

# 一种基于 SVM 的声源定位算法

顾晓瑜, 杨悦

(南京邮电大学 通信与信息工程学院, 江苏 南京 210003)

**摘要:**随着多媒体技术的快速发展,获取高质量的语音成为一种越来越受到广泛重视的技术手段,以麦克风阵列定位声源的方法在诸多领域得到了广泛的应用。支持向量机(Support Vector Machine, SVM)是一种基于统计学习理论和结构风险最小化原则的机器学习方法,其诸多参数的选择直接影响到 SVM 的性能, SVM 可作为估计声源位置的分类器,且可通过选取适当的参数提高算法的抗噪声能力。为此,提出了一种基于 SVM 的声源定位新算法。该算法提取鉴别互相关函数的特征,通过选取合适的参数,对 SVM 的核函数进行优化。基于 Matlab 对提出的新算法进行了仿真实验验证。仿真实验结果表明,该算法较为显著地增加了混响和噪声条件下声源定位的准确性,且具有良好的鲁棒性。

**关键词:**支持向量机;机器学习;声源定位;核函数

**中图分类号:**TP301.6

**文献标识码:**A

**文章编号:**1673-629X(2017)09-0070-05

**doi:**10.3969/j.issn.1673-629X.2017.09.015

## A Sound Source Localization Algorithm with Support Vector Machine

GU Xiao-yu, YANG Yue

(College of Telecommunications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

**Abstract:** With the rapid development of multimedia technology, the method to obtain high-quality voice has become an increasingly widespread technical means, which has been widely used for microphone array sound source localization in many fields. Support Vector Machine (SVM) is a machine learning method based on statistical learning theory and structural risk minimization principle, and its performance depends on the correct selection of related parameters. SVM can be used as a classifier to estimate the position of the sound source, and it can improve the anti-noise ability of the algorithm by selecting the appropriate parameters. Therefore a new kind of sound source localization based on SVM is proposed. By extracting the features of cross-correlation function and selecting appropriate parameters, the kernel function of SVM is optimized. The simulation has been carried out with the proposed algorithm using Matlab, results of which show that it has increased the accuracy of sound source localization significantly in noisy and reverberant environments, with good robustness.

**Key words:** support vector machine; machine learning; sound source localization; kernel function

## 0 引言

作为人机交互的重要媒介,语音是人类最重要的交际工具,具有显著的优势。但是,在实际生活中,常常会有干扰语音的情况出现,比如环境中的噪声、其他声源的干扰等,使得语音质量下降。因此,如何获取高质量的语音成为一个密切关注的话题。一种基于麦克风阵列的语音系统由于其广泛的应用前景,受到了越来越广泛的关注。

在基于麦克风阵列的语音信号处理中,声源定位

技术处在核心位置。除了能够提供位置信息之外,声源定位技术在基于麦克风阵列的语音增强中也发挥着重要作用,对于如何增强语音信号处理的性能以及增强声源定位的性能有很重要的意义<sup>[1]</sup>。

对于绝大多数的定位系统来说,采用的都是麦克风阵。从规模上进行划分,麦克风阵系统可分为两种:一种是大型的麦克风阵,主要用来进行语音控制,这其中包含了几十到几百的阵元;另一种则是小型的麦克风阵,主要在一些电子产品(比如手提电脑以及移动

收稿日期:2016-06-29

修回日期:2016-10-11

网络出版时间:2017-07-11

基金项目:声纳技术国防科技重点实验室开放研究基金(KF201503);江苏省自然科学基金(BK20140891)

作者简介:顾晓瑜(1992-),女,硕士研究生,研究方向为声源定位、机器学习。

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1450.TP.20170711.1452.018.html>

电话)中使用<sup>[2]</sup>。声源定位算法大致可分为三种:基于高分辨率谱估计的定位算法、基于时延估计的定位算法和基于可控波束形成的定位算法<sup>[3]</sup>。

迄今为止,已经提出了很多类时间差估计算法,比如基本互相关法、广义互相关法、最小均方自适应滤波法、互功率谱相关法<sup>[4]</sup>等。在这些算法中,比较经典的是由 Knapp 等提出的 GCC-PHAT(相位变换加权广义互相关)算法。它的实用性非常强,抑制旁瓣的效果很好,而且通过锐化互相关函数主峰的行为,可以使得时延估计的精度增强。然而当室内的混响很严重时,GCC-PHAT 这种时延估计算法的抗噪能力会下降。因此提高 GCC-PHAT 对噪声的鲁棒性显得尤为重要。利用 SVM 作为估计声源位置的分类器,并且通过合适参数的选取提高该模型的抗噪能力。

