

引用格式:倪俊帅,赵梅,胡长青.基于DNN和改进K-means的船舶辐射噪声开集识别方法[J].声学技术,2022,41(3):382-387.[NI Junshuai, ZHAO Mei, HU Changqing. DNN and improved K-means based ship noise open set recognition[J]. Technical Acoustics, 2022, 41(3): 382-387.] DOI: 10.16300/j.cnki.1000-3630.2022.03.011

基于 DNN 和改进 K-means 的船舶 辐射噪声开集识别方法

倪俊帅^{1,2}, 赵梅¹, 胡长青^{1,2}

(1. 中国科学院声学研究所东海研究站, 上海 201815; 2. 中国科学院大学, 北京 100049)

摘要: 为提高船舶噪声识别系统的性能, 实现开集识别, 提出了基于深度神经网络(Deep Neural Network, DNN)和改进 K-means 的船舶辐射噪声开集识别方法。首先, 采用 Welch 功率谱估计方法提取船舶辐射噪声的特征; 然后, 设计并应用 DNN 模型进一步提取特征向量; 最后, 使用改进的 K-means 模型实现开集识别。在实测数据上进行了实验, 结果表明, 所提方法能实现船舶辐射噪声开集识别, 对于实测数据的平均识别正确率为 93.5%, 较 DNN+K-means++ 方法提高了 6.2 个百分点。对实测数据添加实验船发动机噪声或渔船噪声进行实验, 结果表明, 识别方法在其他船只噪声干扰下具有较好的鲁棒性。

关键词: 船舶辐射噪声; 深度神经网络(DNN); 改进 K-means; 开集识别

中图分类号: O429

文献标志码: A

文章编号: 1000-3630(2022)-03-0382-06

DNN and improved K-means based ship noise open set recognition

NI Junshuai^{1,2}, ZHAO Mei¹, HU Changqing^{1,2}

(1. Shanghai Acoustics Laboratory, Chinese Academy of Science, Shanghai 201815, China;

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

Abstract: In order to improve the performance of ship noise recognition system and realize open set recognition, an open set recognition method of ship radiation noise based on Deep Neural Network (DNN) and improved K-means is proposed. First, the Welch power spectrum estimation method is used to extract the characteristics of ship radiation noise. Then, the deep neural network model is designed for further extraction of feature vectors. Finally, the improved K-means model is used to realize open set recognition. Experiments are carried out on the measured data, and the results show that the proposed method can realize the open set recognition of ship radiation noise. The average recognition accuracy for the measured data is 93.5%, which is 6.2% higher than that of the DNN+K-means++ method. After adding experimental ship engine noise or fishing boat noise to the measured data, the experimental results show that the recognition method has good robustness under the interference of other ship noises.

Key words: ship radiation noise; Deep Neural Network; improved K-means; open set recognition

0 引 言

船舶辐射噪声识别是被动声呐研究领域的一项难题, 一直以来受到国内外学者的广泛关注。海洋事业的蓬勃发展, 海上活动日益频繁, 海洋权益保障和国防建设等方面对船舶辐射噪声识别提出了更高的要求。随着深度学习和人工智能的发展及

其在各领域取得的显著成果, 将深度学习应用于船舶辐射噪声识别成为了研究的热点。船舶辐射噪声中包含着一定的特征信息, 特征提取是噪声识别不可缺少的重要环节。已有的特征提取方法主要有: 功率谱估计、小波变换、短时傅里叶变换、梅尔倒谱系数、希尔伯特-黄变换等。在此基础上将深度学习应用于船舶辐射噪声的识别, 取得了一定的研究成果。严韶光等^[1]采用 Welch 功率谱估计方法提取特征, 并采用深度自编码网络对船舶辐射噪声进行识别, 得到了比 BP 网络更好的识别效果。李俊豪等^[2]提取了船舶辐射噪声的时频特征, 设计卷积神经网络进行识别, 识别率得到了明显的提高。朱可卿等^[3]提取了船舶辐射噪声的频谱、梅尔倒谱系数、

