

基于核空间联合稀疏表示和指数平滑的 多基地水下小目标识别

王佳维^{1,2}, 许枫¹, 杨娟^{1*}

(1. 中国科学院声学研究所, 北京 100190; 2. 中国科学院大学, 北京 100049)

摘要: 针对多基地水下小目标分类识别问题, 本文提出了一种基于核空间联合稀疏表示和指数平滑的多基地水下小目标识别方法. 对水下目标多角度散射信号提取6种典型的具有信息互补性和关联性的特征, 提出一种随机森林(Random Forest, RF)和最小冗余最大相关(minimum Redundancy and Maximum Relevance, mRMR)相结合的特征选择方法(RF-mRMR), 得出综合的特征重要性排序结果. 通过实验得出分类模型所需的最优特征子集, 达到降低数据处理复杂度和提高目标分类结果的目的. 为了捕捉到数据中的高阶结构, 在联合稀疏表示模型的基础上, 使用核函数将线性不可分的特征数据映射到多维核特征空间. 为了充分挖掘稀疏重构后包含在残差波段中的有用信息, 使用指数平滑公式对具有一定意义的残差信息进行再利用, 最后由核特征空间下的最小误差准则判定目标的类别. 应用本文提出的方法对4类目标的海试数据进行识别, 结果表明, 相较于其他7种对比算法, 本文提出的改进方法具有更好的分类性能, 而且大多数情况下, 本文提出的算法在双基地声呐模式下具有比单基地声呐更高的识别准确率和更低的虚警率.

关键词: 多基地; 水下小目标识别; 多特征融合; 特征选择; 核空间联合稀疏表示; 指数平滑

基金项目: 国家重点研发计划(No.2018YFC0824103)

中图分类号: TB566; O427; P733.2; TP212 **文献标识码:** A **文章编号:** 0372-2112(2024)01-0217-15

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20220603

Multi-Static Underwater Small Target Recognition Based on Kernel Joint Sparse Representation and Exponential Smoothing

WANG Jia-wei^{1,2}, XU Feng¹, YANG Juan^{1*}

(1. Institute of Acoustics, Chinese Academy of Sciences, Beijing 100190, China;

2. University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: Aiming at the problem of multi-static underwater small target classification and recognition, a multi-static underwater small target recognition method based on joint sparse representation of kernel space and exponential smoothing is proposed. Six typical features with information complementarity and correlation are extracted from the multi angle scattering signals of underwater targets. A feature selection method (RF-mRMR) combining random forest (RF) and minimum redundancy maximum correlation (mRMR) is proposed to obtain the comprehensive feature importance ranking results. The optimal feature subset required by the classification model is obtained through experiments, so as to reduce the complexity of data processing and improve the result of target classification. In order to capture the high-order structure in the data, based on the joint sparse representation model, the kernel function is used to map the linearly indivisible feature data to the high-dimensional kernel feature space. In order to fully mine the useful information contained in the residual band after sparse reconstruction, the exponential smoothing formula is used to reuse the residual information with certain significance. Finally, the category of the target is determined by the minimum error criterion under the kernel feature space. The method proposed in this paper is applied to identify the sea trial data of four types of targets. The results show that the improved method has better classification performance than the other seven comparison algorithms in this paper. In most cas-

es, the proposed algorithm has higher recognition accuracy and lower false alarm rate than mono-static sonar in bistatic sonar mode.

Key words: multi-static; underwater small target recognition; multi-feature fusion; feature selection; kernel joint sparse representation; exponential smoothing

Foundation Item(s): National Key R&D Program of China (No.2018YFC0824103)

1 引言

近年来,水下小目标(如潜水员和水雷等)正在成为水下安全的重要威胁,因此水下小目标识别系统的研究具有重要的现实意义.以往多基于单基地声呐组网的模式对大范围水域进行安全保障工作,目标识别结果受姿态等因素影响较大,因为只利用了目标的后向散射信息.而多基地声呐组网探测系统可以同时利用目标的多角度散射信息,因此可以获得更加稳定的识别结果^[1].

目前,专门针对多基地水下小目标分类识别的研究较少.因此,参考有关雷达目标、水下似雷目标、侧扫声呐目标图像等多角度识别的文献是具有很大意义的.从文献中参考并可应用于多基地水下目标识别的方法分为三类:一是提取在多基地下目标的特殊特征进行分类识别;二是对多基地各个节点分别进行分类,并将分类结果融合,即基于决策级的数据融合方法;三是将多基地各个节点的特征分别提取出来,进行特征融合并分类,即基于特征级的数据融合方法.

在第一类多基地水下目标识别的方法中,如由于传统的双基地高距离分辨率剖面长度无法反映目标长度,Ai等人^[2]定义了一个新的长度:目标在双基地角平分线上的投影长度,对雷达目标进行分类识别.但此方法有两个缺点:一是建立的模型是基于一定假设进行的数学推导,复杂情况下的模型难以建立;二是只进行了电磁计算和动态仿真,在复杂的真实环境下模型不一定适用.

在应用数据融合思想提高目标分类识别效果的领域中,早期由于处理数据的维度和总量的增加受到计算机运算能力的限制,因此研究主要集中在基于决策层的数据融合方法.Dobeck^[3]提出基于模糊逻辑方法的决策级数据融合方法,对侧扫声呐多视角图像进行检测识别.Reed等人^[4]提出基于Dempster-Shafer证据理论的决策级融合方法,对侧扫声呐探测到的多视角海底似雷目标图像进行分类.严科伟等人^[5]将舰船辐射噪声的DEMON谱线谱和DEMON谱连续谱这两种谱信息输入到多神经网络分类识别器,并对输出向量基于加权投票表决规则进行目标分类识别.Huan等人^[6]在决策层应用加权贝叶斯决策融合算法融合分类器的结果,对多角度合成孔径雷达图像

进行识别.

决策层可融合信息少,而且忽视了各节点之间的相关性^[7],因此从信息利用的角度来说无法达到最优的识别性能.而特征层能够保留更多原始信息,并且可以充分利用各节点之间的互补性,充分发挥特征融合分类器本身的优势,在这个层次进行融合是目前最优的选择^[8].基于特征级的数据融合方法有两类:一是提取多基地的单一特征进行融合,二是提取多基地的多特征进行融合.其中,后者融合多种不同类型的特征信息,在多视角下表现出良好的鲁棒性,因此较前者有显著的性能改进^[9-11].

在基于特征级的数据融合方法中,侯平魁等人^[12]提取水下目标回波信号中体现目标丰富信息的多特征矢量,应用模糊融合分类器进行特征层融合.赵自璐等人^[9]提出一种水下冲激噪声环境下的多特征融合的信号调制方式识别方法,应用SVM对三种特征进行融合,进而对调制方式进行识别.温涛等人^[13]利用RELAX算法提取了多视角下的目标散射点回波强度信息以及散射点沿距离像分布的位置信息,利用连续隐马尔科夫模型融合多视角特征数据实现多基地水下目标识别.Pei等人^[14]针对合成孔径雷达自动目标识别,提出一种包含多输入并行拓扑结构的深度卷积神经网络,以及一种端到端的深度特征提取与融合网络^[15],将每个视图中提取的特征进行融合,有效地利用多视角的识别信息,提高目标识别性能.

除以上特征融合方法外,常见的方法还有基于稀疏表示理论的特征融合算法,其通常与最优理论相结合,将特征融合问题转化为优化问题,通过求解多特征的稀疏表示系数达到多特征融合的目的^[16].应用稀疏表示方法对多角度数据提取的多特征进行融合在其他领域有广泛应用,如多视角合成孔径雷达图像识别^[17]、多视角步态识别^[10]、多传感器人类和动物的足迹识别^[8]、多传感器瞬态声学数据分类^[11,18]等,但是目前在多基地水下目标识别研究中没有应用到稀疏表示类方法.

近年来,表示型算法得到了广泛的应用,并且不断涌现出多种改进算法.联合稀疏表示分类(Joint Sparse Representation-based Classification, JSRC)算法^[19]基于联合稀疏性的假设.相较于稀疏表示分类(Sparse Representation-based Classification, SRC)算法^[19],JSRC

算法能够同时得到多个观测值的稀疏表示,充分利用多视角或多传感器之间的相关性,因此可以获得比前者更好的分类性能^[19,20]. 而且在遮挡、尺度、光照、姿态等外观变化下,基于 JSRC 算法的特征融合视觉跟踪器的性能要优于基于 SRC 算法等 10 余种算法的特征融合跟踪器的性能,对外界环境变化具有较高的鲁棒性^[21].

作为 SRC 和 JSRC 算法的延伸,基于核空间稀疏表示分类 (Kernel Sparse Representation-based Classification, KSRC) 的算法^[22]和基于核空间联合稀疏表示分类 (Kernel Joint Sparse Representation-based Classification, KJSRC) 的算法^[11]通过核函数将线性不可分的数据映射到高维核特征空间,隐式地利用了线性模型无法捕捉到的数据中的高阶结构,提高了算法的分类性能.

