Feb., 2023

引用格式: 刘洁,陈劼,韩冰,等.基于改进小波阈值去噪的深度学习水下目标分类[J]. 声学技术, 2023, 42(1): 25-33. [LIU Jie, CHEN Jie, HAN Bing, et al. Deep learning underwater target classification based on improved wavelet threshold denoising[J]. Technical Acoustics, 2023, 42(1): 25-33.] DOI: 10.16300/j.cnki.1000-3630.2023.01.005

基于改进小波阈值去噪的深度学习水下目标分类

刘 洁,陈 劼,韩 冰,马绪峰,安 杰 (电子科技大学通信抗干扰技术国家级重点实验室,四川成都 611731)

摘要:由于海洋环境噪声复杂,噪声等级高,水下待识别目标信噪比低,从而造成了特征提取困难,目标识别率低 的问题。基于此,文章提出了基于改进小波阈值的深度学习水下目标分类方法。此方法在传统小波阈值去噪的基础 上提出了一种新的小波阈值函数,对于所采用的具体阈值将其与分解尺度相联系,从而实现降低背景噪声,提升水 下目标分类识别率的目的。此方法对实测舰船辐射噪声信号进行小波分解,提取每一层的高频小波系数并对其进行 处理:对处理完的信号再提取时频特征,最后将其输入后续的深度学习网络中。实验结果发现:在利用原有数据集 情况下,利用基于改进小波阈值的深度学习进行水下目标的分类识别,采用卷积神经网络算法可达到88.56%的分类 识别率。对前述实验结果进一步分析后,采用生成对抗网络的方法扩充数据样本,可达到96.673%的分类识别率。 关键词:水下目标分类:小波分解;特征提取;信号去噪;深度学习

中图分类号: 0427 文章编号: 1000-3630(2023)-01-0025-09 文献标志码: A

Deep learning underwater target classification based on improved wavelet threshold denoising

LIU Jie, CHEN Jie, HAN Bing, MA Xufeng, AN Jie

(University of Electronic Science and Technology of China, National Key Laboratory of Communication Anti-interference Technology,

Chengdu 611731, Sichuan, China)

Abstract: Because of the complex marine ambient noise and low signal to noise ratio of the underwater targets to be identified, it is difficult to extract target features, and the target recognition rate is low. Aiming at this problem, a deep learning underwater target recognition method based on improved wavelet threshold is proposed in this paper. In this method, a new wavelet threshold function based on the traditional wavelet threshold denoising method is adopted. The specific threshold relates to the decomposition scale, so as to reduce the background noise and improve the recognition rate of underwater targets. This method performs the wavelet decomposition of the measured ship radiated noise signal and extracts the high-frequency wavelet coefficients of each layer for processing. The time-frequency characteristics of the processed signal are extracted and input it into the subsequent deep learning neural network. The experimental results find that, for the original data set, the deep learning underwater target recognition method based on the improved wavelet threshold can bring the recognition rate of convolutional neural network (CNN) to 88.56%. Further analysis shows that by using a generative adversarial network (GAN), the data samples can be expanded to reach a recognition rate of 96.673%.

Key words: underwater target classification; wavelet decomposition; feature extraction; signal denoising; deep learning

0 引言

地球上的海洋面积远远超过陆地面积,同时海 洋中蕴藏着非常丰富的资源,所以世界各国对海洋 的勘探开发也是越来越重视。此外,海洋更是国家

安全的重要天然屏障,海洋的战略部署也一直是各 个国家的重点。战略核潜艇作为各国的一种威慑力 量在当今迅猛发展。对于战略核潜艇而言,信息在 海水介质中安全无错地传输便显得尤为重要印。

声波以其良好的传播特性成为了海洋研究中主 要的信息载体。但随着时代的发展,商业运输、采 矿工程以及其他自然现象逐渐发生改变, 使得海洋 中的噪声水平只增不减,海洋的研究愈发困难重 重。因此,去噪处理作为信号预处理的重要一环, 对于目标分类识别具有重要意义, 而如何有效的降 低噪声也一直是人们关注的焦点四。

