

唐秋华, 刘保华, 陈永奇等. 结合遗传算法的 LVQ 神经网络在声学底质分类中的应用. 地球物理学报, 2007, 50(1): 313~ 319
Tang Q H, Liu B H, Chen Y Q, et al. Application of LVQ neural network combined with the genetic algorithm in acoustic seafloor classification. *Chinese J. Geophys.* (in Chinese), 2007, 50(1): 313~ 319

结合遗传算法的 LVQ 神经网络 在声学底质分类中的应用

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 学习向量量化(Learning Vector Quantization, LVQ)神经网络在声学底质分类中具有广泛应用. 常用的 LVQ 神经网络存在神经元未被充分利用以及算法对初值敏感的问题, 影响底质分类精度. 本文提出采用遗传算法(Genetic Algorithms, GA)优化神经网络的初始值, 将 GA 与 LVQ 神经网络结合起来, 迅速得到最佳的神经网络初始权值向量, 实现对海底基岩、砾石、砂、细砂以及泥等底质类型的快速、准确识别. 将其应用于青岛胶州湾海区底质分类识别研究中, 通过与标准的 LVQ 神经网络的分类结果进行比较表明, 该方法在分类速度以及精度上都有了较大提高.

关键词 学习向量量化, 遗传算法, 多波束测深系统, 底质分类

文章编号 0001- 5733(2007)01- 0313- 07 中图分类号 P631 收稿日期 2005- 12- 10, 2006- 09- 29 收修定稿

Application of LVQ neural network combined with the genetic algorithm in acoustic seafloor classification

TANG Qiu_Hua^{1,2,3}, LIU Bao_Hua², CHEN Yong_Qi³, ZHOU Xing_Hua², DING Ji_Sheng²

1 Marine Geology College, Ocean University of China, Qingdao 266003, China

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

3 Department of Land Surveying and GeoInformatics, The Hong Kong Polytechnic University, Hong Kong, China

Abstract The Learning Vector Quantization (LVQ) neural network approach has been widely used in acoustic seafloor classification. However, one of the major weak points of LVQ is its sensitivity to the initialization, affecting the seafloor classification accuracy. In this paper, Genetic Algorithm (GA) is used to optimize the initial values of LVQ. The GA-based LVQ can rapidly provide the most optimized initial reference vectors and accurately identify many types of seafloor, such as rock, gravel, sand, fine sand and mud in survey areas. The proposed new approach has been applied to seafloor classification using Multibeam Echo Sounder (MBES) backscatter data in Jiaozhou Bay near Qingdao City of China. Comparing the evolving LVQ with the standard LVQ, the experiment results indicate that the approach of GA-based LVQ has improved the seafloor classification speed and accuracy.

Keywords Learning Vector Quantization (LVQ), Genetic Algorithm (GA), Multibeam echo sounder, Seafloor classification

基金项目 863 计划课题(2006AA09Z103)和香港 RGC 项目(B-Q734)资助.

作者简介 唐秋华, 男, 1973 年生, 1992 年于武汉测绘科技大学毕业, 2003 年于国家海洋局第一海洋研究所获硕士学位. 副研究员. 主要从事海洋 GIS 技术及应用研究. E-mail: tangqiuhua@fio.org.cn

© 1994-2012 China Academic Journal Electronic Publishing House. All rights reserved. <http://www.cnki.net>

1 引言

海底底质是海洋环境的重要评价指标, 底质类型的分类与识别是海洋科学考察和研究的重要内容之一。随着海洋资源开发活动的大规模开展, 以及港口、航道、海上平台、海底管线等海洋工程建设的大量进行, 迫切要求更新、更快的方法对调查区域的底质类型及分布情况有全面、系统、科学的掌握。

传统的海底底质探测, 主要依靠站点式的机械手段来获取样品, 然后通过实验室内的样品分析, 确定海底沉积物的类型及其分布特征。这种方法已经成为一种广泛使用的常规方法, 在海洋工程建设和海洋科学研究方面起了重要的作用。但是, 传统的地质取样方式在分析海底底质特性、确定底质类型上, 存在设备笨重, 工作费时、费力等不足, 在深水区域困难尤其大; 同时, 传统取样方式一般是按一定网格定点离散地取样, 通过资料的内插与外延对测区内底质类型进行划分的, 因此其代表性会受到一定影响^[1]。

