

DOI:10.19651/j.cnki.emt.2209324

基于 SAE-SVM 算法的振动信号定位方法研究^{*}

诸燕平¹ 谭强志²

(1. 常州大学微电子与控制工程学院 常州 213164; 2. 常州大学计算机与人工智能学院 常州 213164)

摘要: 针对传统振动信号短时能量检测法精度低、需手工参数选择等问题,提出了一种稀疏自编码器(SAE)网络,用于提取振动信号有效特征,并将其用于支持向量机(SVM),从而检测脚步振动信号。为了缓解了振动信号色散效应造成的信号失真问题,使用了小波分解(WT)方法,并基于实验分析优化了分解参数,然后基于广义互相关和到达时间差(TDoA)算法进行定位解算。实验结果表明,相比人工特征筛选,SAE-SVM 算法的活动段检测精度可达 96.8%,系统平均定位误差为 0.82 m。

关键词: 室内定位;脚步振动;稀疏自编码器;支持向量机;小波分解

中图分类号: TN911 文献标识码: A 国家标准学科分类代码: 510.5015

Research on vibration signal localization method based on SAE-SVM algorithm

Zhu Yanping¹ Tan Qiangzhi²

(1. School of Microelectronics and Control Engineering, Changzhou University, Changzhou 213164, China;

2. School of Computer Science and Artificial Intelligence, Changzhou University, Changzhou 213164, China)

Abstract: A sparse autoencoder (SAE) network is proposed to extract the effective features of vibration signals and apply them to support vector machine (SVM) to detect footstep vibration events, aiming at the problems of low accuracy and manual parameter selection of traditional short-time energy detection method. To alleviate the signal distortion caused by the dispersion effect of vibration signal, the wavelet decomposition method is used, and the decomposition parameters are optimized based on the experimental analysis, and then the location is solved based on the generalized cross-correlation (GCC) and time difference of arrival (TDoA) algorithm. Experimental results show that, compared with manual feature screening, the detection accuracy of an active segment can reach 96.8% by the SAE-SVM algorithm, and the average positioning error of the system is 0.82 m.

Keywords: indoor occupant localization; footstep-induced vibration; sparse autoencoder; support vector machines; wavelet decomposition

0 引言

近年来,市场上对于位置服务的需求逐渐增加。室外定位技术已经趋于成熟,但由于室内信道环境复杂以及建筑密集的地区无法接收到卫星信号等因素,室外定位技术无法提供有效的室内定位服务。目前室内人员定位主要有基于计算机视觉^[1]、红外^[2]、Wi-Fi^[3]、超宽带^[4-5](ultra wide band, UWB)等技术。

基于计算机视觉的定位技术存在视觉盲区且有隐私泄露的风险;基于红外的室内定位技术易受热源干扰,且要求密集部署传感器;基于 Wi-Fi 指纹库的定位技术易受多径

效应的干扰,且需要定期更新指纹库,维护难度较大;基于 UWB 技术的定位系统,虽然抗多径效应能力强,定位精度高,然而设备价格贵,且要求人员携带信号发射装置才能定位。基于振动传感器的定位方法所需传感器数量少,部署方法简单,无需携带设备,不存在隐私暴露风险,具有较好的发展前景,但目前该方法依然存在波传播速度未知和板波的色散效应导致信号失真两个主要挑战^[6]。

针对以上问题,Bahroun 等^[7]简化了振动波传播速度的分布模型并且忽略色散效应造成的失真,基于到达时间差(time differences of arrival, TDoA)算法实现了室内定位,但定位精度较低。Poston 等^[8]基于建筑物结构的详细

收稿日期:2022-03-19

*基金项目:国家自然科学基金青年科学基金(61801055)项目资助

物理先验信息获得了亚米级的室内定位精度,但是需要大量校准,应用受到限制。Mirshekari 等^[6]在文献[8]的研究基础上提出了自适应的室内人员定位方法,无需大量先验信息的校准也获得了亚米级的定位精度。但活动段识别算法基于人工的特征设计,工作量大且识别精度不高^[9];使用的基于小波分解(wavelet decomposition, WT)的色散缓解方法选择的尺度分量范围广、计算量大,实时性差。

