

◇ 研究报告 ◇

基于广义回归神经网络的强干扰下垂直阵 目标距离估计方法*

姚琦海 汪勇[†] 黎佳艺 杨益新

(西北工业大学航海学院 西安 710072)

摘要: 以声压场采样协方差矩阵为特征, 基于广义回归神经网络研究在强干扰下的水下声源测距问题, 该文提出了优化扩展因子的方法以提高神经网络估计性能。使用仅有一个网络参数的广义回归神经网络, 使用 SWellEX-96 实验 S59 航次的垂直阵数据, 比较了以传统匹配场处理为代表的模型驱动方法和以卷积神经网络、广义回归神经网络为代表的驱动方法在强干扰下的水下目标距离估计性能。结果表明, 基于优化扩展因子的广义回归神经网络在强干扰下可以有效实现距离估计。

关键词: 距离估计; 强干扰; 垂直阵; 广义回归神经网络

中图分类号: TB533

文献标识码: A

文章编号: 1000-310X(2021)05-0723-08

DOI: 10.11684/j.issn.1000-310X.2021.05.010

Source range estimation method of vertical array under strong interference based on GRNN

YAO Qihai WANG Yong LI Jiayi YANG Yixin

(School of Marine Science and Technology, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: The sample covariance matrix of sound pressure field is made as the feature. The research on underwater sound source ranging under strong interference based on generalized regression neural network (GRNN), which has only one network parameter, extension factor. It proposes a method of optimizing the extension factor to improve the estimation performance of neural network. The research uses the vector line array (VLA) data from event S59 of the SWellEx-96 experiment, comparing the range estimation performance of underwater targets under strong interference of model-driven traditional matched field processing, data-driven convolutional neural networks (CNN) and GRNN. The results show that GRNN based on the optimized extension factor can effectively realize the estimation of range under strong interference.

Keywords: Range estimation; Strong interference; Vector line array; Generalized regression neural network

2020-11-13 收稿; 2021-01-24 定稿

*国家自然科学基金项目 (61971353)

作者简介: 姚琦海 (1997-), 男, 陕西西安人, 硕士研究生, 研究方向: 信号与信息处理。

[†]通信作者 E-mail: yongwang@nwpu.edu.cn

0 引言

水下目标定位利用基阵接收到的声信号来探测目标声源的位置,一直以来是水声信号处理领域的热点,本文研究其中的一个方面——目标距离估计^[1-3]。在军事和民用领域中,隐蔽性较好的被动定位技术有着广泛的应用。传统的被动定位方法大多为基于匹配场处理(Matched field processing, MFP)的方法。1976年, Buckner^[4]推导出了线性匹配场处理器,使用实际环境模型,引入了距离深度的模糊函数。1988年, Baggeroer^[5]建立水平分层的海洋环境波导模型,将MFP技术应用在低信噪比场景中,研究表明增加带宽可以提升匹配场算法的定位性能。1996年, Michalopoulou等^[6]提出利用非相关方法对各个频点的窄带模糊度函数叠加,验证了宽带匹配场定位算法中非相关方法的可行性。2003年, Soares等^[7]利用各个频点之间的相关信息,建立了归一化相关处理器、匹配相位相关处理。2006年,杨坤德等^[8]针对环境失配条件下的强干扰问题,提出了一种线性匹配场干扰抑制算法。2018年,贾雨晴等^[9]提出了一种在声速剖面时变环境下的自适应匹配场定位算法,结果表明该算法的定位性能较常规匹配场算法有较大提升。MFP方法利用水声信道特性将声传播模型和阵列信号结合起来,实现水下目标被动定位。但此类模型驱动方法需要海深、声速剖面等参数,在低信噪比和缺少环境参数的情况下,会严重影响定位性能。随着机器学习技术的迅速发展,以神经网络为代表的驱动方法在水声领域得到了广泛的应用。

基于数据的机器学习模型不需要海洋环境参数,而基于声场理论的模型会受到环境失配的影响。1991年 Steinberg等^[10]建立单层神经网络模型对均匀介质中的点声源进行深度估计,但受限于当时的机器学习技术发展不成熟,加之传统的MFP方法为当时主流的被动定位算法,因此,在之后的很长一段时间,机器学习方法在水声被动定位领域的发展较为缓慢。2017年, Niu等^[11]利用前馈神经网络(Feed forward neural networks, FFNN)、支持向量机模型,结合海试实测数据验证了机器学习算法的定位性能。2018年, Wang等^[12]引入了广义回归神经网络(Generalized regression neural network, GRNN)方法,实现了浅海高信噪比环境下有效的目标距离估计; Huang等^[13]将声场模型

