集信号的FFT单边幅度谱

Fig. 4 FFT single-sided amplitude spectrum of the signal collected by the accelerometer when the pistol was shooting

为更全面地获取频域内特征用以进行不同特征对枪支射击事件分类精度的影响,还在样本信号的功率谱密度下进行了特征提取,提取的特征有功率谱密度均值、功

率谱密度重心、功率谱密度方差和偏度。

在提取特征时,由于加速度计采集的时域信号有三轴,因此部分时域、频域特征的提取也分别在3个轴上进行,如图5所示,特征提取阶段获得的时域和频域全部特征及特征的维度大小如表1所示。为避免提取出来的特征因其量纲不同或取值范围差异给后续分类模型训练带来较大影响,同时考虑到实际采集的数据样本可能会产生某些特征异常值,使用线性归一化不能很好地对其进行处理,因此对所有提取出来的特征均采用均值方差归一化进行预处理,针对第*j*个特征列*X^j*进行均值方差归一化的计算公式如下:

$$X^j_{scale} = \frac{X^j - X^j_{mean}}{S^j}$$

(9)

其中,*S^j*为特征列*X^j*的方差,*X^j_{mean}*为特征列*X^j*的均值,*X^j_{scale}*为进行均值方差归一化后的特征列,该方法可将数据归一化到均值为0且方差为1的分布中,不易受到异常值影响。




图5 手枪射击时加速度计采集信号的功率谱密度

Fig. 5 Power spectral density of the signal collected by the accelerometer when the pistol was shooting

表1 样本中提取的时域和频域全部特征			
Table 1 All features in both time and frequency domain extracted from the samples			
时域特征	特征维度 (行×列)	频域特征	特征维度 (行×列)
时域分段子片段数 <i>fra_Count</i>	1 926×3	FFT 幅度谱均值	1 926×3
最大子片段长度 <i>ZCL</i>	1 926×3	FFT 幅度谱最大幅值 对应频率分量值	1 926×3
主波动域面积 <i>main_Area</i>	1 926×3	集中频率	1 926×1
均值	1 926×3	功率谱密度均值	1 926×3
方差	1 926×3	功率谱密度重心	1 926×3
最大幅值	1 926×3	功率谱密度方差	1 926×3
最小幅值	1 926×3	功率谱密度偏度	1 926×3
信号幅值面积	1 926×1		
总能量	1 926×1		

3 枪支射击识别算法效果对比

3.1 性能指标

利用上述特征提取阶段收集的特征来对枪击事件信号进行二分类预测(分类标签 0:非枪击,1:枪击),用来评判识别算法分类效果的性能指标有 4 种,分别是准确率(accuracy),精准率(precision),召回率(recall)以及综合评价指标(F1-Score),上述指标的计算公式分别如下所示:

Accuracy = (TP + TN) / (TP + FN + FP + TN) (10)

Precision = TP / (TP + FP) (11)

Recall = TP / (TP + FN) (12)

F1 - Score = (2 * Precision * Recall) / (Precision + Recall) (13)

其中,TP、FP、FN、TN 是训练好的算法模型在测试集上的预测结果组成的混淆矩阵中对应的真正率、假正率、假负率和真负率。指标中,Accuracy 反映了枪击和非枪击两种信号在全部样本中的检测成功率,Precision 反映了正确分类为枪击的信号占有所有被算法模型识别为枪

击信号的比例,即枪击信号的查准率,而 Recall 表明正确分类为枪击的信号占实际枪击信号的比例,即枪击信号的查全率,F1-Score 为基于 Recall 与 Precision 的调和平均,即将召回率和精确率综合起来进行评价。

3.2 算法模型训练结果

本研究采用 scikit-learn 0.24.1 版本中的机器学习分类算法 K 近邻(KNN)、逻辑回归(LR)、支持向量机(SVM)、决策树(DT)和随机森林(RF)对提取的每种特征分别进行训练,训练时,测试集与训练集样本数按 1:3 比例进行划分,为比较不同特征下所能达到的最佳效果,采用网格搜索来寻找最优参数,KNN 下实验的超参数有权重 weights、距离度量 p 及邻居数 n_neighbors;逻辑回归下实验的超参数有惩罚项 penalty、控制正则化程度的系数 C 以及优化算法选择参数 solver;支持向量机下实验的超参数有目标函数的惩罚系数 C、核函数 kernel 及核函数为径向基核函数时的 gamma 值,决策树下实验的超参数有特征选择标准 criterion、节点划分最小不纯度 min_impurity_decrease、决策树最大深度 max_depth 以及内部节点再划分所需最小样本数 min_samples_split,随机森林下实验的超参数有基评估器数量 n_estimators 及基评估器参数 max_depth、min_samples_split,未提及的实验参数都采用默认值,实验在测试集上得到的结果如表 2 和 3 所示。