20世纪70年代, 人们就开始应用声学遥感的方法进行海底底质类型的划分与识别研究^[2]。声学底质分类是通过遥测海底底质的声学特性(如反射系数、声速、衰减、散射等)来了解其物理特性(如底质类型、粒度大小等), 它具有工作高效, 获取资料连续、丰富的特点, 为海底底质类型划分提供了一种迅速而可靠的方法。多波束勘测技术是20世纪60年代以来发展起来的新一代海底地形测量技术, 应用这一高新技术不仅能大范围地了解海底地形、地貌特征, 还能直接用来遥测海底底质特征, 用于底质分类研究。利用多波束测深系统可以在不增加其他外部设备和经费的情况下, 快速、准确地获取调查区域内的底质类型分布情况, 这对于海洋科学考察、海洋工程应用等领域都具有重要意义。

利用多波束测深系统获取的反向散射强度(Backscatter Strength, BS)数据对海底底质进行分类的方法很多, 如频谱分析法^[3~5]、纹理分析法^[6, 7]、统计分类方法^[7, 8]以及神经网络方法^[9~11]等。其中, Kohonen^[12]提出的LVQ神经网络在声学底质分类中具有广泛应用^[13~17]。但是, 常用的LVQ神经网络存在神经元未被充分利用以及算法对初值敏感的问题^[18, 19], 如果初值的选择偏差太大就不会产生好的聚类效果, 影响底质分类精度。本文采用Holland^[20]提出的遗传算法优化神经网络的初始值, 将GA与

LVQ神经网络结合起来, 迅速得到最佳的神经网络初始权值向量, 实现对海底基岩、砾石、砂、细砂以及泥等底质类型的快速、准确识别。

2 底质分类原理及其数据预处理

多波束测深系统在进行水深测量的同时也记录了海底反向散射强度。反向散射强度可以理解为海底介质对声波反射和散射能力的一种反映, 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状况, 反映了海底底质类型特征^[19]。

通常, 可以根据海底反向散射强度的强弱不同划分不同的沉积物类型, 如岩石散射能力比砾石强, 砾石的散射能力又强于砂等。海底反向散射强度可表达为^[21~23]

$$BS = BS_B + 10\lg A, \quad (1)$$

式中, A 表示波束照射区面积(如图1), 它可以通过脉冲宽度 τ 、发射波束宽度 θ_T 、接收波束宽度 θ_R 以及波束的入射角 θ 求出。

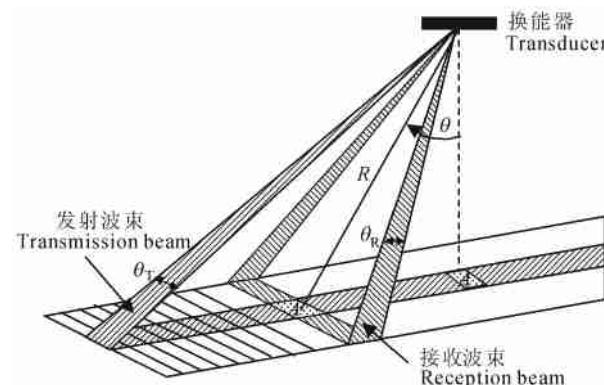


图1 多波束发射/接收波束几何结构示意图

Fig. 1 Beam geometrical configuration of multibeam echo sounder

当波束入射角位于中央波束附近($\theta = 0^\circ$)时,

$$A = \theta_T \theta_R R^2; \quad (2)$$

当波束入射角 θ 为其他值时,

$$A = \frac{1}{2\sin\theta} \theta_T \theta_R R. \quad (3)$$

BS_B 为海底的固有散射强度, 通常情况下依赖于波束的入射角 θ 。当 $\theta = 0^\circ$ 时, BS_B 近似为一常数 BS_N ; 当 $\theta \neq 0^\circ$ 时, BS_B 不但取决于波束的入射角, 还依赖于海底底质类型特征, 其变化服从Lambert定律^[20], 即

$$BS_B = BS_N \quad (\theta = 0^\circ); \quad (4)$$

$$BS_B = BS_0 + 10\lg\cos^2\theta \quad (\theta \neq 0^\circ). \quad (5)$$

根据(1)~(5)式, 可得

$$BS = BS_N + 10\lg(\theta_r R^2) \quad (\theta = 0^\circ); \quad (6)$$

$$BS = BS_0 + 10\lg\cos^2\theta \\ + 10\lg(cT\theta_r R / 2\sin\theta) \quad (\theta \neq 0^\circ). \quad (7)$$

上式中, BS_N 为声波法向入射(Normal incidence)时海底底质反向散射强度, BS_0 为声波斜入射(Oblique incidence)时海底底质反向散射强度, 它们仅仅反映

海底底质类型特征; 入射角 θ 可以根据 Snell 声线跟踪法则确定.

