

纪念马大猷先生诞辰 110 周年

一种多址声呐探测波形增强检测方法

许彦伟^{1,2} 谷浩翔^{1,2} 刘明刚^{1,2†} 侯朝焕^{1,2}

(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)

2024 年 1 月 30 日收到

2024 年 7 月 25 日定稿

摘要 为了提高浅海水声环境多址声呐探测性能,提出了一种多址声呐探测波形及其增强检测方法。建立了浅海回波信道模型,生成了浅海多址声呐回波数据;将基于生成对抗网络 (GAN) 结构的信号增强网络与基于卷积-全连接网络结构的分类网络相结合,引入融合梯度 (FG) 训练方法,设计了 WGAN-FG 信号增强检测器;基于 WGAN-FG 信号增强检测器和传统卷积神经网络、循环神经网络、生成对抗网络及副本相关检测器,对浅海多址声呐回波检测性能进行了仿真分析。结果表明,基于深度学习的神经网络检测器相比传统的副本相关检测器具有更好的多径、多普勒和互干扰抑制能力,同时具备目标速度识别能力;而在神经网络检测器中, WGAN-FG 信号增强检测器在强干扰或强畸变条件下表现出更优的检测性能和目标速度判别能力。

关键词 信道畸变,生成对抗网络,信号增强检测,水下无人航行器,多址声呐

PACS: 43.30, 43.60

DOI: 10.12395/0371-0025.2024045

CSTR: 32049.14.11-2065.2024045

An enhanced signal detection method for a set of multiple access sonar detection waveforms

XU Yanwei^{1,2} GU Haoxiang^{1,2} LIU Minggang^{1,2†} HOU Chaohuan^{1,2}

(1 *Institute of Acoustics, Chinese Academy of Sciences* Beijing 100190)

(2 *University of Chinese Academy of Sciences* Beijing 100049)

Received Jan. 30, 2024

Revised Jul. 25, 2024

Abstract To improve the detection performance of multiple access sonar in shallow water acoustic channels, a set of multiple access sonar detection waveforms and their enhanced detection method are proposed. The shallow water target echo channel is modeled and the multiple access sonar data are generated. The WGAN-FG enhanced signal detector is designed, which consists of a generate adversarial network (GAN) signal enhancer and a fully connected convolutional neural network (CNN) classifier, using the fusion gradient (FG) training method. The detection performances of shallow water multiple access sonar echoes are analyzed by simulation methods using the WGAN-FG enhanced signal detector and the traditional detectors such as the CNN, recurrent neural network (RNN), GAN and replica correlation (RC). Simulation results show that the deep learning based neural network detectors have better multi-path, Doppler and mutual interference suppression capabilities than the RC detector. The neural network detectors also have the ability to measure the target speed. And the WGAN-FG enhanced signal detector has better detection performance and target speed identification ability than the other neural network detectors under strong interference or distortion conditions.

Keywords Channel distortion, Generate adversarial network, Enhanced signal detection, Unmanned underwater vehicle (UUV), Multiple access sonar

† 通讯作者: 刘明刚, liumg@mail.ioa.ac.cn

引言

受限于水声信道带宽窄、频率低, 以及强多径带来的时延扩展、目标或平台运动造成的多普勒扩展等原因, 现有的多用户探测 (MUD) 在解决多水下无人航行器 (UUV) 协同探测问题时仍面临较大挑战。文献 [1] 提出了基于正交频分线性调频信号的离散频率编码波形 (DFCW-OFD-LFM), 具有良好的自、互相关特性、抗混响性能和较大的多普勒容限和多址容量, 可以作为多 UUV 协同探测声呐波形。传统的宽带波形检测方法主要是匹配滤波器, 也称副本相关 (RC) 检测器。在高斯背景噪声下, 匹配滤波器拥有最大信噪比输出, 为最优线性检测器, 但是当回波信号具有时延或多普勒扩展时, 性能会急剧下降。

对于复杂分布信号处理问题, 深度神经网络 (DNN) 在图像、音频、自然语言处理等领域获得了巨大成功, 并且在雷达、声呐等领域被广泛研究^[2-6]。文献 [7] 使用单层以及多层感知机模型 (MLP) 在目标雷达回波分类问题上获得了较高的准确率, 文献 [8, 9] 均使用了卷积神经网络 (CNN) 对不同调制方式的雷达波形进行分类, 文献 [10] 使用了卷积神经网络和循环神经网络 (RNN) 对雷达跳频信号进行了检测与识别。此外, 在环境更加复杂的声呐等领域, 学者们研究了以生成对抗网络 (GAN)^[11-12] 为代表的生成式网络模型对失真严重的回波信号进行降噪增强, 文献 [13] 使用了具有自编码器 (AE) 结构的降噪生成对抗网络对接收信号的时频图进行降噪增强, 并使用 YOLOv3 网络对增强后的时频图进行目标检测, 从而实现波形识别。

以上方法在雷达和声呐领域波形检测方面取得了一定的成功, 但在多 UUV 协同探测方面, 一方面由于水声环境更加复杂, 存在更强的多径、多普勒效应, 另一方面水声信道频带资源有限, 不同回波信号极易相互干扰, 影响检测性能。为了进一步提高多址声呐探测性能, 本文在基于正交频分线性调频信号的离散频率编码波形基础上, 提出了多重正交离散频率编码波形, 并基于浅海信道模型, 仿真生成了多 UUV 协同探测场景下的回波数据。引入 WGAN (Wasserstein GAN) 结构^[14], 结合融合梯度 (FG) 训练方法, 设计了 WGAN-FG 信号增强检测器。基于不同信噪比、信干比、目标速度、多径数目下的仿真数据对 WGAN-FG 信号增强检测器及 CNN、RNN、GAN 等结构人工神经网络检测器和副本相关 (RC) 检测

器进行了仿真分析和性能评估。

1 多址声呐探测波形

多 UUV 协同探测时, 各 UUV 之间探测波形的干扰需尽可能小, 受限于水声信道多径引起的时延扩展与目标相对运动产生的多普勒扩展, 时分多址 (TDMA) 与频分多址 (FDMA) 波形性能和应用场景受限, 因此将码分多址 (CDMA) 作为本文的研究对象。传统码分多址波形有二进制相移键控 (BPSK) 波形和离散频率编码波形 (DFCW) 等, 而 BPSK 波形多普勒容限较小, 不太适合运动探测场景^[1], 本文着重讨论 DFCW-OFD-LFM 波形。为了增强 DFCW-OFD-LFM 波形特征, 并提高其多址容量和正交性, 本文在 DFCW-OFD-LFM 波形基础上, 提出了多重正交 DFCW-OFD-LFM 波形。

1.1 多址声呐探测波形信号模型

1.1.1 DFCW-OFD-LFM 波形信号

将 OFD-LFM 的载频调制方式与使用了 Costas 跳频编码的 DFCW 调制方法相结合, 得到 DFCW-OFD-LFM 信号, DFCW-OFD-LFM 信号模型为

$$s_{\text{DFCW_OFD_LFM}}(t) = \frac{1}{\sqrt{T}} \text{rect}\left(\frac{t}{T}\right) \sum_{n=1}^N s_n(t - (n-1)T_p),$$

$$s_n(t) = \text{rect}\left(\frac{t}{T_p}\right) e^{j2\pi[f_0 t + \frac{1}{2} k t^2 + (c_n - 1)\Delta f t]},$$

$$\text{rect}\left(\frac{t}{\alpha}\right) = \begin{cases} 1, & 0 \leq t \leq \alpha, \\ 0, & \text{其他}, \end{cases} \quad (1)$$