收稿日期: 2021-06-16; 修回日期: 2021-07-22

基金项目: 水声对抗技术重点实验室开放基金(JCKY2020207CH02)、中国科学院声学研究所自主部署项目资助项目。

作者简介: 倪俊帅(1995-), 男, 山东德州人, 博士研究生, 研究方向为信号与信息处理。

通信作者: 赵梅, E-mail: zhaomei@mail.ioa.ac.cn

线谱特征，并采用卷积神经网络对特征的图像进行识别。曾赛等^[4]提出了水下目标多模态深度学习识别方法，提高了船舶辐射噪声识别的正确率。

虽然以上对船舶辐射噪声特征提取和识别算法的研究已经取得了一定的成果，但现实中船舶辐射噪声识别是包含未知船舶的开集识别。目前识别算法多为“监督式学习”的闭集识别，即在已有的船舶辐射噪声样本上训练网络模型并对模型的识别性能进行评估，然后用训练好的网络模型去识别船舶辐射噪声。这样一来模型只能识别训练集中包含的类别，而对于训练集中未包含的类别，则无法给出正确的识别结果。这一问题在一定程度上降低了识别系统的可靠性和准确率。张凯等^[5]提出了基于相似度分布的开集人脸识别算法，提取样本的相似度分布特征，然后运用线性判别分析算法实现开集识别。Bendale 等^[6]提出了深度学习输出层的 Openmax 函数激活方法，取代 Softmax 函数激活实现开集识别。Perera 等^[7]应用生成模型重建已知类别样本，提高已知与未知样本的类间距离，实现未知样本的检测。郝云飞等^[8]将对抗生成网络应用于信号调制方式的开集识别，取得了较高的识别正确率。以上开集识别方法在人脸识别等领域取得了较好的效果，而船舶辐射噪声随机性强，提取的可识别特征少，特征不稳定，相似船舶很难区分。船舶辐射噪声识别属于小样本识别，很难满足生成对抗网络训练样本需求。实现船舶辐射噪声的开集识别，还有待于进一步的研究。

为了提高船舶辐射噪声识别系统的性能，实现开集识别，本文提出了基于深度神经网络(Deep Neural Network, DNN)和改进 K-means 的船舶辐射噪声开集识别方法。采用 Welch 功率谱估计方法提取特征，设计并运用 DNN 模型进一步提取特征向量，提高数据的可分性；改进了 K-means 算法，选择更符合数据分布的聚类中心，并在此基础上实现了开集识别。

1 理论和方法

1.1 Welch 功率谱估计

假定随机信号序列 $x(n)$, $n=0,1,\dots,N-1$ ，将其分为 L 段，每段长度为 M ，相邻两段的重叠长度为 $M-K$ ，第 i 段数据加窗后可表示为^[9]

$$x_M^i(n)=a(n)x(n+iK), i=0,1,\dots,L-1; n=0,1,\dots,M-1 \quad (1)$$

其中： $a(n)$ 为窗函数； K 为一整数； L 为分段数；它们之间满足：

$$(L-1)K+M \leq N \quad (2)$$

第 i 段数据的功率谱估计为

$$\hat{P}_x^i(\omega)=\frac{1}{MU} |X_M^i(\omega)|^2 \quad (3)$$

其中：

$$X_M^i(\omega)=\sum_{n=0}^{M-1} x_M^i(n)e^{-j\omega n} \quad (4)$$

式(3)中， U 为归一化因子，作用是保证得到的谱估计是真实谱的渐进无偏估计， U 表示为

$$U=\frac{1}{M} \sum_{n=0}^{M-1} a^2(n) \quad (5)$$

由此得到的平均周期图法功率谱估计为

$$\bar{P}_x(\omega)=\frac{1}{L} \sum_{i=0}^{L-1} \hat{P}_x^i(\omega) \quad (6)$$

1.2 深度神经网络(DNN)

