

王嘉翀, 吴自银, 王明伟, 等. 海底声学底质分类的 ELM-AdaBoost 方法[J]. 海洋学报, 2021, 43(12): 144–151, doi:10.12284/hyxb2021091
Wang Jiachong, Wu Ziyin, Wang Mingwei, et al. ELM-AdaBoost method of acoustic seabed sediment classification[J]. Haiyang Xuebao, 2021, 43(12): 144–151, doi:10.12284/hyxb2021091

海底声学底质分类的 ELM-AdaBoost 方法

王嘉翀¹, 吴自银^{1*}, 王明伟^{1,2}, 周洁琼¹, 赵荻能¹, 罗孝文¹

(1. 自然资源部第二海洋研究所 自然资源部海底科学重点实验室, 浙江 杭州 310012; 2. 山东科技大学 测绘与空间信息学院, 山东 青岛 266590)

摘要: 基于自适应增强算法 (AdaBoost) 结合极限学习机 (ELM), 通过迭代、调整、优化 ELM 分类器之间的权值, 从而构建了具有强鲁棒性、高精度的 ELM-AdaBoost 强分类器, 增强了现有的 ELM 分类器的稳定性。以珠江口海区侧扫声呐图像为实验数据, 对礁石、砂、泥 3 类典型底质进行分类识别, 该方法的平均分类精度超过 90%, 优于单一 ELM 分类器的平均分类精度 85.95%, 也优于 LVQ、BP 等传统分类器, 且在分类所耗时间上也远少于传统分类器。实验结果表明, 本文构建的 ELM-AdaBoost 方法可有效应用于海底声学底质分类, 可满足实时底质分类的需求。

关键词: 极限学习机; 自适应增强算法; 底质分类; 声呐图像; 特征提取

中图分类号: P714⁺.6

文献标志码: A

文章编号: 0253-4193(2021)12-0144-08

1 引言

海底底质类型的分类识别是海洋科学、海洋资源探测以及海洋军事等领域的重要研究内容, 快速、有效、准确地对海底底质进行识别和分类对于海洋科学研究和应用至关重要。基于传统的地质取样方法进行底质识别成本高、效率低^[1], 而多波束、侧扫声呐和浅地层剖面等海底浅表层声呐探测信号或图像中蕴含着丰富的海底底质信息, 通过对上述海底探测声学信号或图像进行分类和识别, 以快速揭示海底底质类型, 已逐渐发展成一门前沿交叉学科^[2]。

近年来, 有不少文献将多种机器学习方法应用于海底底质类型的自动分类识别。文献 [3–6] 利用反向传播神经网络 (Back Propagation, BP) 对海底底质进行分类识别, 但该方法存在收敛速度慢, 易陷入局部最优优化等问题^[7]。文献 [8–9] 将学习向量量化网络 (Learning Vector Quantization, LVQ) 用于海底底质分

类, 但仍存在未充分使用神经元, 对初始权值敏感等问题。文献 [10–11] 利用支持向量机算法 (Support Vector Machine, SVM) 对海底底质进行分类识别, 虽分类精度高、鲁棒性强, 但其对核函数的参数过于敏感, 且难以解决多分类问题。此外, 国内外学者还利用自组织神经网络 (Self-Organizing Map, SOM)、ISODATA (Iterative Self-Organizing Data Analysis Techniques Algorithm) 算法以及 K-均值聚类算法等非监督分类手段^[12–16], 无需样本训练, 分类过程简单, 但由于输出数据没有标识, 且对异常数据敏感, 容易产生错误分类, 鲁棒性较差。海底底质分类数据量大, 在测量与数据采集过程中进行实时分类识别是其发展的必然趋势^[17–18]。现有的海底底质分类方法多继承或改进已有分类器, 以单一或两个分类器简单结合的方式往往无法同时满足海底底质快速、准确、实时分类的需求, 利用适当的集成算法优化多个弱分类器形成强分类器有望同时满足上述需求。

收稿日期: 2020-10-11; 修订日期: 2021-01-19。

基金项目: 国家自然科学基金 (41830540, 42006073, 41906069); 浙江省自然科学基金 (LY21D060002); 中央级公益性科研院所基本科研业务费专项资金项目 (JZ1902, JG2005, SZ2002); 卫星海洋环境动力学国家重点实验室自主项目 (SOEDZZ2101); 全球变化与海气相互作用专项 (GASIEOGE-01)。

作者简介: 王嘉翀 (1995—), 男, 浙江省台州市人, 研究方向为地球信息与探测技术。E-mail: 444684215@qq.com

*** 通信作者:** 吴自银 (1972—), 男, 河南省信阳市人, 研究员, 研究方向为多波束海底地形地貌探测与研究。E-mail: ziyinwu@163.com

增强学习或提升算法,能够将弱学习器增强为预测精度更高、预测结果更稳定的强学习器^[19]。为实现海底底质快速分类,本文采用极限学习机(Extreme Learning Machine, ELM)作为分类器。该分类器分类效率高,适用于处理数据量较大的样本,已成功应用于水质预测^[20]、遥感图像处理^[21]等领域。利用自适应增强算法优化极限学习机(ELM-AdaBoost),在 ELM 高分类效率的基础上可提升其精度和鲁棒性。基于实测侧扫声呐灰度图像,提取均值、标准差、对比度等 6 个特征向量,对礁石、砂、泥 3 类典型海底底质进行分类识别,取得了较好的分类结果。