支持向量机(support vector machines, SVM)是一种经典且高效的分类模型,可用于脚步事件活动段的提取,但是传统方法在特征处理阶段需要大量的人工参与,比如文献[9]使用的时频特征的参数需要人工调试确定。数据的特征选择对机器学习性能有重要影响。人工设计数据特征费时费力,并且难以获得理想的效果。稀疏自编码器(sparse autoencoder, SAE)是一种数据降维和特征提取算法^[10],相比传统的主成分分析法,能够保证输入和输出的大部分信息完整并且具有较强的泛化能力,可以为 SVM 提取有效特征,并且避免人工特征选择^[11-12]。

本文针对文献[9]活动段提取精度低、计算量大的问题,首先提出了一种基于 SAE 和 SVM 的活动段检测算法 SAE-SVM,解决了不同脚步形态的事件提取以及繁琐的人工特征选择问题;然后根据实验结果缩小了尺度分量范围减少了基于 WT 色散缓解方法的计算量,最后基于 TDoA 算法进行定位解算。

1 算法设计

本算法首先对不同传感器采集到的振动信号做基于 SAE-SVM 的脚步事件检测,然后通过基于时频分析的预处理缓解信号失真,接着通过广义互相关(generalized cross-correlation, GCC)算法计算同一脚步事件到达不同传感器的时间差;最后通过多点定位算法获得目标位置并计算定位精度^[13],如图 1 所示。



图 1 算法整体框架

1.1 脚步事件检测

自编码器(autoencoder, AE)是一种特殊的多层次前馈神经网络,网络结构如图 2 所示,可以看作由一个编码器 $\mathbf{h} =$

$f(\mathbf{x})$ 和一个生成重构信号的解码器 $\mathbf{r} = g(\mathbf{h})$ 两个部分组成。

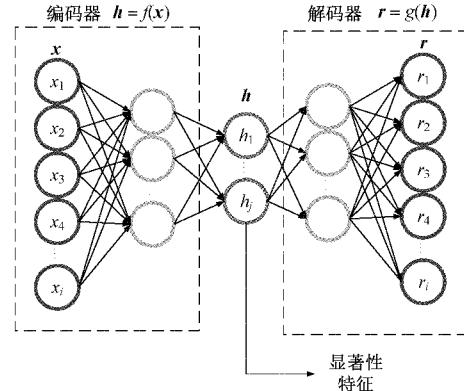


图 2 SAE 原理图

在学习时让解码器输出的目标值 \mathbf{r} 接近于编码器的输入值 \mathbf{x} , 经过训练后的网络能够尝试将输入复制到输出。训练自编码器目的是使 \mathbf{h} 成为有用的特征。所以在网络中需要限制 \mathbf{h} 的维度,使 \mathbf{h} 的维度 j 小于输入向量 \mathbf{x} 的维度 i 。另外,数据的稀疏表示对于分类任务更加有效,所以本文在网络中添加了稀疏惩罚项。

本文设计的 SAE 的损失函数如式(1)所示。

$$J(\mathbf{W}, \mathbf{b}) = \frac{1}{2m} \sum_{i=1}^m \| \mathbf{h}^{(i)} - \mathbf{x}_i \|_2^2 + \frac{\lambda}{2} \sum_{l=1}^n \| \mathbf{W}^{(l)} \|_F^2 + \beta \sum_{l=1}^{n-1} \sum_{j=1}^{s_l} KL(\rho \| \hat{\rho}_j^{(l)}) \quad (1)$$

第 1 项表示给定每个训练采样的重构误差,第 2 项为 F 正则项,即权值矩阵 $\mathbf{W}^{(l)}$ 的 F 范数。F 正则项的作用是减小权值矩阵的大小,防止过拟合。第 3 项是 KL 散度,是网络的稀疏性度量项,加入这一项可以使训练模型获得在压缩和分类任务中较为有效的高维稀疏表示。其中 $\hat{\rho}^{(l)}$ 是每层的平均激活值,如式(2)所示。

$$\hat{\rho}_j^{(l)} = \frac{1}{m} \sum_{i=1}^m a_j^{(l)}(\mathbf{x}_i) \quad (2)$$

ρ 是接近于 0 的稀疏性限制,KL 散度越小, ρ 和 $\hat{\rho}_j^{(l)}$ 越相近,稀疏性越强。权值衰减参数 λ 和 β 控制 F 正则项和稀疏性度量项的相对重要性。