表 2 5 种机器学习分类算法的性能指标(时域特征)

特征\分类器性能		KNN/LR/SVM/DT/RF			
		Accuracy	Precision	Recall	F1-score
1	均值	0.967/0.890/0.974/0.959/0.959	0.944/0.929/0.955/0.946/0.946	0.992/0.834/0.992/0.970/0.970	0.967/0.879/0.973/0.958/0.958
2	方差	0.955/0.866/0.947/0.935/0.945	0.928/0.921/0.927/0.915/0.920	0.983/0.788/0.966/0.953/0.970	0.955/0.849/0.946/0.934/0.944
3	最大值	0.935/0.831/0.955/0.921/0.937	0.892/0.840/0.961/0.877/0.905	0.983/0.801/0.945/0.970/0.970	0.935/0.820/0.953/0.922/0.937
4	最小值	0.927/0.845/0.943/0.923/0.921	0.888/0.839/0.960/0.881/0.877	0.970/0.839/0.919/0.970/0.970	0.927/0.839/0.939/0.923/0.922
5	信号幅值面积	0.908/0.857/0.855/0.906/0.904	0.869/0.884/0.824/0.865/0.862	0.953/0.809/0.890/0.953/0.953	0.909/0.845/0.855/0.907/0.905
6	总能量	0.904/0.849/0.843/0.904/0.902	0.851/0.875/0.853/0.851/0.848	0.970/0.801/0.813/0.970/0.970	0.907/0.836/0.833/0.907/0.905
7	时域分段子片段数 fra_Count	0.882/0.809/0.919/0.910/0.923	0.840/0.763/0.892/0.884/0.893	0.932/0.873/0.945/0.936/0.953	0.884/0.814/0.917/0.909/0.922
8	最大子片段长度 ZCL	0.908/0.754/0.959/0.916/0.902	0.860/0.712/0.974/0.874/0.846	0.966/0.818/0.941/0.966/0.975	0.910/0.761/0.957/0.918/0.906
9	主波动域面积 main_Area	0.994/0.978/0.996/0.992/0.996	0.987/0.963/0.992/0.992/0.992	1.000/0.992/1.000/0.992/1.000	0.994/0.977/0.996/0.992/0.996

表 3 5 种机器学习分类算法的性能指标(频域特征)

特征\分类器性能		KNN/LR/SVM/DT/RF			
		Accuracy	Precision	Recall	F1-score
10	FFT 幅度谱均值	0.925/0.839/0.935/0.933/0.937	0.896/0.852/0.915/0.904/0.905	0.953/0.805/0.953/0.962/0.970	0.924/0.828/0.934/0.932/0.937
11	FFT 幅度谱最大幅值对应频率分量值	0.923/0.688/0.937/0.931/0.947	0.920/0.732/0.915/0.907/0.923	0.920/0.555/0.958/0.953/0.970	0.920/0.631/0.936/0.930/0.946
12	集中频率	0.635/0.481/0.721/0.721/0.721	0.603/0.481/0.634/0.634/0.634	0.708/1.000/0.992/0.992/0.992	0.651/0.649/0.774/0.774/0.774
13	FFT 频谱幅度最大值	0.957/0.890/0.965/0.953/0.957	0.924/0.929/0.933/0.918/0.918	0.991/0.835/1.000/0.992/1.000	0.957/0.879/0.965/0.953/0.957
14	功率谱密度均值	0.957/0.872/0.949/0.955/0.953	0.932/0.918/0.917/0.939/0.924	0.983/0.805/0.983/0.970/0.983	0.957/0.858/0.949/0.954/0.953
15	功率谱密度重心	0.947/0.833/0.965/0.945/0.976	0.901/0.750/0.940/0.903/0.952	1.000/0.979/0.992/0.992/1.000	0.948/0.849/0.965/0.945/0.975
16	功率谱密度方差	0.955/0.843/0.923/0.957/0.955	0.946/0.934/0.896/0.942/0.938	0.962/0.725/0.949/0.970/0.970	0.954/0.816/0.922/0.956/0.954
17	功率谱密度偏度	0.939/0.745/0.949/0.933/0.945	0.899/0.703/0.945/0.904/0.897	0.983/0.814/0.949/0.962/1.000	0.939/0.754/0.947/0.932/0.946

