

基于遗传算法的海底沉积物纹理特征优化方法

李文莉^{1,2} 高宏伟¹ 冀大雄² 李 岩²

(沈阳理工大学自动化与电气工程学院 沈阳 110168)¹ (中国科学院沈阳自动化研究所 沈阳 110016)²

摘 要 为了提高水下机器人对海底沉积物的自主分类感知能力,解决特征冗余问题,对利用遗传算法优化海底沉积物纹理特征进行了研究。以基于灰度共生矩阵和分形理论提取多种海底沉积物视觉纹理特征实现海底沉积物分类识别为背景,提出利用遗传算法对纹理特征项进行优化选择以实现对提取特征的降维,并将降维后的特征项作为自组织映射神经网络模型的输入,对海底沉积物进行视觉分类,提高水下机器人作业时的环境感知能力。实验结果表明,相对于未优化的纹理特征,优化后的纹理特征在海底沉积物分类识别中具有更优的分类效果。

关键词 海底沉积物,遗传算法,纹理特征分析,灰度共生矩阵,分形理论,自组织映射神经网络

中图法分类号 TP242.6+2 文献标识码 A

Optimization Method of Seabed Sediment Texture Feature Based on Genetic Algorithm

LI Wen-li^{1,2} GAO Hong-wei¹ JI Da-xiong² LI Yan²

(College of Automation and Electrical Engineering, Shenyang Ligong University, Shenyang 110168, China)¹

(Shenyang Institute of Automation Chinese Academy of Sciences, Shenyang 110016, China)²

Abstract In order to improve autonomous sensing perception of underwater vehicle on classification of seabed sediments and solve the problem of features redundancy, using genetic algorithm to optimize texture features of seabed sediments was studied. In the background of the classification and identification of seabed sediment based on a variety of seabed sediment visual texture features that are extracted based on gray level co-occurrence matrix and fractal theory, the reduction of feature dimension has been realized by using the genetic algorithm to optimize the texture features, and the texture features after dimension reduction are trained by a self-organizing mapping neural network as inputs for visual classification of seabed sediments, improving the environmental awareness of underwater vehicle on underwater operation. The experimental results show that with respect to the texture features that are not optimized, optimized texture features have better classification effect in seabed sediment classification and recognition.

Keywords Seabed sediments, Genetic algorithm, Texture feature analysis, Gray level co-occurrence matrix, Fractal theory, Self-organizing map

1 引言

在人类生活的地球上,海洋面积占71%,大洋底部拥有大量的矿产资源。据估计,全世界大洋底部多金属结核储量约3万亿吨,仅在太平洋区域就有1.7万亿吨,结核中锰、镍、钴、铜等金属的储量远远高于陆地上的相应储量^[1]。如何对海洋矿产资源进行勘测与开发具有重要的意义。

自主水下航行器(Autonomous Underwater Vehicle, AUV)作为人类认知海洋、进行海洋矿产勘测作业的主要工具^[2],其自身对周围环境的自主感知能力受到越来越多的重视。水下机器人的视觉系统给机器人提供了大量的信息,构建具有自主识别能力的水下机器人视觉系统成为其智能化的重要环节^[3]。随着机器人视觉技术的发展和日趋完善,机器人视觉系统作为一种必备的探测设备普遍搭载于自主水下航

行器和遥控水下机器人(Remotely Operated Vehicle, ROV)等水下机器人载体上,完成海底目标识别与追踪^[4]、形态描绘^[5,6]、视觉定位导航^[7,8]和海底地图构建^[9]等作业。

海底被多种如多金属结核、海底底栖生物群落和沙漠等沉积物覆盖。海底沉积物类型的分类与识别是海洋科学研究的基础,如何准确、迅速地海底沉积物进行分类识别,及如何提高自主水下航行器对周围环境的自主感知能力和作业效率,具有重要的军事及民用意义。

海底沉积物具有种类、形态多样性的特点,并且光受水的散射和吸收影响,图像颜色不仅存在色变现象,边缘也并不清晰,因此传统的依靠图像颜色和边缘等特征进行分类识别的算法并不适用于水下环境。而纹理特征描述了图像中反复出现的局部模式和它们的排列规则,是对局部区域像素之间关系的一种度量^[10],此外,纹理特征还具有旋转不变性、抗噪能

