基于卷积神经网络的高频地波雷达有效波高反演

于彩彩[1], 楚晓亮[1*], 王曙曜[2]

（1. 中国海洋大学 物理与光电工程学院，山东 青岛 266100；
2. 中国船舶集团有限公司第七二四研究所，江苏 南京 211106）

摘　要：高频地波雷达海面回波多普勒谱中蕴含着非常丰富的海浪信息，针对经验模型通常存在对回波谱信息利用不充分的问题，本文提出了一种利用卷积神经网络反演波高的方法。首先基于雷达后向散射截面方程和有效波高反演的参数化经验模型，并结合实测数据分析，本文选取了二阶与一阶谱能量比值、二阶谱能量和、二阶与一阶谱峰值比、Bragg 频率处无向波高谱值、二阶谱能量、二阶谱峰值、左右一阶谱峰值及其比值、$1/\sqrt{2}$布拉格频率处峰值、一阶谱能量共 11 种与有效波高相关的回波谱特征参数；为进一步说明一阶和二阶信息对有效波高的作用，将 11 种特征参数分成 4 个组合，分别搭建了多层深度卷积神经网络并进行高频地波雷达有效波高反演；然后将高、低两种海况下多层深度卷积神经网络模型与经验模型反演结果进行对比分析。研究结果表明，利用 11 种特征参数构建的模型波高反演精度更高，在高、低海况测试集中雷达反演有效波高与浮标波高序列相关系数 R 分别为 0.92 和 0.78，均方根误差（Root Mean Square Error, RMSE）分别为 0.32 m 和 0.21 m，平均绝对误差（Mean Absolute Error, MAE）分别为 0.25 m 和 0.16 m，平均相对误差（Mean Relative Error, MRE）分别为 0.12 和 0.27。综合利用这 11 种特征参数，能够提高雷达在复杂海况下对有效波高的反演精度。

关键词：高频地波雷达；有效波高；卷积神经网络；反演

中图分类号：TN95　　**文献标志码：**A　　**文章编号：**1671-6647（2024）01-0126-11

doi: 10.12362/j.issn.1671-6647.20221027001

引用格式： 于彩彩, 楚晓亮, 王曙曜, 2024. 基于卷积神经网络的高频地波雷达有效波高反演[J]. 海洋科学进展, 42(1): 126-136. YU C C, CHU X L, WANG S Y, 2024. Significant wave height inversion of high frequency surface wave radar based on convolutional neural network[J]. Advances in Marine Science, 42(1): 126-136.

高频地波雷达（High Frequency Surface Wave Radar, HFSWR）工作于高频频段（3～30 MHz），以垂直极化方式发射电磁波，可对海上目标实现超视距探测，亦可对海态信息进行大范围、高精度和全天候的实时监测（孙芳等, 2018）。高频地波雷达在海态探测方面的应用研究最早可以追溯到 20 世纪 50 年代。1955 年，Crombie（1955）注意到海面回波谱中存在着 2 个关于零频对称的波峰，并且其随着雷达工作频率的不同而变化，促使 Crombie 开始研究海面上的电波散射机制。随后，Wait（1966）深入研究了布拉格散射原理，发现在单个正弦波列条件下，海洋回波谱中布拉格峰的强度与海浪的高低起伏密切相关。20 世纪 70 年代初期，Barrick（1972a, 1972b）从理论上推导出了高频电磁波与海面相互作用的雷达一阶和二阶散射截面方程，为从雷达多普勒回波谱中提取海流流速、有效波高和波周期等海洋动力学要素奠定了理论基础。在此基础上，Barrick 等（1977a, 1977b, 1977c）进一步提出了适用于高频地波雷达有效波高反演的经验公式模型，该模型利用了二阶谱能量信息具有简单易用

收稿日期：2022-10-27
资助项目：国家重点基础研究发展计划项目（2017YFC1405202）
作者简介：于彩彩（1997—），女，硕士，主要从事遥感探测方面研究. E-mail: yucaicai@stu.ouc.edu.cn
***通信作者：**楚晓亮（1977—），男，副教授，博士，硕士生导师，主要从事 X 波段导航雷达、高频地波雷达等遥测手段的海态探测技术及其相关应用方面研究. E-mail: xlchu@ouc.edu.cn

（王　燕　编辑）

且在高海况下反演结果较好的优点，被广泛应用于 HFSWR 波高反演研究中（Gurgel et al, 1999; 魏国妹等, 2016）。但在低海况下，由于二阶谱信噪比较低，使用该模型反演的波高与现场测量值会出现较大偏差。针对此问题，Zhou 等（2015）提出了利用一阶谱信息反演波高的方法，以提高低海况下波高反演的精度，这为 HFSWR 有效波高反演提供了新的思路，但该方法在反演高海况的波高时会出现饱和现象。为此，Tian 等（2020）基于经验模型提出了在低海况下选用一阶谱信息、在高海况下选用二阶谱信息进行波高反演的方法，提高了波高的反演精度。由此可知，高频地波雷达的一阶和二阶回波谱中都含有丰富的有效波高信息，都可为波高反演做出贡献。考虑到经验公式反演波高时可利用的海浪特征信息有限，不能够同时使用多种特征信息。因此，需要发展一种能够充分有效地利用雷达回波谱信息反演波高的方法，以弥补经验模型的不足，提高波高反演精度。

