

引用格式: 梁喆, 侯朋, 夏春艳, 等. 融合时频域特征的舰船识别方法及实验研究[J]. 声学技术, 2021, 40(5): 607-613. [LIANG Zhe, HOU Peng, XIA Chunyan, et al. Theoretical and experimental study of ship recognition by fusing feature in time-frequency domains[J]. Technical Acoustics, 2021, 40(5): 607-613.] DOI: 10.16300/j.cnki.1000-3630.2021.05.004

融合时频域特征的舰船识别方法及实验研究

梁 喆, 侯 朋, 夏春艳, 吕孟婷

(大连测控技术研究所, 辽宁大连 116000)

摘要: 文章提出了一种融合舰船辐射噪声时频域特征的识别方法, 将舰船辐射噪声的线谱特征和线性预测倒谱特征作为输入, 分别利用反向传播(Back Propagation, BP)神经网络进行训练、降维及初步判别, 并采用加权投票方式, 引入置信度算法和拒判机制实现决策级融合识别。实验结果表明, 对比基于舰船单一特征的识别方法, 利用舰船辐射噪声时频域特征的互补性进行融合识别, 减小了单一识别方法误判对总识别率的影响, 具有较强的鲁棒性, 可有效提高对目标的识别率。

关键词: 舰船目标识别; 线谱特征; 线性预测倒谱特征; 反向传播(BP)神经网络; 决策融合

中图分类号: TN911.7

文献标识码: A

文章编号: 1000-3630(2021)-05-0607-07

Theoretical and experimental study of ship recognition by fusing feature in time-frequency domains

LIANG Zhe, HOU Peng, XIA Chunyan, LYU Mengting

(Dalian Scientific Test & Control Technology Institute, Dalian 116000, Liaoning, China)

Abstract: In this paper, a recognition method integrating the time-frequency domain features of ship radiated noise is proposed. By taking the line spectrum features and linear prediction cepstrum features of ship radiated noise as inputs, the back propagation (BP) neural network is used for training, dimension reduction and preliminary discrimination. The weighted voting method is adopted, and the confidence algorithm and rejection mechanism are introduced to realize decision-level fusion recognition. The experimental results show that compared with the ship single feature based recognition method, the fusion recognition is carried out by using the complementarity of the time-frequency domain features of the ship radiated noise, which reduces the effect of the misjudgment of the single recognition method on the total recognition rate, has strong robustness, and can effectively improve the target recognition rate.

Key words: ship target recognition; line spectral feature; linear prediction cepstrum feature; back propagation (BP) neural network; decision fusion

0 引 言

近年来, 随着人工智能的快速发展, 将神经网络技术应用于舰船目标的特征识别已成为趋势^[1]。如何提取目标的声学特征作为神经网络输入, 以及采用哪些特征作为目标识别的依据, 是基于神经网络这类人工智能识别方法需要解决的关键问题。

当舰船目标处于高背景噪声环境或较远距离时, 接收水听器难以在高频段获得足够的信噪比,

而舰船目标的低频段噪声具有衰减慢、传播距离远、不易受其他信号调制等特点^[2], 成为目标被动识别的主要信息源。由于舰船目标的机械运动特性, 其低频线谱特征成为少数可以用于目标识别的特征之一^[1]。线谱特征集中了船舶桨轴频率特征以及桨叶频率特征, 甚低频中还包含了将船体尺度作为冲激响应系统的信号特征。另一方面, 舰船目标作为一个独特的发声体, 其时域信号特征也是目标识别中一个重要的参考依据。以往的目标识别大多基于单一特征提取, 但由于舰船目标声学信息的特殊性, 单一特征并不能完整地为目标进行表述^[3-5], 选用不同的特征提取方法提取的特征反映了舰船噪声信号不同的特征, 一般情况下很难做出某种方法优劣的判断, 如果把不同的特征提取方法提取的特征融合起来, 将使识别过程中的不确定性样本数减少, 从而提高目标识别正确概率, 提高整个识别

收稿日期: 2020-04-17; 修回日期: 2020-06-18

基金项目: 国家稳定支持专项(23476000000180001)