其中, s_n 表示第 n 个子波, N 表示 Costas 码阶数, T 为总的信号脉冲宽度, $T_p = T/N$ 为每个子波的脉冲宽度, c_n 为第 n 阶 Costas 码元, f_0 为信号起始频率, k 为子波 LFM 信号的斜率, 子波间的单位频率间隔 $\Delta f = M/T_p$, M 为正交频率间隔系数, $\text{rect}(t/\alpha)$ 为矩形窗函数, α 为矩形窗宽。

1.1.2 多重正交 DFCW-OFD-LFM 波形信号

在 DFCW-OFD-LFM 信号使用 Costas 跳频码对频率进行调制的基础上, 引入另一组对斜率进行调制的跳频码和对相位进行调制的跳频码得到多重正交 DFCW-OFD-LFM 信号。引入多组正交码能够使波形获得更好的互相关性能和自相关性能。表达式如下:

$$s_{\text{MO_DFCW_OFD_LFM}}(t) = \frac{1}{\sqrt{T}} \text{rect}\left(\frac{t}{T}\right) \sum_{n=1}^N p_n s_n(t - (n-1)T_p),$$

$$s_n(t) = \text{rect}\left(\frac{t}{T_p}\right) e^{j2\pi[f_0 t + \frac{1}{2} q_n k t^2 + (c_n - 1)\Delta f t]}, \quad (2)$$

其中, p_n 为调制相位的双极性正交二进制序列, q_n 为调制斜率的双极性二进制序列, 其他参数定义同式 (1)。

1.2 浅海回波信道模型

在理想水声信道下, 回波仅表示为发射信号 $s(t)$ 衰减和时延后与噪声的叠加:

$$s_r(t) = \alpha s(t - \tau_0) + n(t), \quad (3)$$

其中, α 为衰减因子, 表示总的传播损失引起的信号衰减, τ_0 表示双程传播时延, $n(t)$ 表示信道中的背景噪声。而在实际的海洋环境中, 通常存在海面反射, 海底反射以及海面海底多重反射, 从而产生多径效应, 引起回波波形的时间扩展。

等温层型简化浅海水声信道模型示意图如图 1 所示, 其中 D 为直达波信道, SS_1 为海面一次反射信道, BB_1 为海底一次反射信道, SB_1 为海面海底一次反射信道, BS_1 为海底海面一次反射信道。由此可对各个信道的时延以及时延差进行建模, D 信道、 SS_1 信道、 BB_1 信道的双程时延 τ_D , τ_{SS_1} , τ_{BB_1} 分别为

$$\tau_D = \frac{2\sqrt{R^2 + (h_2 - h_1)^2}}{c}, \quad (4)$$

$$\tau_{SS_1} = \frac{2\sqrt{R^2 + (h_1 + h_2)^2}}{c}, \quad (5)$$

$$\tau_{BB_1} = \frac{2\sqrt{R^2 + (2h - h_1 - h_2)^2}}{c}. \quad (6)$$

忽略强度较小的海底海面一次及多次反射信道回波, 等温层型简化浅海多径信道下回波信号可建模为

$$\begin{aligned} s_r(t) = & \alpha_D s(t - \tau_D) e^{j\varphi_D} + \alpha_{SS_1} s(t - \tau_{SS_1}) e^{j\varphi_{SS_1}} + \\ & \alpha_{BB_1} s(t - \tau_{BB_1}) e^{j\varphi_{BB_1}} + \alpha_{DSS_1} s(t - \tau_{DSS_1}) e^{j\varphi_{DSS_1}} + \\ & \alpha_{SS_1D} s(t - \tau_{SS_1D}) e^{j\varphi_{SS_1D}} + \alpha_{DDBB_1} s(t - \tau_{DDBB_1}) e^{j\varphi_{DDBB_1}} + \\ & \alpha_{BB_1D} s(t - \tau_{BB_1D}) e^{j\varphi_{BB_1D}} + \alpha_{SS_1BB_1} s(t - \tau_{SS_1BB_1}) e^{j\varphi_{SS_1BB_1}} + \\ & \alpha_{BB_1SS_1} s(t - \tau_{BB_1SS_1}) e^{j\varphi_{BB_1SS_1}} + n(t), \end{aligned} \quad (7)$$

其中, α_D , α_{SS_1} , α_{BB_1} 分别为回波信号经过信道 D、信道 SS_1 和信道 BB_1 的同信道往返回波幅度因子,




图 1 等温层型简化浅海多径信道模型

α_{DSS_1} , α_{SS_1D} , α_{DDBB_1} , α_{BB_1D} , $\alpha_{SS_1BB_1}$, $\alpha_{BB_1SS_1}$ 分别为 D 到 SS_1 信道、 SS_1 到 D 信道、D 到 BB_1 信道、 BB_1 到 D 信道、 SS_1 到 BB_1 信道和 BB_1 到 SS_1 信道的异信道往返回波幅度因子。 τ_D , τ_{SS_1} , τ_{BB_1} 分别为 D 信道、 SS_1 信道和 BB_1 信道的同信道往返回波时延, τ_{DSS_1} , τ_{SS_1D} , τ_{DDBB_1} , τ_{BB_1D} , $\tau_{SS_1BB_1}$, $\tau_{BB_1SS_1}$ 分别为 D 到 BB_1 信道、 SS_1 到 D 信道、D 到 BB_1 信道、 BB_1 到 D 信道、 SS_1 到 BB_1 信道、 BB_1 到 SS_1 信道的异信道往返回波时延。 φ_D , φ_{SS_1} , φ_{BB_1} 分别为信道 D、信道 SS_1 和信道 BB_1 的同信道往返回波最终相位跳变, φ_{DSS_1} , φ_{SS_1D} , φ_{DDBB_1} , φ_{BB_1D} , $\varphi_{SS_1BB_1}$, $\varphi_{BB_1SS_1}$ 分别为 D 到 SS_1 信道、 SS_1 到 D 信道、D 到 BB_1 信道、 BB_1 到 D 信道、 SS_1 到 BB_1 信道、 BB_1 到 SS_1 信道的异信道往返回波最终相位跳变。

