庆祝张仁和先生85华诞

# 结合卷积神经网络的浅海有源探测信道匹配\*

(1 中国科学院声学研究所 声场声信息国家重点实验室 北京 100190)

(2 中国科学院大学 北京 100049)

2020年10月19日收到

2021年4月21日定稿

**摘要** 信道匹配方法在有源探测领域是一种重要的提升检测信噪比的方法。针对非确知海底参数环境下的有源探测信道匹配 问题.提出一种结合卷积神经网络进行信道匹配的算法。该算法基于海底参数扰动开展声场仿真生成卷积网络训练数据;首 先通过分类网络将信号按照海底底质类型分类,在每个分类区间内采用单独的卷积网络反演海底参数;然后结合声场模型估 计信道传递函数,进行信道匹配,从而在非确知环境下抑制多途影响,提升回波检测能力。仿真与实验结果表明,该算法能 够在不确知海底环境条件下,有效估计信道传递函数,实现信道最优化匹配,在实验条件下可提高回波检测信噪比 4 dB 左 右。相比传统方法,该算法可以在海底参数不确知条件下对低接收信噪比的信号实现信道匹配,同时不需要高信噪比的实验 参考信号,有效提高了信道匹配方法的环境宽容性。 PACS 数: 43.30, 43.60

# Channel matching of shallow water active detection combined with convolutional neural network

XUE Cheng<sup>1,2</sup> GONG Zaixiao<sup>1</sup> GU Yiming<sup>1</sup> WANG Yu<sup>1</sup> LIN Peng<sup>1</sup> LI Zhenglin<sup>1</sup> (1 State Key Laboratory of Acoustics, Institute of Acoustics, Chinese Academy of Sciences Beijing 100190) (2 University of Chinese Academy of Sciences Beijing 100049) Received Oct. 19, 2020

Revised Apr. 21, 2021

**Abstract** Channel matching is an important method to improve the detection SNR in the field of active detection. Aiming at the problem of active detection channel matching in the environment of unascertained seabed parameters, a channel matching algorithm combined with convolution neural network is proposed. The algorithm is based on the seabed parameter disturbance to carry out sound field simulation and generate convolution network training data. Firstly, the signals are classified according to the seabed sediment types by classification network, and the seabed parameters are retrieved by using a separate convolution network in each classification interval. Then, the acoustic field model is used to estimate the channel transfer function for channel matching, so as to suppress the multipath effect and improve the echo detection ability in the unascertained environment. Simulation and experimental results show that the algorithm can effectively estimate the channel transfer function and realize the optimal channel matching under the condition of uncertain seabed environment. Under the experimental conditions, the SNR of echo detection can be improved by about 4 dB. Compared with the traditional methods, this algorithm can achieve channel matching for low SNR signals under the condition of uncertain seabed parameters, and does not need high SNR experimental reference signals, which effectively improves the environmental tolerance of the channel matching method.

<sup>\*</sup> 国家自然科学基金项目(1184061)资助

<sup>†</sup> 通讯作者: 李整林, lzhl@mail.ioa.ac.cn

# 引言

信道匹配技术可在有源探测背景下用于抑制多途对脉冲信号检测的不利影响,提高对回波脉冲的检测能力<sup>[1]</sup>。常见的信道匹配算法有解卷积信道响应法<sup>[2]</sup>,自适应信道匹配法<sup>[3]</sup>和声场模型匹配法等。解卷积法需要以高信噪比的接收信号作为参考信号, 估算信道传递函数,其可行性受限于信道的时空稳定性<sup>[4]</sup>。而基于声场模型计算信道传递函数的信道匹配方法,对实验信号的信噪比要求较低,但处理效果由模型的准确性决定。水声信道中的声速剖面、声源与接收深度和海底声学特性等,构成了水声模型计算的重要参数,都存在一定的不确定性,会直接影响信道匹配的性能。

相对而言,海底声学参数很难直接测量,近年 来,研究者相继提出了很多海底参数反演方案,包 括噪声相干性反演海底参数<sup>[5]</sup>,近场脉冲波形反演 声速<sup>[6]</sup>和声传播损失反演衰减系数<sup>[7]</sup>等。传统的海 底环境参数反演方法通常基于匹配场处理,由于海 底环境参数之间存在耦合关系,反演结果往往受到 多值问题的困扰。李整林等<sup>[8-9]</sup>提出多物理量联合 地声反演方法,以解决反演中的多值问题。李倩倩 等<sup>[10]</sup>利用贝叶斯声源定位法,将环境参数与声源位 置同时反演,以解决不确知海洋环境下的定位问题。 但对于匹配场处理而言,上述方法使得参数搜索空间 维数大大增加,处理的实时性会显著降低。