Dao 等人^[18]对由 4 个声学传感器在迫击炮和火箭的发射和撞击期间收集的瞬态声学数据进行分类,提取信号的倒谱系数特征,提出了一个通用的多传感器联合稀疏表示框架,进一步将框架扩展到核化模型. 该模型在由核函数诱导生成的特征空间中,依赖所有训练样本对测试样本的稀疏表示进行分类. 在几个真实的多传感器数据集上进行了大量实验. 结果表明,核函数对特征空间中的分类产生了非常大的性能改进. 在此基础上,Dao 等人^[11]提取三种不同特征,并对三种特征进行融合分类. 实验结果表明,该方法优于传统分类器、深度神经网络和深度置信网络,原因可能是某些训练集的限制性和缺乏多样性,而且结果证明多种声学特性的组合可以产生显著的性能改进.

多基地水下小目标识别问题的核心是特征选取和分类器的设计. 以上是分类器的分析,接下来介绍常用的水下目标特征. 高阶谱 (Higher Order Spectra, HOS) 特征是一种典型的平移不变特征,对平移、旋转和缩放具有不变性,因此对检测位于原始数据中任意位置和任意大小的对象都非常有用,而且 HOS 特征对加性高斯噪声不敏感. 若是可以获得同一个目标的多组数据,该特征会有更好的应用前景^[23]. 双谱作为阶数最低的高阶谱,在应用中,常选取其对角切片作为特征量^[1].

中心矩特征^[24]既是一种常用的平移不变特征,也是一种典型的波形结构特征,含有目标的形状尺度信息^[25]. 相较于高阶谱特征,中心矩特征具有明确的物理含义,缺点是对波形变化比较敏感.

Relax 算法是一种可以用来提取散射点模型的真实参数的非线性最小二乘松弛算法,可以从加性色噪声中估计正弦信号的幅度和频率^[26],也可以理解为目标散射点的回波强度信息和沿距离像分布的位置信

息^[13]. 形状相同而材料不同的目标具有不同的形态函数和不同的频率特性,因此可以将目标的频率特性作为目标识别的重要依据^[27]. 因此,Relax 算法提取的散射点强度特征包含几何信息;散射点位置特征既包含几何信息,又包含材料信息.

金磊磊等人^[28]通过实测数据验证了小波变换特征对水下材料分类的可行性. 小波包分析是一种比小波分析更精细的正交分解方法,可以把信号按照任意时频分辨率,不重叠、无泄漏地分解到不同频段,各频带内的能量元素构成的特征向量即为小波包能量谱特征,因此小波包能量谱特征^[29]可以提高不同材料目标的分类准确率.

研究表明,声呐操作员分辨水下声音的方式,与人耳识别语音的方式相同. 因此,听觉特征也被广泛应用于水下目标分类^[30,31],希尔伯特-黄变换 (Hilbert-Huang Transform, HHT)^[32]是一种信号分析方法,能够在对信号整体分解的同时兼顾信号的局部性,常被应用于语音信号特征提取. 李秀坤等人^[31]研究发现,应用希尔伯特-黄变换提取的希尔伯特边际谱特征,不仅可以有效地提取目标的弹性亮点特征,还可以有效抑制混响. 实验证明,此方法比频域离散小波变换具有更好的分辨力.

由于目前国内外没有将稀疏表示类模型应用在多基地水下目标分类识别领域的先例,基于以上分析,本文首先对水下目标多角度散射信号提取 6 种典型的具有信息互补性和关联性的特征,其次提出了一种随机森林 (Random Forest, RF)^[33]和最小冗余最大相关 (minimum Redundancy and Maximum Relevance, mRMR)^[34]相结合的特征选择方法 (RF-mRMR),得出综合的特征重要性排序结果. 通过实验得出分类模型所需的最优特征子集,达到降低数据处理复杂度和提高目标分类识别结果的目的. 然后本文将压缩采样匹配追踪 (Compressive Sampling Matching Pursuit, CoSaMP) 算法^[29]扩展得到多视角下的压缩采样匹配追踪算法,并将该框架扩展到核化模型. 在此基础上,参考自适应 boosting 的思想,使用指数平滑公式对稀疏重构后的残差信息进行充分挖掘,达到提高数据集稳定度的目的,进而提出了一种基于核空间联合稀疏表示和指数平滑的多基地水下目标识别方法. 最后,应用核特征空间下的最小误差准则判定目标所属类别.

2 核空间联合稀疏表示和指数平滑

JSRC 算法可以在同一框架下对具有统计相关性的多个观测值进行重构,提高多个观测值的联合表征精度,在多视角合成孔径雷达自动目标识别^[20]、多观测声学信号分类^[19]等领域,其分类性能优于 SRC 算法、SVM

算法和逻辑回归算法等。作为 JSRC 算法的改进, KJSRC 算法分类性能优于传统分类器、深度神经网络和深度置信网络。实验证明,核函数对特征空间中的分类有很大的性能改进^[11,18]。因此,本文提出了一种基于核空间联合稀疏表示和指数平滑的多基地水下目标识别方法。该方法在由核函数诱导的高维特征空间中,依赖未知样本相对于目标训练样本的稀疏表示进行目标检测。

假设目标训练样本库中目标类别总数为 C ,多视观测数目为 M ,则第 $m(m=1,2,\dots,M)$ 个观测视角对应的字典矩阵为 $\mathbf{A}^m \in \mathbb{R}^{b \times N}$,测试样本 $\mathbf{y}^m \in \mathbb{R}^{b \times 1}$, n_c 为类内样本总数, $N = \sum_{c=1}^C n_c$ 为训练样本总数, b 为样本维数。

当训练样本充足时,测试样本可以由与测试样本所属同一目标类别的训练样本集进行线性表示^[29],即

$$\mathbf{y}^m = \mathbf{A}_c^m \mathbf{w}_c^m \quad (1)$$

此处,假设 \mathbf{y}^m 为第 $c(c=1,2,\dots,C)$ 类目标的第 m 个视角所对应的测试样本, \mathbf{A}_c^m 为第 c 类目标的第 m 个观测视角的训练样本集, \mathbf{w}_c^m 为 \mathbf{y}^m 在训练样本集 \mathbf{A}_c^m 上对应的系数向量。

在实际应用中,由于不能分辨测试样本的所属类别,对式(1)进行改写,得到独立观察的情况下各视角的稀疏表示问题,即

$$\mathbf{y}^m = \mathbf{A}^m \mathbf{w}^m \quad (2)$$

即用第 m 个观测视角所对应的所有目标类别的训练样本线性表示 \mathbf{y}^m ,其中, $\mathbf{A}^m = [\mathbf{A}_1^m, \mathbf{A}_2^m, \dots, \mathbf{A}_C^m]$, \mathbf{w}^m 对应 \mathbf{y}^m 在 \mathbf{A}^m 上的系数向量。在理想情况下, \mathbf{w}^m 的非零值应该全部与第 c 类目标相对应,即 $\mathbf{w}^m = [0; \dots; \mathbf{w}_c^m; \dots; 0]$ 。

将不同视角的稀疏表示系数改写为矩阵的形式 $\mathbf{W} = [\mathbf{w}^1, \dots, \mathbf{w}^m, \dots, \mathbf{w}^M]$,则综合考察各个观测视角的重构优化目标函数为

$$\min_{\mathbf{W}} \left\{ g(\mathbf{W}) = \sum_{m=1}^M \|\mathbf{y}^m - \mathbf{A}^m \mathbf{w}^m\| \right\} \quad (3)$$

其中,重构优化目标函数等效于对各个观测视角进行独立的重构。由于同一目标的多个观测视角存在相关性,因此式(3)的这种独立重构获得的结果往往不是最优的。为此,引入联合稀疏表示算法中的混合范数约束对稀疏表示系数矩阵 \mathbf{W} 的字典原子分布进行约束。常见的混合范数约束有 $l_{1,2}$ 和 $l_{0,2}$ 范数。在多任务联合学习中, $l_{0,2}$ 范数可以获得比 $l_{1,2}$ 更加稀疏的矩阵结构,往往具有更高的分类性能^[29]。因此,本文采用 $l_{0,2}$ 范数对系数矩阵 \mathbf{W} 进行约束,即

$$\begin{aligned} \hat{\mathbf{W}}_{\text{JSRC}} &= \arg \min_{\mathbf{W}} \sum_{m=1}^M \|\mathbf{y}^m - \mathbf{A}^m \mathbf{w}^m\| \\ \text{s.t. } &\|\mathbf{W}\|_{0,2} \leq K \end{aligned} \quad (4)$$

其中, K 是稀疏度。

本文在获得稀疏矩阵 \mathbf{W} 的最优估计值 $\hat{\mathbf{W}}$ 后,将依据最小误差准则计算测试样本划分为不同目标类别时对应的重构误差,测试样本所属类别为总重构误差最小的目标类别,最小误差准则^[29]为

$$\hat{c} = \arg \min_{c \in \{1,2,\dots,C\}} \sum_{m=1}^M \|\mathbf{y}^m - \mathbf{A}^m \delta_c(\hat{\mathbf{w}}_{\text{JSRC}}^m)\|_2^2 \quad (5)$$

其中, $\delta_c(\hat{\mathbf{w}}^m)$ 表示稀疏向量 $\hat{\mathbf{w}}^m$ 除了属于第 c 类目标对应的系数以外,其他系数置为 0。

核方法可以在一定程度上提高算法的分类性能,原因是其提供了线性空间到非线性空间的映射,可以利用特征空间中数据的非线性。对于训练样本 \mathbf{A} 和测试样本 \mathbf{y} ,应用非线性映射函数 $\phi(x)$ 将其映射到高维核特征空间,根据高维特征空间中测试样本相对于训练样本的稀疏表示对目标进行检测。

