

基于自组织神经网络的声学底质分类研究

唐秋华^{1,2,3}, 刘保华², 陈永奇³, 周兴华², 丁继胜²

(1. 中国海洋大学海洋地球科学学院 青岛 266003; 2. 国家海洋局第一海洋研究所 青岛 266061;

3. 香港理工大学土地测量及地理资讯学系 香港)

摘要: 研究利用多波束测深系统获取的反向散射强度数据, 应用自组织(Self Organizing Map, 简称 SOM)神经网络分类方法实现了对海底泥、砂、砾石和基岩等底质类型的快速、有效识别。通过实验示例, 将 SOM 神经网络的分类结果与传统海底地质取样获取的真实底质类型进行分析比较, 表明该方法是可行和有效的。

关键词: SOM 神经网络; 多波束测深系统; 声学底质分类; 反向散射强度

中图分类号: P229.2

文献标识码: A

文章编号: 1000-3630(2007)-03-0380-05

Acoustic seafloor classification using self-organizing map neural network

TANG Qiu-hua^{1,2,3}, LIU Bao-hua², CHEN Yong-qi³, ZHOU Xing-hua², DING Ji-sheng²

(1. College of Marine Geosciences, Ocean University of China, Qingdao 266003, China;

2. First Institute of Oceanography, State Oceanic Administration, Qingdao 266061, China;

3. Department of Land Surveying and Geo-Informatics, Hong Kong Polytechnic University, Hong Kong)

Abstract: Multibeam sonar systems can provide hydrographic quality depth data as well as high-resolution seafloor sonar images. Using the seafloor-backscattered data from each beam and with automatic classification, seabed sediments distribution maps can be obtained directly. In this paper, the self-organizing map (SOM) neural network is used in acoustic seafloor classification from multibeam sonar data. This method can rapidly identify all kinds of seafloor types such as mud, sand, gravel and rock in the experimental surveying areas. Compared with the traditional geologic grab method, the experiment indicates that the SOM method is feasible and valid.

Key words: SOM neural network; multibeam sonar systems; acoustic seafloor classification; backscatter strength

1 引言

海底底质类型特征对许多领域, 包括海洋地质、海洋工程、海洋环境科学、海道测量及海洋渔业等, 都是一个必不可少的信息。获得海底底质类型分布的传统方法是依靠地质表层取样和地质钻孔取样。近几十年来, 利用声学遥感手段进行海底底质分类

的方法开始受到重视, 与传统的地质取样方法相比, 声学底质分类方法具有高效、快速的特点。

多波束测深系统中, 不仅可以获得高精度的水深地形数据, 还可以同时获得高质量的海底底质反向散射强度数据。利用多波束测深系统获取的反向散射强度数据对海底底质进行分类的方法很多, 如光谱分析法^[1]、纹理分析方法^[2,3]、统计分类方法^[4,5]、神经网络方法^[6,7]以及分形、小波分解和傅里叶变换等方法。本文主要研究 SOM 神经网络分类方法。

2 研究区域及底质特征的选取

2.1 区域的选择

收稿日期: 2005-11-02; 修回日期: 2006-06-20

基金项目: 863 计划资助项目课题(2006AA09Z103); 国家自然科学基金资助项目(40606026、40506018); 香港 RGC 资助项目(B-Q734)

作者简介: 唐秋华(1973-), 男, 副研究员, 在职博士, 研究方向: 海洋 4S 技术及应用研究。

通信作者: 唐秋华, E-mail: tangqiu-hua@163.com

为了研究问题的明确性,选择“863”项目“海底底质分类的多参数识别技术”在青岛胶州湾应用挪威 Simrad EM3000 多波束测深系统进行多波束测量的部分试验数据作为研究对象(图 1 中小方框线所围区域)。