若目标存在速度为 v 的运动, 假设声呐平台静止, 令目标接近声呐时速度为正, 目标运动方向与目标反射回波方向存在夹角时, 引起多普勒效应的等效速度为目标运动速度在回波方向上的投影。当信道中存在多径时, 每条多径回波多普勒效应的等效速度为目标运动速度在各多径反射回波方向上的投影, 考虑多普勒效应后的回波信号可建模为

$$\begin{aligned} s_r(t) = & \alpha_D \sqrt{\eta_D} s(\eta_D(t - \tau_D)) e^{j\varphi_D} + \\ & \alpha_{SS_1} \sqrt{\eta_{SS_1}} s(\eta_{SS_1}(t - \tau_{SS_1})) e^{j\varphi_{SS_1}} + \\ & \alpha_{BB_1} \sqrt{\eta_{BB_1}} s(\eta_{BB_1}(t - \tau_{BB_1})) e^{j\varphi_{BB_1}} + \\ & \alpha_{DSS_1} \sqrt{\eta_{DSS_1}} s(\eta_{DSS_1}(t - \tau_{DSS_1})) e^{j\varphi_{DSS_1}} + \\ & \alpha_{SS_1D} \sqrt{\eta_{SS_1D}} s(\eta_{SS_1D}(t - \tau_{SS_1D})) e^{j\varphi_{SS_1D}} + \\ & \alpha_{DDBB_1} \sqrt{\eta_{DDBB_1}} s(\eta_{DDBB_1}(t - \tau_{DDBB_1})) e^{j\varphi_{DDBB_1}} + \\ & \alpha_{BB_1D} \sqrt{\eta_{BB_1D}} s(\eta_{BB_1D}(t - \tau_{BB_1D})) e^{j\varphi_{BB_1D}} + \\ & \alpha_{SS_1BB_1} \sqrt{\eta_{SS_1BB_1}} s(\eta_{SS_1BB_1}(t - \tau_{SS_1BB_1})) e^{j\varphi_{SS_1BB_1}} + \\ & \alpha_{BB_1SS_1} \sqrt{\eta_{BB_1SS_1}} s(\eta_{BB_1SS_1}(t - \tau_{BB_1SS_1})) e^{j\varphi_{BB_1SS_1}} + n(t), \end{aligned} \quad (8)$$

式中, $\eta_D = (c + v_D)/(c - v_D)$, $\eta_{SS_1} = (c + v_{SS_1})/(c - v_{SS_1})$, $\eta_{BB_1} = (c + v_{BB_1})/(c - v_{BB_1})$ 分别为回波信号经过信道 D、信道 SS_1 和信道 BB_1 的同信道往返回波多普勒压缩因子, $\eta_{DSS_1} = (c + v_D)/(c - v_{SS_1})$, $\eta_{SS_1D} = (c + v_{SS_1})/(c - v_D)$, $\eta_{DDBB_1} = (c + v_D)/(c - v_{BB_1})$, $\eta_{BB_1D} = (c + v_{BB_1})/(c - v_D)$, $\eta_{SS_1BB_1} = (c + v_{SS_1})/(c - v_{BB_1})$, $\eta_{BB_1SS_1} = (c + v_{BB_1})/(c - v_{SS_1})$ 分别为回波信号经过 D 到 SS_1 信道、 SS_1 到 D 信道、D 到 BB_1 信道、 BB_1 到 D 信道、 SS_1 到 BB_1 信道和 BB_1 到 SS_1 信道的异信道往返回波多普勒压缩因子。 v_D , v_{SS_1} , v_{BB_1} 分别为目标运动速度在信道 D、信道 SS_1 和信道 BB_1 方向上的分量:

$$v_D = v \cos(\psi_D), \quad \psi_D = \tan^{-1} \left(\frac{h_2 - h_1}{R} \right), \quad (9)$$

$$v_{SS1} = v \cos(\psi_{SS1}), \psi_{SS1} = \tan^{-1} \left(\frac{h_1 + h_2}{R} \right), \quad (10)$$

$$v_{BB1} = v \cos(\psi_{BB1}), \psi_{BB1} = \tan^{-1} \left(\frac{2h - h_1 - h_2}{R} \right). \quad (11)$$

1.3 波形特征分析

以多重正交 DFCW-OFD-LFM 信号为研究对象, 分别基于宽带模糊函数和时频特性分析, 对多 UUV 协同探测场景下波形信号进行波形特征分析, 波形基本参数设置如表 1 所示。

表 1 发射波形参数设置

采样率 f_s (kHz)	40	信号总脉宽 T (ms)	100
信号起始频率 f_l (kHz)	10	子信号带宽 B_s (kHz)	1.64
信号终止频率 f_h (kHz)	15	子信号频率间隔 Δf (kHz)	0.56
信号总带宽 B (kHz)	5	子信号脉宽 T_p (ms)	14.29

1.3.1 宽带模糊函数

UUV 探测波形为宽带波形, 因此使用宽带模糊函数分析波形特征。宽带模糊函数表达式为

$$\begin{aligned} \psi(\tau, \eta) &= |\chi(\tau, \eta)|^2 = |\sqrt{\eta} \int s(\eta t) s^*(t + \tau) dt|^2, \\ \eta &= \frac{c + v}{c - v}, \end{aligned} \quad (12)$$

其中, τ 为时延, η 为多普勒压缩因子, $s^*(t)$ 表示 $s(t)$ 的共轭。

图 2 为 DFCW-OFD-LFM 波形和多重正交 DFCW-OFD-LFM 波形的宽带模糊函数。多址波形

互模糊函数反映了不同地址波形之间在不同时延与多普勒下的相关特性。图 3 为 DFCW-OFD-LFM 波形和多重正交 DFCW-OFD-LFM 波形的互模糊函数。由图 2 可见, DFCW-OFD-LFM 和多重正交 DFCW-OFD-LFM 信号均具有较尖锐的相关峰值与一定的多普勒容限, 而多重正交 DFCW-OFD-LFM 信号拥有更低的时延旁瓣。由图 3 可见, 不同多址编码 DFCW-OFD-LFM 信号的最大互相关峰和不同多址编码多重正交 DFCW-OFD-LFM 信号的最大互相关峰均为 -10 dB 左右。

1.3.2 时频特征分析

对于频率成分随时间变化的波形信号, 通过时频分析方法可以有效地反映出信号频率特征随时间的变化趋势。经时频分析后得到的时频图, 与时域信号相比拥有更加稀疏的特征, 这样稀疏的特征更加有利于神经网络尤其是具有卷积结构的神经网络进行处理。时频分析通常采用短时傅里叶变换:

$$\text{STFT}(t, \omega) = \int_{-\infty}^{\infty} s(\tau) g(t - \tau) e^{-j\omega\tau} d\tau, \quad (13)$$

其中, $s(t)$ 表示原始信号, $g(t)$ 为窗函数, 窗函数表示在时间域上对信号进行截断的函数, 其选取对短时傅里叶变换的结果有很大影响^[15]。文献 [16] 指出, 在时频图上频率分辨单元与时间分辨单元尺寸的乘积不小于一个常数, 较长的窗长度可以获得很好的频率分辨力, 但时间分辨力会有所下降, 而较短的窗获得较好时间分辨力时牺牲了一定的频率分辨力。

图 4 为同一多重正交 DFCW-OFD-LFM 信号在




图 2 波形宽带模糊函数 (a) DFCW-OFD-LFM; (b) 多重正交 DFCW-OFD-LFM




图 3 多址波形互模糊函数 (a) DFCW-OFD-LFM; (b) 多重正交 DFCW-OFD-LFM

窗长分别为 1.6 ms 和 6.4 ms 短时傅里叶变换下得到的时频图,窗类型为 Bohman 窗^[17],FFT 点数为 256,窗孔重叠大小为 32。对比图 4(a)和图 4(b)可知,信号在较短窗长短时傅里叶变换下的时频图,频率维度上图像主瓣很宽,频率分辨能力较差,而每个子波间隔处边缘很锋利,有较高的时间分辨能力;当窗长变长时,频域分辨能力变好,而每个子波间时间边缘较模糊,存在拖尾现象,其时间分辨能力变差。