收稿日期: 2021-09-06; 修回日期: 2021-11-03

基金项目: 国家重点研发计划项目(2020YFB1807700)。

作者简介:刘洁(1996一),女,四川成都人,硕士研究生,主要研 究方向为水声目标识别。

通信作者: 马绪峰, E-mail: xufeng_ma@126.com

匹配滤波是应用广泛的一种降噪方法,其利用 了信号与噪声的分布的差异性,通过移动满足两种 信号频率特性的特定滤波器,来实现降低噪声的目 的。但对于含有宽带噪声的非平稳信号匹配滤波具 有局限性。文献[3]采用的局部投影降噪方法考虑 到了延迟时间与嵌入维数对降低噪声所产生的影 响,该方法结构简单,但当信号起伏较大时效果不 理想。针对水下目标的噪声特性, 1999年Hsung 等间提出了一种基于奇异值的去噪方法,该方法几 乎不需要了解噪声的先验信息,而是通过信号的局 部正则性来实现去噪。之后研究人员发现小波分解 可以克服传统方法中同频带信号与噪声无法区分开 的局限,因而Donoho^[5]提出的阈值去噪方法取得了 广泛的实际应用。文献[6]通过傅里叶系数阈值调 整与小波阈值变换相结合的组合算法,较大地提高 了水声信号的信噪比,实现了水声信号的有效提 取。基于小波分解的方法也是近年来的热门去噪方 法之一, 文献[7-8]也是通过小波基与阈值的选取来 实现降噪。此外,采用小波能谱系数的方法提取目 标信号特征也能有效反映信号的本质特征,并在后 续处理中获得较高的识别率的。

伴随着大数据迅猛发展的深度学习已经被运用 到各个领域,如语音与图像的识别等。深度学习的 结构在某些特定的任务中的表现不亚于人类^[10-1]。 如何改进深度学习方法,使其更好地应用于水下环 境也一直是科研工作者的研究重点。

与基于经验模态、奇异值分解等其他常用的信 号去噪方法相比,本文提出的改进小波阈值去噪方 法对于常用信号与实测的舰船辐射噪声均可以实现 有效地信号去噪,以达到提升信噪比、降低均方误 差的目的。采用卷积神经网络算法对去噪后的信号 进行分类,和传统方法相比信号识别率有大幅度提 高。对于其中部分类别识别率较高的情况,对卷积 神经网络进行叠加生成对抗网络,以此来实现数据 样本集的扩充,扩充后的数据识别率得到了大幅提 高,最终可达到96.673%。

1 基于改进型小波阈值的信号去噪方法

20世纪80年代中后期,小波理论已经发展成 熟,其呈现的多分辨率特点及对信号的精细表达, 使得小波分析广泛应用于信号处理的各个方向^[12]。 小波分析也成为了信号处理领域的常用手段。

小波滤波方法其基函数选择多样,多分辨率和 时频域的局部化表示让它能在去除噪声的同时保留 信号的突变部分。 1992年, Donoho等^[13]提出了小波阈值去噪方 法。该算法的主要理论基础是:对信号进行小波变 换后,有用信号与噪声的能量分布呈现出不同的特 点,较大的小波系数中主要包含有用信号,而噪声 却呈现出在整个小波域中分布的特点,这是一种很 强的去数据相关性。由此可知,当小波系数幅度较 大时一般属于有用信号,而小波系数幅度较小时则 主要为噪声。因此,从小波系数出发,对其采用阈 值法,降低噪声系数,保留信号系数。此算法计算 量小,原理简单,能有效去除噪声。最后,灵活选 择小波变换的小波基可使其在不同的场合下有更加 丰富的应用。

1.1 小波阈值去噪算法理论

s(t) = y(t) + n(t)

含噪声信号的表达式为

(1)

式中: y(t)为真实信号, n(t)为噪声信号, s(t)为含 噪声信号。小波阈值去噪的步骤如下:

(1)选择一个小波基类型与小波分解层次N, 对含噪信号s(t)进行N层小波分解,得到各层的小 波系数。

(2) 对*N*层的高频小波系数采取合适的阈值进行量化,利用其去相关性达到抑制噪声的目的。

(3) 对处理后的信号重构,得到去噪声后的信号,如图1为对信号 *s*(*t*)进行四层小波分解,其中 *W*_{CD1}~*W*_{CD4}为每层小波分解的高频小波系数, *W*_{CA1}~*W*_{CA4}为低频小波系数,噪声主要包含在低频 小波系数中,所以需要采用一个合适的阈值来抑制 低频小波系数,而小波阈值去噪方法的核心就是阈 值的选择。