2 极限学习机基本原理

极限学习机算法最早于 2005 年由 Huang 等^[22]提出,是一种针对 SLFNs(即含单个隐含层的前馈型神经网络)的监督学习算法,其主要思想是:输入层与隐含层之间的权值参数,以及隐含层上的偏置向量参数是随机确定的(无需像其他基于梯度的学习算法一样通过迭代反复调整刷新),只需求解一个最小范数最小二乘问题(最终归化为求解一个矩阵的 Moore-Penrose 广义逆问题)。因此,该算法具有训练参数少、运行速度快、泛化性好等优点。

任意给定 N 个样本 $(\mathbf{X}_i, \mathbf{t}_i)$, 其中 $\mathbf{X}_i = [x_{i1}, x_{i2}, \dots, x_{im}]^T \in \mathbb{R}^m$, $\mathbf{t}_i = [t_{i1}, t_{i2}, \dots, t_{in}]^T \in \mathbb{R}^n$, 其中 m, n 分别表示样本数量和类别数。对于一个有 L 个隐含层节点的单隐层标准前馈型神经网络,可表示为

$$\sum_{i=1}^L \beta_i g(\mathbf{W}_i \cdot \mathbf{X}_j + \mathbf{b}_i) = o_j, \quad j = 1, 2, \dots, N, \quad (1)$$

式中, $g(x)$ 为激活函数; $\mathbf{W}_i = [w_{i1}, w_{i2}, \dots, w_{im}]^T$ 为输入权重; β_i 为输出权重; \mathbf{b}_i 是第 i 个隐含层单元的偏置。 $\mathbf{W}_i \cdot \mathbf{X}_j$ 表示 \mathbf{W}_i 和 \mathbf{X}_j 的内积。

单隐层神经网络学习的目标是使得输出的误差最小,可表示为 $\sum_{i=1}^N \|o_j - t_j\| = 0$, 即存在 β_i , \mathbf{W}_i 和 \mathbf{b}_i , 使得

$$\sum_{i=1}^L \beta_i g(\mathbf{W}_i \cdot \mathbf{X}_j + \mathbf{b}_i) = t_j, \quad j = 1, \dots, N. \quad (2)$$

则式(2)可表示为

$$\mathbf{H}\beta = \mathbf{T}, \quad (3)$$

式中, \mathbf{H} 为隐含层输出矩阵; β 为输出权重; \mathbf{T} 为输出期望。

$$\mathbf{H}(\mathbf{W}_1, \dots, \mathbf{W}_L, \mathbf{b}_1, \dots, \mathbf{b}_L, \mathbf{X}_1, \dots, \mathbf{X}_L) = \begin{bmatrix} g(\mathbf{W}_1 \cdot \mathbf{X}_1 + \mathbf{b}_1) & \dots & g(\mathbf{W}_L \mathbf{X}_1 + \mathbf{b}_L) \\ \vdots & & \vdots \\ g(\mathbf{W}_1 \mathbf{X}_N + \mathbf{b}_1) & \dots & g(\mathbf{W}_L \cdot \mathbf{X}_N + \mathbf{b}_L) \end{bmatrix}_{N \times L}. \quad (4)$$

ELM 的训练过程即选定隐层节点个数后,随机确定输入权重 \mathbf{W}_i 和偏置 \mathbf{b}_i , 然后求式(3)的最小二乘解,可得 $\hat{\beta} = \mathbf{H}^+ \mathbf{T}$ 。其中, $\mathbf{H}^+ = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T$ 是矩阵的广义逆。ELM 网络结构如图 1 所示。




图 1 ELM 网络结构

Fig. 1 Network structure of extreme learning machine

3 ELM-AdaBoost 方法实现

自适应增强算法(Adaptive Boosting)是 Freund 和 Schapire^[23]于 1995 年提出的经典集成算法。其自适应性体现如下:前一个基本分类器样本如果被错误分类,它的权值会增大,而正确分类的样本的权值会减小,并用来训练下一个基本分类器。通过迭代、反复学习,组合调整弱分类器直到达到某个预定的错误率或达到预定的最大迭代次数才形成最终的强分类器。

本文采用侧扫声呐图像作为声学底质分类的数据源,基于侧扫图像采用 ELM-AdaBoost 方法进行海底底质的分类识别主要包括 3 大步骤:(1)声呐数据预处理;(2)特征向量提取;(3)ELM-AdaBoost 网络构建和海底底质分类(图 2)。