本文受国家自然科学基金(61233013),机器人学国家重点实验室课题(2013-Z13)资助。

李文莉(1991—),女,硕士生,主要研究方向为图像处理、机器人视觉, E-mail: ytuwenli@126.com; 高宏伟(1978—),男,博士,教授,主要研究方向为计算机视觉检测技术、图像处理技术、智能控制理论与算法; 冀大雄(1980—),男,博士,副研究员,主要研究方向为海洋机器人技术、机器人自动化; 李 岩(1983—),男,博士,助理研究员,主要研究方向为机器人视觉、水下机器人、模式识别。

力强等优点,相对于其他特征,更适用于在水下环境中进行目标分类。目前,许多学者对基于纹理特征的水下目标分类进行了分析与应用,如唐秋华、李杰等通过对水下声呐图纹理特征的描述与分析,实现对海底粉砂质砂、黏土质砂以及砂_粉砂_黏土 3 种底质类型的快速自动分类识别^[11];李岩等采用视觉纹理特征对水下图像进行分析,验证视觉纹理特征在水下沉积物的分类识别方面的可行性^[12,13]。然而在提取的众多纹理特征中,有许多特征之间并不是独立的,当特征之间存在相关性时,就造成了冗余特征项的产生。冗余特征项的存在会影响分类的速度和效果,因此需要把冗余的特征项筛选掉,即对特征项进行优化选择,遗传算法作为优化算法可以很好地应用在图像特征选择方面^[14-16]。此外遗传算法在其他领域也取得很好的优化效果,例如,蒋培应用遗传算法优化了学习环境,在优化机器学习系统的学习能力方面取得很好的效果^[17]。本文的目的就是建立一套海底沉积物纹理特征的视觉提取方法,利用遗传算法对提取的纹理特征进行优化选择,去掉冗余的特征项,找出最有利于分类的特征组合,并在此基础上采用自组织神经网络(Self-organizing map, SOM)对海底沉积物进行分类,从而提高自主水下航行器对海底周围环境的自主感知能力。

2 海底沉积物纹理特征提取

纹理特征的分析方法主要分为基于统计和基于结构的两类分析方法。基于统计的分析方法是采用统计模式识别的形式来描述纹理特征,例如基于灰度共生矩阵(Gray Level Co-occurrence Matrix, GLCM)的纹理分析方法;基于结构分析的方法是分析像素区域的关系来描述纹理特征,例如基于分形理论的纹理分析方法。目前,在基于纹理特征分析的视觉分类研究中经常采用的纹理特征主要有以下几项:能量、对比度、熵、相关性、分形维数^[12,13]。其中能量、对比度、熵、相关性通过基于灰度共生矩阵的纹理分析方法获得,而分形维数通过基于分形理论的纹理分析方法获得。

2.1 基于灰度共生矩阵的特征提取

灰度共生矩阵是由 Haralick 等人在 1973 年提出的一种运用统计学概率来描述纹理的方法^[18],该描述方法运用了像元在灰度空间下的相互关系。灰度共生矩阵的定义式表示为:

$$P_d(i, j), i, j = 0, 1, 2, \dots, L-1 \quad (1)$$

其中, L 为图像的灰度级,表示灰度级为 i 的像元沿 θ 方向到达距离为 d 且灰度级为 j 的像元在图像中出现的概率。在 8 连通域图像下, θ 方向通常取 0° 、 45° 、 90° 和 135° 4 个方向。

灰度共生矩阵可以描述像元灰度分布的局部模式和排列规则。

(1) 能量(Angular Second Moment)

$$f_1 = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P^2(i, j) \quad (2)$$

能量是灰度共生矩阵中各元素的平方和,反映图像灰度分布的均匀程度和纹理的粗细度。

(2) 相关性(Coorelation)

$$f_2 = \frac{\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} (ij) \cdot P(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (3)$$