近年来,随着深度学习技术的快速发展,许多研究者提出了一系列基于神经网络的水声目标测距和 定深方法。牛海强等<sup>[11]</sup>提出基于机器学习算法的水 下声源定位方法,并通过海试实验数据验证了该算法 的定位性能。黄兆琼等<sup>[12]</sup>将仿真声场数据集作为训 练数据,利用卷积神经网络实现水下声源定位,证实 了使用声场模型仿真数据作为神经网络训练数据的 可行性。牛海强<sup>[13]</sup>等利用基于残差神经网络的分段 处理算法,对不确知环境下的声源信号进行了定位 和定深。而机器学习方法在浅海海底反演和信道估 计中的研究相对较少。Van Komen 等<sup>[18]</sup>通过在生成 训练数据的声场模型中引入4种典型海底环境,实 现了基于卷积网络的海底底质分类。Frederick等<sup>[19]</sup> 在此模型基础上增加了多层海底和散射相关参数, 并将多种深度学习网络与匹配场分类方法进行了对

比。但是,上述工作都只对海底底质进行了简单分 类,而没有给出海底参数的定量估计结果。

针对在海底环境参数不确知条件下进行水声信 道匹配处理以提升回波检测性能的问题,本文提出 了一种结合卷积网络的信道匹配算法。该算法首先 针对位置已知的水面目标信号,将声场模型计算出 的不同海底参数条件下的接收信号数据作为卷积神 经网络训练数据,采取分步训练策略,通过一维卷积 神经网络实现海底参数反演,可估计出海底环境参 数。然后再估计不同深度的信道传递函数,用于其 它深度未知的目标回波信号的信道匹配,实现了较 高的有源匹配处理增益,同时可粗略实现对目标的 深度估计。利用 2018 年春季南海海域浅海有源探测 试验数据,在不确知海底环境条件下开展了信道匹 配验证,对比信道匹配处理前后的信噪比增益,实验 验证了算法的有效性。仿真与实验结果均表明, 卷积 神经网络方法克服了海底参数估计中的多值问题的 困扰,相比多参数的匹配场反演,处理实时性显著 提高。与传统信道匹配方法相比,结合卷积网络的信 道匹配算法可以在不确知海底参数条件下实现信道 匹配,可以处理强时变,强噪声干扰信道下的接收信 号,提高了信道匹配方法的环境宽容性。

# 1 信道匹配

水声有源探测应用中,从有源声源发射一定脉 宽和频度宽度的脉冲信号 *s*(*t*):

$$s(t) = \frac{1}{2\pi} \int S(\omega) \exp(i\omega t) d\omega.$$
(1)

在噪声背景下的接收信号可表示为:

$$r(t) = \frac{1}{2\pi} \int S(\omega) H(\omega) \exp(i\omega t) d\omega + n(t), \qquad (2)$$

式中, *H*(*ω*) 为声源到目标再到接收阵的双程信道传 递函数<sup>[21]</sup>, 在简正波理论模型中:

$$H(\omega, r_1, r_2, z_S, z_R, z_T) = C^2 \sum_m \sum_n \phi_m(z_S) \phi_m(z_T) \frac{\exp\left[-ik_m(\omega)r_1\right]}{\sqrt{k_m(\omega)r_1}}$$
(3)  
$$T_{mn}(\omega, \varphi_i, \varphi_s) \phi_n(z_T) \phi_n(z_R) \frac{\exp\left[-ik_n(\omega)r_2\right]}{\sqrt{k_n(\omega)r_2}},$$

其中,  $C = \sqrt{2\pi i} \exp[-i(\pi/4 + k_0)]/\rho(z_s)$  为系数,  $k_0 = \omega/c_0$ ,  $c_0$  为参考声速,  $\rho$  为海水密度,  $z_s$  为声源深度,  $z_R$  为接收深度,  $z_T$  为目标深度。 $\phi(z)$  为各号简正波的本征函数,  $k(\omega)$  为简正波的本征值。 $T_{mn}$  为目标散射函数,  $\varphi_i$ 和  $\varphi_s$  分别为水平入射和散射角度, 此处不考虑目标散射函数随频率的变化。

对式(2)中接收信号进行脉冲压缩的结果为:

$$r_f(t) = r_{fs}(t) + n_f(t),$$
 (4)

式中:

$$r_{fs}(t) = \frac{1}{2\pi} \int |S(\omega)|^2 H(\omega) \mathrm{e}^{\mathrm{i}\omega t} \mathrm{d}\omega, \qquad (5)$$

$$n_f(t) = \int S^*(\omega) \left[ \int n(t) \mathrm{e}^{-\mathrm{i}\omega t} \mathrm{d}t \right] \mathrm{e}^{\mathrm{i}\omega t} \mathrm{d}\omega. \quad (6)$$

脉冲压缩使用声源信号的共轭作为滤波器响应 函数,实现对信号的匹配滤波,提升接收信噪比。但 水声信道的多途效应会使声脉冲的能量在时间轴上 分散,从而降低接收信号的峰值检测信噪比。此时, 可以将信道传递函数 *H*(*ω*)的共轭作为滤波器的响 应函数,对经过脉冲压缩的信号进行进一步匹配处 理,得到:

$$r_{ff}(t) = r_{ffs}(t) + n_{ff}(t),$$
 (7)