非线性映射函数 $\phi(x)$ 不容易确定,在不明确 $\phi(x)$ 的具体形识下,可以通过核技巧的应用,使用 Mercer 内核 $k(\cdot, \cdot)$ 来获得高维核特征空间中的映射数据。设 $\langle a_1, a_2 \rangle$ 表示 a_1 与 a_2 的内积,则 Mercer 核 $k(x_1, x_2)$ ^[18] 的定义如下:

$$k(x_1, x_2) = \langle \phi(x_1), \phi(x_2) \rangle \quad (6)$$

常见的核函数有高斯核、多项式核、线性核、Sigmoid 核等。其中,高斯核^[18](也称径向基函数)能把原始特征数据映射到无穷维特征空间,具有较强的局部性和抗干扰能力,是目前应用最广泛的核函数,其定义如下:

$$k(x_1, x_2) = \exp(-\gamma \|x_1 - x_2\|_2^2) \quad (7)$$

其中,参数 γ 用于控制径向基函数的宽度, $\gamma = \frac{1}{N} \sum_{i=1}^N \frac{1}{\|\mathbf{A}_i - \bar{\mathbf{A}}\|_2^2}$, $\bar{\mathbf{A}}$ 是所有训练样本的平均值^[35],对本文

实验数据分析,参数 $\gamma = 0.307$ 。对式(4)进行改进,得到经过非线性映射函数 $\phi(x)$ 映射后的核空间 JSRC 算法,即

$$\begin{aligned} \hat{\mathbf{W}}_{\text{KJSRC}} &= \arg \min_{\mathbf{W}} \sum_{m=1}^M \|\phi(\mathbf{y}^m) - \phi(\mathbf{A}^m) \mathbf{w}^m\| \\ \text{s.t. } &\|\mathbf{W}\|_{0,2} \leq K \end{aligned} \quad (8)$$

其中, $\phi(\mathbf{y}^m)$ 和 $\phi(\mathbf{A}^m)$ 分别是第 m 个观测视角下的测试样本和训练样本在核特征空间中的映射,由于 $\phi(\mathbf{y}^m)$ 和 $\phi(\mathbf{A}^m)$ 不确定,故式(8)中的稀疏表示矩阵不可直接求得,通过应用核技巧,将式(8)转化为

$$\begin{aligned} \hat{\mathbf{W}}_{\text{KJSRC}} &= \arg \min_{\mathbf{W}} \sum_{m=1}^M \|\phi(\mathbf{A}^m)^T \phi(\mathbf{y}^m) - \phi(\mathbf{A}^m)^T \phi(\mathbf{A}^m) \mathbf{w}^m\| \\ \text{s.t. } &\|\mathbf{W}\|_{0,2} \leq K \end{aligned} \quad (9)$$

其中, $\phi(\mathbf{A}^m)^\top \phi(\mathbf{y}^m) = k(\mathbf{A}^m, \mathbf{y}^m) = (k(\mathbf{A}_{11}^m, \mathbf{y}^m), k(\mathbf{A}_{12}^m, \mathbf{y}^m), \dots, k(\mathbf{A}_{c_n}^m, \mathbf{y}^m))^\top \in \mathbb{R}^{N \times 1}$ 是字典矩阵 \mathbf{A}^m 中各原子与测试样本 \mathbf{y}^m 的核函数值组成的向量, $\phi(\mathbf{A}^m)^\top \phi(\mathbf{A}^m) = k(\mathbf{A}^m, \mathbf{A}^m) \in \mathbb{R}^{N \times N}$ 是字典矩阵 \mathbf{A}^m 中各原子间的核函数值组成的矩阵, 则式(9)可以转化为核函数形式, 即

$$\hat{\mathbf{W}}_{\text{KJSRC}} = \arg \min_{\mathbf{w}} \sum_{m=1}^M \left\| k(\mathbf{A}^m, \mathbf{y}^m) - k(\mathbf{A}^m, \mathbf{A}^m) \mathbf{w}^m \right\| \quad (10)$$

s.t. $\|\mathbf{W}\|_{0,2} \leq K$

本文对压缩采样匹配追踪算法^[29]进行改进, 得到指数平滑后的核空间多视角压缩采样匹配追踪 (Exponential Smoothing Kernel Multi-View Compressive Sampling Matching Pursuit, ESKMV-CoSaMP) 算法, 并应用 ESKMV-CoSaMP 算法求解式(10), 得到稀疏表示矩阵的最优估计值。

与式(10)相对应的分类器为由式(5)改写的核特征空间下的最小误差准则:

$$\hat{c} = \arg \min_{c \in \{1, 2, \dots, C\}} \sum_{m=1}^M \left\| k(\mathbf{A}^m, \mathbf{y}^m) - k(\mathbf{A}^m, \mathbf{A}^m) \delta_c(\hat{\mathbf{w}}_{\text{KJSRC}}^m) \right\|_2^2 \quad (11)$$

参考自适应 boosting 的思想, 在算法每一次迭代过程中, 将本次残差和上一次指数平滑后的残差采用指数平滑法进行叠加, 以便充分挖掘应用 ESKMV-CoSaMP 算法进行稀疏重构后的残差波段中的有用信息, 每次叠加后产生的新波段特征包含更多有用信息并且更加稳定, 指数平滑法表达式如下:

$$S_t = \alpha y_t + (1 - \alpha) \cdot S_{t-1} \quad (12)$$

其中, S_t 是第 t 期指数平滑值; S_{t-1} 是第 $t-1$ 期指数平滑值; y_t 是第 t 期的实际值; α ($0 < \alpha < 1$) 是平滑系数。

ESKMV-CoSaMP 算法如算法 1 所示。

基于核空间联合稀疏表示和指数平滑 (Exponential Smoothing Kernel Joint Sparse Representation-based Classification, ESKJSRC) 的多基地水下目标识别方法具体步骤如算法 2 所示。

3 数据预处理、特征提取和特征选择

3.1 数据预处理

高分辨一维距离像 (High Range Resolution Profile, HRRP) 反映了目标在一定的声呐视角内的分布特性, 包含了目标的尺寸、形状、材料等特征信息^[1], 对目标的分类和识别具有重要意义。

同一个目标的散射信号幅度在不同的观测条件下可能会有很大差异, 这就是强度敏感性, 解决办法通常是舍弃绝对强度信息, 只利用相对强度信息。消除强度

算法 1 ESKMV-CoSaMP 算法

输入: 字典矩阵 \mathbf{A}^m 中各原子与测试样本 \mathbf{y}^m 的核函数值组成的向量 $k(\mathbf{A}^m, \mathbf{y}^m) \in \mathbb{R}^{N \times 1}$, 字典矩阵 \mathbf{A}^m 中各原子间的核函数值组成的矩阵 $k(\mathbf{A}^m, \mathbf{A}^m) \in \mathbb{R}^{N \times N}$, 稀疏度参数 $K=100$, 平滑指数 $\alpha=0.3$, 其中, $m=1, 2, \dots, M$ (M 为多视观测数目), N 为训练样本的总数

输出: 核空间联合稀疏表示矩阵最优估计值 $\hat{\mathbf{W}}$

1. 初始化: $\mathbf{w}_{(0)}^m = \mathbf{0}$, $\mathbf{S}_{(0)}^m = \mathbf{r}_{(0)}^m = k(\mathbf{A}^m, \mathbf{y}^m)$, $\mathbf{E} = [\mathbf{e}^1, \dots, \mathbf{e}^m, \dots, \mathbf{e}^M] = \mathbf{0}$, $\mathbf{u} = [u_1; \dots; u_n; \dots; u_N] = \mathbf{0}$, $n=1, \dots, N$, $\Omega = \emptyset$, $t=0$

2. 计算当前估计误差在字典矩阵上的投影: $\mathbf{e}^m = (k(\mathbf{A}^m, \mathbf{A}^m))^\top \mathbf{S}^m$, 则 $\mathbf{E} = [\mathbf{e}^1, \dots, \mathbf{e}^m, \dots, \mathbf{e}^M]$, 令 $u_n = \|\mathbf{E}(n, :)\|_2^2$, 则 $\mathbf{u} = [u_1; \dots; u_n; \dots; u_N]$

3. 根据投影向量估计支撑集: $\Omega_{\text{res}} = \text{supp}(\mathbf{u}, K)$

4. 合并最近两次迭代的支撑集: $\Omega = \Omega \cup \Omega_{\text{res}}$

5. 根据新的支撑集估计系数:

$$\hat{\mathbf{w}}^m = \left[(k(\mathbf{A}^m, \mathbf{A}^m))_{\Omega}^\top (k(\mathbf{A}^m, \mathbf{A}^m))_{\Omega} \right]^{-1} (k(\mathbf{A}^m, \mathbf{A}^m))_{\Omega}^\top k(\mathbf{A}^m, \mathbf{y}^m)_{\Omega}$$

$$\hat{\mathbf{W}} = [\hat{\mathbf{w}}^1, \dots, \hat{\mathbf{w}}^m, \dots, \hat{\mathbf{w}}^M]$$

6. 根据估计系数估计新的支撑集: $v_i = \|\hat{\mathbf{W}}(i, :)\|_2^2$,

$$\mathbf{v} = [v_1; \dots; v_i; \dots; v_{i_{\max}}], (2K \leq i_{\max} \leq 3K), \Omega = \text{supp}(\mathbf{v}, K)$$

