



# 计算机科学

COMPUTER SCIENCE

## 基于改进CNN-BP的多波束声纳高程数据预测研究

熊豪杰, 魏怡

引用本文

熊豪杰, 魏怡. 基于改进CNN-BP的多波束声纳高程数据预测研究[J]. 计算机科学, 2023, 50(6A): 220100161-4.

XIONG Haojie, WEI Yi. Study on Multibeam Sonar Elevation Data Prediction Based on Improved CNN-BP [J]. Computer Science, 2023, 50(6A): 220100161-4.

---

### 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

**Similar articles recommended (Please use Firefox or IE to view the article)**

#### [基于图像数据耦合识别的输电线路安全风险评估方法](#)

Image Recognition Method of Transmission Line Safety Risk Assessment Based on Multidimensional Data Coupling

计算机科学, 2023, 50(6A): 220500032-6. <https://doi.org/10.11896/jsjcx.220500032>

#### [基于多模态特征融合的时间序列异常检测](#)

Anomaly Detection of Time-series Based on Multi-modal Feature Fusion

计算机科学, 2023, 50(6A): 220700094-7. <https://doi.org/10.11896/jsjcx.220700094>

#### [注意力特征融合的孪生网络目标跟踪方法](#)

Attentional Feature Fusion Approach for Siamese Network Based Object Tracking

计算机科学, 2023, 50(6A): 220300237-9. <https://doi.org/10.11896/jsjcx.220300237>

#### [基于改进的ResNeXt网络结构的遥感图像分类](#)

Remote Sensing Image Classification Based on Improved ResNeXt Network Structure

计算机科学, 2023, 50(6A): 220100158-6. <https://doi.org/10.11896/jsjcx.220100158>

#### [基于数据融合的半监督高分遥感影像语义分割](#)

Semi-supervised Semantic Segmentation for High-resolution Remote Sensing Images Based on Data Fusion

计算机科学, 2023, 50(6A): 220500001-6. <https://doi.org/10.11896/jsjcx.220500001>

# 基于改进 CNN-BP 的多波束声纳高程数据预测研究

熊豪杰 魏怡

武汉理工大学自动化学院 武汉 430000

(xionghaojiephil@163.com)

**摘要** 为了建立精准的多波束声纳高程数据预测模型,解决人工鱼礁空方量预测准确性的问题,提出了一种基于改进卷积神经网络(Convolutional Neural Network,CNN)和 BP 神经网络组合模型的多波束声纳高程数据预测方法。首先,利用改进 CNN 对高程数据进行全卷积操作提取地形趋势特征,再输入到 BP 中进一步挖掘内部地形趋势变化规律,从而实现多波束声纳高程数据的预测。然后以某海底牧场的高程数据进行实验,并利用人工鱼礁的空方量进行交叉验证。最后,与传统克里金、BP、GA-BP、PSO-BP 模型进行比较。结果表明:改进 CNN-BP 模型在多波束声纳高程数据和人工鱼礁空方量上的预测结果表现最优,验证了该方法的可行性、可靠性和精度高。

**关键词:** 多波束声纳高程数据;人工鱼礁;卷积神经网络;BP 神经网络

中图分类号 TP399

## Study on Multibeam Sonar Elevation Data Prediction Based on Improved CNN-BP

XIONG Haojie and WEI Yi

School of Automation,Wuhan University of Technology,Wuhan 430000,China

**Abstract** In order to establish an accurate multibeam sonar elevation data prediction model and solve the problem of the accuracy of air-squared prediction of artificial reefs,a multibeam sonar elevation data prediction method based on a combined model of improved convolutional neural network(CNN) and BP neural network is proposed. First,the improved CNN is used to extract topographic trend features by full convolutional operation of the elevation data,and then input to BP to further explore the internal topographic trend change pattern,so as to achieve the prediction of multibeam sonar elevation data. Experiments are conducted with multibeam sonar elevation data from a submarine ranch and cross-validated using the null square volume of artificial reefs. Finally,it is compared with the traditional kriging,BP,GA-BP,and PSO-BP models. The results show that the improved CNN-BP model performs the best prediction results on multibeam sonar elevation data and artificial reef air-square volume,which verifies the feasibility,reliability and high accuracy of the proposed method.