式中:

$$r_{ffs}(t) = \frac{1}{2\pi} \int |S(\omega)|^2 |H(\omega)|^2 e^{i\omega t} d\omega, \qquad (8)$$

$$n_{ff}(t) = \int S^*(\omega) H^*(\omega) \left[ \int n(t) \mathrm{e}^{-\mathrm{i}\omega t} \mathrm{d}t \right] \mathrm{e}^{\mathrm{i}\omega t} \mathrm{d}\omega, \quad (9)$$

从而实现信道匹配,进一步提高接收信号的峰值检测 信噪比。信道匹配的关键在于对信道传递函数 *H*(ω) 的有效估计。对时不变的稳定信道,可以采用对强脉 冲激励信号进行解卷积运算求解信道响应函数;而 对时、空变化明显的不稳定信道,可以建立声场模型 求解对应接收信号时刻的信道传递函数,以对回波 信号实现自适应信道匹配。

对于浅海有源探测中使用的船载拖曳阵与拖曳 声源构成的有源声呐,其对应的传播信道是明显的 时、空变化多途信道。此时采用基于模型的信道匹配 技术,其关键在于声场建模的准确性,其严重依赖于 环境参数信息的准确性。但在实际探测背景中,环境 参数难免出现测量缺失或误差,尤其是海底环境参 数的测量更为困难。所以,发展不确知海底环境条件 下的声场建模和信道匹配方法,对有源探测具有重 要意义。

# 2 结合卷积神经网络的海底参数反演

针对不确知海底环境条件下的信道匹配问题, 海洋环境模型如图 1 所示,提出一种结合卷积神经 网络的海底参数反演与信道估计方法,如图 2 所示。 将目标回波信号进行预处理后,输入到卷积神经网络 中进行预测,根据神经网络的输出,估计对应环境的 海底参数。随后利用反演出的海底参数构建声场模 型,计算信道响应函数,对实验测量的有源回波信号 进行信道匹配处理。

如图 1 所示算法所用海水声速剖面为南海浅海

有源探测实验中记录的负梯度剖面,海深为 100 m, 海底为半无限大海底模型,其包括海底的密度 ρ<sub>b</sub>,声 速 c<sub>b</sub> 和吸收系数 α<sub>b</sub> 三个未知参数。对于一般浅海 远场环境,使用等效的半无限大液态海底模型,可较 为准确的实现声场预报。对反演问题来说,半无限大 海底模型相比双层或多层海底模型,可有效降低待 反演参数的维数<sup>[9]</sup>。





考虑到不同海底参数之间存在一定的耦合关 系,从而产生多值问题,直接训练单个机器学习模 型预测海底环境参数,搜索空间大,训练难度高。因 此,结合海底环境参数内部关系,采用分步监督式 学习训练卷积神经网络的策略<sup>[13]</sup>,来估计海底环境 参数。 分步的卷积神经网络预测过程如图 2 所示:第 1 步,通过卷积神经网络估计输入信号的海底密度范 围,并基于海底密度将输入信号分为 3 类。密度分 类区间参考 Hamilton 海底沉积层分类法<sup>[15]</sup>,分为 [1.4,1.7),[1.7,1.8),[1.8,2.1](单位:g/cm<sup>3</sup>)3个区间, 分别对应黏土,粉砂和砂 3 大类主要沉积层类型。第 2 步,对不同类型的输入信号,单独训练卷积神经网 络,估计沉积层密度和吸收系数,并且利用 Hamilton 经验公式间接计算海底声速。将第 1 步所训练的模型 记为 NET-1;第 2 步所训练的模型记为 NET-2-X,其 中 X 为分类序号;总计训练 4 个卷积神经网络模型。

### 2.1 数据生成与预处理

这里采用不同海底环境参数组合,经 Kraken 声 场模型计算的仿真声场作为卷积网络的训练数据,以 获取足够多不同海底环境条件下的训练数据样本。 有源探测声源信号为 400~500 Hz 的调频信号,声速 剖面如图 1 所示,环境参数取值范围如表 1 所示, 其中海底密度 ρ<sub>b</sub> 与沉积层吸收系数 α<sub>b</sub> 在区间内均 匀取值,而海底声速 c<sub>b</sub> 利用 Hamilton 经验公式<sup>[15]</sup> 由海底密度间接计算:

$$c_b = 2330.4 - 1257\rho_b + 487.4\rho_b^2.$$
 (10)

参数名	单位	训练数据 取值范围	验证数据 取值范围
目标距离	(m)	$3500 {\sim} 8500$	$3500{\sim}8500$
信噪比	(dB)	$0 \sim 10$	5
声源深度	(m)	45	45
目标深度	(m)	3	3
接收深度	(m)	11	11
海底密度	$(g/cm^3)$	$1.4\!\sim\!2.1$	$1.4\!\sim\!2.1$
吸收系数	$(\mathrm{dB}/\lambda)$	$0.05 \sim 0.8$	$0.05 \sim 0.8$
海底声速	(m/s)	$1525{\sim}1840$	$1525{\sim}1840$