其中:

$$\left\{ \begin{aligned} \mu_x &= \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} i \cdot P(i, j) \\ \mu_y &= \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} j \cdot P(i, j) \\ \sigma_x &= \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} (i - \mu_x)^2 \cdot P(i, j) \\ \sigma_y &= \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} (j - \mu_y)^2 \cdot P(i, j) \end{aligned} \right\}$$

相关是灰度共生矩阵中行或列元素之间的相似程度的度量,反映灰度图像水平或竖直方向上的纹理特征。

(3) 熵(Entropy)

$$f_3 = - \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P(i, j) \log(P(i, j)) \quad (4)$$

熵是图像纹理特征的度量,反映图像纹理的非均匀程度和复杂程度。

(4) 对比度(Contrast)

$$f_4 = \sum_{n=0}^{L-1} n^2 \left\{ \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P(i, j) \mid |i-j|=n \right\} \quad (5)$$

对比度是灰度共生矩阵的主对角线惯性矩,反映图像的清晰度及反差。

在基于纹理特征的分类研究中,通常将以上 4 种纹理特征参数在 0° 、 45° 、 90° 和 135° 4 个方向上求均值和标准方差作为海底沉积物纹理特征^[12,13]。

2.2 基于分形理论的特征提取

分形理论由 B. B. Mandelbrot 提出,是描述自然界中不规则物体和现象的自相似性的一种方法。分形理论指出具有自相似性的物体都可以用一个分形维数(Fractal Dimension, FD)来描述其不规则和复杂的程度^[19]。在图像处理中,分形维数通常用于衡量图像纹理特征,测量像元的灰度值在二维空间中不同尺度下的复杂度分布变化^[20]。针对不同的应用,分形维数有不同的测量方法。在图像处理领域,盒子计数法是普遍采用的分形维数测量方法^[21,22]。利用盒子计数法测量图像分形维数的思路是将二维灰度图像,尺度分解,即分解为若干个尺寸为 $\frac{1}{r}$ 的盒子,存在像素的盒子数量即可表示为:

$$N_r = r^{-FD} \quad (6)$$

改变图像的分解尺度时, N_r 随之改变, FD 存在一个固定的极值,图像分形维数可表示为:

$$FD = \frac{\log(N_r)}{\log(1/r)} \quad (7)$$

3 基于遗传算法的纹理特征优化选择

本文利用灰度共生矩阵和分形理论提取海底沉积物的 9 种纹理特征(能量平均、能量方差、熵平均、熵方差、对比度平均、对比度方差、相关平均、相关方差、分形维数),如何对这 9 种纹理特征进行优化选择,使海底沉积物的分类效果得到有效改善是本文研究的重点。遗传算法是用于解决优化问题的一种高效搜索启发式算法,是进化算法的一种,能够自适应地获得搜索空间的知识,通过选择、交叉、变异等遗传操作,使问题逐渐趋近于最优解或近似最优解,该算法已经被广泛应用于例如图像处理、机器学习、神经网络、模式识别等领域。因而,本研究采用遗传算法对提取的 9 种海底沉积物纹理特征

进行优化选择,并将降维后的特征组合作为新的分类信息。

遗传算法对基于灰度共生矩阵和分形维数提取的特征项进行优化组合的运算流程如图 1 所示。




图 1 遗传算法运算流程

遗传算法的具体运算过程如下:

(1) 产生任意的纹理特征组合组成初始种群。每个纹理特征组合作为初始种群的一个个体采用二进制编码方式表示,编码的二进制位数由原始特征项的个数决定,如提取的原始特征项的数目为 9,则二进制编码的长度为 9,每一个二进制位对应相应的特征项。若二进制位为“0”,表示该二进制位对应的特征不被选用,反之,则被选用。本研究利用随机方法产生 50 个个体组成初始种群,种群中的每个个体都作为问题的候选解。

(2) 适应度函数作为分类的评价准则,使得种群中的候选解能够向最优解逼近,是遗传算法解决优化问题的关键。各类样本之所以能够进行分类,是因为不同样本在特征空间中分布在不同的区域。不同类之间的距离越大,并且同类区域内样本间距离越小,代表分类效果越好,所以应用类内、类间距离作为分类效果的评价准则是可行的^[23]。