近年来，随着机器学习的发展，许多学者将其应用于高频地波雷达海态反演中，以提高海态参数的反演精度（Mathew et al, 2012; Zeng, 2016; 蔡佳佳等, 2019）。张晓愉等（2019）提出了基于集成在线顺序极限学习机（EOS-ELM）反演有效波高的方法，该方法使用了回波谱中的一、二阶谱峰值以及二阶与一阶能量比三种雷达回波特征参数作为输入，基于雷达数据和浮标数据建立了 EOS-ELM 有效波高反演网络模型，显著提高了波高的反演精度。此后，文必洋等（2021）利用一、二阶谱峰值以及二阶与一阶峰值的比值三种雷达回波谱特征参数作为网络输入，建立了 BP 神经网络波高反演模型，与经验模型相比，反演精度得到了提高。虽然利用回波谱强度较强一侧的一阶谱峰值、二阶谱峰值、二阶谱与一阶谱峰值比或能量比三种参数可以得到较好的波高反演结果，但从雷达回波谱中还可获得其他与波高相关的特征信息，亦可作为机器学习的输入参数，这样可以达到尽可能地充分利用回波谱信息，提高反演精度的目的。另外，建立多层的深度学习网络可以应对复杂海况下多参数的拟合，提高波高整体的反演精度。卷积神经网络凭借其权重共享和稀疏连接等特点在构建非线性复杂关系模型中具有一定优势，可以满足多特征信息充分利用的需求。

为充分利用雷达回波谱信息，本文选取了二阶与一阶谱能量比值（ERSB）、左右二阶谱能量总和（SES）、二阶与一阶谱峰值比（RSB）、Bragg 频率处无向波高谱值（BS）、二阶谱能量（SE）、二阶谱峰值（SP）（Zhou et al, 2014）、左右一阶谱峰值及其比值（BP_L、BP_R、RB）、$1/\sqrt{2}$布拉格频率处峰值（BP/R2）（Zhou et al, 2018）、一阶谱能量（BE）雷达回波特征参数作为网络模型的输入，利用现场浮标提供的波高数据作为输出，构建和训练多层卷积神经网络地波雷达有效波高反演模型，以提高波高反演精度。

1　高频地波雷达回波谱中与波浪相关的主要特征参数

经验公式法是较常用的高频地波雷达有效波高反演的方法，该类方法形式简洁，易于工程应用。主要的 HFSWR 反演有效波高的经验公式介绍如下。

1.1　二阶谱与一阶谱能量比（ERSB）

Barrick（1977a）基于高频地波雷达一阶和二阶散射截面方程，推导出均方根波高h_*与海面回波多普勒谱的二阶谱与一阶谱能量的关系，关系式为：

$$k_0{}^2 h_*{}^2 = \frac{2\int_{-\infty}^{\infty}[\sigma_{(2)}(\omega_\mathrm{d})/w(\omega_\mathrm{d}/\omega_\mathrm{B})]\mathrm{d}\omega_\mathrm{d}}{\int_{-\infty}^{\infty}\sigma_{(1)}(\omega_\mathrm{d})\mathrm{d}\omega_\mathrm{d}}, \tag{1}$$

式中：k_0为雷达电波波数；$\sigma_{(1)}$和$\sigma_{(2)}$分别为一阶和二阶散射截面；ω_B为布拉格散射频率；ω_d为多普勒频率；w为无量纲的权重函数。此经验模型还可写成：

$$h_* = \frac{\sqrt{2}}{k_0} R_{\mathrm{w}}^{1/2}, \tag{2}$$

$$R_{\mathrm{w}} = \frac{\int_{-\infty}^{\infty} [\sigma_{(2)}(\omega_{\mathrm{d}})/w(\omega_{\mathrm{d}}/\omega_{\mathrm{B}})]\mathrm{d}\omega_{\mathrm{d}}}{\int_{-\infty}^{\infty} \sigma_{(1)}(\omega_{\mathrm{d}})\mathrm{d}\omega_{\mathrm{d}}}, \tag{3}$$

式中R_{w}是海面回波谱的二阶谱能量与一阶谱能量的加权比值。Maresca 等（1980）通过大量的实验发现，对于大部分多普勒谱，二阶谱与一阶谱能量之间的无权重比值 R 同h_*之间的关系为：

$$h_* = \frac{a}{k_0} R^{\mathrm{b}}, \tag{4}$$

式中 a 和 b 为待定的拟合系数，可通过与实测数据进行拟合和分析确定。由于h_*与有效波高H_{S}之间为线性关系，所以式（4）可改写为有效波高的表达式，即

$$H_{\mathrm{S}} = \frac{a}{k_0} R^{\mathrm{b}}。 \tag{5}$$

基于上式，利用现场数据标定参数 a、b 后即可进行雷达有效波高反演，该公式模型简单有效、应用较广，本文也利用该模型进行了波高反演，以进行比较分析。

1.2 二阶谱能量总和（SES）

基于 Barrick 提出的海面雷达回波散射理论，Wyatt 等（1996）通过对大量实测数据和理论仿真数据的拟合和分析，建立了有效波高与二阶谱能量相关的反演模型，即：

$$H_{\mathrm{S}} = \frac{\beta_1}{k_0} \left(\frac{\sqrt{\sum_{\mathrm{L}} \sigma_{(2)}} + \sqrt{\sum_{\mathrm{R}} \sigma_{(2)}}}{2} \right)^{\alpha_1}, \tag{6}$$

式中：$\sqrt{\sum_{\mathrm{L}} \sigma_{(2)}}$和$\sqrt{\sum_{\mathrm{R}} \sigma_{(2)}}$分别代表较强一侧的一阶 Bragg 峰左、右两侧的二阶谱总能量；α_1和β_1是根据雷达工作频率和海况设定的系数。式（6）在实际应用过程中取得了较好的反演效果，被广泛应用于多种雷达系统（Wyatt et al, 2000, 2007）。

1.3 二阶与一阶谱峰值比（RSB）

Tian 等（2019）提出了二阶谱峰值与一阶谱峰值之比反演有效波高的半经验公式：

$$H_{\mathrm{S}}(r,\theta) = f\left[\frac{P_{\mathrm{S}}(r,\theta)}{P_{\mathrm{B}}(r,\theta)} \cdot \frac{1}{g(\theta-\psi)} \right], \tag{7}$$

式中：$f[\cdot]$ 是一种近似线性模型；r 和θ分别为距离项和方位项；P_{B}和P_{S}分别为一阶谱与二阶谱峰值功率；$g(\theta-\psi)$为校准$P_{\mathrm{S}}/P_{\mathrm{B}}$对波方向传播依赖性的方向函数；$\psi$为波传播方向。