图 1 小波分解过程示意图 Fig.1 Schematic diagram of wavelet decomposition process

1.2 软、硬阈值去噪函数

软阈值函数和硬阈值函数是目前最常用的两种 小波阈值处理函数。

对于有用信号,当其对应的小波系数 W_{j,k}大于 阈值时,若采用软阈值方法,则在小波系数向零收 敛过程中,利用一个固定值λ,对于小于λ的小波 系数,直接置0。经过软阈值函数去噪的信号结果 表现得更加平滑。

软阈值表达式为

$$\hat{W}_{j,k} = \begin{cases} 0, & |W_{j,k}| \leq \lambda \\ \operatorname{sgn}(W_{i,k})(|W_{i,k}| - \lambda), & |W_{i,k}| > \lambda \end{cases}$$
(2)

式中: W_{ik}表示处理前的小波系数, Ŵ_{ik}表示小波系 数经过阈值处理以后的值, λ表示采用的阈值。软 阈值函数曲线如图2所示。



图2 软阈值函数曲线 Fig.2 Soft-threshold function curve

对于有用信号,当其对应的Wik大于阈值时, 若采用硬阈值方法,则直接保存其小波系数。可以 看出,对信号采取硬阈值函数去噪,可以较好地保 留其原始特征。

硬阈值表达式为

 $\begin{cases} 0 , |W_{j,k}| \leq \lambda \\ W_{j,k}, |W_{j,k}| > \lambda \end{cases}$ (3)

硬阈值函数曲线如图3所示。



Fig.3 Hard-threshold function curve

1.3 改进型小波阈值去噪算法

对软、硬阈值法分析后发现,软阈值法函数的 导数不连续,并且其处理后的小波系数的绝对值总 小于实际值,这些问题会导致在进行信号重构时产 生误差。而采用硬阈值法,在阈值点处估计的小波 系数不连续,这会导致信号在重构的过程中,在阈 值点处会产生震荡与振铃现象。传统的软、硬阈值 这样的处理方式,往往会造成过度去噪。

事实上,经过分析得知,在对信号进行若干层 次的小波变换后,其信号与噪声呈现出的分布特性 均不相同。如果选择了一个好的阈值函数,是可以 使重构后信号的小波系数与原始小波系数存在很小 的偏差。针对以上问题,本节提出一种改进的小波 阈值函数,其表达式为

$$\hat{W}_{j,k} = \begin{cases} 0, & |W_{j,k}| \leq \lambda \\ \alpha \operatorname{sgn}(W_{j,k})(|W_{j,k}| - \lambda) + (1 - \alpha), & |W_{j,k}| > \lambda \end{cases}$$
(4)

在软阈值函数中,对于大于阈值的小波系数添 加加权因子 α :

$$\alpha = \frac{\lambda}{\left|W_{j,k}\right| \times \exp\left(\sqrt{\frac{\left|W_{j,k}\right| - \lambda}{\left|W_{j,k}\right| + \lambda}}\right)}$$

$$\lambda_{i} = \delta \sqrt{2\ln(n)} / \lg(j+1)$$
(6)

$$_{i} = \delta \sqrt{2\ln(n)} / \lg(j+1) \tag{6}$$

式中: *i*表示当前的分解尺度,阈值 *i*在通用的固定 规则中添加了一个分解尺度, n 代表小波分解总 数, $\delta = \operatorname{mid}(W_{1k})/0.6745$, W_{1k} 表示当前小波系数 的分解尺度为1,0≤k≤m,m表示当小波系数的尺 度为1时的小波系数总个数, mid()表示对 W_{14} 先取 绝对值再取中值。