为此,研究重点集中在两方面。一方面是鉴别互相关函数特征的提取,利用得到的特征结合 SVM 分类器得到互相关函数的模型;另一方面是在已得到模型的基础上,调整 SVM 的参数,比较不同参数选择的定位效果。

### 1 支持向量机

支持向量机(SVM)<sup>[5]</sup>是这样的一种机器学习算法:SVM 建立在统计学习的 VC 维度(Vapnik-Chervonenkis Dimension)理论<sup>[6]</sup>以及结构风险最小化原理的基础上,可以对有限的样本实现模型复杂度以及学习能力的平衡。支持向量机利用对最大间距的超平面的寻找进行分类,有着很强的泛化能力,并且对小样本的分类尤为适用。SVM 主要处理二分类的情况,主要思想是面向线性可分的问题设计。在样本是线性不可分时,SVM 通过非线性映射,也就是核函数<sup>[7]</sup>,使低维空间的样本映射到高维空间中,这样就可以使样本线性可分,从而可以在高维空间线性分类。对超平面的寻找是建立在结构风险最小理论的基础上,通过对两个间隔最大的平行超平面的寻找,实现样本分类,这就可以让分类器获得全局最优解,并且在样本空间中,符合期望风险以某个概率满足一定上界的情况。

SVM 是按照如下方法实现的:对训练集合内的样本 $(x^i, y^i), i = 1, 2, \dots, N$ ,其中 $N$ 表示样本数量, $x^i \in R^l, y \in \{-1, 1\}$ ,正样本用+1表示,负样本用-1表示, $R^l$ 表示样本空间, $x^i$ 表示第 $i$ 个 $l$ 维的样本向量, $y^i$ 表示此样本被包含的类的标记。在样本处于线性可分的情况下,可以使用一个分类平面,使得训练的样本分离,这个平面称作超平面<sup>[8-9]</sup>,可以用下面的函数来表示:

$$\mathbf{w}^T \cdot \mathbf{x} + b = 0 \tag{1}$$

其中, $\mathbf{w}$ 和 $b$ 分别表示该超平面的法向量和截距。

超平面的作用是划分样本空间,使样本空间变成两个区域。在一侧区域,与样本对应的 $\mathbf{w}^T \cdot \mathbf{x} + b$ 大于零,但是在另一侧区域,与样本对应的 $\mathbf{w}^T \cdot \mathbf{x} + b$ 则小于零。

以上是 SVM 的分类原理,目的是通过寻找两个互相平行的超平面来划分样本,并且这两个超平面之间的距离也是最大的。通过这种方法定下的超平面可以在最大范围内对两类不同的样本进行划分,要让两个超平面间的距离最大,等价于使 $\|\mathbf{w}\|_2$ 最小,也就是:

$$\min_{\mathbf{w}, b} \Phi(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|_2 = \frac{1}{2} \mathbf{w}^T \mathbf{w} \tag{2}$$

通过引入拉格朗日对偶的概念,使用拉格朗日系数 $\alpha$ ,将式(2)的限制条件与目标函数进行融合,得到的拉格朗日函数如下:

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2} \mathbf{w}^T - \sum_{i=1}^m \alpha_i (y_i (\mathbf{w}^T \cdot \mathbf{x}_i + b) - 1) \tag{3}$$

这样, $\mathbf{w}$ 以及 $b$ 的值就可以通过式(3)求得,也就可以得到两个平行的分类超平面,此超平面是支持向量机分类器中距离最大的一组超平面,同时可以计算出支持向量机的判别函数:

$$f(x) = \text{sgn}(\sum_{x_i \in SV} \alpha_i y_i (\mathbf{x}_i \cdot \mathbf{x}) + b) \tag{4}$$

当训练的样本集合满足理想的且完全线性可分的情况时,该方法通过计算支持向量机的决策函数达到很好的效果。然而在实际情况中,许多的训练样本集合不是线性可分而是近似线性可分的,因此提出松弛变量和核函数的思想是很有必要的。

SVM 的核函数有许多类型,包括线性内核、多项式内核、径向基内核(RBF)、sigmoid 核<sup>[9-11]</sup>。其中,RBF 应用最广泛,其适用性表现在对大小样本以及高低维都适用。