1.4 Bragg 频率处无向波高谱值（BS）

在利用雷达回波谱进行波高反演过程中，一般只使用左右一阶回波谱中强度大的一侧数据进行分析。但在左右一阶谱强度相等情况下，若只使用一侧谱信息会产生较差的反演结果。为解决这一问题，李晓东（2020）提出了一个非线性模型，即采用 Bragg 频率处无向波高谱值反演有效波高：

$$H_{\mathrm{S}} = \lg\left(\frac{Q_{\mathrm{B}}^{\alpha}}{k_0^{\beta}} \right), \tag{8}$$

$$Q_{\mathrm{B}} = \Lambda S(\omega_{\mathrm{B}}) = \left(\sqrt[s]{B^+} + \sqrt[s]{B^-} \right)^s, \tag{9}$$

式中：α和β为拟合参数；$S(\omega_{\mathrm{B}})$为 Bragg 频率处无向波高谱值；B^+、B^-分别为海洋回波频谱中左右一阶布拉格峰强度；Λ为常系数；s 的值通常在 1～4，大多数情况下 s=2，式（9）可表示为：

$$Q_{\mathrm{B}} = B^+ + B^- + 2\sqrt{B^+ B^-}。 \tag{10}$$

由于Λ通常未知，因此，将Q_{B}作为 Bragg 频率处无向波高谱值，用于有效波高的反演计算。

2　卷积神经网络波高反演模型

卷积神经网络（Convolutional Neural Networks, CNN）是一类包含卷积计算并且含有深层次结构的深度前馈神经网络，是深度学习的代表算法之一。卷积层表达式如下：

$$f(x)=\sum_{i,j}^{n}\left(\theta_{i,j}\,x_{i,j}\right)+b, \tag{11}$$

式中：$f(x)$为输出特征；$\theta_{i,j}$为第 i 行第 j 列的卷积核元素大小；$x_{i,j}$为第 i 行第 j 列元素大小；b 为偏差。由卷积层中输出特征面的每个神经元与其输入进入局部连接，并通过对应的连接权值与局部输入进行加权求和再加上偏置值，得到该神经元输入值。

Keras 是用 Python 编写的开源人工神经网络库，采用其库内的功能函数可自行搭建卷积神经网络，设置相对灵活。比如：采用卷积层与池化层交替设置，可根据实际情况增减卷积层；可根据输入维度和输入数据量大小调节卷积层参数及网络结构深度；等等。网络模型搭建可分为下面 3 个主要步骤。

1）卷积层参数的设置。卷积核（convolution kernel）大小、步长（stride）和边界填充值（pad）三者共同决定了卷积层输出特征图的尺寸大小。网络层数太多，模型复杂，会导致过拟合现象；而网络层数过少，拟合效果则欠佳。因此在实际操作中需要根据研究的对象和实际的数据选择合适的网络层数、卷积核大小及步长。同时，综合考虑边缘信息、神经网络输入维度以及网络深度，有选择地在卷积层使用边界填充操作使网络达到最优。

2）训练过程轮次（epoch）及批次大小（batch size）的设置。在批次尺寸较大时，确定的下降方向越准，在模型训练时引起的损失函数震荡越小，但其达到相同精度时所需的轮次就越多，进而增加模型训练的时间；当批次尺寸较小时，少量的迭代次数便可达到较好的结果，但在模型训练中也会出现损失函数的震荡，非常难收敛，从而导致欠拟合。因此，轮次及批次大小的设置也比较重要。

3）随机失活层（dropout）的添加及自适应矩估计优化函数（Adam）的选用。灵活添加随机失活层，可以抑制训练过程中的过拟合现象。

本文按上述步骤进行了参数调节和模型搭建，最终形成的神经网络结构如图 1 所示。

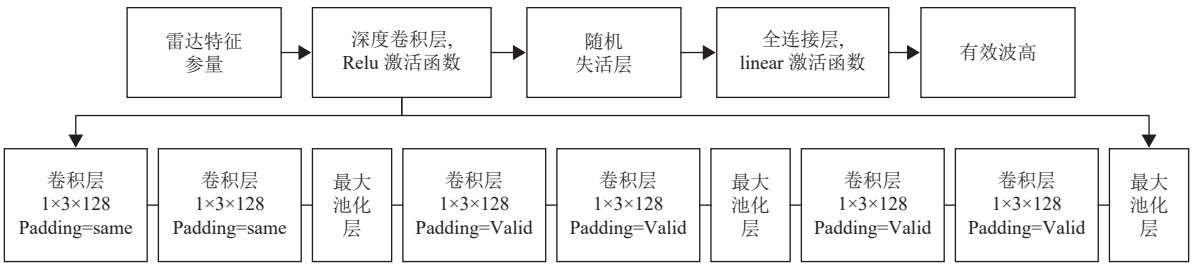

注：Relu 激活函数为非线性激活函数；linear 激活函数为线性激活函数；Padding 为边界填充值，其中 same 为对图像进行填充使卷积前后图像尺寸相同，Valid 为不进行填充操作。

图 1　卷积神经网络结构简图

Fig. 1　Schematic diagram of convolutional neural network structure

3　有效波高反演

3.1　数据分析

本文采用的雷达数据由中船重工鹏力（南京）大气海洋系统有限公司分别部署在黄海和东海海域的岸基高频地波雷达系统获得。比测数据由布放在雷达探测区域的浮标提供，浮标位置距雷达站分

别为 52 km 和 69 km。雷达系统的工作频率分别为 9.15 MHz 和 7.815 MHz，均采用线性调频波形，带宽为 30 kHz，距离分辨率为 5 km，通道数为 8。雷达探测范围和浮标位置示意图如图 2 所示。