数据用于训练,建立多层深度卷积神经网络(Convolutional neural networks, CNN)模型估计浅海声源位置。2019年, Liu等^[14]在深度范围大致确定的前提下,利用一维CNN和集成学习实现了水下目标距离估计; Niu等^[15]在不确知环境下,采集单水听器接收到的声压值,利用50层残差CNN探测声源。2020年, Liu等^[16]将实际数据和仿真数据的组合作为训练数据,并利用CNN估计声源的深度和距离; 张巧力等^[17]搭建了单隐藏层的FFNN,并利用SWellEX-96实验S5航次的垂直阵数据进行验证。以上研究利用CNN、支持向量机等模型对水下单目标进行了位置估计,但大多相关研究是在没有强干扰的高信噪比下的海洋环境中实现的。

机器学习在低信噪比的海洋环境中的应用相对较少,2016年, Niu等^[18]输入归一化互谱密度矩阵,训练仅有一个隐藏层的FFNN,实现在训练样本较少和低信噪比下的距离估计。2018年, Ozanich等^[19]使用KRAKEN模型生成垂直阵列在低信噪比下接收到的声压幅值和相位,利用CNN在多频复声压场中训练距离特征,研究表明通过增加训练数据,可提升低信噪比下的定位性能。2020年, Ozanich等^[20]利用FFNN进行方位估计,用SWellEX-96实验中在强干扰下的S59航次数据进行验证,并与支持向量机方法进行了对比,结果证明了深层FFNN模型在水平阵被动定位中应用的可行性。

在实际浅海中,往往存在着强度较大的水面干扰声源,比如大型的船舶,对水下目标声源的定位造成了很大的考验,传统的MFP方法在此场景下性能较差,因此,在浅海强干扰下的目标距离估计中,研究和建立基于数据驱动的机器学习模型有重要意义和价值。本文利用美国海洋物理实验室1996年5月在距Point Loma约12 km处进行的一次浅海实验(SWellEX-96实验)中的S59航次数据研究强干扰下的垂直阵定位问题^[21],为研究两类驱动方法在强干扰下距离估计性能的差异,本文对基于数据驱动的GRNN和CNN方法和基于简正波模型的传统MFP方法的性能进行了比较。

1 MFP

通过简正波模型以及环境参数,可以计算出声源在特定位置情况下接收阵位置的复声压,作为拷贝向量。在简正波模型下, $(0, z_s)$ 处单频点声源在 (r, z) 处产生的声压表达式^[22]为

$$p(r, z) \approx \frac{i}{\rho(z_s) \sqrt{8\pi r}} e^{-\frac{i\pi}{4}} \sum_{m=1}^{\infty} \Psi_m(z_s) \Psi_m(z) \frac{e^{ik_{rm}r}}{\sqrt{k_{rm}}}, \quad (1)$$

其中, ρ 为介质密度, $\Psi_m(z)$ 和 k_{rm} 分别为第 m 号简正波的模深函数(特征函数)和水平波数。

对水听器阵列接收到的数据与拷贝向量进行匹配, 在计算得到的距离-深度模糊表面中寻找最大值, 该点对应位置即为估计位置^[23]。由互谱密度矩阵 \mathbf{R} 和拷贝向量 $\boldsymbol{\omega}$ 计算 MFP 的定位模糊度平面 \mathbf{B} :

$$\mathbf{B}(\phi) = \boldsymbol{\omega}^H(\phi) \mathbf{R} \boldsymbol{\omega}(\phi), \quad (2)$$

$$\mathbf{R} = \frac{1}{L} \sum_{l=1}^L \mathbf{P}_l \mathbf{P}_l^H, \quad (3)$$

$$\boldsymbol{\omega} = [p_1, p_2, \dots, p_l, \dots, p_L]^T, \quad l=1, 2, \dots, L, \quad (4)$$

其中, p_l 为拷贝场下基阵接收到的复声压, ϕ 为声源位置参数, $(\cdot)^H$ 为共轭转置, L 为快拍数, \mathbf{P}_l 为第 l 个快拍下基阵频域数据向量。

对宽带信号, 累加平均各个频率对应的模糊度平面, 即可得到宽带信号的模糊度平面。

2 GRNN

基于核回归分析的 GRNN 是一种前向神经网络, 且有着优良的非线性映射能力。GRNN 通过计算训练数据的输入输出和测试数据的输入, 得到条件概率密度函数, 从而进一步得到测试数据的输出^[24]。GRNN 只需要选择一个网络参数, 而其他神经网络一般需要选择多个参数, 因此 GRNN 在网络搭建上有着较强的优势。

GRNN 包含输入层、模式层、求和层、输出层, 其结构如图 1 所示。输入层将输入向量传递给模式层。模式层神经元个数和训练样本个数 N 一致, 每个训练样本均有相对应的神经元。神经元 G_i 为训练数据输入 X_i 和测试数据输入 X 间的欧式距离平方的指数:

$$G_i = \exp \left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right], \quad i=1, 2, \dots, N, \quad (5)$$