7. 令 $\mathbf{W}_{(t)} = \hat{\mathbf{W}}_{(t)}$, 其中, $\mathbf{W}_{(t)} = [\mathbf{w}_{(t)}^1, \dots, \mathbf{w}_{(t)}^m, \dots, \mathbf{w}_{(t)}^M]$

8. 计算残差: $\mathbf{r}_{(t+1)}^m = k(\mathbf{A}^m, \mathbf{y}^m) - k(\mathbf{A}^m, \mathbf{A}^m) \mathbf{w}_{(t)}^m$, 将本次残差和上一次指数平滑后的残差采用指数平滑法进行叠加 $\mathbf{S}_{(t+1)}^m = \alpha \mathbf{r}_{(t+1)}^m + (1 - \alpha) \mathbf{S}_{(t)}^m$

9. 令 $t=t+1$, 在步骤(2)-(9)之间迭代, 直至满足循环停止条件

10. 输出 $\hat{\mathbf{W}} = \mathbf{W}_{(t)}$

算法 2 基于 ESKJSRC 算法的多基地水下目标识别方法

输入: 多观测视角对应的字典矩阵 $\mathbf{A}^m \in \mathbb{R}^{b \times N}$, 测试样本 $\mathbf{y}^m \in \mathbb{R}^{b \times 1}$, 稀疏度参数 $K=100$, 平滑指数 $\alpha=0.3$, 核函数 k , 其中, $m=1, 2, \dots, M$ (M 为多视观测数目), $c=1, 2, \dots, C$ (C 为目标类别总数)

输出: 测试样本所属目标类别

1. 通过高斯核函数计算 $k(\mathbf{A}^m, \mathbf{y}^m) \in \mathbb{R}^{N \times 1}$, $k(\mathbf{A}^m, \mathbf{A}^m) \in \mathbb{R}^{N \times N}$

2. 使用算法 1 中的 ESKMV-CoSaMP 算法求解式(10), 得到核空间联合稀疏表示矩阵的最优估计值 $\hat{\mathbf{W}}_{\text{KJSRC}}$

3. 根据式(11)计算测试样本被划分为第 c 类目标时所对应的重构误差 $r_c = \sum_{m=1}^M \left\| k(\mathbf{A}_c^m, \mathbf{y}_c^m) - k(\mathbf{A}_c^m, \mathbf{A}_c^m) \delta_c(\hat{\mathbf{w}}_{\text{KJSRC}}^m) \right\|_2^2$

4. 根据核特征空间下的最小误差准则, 具有最小总重构误差的目标类别即为待测样本所属类别, 即 $\hat{c} = \arg \min_{c \in \{1, 2, \dots, C\}} r_c$

敏感性的方法有利用一些准则对信号进行归一化处理 and 搜索最优幅度匹配因子等^[36], 本文选择利用能量 (I_2 范数) 归一化^[37] 消除强度敏感性。

HRRP 是应用距离窗对声呐接收到的目标散射信号进行截取得到的, 这就导致截取的散射信号在距离窗口中存在未知的相对位移, 真实的散射信号在距离窗中发生平移, 这种现象就是平移敏感性。消除平移敏

感性的方法主要有按照一定的准则进行平移搜索,将距离像平移对准(相对对齐法、绝对对齐法)和提取平移不变特征.相较于相对对齐法,绝对对齐法虽然精度较低,但是大大减少了计算量.因此,在预处理阶段本文选择绝对对齐法中的重心法^[38]消除平移敏感性.

3.2 特征提取

为消除平移敏感性,本文在特征提取时,首先提取平移不变特征——双谱对角切片特征、中心矩特征.

水下目标回波中包含的信息主要分为三类:几何信息、运动信息和材料信息.几何信息包括目标的尺度形状等,材料信息包括目标的纵波速度、横波速度、密度等^[39].本文目标运动幅度较小,故不考虑运动信息.为提取几何信息,本文选择以下特征:中心矩特征、散射点强度特征、散射点位置特征.为提取材料信息,本文选择以下特征:散射点位置特征、小波包能量谱特征.

综上所述,本文提取特征分别为:双谱对角切片特征、中心矩特征、散射点强度特征(正弦波幅度信息)、散射点位置特征(正弦波频率信息)、小波包能量谱特征、希尔伯特边际谱特征.

3.3 特征选择

根据特征选择和分类器之间的关系,特征选择方法可分为过滤式、包裹式和嵌入式^[40].过滤式方法基于特征的通用表现进行选择,如目标相关性、自相关性和发散性等.特征选择和分类器的学习是两个独立的过

程,优点是具有较好的搜索速率和通用性,缺点是忽略了特征选择和分类算法之间的相互作用,如Relief算法、相关性测量法、mRMR算法等.包裹式方法中分类算法将给定特征集的分类效果反馈给特征选择环节,以便改进特征集,以分类器的分类表现为优化目标,选择出的特征对分类器有很好的适应性.优点是往往能够获得较高的分类精度,缺点是没有考虑到特征之间的冗余性,容易发生过拟合,降低算法的泛化能力,如线性判别、随机森林、前向搜索、后向搜索、支持向量机等.嵌入式方法中特征选择和分类算法同步实现,然而目前嵌入式方法的实现往往采用一阶正则化模型,不适用于处理非线性问题,因此该方法的实际使用范围受到限制^[40].

单一的特征选择方法不能同时考虑到降低特征之间的冗余性,以及筛选出能够提高分类精度的特征,如mRMR算法无法体现不同特征对分类效果的差异,RF算法没有考虑特征之间存在的冗余性.因此,本文提出将RF和mRMR相结合的特征选择方法RF-mRMR.结合两种特征选择方法得出最终的特征重要性排序结果,根据排序对从第1个到第*i*个特征所构成的特征子集逐个进行实验测试,然后选择识别效果最好的一组特征作为最优特征子集.

综上所述,基于核空间联合稀疏表示和指数平滑的多基地水下目标识别方法流程图如图1所示.

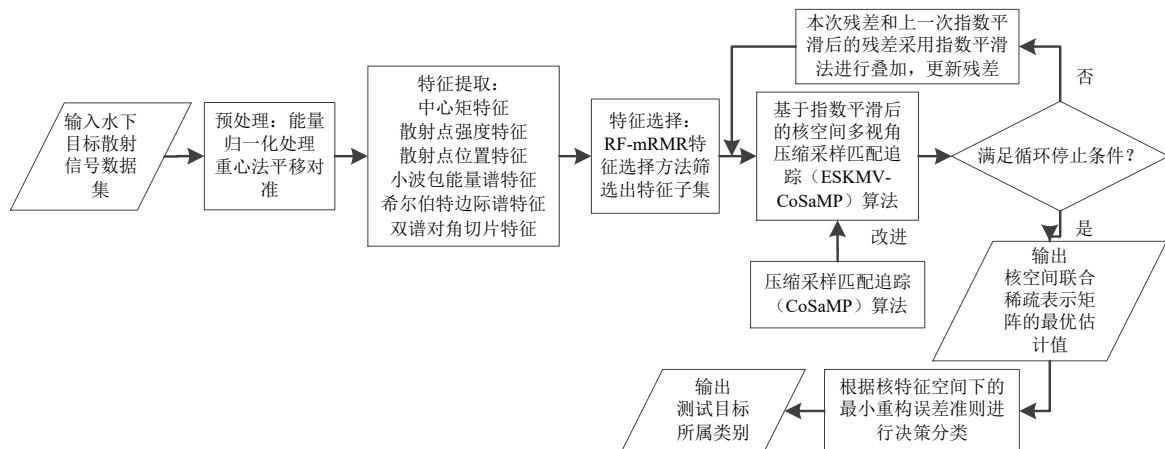


图1 基于核空间联合稀疏表示和指数平滑的多基地水下目标识别方法流程图

4 实验及结果分析

4.1 实验设计

2020年10月30日,在江苏省某海域进行双基地水下小目标识别实验,实验布局示意图如图2所示.码头附近海域水深约10 m(水面起伏在8~12 m),两套收发合置声呐设备采用壁挂架子,固定布放在东、西码头池壁,间距约90 m,声呐入水深度约5 m,探测目标距离东

西两套声呐100~130 m.本文使用的是中国科学院声学研究所研制的蛙人探测声呐,具有水下小目标自动探测、跟踪、识别及报警等功能.在声呐系统采集实验数据时间内,探测目标在水流作用下有轻微的运动,目标的姿态随时间发生变化.

多基地声呐系统的工作模式为系统中一部或多部大功率声源发出声波监测海域,部署在不同基地的声

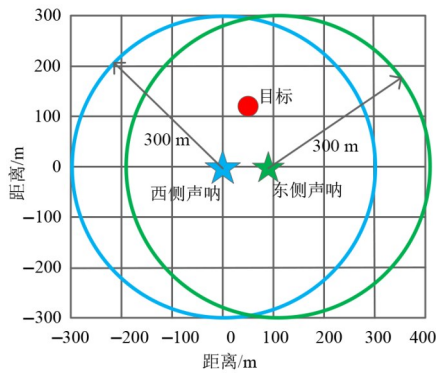


图2 实验现场布局示意图

采用被动监听模式接收目标的散射信号,双基地声

呐系统是多基地声呐系统中最简单的一种^[13]. 本文中的双基地声呐系统工作模式为西侧声呐发射信号,西侧和东侧声呐同时接收信号,以及东侧声呐发射信号,西侧和东侧声呐同时接收信号. 与之进行对比的单基地声呐系统工作模式分别为东侧声呐收发一体和西侧声呐收发一体.