在上述实验获得的性能指标基础上,各分类算法在不同特征下的性能指标对比如图6~9所示。




图6 各算法在不同特征下的准确率对比

Fig. 6 Comparison of the accuracy of each algorithm under different features




图7 各算法在不同特征下的精准率对比

Fig. 7 Comparison of the precision of each algorithm under different features




图8 各算法在不同特征下的召回率对比

Fig. 8 Comparison of the recall of each algorithm under different features




图9 各算法在不同特征下的综合评价指标对比

Fig. 9 Comparison of the F1-Score of each algorithm under different features

4 结论

本文针对枪击事件加速度信号时、频域特征进行了分析和提取,并采用K近邻、逻辑回归、支持向量机以及决策树和随机森林5种分类算法对提取出来的每种特征分别进行参数调优以获得射击事件的最佳检测效果。根据图6和9考虑综合分类效果,可知在各特征下逻辑回归分类效果表现最差,SVM、KNN、DT和RF在多数时频域特征下表现出接近90%甚至以上的分类准确率,在除5和6号时域特征的情况下,SVM在其他时域下的分类效果普遍更为优异,RF作为DT的集成形式,在除8号特征外的多数时频域特征下较DT有小幅度的提升。另外,从单个特征方面考虑,时域特征方面为避免过度依赖于X轴瞬时尖峰的识别而提取出的3种时域分段特征中(表2中第7~9号),9号主被动域面积main_Area特征对枪击事件的检测效果在KNN、SVM、DT和RF分类算法上均取得了99%以上的分类准确率,且相比于其他时域统计量特征,更不易受到X轴时域瞬时尖峰的影响,当加速度传感器采样率较低,不能较好地捕捉X轴瞬时尖峰时,该特征将有较好的适用性;频域特征方面,12号集中频率特征虽然分类准确率不高,但其召回率在LR、SVM、DT、RF上的效果都能达到99%以上;提取的除集中频率外的频域特征虽然相较于时域特征计算量更高,但在召回率和F1-Score指标上,在DT、RF分类算法下要优于除时域均值和main_Area外的时域特征,由于枪击事件的特殊性,某些场景下漏检测的后果较为严重,此时高召回率意味着枪击事件的漏检可能性较低,因此在实际应用中可以采用集中频率或其他频域特征来降低枪击事件的漏检率。

参考文献

- [1] FELSON R B, BERG M T, ROGERS M L. Bring a gun to a gunfight: Armed adversaries and violence across nations[J]. Social Science Research, 2014, 47: 79-90.
- [2] 吴一川,孟欢欢,黄启洋,等. 面向触觉力反馈的可穿戴柔性执行器研究现状[J]. 仪器仪表学报, 2021, 42(9): 244-252.
WU Y CH, MENG H H, HUANG Q Y, et al. Research status of wearable and flexible actuators for haptic force feedback[J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 244-252.
- [3] 路长顺,刘栋. 红外枪弹射击计数器: CN202793169U[P]. 2013-03-13.
LU CH SH, LIU D. Infrared gunshot counter: CN202793169U[P]. 2013-03-13.
- [4] 李意,雷志勇,李青松. 红外探测技术的应用与发展[J].