其中, σ 即为需要选择的扩展因子。

模式层包含一个 D 神经元和 K 个 S 神经元, D 神经元为所有模式层神经元的算数求和, S 神经元为其对应的加权求和(模式层的第 i 个神经元和求和层的第 k 个神经元之间的权重为 y_{ik}), 即

$$D = \sum_{i=1}^N G_i, \quad (6)$$

$$S_k = \sum_{i=1}^N y_{ik} G_i. \quad (7)$$

输出层神经元个数为输出向量的维度 K , 对应神经元的输出由对应模式层 S_k 除以 D 计算得到:

$$\hat{y}_k(X) = S_k/D, \quad k=1, 2, \dots, K. \quad (8)$$

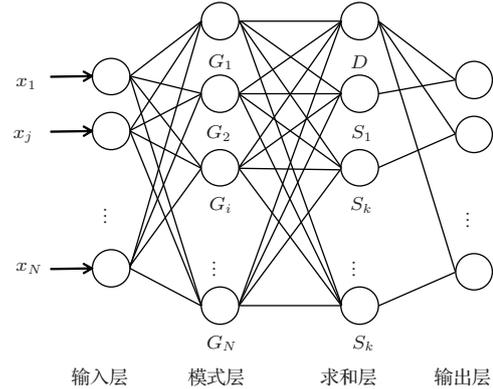


图 1 GRNN 结构图

Fig. 1 GRNN structure chart

2.1 信号预处理

GRNN 的输入特征为采样协方差矩阵 (Sample covariance matrices, SCMs)^[25]。由于存在声源振幅的影响, 将阵元数为 L 的基阵接收的频域复声压 $\mathbf{P}(f) = [p_1, p_2, \dots, p_l, \dots, p_L]^T$ 进行范数归一化:

$$\tilde{\mathbf{P}}(f) = \frac{\mathbf{P}(f)}{\sqrt{\sum_{l=1}^L |p_l(f)|^2}} = \frac{\mathbf{P}(f)}{\|\mathbf{P}(f)\|_2}. \quad (9)$$

利用归一化后的复声压, 采样协方差矩阵根据 N_s 个快拍数据平均计算得到, 即

$$\mathbf{C}(f) = \frac{1}{N_s} \sum_{s=1}^{N_s} \tilde{\mathbf{P}}_s(f) \tilde{\mathbf{P}}_s^H(f), \quad (10)$$

其中, $\tilde{\mathbf{P}}(f)$ 为第 s 个快拍对应的复声压。

GRNN 模型的输入为采样协方差矩阵的上三角矩阵对应复数元素的实部和虚部。单频信号的输入特征维数为 $1 \times L(L+1)$, 将多个频点的特征连接起来得到宽带信号的输入特征, 其维数为 $1 \times L(L+1)N_f$, 其中 N_f 为频点数。

2.2 扩展因子选择

GRNN 只有一个网络参数, 只需优化扩展因子, 即可提高网络的训练性能, 本文使用 k 折交叉验证来确定最优扩展因子, 方法如下:

(1) 确定扩展因子的取值范围, 比如如 0.01, 0.02, \dots , 0.1, 步长为 0.01。

(2) 将平均绝对百分比误差 (Mean absolute percentage error, MAPE) 作为定位性能的衡量指标

$$\text{MAPE} = \frac{100}{N} \sum_{i=1}^N \left| \frac{R_{gi} - R_{ti}}{R_{ti}} \right|, \quad (11)$$

其中, R_{gi} 为神经网络预测数据, R_{ti} 为实际数据。

(3) 对 k 折交叉验证, 随机地将训练数据分成 k 折, 验证集为其中的 1 折, 训练集为其他的 $k-1$ 折, 本研究选择 10 折。

(4) 对每一个扩展因子, 首先将训练集用于训练, 再测试验证集, 并计算对应的 MAPE; 将每一折训练样本均作为一次验证集, 重复上述过程, 统计并计算 k 个 MAPE 的均值, 即平均 MAPE。

(5) 对所有扩展因子, 重复步骤 (4), 将平均 MAPE 的最小值对应的扩展因子左右均设置一个步长的区间, 再将步长调整为之前的 1/10, 即 0.001, 再重复步骤 (4), 将平均 MAPE 的最小值对应的扩展因子作为最优扩展因子, 该方法可将最优扩展因子的精度提高至 0.001, 从而进一步提高网络的训练性能。

3 海试数据验证

3.1 实验描述

SWellEX-96 共包含 S5 和 S59 两个航次, 图 2 为海试环境参数, 图 3 为该实验 S59 航次地图, 图中蓝线表示目标声源轨迹, 红线表示干扰声源 (水面舰船) 轨迹。本文将该实验中有强干扰的 S59 航次的