从新的函数中可以看出随着分解尺度的增加, 阈值减小。而在添加加权因子后可以发现,因为 $0 \leq \sqrt{(|W_{i,k}| - \lambda)/(|W_{i,k}| + \lambda)} \leq 1$,所以处理后的 $\hat{W}_{J,k}$ 是 一个介于软、硬阈值方法之间的数值。当|Wikl趋近 于阈值 λ 的时候,加权因子 α 趋近于1,则处理后的 小波系数 \hat{W}_{lk} 趋近于 0,同时 \hat{W}_{lk} 在 λ 点是连续的, 这也解决了传统方法计算出来的软硬阈值函数在λ 点均不连续的问题。而当 $|W_{ik}|$ 较大时, \hat{W}_{ik} 趋近于 Wik, 解决了传统软阈值一直存在固定误差的问题。

此算法的具体步骤如下:

(1) 输入信号s(t),对其进行小波分解;

(2) 提取每一层的高频小波系数;

(3)利用前文式(6)计算每一层阈值;

(4)利用式(4)处理每一层小波系数;

(5) 对处理后的信号来进行小波重构。

1.4 基于改进型小波阈值变换去噪方法实验

为了说明改进后的小波阈值去噪算法的有效性 和优越性,本节分别采用了传统的软、硬阈值以及 改进的小波阈值在Matlab中进行去噪试验。首先采 用典型的Block 信号来进行仿真实验,该实验中选 用了db4小波进行分解,分解的小波层数为4层, 实验结果如图4所示。

从图4中可以看出,在叠加了噪声信号后,传 统的软、硬阈值的去噪方法去噪效果不彻底,去噪 后的波形毛刺较多,去噪的信号光滑度不佳且伴随 着部分波形的失真。图4(c)中第三个波形为改进小 波阈值去噪后的波形。可看出该方法相对于软、硬 阈值的方法去噪效果有明显的改进,信号的波形更 加平滑,同时重构信号与原始信号的逼近程度也更 高。根据实验结果同样可以看出,改进的小波阈值 方法效果明显优于软、硬阈值去噪的效果。





Block信号去噪后的信噪比(Signal to Noise Ratio, SNR)和均方根误差(Root Mean Square Error, RMSE)如表1所示。

接下来将对数据库内实际采集到的水声信号进 行处理。如图5所示为数据库内一段实测信号分别 采用改进小波阈值去噪以及软/硬阈值去噪后的结 果。通过图5中的实测信号波形可以看出,经过 软、硬阈值去噪后的信号波形效果明显不如基于改 进的小波阈值方法,在图中红圈所示的位置处, 软、硬阈值方法去噪后波形的毛刺更多,并且通过 人耳听到的噪声也是更为明显。

表1 不同去噪方法时Block信号的实验结果 Table 1 Experimental results of different denoising methods for Block signal

去噪方法	SNR/dB	RMSE
软阈值	8.391 3	0.107 0
硬阈值	6.973 6	0.182 1
改进小波阈值	14.785	0.058 9



Fig.5 Simulation diagram of wavelet threshold denoising of measured underwater acoustic signal

实测水声信号去噪后的信噪比和均方根误差如 表2所示。

表2 不同去噪方法实测水声信号的实验结果 Table 2 Experimental results of different denoising methods for measured underwater acoustic signals

		U	
去噪方法	SNR/dB	RMSE	
软阈值	0.318 4	0.006 1	
硬阈值	-0.570 1	0.009 1	
改进小波阈值	3.494 3	0.003 2	

由上述分析的 SNR 和 RMSE 指标显示,对 Block信号和实测水声信号,改进小波阈值方法降 噪后的信噪比更高,均方误差更小。由此验证了小 波阈值去噪方法的有效性,同时还验证了改进小波 阈值的降噪效果比其他几种方法更好。

2 基于改进型小波阈值的水声信号 智能分类识别框架设计

本节基于卷积神经网络与生成对抗网络来实现 水下目标的智能分类识别,其具体的实现框图如图 6所示。

该结构分为三个模块,分别是信号输入模块、 信号预处理模块与基于深度学习的目标分类识别 模块。

(1)信号输入,信号的输入可以是实测的水声 信号也可以是根据水声信号特征的仿真信号。本文



图6 水声信号智能识别框图

Fig.6 Block diagram of intelligent recognition framework of underwater acoustic signal

在后面的实验验证中采用的是 ShipsEar 实测数据。

(2)信号预处理,输入网络的信号根据其特征 进行预处理,预处理模块包含了多种处理方式与方 法,本文主要介绍信号去噪和特征提取这两类预处 理方式,特征提取模块主要包含了短时傅里叶变换 方法、Cohen双线性变换方法与小波变换方法三种。