本文发射信号为 LFM 信号,数据处理过程中对声呐接收的原始带通信号进行带通采样. 4 类目标分别为:圆柱桶子长 2.1 m,直径 0.6 m;注水圆球直径 0.39 m;圆台上直径 0.5 m,下直径 1 m,高 0.5 m;携带开放式呼吸器的蛙人,实验目标如图 3 所示.

双基地声呐系统探测 4 类目标得到的声呐图像如图 4 所示,海试实验的信噪比为 5 dB 左右.



(a) 圆柱桶子



(b) 注水圆球



(c) 圆台



(d) 携带开放式呼吸器的蛙人

图3 实验目标

本文中算法的设计和分析是在 MATLAB 环境下完成的, CPU 是英特尔 i5-6200 U, 主频是 2.3 GHz, 内存是 8 GB. 4 类目标的样本库中分别有 200 组实验数据, 本文中的实验结果为 30 次结果的平均值, 每次数据分析均是从 4 类目标的样本库中随机抽取 100 组作为训练数据, 另外 100 组作为测试数据.

为了检验本文所提方法的有效性, 选取 K 最近邻 (K-Nearest Neighbor, KNN) 分类算法^[41]、SVM (Support Vector Machine) 算法^[42]、SRC 算法^[29]、卷积神经网络

(Convolutional Neural Networks, CNN) 算法^[43]、逻辑回归 (Logistic Regression, LR) 算法^[44]、基于 $l_{0,2}$ 范数约束的 JSRC 算法^[19,29]. 6 种常见分类算法与本文所提算法进行对比, 为更加详细地说明核函数和指数平滑的作用, 增加没有指数平滑的本文算法, 即基于 $l_{0,2}$ 范数约束的 KJSRC 算法进行对比.

4.2 特征提取参数设置

对东西两侧声呐的一维距离像的包络计算双谱, 本文采样率 $f_s = 21.33$ kHz, FFT 点数 $N = 128$, 则频域分

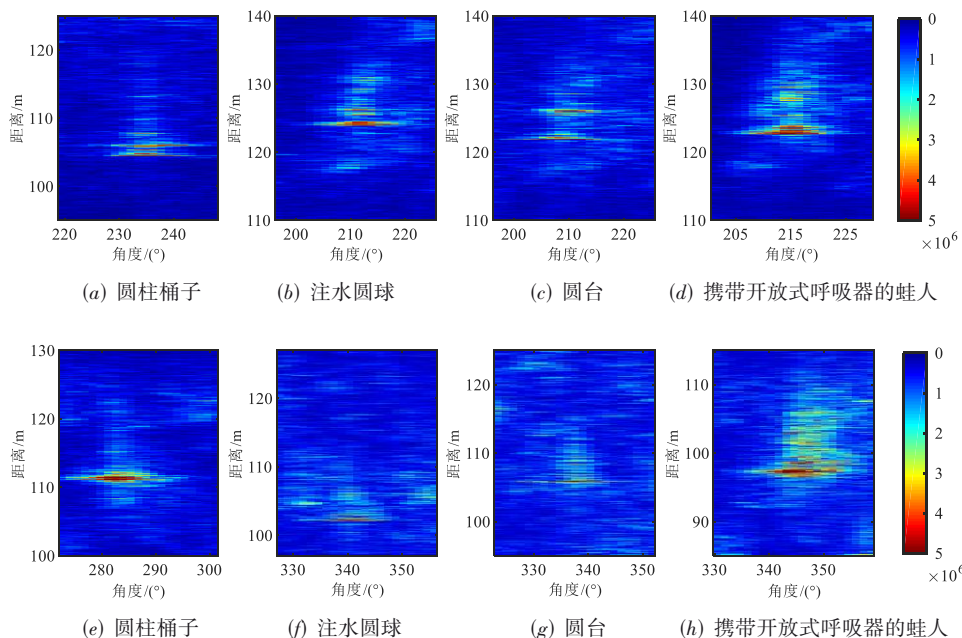


图4 4类目标的声呐探测图像,(a)~(d)为东侧声呐图像,(e)~(h)为西侧声呐图像

分辨率 $\Delta f = f_s/N = 167$ Hz,对四类目标计算双谱并画图,发现双谱主要集中在 0~2 100 Hz,则对应的点数 $M = 2\ 100/\Delta f = 12.6$,取 $M = 13$,提取这一部分的双谱对角切片,得到4类目标的一维距离像双谱对角切片特征。

本文的高阶中心矩以一阶原点矩为参照,取2~3阶中心矩作为中心矩特征向量。

通过4类目标的散射信号计算散射点强度和位置特征。结果表明,当均选取10个强散射点进行特征提取时,可以较好地兼顾特征的有效性和计算复杂度,此时声呐接收的目标散射信号可以看作10个复正弦信号的叠加。本文中散射点强度特征维数为10,分别指10

个散射点的散射强度;散射点位置特征维数为10,分别指10个散射点与参考点的距离。

本文信号的小波包分解层数为4层,计算第4层的16个频段信号对应的能量特征序列,即为小波包能量谱特征。

计算希尔伯特边际谱特征时,各类目标散射信号经验模态分解后得到8~11阶本征模态函数。从目标散射信号的边际谱图可以看出,该信号的高频分量较弱,低频分量较强,信号能量主要分布在前200 Hz,因此取边际谱的前17维代表边际谱特征。

本文提取的6种特征如表1所示。

表1 特征提取

特征名称	特征类型	特征维数	特征序号范围
中心矩特征	平移不变特征、几何特征	2	1~2
散射点强度特征(正弦波幅度信息)	几何特征	10	3~12
散射点位置特征(正弦波频率信息)	几何特征、材料特征	10	13~22
小波包能量谱特征	材料特征	16	23~38
希尔伯特边际谱特征	听觉特征	17	39~55
双谱对角切片特征	平移不变特征	13	56~68

4.3 RF-mRMR 特征选择方法

mRMR^[34]特征选择算法通过最大化特征与类变量之间的相关性和最小化特征之间的冗余性来对特征进行选择,本文中应用mRMR算法对68个特征进行排序,得到归一化后的特征重要性排序,如图5中蓝色柱状图所示。

在特征子集中抽取2/3例样本做随机森林分类,得

到68个特征的重要程度排序,重要程度用平均基尼(Gini)指数下降程度^[33]进行评估,该值越大表示该特征越重要,越能够提高分类精度。平均Gini指数下降程度评价特征的重要性依据的是每个特征对分类树每个节点上的观测值的异质性的影响,归一化后的平均Gini指数下降程度如图5中红色柱状图所示。

由于两类特征选择方法得到的特征重要性量纲相




图5 特征重要性排序图

同,因此将二者归一化后的结果相加求和^[33],即为本文提出的RF-mRMR特征选择方法,得到各特征重要性排序最终结果,如图5所示。

在图5各特征重要性排序最终结果的基础上,需要进行特征筛选选择出分类算法对应的最优特征子集。本文将根据排序对从第1个到第*i*个特征所构成的特征子集逐个进行实验测试,选择识别效果最好的一组特征作为最优特征子集。为了找到合适的特征数量*i*,需要比较不同的*i*值对分类算法的AUC(Area Under Curve)值的影响。取对应*i*值的30个AUC值的平

均值作为各个分类算法的最终AUC值。分析结果如图6所示,横轴是每个基地的特征数量,纵轴是双基地的AUC值。此处,每个基地的特征选择序列是一样的,双基地分类结果是依据两个基地下同样的特征序列得到的。

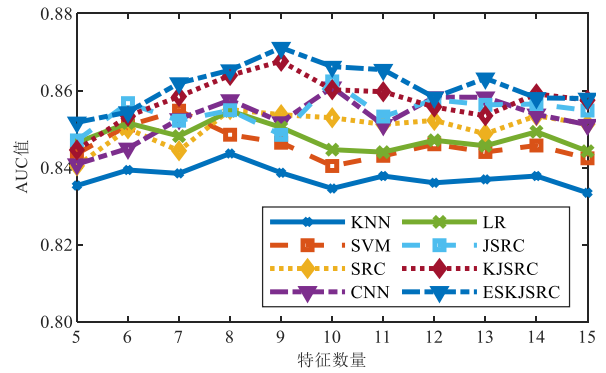


图6 特征数量对各个分类算法的AUC值的影响

以本文算法为例,由图6可以看出,当特征数量*i*为9时,本文算法的双基地AUC值最大,重要性排序前9的特征包括中心矩特征2维、散射点强度特征2维、散射点位置特征5维。因此,本文算法的最优特征子集包括:中心矩特征中的二阶中心矩和三阶中心矩;散射点强度特征中第1和第10个散射点的强度特征;散射点位置特征中前5个散射点的位置特征,即前5个散射点对应的正弦信号的频率。以上这三类特征包含目标的几何特征、材料特征和平移不变特征。

由图5可以看出,三阶中心矩特征以及第1个和第10个散射点的强度特征重要性排序占据前三,原因是这三个特征不仅特征与类变量之间的相关性高,特征间冗余性少(图5中蓝色柱状图所示),而且能提高分类精度(图5中红色柱状图所示),是综合了mRMR算法和RF算法的长处而被选择出来的特征。其余的6维特征被选中的主要原因是能提高分类精度(图5中红色柱状图所示),即提高目标被正确分类的概率。

同样地,由图6可以看出,其他分类算法的最优特征子集所对应的特征数量如表2所示。

表2 不同分类算法的最优特征子集对应的特征数量比较

特征数量	KNN	SVM	SRC	CNN	LR	JSRC	KJSRC	ESKJSRC
	8	7	8	10	8	10	9	9

用t分布随机邻接嵌入(t-distributed Stochastic Neighbor Embedding, t-SNE)^[45]展示RF-mRMR特征选择方法对特征的区分能力,图7(a)、(c)和(e)分别对应东侧、西侧、双基地声呐在特征选择之前所有特征的可

可视化分布图,图7(b)、(d)和(f)分别对应东侧、西侧、双基地声呐在应用RF-mRMR方法筛选后的9维特征的可视化分布图.相较于单特征,多特征可以融合更多的特征信息,增加不同种类目标的可分性^[29],但是由图7(a)、(c)和(e)看出,在全部68维特征集合下,不同

目标之间仍然不能很好地区分.原因可能是存在一些导致分类性能降低的干扰特征,因此特征选择很有必要.由图7可以看出,应用本文提出的RF-mRMR特征选择方法后,不同目标类别的样本之间的间距更大,大多数样本得到较好的区分.