### 2 基于 SVM 的定位算法

基于鉴别互相关函数的声源定位算法包括两种过程,分别是训练过程以及定位过程<sup>[12-13]</sup>。在训练过程中,计算互相关函数作为特征,利用特征向量,计算出互相关函数 SVM 模型的参数。测试时通过计算获得互相关函数,并作为特征,利用 SVM 分类器估计声源的位置。

训练过程和定位过程的模型分别见图 1 和图 2。

在训练过程中,实验目的是创建一个互相关函数的 SVM 模型,步骤如下:

(1)利用麦克风阵列,记录下声源在不同位置产生的混响信号,此时假设每一个训练的位置为 $l_i, i = 1,$

2, \dots, M;

(2) 根据得到的混响信号, 计算出互相关函数;

(3) 根据互相关函数, 生成特征向量  $z$ ;

(4) 对于每一个训练位置  $l_i$ , 利用特征向量计算出 SVM 模型的法向量  $w_i$  和截距  $b_i$ 。

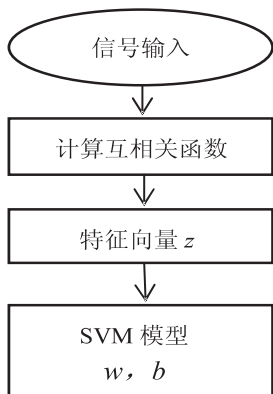


图 1 训练过程

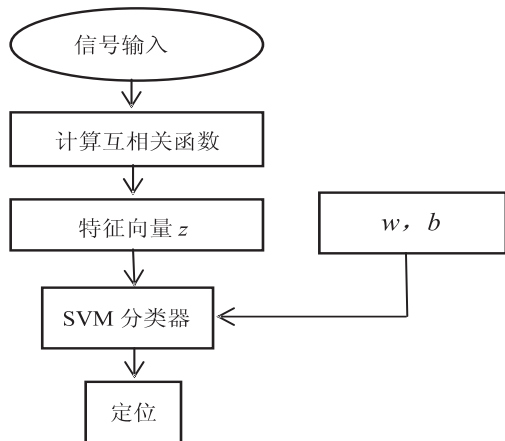


图 2 定位过程

在定位过程中, 声源的位置信息  $\hat{l}_s$  可以由鉴别互相关函数经过估算得到。步骤如下:

(1) 麦克风阵列记录下信号, 此信号包括声源发出的信号(混响信号)以及噪声。

(2) 根据得到的混响信号, 计算出互相关函数。

(3) 根据互相关函数, 生成特征向量  $z$ 。

(4) 利用已经训练得到的 SVM 分类器来估计声源的位置。

在利用 SVM 分类器估计声源的位置信息时, 能够使类间距  $2/\|w\|$  最小的位置可定义为声源的位置:

$$\hat{l}_s = \arg \min_{l_i} \frac{2}{\|w\|} \quad (5)$$

其中, 类间距  $2/\|w\|$  由法向量  $w_i$  和截距  $b_i$  得到。

### 3 算法实现

#### 3.1 特征提取

实验采用由两个麦克风组成的麦克风阵, 其中,

对于第  $i$  个麦克风, 它接收到的信号是:

$$x_i(k) = h_i(l_s, k) * s(k), i = 1, 2 \quad (6)$$

其中,  $s(k)$  表示声源, 它的位置在  $l_s$ ;  $h_i(l_s, k)$  表示从声源到第  $i$  个麦克风房间的脉冲响应。

假设房间脉冲响应的长度为  $H$ , 则对第  $i$  个麦克风, 接收到的信号可以表示为:

$$x_i(k) = \sum_{m=0}^{H-1} h_i(l_s, m) s(k-m) \quad (7)$$

在实际情况下, 由于受到噪声以及混响的干扰, 相关函数往往会受到以下影响: 最大峰被弱化, 以及出现多个峰值。广义互相关法是对一对麦克风信号的互功率谱实行加权处理, 这样便可以达到相关函数在时延的峰值位置更加突出的效果。信号  $x_1(k)$  和  $x_2(k)$  的广义互相关函数可以表示为:

$$R_{x_1 x_2}(\tau) = \int_{-\infty}^{\infty} \Phi_{1,2}(\omega) X_1(\omega) X_2^*(\omega) e^{j\omega\tau} d\omega \quad (8)$$

其中, “\*” 表示复共轭;  $X_1(\omega)$  是  $x_1(t)$  的傅里叶变换;  $\Phi_{1,2}(\omega)$  表示加权函数。