SAE 的输入层维度和输出层维度一致,都等于信号分帧之后的帧长,即 $i = \text{framesize} = 250$ 。隐藏层有 3 层,第 1 层隐藏层和第 3 层隐藏层维度同样一致,第 2 层隐藏层维度最小,也是输出显著性特征的层。输出的显著性特征数,既不能过小,造成代表性不够;也不能太大,否则没有降维效果。

在实验时发现,当设置的输出特征数(即 \mathbf{h} 的维度) $j < 22$ 时,训练时间就会显著增长,当设置的输出特征数 $j < 15$ 时,迭代的误差显著增大,且下降不明显,训练耗时极长。对于使用 SAE 输出特征的 SVM 模型,当输出的每帧特征

小于 20 时, SVM 分类效果明显变差, 比如 $j=15$ 时, 平均定位误差下降为 61.3%。综合训练时间和输出特征的学习效果, 本文设置输出特征的维数 $j=25$ 。第 1 层隐藏层和第 3 层隐藏层维度设置为中间值 120。

经过 SAE 处理获得信号的显著性特征, 然后结合振动激励事件的标签(是否脚步振动事件)组织数据集训练 SVM 模型。

振动信号数据是非线性数据, 经过分类实验对比, 使用径向基核函数(radial basis function, RBF)核函数的 SVM 模型相比使用其他核函数的 SVM 模型的训练和分类耗时以及分类精度均较佳, 因此本文采用使用 RBF 核函数的非线性支持向量机分类器^[15]。RPF 核函数如式(3)所示。

$$K(x_i, x) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (3)$$

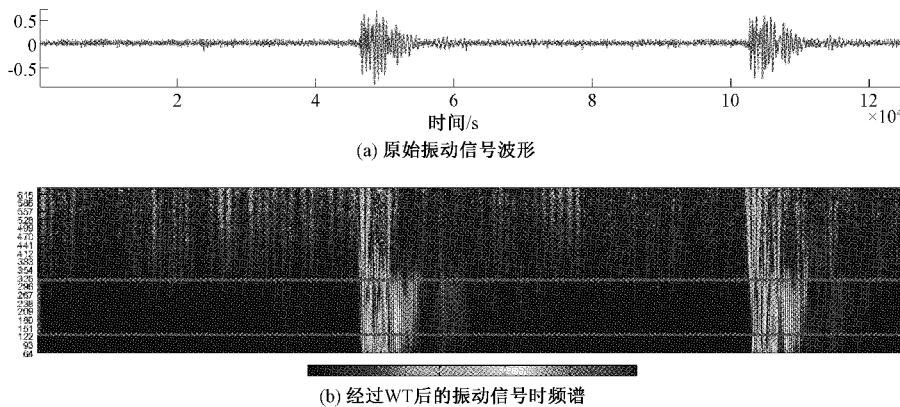


图 3 振动信号的时频域表示

如图 4 所示, 信号一和信号二分别是两个传感器从相同脚步激励接收到的信号, 图 4(a)是原始信号, 图 4(b)是经过 WT 分解的信号。经过分解后信号的形状变得更加相似(最大互相关值从 0.32 增加到 0.86, 相似度提高了 2.7 倍), 峰与峰的对应更加清晰。

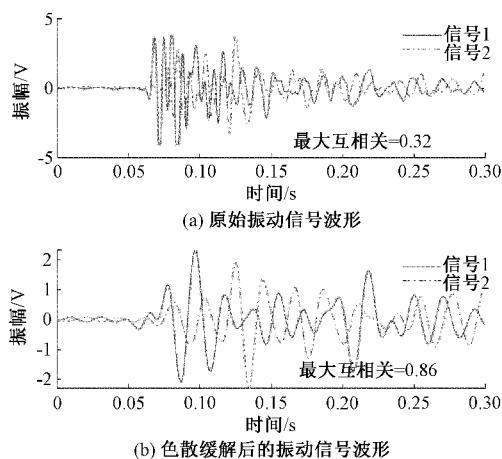


图 4 基于 WT 的色散缓解示意图

1.2 基于时频分析的色散缓解

时频表示法是色散缓解的常用解决方法。本文使用 WT 对信号进行分解, 与短时傅里叶变换等时频分析方法相比, WT 更适合于本文采用的非平稳信号。

本文选择墨西哥帽小波作为母小波, 这种小波的形状与脚步振动波相似, 能够很好地表征脚步振动信号。为了减少连续小波变换的计算量, 需要选择有限的尺度范围^[14]。因为脚步引起的地板振动信号通常低于 100 Hz, 并且对于低于 10 Hz 的频率, 检波器具有显著的衰减效应^[6]。因此选择 10~100 Hz 的范围进行 WT。使用墨西哥帽小波, 对于 25 kHz 的采样频率, 这个相应的尺度分量范围为 64~640^[6]。如图 3 所示, WT 后的时频谱中在尺度分量为 128~320 之间的信号最为清晰, 所以合适的尺度分量范围可缩小为 128~320, 减少 WT 的计算量。