**Keywords** Multibeam sonar elevation data,Artificial reef,Convolutional neural network,BP neural network

## 1 引言

随着全球海洋渔业资源出现明显的衰退现象,为促进海洋渔业可持续发展、维护国家生态安全、维护渔区社会稳定和提高水产品质量,建设海洋牧场成为海洋渔业的根本出路<sup>[1-2]</sup>。人工鱼礁的建造和投放,是当前我国海洋牧场建设的主要工作之一<sup>[3]</sup>。针对人工鱼礁的监测与管理,人工鱼礁的现有空方量是一个重要的评价标准。由于多波束声纳高程数据仅包含人工鱼礁表面的高程信息,并未包含人工鱼礁的底面高程信息,故人工鱼礁的现有空方量难以计算。针对这一问题,本文提出了一种基于人工鱼礁周围海底地形趋势的预测方法。

近年来,凭借对复杂数据的优异特征提取能力,卷积神经网络(Convolutional Neural networks,CNN)和 BP 网络被广泛应用于数据预测、数据分类等方面。CNN 可以从复杂数据

中自动提取数据的多维度空间特征,但不能高效地处理空间数据;而 BP 在处理空间数据时性能表现优异,但无法获取空间数据的特征。将两者结合可以增强空间、位置的特征提取能力并相对减少时间消耗,更适用于多维度空间数据的分析和处理。Wu 等<sup>[4]</sup>提出了一种基于 Attention 机制、卷积神经网络(CNN)和 BP 神经网络的 CNN-Attention-BP 组合预测模型用于降水发生预测研究,预测准确率最高可达 88.4%。Dong 等<sup>[5]</sup>提出了一种基于卷积神经网络和长短期记忆神经网络(Long Short-term Memory,LSTM)组合模型的 NO<sub>x</sub> 排放预测模型,并通过与 PCA-BP,PCA-RNN 和 PCA-LSTM 模型进行比较,验证了该方法的可行性。

而本文的预测思路和方式与上述文献有如下不同之处:1)针对人工鱼礁底面的高程数据进行预测,预测数据是空间连续的;2)根据人工鱼礁周围的海底地形趋势预测中心空白区域,训练数据与预测数据不相关,而训练数据之间构成的

基金项目:国家自然科学基金(51177114);湖北省技术创新重大专项(2019AAA016)

This work was supported by the National Natural Science Foundation of China(51177114) and Major Special Project for Technological Innovation in Hubei Province(2019AAA016).

通信作者:魏怡(shilrey\_yi\_wei@126.com)

地形趋势与预测数据相关;3)本文用于训练和预测的数据量巨大,一般大小的人工鱼礁训练数据有4000多组,预测数据有1000多组。

综上所述,为了提高多波束声纳高程数据的预测精度,本文提出了一种基于改进CNN-BP模型的多波束声纳高程数据预测方法。该方法将某海域人工鱼礁周围的多波束声纳高程数据按滑动窗口构造连续的特征图作为输入,通过CNN挖掘特征图中的潜在关系,然后作为BP的输入特征,最终实现多波束声纳高程数据预测。

## 2 改进CNN-BP网络模型构建

### 2.1 改进CNN神经网络

CNN被广泛应用于图像识别、模式分类、物体检测、人脸识别、数据预测等方面<sup>[6]</sup>。CNN是一种前馈神经网络,由输入层、卷积层、池化层、全连接层和输出层构成。由于CNN在计算时采用了卷积运算,其运算速度相比于一般的矩阵运算有了很大的提高。CNN的卷积层和池化层的交替使用能够有效地提取数据的局部特征并降低局部特征维度<sup>[7]</sup>;通过权值共享方式,可以减少权值数量、降低模型的复杂度,同时也减少了过拟合的现象。