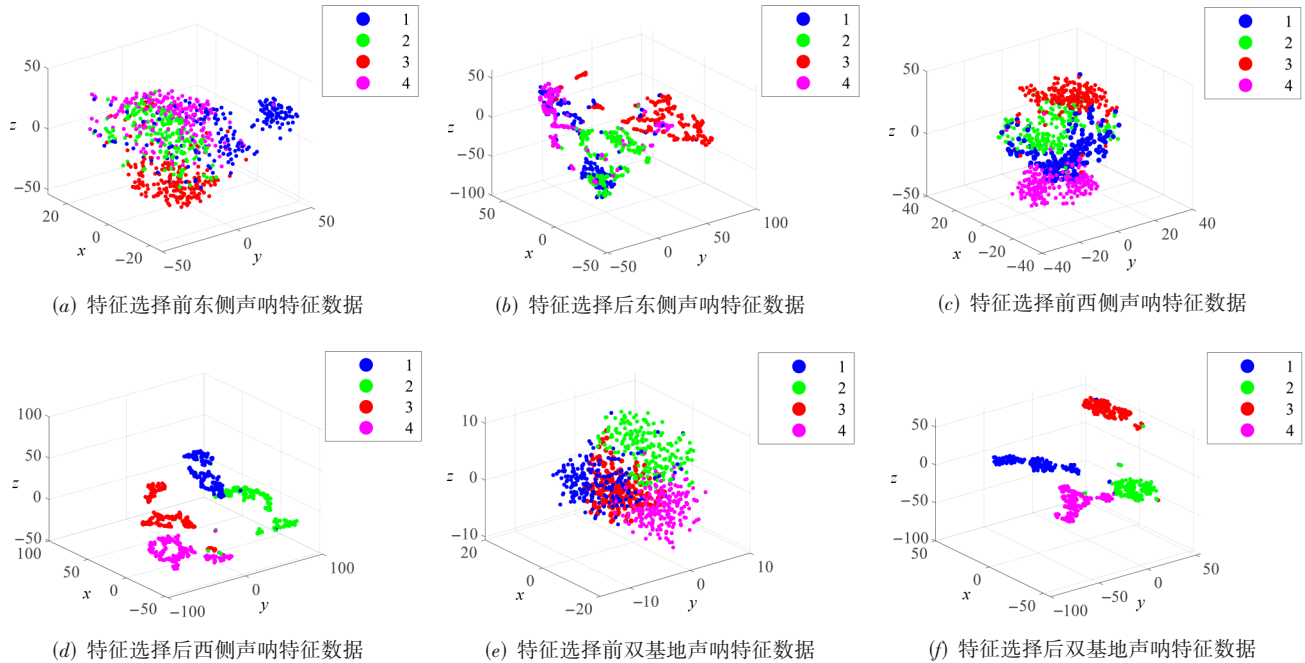


图7 特征选择前后的可视化分布图对比

4.4 分类结果分析

本文使用ROC曲线(Receiver Operating Characteristic curve,接收者工作特征曲线)、AUC(Area Under Curve)值、准确率(Accuracy)和虚警率(False Alarm Rate, FAR)来评价模型性能.其中,AUC的定义是ROC曲线下的面积.模型判断为正样本的正样本为TP(True Positive),模型判断为负样本的负样本为TN(True Negative),模型判断为正样本的负样本为FP(False Positive),模型判断为负样本的正样本为FN(False Negative),准确率表示样本被正确预测的概率,计算公式如式(13)所示,没有目标而认为有目标的概率称为虚警率,计算公式如式(14)所示.

$$\text{Accuracy} = \frac{\text{TN} + \text{TP}}{\text{TP} + \text{FN} + \text{FP} + \text{TN}} \quad (13)$$

$$\text{FAR} = 1 - \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (14)$$

为了检验本文提出的方法的有效性,本文算法及其他7种对比算法在对应的最优特征子集下重复实验30次取平均值,得到的结果如表3和表4所示,加粗数据表示最优结果.

由表3和表4可以看出,对于任意分类算法,基于双基地声呐的分类效果均优于单基地声呐,相较于单

表3 不同分类算法的AUC值比较 单位:%

声呐系统工作模式	KNN	SVM	SRC	CNN	LR	JSRC	KJSRC	ESKJSRC
东侧声呐	74.36	71.14	70.76	87.23	85.55	71.10	90.24	91.42
西侧声呐	87.42	93.11	84.36	94.61	87.21	80.80	94.76	96.03
双基地声呐	90.91	93.69	93.76	95.21	93.68	95.59	96.90	97.78

表4 不同分类算法的准确率比较 单位:%

声呐系统工作模式	KNN	SVM	SRC	CNN	LR	JSRC	KJSRC	ESKJSRC
东侧声呐	63.51	55.04	55.29	80.26	76.00	58.76	85.34	86.99
西侧声呐	83.20	91.64	80.96	93.25	86.00	65.35	92.18	94.33
双基地声呐	90.28	92.43	91.80	94.33	93.16	93.39	96.29	97.43

基地,双基地声呐的AUC值提高0.58%~24.49%,准确率提高0.79%~37.39%.

由表3不同分类算法的AUC值比较可得,对于单/双基地声呐,本文算法均具有最优性能,在双基地模式下,本文算法的AUC值较KJSRC算法提高0.88%,较JSRC算法提高2.19%,较CNN算法提高2.57%,较SRC算法提高4.02%,较SVM算法提高4.09%,较LR算法提高4.10%,较KNN算法提高6.87%.

由表4不同分类算法的准确率比较可得,对于单/

双基地声呐,本文算法均具有最优性能,在双基地模式下,本文算法的准确率较 KJSRC 算法提高 1.14%,较 CNN 算法提高 3.10%,较 JSRC 算法提高 4.04%,较 LR 算法提高 4.27%,较 SVM 算法提高 5.00%,较 SRC 算法提高 5.63%,较 KNN 算法提高 7.15%。

由表 3 和表 4 可以看出,JSRC 算法基于单基地声呐的分类结果普遍低于其他对比算法,但是基于双基地声呐的分类结果明显提高,并且优于大多数对比算法,尤其是和 SRC 算法相比。这证明了基于联合性假设的 JSRC 算法在多视角联合学习过程中的性能优越性。


由表 3 和表 4 可以看出,KJSRC 算法基于单基地声呐的分类结果比 JSRC 算法明显提高,基于双基地声呐的分类结果同样优于 JSRC 算法,这证明了核函数对特征空间中的分类起到了很大的性能改进。本文算法在 KJSRC 算法的基础上使用指数平滑法充分利用残差波段中的有用信息,其基于单/双基地声呐的分类结果均优于 KJSRC 算法,证明指数平滑法达到了提高数据集稳定度的目的。

由表 3 和表 4 可以看出,KJSRC 算法除了在西侧声呐的准确率低于 CNN 算法外,其余声呐模式下的 AUC 值和准确率均高于 CNN 算法,因此在 KJSRC 算法基础上继续改进是很有必要的。本文算法基于单/双基地声呐的分类性能均优于 CNN 算法,推测原因可能是样本数据有限,对 CNN 算法造成一定的局限性。

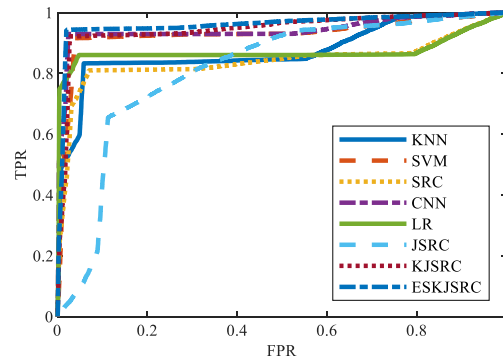
为了更加直观地判断本文提出的算法的有效性,基于单/双基地声呐的不同分类算法的 ROC 曲线图如图 8 所示,图 8(a)、(b)和(c)分别对应基于东侧、西侧、双基地声呐的不同分类算法的 ROC 曲线图,横坐标是负正类率(False Positive Rate, FPR),纵轴是真正类率(True Positive Rate, TPR)。由于本文是对 4 类水下目标进行分类识别,属于多分类范畴,因此,绘制的 ROC 曲线图不如二分类光滑^[33],但是不会影响模型的直观评价。ROC 曲线越接近左上角(0,1),即越往左上角凸,模型对应的 AUC 值越大,模型的分类效果越好,由图 8 可以看出,基于双基地声呐的 ROC 曲线图比单基地声呐更接近左上角,即基于双基地声呐的分类结果优于单基地声呐,由图 8(c)可以看出本文提出的算法具有最优的性能。