图 5 为 4 组不同编码 (p_n, c_n, q_n) 下多重正交 DFCW-OFD-LFM 波形时频图。图 6 展示了图 5(a) 波形在不同目标速度下多普勒效应引起的畸变,其在时间轴上出现了尺度压缩,而频率轴上出现了频率展宽。图 7 为 3 条多径、相邻径时延分别为 10 ms 和 20 ms 时,图 5(a) 波形回波的时频图。

2 多址声呐波形增强检测器设计

为提高多 UUV 协同探测场景下声呐检测性能,在文献 [13] 提出的 LSGAN 信号增强检测器基础上,将基于生成对抗网络结构的信号增强网络与基于卷积-全连接网络结构的分类网络相结合,引入融合梯度训练方法,设计了 WGAN-FG 多址声呐波形增强检测器。

2.1 生成对抗网络 (GAN)

GAN^[11] 是一种生成式模型,用于生成与训练数据,其结构包括一个生成器和一个判别器,判别器用于区分真实数据与生成器生成的数据,生成器则负责生成尽可能接近真实数据的数据使判别器无法区




图 4 不同窗长短时傅里叶变换时频图 (a) 窗长 1.6 ms; (b) 窗长 6.4 ms




图 5 4 组不同编码多重正交 DFCW-OFD-LFM 波形时频图 (a) p_n, c_n, q_n 分别为 (1,1,-1,-1,1,1,1), (1,2,7,5,4,6,3), (1,-1,1,1,1,-1,1); (b) p_n, c_n, q_n 分别为 (-1,-1,-1,1,-1,-1,1), (1,3,6,2,7,4,5), (-1,-1,1,1,1,-1,-1); (c) p_n, c_n, q_n 分别为 (1,-1,1,-1,1,-1,1), (1,4,2,6,7,3,5), (1,1,-1,1,1,-1,1); (d) p_n, c_n, q_n 分别为 (1,1,-1,1,1,-1,1), (2,5,1,7,6,3,4), (1,-1,1,-1,1,-1,1)




图6 不同目标速度下图5(a)波形回波时频图 (a) 0 kn; (b) 51 kn




图7 3条多径时图5(a)波形回波时频图 (a) 相邻径时延为10 ms; (b) 相邻径时延为20 ms

分。GAN的优化目标:

$$\min_G \max_D V(D, G) = \mathbb{E}_{\mathbf{x} \sim p_{\text{data}}(\mathbf{x})} [\log D(\mathbf{x})] + \mathbb{E}_{\mathbf{z} \sim p_z(\mathbf{z})} [\log(1 - D(G(\mathbf{z})))] \quad (14)$$

其中, D 为判别器网络参数, G 为生成器网络参数, $\mathbf{x}$ 为真实数据, $\mathbf{z}$ 为服从特定分布的随机变量。生成器网络 G 将随机变量 $\mathbf{z}$ 映射到与 $\mathbf{x}$ 尽可能相似的分布, 而判别器 D 则负责区分 $G(\mathbf{z})$ 的分布是否与 $\mathbf{x}$ 足够相似并由此对 G 进行训练, 最终使 D 无法区分 $G(\mathbf{z})$ 与 $\mathbf{x}$ 。GAN 作为一种生成模型, 可以在原始信号失真的情况下, 根据失真信号有限的信息量结合训练时获得的先验信息对失真信号进行增强恢复, 检测器对恢复后的信号进行检测从而获得更好的检测性能。

在 GAN 训练过程中, 判别器 D 的性能过好或者过差都会导致生成器 G 无法很好的训练。为此人们提出了诸多改进方法, 其中 WGAN-GP^[14] 在不增加复杂度的基础上很好地提高了训练的稳定性。WGAN-GP 去掉了输出层的 sigmoid 函数, 并将原本的交叉熵损失函数修改为仅有判别器输出值期望的 Wasserstein 损失函数, 修改后的 WGAN 的损失函数为

$$\begin{aligned} \text{Loss}_G &= -\mathbb{E}_{\mathbf{z} \sim p_z(\mathbf{z})} [D(G(\mathbf{z}))], \\ \text{Loss}_D &= \mathbb{E}_{\mathbf{z} \sim p_z(\mathbf{z})} [D(G(\mathbf{z}))] - \mathbb{E}_{\mathbf{x} \sim p_{\text{data}}(\mathbf{x})} [D(\mathbf{x})] + \\ &\quad \lambda \mathbb{E}_{\hat{\mathbf{x}} \sim p_{\text{data}}(\hat{\mathbf{x}})} [(\|\nabla_{\hat{\mathbf{x}}} D(\hat{\mathbf{x}})\|_2 - 1)^2], \end{aligned} \quad (15)$$

其中, $\mathbb{E}_{\mathbf{z} \sim p_z(\mathbf{z})} [D(G(\mathbf{z}))]$ 表示判别器对生成器输出值

进行判别后结果的期望值, $\mathbb{E}_{\mathbf{x} \sim p_{\text{data}}(\mathbf{x})} [D(\mathbf{x})]$ 表示判别器对真实值进行判别后结果的期望值, 而 $\lambda \mathbb{E}_{\hat{\mathbf{x}} \sim p_{\text{data}}(\hat{\mathbf{x}})} [(\|\nabla_{\hat{\mathbf{x}}} D(\hat{\mathbf{x}})\|_2 - 1)^2]$ 为梯度惩罚 (GP) 项, 是对判别器梯度的正则化, 其目的是约束判别器参数满足 1-Lipschitz 条件, 从而使其损失函数能够成立。

2.2 WGAN-FG 信号增强检测器

WGAN-FG 信号增强检测器的结构如图 8 所示, 其中 Conv 表示卷积, BN 表示批归一化 (Batch Normalization), MaxPool 为最大池化, ReLU 为激活函数, ConvTranspose 为卷积转置, MSE 为均方误差。由图 8 可知, 整个检测器中包括降噪生成器 (De-Noise Generator), 判别器 (Discriminator) 以及识别器 (Classifier) 三部分。降噪生成器负责将含有干扰噪声以及多径的畸变信号 $\mathbf{z}$ 映射至原始信号 $\mathbf{x}$ 的分布得到 $\hat{\mathbf{x}} = G(\mathbf{z})$ 。降噪生成器采用了编码器-解码器 (Encoder-Decoder) 结构, 在编码器中, 畸变信号的特征被逐层提取, 并通过降低特征图尺寸的方式对其特征进行降维, 以限制其分布空间大小, 降低过拟合的概率。解码器具有和编码器相对称的结构, 通过将提取到的特征进行逐层恢复。编码器与解码器层间跳跃连接, 可使解码器增强信号特征、抑制干扰与噪声特征, 并在最后生成抑制噪声与干扰的增强回波信号。判别器采用卷积-全连接网络结构, 用于区分降噪生成器所生成数据的分布与真实数据分布的近似程度, 并对其进行打分。分类器同样采用卷积-