为了进一步提高互相关函数的抗混响的能力, 实验利用了相位变换加权函数:

$$\Phi_{1,2}(\omega) = \frac{1}{|X_1(\omega) X_2^*(\omega)|} \quad (9)$$

将式(9)代入到式(8), 可以得到:

$$R_{x_1 x_2}(\tau) = \int_{-\infty}^{\infty} \frac{X_1(\omega) X_2^*(\omega)}{|X_1(\omega) X_2^*(\omega)|} e^{j\omega\tau} d\omega \quad (10)$$

在实际环境下, 信号  $x_1(t)$  和  $x_2(t)$  在经过预处理加窗之后, 接着通过傅里叶变换便可得到  $X_1(\omega)$  和  $X_2(\omega)$ 。由式(7)可知, 若房间脉冲响应的长度  $H$  比窗函数短很多, 那么在频域内,  $S(\omega)$  和  $H_i(l_s, \omega)$  分别为  $s(k)$  和  $h_i(l_s, k)$  的傅里叶变换。那么麦克风信号可表示为:

$$X_i(\omega) = H_i(l_s, \omega) S(\omega), i = 1, 2 \quad (11)$$

将式(11)代入式(10), 可以求得:

$$R_{x_1 x_2}(\tau) = \int_{-\infty}^{\infty} \frac{H_1(l_s, \omega) H_2^*(l_s, \omega)}{|H_1(l_s, \omega) H_2^*(l_s, \omega)|} e^{j\omega\tau} d\omega = R_{h_1 h_2}(l_s, \tau) \quad (12)$$

但是, 在实际环境中, 窗函数的长度会比房间脉冲响应的长度  $H$  小很多, 于是麦克风信号可在频域内近似表示为:

$$X_i(\omega) \approx H_i(l_s, \omega) * S(\omega), i = 1, 2 \quad (13)$$

除此之外, 信号  $x_1(k)$  和  $x_2(k)$  之间的广义互相关函数约为房间脉冲响应  $h_1(l_s, k)$  和  $h_2(l_s, k)$  之间的广义互相关函数, 也就是:

$$R_{x_1 x_2}(\tau) \approx \int_{-\infty}^{\infty} \frac{H_1(l_s, \omega) H_2^*(l_s, \omega)}{|H_1(l_s, \omega) H_2^*(l_s, \omega)|} e^{j\omega\tau} d\omega = R_{h_1 h_2}(l_s, \tau) \quad (14)$$

### 3.2 SVM 定位算法

#### 3.2.1 互相关函数的 SVM 模型

特征向量是通过广义互相关函数  $R_{x_1x_2}(\tau)$  而产生的:

$$\mathbf{z} = [R_{x_1x_2}(-\tau_m), R_{x_1x_2}(-\tau_m + 1), \dots, R_{x_1x_2}(\tau_m)]^T \triangleq [z_1, z_2, \dots, z_i, \dots, z_{2\tau_m+1}]^T \quad (15)$$

其中,  $\tau_m = \text{round}(\alpha L f_s / c)$ , 因子  $\alpha$  设置为 1.67,  $L$ 、 $f_s$ 、 $c$  分别表示一对麦克风之间的距离、采样频率以及声速,  $\text{round}(\cdot)$  表示取整函数。

假设对于单个特征  $z_i, i = 1, 2, \dots, 2\tau_m + 1$  满足 SVM 模型, 那么特征  $z_i$  的几何间隔为:

$$\widehat{\varphi}(z_i) = y_i(\mathbf{w}_i^T \mathbf{z}_i + b_i), i = 1, 2, \dots, 2\tau_m + 1 \quad (16)$$

其中,  $y_i$ 、 $\mathbf{w}_i$ 、 $b_i$  分别为第  $i$  个特征  $z_i$  的法向量、结果标签以及截距。

当处于训练过程时, 针对任意一个位置  $l_i, i = 1, 2, \dots, J$ , 可以利用  $K$  帧的训练数据来估算几何间隔  $\varphi_j(l_i)$ 。由于对于任意一个超平面来说, 这个超平面都可以用一个法向量  $\mathbf{w}$  和一个常数截距  $b$  来表示, 所以一个点到这个超平面的距离可以表示为:

$$\varphi_j(l_i) = \frac{\frac{1}{J} \sum_{c=1}^J (w_j(l_i) z_j^c + b_i(l_i))}{\|\mathbf{w}_j\|}, i = 1, 2, \dots, J \quad (17)$$