多波束测深系统采集到的反向散射强度数据量非常庞大,本文所做的研究工作都是基于微机版的 Linux 和 Windows2000 系统下,考虑数据处理系统本身的限制和研究问题的明确性,仅选择“863”试验海区的小方框内的四条多波束测线数据作为本次多波束底质分类研究的数据源。研究区域位于图 1 试验海区的正中间,经度 $120^{\circ}18'25'' \sim 120^{\circ}19'34''$,纬度 $36^{\circ}00'30'' \sim 36^{\circ}02'20''$ 范围内,长约 4860m,宽约 300m 的条带状测量区域(如图 2);其中,根据已有实测资料及现场地质取样资料分析(图 1 中圆点为取样点),研究区域的海底底质类型有砂、砾石和基岩三种类型。

2.2 特征选择及提取

多波束的反向散射强度可以理解为海底介质回波反射和散射的反应,它依赖于声波入射角、海底粗糙程度、沉积物的声学参数(如密度、声速、衰减、散射等)以及声波在水体中的传播。提取出每个波束的反向散射强度值,通过数据预处理,获得纯粹反映海底底质特征的反向散射强度值,就可以用于海底沉积物分类^[8]。EM3000 多波束测深系统的反向散射强度变化范围为 $-126\text{dB} \sim -128\text{dB}$ 。将反向散射强度同描述图像的灰度量级对应起来,形成海底声像图(图 2)。图像中的每个像素可用两组量确定,即像




图 2 研究区域海底声像图
Fig.2 Seafloor sonar images of the study area

素的位置 (i, j) 以及与之对应的灰度 $f(i, j)$, 灰度值的水平范围为 0~255 色。

海底底质统计特征量可以从少量 Pings 和有限的波束中获得,这些特征量所代表的像元可应用在区块分类中。反向散射强度平均值是指声像图中所有像元灰度值或所有波束反向散射强度的平均值,反映了影像中地物的平均散射强度。本次研究中,选取常用的反向散射强度(灰度)平均值作为输入特征量,通过独立使用这种特征量,获取了高精度海底底质类型的分类。

3 分类方法研究

分类是神经网络最活跃的一个研究和应用领域。近十多年来,神经网络已经成为复杂信号处理和分类的最重要工具。神经网络是数据驱动、非线性、非参数模型。有两类神经网络模型被用于声纳信号的海底分类,即需要真实底质取样数据训练的多层感知器(Multilayer Perceptrons, 简称 MLP)网络和不要监督学习的 SOM 神经网络^[9]。在这里主要研究基于 SOM 神经网络的底质分类方法。

3.1 分类原理

与多层感知器不同, SOM 神经网络作为一个聚类系统无需监督学习。它的网络结构只有两层,即输入层和竞争层(输出层)。竞争层上的节点间通过一定的权重连接,权重根据最小(或最大)距离准则来调整(如图 3)。

当外界输入不同的样本到 SOM 神经网络中,开始时输入样本引起输出兴奋的位置各不相同,

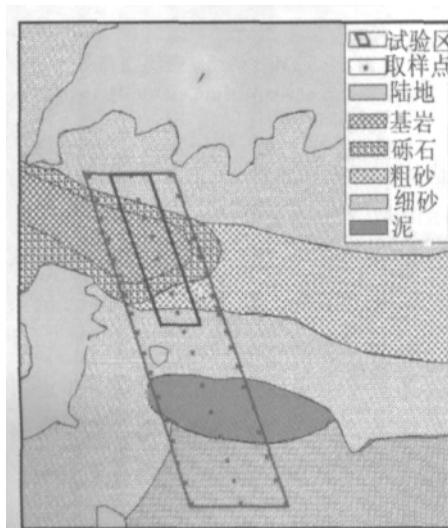


图 1 研究区域底质类型示意图

Fig.1 Schematic depiction of sediments distribution




图3 SOM神经网络

Fig.3 Schematic depiction of SOM neural network

但通过网络的竞争学习后会形成一些输出群,它们分别代表了输入样本的分布(用概率密度函数 pdf 表示),反映了输入样本的图形分布特征,所以 SOM 神经网络常常被称为特性图(Feature Map)。