表1 训练与验证数据参数

在浅海信道的水声传播过程中,海底参数可能 在特定范围内与距离和深度产生较大的耦合。因此 在仿真训练信号时,发射和接收深度都保持不变,采 用固定值,而目标距离在 3500 m 到 8500 m 之间按 一定间隔取值,在每个距离区间内训练相应模型。这 样既保证了模型的适用范围,又避免了可能存在的 多值问题。此外,在有源探测过程中,将用于训练和 预测的目标信号限定为深度已知的水面目标信号, 因此将仿真目标深度设定为3m已知,以简化模型 训练参数。

基于神经网络的无源定位研究<sup>[14]</sup>表明,在较高 信噪比条件下训练的神经网络模型,其在低信噪比条 件下的定位性能会急剧下降。为了提高所训练模型在 低信噪比下的稳定性,可以采用数据增强方法,使用 带噪声的数据作为训练数据。因此对训练数据叠加 一定幅度的高斯白噪声,从而获取相应信噪比的接 收信号,如表1所示。

通过模型计算仿真接收信号,时长为 40 s,其中 400~500 Hz 频带对应频点个数为 4000,获取接收信 号复声压数据 *p*(*f*) 后,根据

$$\widetilde{p}(f) = \frac{|p(f)|}{\max|p(f)|} \tag{11}$$

计算归一化的幅度谱  $\tilde{p}(f)^{[13]}$ 。经过预处理后,  $\tilde{p}(f)$ 转化为元素取值范围为 [0,1]的 1×4000 一维频谱 序列,符合一维卷积神经网络的输入要求,总计生成 60000 个训练样本。输入网络的单个训练样本可以 表示为  $\boldsymbol{x}^{(i)} = [x_1^{(i)}, x_2^{(i)}, \cdots, x_L^{(i)}],其中 L 表示频点个$  $数。整个训练集的输入数据可以表示为矩阵形式 <math>\boldsymbol{X} = [\boldsymbol{x}^{(1)}, \boldsymbol{x}^{(2)}, \cdots, \boldsymbol{x}^{(N)}],其中 N$ 为训练集的样本数。

模型的直接预测结果为海底密度和沉积层吸收 系数,因此将二者标准化并记录为数据标签,即  $y^{(i)} = [\rho^{(i)}, \alpha^{(i)}]$ 。基于密度分类区间,NET-2-X 中的密度 标准化范围各不相同。

### 2.2 深度学习网络设计

神经网络模型的构建采用 TensorFlow2.0<sup>[20]</sup> 作为主要工具,输入特征为一维频谱序列,因此使用一 维卷积神经网络进行预测。

构建的网络总体结构如图 3 所示,参数如表 2 所示。输入数据频点数为 4000,因此网络输入为 1×4000 的一维频谱序列。隐藏层由卷积层和全连接层组成。 其中卷积层共有 10 层,采用卷积核大小为 5,步长



图 3 卷积网络结构示意图

为1的一维卷积, 滤波器个数采用递增形式, 第1层 和第2层为32个, 第3层和第4层为64个, 以此 类推。每层卷积层后加批规范化层处理卷积输出, 并 使用修正线性单元 (ReLU)作为激活函数。在每两个 卷积层后增加一个最大池化层。在最后一层卷积层 之后使用全局平均池化层将提取特征展开, 然后接 一个全连接层, 神经元数目为512, 同样使用 ReLU 激活, 其后加一个丢弃率为0.5 的 Dropout 层。

卷积层序号	卷积核数量	卷积核尺寸	输出向量形式
卷积层 1, 2	32	5	$1\!\times\!4000\!\times\!32$
卷积层 3,4	64	5	$1\!\times\!2000\!\times\!64$
卷积层 5,6	128	5	$1\!\times\!1000\!\times\!128$
卷积层 7,8	256	5	$1\!\times\!500\!\times\!256$
卷积层 9,10	512	5	$1\!\times\!250\!\times\!512$
池化层序号	池化窗	输出向量形式	
最大池化层1	2 4	$1\!\times\!2000\!\times\!32$	
最大池化层 2	2 4	$1\!\times\!1000\!\times\!64$	
最大池化层 3	2 4	$1\!\times\!500\!\times\!128$	
最大池化层 4	2 4	$1\!\times\!250\!\times\!256$	
平均池化层	_	$1 \times 512$	
全连接层序号	节点	输出向量形式	
全连接层1	51	$1 \times 512$	

表 2 卷积网络主要结构参数

NET-1 采用单标签分类器,输出基于海底密度的分类,因此采用三维独热编码表示 3 种类别,输出 层神经元数目为 3,使用 Softmax 激活。网络训练使 用交叉熵

$$L_{\rm CE} = -\frac{1}{N} \sum_{i=1}^{N} \sum_{k=1}^{K} t_{ik} \ln y_{ik}$$
(12)