深度神经网络(DNN)由输入层、隐藏层和输出层组成。它具有强大的非线性建模能力，不但可以有效学习特征向量中的分类信息，抽象出具有更好分类性能的特征向量，还能够达到数据降维和提高运算性能的效果。多分类深度神经网络的代价函数为

$$J(t, y)=-\sum_{n=1}^c t^n \ln(y^n) \quad (7)$$

式中： y^n 和 t^n 分别为网络输出层第 n 个神经元的实际值和期望值， c 为类别数。

DNN 的期望输出向量可看作 c 组单位正交基，具有最好的分类特性。损失函数值衡量的是实际输出与期望输出的差异，因此，网络损失值越小，输出向量的可分性越好。

DNN 的隐藏层采用 Relu 函数激活，Relu 函数的表达式为

$$\text{Relu}(x)=\max(x, 0) \quad (8)$$

DNN 的输出层采用 Softmax 函数激活，Softmax 函数的表达式为

$$\text{Softmax}(x)=\frac{\exp(x_i)}{\sum_{i=1}^c \exp(x_i)} \quad (9)$$

整个网络采用自适应学习率的误差反向传播算法^[10]进行迭代，最小化代价函数并更新权值。迭代过程采用 optimizer 优化器进行参数优化。

DNN 通过 Softmax 函数将输入特征向量映射向 c 个单位正交基，代价函数越小，映射越逼近。所以，越靠近网络输入层，特征向量包含的目标的特征信息越丰富，越靠近输出层，特征向量包含的目标的分类信息越多。文献[6]的研究表明，输出层 Softmax 激活前的特征向量具有更好的开集性能。因此，本文选用该层输出的特征向量进行船舶辐射

噪声开集识别。

1.3 K-means 算法

K-means 算法^[11]是典型的无监督学习算法。实际的聚类应用没有任何关于训练样本的真实分类信息,因此目标是根据特征的相似性对样本进行分组。

K-means 算法可以通过以下 4 个步骤来实现:

(1) 随机从样本中挑选 k 个重心作为初始聚类中心。

(2) 将每个样本分配到最近的重心 u^j , $j \in \{1, \dots, k\}$ 。

(3) 把重心移到已分配样本的中心。

(4) 重复步骤(2)和(3),直到集群赋值不再改变,或达到设置的最大迭代次数。

1.4 改进的 K-means 算法

传统的 K-means 算法有受初始值和离群点的影响,每次结果都不稳定;容易收敛到局部最优解;无法解决“簇”分布差别比较大的情况等缺点。

K-mean++算法^[12]在其基础上对初始聚类中心的选择进行了改进,提高了模型的收敛速率,降低了误差。

为有效解决上述问题并实现开集识别,本文以传统 K-means 算法为基础,结合 Kernel K-means^[13]的改进思想,引入“半监督学习”机制,对 K-means 聚类中心选择和判决策略进行如下改进:(1)在第一步中采用部分标识样本以确定初始聚类中心。(2)标识样本在后续的聚类步骤中标签保持不变。(3)分别应用余弦系数、Dice 系数等相似性度量方法确定聚类中心。(4)对待测样本识别时,设定阈值,最大相似度小于阈值时识别为未知类别。

1.5 船舶辐射噪声开集识别方法

本文所提船舶噪声开集识别方法具体包括如下两个过程:

(1) 运用深度神经网络(DNN)提取船舶辐射噪声的特征向量。

首先,对船舶噪声进行 Welch 方法的谱估计,获得归一化的单边功率谱。其次,设计深度神经网络,将功率谱部分离散的功率值作为特征参数训练和验证网络模型,改变起始频率和带宽进行重复训练和验证,选择网络最小损失函数值对应的起始频率和带宽,确定输入特征向量的提取方法。最后,将训练集样本输入已训练的最小损失网络进行分类,提取网络输出层 softmax 函数激活前的值作为特征向量。该过程的流程如图 1 所示。