为了获取与入射角度无关、仅仅反映海底底质特征的 BS_N 和 BS_0 , 首先对原始反向散射强度数据经过声信号传播损失改正、声线弯曲改正、Lambert 法则改正(消除 $10\lg\cos^2\theta$ 项), 然后再经过海底地形起伏及波束照射区面积改正(消除 $10\lg A$ 项)、船底正下方中央波束区反射信号影响改正以及中值滤波处理后, 最后获取真实反映底质类型特征的反向散射强度信息(图 2), 用于海底底质分类识别研究^[24].

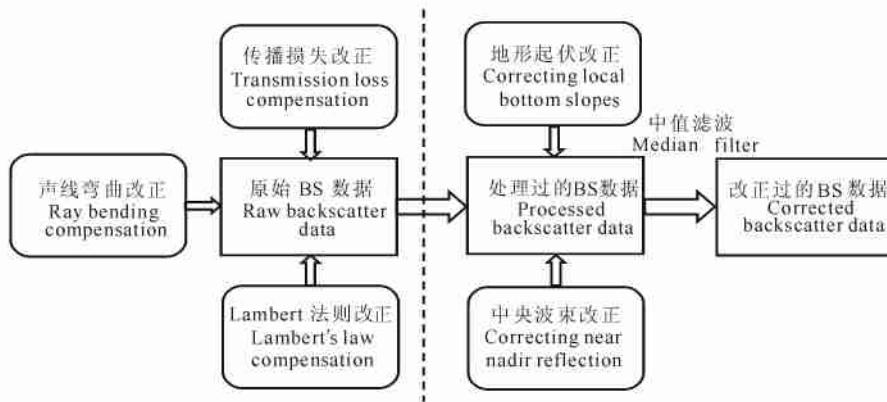


图 2 反向散射强度数据预处理流程图^[24]

Fig. 2 Process flow for backscatter data pre-processing^[24]

3 LVQ 神经网络分类方法

神经网络是数据驱动、非线性、非参数模型. 近十多年来, 神经网络已经成为复杂信号处理和分类的重要工具, 分类是神经网络最活跃的应用领域之一. 通常有两类神经网络模型用于多波束反向散射强度数据的底质分类研究, 即需要真实地质取样数据的监督学习网络^[9~11]和不需要真实地质取样数据的非监督学习网络^[13~17].

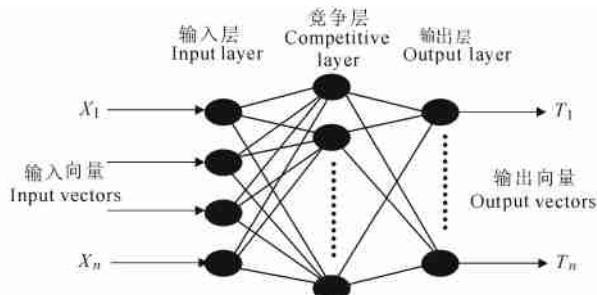


图 3 LVQ 神经网络结构示意图

Fig. 3 Schematic depiction of LVQ neural network

LVQ 神经网络属于一种结合监督学习与非监督学习的混合网络结构, 且在学习的速度上较反向传播(Back Propagation, BP) 神经网络快很多, 应用于分类的工作上, 颇为省时方便. 它由三部分组成: 输入层、竞争层(隐含层)和输出层(图 3)^[12]. 前两层实际上就是竞争网络. 一般的自组织特征映射(Self_Organizing Feature Map, SOFM) 神经网络^[12]的竞争层能够自动学习对输入向量的分类, 其分类的根据是输入向量之间的距离, 如果两个输入向量距离接近, 竞争层就把它们分为同类. 而 LVQ 是在监督状态下对竞争层进行训练的一种学习算法, 通过学习, LVQ 神经网络将输入向量中与目标向量相近的分离出来, 对其进行分类.

LVQ 神经网络基本原理和概念是比较直观的. 一群 N 维输入训练样本, 可以视为在 N 维空间的样本点, 而同一个类别的样本点可能散布成数群, 各有各自的形心; LVQ 神经网络通过样本点来估计各个群体的形心位置, 并正确地对应到所属的类别中; 训练完成后的应用阶段, 即可利用各自群体的形心位置, 做出正确的分类判断.