作者简介: 梁喆(1995-), 男, 云南曲靖人, 硕士研究生, 水声目标模式识别。

通讯作者: 侯朋, E-mail: hope.cssc@tom.com

系统的性能^[1-2,6]。

特征融合是将多源数据进行多级别、多方面、多层次的处理,从而获得比任何单个输入数据更准确的信息。特征融合方式主要分为三类^[5]:数据级融合、特征级融合、决策级融合。相比而言,数据级融合充分应用了目标的原始物理信息,但需要处理的信息量大,实时性差,处理代价高。常用的特征级融合方法利用特征的欧氏距离确定基本概率赋值的方法,虽然简单直观地反映了特征向量之间的近似度,实现了可观的信息压缩,但该方法直接对特征向量进行计算,不但计算量大,而且在证据冲突状态下无法横向对比不同特征提取方法得到特征向量的置信度^[6],导致其中一种或几种特征识别率严重下降时仍给出有效投票,增加目标的错误识别率。而决策级融合由于决策向量维数较低且已经将目标进行预识别,因此有很高的灵活性^[7]。

基于上述考虑,本文提出一种融合舰船辐射噪声时频域特征的识别方法,将舰船辐射噪声的线谱特征和线性预测倒谱特征作为输入,分别利用BP神经网络进行训练、降维及初步判别,并采用加权投票方式,引入置信度算法和拒判机制实现决策级融合识别,上述方法可以使不同的特征向量相互补充,提高舰船目标识别的正确率。

1 特征提取方法

1.1 线谱特征提取

图1给出了典型的线谱特征提取流程。

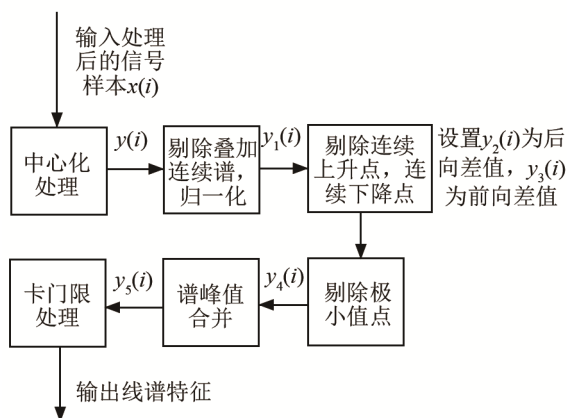


图1 线谱提取流程图

Fig.1 The flowchart of line spectrum extraction

首先,将降噪处理后的信号样本进行中心化处理:

$$y(i) = x(i) - \frac{1}{N} \sum_{j=0}^{N-1} x(j), \quad i=0,1,\dots,N-1 \quad (1)$$

式中: $x(i)$ 为信号样本, $y(i)$ 为中心化处理得到的

信号。通过多个时刻谱值积累可以减少偶然因素的影响,抑制随机干扰弱线谱,提高线谱提取的可靠性。由于线谱叠加在连续谱之上,为了分解出线谱信息,需要通过谱平滑减去连续谱,得到去除连续谱后的线谱图,只保留线谱。

对剔除连续谱后的线谱图进行归一化处理得到 $y_1(i)$:

$$y_1(i) = \frac{y(i) - \min[y(i)]}{\max[y(i)] - \min[y(i)]} \quad (2)$$

对每一点设置标志 $F(i)$, 对 $y_1(i)$ 求平均值, 舍去小于平均值的点:

$$F(i) = \begin{cases} 1, & y_1(i) > \bar{y}_1(i) \\ -1, & y_1(i) \leq \bar{y}_1(i) \end{cases} \quad (3)$$

式中, \bar{y}_1 为去连续谱后样本信号的均值:

$$\bar{y}_1(i) = \frac{1}{N} \sum_{j=0}^{N-1} y_1(j) \quad (4)$$

谱峰值所在点在局部为最大点,不可能出现在中间点上,因此剔除连续上升或连续下降点,只留下转折点^[2]:

$$\begin{aligned} y_2(i) &= y_1(i+1) - y_1(i) \\ y_3(i) &= y_1(i) - y_1(i-1) \end{aligned} \quad (5)$$

可得:

$$F(i) = \begin{cases} 1, & y_2(i) \cdot y_3(i) > 0 \\ -1, & y_2(i) \cdot y_3(i) < 0 \end{cases} \quad (6)$$

剔除极小值:

$$F(i) = \begin{cases} 1, & \text{其他} \\ -1, & y_1(i-1) > y_1(i) < y_1(i+1) \end{cases} \quad (7)$$