(2) 针对过程(1)中 DNN 提取的训练集特征向量,将分类正确且置信度大于 0.95 的样本继续作为

已标识样本,即正样本,其余样本作为未标识样本,即难负样本,训练改进策略的 K-means 模型,确定聚类中心。然后,将 DNN 提取的测试集样本特征向量输入训练好的聚类模型,设定阈值进行开集识别。改进的 K-means 开集识别流程如图 2 所示。

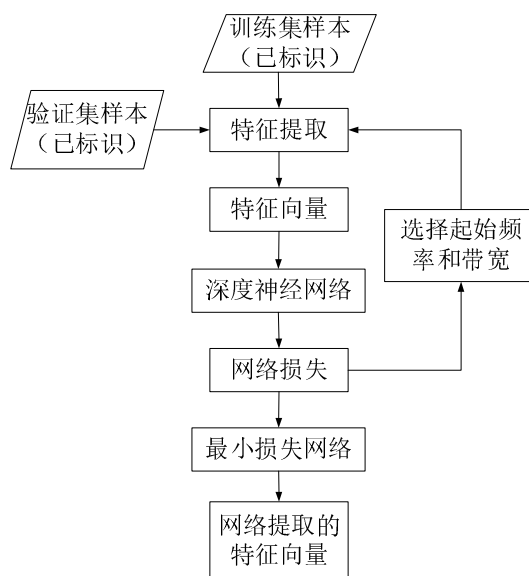


图 1 DNN 提取特征向量流程图

Fig.1 Flow chart of feature vector extraction by DNN

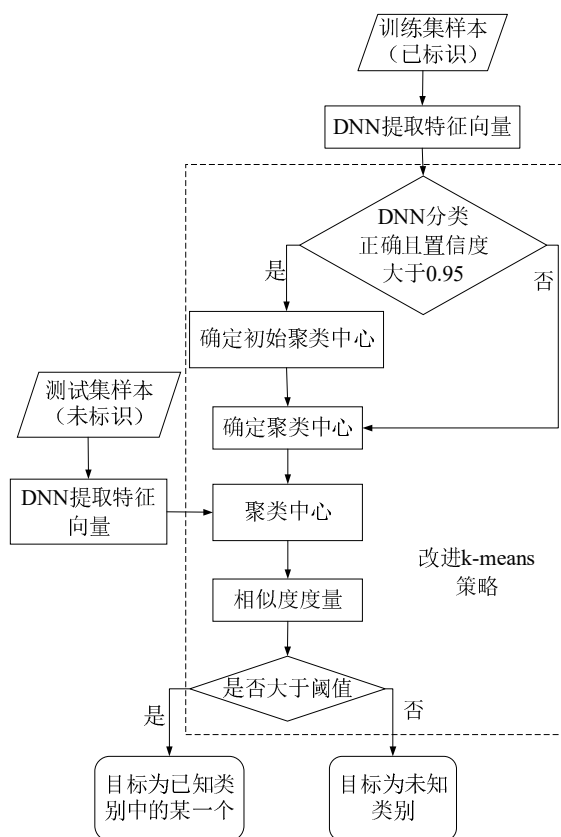


图 2 改进的 K-means 开集识别流程图

Fig.2 Flow chart of open set recognition by improved K-means

2 实验及结果

2.1 实验数据获取

实验采用 2018 年 6 月在某湖试中实测的船舶辐射噪声数据。该实验采用 Ocean Sonics 生产的 icListen-900 自容式水听器，工作频带为 1 Hz~100 kHz，以潜标形式布放海底采集噪声数据。实验设备布放图如图 3 所示。实验地点选择在游船频繁经过的水域，采集的目标船舶辐射噪声具有通过特性，受其他船只噪声干扰较小。