LVQ 神经网络的第 2 层属于非监督的竞争层,

每个神经元为一个独立的子类别。当样本点输入竞争层中，计算样本点与各子类别间的欧氏距离，寻找出最适合的子类别归属它，如下式：

$$d(\mathbf{X}, \mathbf{W}_c) = \min\{d(\mathbf{X}, \mathbf{W}_i)\}, (i = 1, 2, \dots, n), \quad (8)$$

式中， \mathbf{X} 表示输入样本向量， \mathbf{W} 表示网络初始形心位置向量， $d(\mathbf{X}, \mathbf{W}_i)$ 表示输入样本点 i 与子类别间的距离， \mathbf{W}_c 表示竞争胜出后的子类别。

将竞争层优胜者的信息传入第 3 个输出层，进行监督学习的分类。第 3 层的权值是固定值，优胜者信息传入后，即会产生学习结果的正确或错误；根据分类结果的正确与否，适当地修正竞争层的网络权值，以寻找正确形心位置。权值 \mathbf{W} 的调整方式如下：

当 $i = c$ 时，

$$\mathbf{W}_c(t+1) = \mathbf{W}_c(t) + \alpha(t)[\mathbf{X}(t) - \mathbf{W}_c(t)] \quad (9)$$

(分类结果正确)，

$$\mathbf{W}_c(t+1) = \mathbf{W}_c(t) - \alpha(t)[\mathbf{X}(t) - \mathbf{W}_c(t)] \quad (10)$$

(分类结果错误)；

当 $i \neq c$ 时，

$$\mathbf{W}_i(t+1) = \mathbf{W}_i(t), \quad (11)$$

上式中， $\alpha(t)$ 表示学习速率，数值介于 0 与 1 之间，它具有抑制网络权值趋近无限大的作用。

式(9)表示子类别形心受样本点吸引，往样本空间中的样本点移动；式(10)则表示受到样本点的排斥，远离样本点；经过数次迭代，寻找出各子类别适当的形心位置，完成分类工作。此为标准的 LVQ 神经网络分类算法。

4 结合遗传算法的 LVQ 神经网络分类方法

LVQ 神经网络具有很好的分类识别特性，能够对任意输入向量进行分类，不管它们是不是线性可分的，这一点比 BP 神经网络要优越得多；此外，LVQ 神经网络表现出比 BP 神经网络更强的容错性和鲁棒性，不易导致系统的崩溃，一般只要使用建立好的网络分类结构，输入实际所需的性能指标就能得到较为满意的识别结果。但是，常用的 LVQ 神经网络存在神经元未被充分利用以及算法对初值敏感的问题^[18, 19]，如果初值的选择偏差太大就不会产生好的聚类效果。GA 具有很强的通用优化能力，采用 GA 优化 LVQ 神经网络的初始值，可以迅速得到最佳的

网络权值向量，然后应用 LVQ 算法进行分类识别，能够有效提高分类速度和精度。

4.1 遗传算法

GA 具有很强的鲁棒性和全局优化能力，它最大的优点是在寻优过程中，只使用目标函数（适应度函数），而不采用梯度和其他的辅助信息，其寻优过程也是从解空间点集出发，直到全局最优。应用这一特性，可以给 LVQ 神经网络选择初始权值。

(1) 编码

GA 的编码就是解的遗传表示，它是应用 GA 求解问题的第一步。GA 的编码方式有很多种，我们采用格雷码（Gray Code）对个体进行编码。这种编码方式便于进行交叉、变异等遗传操作，有利于提高 GA 的局部搜索能力。

(2) 适应度函数

在 GA 中使用适应度函数来度量群体中各个个体在优化计算中能达到或接近于达到最优解的优良程度。适应度较高的个体遗传到下一代的概率就较大，而适应度较低的个体遗传到下一代的概率就相对小些。对于不同的问题，适应度函数的定义方式不同。