将剔除的点所在位置的值置为0,得到 $y_4(i)$:

$$y_4(i) = \begin{cases} y_1(i), & F=1 \\ 0, & F=-1 \end{cases} \quad (8)$$

对剔除连续上升点、连续下降点和极小值点得到的 $y_4(i)$ 进行谱峰值合并处理,即设置频率范围门限 Δg , 将频率范围 Δg 内的线谱看作同一根线谱,其频率局部最大值点为

$$y_5(i) = \begin{cases} y_4(i), & \max[y_4(i)]_{\Delta g} > 0 \\ 0, & y_4(i) = 0 \end{cases} \quad (9)$$

对式(9)中 $y_5(i)$ 剩下的局部最大值点进行门限阈值处理,即得到线谱特征。

1.2 线性预测倒谱特征提取

舰船目标是一个复杂的发声体,即一个声频系统。通过水听器侦听到的噪声信号也可近似看作语音信号,这种语音信号就是目标中的各种噪声源通过这一声频系统产生的响应,即声频系统冲激响应和激励噪声源两者在时域中的卷积,简单来说也就是将船体视为一个响应系统,而内部的各个工作部

件就是这个系统的输入激励信号，由于船体本身是不变的，那么分离出来的响应函数也就能代表舰船的目标特性^[8]。

线性预测系数(Linear Prediction Coefficients, LPC)是用过去 p 个时刻的声信号采样值的线性组合以最小的预测误差对下一时刻的信号进行预测^[9]，该预测值定义为对噪声信号 $x(n)$ 的 p 阶线性预测，预测值表示为：

$$\hat{x}(n) = -\sum_{i=1}^p a_i x(n-i) \quad (10)$$

式中，系数 $a_i (i=0,1,2,\dots,p)$ 称为噪声信号的线性预测系数，即 LPC。

信号 $x(n)$ 的倒谱 c_n 反映了信号的时域特征，定义^[10]为

$$c_n = Z^{-1}[\ln X(z)] \quad (11)$$

式中， $X(z)$ 为信号 $x(n)$ 的 Z 变换。

水听器接收到的声信号可以表示为

$$x(n) = f(n) * h(n) * h_c(n) + N(n) \quad (12)$$

式中： $f(n)$ 为目标中的激励噪声源； $h(n)$ 为目标作为一个响应系统时的冲激响应； $h_c(n)$ 为声信道的冲激响应； $N(n)$ 为加性噪声，一般情况下可将加性噪声视为高斯白噪声。将信号中的加性噪声进行高斯平滑预处理，以尽量减小对目标噪声信号的影响，将模型简化为

$$x(n) = f(n) * h(n) * h_c(n) \quad (13)$$

为了分离目标声频特性冲激响应 $h(n)$ ，对信号进行倒谱计算，设式(3)中 $x(n)$ 、 $f(n)$ 、 $h(n)$ 、 $h_c(n)$ 的倒谱分别为 c_n 、 f_n 、 h_n 、 h_{cn} ，则：

$$c_n = f_n + h_n + h_{cn} \quad (14)$$

由于相同情况下，不同目标舰船的声信道冲激响应 h_{cn} 基本不变，可将 h_{cn} 作为系统误差进行忽略，所以式(14)简化得到信号 $x(n)$ 的倒谱 c_n ：

$$c_n = f_n + h_n \quad (15)$$

若噪声使用全极点模型，舰船目标系统函数可表示为^[10]

$$H(z) = A \prod_{k=1}^p \frac{1}{1 - b_k z^{-k}} \quad (16)$$

式中： A 为常数， $|b_k| < 1$ ，根据倒谱定义，可得^[10]：

$$h_n = Z^{-1}[\ln H(z)] = \begin{cases} \ln A, & n=0 \\ \sum_{k=1}^p \frac{b_k^n}{n}, & n>0, |b_k| < 1 \\ 0, & n<0 \end{cases} \quad (17)$$

由上式可知 $h(n)$ 的倒谱 h_n 随 n 的增加而衰减，因此， h_n 集中在目标噪声信号倒谱的低时段。线性预测倒谱是基于时域划分的以时间片段为轴系的

特征，低时段指坐标轴中时间序列较低部分，高时段指坐标轴中时间序列较高部分。

激励噪声源 $f(n)$ 可以表示为周期性的冲激信号^[10]：

$$f(n) = \sum_{r=0}^M a_r \delta(n - rN_p) \quad (18)$$

对 $f(n)$ 求倒谱得到 f_n ^[9]：

$$f_n = \sum_i \sum_{m=1}^{\infty} (-1)^{m+1} \frac{a_i^m}{m} z^{-mN_p} + \sum_j \sum_{m=1}^{\infty} (-1)^{m+1} \frac{b_j^m}{m} z^{-mN_p} \quad (19)$$