适应度函数由类内距离和类间距离确定,即

$$J = S_b - S_w \quad (8)$$

其中, S_b 表示类间距离, S_w 表示类内距离。利用以上公式计算种群中各个个体代表的纹理特征组合的适应度值。

(3) 在遗传算法中,个体的进化过程是在遗传算子的作用下进行的,主要的遗传算子包括选择、交叉和变异。以适应度函数值为依据,从种群中按照一定的选择方法选择出优势特征组合,并按照相应的概率进行交叉、变异等遗传操作,从而产生新的特征组合形成下一代种群。选择算子采用轮盘赌比例选择方法,经过选择,适应度值高的样本,即有利于分类的特征组合将被遗传到下一代,而适应度值低的特征组合将被淘汰。交叉操作是遗传算法中最重要的过程,该操作按照一定的交叉概率将两个父代个体中部分信息进行交换,产生两个继承父代信息的新特征组合作为子代个体。变异操作按照一定的概率对个体的每个二进制位进行操作,可以降低遗传算法进入局部最优的可能。本文中交叉算子选用均匀交叉和多点交叉,交叉概率设为 0.8,变异概率设为 0.01。

(4) 遗传算法终止条件设为最大迭代次数,即到算法达最大迭代次数时,停止运算,本文设定最大迭代次数为 500。通过实验测试发现,当迭代次数大于 500 时,适应度函数的值

达到最高并且不再发生变化,因此可以认为迭代次数设为 500 时,可以将得到的最优特征组合作为问题的最优解。

4 基于自组织映射神经网络模型的分类算法

多层感知器的学习和分类是以已知一定的先验知识为前提条件,即网络模型的权值是在监督的情况下进行调整。在海底沉积物分类识别感知的实际应用中,由于沉积物种类和形态的多样性,并不能提供所需的先验知识,因此需要一种无监督学习的算法模型对其进行分类感知。

SOM 网络是一种聚类和高维可视化的无监督学习的神经网络模型^[24]。SOM 网络可以在保持拓扑结构不变的条件下,将高维的输入在输出层映射为多个一维或者二维图形。通过对输入样本的反复学习可以检测其内在规律性和相互之间的关系,并根据输入样本的信息自适应调整网络模型的参数和结构,使其对以后的响应与之相适应。SOM 网络的自组织功能是通过竞争学习来实现的,其网络结构如图 2 所示。




图 2 SOM 网络拓扑结构

本文分别将原始的特征组合和优化后的特征组合作为 SOM 网络的输入,对同一组样本进行聚类分析,从而验证经遗传算法优化后的特征组合能否得到更好的分类效果。

5 实验与结果分析

为了验证所提海底沉积物分类算法的效果,本文对底栖生物群落、多金属结核和沙漠 3 类常见的海底沉积物进行分类(见图 3)。




图 3 各类海底沉积物形态

实验以“蛟龙号”载人深潜器在 2013 年的试验性航程,在我国南海进行科学考察实验时获取的图像数据作为样本图像。实验对随机的 81 幅海底沉积物图像进行聚类分析,实验数据的组成如表 1 所列。

表 1 实验数据组成

类型	底栖生物群落	多金属结核	沙漠
数量	19	18	44

对 81 幅样本图像分别提取 9 个纹理特征数据,并进行遗传算法优化操作,得到的适应值函数曲线如图 4 所示。




图4 适应度函数曲线

实验结果显示当迭代次数到达 256 次以后算法收敛、遗传代数增加时,适应度值基本无变化,此时得到的解为最优解或近似最优解。最终经过优化得到的特征组合由能量平均、熵方差、对比度方差、相关方差 4 个特征项组成。

通过图 5 对比可以发现,3 类沉积物图像的能量平均、熵方差、对比度方差、相关方差存在差异,这表明 4 个特征项可以作为对沉积物分类的一个参数。




图5 各类海底沉积物 4 个优化特征项比较

以基于遗传算法优化得到的 4 个纹理特征作为 SOM 网络的输入进行聚类。U 矩阵图是普遍采用的显示 SOM 网络聚类训练结果的可视化方法,体现神经元间所代表样本的相似性。U 矩阵(见图 6)中颜色的深浅变化代表神经元之间的距离关系,颜色越深表示距离越远,反之,颜色越浅表示距离越近,可以看出浅色单元被深色单元大致分为了左上部、右上部和下部 3 类,也就是原始样本即海底沉积物图像根据其自身纹理相似性被分为了 3 类。