(3)目标识别,对于水声信号,在根据其特性 进行预处理后,输入到基于深度学习的分类识别模 块。此模块中包含卷积神经网络以及针对数据样本 量不足问题采用的生成对抗网络。

2.1 信号预处理模块

信号预处理包括:基于改进型小波阈值的信号 去噪处理与基于三种方法的特征提取处理。改进型 小波阈值的信号去噪处理方法已在第1节中详细描 述过,本节仅对三种特征提取方法进行简单介绍。

本文研究的水下的目标辐射噪声就具有着非线 性与非平稳的特性,因此采用时频域分析法,通过 建立时频联合函数来同时得到信号的时频域信息, 并保障了可以局部分析信号。本文主要采用了短时 傅里叶变换和维格纳-维尔分布(Wigner-Ville Distribution, WVD)变换域小波变换。

短时傅里叶变换是一种最常见的时频分析方法,其计算过程是对于非平稳信号*s*(*t*),将其截取为许多长度相同但时间更短的信号,对于这样的信号可以假设其近似平稳,随后在每个时间段上计算 其傅里叶变换,截取的工具是一定长度的时间窗 函数。

本文所采用的WVD,具体描述如下:当x(t)为 任意的一时间连续信号,首先将 $x(t-\frac{\tau}{2})$ 与 $x(t+\frac{\tau}{2})$ 相乘,然后对两个时间差 τ 求傅里叶变换。其中 $x(t-\frac{\tau}{2})$ 与 $x(t+\frac{\tau}{2})$ 代表着时间的平移,即过去和未 来的某一时间信号。因为x(t)在式中出现了两次, 所以称为"双线性"^[14]。

小波变换利用了多分辨率分析的思想,借鉴了 短时傅里叶变换的思想,若当前的信号能量受限, 则考虑先在其函数空间中找到一组函数,使其成为 标准正交基,随后通过该函数的展开和平移来构成 小波变换。

2.2 基于卷积神经网络的水下目标智能分类识别 框架设计

2.2.1 卷积神经网络结构设计

对于实验中的卷积神经网络(Convolutional Neural Network, CNN),首先利用不同大小的卷积核来完成卷积与池化的工作以获得不同的信息尺度特征,以此实现平衡数据特征分布的全局性与局部性。随后级联每一个子层的输出并通过后续的卷积层与池化层,在完成卷积和池化后通过压平(Flatten)层与密集(Dense)层实现分类识别。

对于输入卷积神经网络的特征,先将其通过如 图7的结构,图中的五个卷积层卷积核大小均不 同,这样的操作让网络结构变得更宽,可以使得网 络的计算资源被更加高效地利用。而每一个卷积层 之后都会通过一个激活函数,这就增加了网络的非 线性程度。

图8是卷积神经网络后续的网络参数,每一层 卷积层后会经过一个relu激活函数与最大池化层来 减轻网络复杂度。





2.2.2 扩展数据样本的生成对抗网络设计

首先,生成对抗网络主要包含两种模型,即生成模型G与判别模型D。在实际操作过程中,对于输入的随机噪声N,首先通过生成模型G来生成尽量满足真实数据分布的数据样本G(Z)。判别模型D可以判断当前的输入样本是真实数据还是生成的数



Fig.8 Parameters of subsequent convolutional neural network

据 G(z)。生成对抗网络结构图如图9 所示。生成对抗网络的最终目标是让判别模型无法判断生成模型 产生的数据的真伪。



图9 主成为机网络石树图 Fig.9 Structure diagram of generative adversarial network

生成对抗网络的最终目标为

 $V_{GAN}(G, D) = E_{model}[\log_2 D(x)] + E_z \log_2\{1 - D[G(z)]\}(7)$ 式中: $E(\cdot)$ 表示数据的期望, x在通过判决网络后, 其被判断为真实样本值的概率为D(x)。对于 $E_z \log_2\{1 - D[G(z)]\}$, 当噪声输入生成网络后,G(z)代表生成网络生成的样本。生成的样本G(z)输入判 别网络后,D[G(z)]可以表示当前样本被判断为真 实样本的概率。