作为损失函数,其中 N 为样本总数, K 为总分类数, t<sub>ik</sub> 为类别指示变量, y<sub>ik</sub> 为预测概率。采用 Adam 优 化器对网络的参数进行优化,并设置 0.001~0.0001 的衰减学习率。

NET-2-X 采用多输出回归模型,输出海底密度和吸收系数,因此输出层数目为2,不使用激活函数。 作为回归问题,网络训练使用均方误差 (MSE)

$$L_{\text{MSE}} = \sum_{j=1}^{J} l_j \left[ \frac{1}{N} \sum_{i=1}^{N} \left( y_j^{(i)} - \widehat{y}_j^{(i)} \right)^2 \right]$$
(13)

作为损失函数,其中 N 为样本总数,J 为输出层总数, $l_j$  为单项输出的损失函数权重, $y_j^{(i)}$  为真实值, $\hat{y}_j^{(i)}$  为预测值。在近距离水声传播中,海底密度与声速对信号传播的影响要大于海底吸收系数的影响,

因此将海底密度损失权重设为 1, 吸收系数损失权重 为 0.2。优化器设置与 NET-1 相同。

#### 2.3 拟合分析

由于仿真训练数据包含的参数较多且存在耦合 关系,在训练过程中容易产生过拟合。因此在训练数 据集之外,通过仿真计算额外生成验证数据集,用于 观察训练过程中模型对数据集的拟合状况,控制训 练过程,从而消除过拟合现象。其环境参数取值范围 如表1所示,采用随机取值,并同样叠加一定幅度的 环境噪声,验证数据的样本数量为训练数据的10% 左右。

NET-1 训练过程中的损失函数和预测准确率变 化如图 4 所示。从图中可见,在经过一定批次的训练 后,训练曲线的准确率已经收敛到 99%,而验证曲线 也收敛到 94% 左右,表明 NET-1 对验证数据也能较 好的拟合分类,不存在过拟合问题。



#### 图 4 NET-1 拟合分析

NET-2-X 分为 3 个独立的网络进行训练,以对 应密度区间为 [1.7,1.8) (g/cm<sup>3</sup>) 的 NET-2-2 为例, 训练过程中的损失函数变化以及密度和吸收系数对 应的 MSE 变化曲线如图 5 所示。从图 5 可见,经过



图 5 NET-2-2 拟合分析

通过控制训练参数等方法,在网络训练过程中 消除过拟合现象,提高了模型的泛化能力。高度泛化 的多输出网络模型实际上解决了反演过程中海底参 数之间的耦合关系带来的多值问题,从而可以同时 估计多个海底环境参数。

# 3 结果与分析

为了验证结合卷积网络的信道匹配算法的有效 性,采用模拟数据和实验数据分别对卷积网络性能 进行测试,并将网络预测结果用于信道匹配处理。作 为分类问题,NET-1的性能直接以测试集的分类准 确率进行评估,即:

$$E_{\rm acc} = \frac{N_c}{N} \times 100\%,\tag{14}$$

其中, N 为总样本数, N<sub>c</sub> 为分类正确的样本数。而 作为回归问题, NET-2 的性能使用测试集输出结果 的平均绝对误差 (MAE):

$$E_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^{N} \left| y_p^{(i)} - y_g^{(i)} \right|$$
(15)

作为衡量指标,其中  $y_p$  为海底参数预测值,  $y_g$  为真实值。

在理想情况下,信道匹配的理论增益上限与多途拓展附加传播损失 TLR<sup>[1]</sup>相同,即:

TLR =

$$10 \lg \left\{ \frac{\max\left[ |s_0(t)|^2 \right]}{\int_0^T |s_0(t)|^2 \, \mathrm{d}t} \right\} - 10 \lg \left\{ \frac{\max\left[ |s(t)|^2 \right]}{\int_0^T |s(t)|^2 \, \mathrm{d}t} \right\}, \quad (16)$$

式中前一项对应发射信号峰值功率与信号能量比, 后一项对应接收信号峰值功率与信号能量比。上式 可以通过发射和接收信号波形估算多途附加传播损 失 TLR,并与算法的实际增益进行对比。

#### 3.1 测试数据

卷积网络测试集的参数取值如表 3 所示,并根据随机选取的目标距离分为 3 组。测试集的数据同样采用 Kraken 模型生成并添加一定环境噪声,如表 3 所示,而并非从训练数据集中截取。测试集的总样本数量约为训练集的 5% 左右。此外,为了验证当目标深度不匹配时的网络估计效果,额外添加 1 m 到 10 m(间隔为 0.5 m)的深度区间内的仿真数据,以作对比。