3.1 声呐数据预处理

由于获取的原始散射数据畸变严重且含有大量噪声,所以需要原始反向散射数据进行预处理^[24-25],为此,本文进行了海底线跟踪、增益补偿和几何校正等预处理,同时通过图斑和条纹噪声滤波处理降低侧扫声呐噪声,提升鲁棒性,使声呐图像能真实反映底质情况,提高分类精度。

3.2 特征向量提取

特征向量作为分类器的输入向量,代表着不同底质各自的特征,是区分不同底质的标识。本文基于侧扫声呐图像进行底质分类,从基本统计量和灰度共生矩阵中提取多种图像纹理特征作为分类的特征向量。

由于纹理是由灰度分布在空间位置上反复出现而形成的,因而在图像空间中相隔一定距离的两像素之间会存在一定的灰度关系,即图像中灰度的空间相关特性。灰度共生矩阵就是通过研究一定方向(0° 、

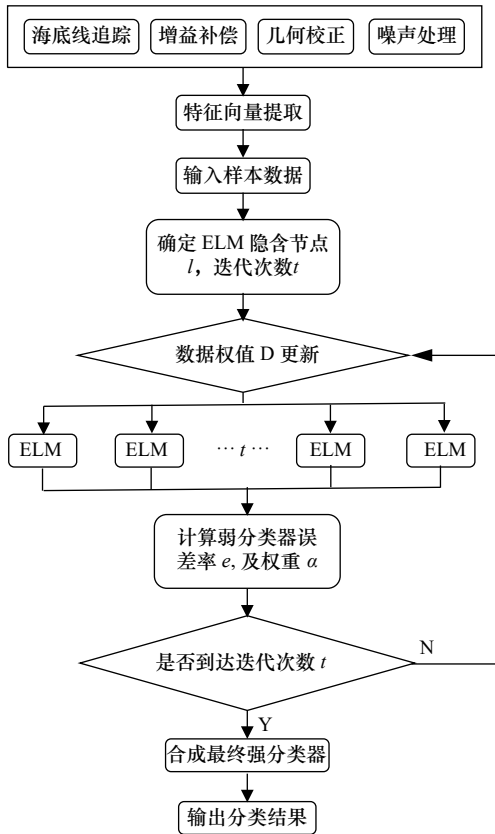


图 2 基于 ELM-AdaBoost 方法的海底底质分类流程
Fig. 2 Flow chart of seabed sediment classification based on ELM-AdaBoost method

45°、90°、135°)上间隔一定距离的灰度级像素之间的相互关系来揭示图像的某些纹理特征。矩阵元素的值就是沿一定方向间距为 d 时, 灰度 i 和 j 的像素对出现的概率或频数^[26]。Haralick 等^[27]在灰度共生矩阵的基础上提出了共 14 种量化纹理的特征向量, 主要包括: 灰度值、角二阶矩、熵、对比度、协方差等。

为了减少图像中相关性较少或者冗余的图像特征、减少数据维度、提高分类效率, 需要进行特征向量降维。本文利用主成分分析方法 (Principal Component Analysis, PCA) 从所有特征向量中选择关联性较高的特征向量, 确定了 6 个特征向量:

(1) 对比度

$$\text{Constrast} = \sum_{i=1}^N \sum_{j=1}^N P(i, j|d, \theta) \cdot (i - j)^2. \quad (5)$$

反映了图像的清晰度和纹理沟纹深浅的程度, 纹理沟纹越深, 其对比度越大, 视觉效果越清晰。

(2) 相关系数

$$\text{Correlation} = \frac{\sum_{i=1}^N \sum_{j=1}^N (i - \text{Mean}) \cdot (j - \text{Mean}) \cdot P(i, j|d, \theta)^2}{\text{Variance}}. \quad (6)$$

用以度量空间灰度共生矩阵元素在行或列方向上的相似程度。

(3) 能量

$$\text{ASM} = \sum_{i=1}^N \sum_{j=1}^N P(i, j|d, \theta)^2. \quad (7)$$

是灰度共生矩阵元素值的平方和, 反映图像灰度分布均匀程度和纹理粗细度。

(4) 熵

$$\text{Entropy} = \sum_{i=1}^N \sum_{j=1}^N P(i, j|d, \theta) \cdot \ln P(i, j|d, \theta). \quad (8)$$

是图像所具有的信息量的度量, 表示图像中纹理的非均匀程度或复杂程度。

(5) 均值

$$\bar{C} = \frac{1}{N} \sum_{i=1}^N C_i. \quad (9)$$

构成对象所有像元的灰度平均值。

(6) 标准差

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (C_i - \bar{C})^2}. \quad (10)$$