由以上实验结果可以看出,相对于其他 7 种对比算法,本文提出的算法在双基地声呐系统工作模式下分类效果最好。接下来在单/双基地声呐的条件下,应用本文提出算法分别计算 4 类水下目标的识别准确率和虚警率,结果如表 5 所示,加粗数据表示最优结果。


由表 5 可以看出,圆柱桶子的西侧声呐识别准确率略高于双基地声呐,其他目标的双基地声呐识别准确率均高于单基地声呐;注水圆球的西侧声呐虚警率略



(a) 东侧声呐



(b) 西侧声呐



(c) 双基地声呐

图 8 基于单/双基地声呐的不同分类算法的 ROC 曲线图

低于双基地声呐,其他目标的双基地声呐虚警率均低于单基地声呐。综上所述,在大多数情况下,本文算法的双基地声呐的识别准确率和虚警率均优于单基地声呐。

接下来分析样本数量对分类效果的影响。双基地条件下,样本数量对不同算法的识别准确率影响如图 9 所示。由图 9 可以看出,相较于 CNN 算法,稀疏表示分类算法更适用于小样本量情况。随着样本数量的增加,在 JSRC 算法基础上改进得到的本文算法的准确率一直优于 JSRC 算法。在不同声呐工作模式下,样本数量对本文算法的识别准确率影响如图 10 所示。由图 10 可以看出,当样本数量超过 100 时,本文算法的准确率

表5 本文算法基于单/双基地声呐的目标识别准确率和虚警率

单位:%

声呐系统工作模式	准确率				虚警率			
	圆柱桶子	注水圆球	圆台	携带开放式呼吸器的蛙人	圆柱桶子	注水圆球	圆台	携带开放式呼吸器的蛙人
东侧声呐	77.90	97.80	95.95	76.30	10.70	20.02	7.80	11.10
西侧声呐	94.55	94.25	90.95	97.55	10.96	5.04	2.36	3.28
双基地声呐	92.70	98.60	99.00	99.40	1.05	5.16	1.63	2.13

趋于平缓. 图9和图10的横轴为总的样本数量,其中一半作为训练样本,一半作为测试样本,纵轴为30次的平均识别准确率.




图9 样本数量对不同算法的识别准确率影响




图10 样本数量对本文算法的识别准确率影响

三种算法的重构误差随迭代次数的变化示意图如图11所示. 由图11可以看出,随着迭代次数的增加,三种算法的重构误差均变小,KJSRC算法和ESKJSRC算法的重构误差明显小于JSRC算法,这证明了核函数对




图11 三种算法重构误差对比示意图

特征空间中的分类起到了很大的性能改进. 当迭代次数增多时,加指数平滑法的ESKJSRC算法充分利用残差波段中的有用信息,取得了比KJSRC算法更小的重构误差.

5 结论

本文针对多基地水下小目标识别问题,提出了一种基于核空间联合稀疏表示和指数平滑的多基地水下目标识别方法. 首先,本文对水下目标特征进行总结归类,并对水下目标多角度散射信号提取6种具有信息互补性和关联性的特征. 然后,分析RF和mRMR算法进行特征选择时的优缺点,将二者相结合提出RF-mRMR特征选择方法,基于由RF-mRMR方法得到的最优特征子集对水下目标进行分类识别,不仅降低了数据处理复杂度,而且可以使不同目标类别的样本之间的间距更大,提高目标的分类效果. 本文提出的方法是在JSRC算法的基础上改进得到的. 本文中的核函数通过将线性不可分的数据映射到高维核特征空间,隐式地利用了数据中的高阶结构,提高了算法的分类性能. 在此基础上,为了提高数据集稳定度,使用指数平滑公式对稀疏重构后的残差信息进行充分挖掘,最后应用核特征空间下的最小误差准则判定待分类目标所属类别.

对4类目标海试数据处理结果分析可得:

(1)在本文算法和7种对比算法(CNN算法、JSRC算法、SRC算法、LR算法、SVM算法、KNN算法、KJSRC算法)的分类结果中,双基地声呐融合识别系统均比单基地具有更高的识别准确率和AUC值.

(2)在单/双基地声呐实验结果中,本文算法的AUC值和准确率均高于其他7种对比算法. 本文算法的分类性能优于CNN算法,原因可能是样本数据有限,对CNN算法造成一定的局限性.

(3)基于多视角联合性假设的JSRC算法分类性能优于SRC算法,与JSRC算法相比,本文算法中的核函数对特征空间中的分类起到了很大的性能改进,指数平滑法达到了提高数据集稳定度的目的.

(4)应用本文算法计算4类水下目标的识别准确率和虚警率,其中圆柱桶子的西侧声呐识别准确率略高于双基地声呐,注水圆球的西侧声呐虚警率略低于双

基地声呐,其他目标的双基地声呐识别准确率和虚警率均优于单基地声呐,也就是说,在大多数情况下,本文算法的双基地声呐识别准确率和虚警率均优于单基地声呐。

(5)稀疏表示类分类算法比 CNN 算法更适用于小样本量情况,随着样本数量的增加,本文算法的准确率一直优于 JSRC 算法,本文算法的识别准确率在样本数量超过 100 时趋于平缓。随着迭代次数的增加,本文算法具有比 JSRC 算法和 KJSRC 算法更小的重构误差。

参考文献

- [1] 温涛,许枫,王梦宾,等. 预测特征误差映射及其在多基地水下目标识别中的应用[J]. 声学学报, 2019, 44(1): 57-67.
WEN T, XU F, WANG M B, et al. Predicted feature error mapping and its application in multi-static underwater target recognition[J]. Acta Acustica, 2019, 44(1): 57-67. (in Chinese)
- [2] AI X, LI Y, WANG X, et al. Some results on characteristics of bistatic high-range resolution profiles for target classification[J]. IET Radar Sonar & Navigation, 2012, 6(5): 379.
- [3] DOBECK G J. Fusing sonar images for mine detection and classification[C]//Proceedings SPIE 3710, Detection and Remediation Technologies for Mines and Minelike Targets IV. Orlando: SPIE, 1999: 602-614.
- [4] REED S, PETILLOT Y, BELL J. Automated approach to classification of mine-like objects in sidescan sonar using highlight and shadow information[J]. IEE Proceedings - Radar, Sonar and Navigation, 2004, 151(1): 48.
- [5] 严科伟, 马爱民. 基于神经网络的舰船目标识别研究[J]. 指挥控制与仿真, 2006, 28(1): 44-47.
YAN K W, MA A M. Researches for ship identification based on neural network[J]. Command Control & Simulation, 2006, 28(1): 44-47. (in Chinese)
- [6] HUAN R H, WANG C, PAN Y, et al. New structure for multi-aspect SAR image target recognition with multi-level joint consideration[J]. Multimedia Tools and Applications, 2016, 75(13): 7519-7540.
- [7] XU L Y, CAO Z J. Sub-dictionary based joint sparse representation for multi-aspect SAR automatic target recognition [C]//The Proceedings of the Third International Conference on Communications, Signal Processing, and Systems. Cham: Springer, 2015: 167-175.
- [8] NGUYEN N H, NASRABADI N M, TRAN T D. Robust multi-sensor classification via joint sparse representation [C]//14th International Conference on Information Fusion. Piscataway: IEEE, 2011: 1-8.
- [9] 赵自璐, 王世练, 张炜, 等. 水下冲激噪声环境下基于多特征融合的信号调制方式识别[J]. 厦门大学学报(自然科学版), 2017, 56(3): 416-422.
ZHAO Z L, WANG S L, ZHANG W, et al. Classification of signal modulation types based on multi-features fusion in impulse noise underwater[J]. Journal of Xiamen University (Natural Science), 2017, 56(3): 416-422. (in Chinese)
- [10] 胡欣, 吴晓红, 雷翔, 等. 基于联合多特征字典稀疏表示的步态识别算法[J]. 计算机科学与应用, 2017, 7(4): 398-406.
HU X, WU X H, LEI X, et al. Gait recognition algorithm based on sparse representation of joint multi-feature dictionary[J]. Computer Science and Application, 2017, 7(4): 398-406. (in Chinese)
- [11] DAO M, TRAN-LUU T D, NASRABADI N M. Sparsity-based fusion of multiple sensors and multiple features for acoustic transients classification[C]//2016 IEEE Global Conference on Signal and Information Processing (GlobalSIP). Piscataway: IEEE, 2017: 182-186.
- [12] 侯平魁, 史习智, 林良骥, 等. 水下目标识别的特征融合分类器设计[J]. 电子学报, 2001, 29(4): 443-446.
HOU P K, SHI X Z, LIN L J, et al. Design of feature fusion classifier for underwater targets recognition[J]. Acta Electronica Sinica, 2001, 29(4): 443-446. (in Chinese)
- [13] 温涛, 许枫, 杨娟, 等. 连续隐马尔科夫模型在多基地目标识别中的应用[J]. 应用声学, 2017, 36(6): 512-520.
WEN T, XU F, YANG J, et al. Multi-static underwater target recognition method based on continuous hidden Markov model[J]. Journal of Applied Acoustics, 2017, 36(6): 512-520. (in Chinese)
- [14] PEI J F, HUANG Y L, HUO W B, et al. SAR automatic target recognition based on multiview deep learning framework[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(4): 2196-2210.
- [15] PEI J F, WANG Z Y, SUN X P, et al. FEF-Net: A deep learning approach to multiview SAR image target recognition[J]. Remote Sensing, 2021, 13(17): 3493.
- [16] 刘渭滨, 邹智元, 邢薇薇. 模式分类中的特征融合方法[J]. 北京邮电大学学报, 2017, 40(4): 1-8.
LIU W B, ZOU Z Y, XING W W. Feature fusion methods in pattern classification[J]. Journal of Beijing University of Posts and Telecommunications, 2017, 40(4): 1-8. (in Chinese)
- [17] 陈宏. 结合多视角-多特征 SAR 图像目标识别方法