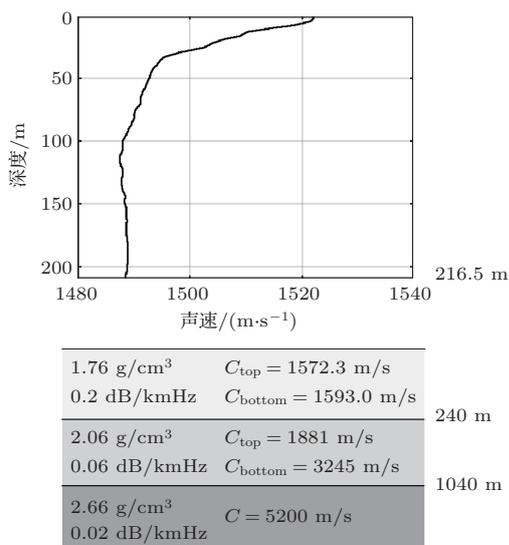


图 2 SWellEX-96 实验浅海环境参数模型

Fig. 2 Swellex-96 experiment shallow sea environment parameter model

垂直阵接收的数据用于网络的训练和测试。实验船共拖曳了深 (54 m) 和浅 (9 m) 两个声源, 其速度约为 2.5 m/s, 共采集了 65 min 数据, 发射在 49~400 Hz 之间多个频点的连续波 (Continuous wave, CW) 信号。实验使用共有 22 个水听器的垂直阵, 采样频率为 1.5 kHz, 布放的深度为 94.125~212.25 m 之间, 在实验中有一个水听器出现故障, 因此仅使用其他 21 个水听器的测量数据, 干扰信号由水面舰船发出, 频段为 62~401 Hz^[21]。

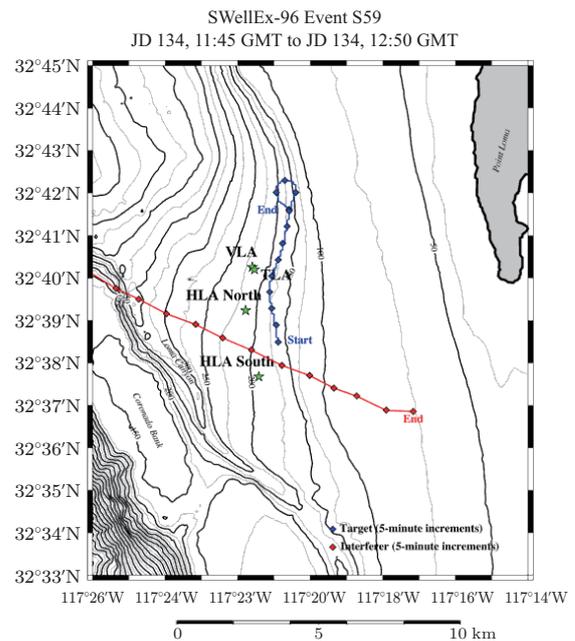


图 3 SWellEX-96 实验 S59 航次地图^[21]

Fig. 3 Swellex-96 experiment S59 voyage map^[21]

3.2 实验数据处理及结果分析

3.2.1 MFP 定位

本文对深 (54 m) 声源进行距离估计, 窄带声源的中心频率为 235 Hz, {112 235 388} Hz 三个频点 (SWellEX-96 实验中发射声源级最大的一组频点中取得) 作为宽带声源频率, 设置海域的搜索距离范围是 0~10 km, 间隔为 10 m; 深度范围 1~200 m, 间隔为 1 m, 从而计算拷贝场。测试海域为浅海, 且为距离不相关的波导环境, 声源发射信号为低频, 因此使用基于简正波模型的 Kraken 程序进行仿真, 声压场的互谱密度矩阵由 3 个 1 s 的快拍数据计算得到, 基于 Bartlett 算法估计出水下目标声源的空间位置。图 4 为以实际距离 3.93 km 处为例的窄带和宽带模糊度平面图, 图 5 为窄带和宽带的距离估计结果。结果表明: 在强干扰下, MFP 无法得到有效