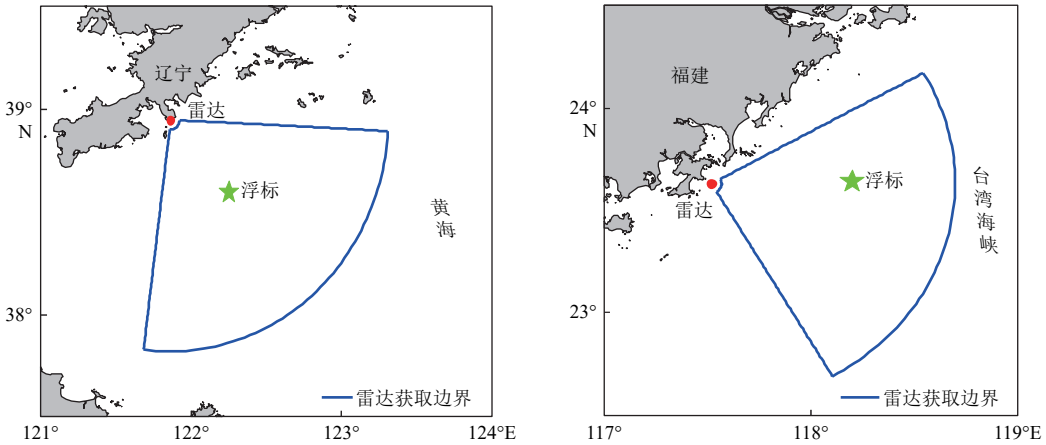

(a) 大连站 (b) 福建站

图 2 雷达探测范围和浮标位置

Fig. 2 Radar acquisition range and buoy position

所用大连站雷达数据的时间范围为 2017 年 1 月至 9 月，浮标波高范围为 0.1～2.1 m，其中波高超过 1 m 的数据约占总数据的 10%，整体海况偏低。在特征参数提取过程中，二阶谱提取的信噪比阈值设置为 2 dB，当小于此阈值时，则认为无有效的二阶谱信息。通过数据处理发现，仅有 3 336 组数据能够提取到二阶谱参数，其中波高小于 1 m 的数据约占 78%。虽然经过一定的数据质量控制，但在这些数据中依然包含了低海况下的误判数据。为了便于对不同的输入特征参数进行比较分析，本文仅选用能够提取到二阶谱参数的数据进行分析计算。所用福建站雷达数据的时间范围为 2013 年 10 月至 12 月，浮标波高范围为 0.56～4.48 m，经过数据提取处理，可用于计算的数据共 8 746 组，其中波高小于 1 m 的数据约占总数据的 3%。福建站和大连站的雷达数据分别代表了高、低两种海况的情况，能够说明不同特征参数在这 2 种海况下的有效波高反演精度。

分析大连站和福建站布放雷达的回波特征参数与浮标波高的线性相关系数可知，所采用的特征参数都与有效波高存在或强或弱的相关性（表 1、表 2）。大连站数据的一阶谱特征参数与波高的相关程度整体上要高于二阶谱，其中，BE、BS 和 BP_R 与浮标波高线性相关系数可分别达到 0.50、

表 1 雷达一阶谱特征参数与浮标波高相关程度

Table 1 The correlation degree between radar first-order spectral characteristic parameters and buoy wave height

雷达站点	BP_L 与 H_S	BP_R 与 H_S	BP / R2 与 H_S	RB 与 H_S	BE 与 H_S	BS 与 H_S
大连站	r=0.21, p<0.05	r=0.39, p<0.05	r=0.11, p<0.05	r=0.27, p<0.05	r=0.50, p<0.05	r=0.42, p<0.05
福建站	r=−0.20, p<0.05	r=0.01, p>0.05	r=0.10, p<0.05	r=0.12, p<0.05	r=−0.05, p<0.05	r=−0.12, p<0.05

注：r 为线性相关系数；p 为显著性检验水平，p<0.05 表示二者呈显著相关。

表 2 雷达二阶谱特征参数与浮标波高相关程度

Table 2 The correlation degree between radar second-order spectral characteristic parameters and buoy wave height

雷达站点	SP 与 H_S	SES 与 H_S	RSB 与 H_S	SE 与 H_S	ERSB 与 H_S
大连站	r=0.34, p<0.05	r=0.16, p<0.05	r=−0.27, p<0.05	r=0.36, p<0.05	r=−0.28, p<0.05
福建站	r=0.38, p<0.05	r=0.18, p<0.05	r=0.66, p<0.05	r=0.40, p<0.05	r=0.78, p<0.05

注：r 为线性相关系数；p 为显著性检验水平，p<0.05 表示二者呈显著相关。

0.42 和 0.39，这都高于二阶谱特征参数中最高值 SE(0.36)；而福建站的所有二阶谱特征参数与浮标波高的相关系数都高于一阶谱的，其中 ERSB 的相关系数甚至达到了 0.78。这充分说明，在低海况下，由于二阶谱的信噪比较低，一阶谱特征参数更能反映波高信息；而在高海况下，由于一阶谱可能出现饱和的情况，不能准确反映波高变化，因此二阶谱特征参数用于反演波高更有优势。

3.2　有效波高反演结果分析

为进一步分析不同特征参数对反演波高精度的影响。本文将特征参数分成 4 种组合作为输入信息，通过建立不同的深度学习卷积神经网络进行波高反演。其中一阶谱峰值、二阶谱峰值以及二者比值三种参数作为第一组合(文必洋等, 2021)，一阶谱特征参数为第二组合，二阶谱特征参数为第三组合，一阶谱和二阶谱特征参数合为第四组合。同时，本文也使用了 Barrick 经验模型反演波高，并与各组反演结果的精度进行比较。反演精度评价指标包括相关系数(R)、均方根误差(Root Mean Square Error, RMSE)、平均绝对误差(Mean Absolute Error, MAE)、平均相对误差(Mean Relative Error, MRE)。数据集采用留出法(张利军, 2012)，按照 8∶2 的比例随机划分。其中大连站与福建站训练集数据分别为 2 669 组和 6 997 组，测试集数据分别为 667 组和 1 749 组。由于训练集与测试集波高同分布，且测试集可以对模型进行检验和评估，因此使用测试集数据即可对波高反演影响因素以及反演精度进行分析。利用训练的网络进行反演得到大连海域和福建海域的有效波高精度结果分别如表 3 和表 4 所示。