(3) 选择、交叉及变异操作

GA 有 3 个基本操作：选择、交叉和变异。

选择的目的是为了从当前群体中选出优良的个体，使它们有机会作为父代为下一代繁殖子孙。选择体现了达尔文的适者生存原则。

交叉操作是 GA 中最主要的遗传操作。通过交叉操作可以得到新一代个体，新个体组合了父辈个体的特性。交叉体现了信息交换的思想。

变异操作首先在群体中随机选择一个个体，对于选中的个体以一定的概率随机改变二进制编码中的值。变异为新个体的产生提供了机会。

4.2 GA_LVQ 神经网络分类方法

首先通过 GA 获得最佳的初始权值向量，然后应用 LVQ 神经网络分类方法实现对输入向量的快速、准确识别。算法步骤如下（图 4）：

(1) 网络建立

建立一个 LVQ 神经网络，选取输入向量 \mathbf{X} ，同输入向量 \mathbf{X} 相对应的输出目标向量 \mathbf{T} ，并且选定网络竞争层的神经元数目 S ，将输入样本向量数据 \mathbf{X} 进行归一化处理，数据值归算到 [0, 1] 之间。

(2) GA 参数的定义

随机产生 N 个初始串结构数据，每个串结构称为一个个体， N 个个体构成了一个群体，取遗传代

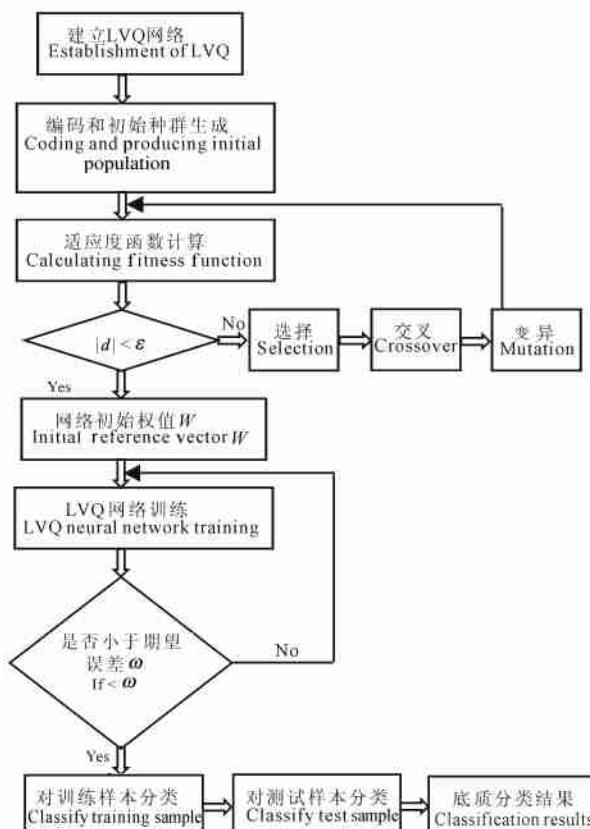


图 4 GA_LVQ 神经网络分类方法流程图

Fig. 4 Process flow for classification of
GA_LVQ neural network

数计数器 $t = 0$, 形成初始群体 $P(0)$; 确定交叉概率 P_c 、变异概率 P_m 以及误差 ϵ .

(3) 适应度函数的计算

根据随机个体到输入样本点的平均方差距离:

$$D(t) = \left[\frac{1}{M} \sum_i (X_i(t) - P_i(t))^2 \right]^{1/2}, \quad (12)$$

式中, $D(t)$ 表示平均方差距离, M 表示群体数目, $X_i(t)$ 表示输入样本向量, $P_i(t)$ 表示随机个体向量. 计算个体的适应度:

$$f(t) = \frac{1}{1 + D(t)}, \quad (13)$$

式中, $f(t)$ 在 $[0, 1]$ 之间.

计算

$$d = D(t) - D(t-1), \quad (14)$$

若 $|d| < \epsilon$, 则跳转到第 5 步.

(4) 遗传迭代

根据适应度以交叉概率 P_c 对个体进行交叉, 并以变异概率 P_m 对新个体进行变异操作. 令 $t = t+1$, 形成 t 代群体, 转到第 3 步.

(5) 获取网络初始权值

通过 GA 的迭代计算, 当 $|d| < \epsilon$, 获得网络初始权值向量 W .

(6) 网络训练

设定学习速率 α 、最大训练步数 max_epoch 、期望误差 ω . 经过多次循环训练后, 竞争层的神经元的权重向量分布发生了变化, 这种分布适合对输入向量进行分类.

(7) 网络测试和使用

网络训练好以后, 其权值就固定下来, 以后对于每一个输入值, 网络都会提供相应的分类结果. 可以利用仿真函数来观察 GA_LVQ 神经网络对训练数据和测试数据的分类结果.