其中,  $z_j^c$  表示第  $c$  帧训练数据的第  $j$  个特征。

#### 3.2.2 SVM 分类器的定位实现

在该实验中, 可以利用一个特征向量  $\mathbf{z}$  实现 SVM 分类器对声源位置的估计功能。

假设有这样一个前提, 对于任意一个特征  $z_i, i = 1, 2, \dots, 2\tau_m + 1$ , 它们之间都是统计独立的, 那么特征  $z_i$  的几何间隔为:

$$\widehat{\varphi}_i(\mathbf{z}) = \prod_{j=1}^{2\tau_m+1} \widehat{\varphi}_i(z_j) = \prod_{j=1}^{2\tau_m+1} \frac{\frac{1}{J} \sum_{c=1}^J (w_j(l_i) z_j^c + b_i(l_i))}{\|\mathbf{w}_j\|} \quad (18)$$

对于给定的样本点, 可以选出一组  $(w_i, b_i)$  来表示, 所以可令  $\mathbf{w} \cdot \mathbf{x} + b = 1$ , 超平面的距离可以表示为  $2/\|\mathbf{w}\|$ 。使得几何间隔最小的位置就被认为是声源的位置:

$$\widehat{l}_s = \arg \min_{l_i} \widehat{\varphi}_i(\mathbf{z}) = \arg \min_{l_i} \frac{2}{\|\mathbf{w}\|} \quad (19)$$

## 4 实验

### 4.1 实验数据

实验利用数据改进的镜像法, 用来模拟测量房间

脉冲响应的实际系统<sup>[14-16]</sup>。在房间中, 从声源发出的声波能量, 在传播过程中由于不断被壁面吸收而逐渐衰减, 声波在各个不同的方向来回反射, 而又逐渐衰减的现象称为室内混响。当声源停止后, 从初始的声压降到 60 dB 所需的时间称为混响时间, 这里用  $T_{60}$  表示室内声音的混响时间<sup>[1]</sup>。

利用一种仿真的矩形长方体房间, 仿真软件为 Roomsim, 模拟生成房间脉冲响应。得到混响时间和反射系数的关系:

$$\varepsilon = \exp\left(\frac{-13.82}{342(a^{-1} + b^{-1} + c^{-1})} \cdot T_{60}\right) \quad (20)$$

其中,  $T_{60}$  表示混响时间;  $\varepsilon$  表示反射系数;  $a, b, c$  分别表示矩形房间的长、宽、高; 342 表示声速, 约为 342 m/s。

仿真矩形房间的尺寸为 8 m × 6 m × 4 m, 调整反射系数  $\varepsilon$  使得混响时间  $T_{60}$  为 0.3 s。仿真的房间平面图如图 3 所示。实验条件是: 假设加性白噪声与声源的信号以及麦克风的噪声都不相关。一对麦克风的位置相距 0.3 m, 并且分别位于矩形房间的 (4.25 m, 3 m, 2 m) 和 (4.55 m, 3 m, 2 m) 处, 声源到一对麦克风中心的距离为 1.5 m。通过采样率为 16 kHz 的信号和房间脉冲响应的卷积生成混响信号。加入噪声, 并取不同的信噪比作对比。帧长是 32 ms, 有 512 个采样点, 给每帧信号加汉明窗。实验中训练和测试的声源的位置有 17 种, 分别为 10, 20, ..., 170 度。




图3 仿真的矩形长方体房间平面图

实验是在 Matlab R2014a 环境下实现的, 通过安装由台湾大学林智仁<sup>[9]</sup>教授开发的 LibSVM 工具包进行。LibSVM 是以源代码和可执行文件这两种方式设计的。它的使用步骤包括: 准备数据集、对数据进行缩放操作, 以及利用获取的模型进行测试与预测。

### 4.2 实验结果

计算得到 GCC-PHAT, 转换为特征  $\mathbf{z}$ , 得到 420 帧特征数据。将此特征分为训练集和测试集。基于 SVM 的定位算法使用了 90 帧训练数据, 330 帧测试数据。然后利用训练集建立分类模型, 利用建立的 SVM 模型观察其在训练集上的分类效果, 得到测试的结果准确度。