表 3　大连站数据不同特征参数卷积神经网络的有效波高反演结果

Table 3　The significant wave height inversion results of convolutional neural network with different characteristic parameters of Dalian Station data

输入特征参数	训练集				测试集			
	R	RMSE/m	MAE/m	MRE	R	RMSE/m	MAE/m	MRE
第一组合	0.70	0.25	0.19	0.29	0.68	0.25	0.19	0.31
第二组合	0.71	0.23	0.18	0.29	0.71	0.23	0.18	0.29
第三组合	0.70	0.25	0.19	0.29	0.67	0.26	0.20	0.32
第四组合	0.80	0.21	0.15	0.26	0.78	0.21	0.16	0.27
经验法	0.30	0.34	0.25	0.37	0.28	0.35	0.26	0.39

表 4　福建站数据不同特征参数卷积神经网络的有效波高反演结果

Table 4　The significant wave height inversion results of convolutional neural network with different characteristic parameters of Fujian Station data

输入特征参数	训练集				测试集			
	R	RMSE/m	MAE/m	MRE	R	RMSE/m	MAE/m	MRE
第一组合	0.83	0.44	0.34	0.17	0.82	0.44	0.34	0.17
第二组合	0.42	0.71	0.58	0.29	0.42	0.71	0.58	0.29
第三组合	0.84	0.43	0.33	0.16	0.83	0.43	0.34	0.16
第四组合	0.92	0.30	0.23	0.11	0.92	0.32	0.25	0.12
经验法	0.78	0.49	0.39	0.19	0.79	0.48	0.38	0.19

由表 3 可知，第四组合结果最好，而经验模型的结果最差。由于大连站数据整体海况较低，二阶谱的信噪比较低，故 Barrick 经验模型的反演结果最差。另外，经验模型反演精度受限于雷达工

作频率，当波高在$0.14\lambda_0/\pi$～λ_0/π范围内时反演精度较高（Barrick, 1977a; 李晓东, 2020），按照大连站雷达的工作频率计算，反演精度较高的波高范围应为 1.46～10.40 m。对于大连站数据来说，其大多数波高达不到 1.46 m 的下限，故经验模型的反演结果较差。第一至第三组合的测试集误差相差较小，其中第一组合虽然同时采用了一种一阶特征参数和 2 种二阶特征参数，但是所选用的参数与波高的相关性并不是最高的，故其对波高反演精度提高不显著。

由表 4 可知，在福建海域高海况下，第四组合的结果最好，而第二组合（一阶谱组合）的反演结果最差。一阶谱组合结果差的原因主要是波高整体较高，一阶谱容易达到饱和，不能反映波高的变化，与波高的相关性也较差，导致反演精度较低。经验模型与第一、第三组合的结果相差不大，其中相对较好的为第三组合。这主要是由于经验模型所采用的二阶谱参数虽然相关性较高，但参数单一，也可能与未采用深度网络学习有关，使得结果没有显著提高；而第一组合中仅包含了 2 种二阶谱信息，并且一阶谱信息提供的贡献较少；第三组合包含了所提供的所有二阶谱信息，总体贡献相对较大一些，使得反演精度稍有优势。

综合表 3 与表 4 的结果可以发现，无论是高海况还是低海况，利用第四组合（一、二阶谱所有特征参数）获得的有效波高精度都是所有组合中最高的，并且优势明显。其在大连站测试集得到的相关系数比其他组合提高了 0.07～0.50；对于福建站数据，相关系数提高了 0.09～0.50。这说明一阶和二阶谱的综合利用能够提高波高反演的精度。本文选用的 11 种特征参数能够涵盖目前雷达回波谱中可用于海态反演的有效信息，同时借助于多层卷积神经网络能够构建非线性的复杂关系模型的优势，进一步提高了复杂海况下波高反演的精度。

为了便于分析波高反演结果，分别给出了大连站和福建站数据的第一和第四组合的有效波高反演结果与浮标波高的比较图和散点图，如图 3 至图 6 所示。比较图 3a 和图 4a、图 5a 和图 6a 可以明显看出，相较第四组合，第一组合特征参数的结果与浮标符合的程度较差，在高波高和低波高部分尤为明显，主要表现为对于浮标高波高的情况，反演的波高“上不去”，而对于浮标波高低的情况，反演的波高却“下不来”。比较图 3b 和图 4b、图 5b 和图 6b 发现，第四组合较第一组合的反演结果更集中，也更靠近 $y=x$ 线。