用以衡量对象灰度值的离散程度。

3.3 ELM-AdaBoost 网络构建

ELM-AdaBoost 网络构建, 包括以下 5 个步骤。

(1) 通过数据预处理后的图像提取 6 种特征向量, 作为输入数据。给定训练数据 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_i, y_i)\}, i = 1, \dots, n$, 其中 $y_i \in \{1, -1\}$, 用于表示训练样本的类别标签。当 $x_i = y_i$ 时, 分类正确, 类别标签为 1; 当 $x_i \neq y_i$ 时, 分类错误, 类别标签为 -1。

(2) 初始化训练数据的权值分布。每一个训练样本最开始都被赋予相同权值: $w_i = \frac{1}{n}$, 训练样本集的初始权值分布如下:

$$D_i(i) = (w_1, w_2, \dots, w_n) = \left(\frac{1}{n}, \dots, \frac{1}{n}\right). \quad (11)$$

(3) 选定 ELM 分类器的个数, 确定迭代次数 t , 进行迭代:

a. 使用初始化的训练集进行单个 ELM 训练学习以确定最佳隐含层节点个数 l , 同时得到基本分类器 $H_i(x): x \rightarrow \{-1, 1\}$;

b. 计算分类器 $H_i(x)$ 数据集上 D_i 的误差率

$$e_i = P(H_i(x_i) \neq y_i) = \sum_{i=1}^n w_i I(H_i(x_i) \neq y_i). \quad (12)$$

c. 计算该基本分类器在最终 ELM-AdaBoost 强分类器中所占的权重

$$\alpha_t = \frac{1}{2} \ln \left(\frac{1 - e_t}{e_t} \right). \quad (13)$$

d.更新训练样本的权值分布

$$D_{t+1} = \frac{D_t(i) \exp(-\alpha_t y_i H_t(x_i))}{Z_t}, \quad (14)$$

式中, Z_t 为归一化常数, $Z_t = 2 \sqrt{e_t(1-e_t)}$, 即分类错误的样本获得更大的权值。

(4)全部迭代完成后,根据弱分类器权重 α_t 组合各个 ELM, 即:

$$f(x) = \sum_{t=1}^T \alpha_t H_t(x), \quad (15)$$

再通过符号函数 sign 得到最终强分类器 ELM-AdaBoost:

$$H_{\text{final}} = \text{sign}(f(x)). \quad (16)$$

(5)最后利用 ELM-AdaBoost 分类器对测试样本进行特征向量分类,输出分类结果。

4 实验分析

为验证 ELM-AdaBoost 方法在海底底质分类中的可行性,本文实验数据来源于 908 专项海洋调查航次,利用 Edgetech 2000DSS 侧扫声呐系统在珠江口海

区获取了侧扫声呐图像(图 3a),其空间分辨率为 0.5 m。珠江口海区微地貌类型多样,具有比较典型的礁石、砂、泥类底质,从获取的侧扫图像分析,河口分布有大片的沙波和礁石^[28-31]。河口区丰富的底质类型如图 3b 至图 3d 所示,分别为礁石、砂和泥 3 种典型的底质灰度图像。

4.1 图像处理与特征提取

从图形校正和噪声处理后的侧扫声呐图像中截取典型的已知底质类型区域,并进行分割和归一化处理,将图像分割成 12×12 的像素单元,得到礁石样本 360 个,砂样本 361 个,泥样本 322 个,总计 1 043 个样本。

然后,利用主成分分析法选择其中识别精度较高的特征向量,最终确定了均值、标准差、对比度、相关系数、能量和熵 6 个特征向量(表 1)。

从部分数据中可以看出,礁石的标准差范围为 [0.142 0~0.230 5],均值为 0.186 2;砂的标准差范围为 [0.104 7~0.127 6],均值为 0.116 1;泥的标准差范围为 [0.220 0~0.302 3],均值为 0.261 1。可见不同底质之间特征向量具有差异性,分类器据此进行分类训练。