图 3 实验设备布放图
Fig.3 Layout of experimental equipment

实测目标为 10 艘不同的游船，分别记为目标 I~X。对获取的辐射噪声信号预处理共得到数据 4 560 段，每段数据长度均为 3 s，采样率为 32 kHz。将目标 X 记为未知船舶，其他目标记为已知船舶，训练集、验证集、测试集中各类样本组成如表 1 所示。

表 1 数据集样本组成
Table 1 Sample composition of data sets

数据集	样本量/段										总样本量/段
	目标 I	目标 II	目标 III	目标 IV	目标 V	目标 VI	目标 VII	目标 VIII	目标 IX	目标 X	
训练集	288	432	144	216	216	288	288	144	288	0	2 304
验证集	96	144	48	72	72	96	96	48	96	0	768
测试集	96	144	48	72	72	96	96	48	96	720	1 488

2.2 基于船舶辐射噪声实测数据的开集识别实验

对采集的每一段数据均做 Welch 方法的功率谱估计，分段数为 5，重叠率为 0.5，窗函数选用汉明(Hamming)窗，频率采样间隔为 1 Hz。由于高识别性的线谱主要集中在 200 Hz 以内的低频部分，且 2 000 Hz 以内的连续谱形态变化也是重要的识别因

素之一。因此采用不同的方法对功率谱进行截取。起始频率分别选择 1、21、41、81、101 Hz，点数分别选择 300、600、900、1 200、1 500。

本文设计的深度神经网络(DNN)具有三个隐藏层，其输入层节点数 n 为输入特征向量的维数，由截取功率谱的点数决定。网络各层的节点数和训练的参数数量如表 2 所示。

表 2 层节点数和参数数量
Table 2 Number of layer nodes and parameters

层名称	节点数	参数数量
输入层	n	0
隐藏层 1	16	$16(n+1)$
隐藏层 2	16	272
隐藏层 3	16	272
输出层	9	153

采用不同的截取方法获得的特征向量训练和验证本文设计的深度神经网络(DNN)。当起始频率为 21 Hz、点数为 1 200 时，即选用频率 21~1 220 Hz 对应的功率值作为特征向量时，DNN 的验证损失最小，最小值收敛于 8.29×10^{-4} 。在此条件下，网络迭代 20 次的精度和损失曲线分别如图 4 和图 5 所示。迭代完成后，网络对训练集分类的平均正确率为 99.1%，对验证集分类的平均正确率为 97.3%。




图 4 训练和验证精度曲线
Fig.4 Accuracy curves for training and verification




图 5 训练和验证损失曲线
Fig.5 Loss curves for training and verification

接下来, 获取网络对训练集的分类结果、置信度、特征向量, 并根据本文改进 K-means 策略训练聚类模型, 确定聚类中心。其中分类结果正确且置信度大于 0.95 的样本数为 1 959。将本文方法确定的聚类中心和 K-means++算法确定的聚类中心通过 PCA^[14]降维, 如图 6 所示。




图 6 本文方法与 K-means++算法确定的聚类中心
Fig.6 The clustering centers determined by the proposed method and K-means++ method


由图 6 可以看出, 本文方法确定的聚类中心和 K-means++算法确定的聚类中心有部分较为接近, 这是因为对应类别的数据难负样本较少, 且与其他类别的差异较大; 本文方法确定的聚类中心更能反映实际数据的重心, 重心之间的平均相对距离更远, 更有利于开集识别。

用本文改进 K-means 方法对测试集样本进行开集识别, 并与 K-means++算法进行对比, 在不同阈值下, 分别采用欧式距离、余弦距离、Dice 系数、曼哈顿距离作为相似性度量方法的 ROC 曲线分别如图 7 所示。其中 R_{FR} 为错误拒绝率(False Rejection Rate, FRR), 表示所有正例(已知类)中被预测为负例(未知类)的比例, R_{FA} 为错误接受率(False Acceptance Rate, FAR), 表示所有负例(未知类)中被预测为正例(已知类)的比例。