- [J]. 电子测量与仪器学报, 2019, 33(9): 87-92.
- CHEN H. Target recognition method of SAR images by combination of multiple views and features[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(9): 87-92. (in Chinese)
- [18] DAO M, NGUYEN N H, NASRABADI N M, et al. Collaborative multi-sensor classification via sparsity-based representation[J]. IEEE Transactions on Signal Processing, 2016, 64(9): 2400-2415.
- [19] ZHANG H C, NASRABADI N M, HUANG T S, et al. Transient acoustic signal classification using joint sparse representation[C]//2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway: IEEE, 2011: 2220-2223.
- [20] ZHANG H C, NASRABADI N M, ZHANG Y N, et al. Multi-view automatic target recognition using joint sparse representation[J]. IEEE Transactions on Aerospace and Electronic Systems, 2012, 48(3): 2481-2497.
- [21] LAN X Y, MA A J, YUEN P C, et al. Joint sparse representation and robust feature-level fusion for multi-cue visual tracking[J]. IEEE Transactions on Image Processing, 2015, 24(12): 5826-5841.
- [22] CHEN Y, NASRABADI N M, TRAN T D. Kernel sparse representation for hyperspectral target detection[C]//2012 IEEE International Geoscience and Remote Sensing Symposium. Piscataway: IEEE, 2012: 7484-7487.
- [23] CHANDRAN V, ELGAR S, NGUYEN A. Detection of mines in acoustic images using higher order spectral features[J]. IEEE Journal of Oceanic Engineering, 2002, 27(3): 610-618.
- [24] WEN T, XU F, YANG J, et al. An identification method based on multi-aspect target scattering characteristics[C]//2016 IEEE/OES China Ocean Acoustics (COA). Piscataway: IEEE, 2016: 1-4.
- [25] 温福喜, 刘宏伟. 基于中心矩特征的空间目标识别方法[J]. 雷达科学与技术, 2007, 5(1): 8-12.
- WEN F X, LIU H W. Space target recognition based on central moment feature[J]. Radar Science and Technology, 2007, 5(1): 8-12. (in Chinese)
- [26] 孙长印, 保铮. 一种稳健的雷达成像超分辨算法[J]. 电子科学学刊, 2000, 22(5): 735-740.
- SUN C Y, BAO Z. A robust super resolution algorithm for radar imaging[J]. Journal of Electronics and Information Technology, 2000, 22(5): 735-740. (in Chinese)
- [27] 孙滨. 水底掩埋物识别方法研究[D]. 南京: 东南大学, 2006.
- [28] 金磊磊, 梁红, 陆禹. 水下不同材料的回波特征提取与分类研究[C]//2016 中国西部声学学术交流会议论文集. 上海: 《声学技术》编辑部, 2016: 115-118.
- JIN L L, LIANG H, LU Y. Echo feature extraction and classification of different underwater materials[C]//Proceedings of 2016 Western China acoustic Symposium. Shanghai: Editorial Office of *Technical Acoustics*, 2016: 115-118. (in Chinese)
- [29] WANG J W, XU F, YANG J. An identification method of underwater targets based on sparse representation[C]//2021 OES China Ocean Acoustics (COA). Piscataway: IEEE, 2021: 971-975.
- [30] 谢磊. 基于 HHT 的水雷目标特征提取技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2008.
- XIE L. The Research on the Extraction of Mine based on the HHT[D]. Harbin: Harbin Engineering University, 2008. (in Chinese)
- [31] 李秀坤, 谢磊, 秦宇. 应用希尔伯特黄变换的水下目标特征提取[J]. 哈尔滨工程大学学报, 2009, 30(5): 542-546.
- LI X K, XIE L, QIN Y. Underwater target feature extraction using Hilbert-Huang transform[J]. Journal of Harbin Engineering University, 2009, 30(5): 542-546. (in Chinese)
- [32] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London Series A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903-995.
- [33] 赖祥源, 朱勤东, 陈火荣, 等. 基于 RF 特征选择和 XGBoost 模型的赤潮等级预测[J]. 渔业研究, 2021, 43(1): 1-12.
- LAI X Y, ZHU Q D, CHEN H R, et al. Red tide level prediction based on RF feature selection and XGBoost model[J]. Journal of Fisheries Research, 2021, 43(1): 1-12. (in Chinese)
- [34] 马国娟, 吴辰文, 刘文祎. 基因数据集混合特征选择算法研究[J]. 测控技术, 2019, 38(10): 71-75.
- MA G J, WU C W, LIU W Y. Research on hybrid feature selection algorithm for gene data sets[J]. Measurement & Control Technology, 2019, 38(10): 71-75. (in Chinese)
- [35] ZHANG L, ZHOU W D, CHANG P C, et al. Kernel sparse representation-based classifier[J]. IEEE Transactions on Signal Processing, 2012, 60(4): 1684-1695.
- [36] CHEN F, YU W X, LIU X Z, et al. Combinational match-

ing method of amplitude-scale and time-shift for radar HRRP recognition[C]//2011 IEEE International Geoscience and Remote Sensing Symposium. Piscataway: IEEE, 2011: 1311-1314.

- [37] 孙同晶, 贺锦鹏, 谷雨. 基于稀疏分解的水下目标回波信号处理方法[J]. 数据采集与处理, 2016, 31(2): 282-288.
SUN T J, HE J P, GU Y. Underwater echo signal processing method based on sparse decomposition[J]. Journal of Data Acquisition and Processing, 2016, 31(2): 282-288. (in Chinese)
- [38] 陈渤, 刘宏伟, 保铮. 基于三种不同绝对对齐方法的分类器分析[J]. 现代雷达, 2006, 28(3): 58-62.
CHEN B, LIU H W, BAO Z. Analysis of three kinds of classification based on different absolute alignment methods[J]. Modern Radar, 2006, 28(3): 58-62. (in Chinese)
- [39] 汤渭霖. 声呐目标回波的亮点模型[J]. 声学学报, 1994, 19(2): 92-100.
TANG W L. Highlight model of echoes from sonar targets[J]. Acta Acustica, 1994, 19(2): 92-100. (in Chinese)
- [40] 宁波, 王运, 邵鹏, 等. 基于包裹式框架的风功率特征选择与预测方法[J]. 信息技术, 2020, 44(12): 17-21.
NING B, WANG Y, SHAO P, et al. Wind power feature selection and prediction method based on wrapped framework[J]. Information Technology, 2020, 44(12): 17-21. (in Chinese)
- [41] COVER T, HART P. Nearest neighbor pattern classification[J]. IEEE Transactions on Information Theory, 1967, 13(1): 21-27.
- [42] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273-297.
- [43] 程锦盛, 杜选民, 曾赛. 采用深度学习方法的 underwater 目标听觉特征提取与识别技术研究[C]//2018 年全国声学大会论文集. 北京: 中国声学学会, 2018: 167-168.
CHENG J S, DU X, M, ZENG S. Research on extraction and recognition technique to auditory features of underwater target based on deep learning[C]//Proceedings of 2018 National Acoustic Conference. Beijing: The Acoustical Society of China, 2018: 167-168. (in Chinese)
- [44] 龚健, 陈耀霖, 张志. 基于多分类 Logistic 回归模型的区域土地利用变化及驱动因素研究[J]. 湖北农业科学, 2016, 55(17): 4545-4550.
GONG J, CHEN Y L, ZHANG Z. Regional land use change and its driving forces analysis based on multinomial logistic regression[J]. Hubei Agricultural Sciences, 2016, 55(17): 4545-4550. (in Chinese)

- [45] DIMITRIADIS G, NETO J P, KAMPFF A R. T-SNE visualization of large-scale neural recordings[J]. Neural Computation, 2018, 30(7): 1750-1774.

作者简介



王佳维 女, 1995 年生, 河北廊坊人. 中国科学院大学声学研究所博士研究生. 主要研究方向为水声信号处理.

E-mail: wangjiawei@mail.ioa.ac.cn



杨娟 女, 1981 年生, 山西太原人. 中国科学院大学声学研究所研究员. 主要研究方向为高频声呐、水下小目标探测及声学智能信号处理等.

E-mail: yangjuan@mail.ioa.ac.cn