可以看出激励噪声源的倒谱是周期性的冲激函数，周期 N_p 保持不变，因 N_p 相对于 n 较大，所以 f_n 处于高时段。

由于 h_n 和 f_n 所处的倒谱时段不同，通过提取噪声信号倒谱的低时段和高时段，可以将它们较好地分离。因此用噪声信号倒谱的低时段分量就可以很好地表示目标作为发声体的冲激响应^[9]。从而将信号中的激励噪声源 f_n 剔除，保留响应函数特征，即仅保留 h_n 。

将 LPC 系数代入式(15)推导得出舰船目标辐射噪声信号的 LPC 倒谱 c_n ^[9]：

$$\begin{cases} c_1 = a_1 \\ c_n = \sum_{i=1}^{n-1} (1 - \frac{i}{n}) a_{n-i} c_{n-i} + a_n, & 1 < n \leq p \end{cases} \quad (20)$$

式(20)中的 a_n 即为由式(10)计算得到的 LPC 系数。典型的 LPC 倒谱特征提取结果如图 2 所示。




图 2 典型的 LPC 倒谱特征
Fig.2 Typical cepstrum features of LPC

2 目标特征融合识别

2.1 特征融合识别方法

考虑到对目标的特征融合算法本身增大了识别算法整体的运算量和复杂度，本文采用将 BP 神经网络的输出向量作为决策级融合的输入数据。一方面因为 BP 神经网络具有优异的非线性映射能力，并且它的简单高效使其在模式识别领域被广泛

应用，另一方面由于特征融合导致的特征维数增加，而经过 BP 神经网络的判别后，特征维数被有效降低至低维矢量，再经过融合算法构成完整的识别系统，既有效降低了数据运算量，提高了系统效率，避免了维数过高可能带来的精度降低问题。决策级融合方式如图 3 所示。




图 3 决策级特征融合识别方式示意图
Fig.3 Schematic diagram of decision-level feature fusion

2.2 决策级融合的加权投票法

在决策级融合方法中，常见的有投票法、贝叶斯(Bayes)推理法、D-S 证据论证法^[11-13]。其中，投票法最为简单直观，且应用广泛。因此，本文采用加权投票决策级融合方式。

设定给定的模式空间 D 中的向量分属于 M 个互斥的集合 $C_1, C_2 \dots C_M$ ，识别系统由 J 个特征提取连接独立的分类器组合形成，若分类器 e_j 对于来自 C_i 的样本有期望输出 $E_{i,j}$ ，而在分类器 e_j 进行识别时产生的输出向量为 y_j ，由于期望输出向量 $E_{i,j}$ 与实际输出向量 y_j 基本不相同，并且类别相差越大的目标，向量 $E_{i,j}$ 与 y_j 差值越大。所以当期望输出向量 $E_{i,j}$ 与实际输出向量 y_j 差值较大时，赋予识别集合 C_i 较小权值，当 $E_{i,j}$ 与 y_j 差值较小时，赋予识别集合 C_i 较大权值。

权值计算流程如图 4 所示，权值公式定义为

$$P(D \in C_i | e_j(x_j) = y_j) = \frac{\exp(-\|E_{i,j} - y_j\|)}{\sum_{i=1}^M \exp(-\|E_{i,j} - y_j\|)} \quad (21)$$

相对距离定义为

$$S_{ij} = \frac{\|E_{i,j} - y_j\|}{\sum_{i=1}^M \|E_{i,j} - y_j\|} \quad (22)$$

以往的决策级融合方式仅有对类别向量的权值计算，各个分类器仍以相同的票数输出识别结果，当某一识别方法出现严重错误时，对融合识别结果会产生不利影响，为了改进这个问题，本文在各个分类器后端再加入对分类器的置信度算法，即将各个分类器输出向量与类别期望向量的相对距离最小值作比较，将相对距离最小值较低的赋予高支持度，相对距离最小值较大的赋予低支持度。例如， y_1 与 $E_{3,1}$ 的相对距离 $S_{3,1}$ 作为同分类器对不同类别期望向量的最小值， y_2 与 $E_{2,2}$ 的相对距离 $S_{2,2}$ 作为同分类器对不同类别期望向量的最小值，若