SOM 神经网络使输入样本通过竞争学习后,功能相同的输入靠得比较近,功能不同的则分得比较开,以此将一些无规则的输入自动排开,在连接权的调整过程中,使得权的分布与输入样本的概率密度分布相似。SOM 神经网络的权向量收敛到所代表的输入向量的平均值,它反映了输入数据的统计特性,能够表现出输入向量在线上或平面上的分布特征,海底底质自动分类识别正是根据这一特性进行的。

3.2 分类过程

美国 MathWorks 公司开发的 MATLAB 软件,在需要大量数据运算的科学研究和工程应用中具有很大的优越性,它的强大功能在于它的开放式可扩展环境以及诸多的面向不同应用领域的工具箱。在本次研究中,利用其中的图像处理工具箱和神经网络工具箱,编写相应的程序,实现了 SOM 神经网络分类识别(如图 4)。

3.2.1 网络结构的选择

多波束反向散射强度值的不同,反映了不同的底质类型特征,根据问题的需要,决定采用一维 SOM 神经网络结构进行分类研究。

选取 1416 组处理过的反向散射强度平均值作为训练样本输入数据,网络的输入向量为 $P=(P_1, P_2, \dots, P_{1416})$ 。竞争层的神经元数 S 代表输入向量可能被划为的种类数,其值若选得过多,则会出现有些向量无法被分类的不良结果;但若被选得太大,竞争后可能有许多节点都被空闲,而且在网络竞争过程中还占有了大量的设计量和时间,在一定程度上造

当地加以确定。根据已有的现场地质取样数据资料(图 1),将输入数据划分为 3 类,分别为砂、砾石和基岩,选取竞争层的神经元数 $S=3$ 。

另外还要事先确定的数有:学习速率 $lr(0 < lr < 1)$ 和最大循环数 max_epoch ,选取学习速率为 $lr=0.02$, $max_epoch=15\ 000, 30\ 000$ 。

3.2.2 网络初始化

将输入样本向量数据 P 进行归一化处理,数据值归算到 $[0, 1]$ 之间,建立一维 SOM 神经网络,获取网络初始化权值 $\omega_{ij}(0 < \omega_{ij} < 1)$ 。

3.2.3 网络训练竞争

SOM 神经网络在训练过程中,对连接权向量 ω_{ij} 进行归一化处理,计算 ω_{ij} 与 P 之间的欧氏距离 d_j :

$$d_j = \sum_{i=1}^N (P_i - \omega_{ij})^2 \quad (1)$$

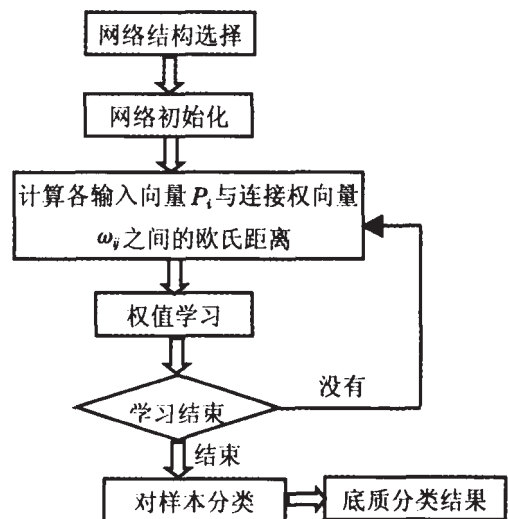


图4 SOM神经网络分类流程图

Fig.4 Process for classification of SOM neural network

找出最小距离 d_g , 确定获胜神经元 g 。

$$d_g = \min[d_j] \quad (2)$$

经过竞争求得获胜结点后,则对与获胜结点相连的权值进行调整,调整权值的目的是为了使得权值与输入向量之间的差别越来越小,从而使训练后的竞争网络的权值能够代表对应输入向量的特征,把相似的输入向量分成了同一类,并由输出指示所代表的类别。SOM 神经网络修正权值的公式为:

$$\Delta\omega_{ij} = lr(P_i - \omega_{ij}) \quad (3)$$

式中, lr 为学习速率,且 $0 < lr < 1$,一般的取值范围为 $0.01 \sim 0.3$; P_i 为经过归一化处理后的输入。

所得的结果为几个相同类型输入模式的平均值, 而当一个不同类型的模式输入, 将使网络竞争层中的其它节点获胜而得到新的权矩阵。如此重复, 直到达到最大训练循环次数 \max_epoch , 则可以将所有的不同类型的模式都聚集到不同的权矩阵下, 每个权矩阵代表一种类型。