4.2 分类结果分析与讨论

从 1 043 个样本中随机挑选,其中 700 个用于训

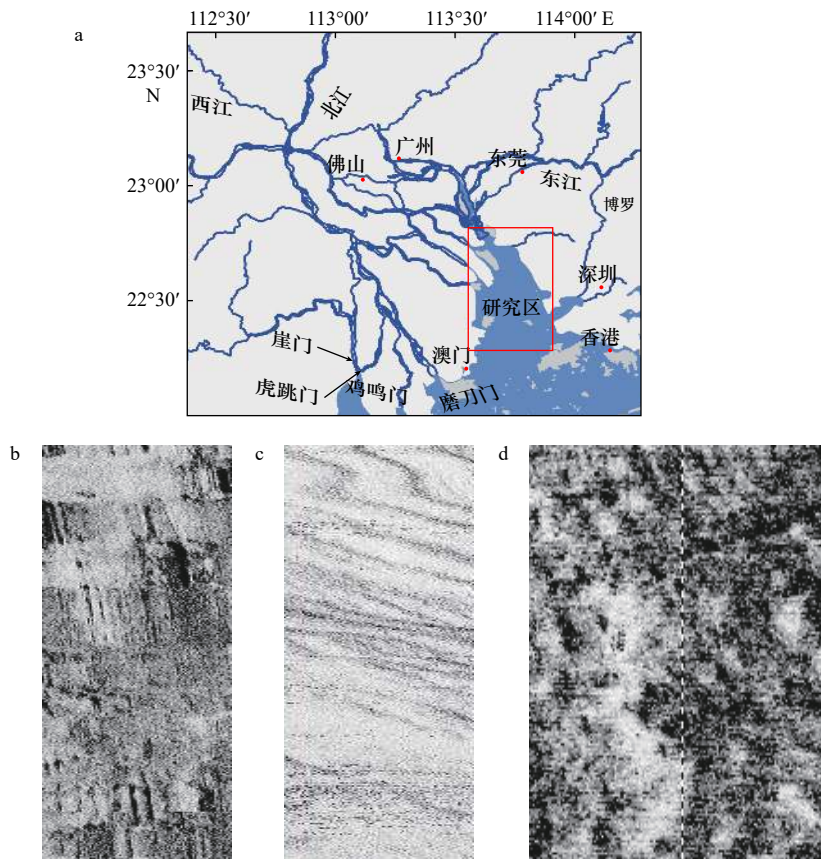


图 3 研究区位置示意图(a)及礁石(b)、砂(c)和泥(d)3种典型底质的声呐图像

Fig. 3 Location of study area (a) and three typical seabed sediment sonar images of rock (b), sand (c) and mud (d)

表 1 礁石、砂和泥 3 种底质的特征向量

Table 1 Characteristic vectors of three types of seabed sediment of rock, sand, and mud

	均值	标准差	对比度	相关系数	能量	熵
礁石	0.765 7	0.153 4	1.621 2	0.326 1	0.121 6	0.616 4
	0.724 2	0.180 2	3.750 0	0.032 8	0.087 6	0.577 1
	0.726 6	0.142 0	1.681 8	0.358 7	0.097 6	0.603 5
	0.675 0	0.155 9	2.659 1	0.194 7	0.062 1	0.574 6
	0.562 7	0.230 5	6.053 0	0.127 9	0.040 3	0.472 6
砂	0.848 8	0.104 7	1.015 1	0.235 8	0.159 9	0.694 7
	0.812 5	0.112 1	1.659 1	0.066 4	0.103 1	0.615 4
	0.768 6	0.127 6	2.560 6	-0.089 4	0.097 7	0.570 8
	0.760 8	0.114 5	1.712 1	0.023 6	0.107 1	0.625 6
	0.798 6	0.109 1	1.825 7	-0.164 6	0.118 0	0.602 6
泥	0.535 9	0.298 0	3.257 6	0.702 6	0.033 6	0.587 0
	0.279 7	0.252 5	3.151 5	0.604 3	0.106 6	0.664 4
	0.408 7	0.302 3	4.204 5	0.572 0	0.035 2	0.563 0
	0.512 7	0.288 2	3.454 5	0.654 4	0.039 4	0.586 9
	0.630 8	0.220 0	2.598 5	0.598 7	0.045 6	0.597 9

表 2 5 种分类器的分类性能对比表

Table 2 Comparison of classification performance of five classifiers

分类器	训练样本平均精度/%	底质类型	测试平均精度/%	所有测试样本平均精度/%	完成分类所耗平均时间/s
BP	89.80	礁石	86.88	82.52	5
		砂	81.44		
		泥	79.23		
LVQ	76.83	礁石	75.66	81.09	298
		砂	84.35		
		泥	83.26		
PSO-SVM	93.87	礁石	85.62	88.22	447
		砂	93.85		
		泥	85.18		
ELM	93.68	礁石	82.70	85.95	0.11
		砂	90.41		
		泥	85.19		
ELM-AdaBoost	93.56	礁石	91.92	90.40	0.37
		砂	91.58		
		泥	87.70		

练, 343 个用于测试。首先构建单个 ELM 数据实验, 以确定隐含层最佳节点数, 结果如图 4 所示, 选取隐含层节点个数 l 为 200, 迭代次数 t 为 10 次。




图 4 隐含层神经元个数对 ELM 分类性能影响
Fig. 4 The influence of the number of hidden layer neurons on the extreme learning machine classification performance

确定隐含层节点个数和迭代次数后, 进行 10 组 ELM-AdaBoost 的网络训练, 取其平均值作为最终分类结果。同时, 为验证 ELM-AdaBoost 算法的可行性, 基于同一组数据进行了多次 BP、LVQ、PSO (Particle Swarm Optimization)-SVM 和单独 ELM 的网络训练, 并取其结果平均值, 测试结果如表 2 所示。

结合表 2 和图 5 可看出, 相比于单一 ELM 弱分类器, ELM-AdaBoost 强分类器调整了各个 ELM 间的权重, 即加大其中分类误差率小的分类器权重, 使其在最终分类函数中起着较大的决定作用, 从而减少了最终分类结果因错误分类所受的干扰, 提高了分类的稳定性, 最终分类精度提高约 5%。