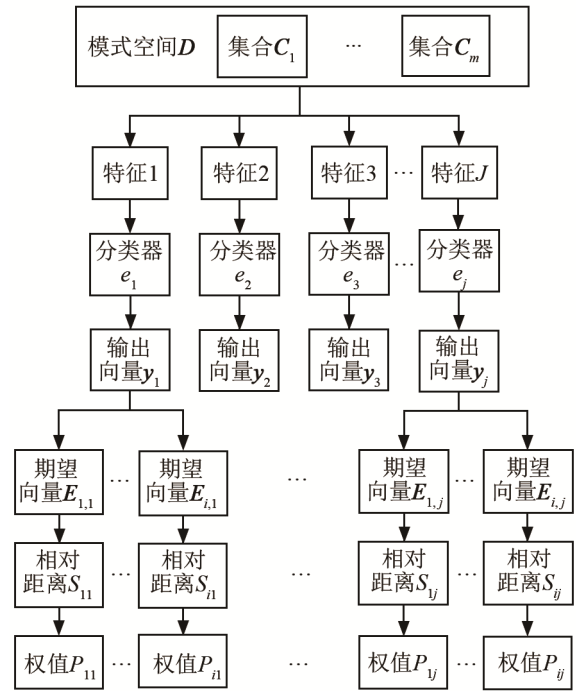


图 4 权值计算流程图
Fig.4 Flow chart of weight calculation

$S_{3,1} < S_{2,2}$ ，则说明 1 号分类器所对应的特征提取方式在该环境下的准确率高于 2 号分类器所对应的特征提取方式。此时赋予 y_1 的权值 $P(D \in C_i | e_1(x_1) = y_1)$ 一个较大的支持度，赋予 y_2 的权值 $P(D \in C_i | e_2(x_2) = y_2)$ 一个较小的支持度。

支持度计算流程如图 5 所示， $D \in C_i$ 的总票数可表示为

$$P(D \in C_i) = \sum_{j=1}^J P(D \in C_i | e_j(x_j) = y_j) \times S_{up,j}, \quad (i=1, 2, \dots, M) \quad (23)$$

式中，设支持度 $S_{up,j}$ 满足标准正态分布，定义为

$$S_{up,j} = \frac{S_{up0,j}}{\sum_{j=1}^J S_{up0,j}} \quad (24)$$

$$S_{up0,j} = 2 \int_{-\infty}^{-O_j} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx \quad (25)$$

则积分上限 O_j 为各分类器产生输出向量中相对距离最小值的负数：

$$O_j = \min_i S_{ij}, \quad i=1, 2, \dots, M \quad (26)$$

基于多个分类器输出向量加权投票法的判决规则 $E(D)$ 为^[14]

$$E(D) = \begin{cases} k, & P(D \in C_k) = \max_{i \in \Lambda} P(D \in C_i) \geq T_k \\ 0, & \max_{i \in \Lambda} P(D \in C_i) \leq T_k, \text{ 拒绝识别} \end{cases} \quad (27)$$

式中： T_k 为决策阈值根据系统需求设定； k 为某个已设定类别； $P(D \in C_i)$ 为式(23)计算得到输入数据属于 C_i 类别的票数。该系统引入拒判机制，当票数