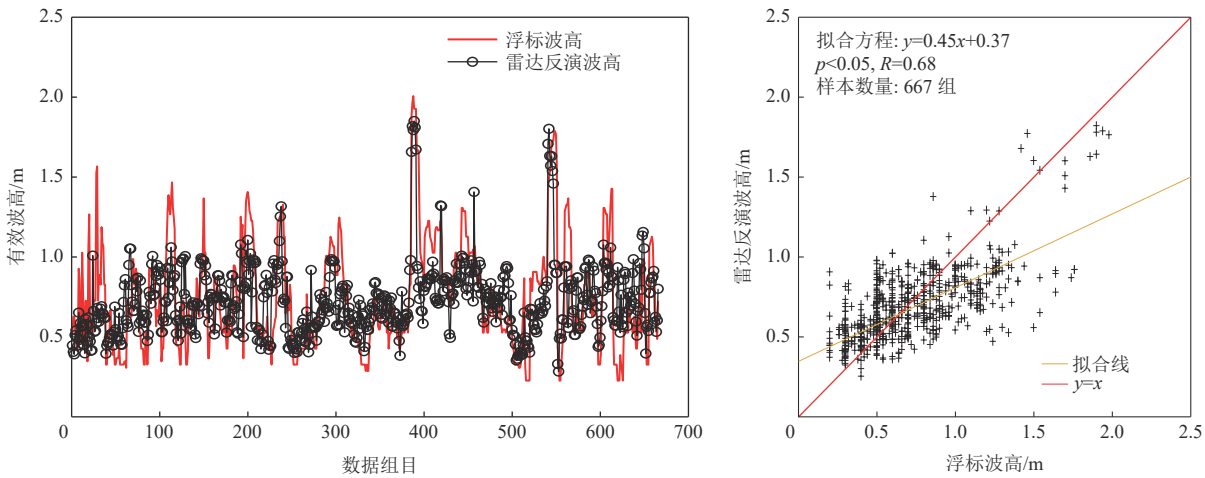

(a) 浮标波高与反演波高的对比　　(b) 浮标波高与反演波高的关系

图 3　大连站数据第一组合特征参数反演有效波高

Fig. 3　SWH Results of the first combination characteristic parameters of Dalian Station data

为验证本文所搭建模型的可靠性，将数据按 8∶2 进行多次训练集和测试集的随机划分，即采用不同的训练集和测试集数据组合对模型进行训练和测试。本文将第四组合参数训练得到的网络模型进行了 30 次重复试验。30 次重复过程中大连站与福建站测试集的均方根误差分别为 0.21～0.23 m 和 0.31～0.36 m，相关系数分别为 0.76～0.80 和 0.89～0.92，平均绝对误差分别为 0.14～0.18 m 和 0.24～0.28 m，平均相对误差分别为 0.25～0.30 和 0.11～0.14。通过模型在不同测试集上的结果可以看出，本文所搭建的卷积神经网络模型在多次训练时 4 项衡量指标浮动范围总体较小，综合相关系数和误差的变化整体上并不影响对模型反演精度的评价，说明该模型比较可靠。

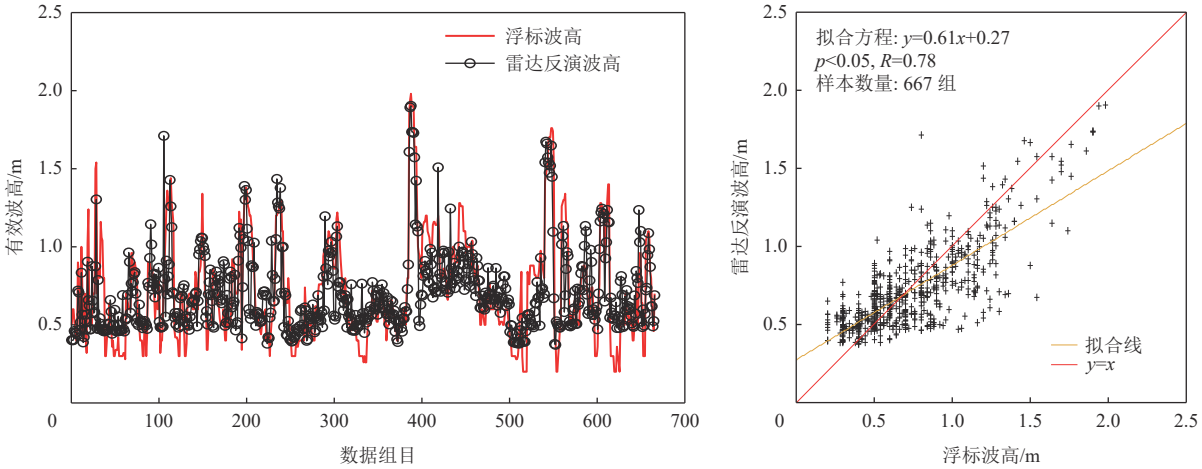

(a) 浮标波高与反演波高的对比　　(b) 浮标波高与反演波高的关系

图 4　大连站数据第四组合特征参数反演有效波高

Fig. 4　SWH Diagram of the fourth combination characteristic parameters of Dalian Station data

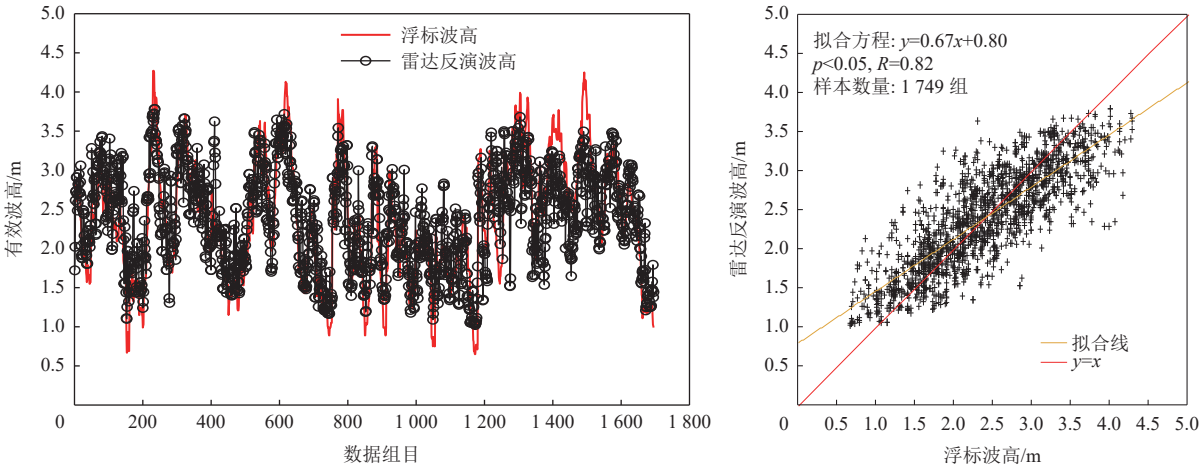

(a) 浮标波高与反演波高的对比　　(b) 浮标波高与反演波高的关系

图 5　福建站数据第一组合特征参数反演有效波高

Fig. 5　Results of inversion of SWH of the first combination characteristic parameters of Fujian Station data