通过分析式(7)可知,生成器 G希望最小化 V_{GAN}(G,D),而判别器 D 则希望最大化 V_{GAN}(G,D)。 所以最优目标函数可以表示为

 $V_{\text{GAN}}^* = \arg\min_{G} \max_{D} V_{\text{GAN}}(G, D)$ (8)

通过式(8)我们可以看出生成器和对抗器是一种最大、最小博弈,当*D*[*G*(*z*)]接近1的时候,表示生成的样本接近真实样本;同时当*D*(*x*)接近1的时候,*D*[*G*(*z*)]接近0,表示判决当前输入样本为真实样本。

对于经过预处理后的数据,转换其维度为该生 成对抗网络的要求维度,然后将实测数据和随机噪 声输入网络中进行训练。具体的生成器算法和判别 器算法如下:

(1)生成器算法

① 输入随机噪声 $N=[n_0 \cdots n_{100}]$, X为经过预处 理后的样本。

② 设置相关的初始化参数,固定判别器D的参数,设置总迭代次数。

③ 在每一轮迭代中,依次经过全连接层来变换 输入维度,通过反卷积运算,损失函数计算,反向传 播更新网络参数。生成器的网络结构如图 10 所示。



Fig.10 Structure diagram of generator network

(2)判别器算法

① 输入真实的数据样本 $X_r = [x_1 \cdots x_n]$,其中 x_i 表示第i个输入样本。

② 固定生成器的网络参数,输入样本数据集, 分别设置网络的迭代次数。

③ 输入如图11所示的判别器网络,分别经过3 层卷积层与2层全连接层,Sigmoid函数是当前过 程的激活函数。

目前公开的水下实验数据样本量较小,因此水 下目标的识别率不高。通过生成对抗网络可以实现 样本集的扩充,进而提高水下信号的识别率。



Fig.11 Structure diagram of discriminator network

3 基于改进小波阈值的深度学习水 下目标信号分类识别实验

3.1 实验数据来源

由于水下信号的采集难度较大,所以目前公开 使用的数据库一直较少。本文选用了ShipsEar数据 库内中的实测水声信号来进行验证实验^[15-17]。在 2012年秋季及2013年夏季,研究人员在西班牙西 北部的大西洋海岸的不同区域,通过放置水听器录 制了水声信号,其中大部分信号是在vigo港口及其 附近录制的。录音信号包括渔船、远洋客轮、滚装 船、帆船等多种船舶类型。

由于整个录音过程捕获的是真实环境中船舶的 噪声数据,所以数据库还包含了人为与自然的背景 噪声以及各类海洋生物偶尔发出的声音。数据库内 共有90段wav格式的声音信号,时长在15 s~10 min 不等,声音信号共有11种类型,其中还包含了海 洋背景噪声。在此基础上,根据船舶的大小可以将 11种类型的信号分为4大类,如图12所示。

按照图12将船舶目标信号分为A、B、C、D 四类,图13为四类船舶信号所对应的原始波形。

本文在基于深度学习的水下目标智能识别过程



Fig.13 Original signal waveforms of four types of targets

中,其硬件与软件的实验环境如下:操作系统为 Ubuntu16.04,GPU为GTX 1080ti,编程环境为 MATLAB R2016b与Python3.6,最后深度学习库运 用到了Librosa音频处理库和Keras。

3.2 基于改进小波阈值的卷积神经网络识别仿真验证

对信号首先进行改进后的小波阈值去噪处理,

再通过短时傅里叶变换(STFT, short-time Fourier transform)、WVD变换、小波变换(WT)提取其特征,随后输入3.2节所述的卷积神经网络(CNN)。通过上述处理后输出的混淆矩阵如图14~16所示。









图15 基于去噪后WVD变换的混淆矩阵







ShipsEar数据库公开之后, 文献[18]中研究学 者就曾将其用于水下目标的识别中, 采用的方法是 提取信号的梅尔频率倒谱系数(Mel Frequency Cepstrum Coefficient, MFCC), 随后将提取到的MFCC 特征输入高斯混合模型(Gaussian Mixed Model, GMM), 从网络中得到四种目标类型的类别准确 率。将其与传统的分类识别方法相比较, 结果如表 3所示。