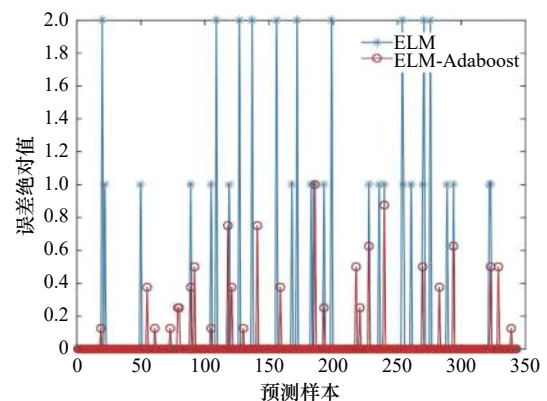


图 5 ELM-AdaBoost 和 ELM 误差绝对值对比
Fig. 5 Comparison of absolute error value between extreme learning machine-adaptive boosting and extreme learning machine

结合表 2 和图 6 可看出, ELM-AdaBoost 分类器对于砂、礁石的平均分类精度均超过 90%, 泥的平均分

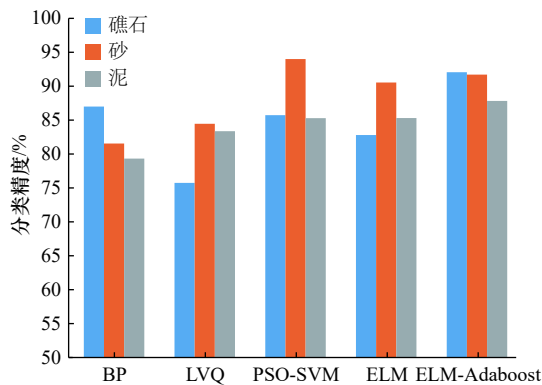


图 6 5 种分类器的分类精度对比

Fig. 6 Comparison of classification accuracy of five classifiers

类精度也接近 90%，相比于传统分类方法 (BP 为 83%、LVQ 为 81%)，分类精度有明显提高。从分类器的分类效率来看，ELM 和 ELM-AdaBoost 分类器完成分类所耗时间仅为 0.11 s 和 0.37 s，相比其他分类器有明显的优势。

参考文献:

- [1] 周兴华, 陈永奇. 多波束声纳数据的底质分类[C]// 我国专属经济区和大陆架勘测研究专项学术交流会议论文集. 北京: 海洋出版社, 2002: 1-7.
Zhou Xinghua, Chen Yongqi. A review of seafloor sediment classification using multibeam sonar data[C]// Collected Works of Exploration in Exclusive Economic Zone and Shelf Area of China. Beijing: China Ocean Press, 2002: 1-7.
- [2] 吴自银, 郑玉龙, 初凤友, 等. 海底浅表层信息声探测技术研究现状及发展[J]. 地球科学进展, 2005, 20(11): 1210-1217.
Wu Ziyin, Zheng Yulong, Chu Fengyou, et al. Research status and prospect of sonar-detecting techniques near submarine[J]. *Advances in Earth Science*, 2005, 20(11): 1210-1217.
- [3] Alexandrou D, Pantartzis D. Seafloor classification with neural networks[C]//Conference Proceedings on Engineering in the Ocean Environment. Washington: IEEE, 1990: 24-26.
- [4] 阳凡林, 刘经南, 赵建虎, 等. 基于遗传算法的BP网络实现海底底质分类[J]. 测绘科学, 2006, 31(2): 111-114.
Yang Fanlin, Liu Jingnan, Zhao Jianhu, et al. Seabed classification using BP neural network based on GA[J]. *Science of Surveying and Mapping*, 2006, 31(2): 111-114.
- [5] 唐秋华, 刘保华, 陈永奇, 等. 基于改进BP神经网络的海底底质分类[J]. 海洋测绘, 2009, 29(5): 40-43, 56.
Tang Qiuhua, Liu Baohua, Chen Yongqi, et al. Seabed classification with improved BP neural network[J]. *Hydrographic Surveying and Charting*, 2009, 29(5): 40-43, 56.
- [6] 陈佳兵, 吴自银, 赵荻能, 等. 基于粒子群优化算法的PSO-BP海底声学底质分类方法[J]. 海洋学报, 2017, 39(9): 51-57.
Chen Jiabing, Wu Ziyin, Zhao Dineng, et al. Back propagation neural network classification of sediment seabed acoustic sonar images based on particle swarm optimization algorithms[J]. *Haiyang Xuebao*, 2017, 39(9): 51-57.
- [7] 贺清碧. BP神经网络及应用研究[D]. 重庆: 重庆交通学院, 2004.
He Qingbi. Back propagation neural network and applications[D]. Chongqing: Chongqing Jiaotong University, 2004.
- [8] 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[J]. *IEEE Journal of Oceanic Engineering*, 2003, 28(1): 121-128.
- [9] 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研究[J]. 武汉大学学报: 信息科学版, 2006, 31(3): 229-232.
Tang Qiuhua, Zhou Xinghua, Ding Jisheng, et al. Seafloor classification from multibeam backscatter data using learning vector quantization neural network[J]. *Geomatics and Information Science of Wuhan University*, 2006, 31(3): 229-232.
- [10] 熊明宽, 吴白银, 李守军, 等. 基于SVM的海底声纳图像底质识别[J]. 海洋通报, 2012, 31(4): 409-414.
Xiong Mingkuan, Wu Ziyin, Li Shoujun, et al. Seafloor sonar sediment image recognition with the Support Vector Machine[J]. *Marine Science Bulletin*, 2012, 31(4): 409-414.
- [11] 郭军, 马金凤. 基于粒子群优化算法的SVM神经网络在海底底质分类中的应用[J]. 测绘与空间地理信息, 2012, 35(12): 66-68.
Guo Jun, Ma Jinfeng. Support vector machine neural network based on particle swarm optimization in seafloor classification[J]. *Geomat-*