3.2.4 网络测试及使用

网络训练好以后, 其权值就固定下来了。以后对于每一个输入值, 网络就会输出相应的分类值, 可以利用这一点来进行网络的测试。

根据已有的研究区域现场地质取样数据, 选取测试数据 702 组, 其中砂 197 组, 砾石 212 组, 基岩 293 组。通过 MATLAB 自组织神经网络仿真函数 $\text{sim}()$ 对其进行分类识别:

$$a = \text{sim}(\text{net}, P) \quad (4)$$

式中, net 为训练好的一维 SOM 神经网络, P 为测试样本数据向量, a 为分类结果。

通过网络测试, 输入的全部测试数据都有和它们相对应的底质类型, 数据被分为砂、砾石和基岩三种类型, 分类测试结果见饼状图 5、表 1 所示。图 5 中 1 代表砂, 2 代表砾石, 3 代表基岩, 百分数为相应分类精度。

当网络的循环次数增大到 30 000 次, 得到的竞争层神经元的权重向量与循环 15 000 次的相同(小数点后七位都相同), 神经元的权重值没有发生太大变化, 应用 702 组测试数据对其进行测试验证, 网络能较好的识别砂、砾石和基岩 3 种类型, 分类精度与循环 15 000 次的相同(如图 5, 表 1)。

训练、测试好的网络, 将需要分类的数据向量, 输入到网络中, 网络就可以对其分类。

3.3 分类结果及分类方法适用性验证

将需要分类的数据向量输入到网络中, 得到分类结果数据矩阵, 在 Matlab 中应用图像处理工具将数据矩阵转换为对应的栅格图像格式, 如图 6(a) 所示。图中不同的灰度分别代表表砂、砾石、基岩三种底质类型。比较图 6(a) 与图 1(图中小方框线所围区域) 的海底底质类型, 可以看出, 利用 SOM 神经网络进行海底底质类型分类识别, 能较好的区分出砂(分类精度 88%)、砾石(分类精度 71%) 和基岩(分类精度 79%) 等 3 种海底底质类型, 分类界线基本同已有实测资料吻合, 分类效果较好。

为了检验非监督分类的 SOM 神经网络方法的普遍适用性, 另外选取海南东方多波束测量区域作

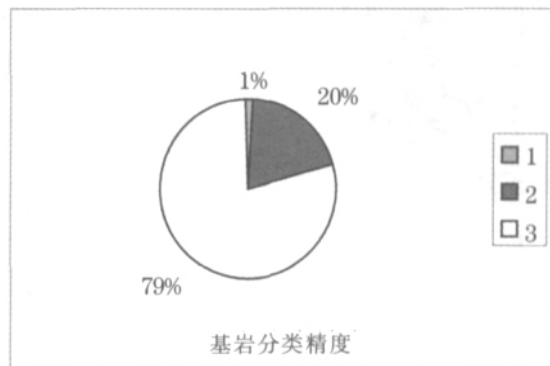




图 5 循环 15 000 次后 SOM 神经网络分类精度示意图
Fig.5 Schematic depiction of SOM neural network classification precision after 15 000 cycles

表 1 循环 15000 次后 SOM 神经网络分类测试结果
Table 1 Classification results of SOM Neural network after 15000 Cycles