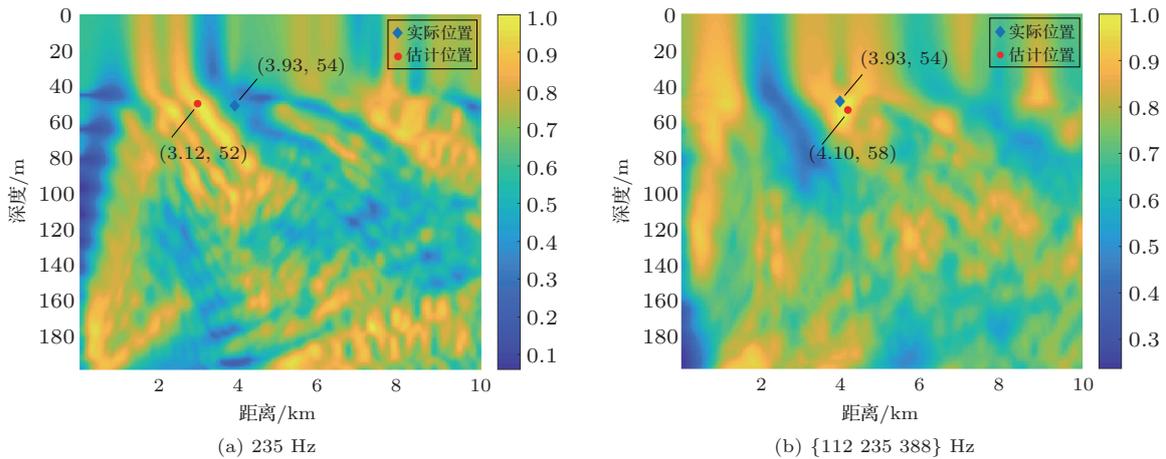


图4 MFP 模糊度平面图

Fig. 4 Ambiguity surface of MFP

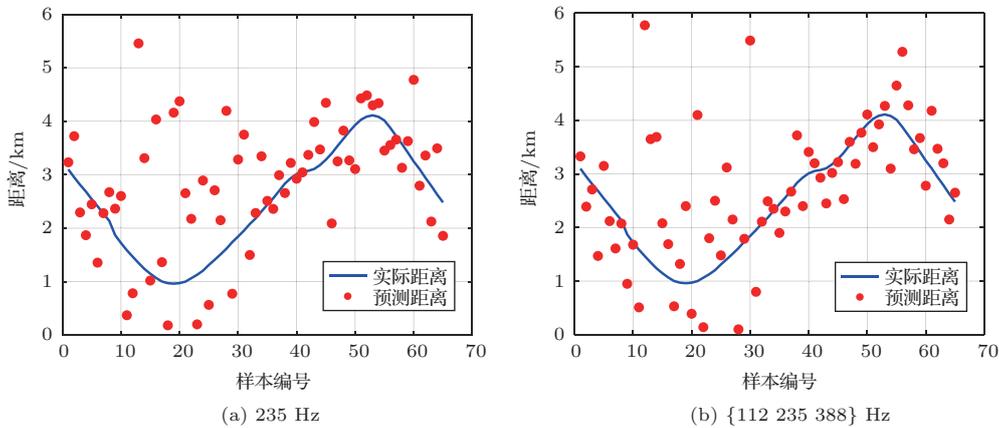


图5 MFP 在测试集上的距离估计结果

Fig. 5 Range estimation results of MFP on the test set

的距离估计,由于简正波模型不适合近场声场建模,导致在0~2 km之间的声源定位效果较差。相比窄带声源,宽带声源的距离估计性能略好。

3.2.2 CNN

该实验共记录了65 min数据,每1 min给出了该时刻的空间位置信息,将该66个位置的对应数据作为测试样本。在相邻的两个测试样本间,每间隔5.0 m (约为2 s)作为一个训练样本,距离值通过插值获得,各个选取频率及各位置下的SCMs由3个1 s快拍数据平均计算获得,共1775个插值点作为训练样本(为避免测试集泄漏,剔除距离测试样本5.0 m的训练样本),窄带和宽带声源的特征数分别为462和1386,网络输入分别为 1×462 和 1×1386 的一维序列。隐藏层由卷积层和全连接层组成,其中卷积层使用卷积核大小为5,在3个阶段中,步长分别为1、2、2,滤波器个数分别为5、10、20。卷积之

后通过批规划化层使得卷积输出满足0均值和1标准差,批规范化后使用修正线性函数ReLU作为激活函数。卷积层之间使用残差连接来训练深层网络,卷积层之后为全局平均池化层、全连接层、ReLU 激活层、比率为0.5的Dropout层和回归层^[26]。

网络输出为距离值,因此输出层仅有一个神经元。作为回归问题,网络训练使用

$$L_{MSE}(d, \hat{d}) = \frac{1}{N} \sum_{i=1}^N (d^{(i)} - \hat{d}^{(i)})^2, \quad (12)$$

作为损失函数,采用Sgdm算法作为优化算法,学习率为0.0001,最大迭代次数为500,图6为网络的总体结构。图7为CNN在测试集上的距离估计结果,可得到CNN方法相比MFP,可以在环境失配下的0~2 km下有较好的估计性能,但其精度和稳健性相比GRNN方法较差,网络参数较多,训练时间较长,并且容易过拟合。