1.3 基于广义互相关的 TDoA 计算及多点定位算法

本文使用基于相位变换的广义互相关的算法(GCC-PHAT)计算经过色散缓解后不同传感器接收到的相同脚步激励产生的信号之间的到达时间差。广义互相关法在对两路信号进行互相关处理之前, 先进行加权处理, 增强信号中信噪比高的频率成分, 抑制噪声功率, 从而减少时延估计的误差。

TDoA 多边定位技术原理如式(4)所示。这种技术对被测点的要求相对较低, 不要求被测目标与基站的时间同步。

$$\|\hat{L} - p_i\|_2 - \|\hat{L} - p_e\|_2 = v(t_i - t_e) \quad (4)$$

其中, p_i 是第 1 个传感器的位置, p_e 是第 2 个传感器的位置, v 是波传播速度, \hat{L} 被测点的坐标。 $(t_i - t_e)$ 就是 TDoA。每个 TDoA 可以将 \hat{L} 的范围限制在一个双曲线上, 多个双曲线的交点就是测得的定位点。定位点与真实点的距离差值, 作为代价函数。

基于 TDoA 的多点定位法需要信号传播速度 v 已知, 然而不同结构中振动波的传播速度是不同且未知的。可

以建立一个模型,估算波传播的速度。首先,假设振动波在地板结构中传播速度不变。使用给定的速度初值对已知的点按照式(4)进行定位,则估计速度 v^* 为:

$$v^* = \operatorname{argmin}_v \sum_{i=1}^N \frac{1}{N} \| L_i - \hat{L}_i(v) \|_2 \quad (5)$$

其中, L_i 是第 i 个真实点的坐标, \hat{L}_i 是速度为 v 时经式(4)所得的预测点的坐标。

2 实验结果与分析

2.1 数据采集

本文用地震检波器(Geophone)测量地板不同位置的垂直振动,选择的检波器型号为 LGT-20D10 垂直地震检波器。LGT-20D10 是动圈结构的模拟检波器,可以有效采集脚步引起的振动纵波。本文选择 AD620 运算放大器放大地震检波器产生的通常为毫伏级的微弱电压,放大倍数为 100 倍。AD620 模块精度高、失调电压低和失调漂移低,共模抑制比高达 100 dB,适合对小微信号的放大。AD620 模块是电压型放大器,压摆率较低,而系统目标信号的有效频率范围在 10~100 Hz 之间,属于低频信号,对于压摆率要求不高,可以使用。放大后的模拟信号传输至 MCC118 ADC 模块进行采样,MCC118 提供最高 8 通道的模拟电压输入,可以同时进行多通道的采集满足了 TDoA 算法的时间同步要求。每张 MCC 118 最大采样率为 100 kSa/s,可以保证 TDoA 算法的时间分辨率。采集的信号由树莓派保存并经过局域网传输至上位机进行进一步处理。