对表3进行分析,可以发现,基于小波阈值去 噪的处理方法从降低噪声入手来进行水下信号的预 处理,首先对信号进行去噪处理,随后对其采用三 种不同的时频特征提取方法再输入卷积神经网络 中,和传统的方法相比,识别率有较大提高。添加 小波阈值去噪的方法对C、D两种目标类别的识别 率较高,对A、B两类目标其识别率相对较差。对 实验样本进行分析,发现数据库内A、B两类信号 的样本数量较少,而深度学习的方法需要基于大量 的样本来进行模型的学习。所以判断是因为样本量 较少导致对数据库内A、B类信号的识别率较低。

3.3 基于改进小波阈值的生成对抗网络识别仿真验证

生成对抗网络可以实现数据集的扩展,对于类 似于水下目标的数据集有很好的扩展作用。将实测 信号输入生成对抗网络实现数据集样本扩展,深度 神经网络便可以更好地进行学习,可以提高最终的 目标识别率。

按照图6所示的网络模型图,对实测水声信号 首先进行改进的小波阈值去噪预处理,随后输入特 征提取模块,分别提取其短时傅里叶变换(STFT)、 WVD变换与小波变换(WT)的时频特征。对于时频 特征矩阵首先输入生成对抗网络,在生成对抗网络 中进行数据样本的扩展,训练生成器与判断器,最 终达到随机噪声输入模型后可以产生类似于输入样 本的数据,同时判别器无法进行判决以此扩充数据 样本。在扩充完数据样本后将其输入卷积神经网 络,卷积神经网络再对带标签的数据进行训练与决 策实现目标的分类识别,得到最终的识别率。三种 不同时频特征输入后所对应的输出混淆矩阵如图 17~19所示。









实测样本在经过改进的小波阈值去噪、三种不同时频特征提取、生成对抗网络扩充数据样本以及基于卷积神经网络的分类识别后,结果如表4所示。根据表4中可以看出,对于A、B、C、D四类阈值均有较高的识别率,平均识别率均大于90%。同时3.2节中作为对照组的信号特征增强,然后输入卷积神经网络的方法相比,本节所述的方法对于B 类信号的识别率有较明显的提高。对目标信号的识

	表3	基于改进小波阈值去噪后的卷积神经网络识别率	
Fable 3	Recognition rates of c	onvolutional neural network based on improved wavelet threshold denoising	5

	识别率/%			
目标类别	改进小波阈值去噪+ STFT+CNN	改进小波阈值去噪+ WVD+CNN	改进小波阈值去噪+ WT+CNN	MFCC+GMM
А	66.68	73.78	69.34	62.50
В	87.53	86.24	89.22	80
С	99.43	100	98.25	76.4
D	93.87	94.19	80.49	55.5
平均识别率/%	86.877 5	88.552 5	84.325	68.6



图19 扩充样本后基于小波变换的混淆矩阵

Fig.19 Confusion matrix based on wavelet transform after sample expansion

别,A类信号最高为95.51%,B类信号为93.57%, C类信号达到了100%,D类信号为97.61%,平均识 别率为96.67%。C类目标的识别率最高,B类目标 识别率稍低,但是在扩充样本后整体的识别率均相 比较之前的方法有显著提高。本文采用的方法有效 增强了其识别率较差的B类信号的识别率。

- 表4 基于改进小波阈值去噪后的生成对抗网络叠加卷积神经 网络的识别率
- Table 4 Recognition rates of generative adversarial network superimposed convolutional neural network based on improved wavelet threshold denoising

日行米別	识别率/%		
日你矢加	STFT+GAN	WVD+GAN	WT+GAN
А	90.32	95.51	89.71
В	89.35	93.57	91.51
С	100.00	100.00	99.42
D	95.35	97.61	92.68
平均识别率/%	93.755	96.6725	93.33

4 结论

本文研究了水下目标分类识别中集信号的预处 理和小样本数据集扩展方法。本文在传统小波阈值 去噪的基础上提出了一种新的小波阈值函数,对于 所采用的阈值和分解尺度相关联,从而降低背景噪 声,提升水下目标分类识别率。通过小波阈值去噪 方法,有效降低了信号的噪声。在利用原有实验数 据集情况下,其深度学习水下目标网络的识别率可 有一定程度的提高。对实验结果进一步分析之后, 采用生成对抗网络扩充原有数据集的数据样本,最 终达到了较高的水下目标分类识别率。后续将进一 步研究提高水下目标信号识别中去噪性能的处理 方法。

参考文献

[1] 陶笃纯.按辐射噪声平均功率谱形状识别船舶目标[J]. 声学学报, 1981, 4: 199-228

TAO Duchun. Identify ship targets according to the shape of the average power spectrum of radiated noise[J]. Acta Acoustica, 1981, **4**: 199-228.