- 国外电子测量技术, 2018, 37(2): 80-83.
- LI Y, LEI ZH Y, LI Q S. Application and development of the infrared detection technology [J]. Foreign Electronic Measurement Technology, 2018, 37(2): 80-83.
- [5] 于鑫, 黄文胜, 董自卫. 基于霍尔阵列某型枪弹计数器设计[J]. 传感器世界(自然科学版), 2013, 19(3): 36-38, 15.
- YU X, HUANG W SH, DONG Z W. A certain type of bullet counter design based on hall array [J]. Sensor World (Natural Science Edition), 2013, 19(3): 36-38, 15.
- [6] 裴东兴, 王文武, 崔春生. 利用转速测试弹丸炮口速度的方法研究[J]. 兵工学报, 2013, 34(1): 125-128.
- PEI D X, WANG W W, CUI CH SH. Study on projectile muzzle velocity measurement based on rotational speed [J]. Acta Armamentarii, 2013, 34(1): 125-128.
- [7] 马利祥, 李争. 紫外探测式的子弹统计系统设计[J]. 光电工程(自然科学版), 2012, 39(12): 37-41.
- MA L X, LI ZH. Design of bullet counting system based on UV detection [J]. Opto-Electronic Engineering (Natural Science Edition), 2012, 39(12): 37-41.
- [8] MOREHEAD A, OGDEN L, MAGEE G, et al. Low cost gunshot detection using deep learning on the raspberry pi[C]. 2019 IEEE International Conference on Big Data (Big Data), 2019: 3038-3044.
- [9] BAJZIK J, PRINOSIL J, KONIAR D. Gunshot detection using convolutional neural networks [C]. 2020 24th International Conference Electronics, 2020: 1-5.
- [10] SHIEKH A A, TAHIR M, UPPAL M. Accurate gunshot detection in urban environments using blind deconvolution[C]. 2017 International Multi-topic Conference (INMIC), 2017: 1-4.
- [11] RAHMAN S U, KHAN A, ABBAS S, et al. Hybrid system for automatic detection of gunshots in indoor environment [J]. Multimedia Tools and Applications, 2021, 80(3): 4143-4153.
- [12] KHAN M A A H, WELSH D, ROY N. Firearm detection using wrist worn tri-axis accelerometer signals [C]. 2018 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops), 2018: 221-226.
- [13] LOEFFLER C E. Detecting gunshots using wearable accelerometers [J]. PloS One, 2014, 9(9): e106664.
- [14] KASARDA M, TARAZAGA P, EMBREE M, et al. Detection and identification of firearms upon discharge using floor-based accelerometers [C]. Special Topics in Structural Dynamics, 2016, 6: 45-53.
- [15] WELSH D, FARIDEE A Z M, ROY N. Hybrid distance-based framework for classification of embedded firearm recoil data [C]. 2021 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops), 2021: 50-55.
- [16] TIAN Y, WANG X, CHEN L, et al. Wearable sensor-based human activity recognition via two-layer diversity-enhanced multiclassifier recognition method [J]. Sensors, 2019, 19(9): 2039.
- [17] 孙佳亨, 孟晓亮, 梁豪, 等. 基于 MEMS 传感器的体操动作识别 [J]. 电子测量与仪器学报, 2020, 34(3): 94-99.
- SUN J H, MENG X L, LIANG H, et al. Gymnastics motion recognition based on MEMS sensor [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(3): 94-99.
- [18] WANG B, LEI Q, WANG D. Experimental study on ground vibration response in gun firing environment [J]. Vibroengineering Procedia, 2019, 28: 136-141.
- [19] HRABINA M, SIGMUND M. Gunshot recognition using low level features in the time domain [C]. 2018 28th International Conference Radioelektronika, 2018: 1-5.
- [20] KIKTOVA E, LOJKA M, PLEVA M, et al. Gun type recognition from gunshot audio recordings [C]. 3rd International Workshop on Biometrics and Forensics (IWBF 2015), 2015: 1-6.

作者简介



伍弘毅, 福州大学物理与信息工程学院在读硕士, 主要研究方向为嵌入式系统、信号处理、机器学习及其在人类活动识别的应用。

E-mail: wuhongyi0916@foxmail.com

Wu Hongyi now is a M. Sc. candidate in College of Physics and Information Engineering at Fuzhou University. His main research interests include embedded systems, signal processing, machine learning and their application in human activity recognition.



陈志聪(通信作者), 2011 年于意大利帕维亚大学获得博士学位, 2011~2013 年于意大利帕维亚大学任博士后研究员, 现为福州大学物理与信息工程学院副教授, 主要研究方向为无线传感器网络、信号处理、机器学习及其在工业检测、诊断及预测的应用。

E-mail: zhicong.chen@fzu.edu.cn

Chen Zhicong (Corresponding author) received his Ph. D.

degree from University of Pavia, Italy, in 2011. From 2011 to 2013, he was a post doctor researcher with University of Pavia, Italy. Currently, he is an associated professor with College of Physics and Information Engineering, Fuzhou University, China. His main research interests include wireless sensors networks, signal processing, machine learning and their application in industrial detection, diagnosis and prognosis.



吴丽君, 2013 年于意大利帕维亚大学获得博士学位, 现为福州大学物理与信息工程学院副教授, 主要研究方向为无线传感器网络、模型压缩与加速、监控场景异常检测、视觉检测和 SLAM。

E-mail: lijun.wu@fzu.edu.cn

Wu Lijun received her Ph. D. degree from University of Pavia, Italy, in 2013. Currently, she is an associated professor in College of Physics and Information Engineering, Fuzhou

University, China. Her main research interest includes wireless sensors networks, model compression and acceleration, surveillance scene abnormality detection, visual inspection and SLAM.



何虔恩, 2008 年于哈尔滨工业大学获得学士学位, 2013 年于清华大学获得博士学位, 现为福州大学副教授, 主要研究方向为惯性技术及其应用、机电控制工程、生物医学信息处理。

E-mail: heqianen@tsinghua.org.cn

He Qian'en received his B. Sc. degree from Harbin Institute of Technology in 2008, and Ph. D. degree from Tsinghua University in 2013, respectively. Now he is an associate professor in Fuzhou University. His main research interests include inertial technology and its application, mechatronic control engineering and biomedical information processing.