#### 3.1.1 测试结果分析

图 6 给出了部分测试集的密度估计结果,图中圆 圈与叉号分别对应测试数据的真实值与网络输出的 预测值。3 组测试集分类准确率分别为:97.5%,95.5% 和 96.5%。证明了 NET-1 对不同目标距离下的接收 信号进行密度分类的准确性。 图 7 与图 8 给出了 NET-2-2 的海底环境参数预 测结果,图中实线与叉号分别对应测试数据的真实值 与网络输出的预测值。其中,密度估计结果的 MAE 分别为 0.0057,0.0049 和 0.0051,而吸收系数估计的 MAE 分别为 0.051,0.045 和 0.047。预测结果证明了 NET-2-X 可以在不同目标距离条件下,较好的估计 海底环境参数。通过引入机器学习方法,大量密集的 计算被集中在模型的训练阶段,而预测阶段只需要 进行轻量级的计算。以上文测试集为例,训练过程用 时 9 小时左右,而预测用时仅 13.4 s;作为对比,多参 量联合地声反演处理单个测试样本用时约 400 s,对 整个测试集进行反演需要 60 小时以上。相比多参量 匹配场反演方法,海底环境参数估计的处理实时性 大幅提高。

表 3 测试集参数表

测试	数据	a b c		с
参数名	单位	取值范围		
目标距离	(m)	4556	6063	7397
信噪比	(dB)	5		
声源深度	(m)	45		
目标深度	(m)	3		
接收深度	(m)	11		
海底密度	$(g/cm^3)$	$1.4 \sim 2.1$		
吸收系数	$(dB/\lambda)$	$0.05 \sim 0.8$		
海底声速	(m/s)	$1525\!\sim\!1840$		





图 8 NET-2-2 吸收系数估计结果

3.1.2 深度不匹配的影响

针对实验场景中, 探测目标深度偏离平均深度, 导致训练和测试数据的深度不完全匹配的情况, 进一 步测试网络的估计性能。以 NET-2-2 为例, 分别测 试当实际目标在不同深度时, 网络对接收信号的估 计性能, 结果如图 9 所示, 其中与训练数据匹配的目 标深度为 3 m。

通过测试结果可以看出,当实际目标深度在 0.5 m 到 5 m 之间时,卷积网络的估计 MAE 与深度 完全匹配时相近;当实际目标深度在 5 m 以下时, 估计 MAE 逐渐增大。因此在实验场景中,网络对于 接近水面的目标数据拥有较强的泛化能力,在针对 水面舰艇目标的场景下拥有较好的鲁棒性。

#### 3.1.3 信道匹配过程

通过卷积网络的预测得到估计海底参数后,估

算信道传递函数,进行信道匹配。通过卷积网络预测 的海底环境参数与实际目标深度无关,在实验海区 环境参数不随目标变化的条件下,针对未知深度的 水下目标回波探测的场景,可以通过相同环境下的 水面目标进行海底参数估计,并通过构建声场模型 后进行深度搜索,来实现未知深度目标回波的信道 匹配。以下通过不同深度的仿真信号进行验证。

信号 1 为距离 4556 m、深度 3 m 的目标回波仿 真信号,其真实海底密度为 1.70 g/cm<sup>3</sup>, 沉积层吸收 系数为 0.69 dB/λ, 声速剖面如图 1 所示;信号 2 为 目标距离 6063 m, 深度 30 m 的仿真接收信号,海洋 环境参数与信号 1 相同。两信号带宽为 100 Hz, 中心 频率为 450 Hz, 接收信噪比均为 5 dB。接收信号经 过常规脉冲压缩处理后,信号 1 的接收信噪比提升 至 34.3 dB,信号 2 提升至 32.2 dB, 对应图 10 中标注 为圆圈的包络曲线,但都存在明显的信道多途, 难以



图 9 深度不匹配时的测试数据 MAE

准确确定信号到达时间。使用卷积网络对作为水面目标回波的信号1进行海底环境参数估计,结果为:海底密度为1.71 g/cm<sup>3</sup>,吸收系数为0.56 dB/λ。使用估计参数代入物理模型,在0.5 m 至95 m 目标深度范围内分别计算信道传递函数,对两段脉冲压缩后的信号进行信道匹配处理,结果如图11 所示。从图中可以看出,信道匹配产生的信噪比增益在对应深度处达到最大值,分别为3 m 和 30 m,从而可以通过深度搜索得到目标深度估计;同时匹配增益在 深度维度上是缓变的,因此信道匹配处理在一定深度范围内具有鲁棒性。将最佳匹配增益对应输出取

出,对应图 10 中标注为叉号的包络曲线。信号 1 的 接收信噪比提升至 39.7 dB,处理增益增加了 5.4 dB; 信号 2 提升至 34.5 dB,处理增益增加了 2.3 dB。对 应的频段内估计信道响应如图 12 所示。结合图 12 分 析,信道匹配后,双程传播过程中的多个脉冲路径变 为单个主脉冲路径,产生的实际增益与信道多途结 构产生的 TLR 基本相符,表明信道匹配处理有效补 偿了附加传播损失。信号对比结果表明,结合卷积网 络估计得出的海底参数,对于相同环境下其它目标 的回波信号,也有较好的适用性,从而实现对不同深 度的目标回波的信道匹配处理。