传感单元的结构如图 5 所示,每个传感器节点包括 1 个地震检波器和 1 个放大器模块。

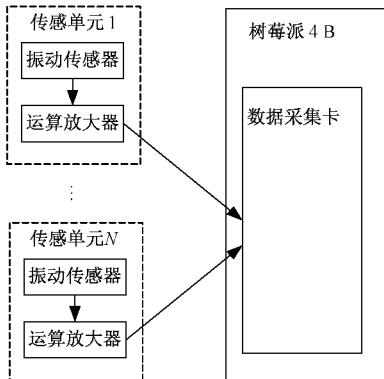


图 5 传感单元结构图

本实验共部署 4 个传感器节点连接到装有 MCC118 数据采集板的树莓派 4 B 上。

信号采集设备如图 6 所示,实验的场地为开间 6 m、进深 6 m 的会议室,地面结构为防静电地板,如图 7 所示。

实验采集的部分信号原始数据如图 8 所示。

2.2 脚步事件检测实验

实验首先对采集的信号进行分帧处理,每一帧信号作

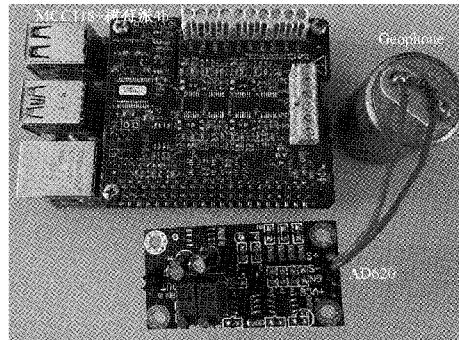


图 6 信号采集设备



图 7 实验现场

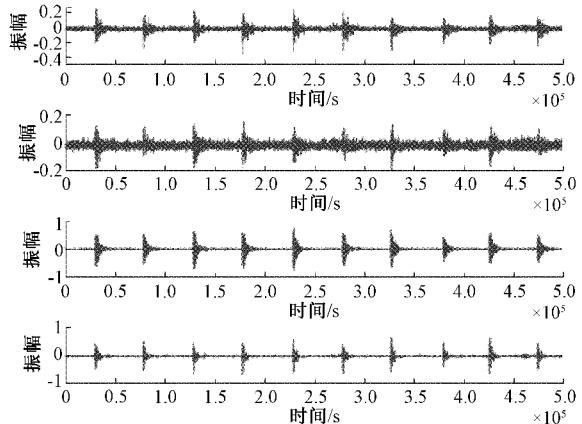


图 8 部分原始数据

为 SAE 的输入提取显著性特征。提取的特征和实验的标签组成 SVM 的数据集,训练 SVM 模型。训练好的 SVM 模型可用于脚步事件提取。

实验效果如图 9 所示,使用 SAE 提取信号特征训练的 SVM 分类器可以从信号中提取出激励事件段并识别非脚步的脉冲激励。

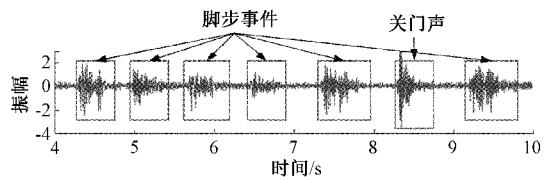


图 9 脚步事件检测示意图

实验使用了采集的 50 000 个样本,做了 10 次交叉检验,并与文献[9]的效果进行了对比。平均结果如表 2 所示。可以看出 SAE-SVM 算法能实现较为准确的脚步事件提取任务并提高了分类精度。

表 1 SVM 振动信号活动段检测性能评估结果

	<i>Se</i>	<i>Sp</i>	<i>P</i>	<i>Acc</i>
文献[9]方法	94.2%	85.5%	72.0%	84.7%
SAE-SVM	97.3%	91.6%	97.5%	96.8%
效果提升	1.03X	1.07X	1.35X	1.14X

2.3 定位实验

实验的传感器布置和脚步位置分布如图 10 所示。虚线矩形框的顶点是 4 个传感器的位置,三角形是测试的实际脚步位置点,圆点是本文方法获得的定位点。以传感器 1 所在位置为坐标零点建立笛卡尔坐标系。

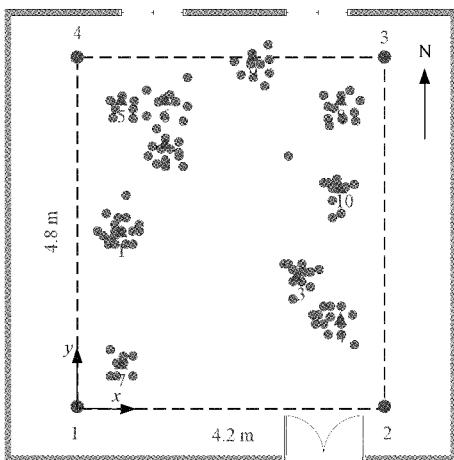


图 10 传感器布置和脚步位置

以传统的没有色散缓解的广义互相关方法作为对照方法,实验结果如表 2 所示(单位为 m)。由表 2 可以看出本文提出的定位算法有效提高了定位精度。

表 2 定位结果表

	均值	标准差	中位数	四分位数
文献[6]方法	1.23	1.52	1.06	2.55
本文方法	0.82	1.04	0.95	1.57
效果提升	1.50X	1.46X	1.12X	1.62X