传统CNN的卷积核仅可以提取数据的变化规律,无法将变化规律中的随机性变化和规律性变化分离,如均值卷积核、高斯卷积核。为适应多波束声纳高程数据的地形趋势规律,提取地形趋势的规律性变化,本文对CNN神经网络的卷积核进行参数调整。根据中国古代杨辉数表的分布规律<sup>[8]</sup>,建立了如图1所示的卷积神经网络结构。利用改进的卷积核对多波束声纳高程数据进行全卷积操作,把地形趋势的随机性变化和规律性变化分离出来,将高程数据的规律性变化用于BP神经网络的训练。




图1 改进的卷积过程

Fig. 1 Improved convolution process

### 2.2 BP神经网络

BP神经网络,即反向传播神经网络,属于多层前馈型神经网络,包含输入层、隐含层和输出层,各层之间的神经元采用全连接的方式,每一层中的神经元互不相连。BP神经网络采用输入信号正向传递和输出误差反向传播的监督式学习规则,是目前各种人工神经网络模型中运用最为广泛的一种,具有较为成熟的理论体系<sup>[9]</sup>。输入信号在网络中的正向传递会产生网络的实际输出,通过比较实际输出与输入信号的期望输出,得到网络的误差,将得到的误差从输出层传入网络,采用梯度下降法对网络各层的权值和阈值进行修正,当样本的输出误差收敛于设定误差时,结束训练过程,得到网络模型。

若单隐层前馈型神经网络连续,且传递函数为sigmoid,则网络可以逼近任何一个复杂的连续映射<sup>[10]</sup>。因此,本预测模型采用单隐层网络结构。网络输入层包含2个节点,输出层包含1个节点,隐含层根据经验公式<sup>[11]</sup>确定节点数为5。经验公式为:

$$k = \sqrt{n+m} + a \quad (1)$$

其中, $k$ 为隐含层节点数; $n$ 为输入层节点数; $m$ 为输出层节点数; $a$ 为1~10之间的可调常数。故3层BP神经网络结构如图2所示。




图2 BP神经网络的拓扑结构

Fig. 2 Topological structure of BP neural network

### 2.3 CNN-BP模型构建

本文将改进CNN和BP模型集成并改进后应用到多波束声纳高程数据预测中,充分发挥CNN模型的空间特征提取能力和BP模型的位置特征提取能力。以CNN-BP模型基本结构为基础,在单个BP层基础上再添加一个BP层,提取深层次位置特征;在CNN中加入BN层,用来规范数据分布,增强模型泛化能力和鲁棒性;最后,在每个BP层后加入Dropout层来随机屏蔽部分神经元输出,防止模型过拟合。改进CNN-BP模型网络结构如图3所示。




图3 改进CNN-BP模型示意图

Fig. 3 Improved CNN-BP model diagram

改进CNN-BP网络中,CNN部分主要负责提取位置序列的特征,BP网络部分主要负责预测,主要步骤为:1)将输入特征参数组成矩阵,并按规则分割为训练集与预测集,然后重构为网络所需要的维度的矩阵输入CNN-BP网络;2)以卷积形式提取参数间的潜在关系作为特征;3)将所得特征输入池化层,通过池化计算减少模型参数并增强特征;4)将池化层所得结果输入BP网络,各层神经元之间通过权值和阈值形成全互连接,并利用梯度下降法,不断调整权值和阈值,使得网络输出值和期望值的误差最小,通过回归层输出最终结果。改进CNN-BP网络模型可充分提取输入数据的高级特征,并利用数据的空间性特征进行多波束声纳高程数据预测。

为加快模型的收敛速度并缩短模型的学习周期,本文构建的CNN-BP网络模型采用ReLU激活函数<sup>[12]</sup>,从而有效提高模型的非线性表达能力并避免训练过程中发生过拟合。另外,本文在进行模型训练前对数据进行标准化处理,以消除原始数据的特征尺度不一致的问题,增强模型的稳定性,加快收敛速度。