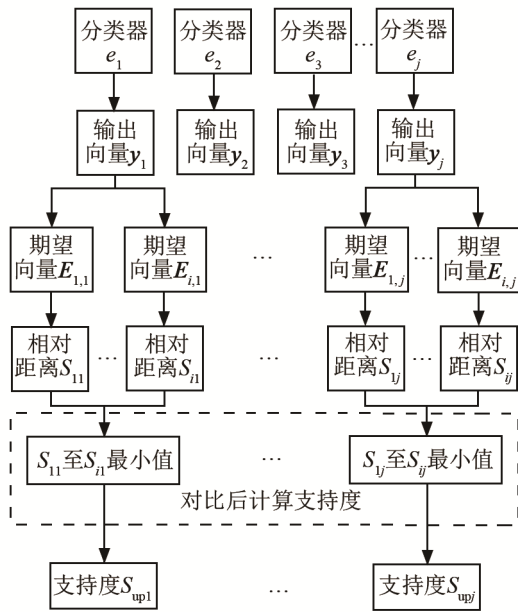


图 5 支持度计算流程图

Fig.5 Flow chart of support calculation

P 低于决策阈值 T_k 时，判决输入数据不属于数据库内的已知目标，防止识别系统将数据库外的目标进行误判。

3 实验验证

3.1 实验概述

为验证本文提出的舰船目标识别方法的有效性，在某海域进行了实验验证实验。实验涉及三类实船目标，主要参数如表 1 所示。实验海域为泥沙质斜坡式海底，水深 30~50 m，海况 3~4 级。参照实船噪声测试规范，实验过程中，被测舰船由出发点加速至目标航速，以既定正横距离通过测量系统后驶出测量区域。选取每段噪声数据末尾处即目标舰船离开测量区域后的测试数据作为背景噪声，以目标舰船处于正横处的测试数据作为信号计算信噪比。

表 1 三类目标船型数据

Table 1 The data of three types of target ship

目标类别	船型	船长/m	型宽/m	吃水深度/m	排水量/t
A 类	交通艇	45	8.4	4.0	438
B 类	拖轮	40	10	4.0	700
C 类	实验船	86.9	14.6	4.0	2 300

针对三类舰船辐射噪声数据进行分析，其中：

(1) 交通艇测试数据 206 个，航速均为 6 kn (1 kn=1.852 km·h⁻¹)，测试正横距离 300 m，水深 30 m，信噪比约为 11.1 dB，验证大数据量情况下系

统的识别效果；

(2) 拖轮测试数据 284 个，航速 4 kn，正横距离 300 m，水深 30 m，信噪比约为 10.8 dB 的数据 142 个；航速 7 kn，正横距离 1 500 m，水深 50 m，信噪比约为 3 dB 的数据 142 个，主要验证目标相对距离对系统识别稳定性的影响；

(3) 某型实验船测试数据 198 个，航速 6 kn，正横距离 300 m，水深 30 m，信噪比约为 9.4 dB 的数据 70 个；航速 9 kn，拖桨滑行，正横距离 300 m，水深 30 m，信噪比约为 4.3 dB 的数据 71 个；航速 13 kn，正横距离 300 m，水深 30 m，信噪比约为 26.1 dB 的数据 57 个，验证不同工况及小数据量情况下识别系统的稳定性。

3.2 数据处理流程

(1) 将测量得到的 A、B、C 三类不同类型的船只辐射噪声分为训练组和测试组两组数据，挑选具有典型特征代表的的数据作为训练组，训练组样本个数分别为：A 类 56 个、B 类 84 个、C 类 61 个。测试组样本个数分别为：A 类 150 个、B 类 200 个、C 类 137 个。

(2) 将训练组噪声数据进行线谱特征提取和 LPC 倒谱特征提取，保存得到特征向量。

(3) 分别用线谱特征向量和 LPC 倒谱特征向量训练独立的 BP 神经网络并存储。

(4) 提取测试组数据的线谱特征，输入由训练组的线谱特征训练好的 BP 神经网络，得到单独使用线谱特征识别目标的识别率。

(5) 提取测试组数据的 LPC 倒谱特征，输入由训练组的 LPC 倒谱特征训练好的 BP 神经网络，得到单独使用 LPC 倒谱特征识别目标的识别率。

(6) 将测试组数据的线谱特征和 LPC 倒谱特征同时输入对应的 BP 神经网络分类器，得到两个分类器的输出向量后，输入至决策器进行判决，最终得出联合特征识别的识别率。

3.3 BP 神经网络及决策器设计

BP 神经网络设计为 3 层，其中输入层神经节点数为各自特征的维数，输出层神经节点数为 3，三类目标的期望输出值分别为 [1 0 0]、[0 1 0]、[0 0 1]。隐含层的神经节点数按照经验公式设计^[15]：

$$k = \sqrt{m+n} \tag{28}$$

其中： m 为输入层神经节点数， n 为输出层神经节点数。

经过多次实验得出的最优结果，设决策阈值 $T_k=0.45$ ，此时的判决准则为：输出向量得票数最高且超过决策阈值 T_k 的决策结果。

3.4 实验结果及分析

表 2~4 分别给出了不同工况下分别基于线谱特征、LPC 倒谱特征及融合时频域特征的三型船只识别结果。

表 2 基于 A 类目标识别结果
Table 2 Recognition result of Class A targets

航速/kn	识别方式	测试样本数	识别正确数	识别错误数	拒绝识别数	识别率/%
6	线谱特征	150	140	10	-	93.3
	倒谱特征	150	147	3	-	98
	融合识别	150	150	0	0	100