循环次数	测试样本类型	测试数目(组)	测试结果(组)	分类精度	
15 000 次	砂	197	砂	173	88%
			砾石	20	
			基岩	4	
	砾石	212	砂	12	71%
			砾石	151	
			基岩	49	
	基岩	293	砂	3	79%
			砾石	59	
			基岩	231	




图 6 SOM 神经网络底质分类结果图

Fig.6 Seafloor classification results map using SOM neural network

训练样本数据 908 组, 测试样本数据 454 组) 处理过的反向散射强度平均值作底质分类研究, 应用 SOM 神经网络方法对这一区域海底底质类型进行预测, 结果显示, 该区域包含 4 种不同海底底质类型(如图 6(b) 所示); 最后, 通过与现场地质取样数据(包括泥、砂、砾石及基岩 4 种不同底质类型) 进行对比, 得到泥的分类精度 82%、砂的分类精度 85%、砾石的分类精度 74%和基岩的分类精度 81%。

通过对不同区域的多波束反向散射强度数据的分类识别验证, 可以得出非监督的 SOM 神经网络分类方法具有普遍适用性, 在底质类型未知或地质取样数据较少时, 可以用这种方法进行分类

4 小 结

研究多波束测深系统数据后处理方法, 特别是研究利用多波束反向散射强度数据进行海底底质分类识别, 是一个研究性和实用性都比较强的新课题, 可借以跟踪应用声学遥感方法和技术对海底进行遥测的热点问题。

本文利用多波束测深系统的反向散射强度数据, 应用 SOM 神经网络分类方法实现了对海底泥、砂、砾石和基岩等底质类型的快速、有效识别。通过实验示例, 将 SOM 神经网络的分类结果与传统海底地质取样获取的真实海底底质类型进行比较, 得出利用神经网络分类方法适合于底质类型未知或取样数据较少的海区, 能够较好的区分出海底泥、砂、砾石和基岩等不同底质类型。

参 考 文 献

- [1] Milvang O, Huseby R B, K. Weisteen et al. Feature Extraction from Backscatter Sonar data[A]. Proceeding of the Institute of Acoustics Conference on Acoustic Classification and Mapping of the Seabed[C]. 1993, 15(2): 157-163.
- [2] Subramaniam S, Barad H, Martinez A B. Seafloor characterization using texture[A]. Proceedings of IEEE Southeastco 93[C]. 1993, 299-317.
- [3] Pican N, Trucco E, Ross M, et al. Texture analysis for seabed classification: cooccurrence matrices vs. self-Organizing maps[A]. OCEANS 98 Conference Proceedings[C]. 1998, 1: 424-428.
- [4] Huseby R B, Milvang O, Solberg A S, et al. Seabed classification from multibeam echosounder data using statistical methods[A]. OCEANS 93 Conference Proceedings[C]. 1993, 3: 229-233.
- [5] Michalopoulou Z H, Alexandrou D, de Moustier C. Application of neural and statistical classifiers to the problem of seafloor characterization[J]. IEEE Journal of Oceanic Engineering, 1995, 20(3): 190-197.
- [6] Alexandrou D, Pantartzis D. Seafloor Classification with Neural Networks[A]. OCEANS 90 Conference Proceedings [C]. 1990, 1: 18-23.
- [7] Tom K, Mats C, Rune M. Seabed classification using artificial neural networks and other non-parametric methods [J]. Proceedings of the Institute of Acoustics, 1993, 15(2): 141-148.
- [8] 唐秋华, 陈义兰, 周兴华, 等. 多波束声纳图像形成及应用研究[J]. 海洋测绘, 2004, 24(5): 9-12. TANG Qihua, CHEN Yilan, ZHOU Xinghua, et al. Study on the producing and application of multibeam sonar image[J]. Hydrographic Surveying and Charting, 2004, 24 (5): 9-12.
- [9] Bishwajit Chakraborty, Kaustubha R, Amey Hegde, et al. Acoustic seafloor sediment classification using self-Organizing feature maps[J]. IEEE Transaction on Geoscience and Remote Sensing, 2001, 39(12): 2722-2725.