5 结论

本文充分利用了 AdaBoost 算法集成多个 ELM, 通过反复迭代调整各个 ELM 分类器之间的权值, 加大其中分类误差率小的分类器权重, 使其在最终分类函数中起较大的决定作用。最终克服了单个 ELM 输出波动大, 模型不稳定的缺点, 构建了具有强鲁棒性、高精度的 ELM-AdaBoost 强分类器。

基于实测珠江口侧扫声呐图像, 利用灰度共生矩阵提取对比度、相关系数、熵等特征向量, 通过改进的 ELM-AdaBoost 方法, 实现对砂、礁石和泥 3 种海底底质的分类, 其分类精度达到 90%, 优于单一 ELM 分类器的平均分类精度 85.95%, 也优于 LVQ、BP 等其他传统分类器。同时, 在分类效率上, 分类时间仅为 0.37 s, 也远少于其他传统分类器, 验证了本文方法的可行性。

- ics & Spatial Information Technology, 2012, 35(12): 66–68.
- [12] 马飞虎, 鄂栋臣, 赵建虎, 等. 基于ISODATA算法的海底底质分类[J]. 测绘信息与工程, 2008, 33(6): 43–45.
Ma Feihu, E Dongchen, Zhao Jianhu, et al. Seabed classification based on ISODATA algorithm[J]. Journal of Geomatics, 2008, 33(6): 43–45.
- [13] 吕良, 金绍华, 边刚, 等. K-均值聚类算法在多波束底质分类中的应用[J]. 海洋测绘, 2018, 38(3): 64–68.
Lü Liang, Jin Shaohua, Bian Gang, et al. The application of K-means clustering analysis algorithm in multibeam seafloor classification[J]. Hydrographic Surveying and Charting, 2018, 38(3): 64–68.
- [14] Marsh I, Brown C. Neural network classification of multibeam backscatter and bathymetry data from Stanton Bank (Area IV)[J]. Applied Acoustics, 2009, 70(10): 1269–1276.
- [15] 唐秋华, 刘保华, 陈永奇, 等. 基于自组织神经网络的声学底质分类研究[J]. 声学技术, 2007, 26(3): 380–384.
Tang Qiuhua, Liu Baohua, Chen Yongqi, et al. Acoustic seafloor classification using self organizing map neural network[J]. Technical Acoustics, 2007, 26(3): 380–384.
- [16] 郭军, 马金凤. 基于K-L变换的自组织竞争神经网络在海底底质分类中的应用[J]. 测绘工程, 2013, 22(1): 51–54.
Guo Jun, Ma Jinfeng. Self-organization competition neural network based on K-L transform in seafloor classification[J]. Engineering of Surveying and Mapping, 2013, 22(1): 51–54.
- [17] 赵芳, 索岩, 彭子然. 基于蚁群优化与独立特征集的遥感图像实时分类算法[J]. 计算机应用研究, 2020, 37(2): 573–577.
Zhao Fang, Suo Yan, Peng Ziran. Real-time classification algorithm of remote sensing images based on ant colony optimization algorithm and independent feature sets[J]. Application Research of Computers, 2020, 37(2): 573–577.
- [18] 吴自银, 阳凡林, 罗孝文, 等. 高分辨率海底地形地貌——探测与处理理论技术[M]. 北京: 科学出版社, 2017.
Wu Ziyin, Yang Fanlin, Luo Xiaowen, et al. High-Resolution Submarine Topography—Theory and Technology for Surveying and Post-Processing[M]. Beijing: Science Press, 2017.
- [19] Ji Xue, Yang Bisheng, Tang Qiuhua. Acoustic seabed classification based on multibeam echosounder backscatter data using the PSO-BP-AdaBoost Algorithm: A case study from Jiaozhou Bay, China[J]. IEEE Journal of Oceanic Engineering, 2021, 46(2): 509–519.
- [20] 边冰, 赵明政. 基于深度极限学习机的水质预测研究[J]. 华北理工大学学报(自然科学版), 2020, 42(1): 51–57.
Bian Bing, Zhao Mingzheng. Study on water quality prediction based on deep extreme learning machine[J]. Journal of North China University of Science and Technology (Natural Science Edition), 2020, 42(1): 51–57.
- [21] 吴军, 王士同, 赵鑫. 正负模糊规则系统、极限学习机与图像分类[J]. 中国图象图形学报, 2011, 16(8): 1408–1417.
Wu Jun, Wang Shitong, Zhao Xin. Positive and negative fuzzy rule system, extreme learning machine and image classification[J]. Journal of Image and Graphics, 2011, 16(8): 1408–1417.
- [22] Huang Guangbin, Zhu Qinyu, Siew C K. Extreme learning machine: A new learning scheme of feedforward neural networks[C]//2004 IEEE International Joint Conference on Neural Networks. Budapest: IEEE, 2005: 25–29.
- [23] Freund Y, Schapire R E. A decision-theoretic generalization of on-line learning and an application to boosting[J]. Journal of Computer and System Sciences, 1995, 55(1): 119–139.