- [2] 汪德昭,尚尔昌.水声学[M].北京:科学出版社,1981.
- [3] 郑宏民, 李亚安, 陈澜. 基于局部投影算法的舰船信号降噪处 理研究[J]. 西北工业大学学报, 2011, 29(4): 569-574.
 ZHENG Hongmin, LI Ya'an, CHEN Lan. Noise reduction of ship signals based on the local projective algorithm[J]. Journal of Northwestern Polytechnical University, 2011, 29(4): 569-574.
- [4] HSUNG T C, LUN D P K, SIU W C. Denoising by singularity detection[J]. IEEE Transactions on Signal Processing, 1997, 47(11): 3139-3144.
- [5] DONOHO D L. De-noising by soft-thresholding[J]. IEEE Transactions on Information Theory. 1995, 41(3): 613-627.
- [6] 常浩,杨立波,石字轩,等.一种强噪声环境下的水声信号提取 算法研究[J]. 测试科学与仪器, 2020, 11(3): 222-227.
 CHANG Hao, YANG Libo, SHI Yuxuan, et al. Underwater acoustic signal extraction algorithm in a strong noise environment[J]. Journal of Measurement Science and Instrumentation, 2020, 11(3): 222-227.
- [7] ALYASSERI Z A A, KHADER A T, AL-BETAR M A, et al. Hybridizing beta-hill climbing with wavelet transform for denoising ECG signals[J]. Information Sciences, 2018, 429:229-246.
- [8] WANG Y, CAO X, ZHANG J, et al. Detection and Analysis of All-Day Atmospheric Water Vapor Raman Lidar Based on Wavelet Denoising Algorithm[J]. Acta Optica Sinica, 2018, 38 (2): 8-17.
- [9] 魏鑫. 基于小波能谱系数的舰船目标分类与识别[J]. 舰船科学 技术, 2013, 35(9): 92-96.
 WEI Xin. Ship target classification and identification using wavelet energy spectrum coefficients[J]. Ship Science and Technology, 2013, 35(9): 92-96.
- [10] CIREŞAN D, MEIER U, MASCI J, et al. Multi-column deep neural network for traffic sign classification[J]. Neural Networks, 2012, 32: 333-338.
- [11] MNIH V, KAVUKCUOGLO K, SILVER D, et al. Human-level control through deep reinforcement learning[J]. Nature, 2015, 518(7540): 529-533.
- [12] 孙延奎. 小波分析及其应用[M]. 北京: 机械工业出版社, 2005.
- [13] DONOHO D L, JOHNSTONE I M. Ideal spatial adaptation by wavelet shrinkage[J].Biometrika, 1994, 81(3):425-455.
- [14] MALLAT S G. A theory for multiresolution signal decomposition: the wavelet representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1989, 11(7): 674-693.
- [15] RATLIFI L J, BURDEN S A, SASTRY S S. Characterization and computation of local Nash equilibria in continuous games [C]//Communication, Control, and Computing, USA, 2013, 917-924.
- [16] SHEN S, YANG H H, SHENG M P. Compression of a deep competitive network based on mutual information for underwater acoustic targets recognition[J]. Entropy, 2018, 20(4): 243.
- [17] SHEN S, YANG H H, LI J H, et al. Auditory inspired convolutional neural networks for ship type classification with raw hydrophone data[J]. Entropy, 2018, 20(12): 990.
- [18] SANTOS-DOMÍNGUEZ D, TORRES-GUIJARRO S, CARDENAL-LÓPEZ A, et al. ShipsEar: an underwater vessel noise database[J]. Applied Acoustics, 2016, 113: 64-69.