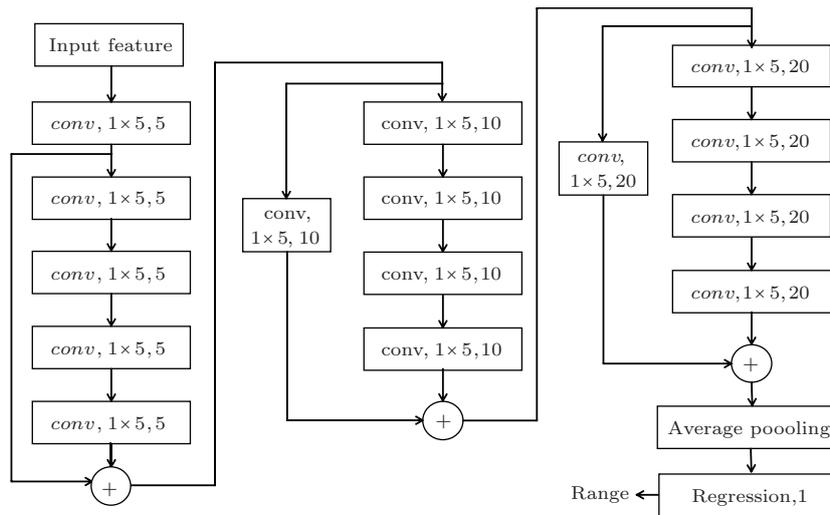


图6 CNN结构图

Fig. 6 CNN structure chart

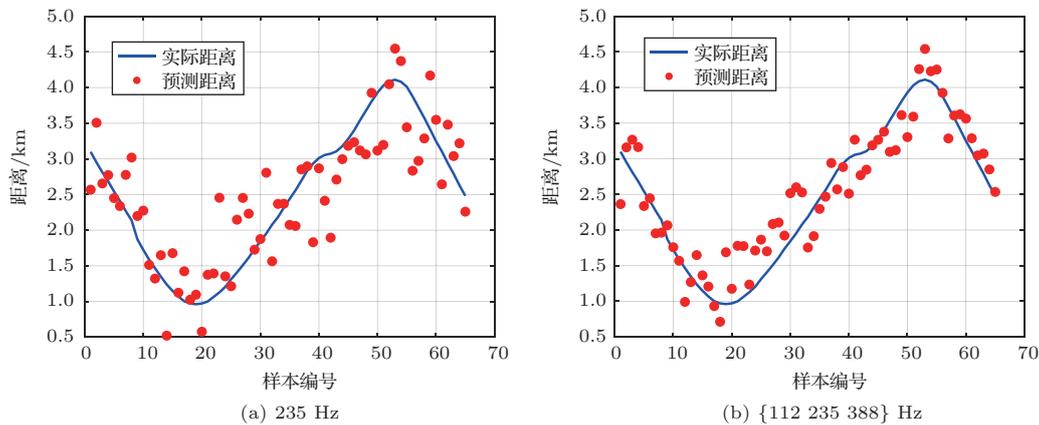


图7 CNN在测试集上的距离估计结果

Fig. 7 Range estimation results of CNN on test set

3.2.3 GRNN回归器

GRNN的输入和CNN一致,图8为窄带声源和宽带声源在不同扩展因子下的预测结果,可得到窄带声源和宽带声源的最佳扩展因子分别为0.005和0.006。窄带声源和宽带声源的验证集在GRNN方法下的距离估计结果如图9所示,可得到:和MFP相比,GRNN对窄带和宽带声源的距离估计性能均明显提升,尤其是在0~2 km间的声源距离估计。

窄带和宽带声源的距离分别在MFP、CNN和GRNN三种方法估计下的MAPE如表1所示。由表1的横向对比可得到,窄带声源和宽带声源在GRNN方法下的MAPE均远小于CNN和MFP,GRNN估计性能明显优于CNN和MFP;相比MFP,CNN方法下的MAPE较小,CNN的估计性能较为优良。由表1的纵向对比可得到,GRNN、CNN和MFP三种方法对宽带声源的MAPE均小

于窄带声源,由于和窄带声源相比,宽带声源的输入特征较多,因此其估计性能会更好。

宽带声源的距离在3种方法下估计结果的绝对误差如图10所示。MFP、CNN和GRNN的平均绝对误差分别为1.121 km、0.310 km和0.058 km,CNN和GRNN均大幅度地减小了距离估计的绝对误差,且GRNN具有最高的估计精度和最好的稳定性。

表1 宽带声源和窄带声源在不同方法下的MAPE
Table 1 MAPE of broadband and narrow-band sources under different methods

方法	MFP	CNN	GRNN
窄带 235 Hz	83.10	19.85	8.0634
宽带 {112 235 388} Hz	37.78	15.05	2.0433

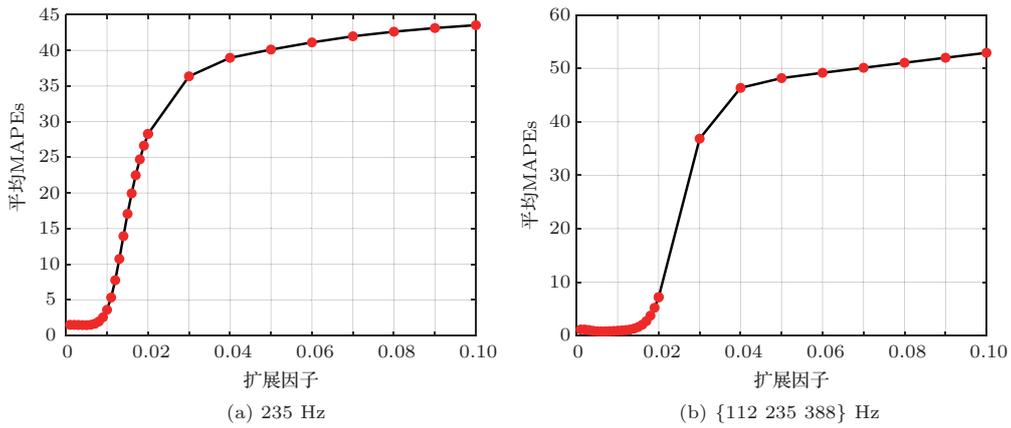


图8 GRNN在验证集上不同扩展因子的距离估计结果

Fig. 8 Range estimation results of different extension factors of GRNN on the validation set