图6 U 矩阵

聚类结果采用输出节点数为 14×10 的二维网格表示,利用原始特征组合与优化后的特征组合分别作为 SOM 网络的输入,聚类结果对比如图 7 所示。图 7(a)表示原始特征组合进行聚类的结果,可以看出海底沉积物样本大体被分为 3 类,其中第一类中 P 表示多金属结核样本,第二类中 B 表示底栖生物群落样本,第三类中 S 表示海底沙漠样本。图 7(b)表示优化后的特征组合进行聚类的结果,可以看出经过优化后,样本图像被分为同样的 3 类,但是分类结果中样本的聚合度更

高,类间距更大,分类效果优于图 7(a),即经过遗传算法优化后的特征组合使得分类效果得到较好的改善。




图7 SOM 网络聚类结果对比

结束语 本文提出了一种利用遗传算法优化纹理特征组合的海底沉积物的视觉分类识别感知算法。以 7000 米载人潜水器蛟龙号在前期所获得的海底图像数据为研究对象,针对基于灰度共生矩阵和分形理论提取海底沉积物的视觉纹理特征存在冗余的问题,利用遗传算法优化纹理特征组合,实现纹理特征的精简,并与自组织神经网络模型相结合,实现了在水下环境的特征提取及分类,并且该方法有效提高了分类的效果。今后的研究将侧重于算法的优化,如神经元数的选择,以求减少算法的运算量和提高算法分类的准确率,使算法真正和更好地应用于海洋资源勘探和开发。

参考文献

- [1] 牛京考. 大洋多金属结核开发研究述评[J]. 中国锰业, 2002, 20(2): 20-26
- [2] 封锡盛, 李一平, 徐红丽, 等. 下一代海洋机器人——写在人类创造下潜深度世界纪录 10912 米 50 周年之际[J]. 机器人, 2011, 33(1): 113-118
- [3] 唐旭东, 朱炜, 庞永杰, 等. 水下机器人光视觉目标识别系统[J]. 机器人, 2009, 31(2): 171-178
- [4] Kia C, Arshad M R. Robotics Vision-based Heuristic Reasoning for Underwater Target Tracking and Navigation[J]. International Journal of Advanced Robotic Systems, 2005, 2(3): 245-250
- [5] Armstrong R A, Singh H, Torres J, et al. Characterizing the deep insular shelf coral reef habitat of the Hind Bank marine conservation district (US Virgin Islands) using the Seabed autonomous underwater vehicle[J]. Continental Shelf Research, 2006, 26(2): 194-205
- [6] Singh H, Armstrong R, Gilbes F, et al. Imaging coral I: imaging coral habitats with the SeaBED AUV[J]. Subsurface Sensing Technologies and Applications, 2004, 5(1): 25-42
- [7] 郝颖明, 吴清蒲, 周船, 等. 基于单目视觉的水下机器人悬停定位技术与实现[J]. 机器人, 2006, 28(6): 656-661
- [8] Gracias N R, Van Der Zwaan S, Bernardino A, et al. Mosaic-based navigation for autonomous underwater vehicles[J]. IEEE Journal of Oceanic Engineering, 2003, 28(4): 609-624
- [9] Rzhano Y, Linnett L M, Forbes R. Underwater video mosaicing for seabed mapping[C]// Proceedings 2000 International Conference on Image Processing, 2000. IEEE, 2000: 224-227

(下转第 141 页)