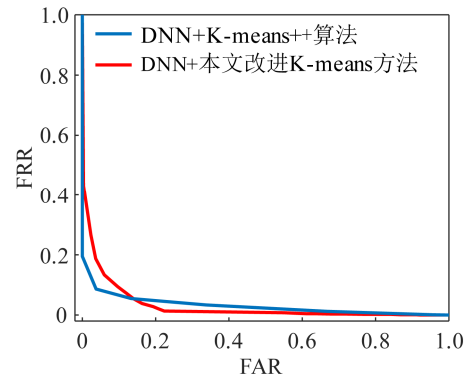
由图 7 可以看出, 采用欧式距离、曼哈顿距离、Dice 系数且 $R_{FA} < 0.6$, 以及采用余弦系数且 $R_{FA} < 0.1$ 时, 本文方法的 FRR 均小于 DNN+K-means++方法的 FRR。本文方法对船舶辐射噪声进行开集识别, 具有更小的错误率。当 $R_{FA} = R_{FR}$ 时, 开集识别正确率如表 3 所示。

采用 4 种不同的相似性度量方法, 当 $R_{FR} = R_{FA}$ 时, 本文方法的开集识别正确率均在 90%以上, 相比于 DNN+K-means++方法平均高出 6.2 个百分点。


接下来, 对获取的船舶辐射噪声分别添加信噪比为 10、0、-10 dB 的实验船发动机噪声、渔船辐射噪声, 信噪比定义为




(a) 欧式距离度量的 ROC 曲线



(b) 余弦距离度量的 ROC 曲线



(c) Dice 系数度量的 ROC 曲线



(d) 曼哈顿距离度量开集识别的 ROC 曲线

图 7 两种方法对 4 种相似性度量开集识别的 ROC 曲线
Fig.7 ROC curves of open set recognition by the two methods for four different similarity measures

$$R_{SN} = 10 \lg \left[\frac{\sum_{n=1}^N X_t^2(n)}{\sum_{n=1}^N X_n^2(n)} \right] \quad (10)$$

式中： X_t 为待识别船舶辐射噪声信号， X_n 为实验船发动机辐射噪声信号， N 为信号长度。选用余弦系数进行相似性度量，本文方法对含噪声的船舶辐射噪声信号开集识别正确率如表 4 所示。

表 3 $R_{FR}=R_{FA}$ 时两种方法对 4 种相似性度量的开集识别正确率

Table 3 Open set recognition accuracies of the two methods for four different similarity measures when $R_{FR}=R_{FA}$

相似性度量	识别准确率/%	
	DNN+K-means++	本文方法
欧氏距离	87.9	94.2
余弦系数	90.1	94.5
Dice 系数	86.2	93.8
曼哈顿距离	85.2	91.5

表 4 加噪声后本文方法开集识别正确率

Table 4 Open set recognition accuracy of the proposed method after adding noise

R_{SN}/dB	识别正确率/%	
	发动机噪声	渔船噪声
10	88.5	87.1
0	84.1	83.8
-10	72.2	71.7

本文方法具有较好的鲁棒性，在实验船发动机噪声和渔船噪声干扰的情况下，依然能对目标船舶有效地实现开集识别。当信噪比大于 0 dB 时，开集识别正确率达到 83% 以上。

3 结论

为实现船舶辐射噪声的开集识别，本文提出了一种基于 DNN 和改进 K-means (DNN+K-means++) 的开集识别算法。根据网络最小损失原则选取功率谱特征，得到了分类性能良好的初始特征向量；应用神经网络进一步提取特征向量，在降维的同时提高了数据的可分性；采用改进的 K-means 算法，获得了更符合数据分布的聚类中心并实现了船舶辐射噪声的开集识别。实验结果表明，该方法对实测船舶辐射噪声数据有较好的识别效果，4 种不同的相似性度量方法下，该方法的开集识别性能均优于 DNN+K-means++ 方法。采用余弦系数进行相似性度量时，开集识别正确率最高。对实测信号添加实验船发动机噪声或渔船噪声后，本文方法的识别正确率较高，具有较好的鲁棒性。

参 考 文 献

[1] 严韶光, 康春玉, 夏志军, 等. 基于深度自编码网络的舰船辐射噪

声分类识别[J]. 舰船科学技术, 2019, 41(3): 124-130.