最后, 将需要分类的全部数据向量, 输入到已经训练、测试好的 LVQ 神经网络中, 网络就可以对其进行分类, 获取测区底质分布图.

5 实验结果

5.1 数据选取

选择在青岛胶州湾利用挪威 Simrad EM3000D 多波束测深系统进行多波束测量试验的部分数据作为研究对象(图 5 中四边形框线所围区域). 根据已有的实测资料^[25]及本次试验 42 个现场地质取样资料分析(图 5 中黑点为取样点), 研究区域的海底底质类型可以分为基岩(A类)、砾石(B类)、砂(C类)、细沙(D类)、泥(E类).

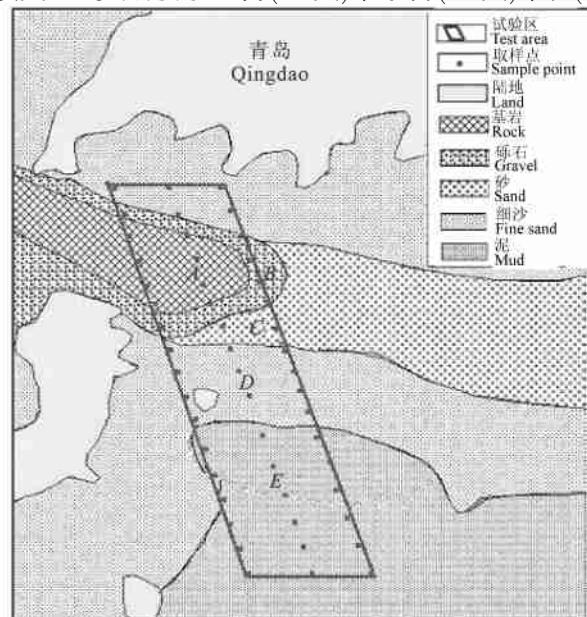


图 5 研究区域海底底质类型分布示意图

Fig. 5 Schematic depiction of sediment distribution in the study area near Qingdao
© 1994-2012 China Academic Journal Electronic Publishing House. All rights reserved. <http://www.cnki.net>

类)、细砂(D类)以及泥(E类)等5种类型(图5)。

对于多波束测深系统获取的原始反向散射强度数据,必须经过一系列数据预处理^[24],才能获取真实反映底质类型特征的反向散射强度信息,用于底质分类识别研究。根据现场地质取样资料的分析结果,选取相应的3828组处理过的反向散射强度数据作底质分类研究(包括783组基岩、549组砾石、450组砂、990组细砂及1056组泥),将其分为训练样本数据2552组(包括522组基岩、366组砾石、300组砂、660组细砂及704组泥),测试样本数据1276组(包括261组基岩、183组砾石、150组砂、330组细砂及352组泥)。

5.2 分类结果

建立LVQ神经网络,选取输入2552组训练样本数据,输出目标向量T表示5种底质类型,竞争层神经元个数为30,设定网络学习速率 $\alpha=0.01$,网络期望误差 $\omega=0.003$;取遗传群体个数为30,采用较为常用的24位格雷编码,交叉概率 $P_c=0.9$ 、变异概率 $P_m=0.1$,设定 $\epsilon=0.001$,遗传迭代结束的条件为 $|d|<\epsilon$ (图4)。分别应用LVQ和GA_LVQ神经网络方法对训练样本数据进行分类识别,计算结果如图6。

从图6可以看出,GA_LVQ神经网络在收敛速度和收敛性能上都比标准LVQ神经网络有了显著提高,当GA_LVQ计算至1575步时,计算耗时36 min,期望误差 ω 就已经小于0.003,达到网络收敛要求;而LVQ神经网络计算至3000步,期望误差 ω 还大于0.1,远大于收敛条件,网络还处在振荡状态,难以很快收敛,网络计算至15000步,计算耗时12 h以上,期望误差 ω 才小于0.01,无法达到网络收敛条件,训练强制结束。

分别将训练数据和测试数据输入训练好的GA_LVQ和LVQ中进行分类识别,其分类结果见表1和图7。表1中,全部样本的分类精度不是训练样本和测试样本分类精度的简单平均,而是通过输入全部样本数据(包括训练样本及测试样本),最后计算得

表1 GA_LVQ与LVQ分类精度比较

Table 1 Accuracy comparison of seafloor classification using GA_LVQ and LVQ neural network