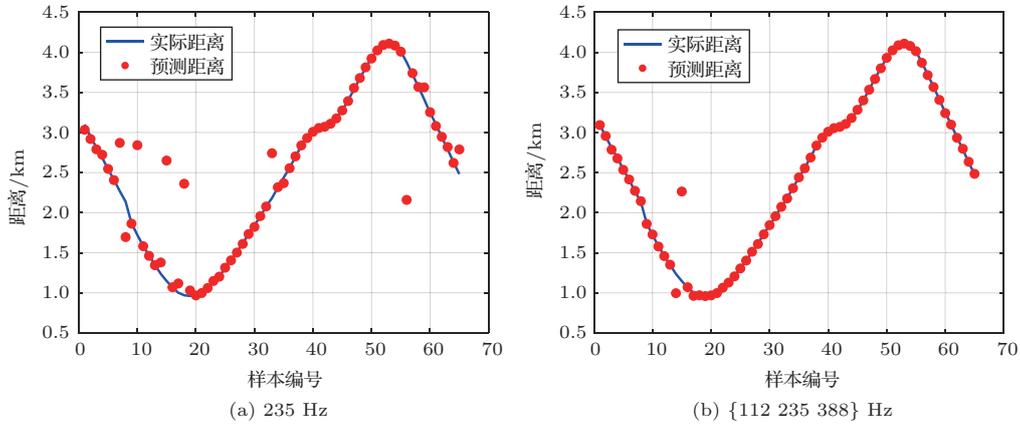


图9 GRNN在测试集上的距离估计结果

Fig. 9 Range estimation results of GRNN on the test set

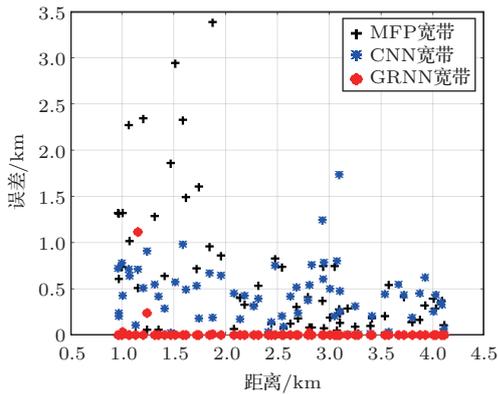


图10 宽带声源在3种方法下距离估计结果的绝对误差
Fig. 10 Absolute error of range estimation results for broadband sound sources under three methods

4 结论

机器学习在水声被动定位领域的结合日益密切, 本文研究其中的目标距离估计方面, 大多相关

研究是在高信噪比下的目标距离估计, 而机器学习在强干扰下的低信噪比海洋环境中应用相对较少。本文提出了基于优化扩展因子的GRNN, 并利用SWellEX-96实验中在强干扰下的S59航次数据进行了方法的验证, 对比了MFP、CNN、GRNN三种方法的水下目标声源距离估计性能。可得到, 数据驱动的GRNN和CNN方法距离估计性能明显优于传统模型驱动的MFP方法, 在已知海洋环境参数的条件下, GRNN、CNN和MFP三种方法对宽带声源的估计性能均优于窄带声源, 且对窄带和宽带声源, GRNN均具有最优的估计性能, 在海洋环境参数出现失配时, MFP方法已不适用, CNN方法的精度和稳健性较差, 而GRNN方法仍可以较好地实现距离估计。在实际应用中, GRNN方法需要获得一定数量的阵列实际测量数据来训练网络, 无需海洋环境参数, 有着较好的可行性和稳健性。