YAN Shaoguang, KANG Chunyu, XIA Zhijun, et al. Classification and recognition of ship radiated noise based on deep auto-encoding networks[J]. Ship Science and Technology, 2019, 41(3): 124-130.

[2] 李俊豪, 杨宏晖. 用于水声目标信号时频特征提取与识别的深度卷积神经网络[J]. 无人系统技术, 2019, 2(4): 26-30.

LI Junhao, YANG Honghui. Deep convolutional neural networks for underwater acoustic target time-frequency feature extraction and recognition[J]. Unmanned Systems Technology, 2019, 2(4): 26-30.

[3] 朱可卿, 田杰, 黄海宁, 等. 基于深度学习的船舶辐射噪声识别研究[J]. 应用声学, 2018, 37(2): 238-245.

ZHU Keqing, TIAN Jie, HUANG Haining, et al. Ship-radiated noise recognition research based deep learning[J]. Journal of Applied Acoustics, 2018, 37(2): 238-245.

[4] 曾赛, 杜选民. 水下目标多模态深度学习分类识别研究[J]. 应用声学, 2019, 38(4): 589-595.

ZENG Sai, DU Xuanmin. Multimodal underwater target recognition method based on deep learning[J]. Journal of Applied Acoustics, 2019, 38(4): 589-595.

[5] 张凯, 苏剑波. 基于相似度分布的开集人脸识别方法[J]. 模式识别与人工智能, 2011, 24(1): 147-152.

ZHANG Kai, SU Jianbo. Open set face recognition approach based on similarity distribution[J]. Pattern Recognition and Artificial Intelligence, 2011, 24(1): 147-152.

[6] BENDALE A, BOULT T E. Towards open set deep networks[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA. IEEE, 2016: 1563-1572.

[7] PERERA P, MORARIU V I, JAIN R, et al. Generative-discriminative feature representations for open-set recognition[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA. IEEE, 2020: 11811-11820.

[8] 郝云飞, 刘章孟, 郭福成, 等. 基于生成对抗网络的信号调制方式的开集识别[J]. 系统工程与电子技术, 2019, 41(11): 2619-2624.

HAO Yunfei, LIU Zhangmeng, GUO Fucheng, et al. Open-set recognition of signal modulation based on generative adversarial networks[J]. Systems Engineering and Electronics, 2019, 41(11): 2619-2624.

[9] 程玉胜, 李智忠, 邱家兴. 水声目标识别[M]. 北京: 科学出版社, 2018.

[10] (美)俞栋, (美)邓力, 著. 俞凯, 钱彦旻等, 译. 解析深度学习语音识别实践[M]. 北京: 电子工业出版社, 2016.

[11] ZUO Y, LIN J Y, ZENG X X, et al. CarSite-II: an integrated classification algorithm for identifying carbonylated sites based on K-means similarity-based undersampling and synthetic minority oversampling techniques[J]. BMC Bioinformatics, 2021, 22(1): 216.

[12] TAO F, SURESH R, VOTION J, et al. Graph based multi-layer K-means++(G-MLKM) for sensory pattern analysis in constrained spaces[J]. Sensors (Basel, Switzerland), 2021, 21(6): 2069.

[13] PUTRI A M, SARI A M, RUSTAM Z, et al. Classification of cerebral infarction data using K-means and kernel K-means[J]. Journal of Physics: Conference Series, 2021, 1752(1): 012041.

[14] WANG Y J, YANG K, LI H G. Industrial time-series modeling via adapted receptive field temporal convolution networks integrating regularly updated multi-region operations based on PCA[J]. Chemical Engineering Science, 2020, 228: 115956.