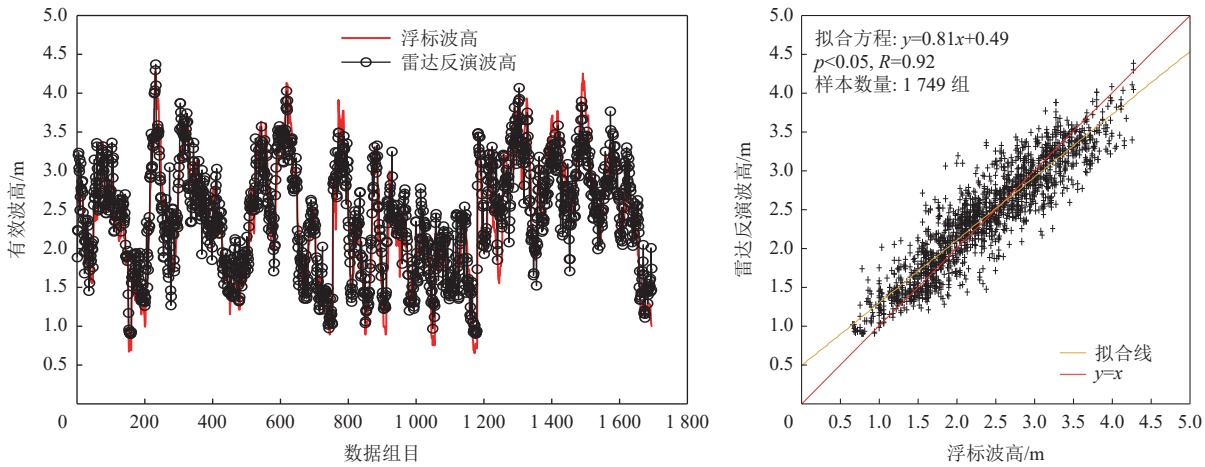

(a) 浮标波高与反演波高的对比 (b) 浮标波高与反演波高的关系

图 6 福建站数据第四组合特征参数反演有效波高

Fig. 6 Diagram of SWH inversion of the fourth combination characteristic parameters of Fujian Station data

4 结 语

针对传统经验模型无法充分利用回波谱信息等问题，本文提出了一种基于卷积神经网络的有效波高反演方法，建立了一阶谱和二阶谱中多个特征参数与有效波高之间的映射关系，有效提高了波高的反演精度。本文首先在经验模型的基础上选取了 11 种与有效波高相关的高频地波雷达回波谱特征参数，并基于整体海况高低特征明显的实测数据分析了这些参数波高的相关性。其次，将特征参数分成了 4 个组合作为输入参数集，利用 Keras 深度学习库分别搭建了多层深度卷积神经网络进行高频地波雷达有效波高反演，并与经验模型进行对比分析。结果表明，对于低海况的数据经验模型的反演精度最低，而对于高海况的数据一阶谱特征参数作为输入集的网络反演精度最低；常用的一阶谱峰值、二阶谱峰值、二阶谱与一阶谱峰值比三种参数组合的网络反演精度相对于其他组合并没有显著优势，而无论是低海况数据还是高海况数据，11 种参数统一组合作为输入集的网络反演结果都是最好的。因而充分利用雷达回波多普勒谱一、二阶谱信息，能够提升高频地波雷达有效波高反演的精度。最后，对模型进行了 30 次重复实验，由测试集性能指标可知，本文搭建的网络模型具有鲁棒性与稳定性。本文工作可以为后续卷积神经网络在高频地波雷达海态反演方面提供一定的帮助。

参考文献 (References):

蔡佳佳, 曾玉明, 周浩, 等, 2019. 基于人工神经网络的高频雷达风速反演[J]. 海洋学报, 41(11): 150-155. CAI J J, ZENG Y M, ZHOU H, et al, 2019. Wind speed inversion of high frequency radar based on artifical neural network[J]. Haiyang Xuebao, 41(11): 150-155.

李晓东, 2020. HFSWR远程多海况下海洋表面动力学要素提取及预测方法研究[D]. 哈尔滨: 哈尔滨工业大学. LI X D, 2020. Extraction and prediction of ocean surface dynamics elements using a HFSWR under multiple sea states in remote sea areas[D]. Harbin: Harbin Institute of Technology.

孙芳, 刘玉红, 李佳讯, 2018. 高频地波雷达的发展与应用现状分析[J]. 海洋测绘, 38(4): 22-24, 30. SUN F, LIU Y H, LI J X, 2018. Review of developments and applications status of high-frequency radar[J]. Hydrographic Surveying and

Charting, 38(4): 22-24, 30.

魏国妹, 商少平, 刘轲, 等, 2016. 便携式高频地波雷达海流探测长周期工作性能试验[J]. 应用海洋学学报, 35(3): 433-441. WEI G M, SHANG S P, LIU K, et al, 2016. Capability evaluation for long-term detection of surface current by portable HFSWR[J]. Journal of Applied Oceanography, 35(3): 433-441.

文必洋, 汤文成, 田应伟, 2021. 基于BP神经网络的高频雷达有效浪高场反演[J]. 华中科技大学学报(自然科学版), 49(4): 114-119. WEN B Y, TANG W C, TIAN Y W, 2021. Significant wave height field inversion of high frequency radar based on BP neural network[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 49(4): 114-119.

张利军, 2012. 大规模机器学习理论研究与应用[D]. 杭州: 浙江大学. ZHANG L J, 2012. Research and application of large-scale machine learning theory[D]. Hangzhou: Zhejiang University.

张晓愉, 楚晓亮, 王曙曜, 2019. 基于EOS-ELM的高频地波雷达有效波高反演[J]. 中国海洋大学学报(自然科学版), 49(增1): 163-169. ZHANG X Y, CHU X L, WANG S Y, 2019. Significant wave height using the HFSWR system based on EOS-ELM[J]. Periodical of Ocean University of China (Natrual Science Edition), 49(Suppl.1): 163-169.