图8 WGAN-FG 信号增强检测器结构示意图

全连接结构,用于判断经过降噪生成器增强后信号中是否包含目标回波,并对其多普勒特征进行识别,从而实现对目标速度的分辨,分类器输出层采用 Softmax 作为激活函数,将输出表示为各个类别的概率值,并根据概率最大的类别作为分类结果。在训练过程中,降噪生成器与判别器交替训练,判别器训练时需要区分降噪生成器增强后的信号与真实数据的分布差异,而降噪生成器需要生成与真实数据分布相近的增强信号,使判别器无法区分。降噪生成器与判别器采用了 Wasserstein 损失,同时对判别器增加了梯度惩罚正则项,避免判别器训练速度过快导致降噪生成器的训练梯度消失而无法训练。

降噪生成器的损失函数如式 (16) 所示,其中包含了判别器对降噪生成器结果进行判别的损失项,以及与真实数据间误差的二范数,对二范数的优化可以很好促进降噪生成器干扰成分的拟合。此外还结合了分类器的损失函数,其反向传播的梯度与降噪生成器自身损失函数的梯度相结合得到融合梯度后对降噪生成器进行训练。通过优化分类器损失,可以促进降噪生成器在信号增强过程中保留有利于分类器识别的特征,从而提升检测性能。

$$\text{Loss}_G(\mathbf{z}, \mathbf{x}, \text{label}) = -\mathbb{E}_{\mathbf{z} \sim p_z(\mathbf{z})}[D(G(\mathbf{z}))] + \sum_i \omega_i \|\mathbf{G}(\mathbf{z}) - \mathbf{x}\|_2 + \text{Loss}_C[C(G(\mathbf{z})), \text{label}], \quad (16)$$

其中, $\mathbf{x}$ 为无失真信号, $\mathbf{z}$ 为接收到的失真回波信号, ω_i 为不同类别下的误判风险率,用于虚警率控制。 D 为判别器网络, C 为分类器网络, Loss_C 为分类器损失函数, $-\mathbb{E}_{\mathbf{z} \sim p_z(\mathbf{z})}[D(G(\mathbf{z}))]$ 为判别器对降噪生成器结

果进行判别的损失, $\sum_i \omega_i \|\mathbf{G}(\mathbf{z}) - \mathbf{x}\|_2$ 为不同类别降噪生成器输出值与真实误差二范数的加权和。

分类器和判别器损失函数如式 (17) 所示,其中分类器损失函数采用 Multi-Focal-Loss, 该损失函数可以调整不同类别的权重。通过增加无目标信号类别数据对应损失项的权重,降低虚警率和误检率。

$$\begin{aligned} \text{Loss}_D(\mathbf{z}, \mathbf{x}) &= \mathbb{E}_{\mathbf{z} \sim p_z(\mathbf{z})}[D(G(\mathbf{z}))] - \mathbb{E}_{\mathbf{x} \sim p_{\text{data}}(\mathbf{x})}[D(\mathbf{x})] + \\ &\quad \lambda \mathbb{E}_{\mathbf{x} \sim p_{\text{data}}(\mathbf{x})}[(\|\nabla_{\mathbf{x}} D(\mathbf{x})\|_2 - 1)^2], \\ \text{Loss}_C(\mathbf{z}, \text{label}) &= -\sum_i \omega_i y_i \log(p_i), \end{aligned} \quad (17)$$

其中, $\text{label} = [y_1, y_2, \dots, y_i, \dots]$ 为样本标签, $[p_0, p_1, \dots, p_i, \dots]$ 为分类器预测结果。

3 仿真性能分析

为了评估神经网络检测器的检测性能,基于多重正交离散频率编码波形和时频扩展信道模型,对多 UUV 协同探测声呐回波进行了建模、仿真和数据生成,共仿真生成 158400 条训练数据,数据信号特性依据设定比例随机生成,其中包括 37.5% 的无目标回波信号数据和 62.5% 的目标回波畸变数据,无目标回波信号数据包含 60% 纯高斯噪声数据与 40% 高斯噪声参杂干扰波形数据。目标回波畸变信号数据包括 0 kn, 15 kn, 19 kn, 23 kn, 27 kn, 31 kn, 39 kn, 43 kn, 47 kn, 51 kn 共 10 种不同目标速度类别的数据,目标运动方向为接近声呐方向,每种速度类别回波受到以当前类别速度为中心 ± 2 范围内均匀分布的速度引起的多普勒效应影响,信噪比在 -30 dB,

-25 dB, -20 dB, -15 dB, -10 dB, -5 dB, 0 dB, 10 dB, 15 dB, 20 dB 下等比例分布, 多径数在 0~3 条下等比例分布, 每条多径时延服从 $[0, 0.1]$ s 的均匀分布, 衰减因子服从 $[0, 1]$ 的均匀分布。所有检测器的输入均为回波数据经短时傅里叶变换后尺寸为 48×126 的时频图, 输出为 11 种类别标签, 其中 1 种表示未检测到目标回波信号标签, 其他 10 种分别表示不同多普勒速度目标回波信号标签, 当输入数据被判断为“未检测到目标回波信号”时, 则分类为无目标信号; 当输入数据中被判断为“目标回波信号”时, 则根据其多普勒特征对多普勒速度进行分类。评估检测率时, 仅考虑输入数据中是否包含目标信号, 而不考虑对目标信号分类是否正确, 评估测速准确率时则对速度类别分类的正确率进行分析; 虚警率为在仅有高斯噪声数据输入情况下, 检测器将其分类为目标回波信号的概率, 误检率为输入数据为高斯噪声参杂干扰波形时, 被判断为目标回波信号的概率。根据上述定义, 对神经网络检测器的 F1 分数、虚警率、误检率, 以及多种场景下的检测率和测速准确率进行测试, 同时比较神经网络检测器与传统副本相关检测器的检测性能。

3.1 神经网络检测器结构及参数介绍

本文研究的神经网络检测器有 CNN-FCN、GRU-FCN、WGAN 和 WGAN-FG 信号增强检测器。其中, GRU 网络为循环神经网络的一种, 已广泛用于音频信号处理领域, 其具体结构可参考文献 [18]。为方便计算卷积后特征图尺寸, 输入时频图尺寸为 48×128 , 通道数为 2, 分别为时频图的实部和虚部。CNN-FCN 检测器包括 11 层卷积层、6 层转置卷积层和 3 层全连接层, 池化层均采用窗口 2×2 、步长为 2 的最大池化 (Max Pooling), 卷积层间设有批归一化 (Batch Normalization) 层^[19], 全连接层间采用概率为 0.2 的 Dropout; GRU-FCN 检测器将 3 层 GRU^[18] 堆叠后与全连接层 (FCN) 结合设计, 输入为时频图沿时间维度划分后逐列送入检测器, 每一列是长度为 48 点的表征瞬时频率的复向量, 将实部与虚部拼接后得到 96 点长的实向量, 循环 126 次后将整张时频图送入检测器, 最终得到分类结果; WGAN 与 WGAN-FG 信号增强检测器采用了相同的网络参数, 以更好地对比融合梯度训练对网络性能的增益。其结构如图 8 所示, 降噪生成器包括由 6 层卷积层组成的编码器和 6 层转置卷积层组成的解码器。编码器中所有卷积层步长均为 1, 卷积层间设有批归一化层, 每经过两层卷积层后进行一次最大池化 (Max