## 3 实验与结果分析

由于多波束声纳无法得到人工鱼礁底面真实的高程数据,故本文采用两种不同的验证思路进行交叉验证。首先,选取与人工鱼礁周围海底有相似地形和大小海底区域,利用海底区域已知的格网数据进行不同预测方法的比较;然后

通过 Global Mapper 专业软件对人工鱼礁进行手绘边界,并导出人工鱼礁和周围海底的格网数据;最后比较不同预测方法计算的空方量和 Global Mapper 专业软件计算的空方量。

### 3.1 数据构建

本文基于不同海域的多波束声纳高程数据,建立不同地形下的地形数据集。根据人工鱼礁及周围海底的大小,选取相似规格的多波束声纳高程数据作为实验数据。在实验数据




图4 人工鱼礁数据集

Fig. 4 Artificial reef data set

### 3.2 评价指标

为了更好地评估模型的预测效果,本文采用均方误差 MSE、平均绝对误差 MAE、模型判定系数  $R^2$  这 3 个指标对预测结果进行评定。MSE, MAE,  $R^2$  分别如式(2)~式(4)所示:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

其中,  $\hat{y}_i$  为多波束格网数据中高程的预测值;  $y_i$  为高程的真实值;  $\bar{y}$  为高程的平均值;  $n$  为预测高程的总个数。

### 3.3 不同卷积核预测结果分析

为研究改进后的卷积核对 CNN-BP 模型预测能力的影响,将均值卷积核、高斯卷积核和改进后的卷积核进行预测结果的比较。选取两种不同的地形进行实验,根据评价指标,将预测结果与测试数据进行比较,结果如表 1 所列。

表 1 不同卷积核对比分析

Table 1 Comparative analysis of different convolution kernels

卷积核	平稳地形			复杂地形		
	MSE	MAE	$R^2/\%$	MSE	MAE	$R^2/\%$
均值卷积核	0.00009	0.0076	95	0.00521	0.0544	83
高斯卷积核	0.00008	0.0072	95	0.00452	0.0511	85
改进卷积核	0.00006	0.0069	96	0.00356	0.0453	90

根据表 1 可知:

(1)在平稳地形中,3 种不同的卷积核的预测结果皆表现优异,其中改进卷积核表现最佳,其相较于均值卷积核 MSE 降低了 33%,MAE 降低了 9%,决定系数  $R^2$  提升了 1%;相较于均值卷积核 MSE 降低了 25%,MAE 降低了 4%,决定系数  $R^2$  提升了 1%。

(2)在复杂地形中,改进卷积核表现优异,而均值卷积核和高斯卷积核则表现较差。改进卷积核预测结果的 MSE 和 MAE 最小,决定系数  $R^2$  最大。

(3)改进卷积核可以适应不同的地形趋势,分离地形趋势变化规律中的随机性变化和规律性变化,并将规律性变化应用到地形趋势的预测中。

中选取与人工鱼礁大小类似的中心区域作为测试数据、中心区域以外的多波束声纳高程数据作为训练数据。

同时,本文建立了不同形状和规格下的人工鱼礁数据集。选取人工鱼礁在内的周围海底的多波束声纳高程数据作为实验数据,以人工鱼礁的边界为界限,将人工鱼礁边界及以内的格网数据作为测试数据,将人工鱼礁边界以外的格网数据作为训练数据。人工鱼礁数据集如图 4 所示。

### 3.4 不同地形趋势预测结果分析

为研究改进 CNN-BP 网络模型对多波束声纳高程数据的预测能力,将传统克里金、BP、GA-BP、PSO-BP 与改进 CNN-BP 网络的预测结果进行对比分析。选取两种不同的地形进行实验,根据评价指标,将预测结果与测试数据进行比较,结果如表 2 所列。