- [24] 唐秋华, 周兴华, 丁继胜, 等. 多波束反向散射强度数据处理研究[J]. 海洋学报, 2006, 28(2): 51–55.
Tang Qiuhua, Zhou Xinghua, Ding Jisheng, et al. Study on processing of multibeam backscatter data[J]. Haiyang Xuebao, 2006, 28(2): 51–55.
- [25] 李庆武, 霍冠英, 周妍. 声呐图像处理[M]. 北京: 科学出版社, 2015.
Li Qingwu, Huo Guanying, Zhou Yan. Sonar Image Processing[M]. Beijing: Science Press, 2015.
- [26] 刘丽, 匡纲要. 图像纹理特征提取方法综述[J]. 中国图象图形学报, 2009, 14(4): 622–635.
Liu Li, Kuang Gangyao. Overview of image textural feature extraction methods[J]. Journal of Image and Graphics, 2009, 14(4): 622–635.
- [27] Haralick R M, Shanmugam K, Dinstein I. Textural features for image classification[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1973, SMC-3(6): 610–621.
- [28] Wu Ziyin, Milliman J D, Zhao Dineng, et al. Geomorphologic changes in the lower Pearl River Delta, 1850–2015, largely due to human activity[J]. Geomorphology, 2018, 314: 42–54.
- [29] Wu Ziyin, Saito Y, Zhao Dineng, et al. Impact of human activities on subaqueous topographic change in Lingding Bay of the Pearl River Estuary, China during 1955–2013[J]. Scientific Reports, 2016, 6(1): 37742.
- [30] Wu Ziyin, Milliman J D, Zhao Dineng, et al. Recent geomorphic change in Lingding Bay, China, in response to economic and urban growth on the Pearl River Delta, Southern China[J]. Global and Planetary Change, 2014, 123: 1–12.
- [31] 熊明宽, 吴自银, 李守军, 等. 基于遗传小波神经网络的海底声学底质识别分类[J]. 海洋学报, 2014, 36(5): 90–97.
Xiong Mingkuan, Wu Ziyin, Li Shoujun, et al. Wavelet neural network identification and classification of sediment seabed sonar images based on genetic algorithms[J]. Haiyang Xuebao, 2014, 36(5): 90–97.

ELM-AdaBoost method of acoustic seabed sediment classification

Wang Jiachong¹, Wu Ziyin¹, Wang Mingwei^{1,2}, Zhou Jieqiong¹, Zhao Dineng¹, Luo Xiaowen¹

(1. *Key Laboratory of Submarine Geosciences, Second Institute of Oceanography, Ministry of Natural Resources, Hangzhou 310012, China;*
2. *College of Geodesy and Geomatics, Shandong University of Science and Technology, Qingdao 266590, China*)

Abstract: Based on the adaptive boosting algorithm (AdaBoost) combined with the extreme learning machine (ELM), the strong classifier of ELM-AdaBoost with strong robustness and high precision is thus constructed by iterating, adjusting, and optimizing the weights between each ELM classifier. ELM-AdaBoost method can enhance the stability of the existing ELM classifier. In this paper, the data collected by side scan sonar in the Zhujiang River Estuary was used to classify and identify three types of typical sediments as rock, sand, and mud. The average classification accuracy of new method exceeds 90%, which is better than the average classification accuracy of a single ELM classifier of 85.95%. It is also superior to other traditional classifiers (i.e. LVQ and BP) and it takes much less time to classify than traditional classifiers. The experimental result shows that the proposed ELM-AdaBoost method can be effectively applied to the classification and identification of seabed sediment and can meet the needs of real-time classification of seabed sediment.

Key words: extreme learning machine; adaptive boosting algorithm; sediment classification; sonar image; feature extraction