Pooling), 进行下采样, 池化层窗口均为 2×2 , 步长均为 2。解码器采用步长为 2 和步长为 1 的转置卷积层组合进行升采样, 转置卷积层间设有批归一化层。编码器的每一个下采样层和上采样层间采用跳跃连接。判别器和分类器采用相同的网络结构, 包括 5 层卷积层和 3 层全连接层, 卷积层间设有批归一化层和窗口为 2×2 、步长为 2 最大池化层, 全连接层间设有概率为 0.2 的 Dropout。图 9 为 WGAN-FG 网络在训练过程中各项损失函数变化趋势, 其中生成器均方损失函数对应式 (16) 中的 $\sum_i \omega_i \|G(z) - x\|_2$ 项, 生成器判别损失函数则对应式 (16) 中的 $-\mathbb{E}_{z \sim p_z(z)} [D(G(z))]$ 项, 判别器损失函数对应式 (17) 中的 $\text{Loss}_D(z, x)$, 分类器损失函数对应式 (17) 中的 $\text{Loss}_C(z, \text{label})$ 。分类器损失函数和生成器均方损失函数均逐渐下降, 生成器判别器损失与判别器损失函数由于生成对抗网络自身特性, 在经起初的震荡之后也逐渐平稳, 各个损失函数均随训练逐渐收敛。




图 9 WGAN-FG 网络在训练过程中各项损失函数变化趋势

3.2 信号增强性能分析

图 10—图 13 为降噪生成器以图 5(a) 为目标波形、以图 5(b)(c)(d) 等其他 UUV 波形为干扰波形的增强效果图。其中图 10 展示了信噪比 10 dB、信干比 5 dB、无多径影响时的信号增强效果, 图 11 展示了信噪比 -10 dB、信干比 -5 dB、无多径影响时的信号增强效果, 图 12 展示了信噪比 10 dB、信干比 5 dB、多径条数为 3 时的信号增强效果, 图 13 展示了在仅存在干扰与噪声时降噪生成器对干扰与噪声的抑制效果。

由图 10 可知, 在较小的干扰与噪声下, 降噪生成器能够很好的对目标信号进行增强, 得到清晰的目标信号时频图。图 11 显示在较强的干扰与噪声下, 原始信号时频图已经几乎无法识别出目标信号, 降噪生成器增强后的信号时频图虽有一定的畸变与残缺, 但整体上仍然保留了目标信号的主要特征。图 12 显示存在多径时原始目标信号时频图十分模




图 10 信噪比 10 dB、信干比 5 dB、无多径影响时回波信号时频图 (a) 原始回波信号; (b) 增强回波信号




图 11 信噪比-10 dB、信干比-5 dB、无多径影响时回波信号时频图 (a) 原始回波信号; (b) 增强回波信号




图 12 信噪比 10 dB、信干比 5 dB、多径数为 3 时回波信号时频图 (a) 原始回波信号; (b) 增强回波信号




图 13 仅存在噪声与干扰信号时频图 (a) 原始噪声和干扰; (b) 噪声与干扰抑制

糊, 很难分辨出目标信号的特征, 而经过降噪生成器增强后, 目标信号时频图得到了明显增强, 虽然存在一定的畸变, 但仍然清晰地反映出目标信号的特征。图 13 显示当信号时频图中不存在目标信号、仅有干扰信号和噪声时, 降噪生成器能够很好地对干扰与噪声进行抑制, 从而降低检测器误检的概率。

3.3 虚警率分析

虚警率为在纯噪声数据输入时检测器误判为存在目标回波信号的概率。测试使用蒙特卡罗方法, 首先生成 4000 点长度的高斯噪声序列, 然后根据 1.3 节的参数对其进行短时傅里叶变换, 得到噪声时频图, 最后经过神经网络识别后统计其分类结果。

每种网络测试的蒙特卡罗仿真次数都为 61400。RC 检测器检测门限由与神经网络相近的虚警率获取, 各检测器虚警率统计结果如表 2 所示。

表 2 虚警率统计结果

模型	WGAN-FG	WGAN	CNN-FCN	GRU-FCN	RC
虚警率	0.31%	0.32%	0.32%	0.30%	0.31%

3.4 干扰条件误检率分析

误检率即输入数据为高斯噪声参杂干扰波形数据时, 检测器误判为存在目标信号的概率, 误检率测试使用了仿真生成的 102400 条高斯噪声参杂干扰波形数据, 干噪比在 $-30 \sim 20$ dB 下等概率分布。图 14 为不同干噪比下各神经网络检测器和传统 RC 检测器的误检率统计结果。




图 14 不同干噪比下各神经网络检测器误检率统计结果

由图 14 可见, 所有神经网络检测器误检率均控制在 0.1 以下, WGAN-FG 信号增强检测器误检率均在 0.05 以下, 其中神经网络检测器在 $-25 \sim -15$ dB 干噪比下的误检率较高, 更小或更大干噪比时误检率都更低。这表明, 在较大干噪比下, 干扰信号特征明显, 基于神经网络的检测器能够有效识别干扰信号, 干噪比很小时, 噪声完全淹没干扰信号, 干扰信号不易对检测器造成影响。而在干噪比处于 $-25 \sim -15$ dB 时, 容易出现干扰信号与目标信号相似的部分特征被神经网络提取、而干扰信号与目标信号有差异的特征被噪声淹没的现象, 此时神经网络检测器有较高的误检率。对于 RC 检测器, 当干噪比小于 -5 dB 时, 其误检率很低, 当干噪比逐渐变大到 0 dB 时, 误检率迅速上升至 1 附近。所以, 当干噪比大于 0 dB 时, RC 检测器很难抑制基于多重正交 DFCW-OFD-LFM 波形信号的多 UUV 协同探测声呐

波形互扰, 而对于神经网络检测器, 无论干噪比多大, 都能够很好地抑制多 UUV 声呐波形互扰。

3.5 检测性能分析

基于仿真数据和 RC 检测器对 WGAN-FG、WGAN、CNN-FCN 和 GRU-FCN 四种神经网络检测器性能进行评估, 各检测器的虚警率如表 2 所示。仿真数据包括 1 组无干扰、无多径目标回波数据, 1 组无干扰、时频双扩展目标回波数据, 以及 6 组不同信干比时频双扩展目标回波数据。时频扩展信道根据 2.2 节的回波信号模型在不同目标距离下进行建模, 模型其他参数设定为海深 200 m, 目标深度 150 m, 声呐深度 100 m, 直达信道 D 和水面一次反射信道 SS_1 的最终回波幅度因子 α_D 和 α_{SS_1} 都为 0.2506, 海底一次反射信道 BB_1 的最终回波幅度因子 α_{BB_1} 为 0.1253, 目标测试回波为直达信道方向回波, 包括 1 条直达信道双程回波和 2 条多径回波, 各信道回波最终相位跳变在 $[0, 2\pi]$ 均匀分布。在以上条件下仿真生成 8 组测试回波数据: 无干扰、无多径回波数据, 无干扰、目标距离 500 m 回波数据, 信干比 20 dB、目标距离 500 m 回波数据, 信干比 20 dB、目标距离 2000 m 回波数据, 信干比 0 dB、目标距离 500 m 回波数据, 信干比 0 dB、目标距离 2000 m 回波数据, 信干比 -20 dB、目标距离 500 m 回波数据和信干比 -20 dB、目标距离 2000 m 回波数据。每组数据都包含 0 kn, 15 kn, 19 kn, 23 kn, 27 kn, 31 kn, 39 kn, 43 kn, 47 kn, 51 kn 共 10 种不同速度类别数据, 每种速度类别数据都包含 -30 dB, -25 dB, -20 dB, -15 dB, -10 dB, -5 dB, 0 dB, 10 dB, 15 dB, 20 dB 等不同大小信噪比数据, 每种信噪比有 512 条数据, 共计 8×56320 条测试数据。基于这些数据, 对各神经网络检测器的 F1 分数、检测性能、速度识别准确率进行了测试评估, 并在无干扰信号时与 RC 检测器性能进行比较。