实验中, 选取了 SVM 的不同参数, 包括 SVM 三种



类型:C-SVC(C-支持向量分类)、V-SVC(V-支持向量分类)和一类 SVM。其中一类 SVM 是用于一类分类的分类器,在这里不予考虑。SVM 核函数有三种选择:线性核函数、多项式核函数和 RBF 函数。为了比较不同情况下 SVM 的定位性能,分别选择纯净语音,信噪比为 25 dB、15 dB 以及 5 dB 的信号,通过对 SVM 不同参数的选择而得到不同的抗噪性能。实验结果如表 1 和表 2 所示。

表 1 选择 C-SVC 时的分类准确率 %

核函数	clean	SNR=25 dB	SNR=15 dB	SNR=5 dB
线性	98.19	86.41	71.91	45.94
多项式	96.03	82.01	55.62	34.38
RBF	97.95	87.12	72.53	46.78

表 2 选择 V-SVC 时的分类准确率 %

核函数	clean	NR=25 dB	SNR=15 dB	SNR=5 dB
线性	97.93	85.61	70.75	44.13
多项式	95.88	78.48	51.45	29.28
RBF	97.79	86.38	72.34	45.40

从实验结果可以看出,基于 SVM 的声源定位算法的定位准确率随着信噪比的增加而上升。当处于相同的信噪比时,选择核函数的类型为 RBF,都有较高的分类准确率。在混响时间  $T_{60}$  为 0.3 s 时,核函数选择类型为多项式的定位算法随着信噪比的降低,定位精度下降幅度较大。当选择 C-SVC 的 SVM 类型且核函数为 RBF 时,有最高的分类准确率,定位效果最好。

5 结束语

针对现有声源定位算法的定位和鲁棒性有所不足的问题,提出了一种新的基于 SVM 的声源定位算法,通过 Matlab 仿真进行了实验验证,同时还比较了 6 种不同的 SVM 参数的组合情况。结果表明,该算法提高了定位的鲁棒性,在混响和噪声情况下也有很好的定位效果。在多媒体技术日益成熟的今天,该算法具有一定的实用性。

参考文献:

[1] 万新旺. 基于阵列信号处理与空间听觉的声源定位算法研

究[D]. 南京:东南大学,2011.

[2] 郭俊成. 基于传声器阵列的声源定位技术研究[D]. 南京:南京航空航天大学,2007.

[3] 宗志亚. 基于麦克风阵列的室内声源定位方法研究[D]. 重庆:重庆大学,2012.

[4] Wan Xinwang, Liang Juan. Improved sound source localization using classifier in reverberant noisy environment[J]. Journal of Applied Sciences, 2013, 13(21): 4897-4901.

[5] 李 琼, 陈 利. 一种改进的支持向量机文本分类方法[J]. 计算机技术与发展, 2015, 25(5): 78-82.

[6] 平 源. 基于支持向量机的聚类及文本分类研究[D]. 北京:北京邮电大学,2012.

[7] 常甜甜. 支持向量机学习算法若干问题的研究[D]. 西安:西安电子科技大学,2010.

[8] Laouti N, Othman S, Alamir M, et al. Combination of model-based observer and support vector machines for fault detection of wind turbines[J]. International Journal of Automation and Computing, 2014, 11(3): 274-287.

[9] 丁世飞, 齐丙娟, 谭红艳. 支持向量机理论与算法研究综述[J]. 电子科技大学学报, 2011, 40(1): 2-10.

[10] Xue X H, Yang X G, Chen X. Application of a support vector machine for prediction of slope stability[J]. Science China Technological Sciences, 2014, 57(12): 2379-2386.

[11] 何 清, 李 宁, 罗文娟, 等. 大数据下的机器学习算法综述[J]. 模式识别与人工智能, 2014, 27(4): 327-336.

[12] Campbell D. ROOMSIM toolbox[DB/OL]. 2012-08-08. <http://media.paisley.ac.uk/~campbell/Roomsim/> (Last viewed).

[13] 柯 昆. 声源定位技术研究[D]. 西安:西安电子科技大学,2010.

[14] Wan X, Wu Z. Improved speech source localization in reverberant environments based on correlation dimension[C]//International conference on wireless communications & signal processing. [s. l.]: IEEE, 2009: 1-4.

[15] Wan X, Wu Z. Sound source localization based on discrimination of cross-correlation functions[J]. Applied Acoustics, 2013, 74(1): 28-37.

[16] Dibiase J H. A high-accuracy, low-latency technique for talker localization in reverberant environments using microphone arrays[J]. European Journal of Biochemistry, 2010, 216(1): 281-291.