图 10 测试信号脉冲压缩与信道匹配输出((a) 信号 1; (b) 信号 2)



图 11 各深度信道匹配输出 ((a) 信号 1; (b) 信号 2)



图 12 测试信号估计信道响应 ((a) 信号 1; (b) 信号 2)

仿真信号的测试结果证明了基于卷积网络的信 道匹配算法的有效性,该算法可以在不确知海底环 境参数的条件下,有效估算信道传递函数,进行信 道匹配处理,抑制信道多途的影响,从而提升检测 信噪比。

### 3.2 实验数据

实验数据来自 2018 年 4 月在南海浅海海域进行 的有源探测实验。此次实验中使用船载拖曳声源和拖 曳阵构成收发合置的有源探测声呐,以"实验 1 号" 船的水下船体作为探测目标,"实验 2 号"船作为收 发合置平台,分别在 2 海里与 4 海里的相对距离下 进行了探测试验。实验中,拖曳声源深度约 45 m,发 射信号为双曲调频信号,频带为 400~500 Hz;探测 目标为实验船体的水下潜体,双体船平均吃水深度 为 6 m,近似为两个长轴约 57 m,短轴约 6 m 的旋转 椭球体,因此目标几何中心平均深度为 3 m;拖曳阵 平均接收深度为 11 m。实验环境平均海深 100 m,声 速剖面由 CTD 测得,呈现如图 1 所示的负梯度。实 验中没有对海底沉积层进行测量,因此没有获得确 知的海底环境参数。

在实验中,信号接收端为光纤拖曳阵,长度为

256 m, 阵元数为 256。由于实验条件限制, 实际接收 信噪比较低, 因此接收回波信号需要在经过常规波 束形成、滤波消除直达波影响后, 再进行预处理, 以 下使用 4 段有效实验信号。首先使用卷积网络对实 验数据进行分类和预测, 得到 4 段信号对应的估计 环境参数, 估计结果如表 4 所示。

表 4	实验测试数据估计结果

信号	1	2	3	4
GPS 距离 (m)	4241	4130	7819	7825
吸收系数 $(dB/\lambda)$	0.431	0.427	0.415	0.433
海底密度 (g/cm <sup>3</sup> )	1.758	1.747	1.749	1.738
海底声速 (m/s)	1627	1622	1622	1617

从表中可以看出,实验信号海底密度的估计值均 在 1.75 g/cm<sup>3</sup> 左右,吸收系数的估计值在 0.43 dB/λ 左右。对比海底底质分类参考值<sup>[15]</sup>,可以得出实验 海区的海底沉积层接近粉砂或砂质粉砂海底,与实 验海域底质类型预期相符。

使用卷积网络估计结果计算信道传递函数,深 度搜索后得出各实验信号对应的估计信道响应,对 实验数据进行信道匹配处理并分析处理前后的检测 信噪比,其4个实验站位的输出如图13所示。通过 最佳信噪比增益确定估计深度后,将4个实验站位 对应深度的信道响应归一化,逐个偏移绘于同一图 中,如图14所示。实验信号估计目标深度均在3m 到4m之间,与预期相符,信道匹配处理前后的信 噪比信息如表5所示,结合图14分析,不难看出, 接收信号信道多途结构越明显,其理论TLR越高, 信道匹配对接收信号的信噪比提升越大,信道匹配 增益与 TLR 理论预测基本相符。

以4海里段的信号4为例,其常规脉冲压缩与 信道匹配结果如图15所示,对应目标深度为4m。 常规脉冲压缩后的接收信噪比为23.3 dB,经过信道 匹配处理后,信噪比提升到27.6 dB,信道匹配增益 4.3 dB。对比分析表明,信道匹配增益的实验结果与



图 13 实验信号各深度信道匹配输出



TLR 的理论值基本一致,结合卷积网络的信道匹配 处理在不确知海底环境条件下有效补偿了多途传播 损失,抑制了多途效应的影响,从而提高了信号的检 测信噪比。与文献1中的信道匹配方法相比,该方法 不需要高信噪比的实验参考信号,因此对脉间相关 性也没有要求,可以处理强时变、强噪声干扰下的接 收信号,提高了信道匹配处理对环境的宽容性,对有 源探测具有重要意义。

表5 实验	金数据信道	匹配信噪	比对比
-------	-------	------	-----

信号	1	2	3	4
估计目标深度 (m)	3	3	4	4
信道匹配前信噪比 (dB)	21.0	20.0	26.5	23.3
信道匹配后信噪比 (dB)	24.6	23.1	30.4	27.6
信道匹配增益 (dB)	3.6	3.1	3.9	4.3
数值预测 TLR (dB)	4.8	4.3	5.4	5.2