表 2 不同预测方法对比分析

Table 2 Comparative analysis of different prediction methods

预测方法	平稳地形			复杂地形		
	MSE	MAE	$R^2/\%$	MSE	MAE	$R^2/\%$
传统克里金	0.00096	0.0255	83	0.06666	0.1845	72
BP	0.00036	0.0151	93	0.00791	0.0681	84
GA-BP	0.00029	0.0138	95	0.01363	0.0978	79
PSO-BP	0.00025	0.0129	95	0.01173	0.0794	82
改进 CNN-BP	0.00006	0.0069	96	0.00356	0.0453	90

由表 2 可知:

(1)在预测有效性方面,在平稳地形中传统克里金预测值的 MSE 为 0.00096,MAE 为 0.0255;在复杂地形中传统克里金预测值的 MSE 为 0.06666,MAE 为 0.1845,均高于 BP 神经网络的预测结果。在方法的泛化性方面,传统克里金方法在两种不同地形中,决定系数  $R^2$  分别为 0.83 和 0.72,均低于 BP 神经网络的预测结果。表明 BP 神经网络的预测结果更接近实测值,可解释性更强,拟合效果更好。

(2)改进 CNN-BP 网络的预测误差指标均低于 BP,GA-BP,PSO-BP 网络,其中,在平稳地形中,其相较于 BP 网络预测值的 MSE 和 MAE 分别降低 83%,54%,相较于 GA-BP 网络预测值的 MSE 和 MAE 分别降低 79%,50%,相较于 PSO-BP 网络预测值的 MSE 和 MAE 分别降低 76%,46%,相较于这 3 种网络的决定系数  $R^2$  分别提升 3%,1%,1%;在复杂地形中,相较于 BP 网络预测值的 MSE 和 MAE 分别降低 55%,33%,相较于 GA-BP 网络预测值的 MSE 和 MAE 分别降低 74%,54%,相较于 PSO-BP 网络预测值的 MSE 和 MAE 分别降低 70%,43%,相较于这 3 种网络的决定系数  $R^2$  分别提升 6%,11%,8%。这充分体现了改进 CNN-BP 网络的优越性与所提出改进方法的合理性。

(3)BP 网络根据 CNN 提取的空间特征进行预测的效果有一定程度的提升,验证了改进 CNN 在形成特征的同时

保证了数据在空间维度上的关系不丢失,而 BP 又可以完整地考虑空间维度中长期的规律性依赖关系,因此组合改进 CNN 和 BP 可以更全面地发挥二者的优势,实现准确的多波束声纳高程数据预测,对监测人工鱼礁空间信息和空方量有一定的参考价值。

### 3.5 人工鱼礁空方量预测结果分析

对改进 CNN-BP 网络模型进行交叉实验<sup>[13]</sup>,选取图 4 中的 12 个已知真实空方量的人工鱼礁,利用传统克里金、BP、GA-BP、PSO-BP 与 CNN-BP 网络对其底面高程数据进行预测,根据预测的高程数据使用方格网法计算人工鱼礁的空方量,结果如图 5、表 3 所示。




图 5 人工鱼礁数据集

Fig. 5 Artificial reef data set

表 3 人工鱼礁空方量的不同预测方法对比分析

Table 3 Comparative analysis of different prediction methods of artificial reef empty space

预测方法	MSE	MAE	R <sup>2</sup> /%
克里金	23.53	25.42	76
BP	6.13	7.56	84
改进 CNN-BP	2.16	2.29	91
GA-BP	5.13	5.84	86
PSO-BP	3.29	3.63	88

实验结果表明:

(1)传统克里金预测结果的 MSE 和 MAE 远大于 BP 神经网络,表明 BP 神经网络在人工鱼礁底面高程数据预测方面优于传统克里金方法。

(2)相较于 BP、GA-BP、PSO-BP 网络,改进 CNN-BP 的预测误差指标 MSE 和 MAE 最小,决定系数 R<sup>2</sup> 最大,表明 CNN-BP 的预测精度最高,拟合效果最好。