表 3 对于 B 类目标识别结果
Table 3 Target recognition result of Class B targets

航速/kn	识别方式	测试样本数	识别正确数	识别错误数	拒绝识别数	识别率/%
4	线谱特征	100	96	4	-	96
		100	99	1	-	99
7	倒谱特征	100	90	10	-	90
		100	86	14	-	86
4	融合识别	100	98	1	1	98
		100	99	1	0	99


表 4 对于 C 类目标识别结果
Table 4 Target recognition result of Class C targets

航速/kn	识别方式	测试样本数	识别正确数	识别错误数	拒绝识别数	识别率/%
6	9(拖桨) 线谱特征	50	47	3	-	94
		50	43	7	-	86
		37	35	2	-	94.5
6	9(拖桨) 倒谱特征	50	44	6	-	88
		50	41	9	-	82
		37	14	23	-	37.8
6	9(拖桨) 融合识别	50	47	3	0	94
		50	44	6	0	88
		37	35	2	0	94.5

如图 6 所示,对 A 类目标特征的线谱提取时发现,由于某单程受到不明来源的低频噪声干扰,导



(a) 无噪声干扰线谱图



(b) 有噪声干扰线谱图

图 6 A 类目标 6 kn 航速的线谱特征对比
Fig.6 Comparison of line spectrum feature of Class A targets at 6 kn speed

致测试组中的几个特征数据出现了较强干扰谱线,分类器对这几个特征数据误判。但由于总体信噪比条件良好,以 LPC 倒谱作为对目标时域特征的描述未受无节奏周期声干扰的影响,仍表现出对 A 类目标较高的识别率。而应用融合特征识别时将错误判例及时纠正,提高了对 A 类目标的识别率(表 2)。

由于 B 类目标的线谱特征较为明显,且作为训练组的数据具有代表性,对 B 类目标的线谱识别即使在远距离也具有极高的识别率,而 LPC 倒谱特征作为时域上的节奏性特征,远距离识别率出现下降,但两种特征依然互为补充,从而达到准确识别目标的效果(表 3)。

针对 C 类目标 13 kn 航速状态下的识别,由于训练组供分类器训练的数据样本较少,且工况中存在目标在加速状态后切换到匀速航行状态并转舵的情况,使声节奏叠加并受到干扰结果如图 7 所示。LPC 倒谱的识别率严重降低,决策器通过置信度算法显示分类器偏移期望向量过大,自动给予线谱特征识别方式较高的支持度,而线谱在谱值积累的作用下抑制了短时出现的转舵声,仍有较好的识




图 7 C 类目标 13 kn 航速的 LPC 倒谱特征对比
Fig.7 Comparison of LPC cepstrum feature of class C targets at 13 kn speed

别率,使总识别率不受LPC倒谱特征的影响,即联合特征的识别率仍与线谱特征识别率持平(表4)。

4 结论

本文提出了一种融合时频域特征,并在常用的加权投票法后加入置信度算法的识别方法,对三类不同类型的舰船在多种工况下进行识别,分析了不同识别方法的特点,通过实验验证了本方法的可行性。

研究发现,对于舰船目标声学特征的描述,频域方面的线谱特征识别率较为稳定,时域方面的LPC倒谱特征识别率波动较大,推测其使用的声节奏特征易受到复杂工况和环境叠加干扰的影响,后续研究将加强对该方面进行验证。尽管如此,由于频域和时域对目标声学特征的描述方式不同,呈现出互补的效果,所以融合多种特征的目标识别方式可以互相修正某些错误判别,具有较强的鲁棒性,可提升对目标的识别率。加权投票法后加入置信度算法的方式,避免了常用投票法中出现被低识别率识别方法拉低总识别率的问题,提高了识别系统的稳定性和可信度。

本文将线谱特征作为融合特征之一,但近代舰船大量使用大侧斜螺旋桨,大幅降低了叶频和谐波噪声。为了在低信噪比状况下提取目标低频线谱特征,研究人员提出了DEMON谱分析、循环平稳谱分析、Hilbert-Huang变换、小波分析等系列方法。后续研究可考虑将上述方法融入到本文提出的多特征联合识别系统,进一步提升目标识别的准确率和鲁棒性。