图 15 实验信号信道匹配输出

# 4 结论

本文提出了一种结合分步监督式学习卷积神经 网络的信道匹配算法。该算法首先通过估计海洋环 境的海底参数信息,对接收信号进行分类,再对每个 密度区间的信号分别采用独立的卷积网络模型进行 海底参数估计,并结合深度搜索估计出目标深度及 其信道传递函数。分步训练的卷积神经网络克服了 环境参数之间的耦合关系对海底参数估计的影响, 有效提高了复杂海洋环境下的参数估计准确率,实 现了水声信道估计的实时处理。仿真与实验结果表 明,通过引入机器学习方法,可以在不确知海底环境 的条件下,较为准确的估计信道传递函数,从而进行 有效的信道匹配处理。相比传统信道匹配方法,结合 卷积网络的信道匹配方法可以应对未知海底环境参 数,提高了匹配处理的环境宽容性,对有源探测具有 重要意义。

本算法在设计和应用中仍然存在一些不足,在 网络训练过程中,通过将声速剖面和海深等海洋环

境参数限制为确定值,使得训练数据与实验的测试 数据相对匹配。但在实际应用中可能出现跨季节、 跨水域等训练与测试不匹配的情况,从而严重降低 估计性能,需要针对海洋环境条件改变训练参数。 如何提升算法的适用性和稳健性将是下一步研究的 重点。

### 参考文献

- 1 宫在晓,张仁和,李秀林,吴立新. 浅海脉冲声传播及信道匹配 实验研究. 声学学报, 2005; **30**(2): 108—114
- 2 徐俊华,陈庚.时变信道相干部分的修正匹配.声学学报,1982;
   7(6):18—29
- 3 陈庚. 海洋声信道自适应匹配实验研究. 声学学报, 1996; 21(2):
   139—148
- 4 张仁和,张双荣,肖金泉,孙庚辰,王孟新. 浅海远程声场的空间相关性与时间稳定性. 声学学报, 1981; **6**(1): 11—21
- 5 江鹏飞,林建恒,马力,殷宝友,蒋国健. 一种海洋环境噪声分 步反演地声参数方法. 声学学报, 2016; **41**(1): 59—66
- 6 李风华,张仁和.由脉冲波形与传播损失反演海底声速与衰减系数.声学学报,2000;25(4):297—302
- 7 Wu S L, Li Z L, Qin J X. Geoacoustic inversion for bottom parameters in the deep-water area of the south China sea. *Chinese Phys. Lett.*, 2015; **32**(12): 124301

- 8 Li Z, Zhang R, Yan J et al. Geoacoustic inversion by matched-field processing combined with vertical reflection coefficients and vertical correlation. *IEEE J. Oceanic Eng.*, 2004; **29**(4): 973—979
- 9 李梦竹,李整林,李倩倩.南海北部负跃层环境下海底参数声学
   反演.声学学报,2019;44(3):321—328
- 10 李倩倩,李整林,张仁和.不确知海洋环境下的贝叶斯声源定位
  法.声学学报,2014; **39**(5): 535—543
- 11 Niu H, Reeves E, Gerstoft P. Source localization in an ocean waveguide using supervised machine learning. J. Acoust. Soc. Am., 2017; 142(3): 1176
- 12 Huang Z, Xu J, Gong Z et al. Source localization using deep neural networks in a shallow water environment. J. Acoust. Soc. Am., 2018; 143(5): 2922—2932
- Niu H, Gong Z, Ozanich E et al. Deep-learning source localization using multi-frequency magnitude-only data. J. Acoust. Soc. Am., 2019; 146(1): 211
- 14 Liu Y N, Niu H Q, Li Z L. Source ranging using ensemble convolutional networks in the direct zone of deep water. *Chinese Phys. Lett.*, 2019; **36**(4): 044302

- Hamilton, Edwin L. Geoacoustic modeling of the sea floor.
   J. Acoust. Soc. Am., 1980; 68(5): 1313-1340
- 16 Biot, M. A. Generalized theory of acoustic propagation in porous dissipative media. J. Acoust. Soc. Am., 1962; 34(9A): 1254
- Stoll R D. Marine sediment acoustics. J. Acoust. Soc. Am., 1985; 74(5): 1789—1799
- 18 Van Komen D F, Neilsen T B, Howarth K et al. Seabed and range estimation of impulsive time series using a convolutional neural network. J. Acoust. Soc. Am., 2020; 147(5): EL403—EL408
- Frederick C, Villar S, Michalopoulou Z H. Seabed classification using physics-based modeling and machine learning. J. Acoust. Soc. Am., 2020; 148(2): 859-872
- 20 Abadi M, Barham P, Chen J et al. TensorFlow: A system for large-scale machine learning. 2016
- 21 顾怡鸣,李整林,宫在晓,余炎欣,张仁和,李风华.浅海负跃 层条件下的双基地有源探测实验及定位声速修正.声学学报, 2019;44(4):429—441