(3)改进 CNN-BP 网络可以有效地应用到人工鱼礁的监测和管理中,更好地监测人工鱼礁的空间信息和空方量,为人工鱼礁的管理提供指导意义。

**结束语** 由于多波束声纳高程数据中不包括人工鱼礁底面的高程数据,本文提出了一种基于改进 CNN-BP 的组合模型,利用人工鱼礁周围的地形趋势对底面高程数据进行预测。先采用改进 CNN 有效地学习人工鱼礁周围多波束声纳高程数据的空间特征,进而使用 BP 对整个网络进行参数调整已达到最优的预测结果。通过实验验证了改进 CNN-BP 模型在多波束声纳高程数据预测的有效性和可行性,并将其与传统克里金、BP、GA-BP 与 PSO-BP 模型进行了对比,得到的主要结论如下:

(1)改进 CNN-BP 网络的预测效果优于传统的预测方法和传统的深度学习模型,改进的 CNN 可以有效地提取出多波束声纳高程数据的空间特征,用于后续 BP 网络的准确预测。

(2)改进 CNN-BP 网络模型在多波束声纳高程数据预测

方面稳定性和准确性更好,具有较好的适应性,可以更好地应用于人工鱼礁底面高程数据的预测,以及人工鱼礁空方量的监测与管理,更好地服务于海洋牧场的建设。

### 参考文献

- [1] HE G M, ZENG J, LIANG X Y. Ranchization-the direction of modern marine fisheries[J]. Fishery Modernization, 2003(5): 4-6.
- [2] SI Y J. Legal regulation of artificial reefs[D]. Qingdao: Ocean University of China, 2012.
- [3] YANG H S, ZHANG S Y, ZHANG X M, et al. Strategic thinking on the construction of modern marine pastures in China [J]. Journal of Fisheries, 2019, 43(4): 1255-1262.
- [4] WU X H, HUA Y J, GUAN Y H, et al. Prediction of precipitation based on CNN-Attention-BP [J]. Journal of Nanjing University of Information Technology (Natural Science Edition), 2022, 14(2): 148-155.
- [5] DONG Y B, MAO D J, ZHANG M M. Research on NO<sub>x</sub> Emission Prediction of Gas Turbine Based on CNN-LSTM[J]. Thermal Energy and Power Engineering, 2021(9): 132-138.
- [6] SIEGFRIED R, INGRID M, CHRISTOPH J, et al. One-year safe use of the Prismaflex HF20 disposable set in infants in 220 renal replacement treatment sessions [J]. Intensive Care Medicine, 2011, 37(5): 884-885.
- [7] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. IEEE, 1998, 86(11): 2278-2324.
- [8] JIANG X W. The determinant in Yang Hui's triangle[J]. Bulletin of Mathematics, 1988(5): 16-17.
- [9] HI Z Z. Neural Network [M]. Beijing: Higher Education Press, 2009.
- [10] HORNIK K, STINCHCOMBE M, WHITE H. Multilayer feed-forward networks are universal approximators[J]. Neural networks, 1989, 2(5): 359-366.
- [11] CHEN M. MATLAB Neural Network Principles and Examples [M]. Beijing: Tsinghua University Press, 2013.
- [12] GONG G J, ZHANG S, WU Q X, et al. Foreign body recognition of high-voltage transmission lines based on TensorFlow[J]. Electric Power Automation Equipment, 2019, 39(4): 204-209, 216.
- [13] LI Y, SHI Z, WANG R C, et al. Co-Kriging estimation of soil profile conductivity of tidal flat soil and comparative study of different sampling numbers[J]. Acta Pedologica Sinica, 2004, 41(3): 434-443.



**XIONG Haojie**, born in 1996, master, is a member of China Computer Federation. His main research interests include neural network and data prediction.



**WEI Yi**, born in 1972, Ph.D, professor. Her main research interests include pattern recognition and machine vision.