参 考 文 献

- [1] 张旭, 孙翱, 韩旭, 等. 水下垂向运动目标的海底多基站声定位方法及精度分析[J]. 声学学报, 2019, 44(2): 155–169.
Zhang Xu, Sun Ao, Han Xu, et al. Acoustic localization scheme and accuracy analysis for underwater vertical motion target using multi-stations in the seabed[J]. Acta Acustica, 2019, 44(2): 155–169.
- [2] 张雪冬, 牛海强, 吴立新. 一种基于序贯估计的直达声区水面舰船被动测距方法[J]. 应用声学, 2020, 39(4): 491–500.
Zhang Xuedong, Niu Haiqiang, Wu Lixin. Passive tracking of a surface ship in the direct zone using sequential parameter estimation[J]. Journal of Applied Acoustics, 2020, 39(4): 491–500.
- [3] 刘炎堃, 郭永刚, 李整林, 等. 基于路径选择的深海水下运动目标被动深度估计[J]. 应用声学, 2020, 39(5): 647–655.
Liu Yankun, Guo Yonggang, Li Zhenglin, et al. Depth estimation of moving underwater source based on routes choosing[J]. Journal of Applied Acoustics, 2020, 39(5): 647–655.
- [4] Bucker H P. Use of calculated sound fields and matched-field detection to locate sound sources in shallow water[J]. The Journal of the Acoustical Society of America, 1976, 59(2): 368–373.
- [5] Baggeroer A B. Matched field processing: source localization in correlated noise as an optimum parameter estimation problem[J]. The Journal of the Acoustical Society of America, 1988, 83(2): 571–587.
- [6] Michalopoulou Z H, Porter M B. Matched-field processing for broad-band source localization[J]. IEEE Journal of Oceanic Engineering, 1996, 21(4): 384–392.
- [7] Soares C, Jesus S M. Broadband matched-field processing: coherent and incoherent approaches[J]. The Journal of the Acoustical Society of America, 2003, 113(5): 2587–2598.
- [8] 杨坤德, 马远良, 邹士新, 等. 基于环境扰动的线性匹配场处理方法[J]. 声学学报, 2006, (6): 496–505.
Yang Kunde, Ma Yuanliang, Zou Shixin, et al. Linear matched field processing based on environmental perturbation[J]. Acta Acustica, 2006, 43(6): 496–505.
- [9] 贾雨晴, 苏林, 郭圣明, 等. 浅海时变声速环境下的自适应匹配场定位算法实现[J]. 应用声学, 2018, 37(4): 518–527.
Jia Yuqing, Su Lin, Guo Shengming, et al. An adaptive matched-field source localization algorithm in coastal water under the circumstances of time-evolving sound speed profiles[J]. Journal of Applied Acoustics, 2018, 37(4): 518–527.
- [10] Steinberg B Z, Beran M J, Chin S H, et al. A neural network approach to source localization[J]. The Journal of the Acoustical Society of America, 1991, 90(4): 2081–2090.
- [11] Niu H, Reeves E, Gerstoft P. Source localization in an ocean waveguide using supervised machine learning[J]. The Journal of the Acoustical Society of America, 2017, 142(3): 1176–1188.
- [12] Wang Y, Peng H. Underwater acoustic source localization using generalized regression neural network[J]. The Journal of the Acoustical Society of America, 2018, 143(4): 2321–2331.
- [13] Huang Z, Xu J, Gong Z, et al. Source localization using deep neural networks in a shallow water environment[J]. The Journal of the Acoustical Society of America, 2018, 143(5): 2922–2932.
- [14] Liu Y, Niu H, Li Z. Source ranging using ensemble convolutional networks in the direct zone of deep water[J]. Chinese Physics Letters, 2019, 36(4): 044302.
- [15] Niu H, Gong Z, Ozanich E, et al. Deep-learning source localization using multi-frequency magnitude-only data[J]. The Journal of the Acoustical Society of America, 2019, 146(1): 211–222.
- [16] Liu W, Yang Y, Xu M, et al. Source localization in the deep ocean using a convolutional neural network[J]. The Journal of the Acoustical Society of America, 2020, 147(4): EL314–EL319.
- [17] 张巧力, 刘福臣. 基于 FFNN 的垂直阵被动定位技术研究[J]. 声学与电子工程, 2020 (1): 32–36.
- [18] Niu H, Gerstoft P. Source localization in underwater waveguides using machine learning[J]. The Journal of the Acoustical Society of America, 2016, 140(4): 3232–3232.
- [19] Ozanich E R, Gerstoft P, Purohit A. Ocean acoustic range estimation in noisy environments using convolutional networks[J]. The Journal of the Acoustical Society of America, 2018, 144(3): 1743–1743.
- [20] Ozanich E, Gerstoft P, Niu H. A feedforward neural network for direction-of-arrival estimation[J]. The Journal of the Acoustical Society of America, 2020, 147(3): 2035–2048.
- [21] Muarry J, Ensberg D. The swellex-96 experiment [DB/OL]. [1996-05-31]. [2019-10-15]. <http://www.swellex96.ucsd.edu/>.
- [22] Porter M B. The KRAKEN normal mode program[R]. Naval Research Lab Washington DC, 1992.
- [23] 杨坤德. 水声信号的匹配场处理技术研究[D]. 西安: 西北工业大学, 2003.
- [24] Specht D F. A general regression neural network[J]. IEEE Transactions on Neural Networks, 1991, 2(6): 568–576.
- [25] Niu H, Ozanich E, Gerstoft P. Ship localization in Santa Barbara Channel using machine learning classifiers[J]. The Journal of the Acoustical Society of America, 2017, 142(5): EL455–EL460.
- [26] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770–778.