3 结 论

本文针对目前基于振动信号的室内定位系统的脚步事件提取部分存在的人工特征选择和提取精度低的问题,提出了改进算法 SAE-SVM。SAE-SVM 算法使用 SAE 提取振动信号的代表性特征,并将其应用于 SVM 以检测脚步信号,过滤噪声和非脚步激励。使用 WT 缓解了振动信

号色散效应造成的信号失真问题,并基于实验分析优化了分解参数。最后使用基于广义互相关的 TDoA 算法进行了定位结算和结果分析。结果表明相比人工特征筛选,SAE-SVM 算法的活动段检测精度可达 96.8%,系统平均定位误差为 0.82 m。

本文通过人工参考 WT 的时频谱图的方式改进了分解参数,虽然确定了较合适的母小波和尺度分量范围,减少了计算量。但是人工干预和计算量仍然较大,之后的研究可以考虑应用神经网络算法完成色散缓解和定位解算问题,进一步减少人工干预和提高定位精度。

参 考 文 献

- [1] 焦传佳,江明. 基于 AprilTag 图像识别的移动机器人定位研究[J]. 电子测量与仪器学报,2021,35(1):110-119,DOI:10.13382/j.jemi.B2003304.
- [2] SANTO H, MAEKAWA T, MATSUSHITA Y. Device-free and privacy preserving indoor positioning using infrared retro-reflection imaging[C]. 2017 IEEE International Conference on Pervasive Computing and Communications(PervCom), IEEE, 2017.
- [3] 乐燕芬,许远航,施伟斌. 基于 DPC 指纹子空间匹配的室内 WiFi 定位方法[J]. 仪器仪表学报,2021,42(11):106-114,DOI:10.19650/j.cnki.cjsi.J2108314.
- [4] 韦子辉,王世昭,叶兴跃,等. 基于超宽带的 TDOA 相邻单元协同定位技术[J]. 电子测量技术,2022,45(1):77-83.
- [5] 宰昶丰,郭英,叶瑾,等. 基于 UWB 穿墙定位中 NLOS 误差的优化方法[J]. 电子测量技术,2021,44(19):128-133.
- [6] MIRSHEKARI M, PAN S, FA GERT J, et al. Occupant localization using footstep-induced structural vibration [J]. Mechanical Systems and Signal Processing, 2018, 112:77-97.
- [7] BAHROUN R, MICHEL O, FRASSATI F, et al. New algorithm for footstep localization using seismic sensors in an indoor environment[J]. Journal of Sound & Vibration, 2014, 333(3):1046-1066.
- [8] POSTON J D, BUEHRER R M, TARAZAGA P A. Indoor footstep localization from structural dynamics instrumentation[J]. Mechanical Systems & Signal Processing, 2017, 88:224-239.
- [9] MIRSHEKARI M, PEI Z, NOH H Y. Calibration-free footstep frequency estimation using structural vibration[M]. Springer: Dynamics of Civil Structures Cham, 2017.
- [10] LIU J, LI C, YANG W. Supervised Learning via Unsupervised Sparse Autoencoder[J]. IEEE Access, 2018;1-1,DOI:10.1109/ACCESS.2018.2884697.
- [11] 王文凯,邓斌. 基于 DAE-IPSO-SVM 的电缆早期故障

- 识别方法[J].国外电子测量技术,2021,40(8):29-35.
- [12] JIAO R, HUANG X, MA X, et al. A model combining stacked auto encoder and back propagation algorithm for short-term wind power forecasting[J]. IEEE Access, 2018,6: 17851-17858.
- [13] ZHOU Y, LI J, LAMONT L. Multilateration localization in the presence of anchor location uncertainties[C]. Global Communications Conference, IEEE, 2012:309-314.
- [14] 张军,郑玉新,赵静.经验小波变换在信号趋势项提取中的应用研究[J].电子测量技术,2019,42(16):17-22.
- [15] KASHEF R. A boosted SVM classifier trained by incremental learning and decremental unlearning approach-ScienceDirect [J]. Expert Systems with Applications, 2020,DOI:10.1016/j.eswa.2020.114154.

作者简介

诸燕平,副教授,主要研究方向为无线传感器网络、数值优化、移动网络计算。

E-mail:zhuyanping@cczu.edu

谭强志,硕士研究生,主要研究方向为无线传感器网络。

E-mail:wcimcitzu@qq.com