底质类型	训练样本数	测试样本数	分类精度(训练样本)		分类精度(测试样本)		分类精度(全部样本)	
			LVQ	GA_LVQ	LVQ	GA_LVQ	LVQ	GA_LVQ
基岩	521	261	90.2%	95.6%	89.3%	95.2%	89.7%	95.4%
砾石	367	183	72.4%	85.7%	71.5%	84.7%	72.0%	85.3%
砂	300	150	81.1%	92.0%	79.6%	91.5%	80.3%	91.7%
细砂	660	330	75.4%	88.6%	75.0%	87.8%	75.2%	88.2%
泥	704	352	82.3%	90.8%	81.7%	89.7%	82.1%	90.2%

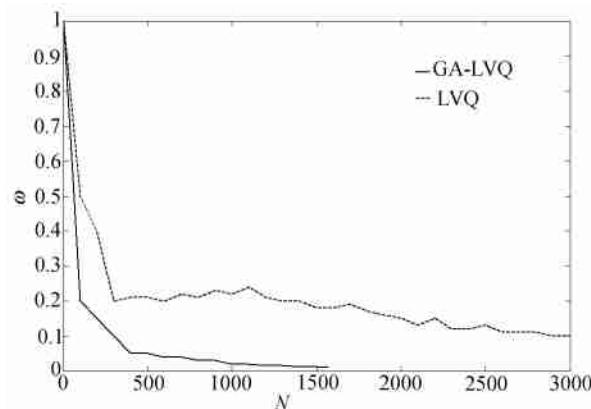


图6 GA_LVQ与LVQ平均方差曲线图

Fig. 6 Mean square errors of GA_LVQ and standard LVQ neural network

到的5种底质类型分类精度。从表1及图7可以看出,应用GA_LVQ神经网络进行底质分类识别,基岩、砾石、砂、细砂以及泥的分类精度达到95.4%、85.3%、91.7%、88.2%、90.2%,远远高于应用标准LVQ神经网络的分类精度89.7%、72.0%、80.3%、75.2%、82.1%,分类精度有了很大提高,取得了满意的分类结果。

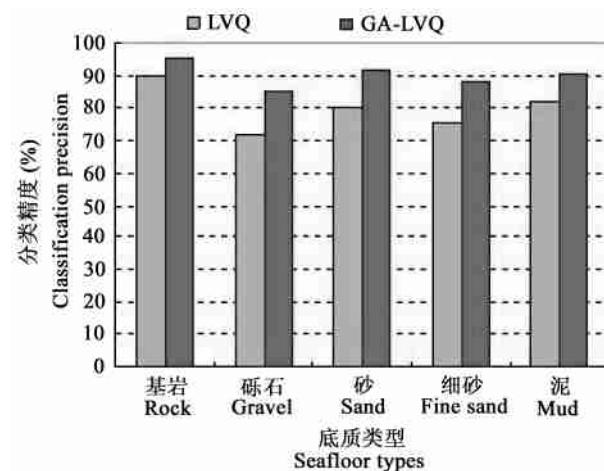


图7 GA_LVQ与LVQ分类精度比较图

Fig. 7 Accuracy comparison of classification using the proposed GA_LVQ and the standard LVQ neural network

6 结 论

利用神经网络进行海底底质分类是近年来声学海底遥测的一个研究热点。本文针对常用的LVQ神经网络存在神经元未被充分利用以及算法对初值敏感的问题,采用遗传算法优化LVQ神经网络的初始值,将GA与LVQ神经网络有效结合起来,可以迅速获取最佳的神经网络权值向量,从而加速了网络收敛速度,提高了网络分类精度。实验结果表明,应用GA_LVQ神经网络能够快速、准确地实现对海底基岩、砾石、砂、细砂以及泥等底质类型的自动分类识别。

参考文献(References)