BARRICK D E, 1972a. First-order theory and analysis of MF/HF/VHF scatter from the sea[J]. IEEE Transactions on Antennas and Propagation, 20(1): 2-10.

BARRICK D E, 1972b. Remote sensing of sea state by radar[C]//Engineering in the Ocean Environment, Ocean 72-IEEE International Conference on. IEEE, Newport, RI, USA.

BARRICK D E, 1977a. Extraction of wave parameters from measured HF radar sea-echo Doppler spectra[J]. Radio Science, 12(3): 415-424.

BARRICK D E, 1977b. The ocean waveheight nondirectional spectrum from inversion of the HF sea-echo Doppler spectrum[J]. Remote Sensing of Environment, 6(3): 201-227.

BARRICK D E, SNIDER J, 1977c. The statistics of HF sea-echo Doppler spectra[J]. IEEE Journal of Oceanic Engineering, 2(1): 19-28.

CROMBIE D D, 1955. Doppler spectrum of sea echo at 13.56 Mc./s[J]. Nature, 175(4459): 681-682.

GURGEL K W, ANTONISCHKI G, ESSEN H H, et al, 1999. Wellen Radar (WERA): a new ground-wave HF radar for ocean remote sensing[J]. Coastal Engineering, 37(3/4): 219-234.

MARESCA J W, GEEORGES T M, 1980. Measuring RMS wave height and the scalar ocean wave spectrum with HF sky-wave radar[J]. Journal of Geophysical Research: Oceans, 85(C5): 2759-2771.

MATHEW T E, DEO M C, 2012. Inverse estimation of wind from the waves measured by high-frequency radar[J]. International Journal of Remote Sensing, 33(10): 2985-3003.

TIAN Z, TIAN Y W, WEN B Y, et al, 2019. Wave-height mapping from second-order harmonic peaks of wide-beam HF radar backscatter spectra[J]. IEEE Transactions on Geoscience and Remote Sensing, 58(2): 925-937.

TIAN Y W, TIAN Z, ZHAO J R, et al, 2020. Hybrid wave height estimation from first- and second-order Doppler spectral peaks of compact high frequency radar[C]//Conference on Global Oceans: Singapore-U.S. Gulf Coast. Biloxi, MS, USA.

WAIT J R, 1966. Theory of HF ground wave backscatter from sea waves[J]. Journal of Geophysical Research: Oceans, 71(20): 4839-4842.

WYATT L R, LEDGARD L J, 1996. OSCR wave measurements some preliminary results[J]. IEEE Journal of Oceanic Engineering, 21(1): 64-76.

WYATT L R, 2000. Limits to the inversion of HF radar backscatter for ocean wave measurement[J]. Journal of Atmospheric and Oceanic Technology, 17(12): 1651-1666.

WYATT L R, GREEN J J, MIDDLEDITCH A, et al, 2007. Operational wave, current, and wind measurements with the Pisces HF radar[J]. IEEE Journal of Oceanic Engineering, 31(4): 819-834.

ZENG Y M, ZHOU H, ROARTY H, et al, 2016. Wind speed inversion in high frequency radar based on neural network[J]. International Journal of Antennas and Propagation, (3): 2706521.1-2706521.8.

ZHOU H, WEN B Y, 2014. Observations of the second-harmonic peaks from the sea surface with high-frequency radars[J]. IEEE Geoscience and Remote Sensing Letters, 11(10): 1682-1686.

ZHOU H, WEN B Y, 2015. Wave height extraction from the first-order Bragg peaks in high-frequency radars[J]. IEEE Geoscience and Remote Sensing Letters, 12(11): 2296-2300.

ZHOU H, WEN B Y, 2018. Wave height estimation using the singular peaks in the sea echoes of high frequency radar[J]. Acta Oceanologica Sinica, 37(1): 108-114.

Significant Wave Height Inversion of High Frequency Surface Wave Radar Based on Convolutional Neural Network

YU Caicai[1], CHU Xiaoliang[1], WANG Shuyao[2]

（1. *College of Physics and Optoelectronic Engineering*, *Ocean University of China*, Qingdao 266100, China；
2. *The 724th Research Institute of China Shipbuilding Group Corporation*, Nanjing 211106, China）

Abstract: The Doppler spectrum of sea surface echo from High Frequency Surface Wave Radar (HFSWR) contains very rich wave information. In order to solve the problem of inadequate use of echo spectrum information in empirical models, a method of wave height inversion using convolutional neural network is proposed in this paper. In this paper, based on the radar backscattering cross section equation and the parametric empirical model of Significant Wave Height (SWH) inversion, combined with the analysis of measured data, 11 kinds of echo spectral characteristic parameters related to SHW are selected, including the ratio of second-order to first-order spectral energy, the sum of second-order spectral energy, the ratio of second-order to first-order peak power, the undirected peak power at the Bragg frequency, the second-order spectral energy, the second-order peak power, the left and right first-order peak power and their ratios, the peak power at the $1/\sqrt{2}$ Bragg frequency, and the first-order spectral energy. Secondly, in order to further explain the role of first and second order information on SWH, the 11 characteristic parameters are divided into 4 combinations, and multi-layer deep convolutional neural networks are built to retrieve the SWH. Then, the inversion results of the multi-layer deep convolutional neural network model and the empirical model are compared and analyzed in high and low sea states. The results show that the inversion accuracy of SWH based on 11 characteristic parameters is higher. In the high and low sea state test sets, the correlation coefficients (R) of SWH retrieved by radar and by buoy are 0.92 and 0.78, respectively, and the Root Mean Square Error (RMSE) is 0.32 m and 0.21 m, respectively. The Mean Absolute Error (MAE) is 0.25 m and 0.16 m, and the Mean Relative Error (MRE) is 0.12 and 0.27, respectively. The comprehensive use of these 11 characteristic parameters can improve the inversion accuracy of significant wave height under complex sea conditions.

Keywords: High Frequency Surface Wave Radar (HFSWR)；significant wave height；convolution neural network；inversion

Received: October 27, 2022