3.5.1 F1 分数分析

F1 分数 (F1 Score) 是统计学中用来衡量二分类或多任务二分类模型精确度的一种指标, 同时兼顾了分类模型的精确率和召回率, 可看作是模型精确率和召回率的一种调和平均。其取值为 0~1, 在同一组测试数据下, 越接近 1 表明模型精确度越高。其表达式为

$$F_1 = 2 \frac{pr}{p+r}, \quad (18)$$

其中, p 为查准率 (precision), 定义为在测试数据某一类别中分类正确的样本个数与所有分到该类的样本

个数的比例; r 为召回率 (recall), 定义为在测试数据某一类别中分类正确的样本个数与该类别样本总个数的比例。对于多分类问题, 采用 Macro-F1 与 Micro-F1 进行评价, Macro-F1 为对每个类别计算 F1 后进行平均得到, Micro-F1 为计算出所有类别总的查准率 p 与召回率 r , 并计算 F1。WGAN-FG、WGAN、CNN-FCN、GRU-FCN 四种检测器的 Macro-F1 和 Micro-F1 如表 3 所示, WGAN-FG 信号增强检测器拥有最高的 F1 分数, 说明其具有最好的分类检测性能。

表 3 WGAN-FG, WGAN, CNN-FCN, GRU-FCN 的 Macro-F1 与 Micro-F1

	WGAN-FG	WGAN	CNN-FCN	GRU-FCN
Macro-F1	0.8291	0.7898	0.7142	0.7413
Micro-F1	0.8294	0.7902	0.7163	0.7415

3.5.2 无干扰背景信号检测性能分析

评估 WGAN-FG、WGAN、CNN-FCN 和 GRU-FCN 四种检测器在无干扰、无多径, 无干扰、时频双扩展浅海信道、目标距离 500 m 和无干扰、时频双扩

展浅海信道、目标距离 2000 m 时的目标回波检测性能, 同时与 RC 检测器检测性能进行比较。无干扰、无多径时不同速度回波检测性能曲线如图 15 所示。图 16 为无干扰、时频双扩展浅海信道、目标距离 500 m 时不同多普勒速度回波检测曲线, 图 17 为无干扰、时频双扩展浅海信道、目标距离 2000 m 时不同多普勒速度回波检测曲线。图 15 中的 RC 检测器没有对回波数据进行多普勒速度补偿, 其 0 kn 时的 RC 检测曲线也是速度补偿时的 RC 检测曲线, 图 16 和图 17 的 RC 检测曲线分为有多普勒速度补偿和无多普勒速度补偿 RC 检测曲线。

图 15 显示, 在无干扰、无多径时, 如果目标回波没有多普勒压缩 (或能够已知多普勒速度, 并对其进行精确补偿), 则 RC 检测器在信噪比大于 -20 dB 时性能较好, 否则性能较差, 而神经网络检测器在信噪比小于 -20 dB 时, 性能优于 RC 检测器, 其中 WGAN-FG 信号增强检测器略优于 WGAN 与 CNN-FCN, 显著优于 GRU-FCN; 在回波有多普勒压缩时, 神经网络检测器检测性能受多普勒效应影响不大, 而 RC 检测器检测性能随着多普勒速度的增大而快速变差。




图 15 无干扰、无多径时不同速度回波检测曲线 (a) 0 kn; (b) 15 kn; (c) 31 kn; (d) 51 kn




图 16 无干扰、浅海信道、目标距离 500 m 时不同多普勒速度回波检测曲线 (a) 0 kn; (b) 15 kn; (c) 31 kn; (d) 51 kn




图 17 无干扰、浅海信道、目标距离 2000 m 时不同多普勒速度回波检测曲线 (a) 0 kn; (b) 15 kn; (c) 31 kn; (d) 51 kn

由图 16 和图 17 可知, 当目标回波存在多径和多普勒双扩展时, 即使 RC 检测器已知多普勒速度、并对其进行精确补偿, 其检测性能仍差于 WGAN-FG 信号增强检测器。在神经网络检测器中, WGAN-FG 信号增强检测器检测性能略优于 WGAN 与 CNN-FCN 检测器, 显著优于 GRU-FCN 检测器, WGAN-FG 信号增强检测器性能几乎不受目标运动影响, 而 WGAN 与 CNN-FCN 随目标运动速度增加性能略微下降。对比目标距离 500 m 和 2000 m 时的检测性能可知, 目标距离 500 m 时各神经网络检测器检测性能优于目标距离 2000 m 时检测性能, 这应该源于目标距离 500 m 时, 目标回波多径之间的时延差较大、特征更清晰, 目标距离 2000 m 时, 目标回波多径更密集、特征更模糊, 而对于 RC 检测器, 由于波形带宽很宽, 时间分辨率很高, 所以目标距离 500 m 和 2000 m 时的多径扩展差异对其检测性能的影响不太明显。对比图 15—图 17 可知, 如果无法精确估计多普勒速度, 那么多普勒效应带来的波形失配会严重影响 RC 检测器的检测性能, 且失配越大, 检测性能越差, 而多普勒效应对神经网络检测器的

检测性能影响较小。

3.5.3 干扰背景信号检测性能分析

由 3.4 节分析可知, 当干扰信号干噪比达到 0 dB 时, RC 检测器将无法区分出目标信号与干扰信号, 强干扰信号将会造成 RC 检测器检测率大幅提高, 但可能是误检率带来的高检测率, 因此本节分析检测性能时, 仅对各神经网络检测器在干扰背景、时频双扩展浅海信道下的检测性能进行分析。图 18—图 23 分别为信干比 20 dB、目标距离 500 m, 信干比 20 dB、目标距离 2000 m, 信干比 0 dB、目标距离 500 m, 信干比 0 dB、目标距离 2000 m, 信干比 -20 dB、目标距离 500 m 和信干比 -20 dB、目标距离 2000 m 时, 不同多普勒速度下的检测性能曲线。

由图 18—图 23 可知, 随着干扰的增强和多普勒速度的增加, 神经网络检测性能也有所下降, 但由图 22 和图 23 可知, 在强干扰下, 各检测器受多普勒速度影响并不随速度的增加而单调下降, 这可能是干扰信号与目标回波相关性不随速度单调变化导致。当信道条件很差时, 如信干比小于 -20 dB、目标速度大于 31 kn, 除所提 WGAN-FG 信号增强检测器外, 其