致谢 感谢大连测控技术研究所科研一室参加海试的科研人员,他们对实验数据获取做了大量的工作。

参 考 文 献

- [1] 程玉胜,邱家兴,刘振,等. 水声被动目标识别技术挑战与展望[J]. 应用声学, 2019, 38(4): 653-659.
CHENG Yusheng, QIU Jiaying, LIU Zhen, et al. Challenges and prospects of underwater acoustic passive target recognition technology[J]. Journal of Applied Acoustics, 2019, 38(4): 653-659.
- [2] 程玉胜,李智忠,邱家兴. 水声目标识别[M]. 北京: 科学出版社, 2018: 81-92.
- [3] 柳革命,孙超,杨益新. 基于特征融合的被动声纳目标识别[J]. 计算机仿真, 2009, 26(8): 326-329.
LIU Geming, SUN Chao, YANG Yixin. Passive sonar target recognition based on feature fusion[J]. Computer Simulation, 2009, 26(8): 326-329.
- [4] 王海燕,贺一平,申晓红,等. 相关证据下的水中目标识别方法研究[J]. 探测与控制学报, 2003, 25(1): 25-28.
WANG Haiyan, HE Yiping, SHEN Xiaohong, et al. Study on target recognition based on D-S theory of Co-evidence[J]. Journal of Detection & Control, 2003, 25(1): 25-28.
- [5] 史广智,胡均川. 基于小波包和 1(1/2)维谱的舰船辐射噪声频域特征提取及融合[J]. 声学技术, 2004, 23(1): 4-7.
SHI Guangzhi, HU Junchuan. Extraction and fusion of frequency-domain features from ship radiated-noise based on wavelet packet and 1(1/2)-dimensional spectrum[J]. Technical Acoustics, 2004, 23(1): 4-7.
- [6] LEGAULT R, NADAL C, SUEN C Y, et al. Complementary algorithms for the recognition of totally unconstrained handwritten numerals on Proceedings[C]//10th International Conference on Pattern Recognition. Concordia University, 1990: 131-143.
- [7] 李杨. 水下瞬态信号特征提取与多分类器融合[D]. 哈尔滨: 哈尔滨工程大学, 2009.
- [8] 励荣锋,陈磊. 水声目标辐射噪声可分性时频特征的选择和提取研究[J]. 声学及电子工程, 2013(3): 10-12, 22.
- [9] 柳革命,孙超,刘兵. 基于线性预测倒谱的被动声纳目标特征提取技术[J]. 应用声学, 2007, 26(5): 277-281.
LIU Geming, SUN Chao, LIU Bing. Technique of passive sonar target feature extraction based on lpc cepstrum[J]. Applied Acoustics, 2007, 26(5): 277-281.
- [10] 张军英. 说话人识别的现代方法与技术[M]. 西安: 西北大学出版社, 1994: 14-30.
- [11] 强超超,王元斌. 水声目标识别技术现状与发展[J]. 指挥信息系统与技术, 2018, 9(2): 73-78.
QIANG Chaochao, WANG Yuanbin. Current situation and development of underwater acoustic target recognition technology[J]. Command Information System and Technology, 2018, 9(2): 73-78.
- [12] 张晓,王莉莉. 基于多分类器融合的卫星图像舰船目标识别[J]. 通信技术, 2019, 52(9): 2143-2148.
ZHANG Xiao, WANG Lili. Ship target recognition from satellite images base on multi-classifier fusion[J]. Communications Technology, 2019, 52(9): 2143-2148.
- [13] 胡金海,余治国,翟旭升,等. 基于改进 D-S 证据理论的航空发动机转子故障决策融合诊断研究[J]. 航空学报, 2014, 35(2): 436-443.
HU Jinhai, YU Zhiguo, ZHAI Xusheng, et al. Research of decision fusion diagnosis of aero-engine rotor fault based on improved d-s theory[J]. Acta Aeronautica Et Astronautica Sinica, 2014, 35(2): 436-443.
- [14] ZHANG X C, YE P, PENG S Y, et al. Dsiammft: an rgb-t fusion tracking method via dynamic siamese networks using multi-layer feature fusion[J]. Signal Processing: Image Communication, 2020, 84: 115756.
- [15] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.