- [1] 潘国富. 声学方法进行海底沉积物遥测分类: 综述. 海洋技术, 1997, **16**(1): 14~ 19
Pan G F. Remote acoustic classification of seafloor sediments: a review. *Ocean Technology* (in Chinese), 1997, **16**(1): 14~ 19
- [2] King L H, Maclean B. Pockmarks on the Scotian shelf. *Geological Society of America Bulletin*, 1970, **81**(10): 3141~ 3148
- [3] Reut Z, Pace N G, Heaton M J P. Computer classification of sea beds by sonar. *Nature*, 1985, **314**(3): 426~ 428
- [4] Pace N G, Gao H. Swathe seabed classification. *IEEE Journal of Oceanic Engineering*, 1988, **13**(2): 83~ 90
- [5] Milvang O, Huseby R B, Weisteen K, et al. Feature extraction from backscatter sonar data. Proceedings of the International Conference on Acoustic Classification and Mapping of the Seabed, 1993. 157~ 163
- [6] Subramanian S, Barad H, Martinez A B, et al. Seafloor characterization using texture. Proceedings of the IEEE Southeastcon'93, 1993. 299~ 317
- [7] Picani N, Trucco E, Ross M, et al. Texture analysis for seabed classification co_occurrence matrices vs. self_organizing maps. OCEANS'98 Conference Proceedings, 1998. 424~ 428
- [8] Huseby R B, Milvang O, Solberg A S, et al. Seabed classification from multibeam echo sounder data using statistical methods. OCEANS'93 Conference Proceedings, 1993. 229~ 233
- [9] Michalopoulou Z H, Alexandrou D, de Moustier C. Application of neural and statistical classifiers to the problem of seafloor characterization. *IEEE Journal of Oceanic Engineering*, 1995, **20**(3): 190~ 197
- [10] Alexandrou D, Pantartzis D. Seafloor classification with neural networks. OCEANS'90 Conference Proceedings, 1990. 18~ 23
- [11] Kavli T, Carlin M, Madsen R. Seabed classification using artificial neural networks and other nonparametric methods. Proceedings of the International Conference on Acoustic Classification and Mapping of the Seabed, 1993. 141~ 148
- [12] Kohonen T. *Self_organizing Maps*, 3rd Edition. Berlin: Springer-Verlag, 2001. 88~ 101
- [13] Zerr B, Maillard E, Gueriot D. Sea_floor classification by neural hybrid system. OCEANS'94 Conference Proceedings, 1994. 239~ 243
- [14] Chakraborty B, Kodagali V, Baracho J. Sea_floor classification using multibeam echo_sounding angular backscatter data: a real_time approach employing hybrid neural network architecture. *IEEE Journal of Oceanic Engineering*, 2003, **28**(1): 121~ 128
- [15] Chakraborty B, Mahale V, de Sousa C, et al. Seafloor classification using echo_waveforms: a method employing hybrid neural network architecture. *IEEE Geoscience and Remote Sensing Letters*, 2004, **1**(3): 196~ 200
- [16] Zhou X H, Chen Y Q. Seafloor classification of multibeam sonar data using neural network approach. *Marine Geodesy*, 2005, **28**(2): 201~ 206
- [17] 唐秋华, 周兴华, 丁继胜等. 学习向量量化神经网络在多波束底质分类中的应用. 武汉大学学报·信息科学版, 2006, **31**(3): 229~ 232
Tang Q H, Zhou X H, Ding J S, et al. Seafloor classification from multibeam backscatter data using learning vector quantization neural network. *Geomatics and Information Science of Wuhan University* (in Chinese), 2006, **31**(3): 229~ 232
- [18] Chung F L, Lee T. Fuzzy competitive learning. *Neural Networks*, 1994, **7**(3): 539~ 551
- [19] Pal N R, Bezdeck J C, Tsao E C K. Generalized clustering networks and Kohonen's self_organizing scheme. *IEEE Transaction on Neural Networks*, 1993, **4**(4): 549~ 557
- [20] Holland J H. Adaptation in Natural and Artificial System. Michigan: The University of Michigan Press, 1975. 12~ 27
- [21] Simrad. Instruction Manual of Simrad Triton Seabed Classification. Norway: Simrad Company, 1998. 1~ 5
- [22] Lurton X, Dugelay S, Augustin J M. Analysis of multibeam echo_sounder signals from the deep seafloor. OCEANS'94 Conference Proceedings, 1994. 213~ 218
- [23] Zietz S, Satriano J H, Geneva A. Development of physically_based ocean bottom classification analysis system using multibeam sonar backscatter. OCEANS'94 Conference Proceedings, 1994. 1058~ 1063
- [24] Tang Q H, Zhou X H, Liu Z C, et al. Processing multibeam backscatter data. *Marine Geodesy*, 2005, **28**(3): 251~ 258
- [25] 国家海洋局第一海洋研究所. 胶州湾自然环境. 北京: 海洋出版社, 1984. 185~ 244
The First Institute of Oceanography. *The Environments of Jiaozhou Bay* (in Chinese). Beijing: Ocean Press, 1984. 185~ 244

(本文编辑 何 燕)