图 18 信干比 20 dB、目标距离 500 m 时不同速度回波检测曲线 (a) 0 kn; (b) 15 kn; (c) 31 kn; (d) 51 kn




图 19 信干比 20 dB、目标距离 2000 m 时不同速度回波检测曲线 (a) 0 kn; (b) 15 kn; (c) 31 kn; (d) 51 kn




图 20 信干比 0 dB、目标距离 500 m 时不同速度回波检测曲线 (a) 0 kn; (b) 15 kn; (c) 31 kn; (d) 51 kn




图 21 信干比 0 dB、目标距离 2000 m 时不同速度下回波检测曲线 (a) 0 kn; (b) 15 kn; (c) 31 kn; (d) 51 kn




图 22 信干比 -20 dB、目标距离 500 m 时不同速度下回波检测曲线 (a) 0 kn; (b) 15 kn; (c) 31 kn; (d) 51 kn




图 23 信干比 -20 dB、目标距离 2000 m 时不同速度下回波检测曲线 (a) 0 kn; (b) 15 kn; (c) 31 kn; (d) 51 kn




图 24 不同信干比和多径数下速度识别性能曲线 (a) 信干比 20 dB、目标距离 500 m; (b) 信干比 20 dB、目标距离 2000 m; (c) 信干比 0 dB、目标距离 500 m; (d) 信干比 0 dB、目标距离 2000 m; (e) 信干比 -20 dB、目标距离 500 m; (f) 信干比 -20 dB、目标距离 2000 m

他神经网络检测器的性能都明显下降。因此,相比于其他神经网络检测器, WGAN-FG 信号增强检测器在抑制强干扰、大多普勒畸变方面具有明显优势。同样,对于干扰背景浅海信道,目标距离 500 m 时各

神经网络检测器检测性能优于目标距离 2000 m 时检测性能。

3.5.4 速度识别率分析

图 24 为信干比 20 dB、目标距离 500 m, 信干比

20 dB、目标距离 2000 m, 信干比 0 dB、目标距离 500 m, 信干比 0 dB、目标距离 2000 m, 信干比-20 dB、目标距离 500 m 和信干比-20 dB、目标距离 2000 m 时, 不同神经网络检测器的速度识别性能曲线, 速度识别准确率根据直达波多普勒特征所判断的速度准确与否进行分析。由图 24 可知, 随着干扰的增强, 各神经网络速度识别准确率都明显下降, 目标距离 500 m 时的速度识别准确率明显高于目标距离 2000 m 时的速度识别准确率, 相比于其他神经网络检测器, 所提 WGAN-FG 信号增强检测器在强干扰、多径密集信道下的速度识别性能优势更加明显。

4 结论

提出了一种多址声呐探测波形及其增强检测方法, 建立了浅海回波信道模型, 生成了浅海多址声呐回波数据, 并仿真分析了浅海多址声呐回波检测性能。主要结论如下: (1) 在浅海多用户声呐探测场景下, 如果存在强互扰波形, RC 检测器会将干扰波形误检为目标回波, 不利于弱目标回波检测, 而神经网络检测器能够很好地抑制强干扰波形, 具有很好的弱目标回波检测能力; (2) 如果没有强干扰波形, 但目标回波为运动目标回波, 则多普勒效应带来的波形失配会严重影响 RC 检测器检测性能, 而对神经网络检测器检测性能影响较小; (3) 相比于其他神经网络检测器, WGAN-FG 信号增强检测器在强干扰、大多普勒畸变等环境下具有明显优势; (4) 在目标速度识别方面, 相比于其他神经网络检测器, WGAN-FG 信号增强检测器在强干扰、多径密集条件下的目标速度识别性能优势明显。

参 考 文 献

- 1 许彦伟, 薛勐, 刘明刚, 等. 多无人水下航行器协同探测声呐宽带波形设计与性能分析. *电子与信息学报*, 2023; **45**(10): 3796–3804
- 2 Kroh P K, Simon R, Rupitsch S J. Classification of sonar targets in air: A neural network approach. *Sensors*, 2019; **19**(5): 1176
- 3 Ahmed F, Xiang X, Jiang C, *et al.* Survey on traditional and AI based estimation techniques for hydrodynamic coefficients of autonomous underwater vehicle. *Ocean Eng.*, 2023; **268**: 113300
- 4 周天, 司吉坤, 杜伟东, 等. 采用 GAF-D3Net 深度学习网络的水下目标有源识别方法. *声学学报*, 2023; **48**(5): 950–958
- 5 李琛, 黄兆琼, 徐及, 等. 使用深度学习的多通道水下目标识别. *声学学报*, 2020; **45**(4): 506–514
- 6 Nie J, Xiao Y, Huang L, *et al.* Time-frequency analysis and target recognition of HRRP based on CN-LSGAN, STFT, and CNN. *Complexity*, 2021: 1–10
- 7 Sigillito V G, Wing S P, Hutton L V, *et al.* Classification of radar returns from the ionosphere using neural networks. *Johns Hopkins APL Technical Digest*, 1989; **10**(3): 262–266
- 8 Wan C, Si W, Deng Z. Research on modulation recognition method of multi-component radar signals based on deep convolution neural network. *IET Radar Sonar Navig.*, 2023; **17**(9): 1313–1326
- 9 Wang L, Tang J, Liao Q. A study on radar target detection based on deep neural networks. *IEEE Sens. Lett.*, 2019; **3**(3): 1–4
- 10 Lee K G, Oh S J. Detection of frequency-hopping signals with deep learning. *IEEE Commun. Lett.*, 2020; **24**(5): 1042–1046
- 11 Goodfellow I, Pouget-Abadie J, Mirza M, *et al.* Generative adversarial networks. *Commun. ACM*, 2020; **63**(11): 139–144
- 12 Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks. arXiv preprint: 1511.06434, 2015
- 13 Yin Y, Qiu J, Sun S, *et al.* Sonar pulse detection and recognition based on deep denoising. Proceedings of the 6th International Conference on Electronic Information Technology and Computer Engineering, 2022: 384–389
- 14 Gemici M, Akata Z, Welling M. Primal-dual Wasserstein Gan. arXiv preprint: 1805.09575, 2018
- 15 Gröchenig K. Foundations of time-frequency analysis. Birkhäuser Boston, MA: Springer, 2001: 37–57
- 16 Donoho D L, Stark P B. Uncertainty principles and signal recovery. *SIAM J. Appl. Math.*, 1989; **49**(3): 906–931
- 17 Heil M M, Hammoodi A T, Rasool J M. A comparative analysis of Bohman windowing performance for UFMCM with higher QAM modulation. 2023 Al-Sadiq International Conference on Communication and Information Technology, IEEE, Al-Muthana, Iraq, 2023: 13–17
- 18 Chung J, Gulcehre C, Cho K H, *et al.* Empirical evaluation of gated recurrent neural networks on sequence modeling. arXiv preprint: 1412.3555, 2014
- 19 Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. International Conference on Machine Learning, PMLR, 2015: 448–456