51	55	179	183	49	53	177	181	59	63	187	191	57	61	185	189
19	23	147	151	17	21	145	149	27	31	155	159	25	29	163	167
50	54	178	182	48	52	176	180	58	62	186	190	56	60	184	188
18	22	146	150	16	20	144	148	26	30	154	158	24	28	152	156
115	119	243	247	113	117	241	245	123	127	251	255	121	125	249	253
83	87	211	215	81	85	209	213	91	95	219	223	89	93	217	221
114	118	242	246	112	116	240	244	122	126	250	254	120	124	248	252
82	86	210	214	80	84	208	212	90	94	218	222	88	92	216	220
35	39	163	167	33	37	161	165	43	47	171	175	41	45	169	173
3	7	131	135	1	5	129	133	11	15	139	143	9	13	137	141
34	38	162	166	32	36	160	164	42	46	170	174	40	44	168	172
2	6	130	134	0	4	128	132	10	14	138	142	8	12	136	140
99	103	227	231	97	101	225	229	107	111	235	239	105	109	233	237
67	71	195	199	65	69	193	197	75	79	203	207	73	77	201	205
98	102	226	230	96	100	224	228	106	110	234	238	104	108	232	236
66	70	194	198	64	68	192	196	74	78	202	206	72	76	200	204

图5 46053172⁰¹⁰⁰¹⁰¹¹ 图像

51	19	35	3	49	17	33	1	50	18	34	2	48	16	32	0
55	23	39	7	53	21	37	5	54	22	38	6	52	20	36	4
59	27	43	11	57	25	41	9	58	26	42	10	56	24	40	8
63	31	47	15	61	29	45	13	62	30	46	14	60	28	44	12
115	83	99	67	113	81	97	65	114	82	98	66	112	80	96	64
119	87	103	71	117	85	101	69	118	86	102	70	116	84	100	68
123	91	107	75	121	89	105	73	122	90	106	74	120	88	104	72
127	95	111	79	125	93	109	77	126	94	110	78	124	92	108	76
179	147	163	131	177	145	161	129	178	146	162	130	176	144	160	128
183	151	167	135	181	149	165	133	182	150	166	134	180	148	164	132
187	155	171	139	185	153	169	137	186	154	170	138	184	152	168	136
191	159	175	143	189	157	173	141	190	158	174	142	188	156	172	140
243	211	227	195	241	209	225	193	242	210	226	194	240	208	224	192
247	215	231	199	245	213	229	197	246	214	230	198	244	212	228	196
251	219	235	203	249	217	233	201	250	218	234	202	248	216	232	200
255	223	239	207	253	221	237	205	254	222	238	206	252	220	236	204

图6 76320145¹¹¹¹⁰⁰⁰⁰ 图像

W 编码:

置换序列:01237654;互补序列:11111111。

F 编码:

置换序列:46053172;互补序列:01001011。

C 编码:

置换序列:76320145;互补序列:11110000。

5 结果分析

本文通过对元胞自动机₄种经典分类在三变量变值逻辑体系中全部W编码的可视化结果进行分析,其图像在部分W

编码条件下具有对称性。

F编码是W编码的子集,元胞自动机₄种经典分类在全部F编码的可视化图像中具有对称性,并且其图像对称性各具特点。

C编码是F编码的子集,元胞自动机₄种经典分类在C编码模式下的可视化图像具有更强烈的对称性,其部分元胞自动机规则之间在图像中保持稳定的对称特性。

结束语 由于元胞自动机的₄种经典分类在顺序排列的条件下不具有明显的规律特征,本文通过经典分类在三变量变值逻辑函数的W编码、F编码和C编码模式下不同特色的对称性图像展示,为研究经典分类在整个初等元胞自动机规则空间的分布状态提供了一种新方法,也为后续变值逻辑体系在元胞自动机应用中提供了实验基础。

参考文献

- [1] Wolfram S. Universality and complexity in cellular automata. [J]. Physica, 1984, 10: 1-35
- [2] Gutowitz H A. A hierarchical classification of cellular automata [J]. Physica D Nonlinear Phenomena, 1990, 45(1): 136-156
- [3] Mizraji, Eduardo. The emergence of dynamical complexity: An exploration using elementary cellular automata[J]. Complexity, 2004, 9(6): 33-42
- [4] Obando R A. Partitioning of cellular automata rule spaces[J]. Complex Systems, 2015, 24(1): 27-48
- [5] Zheng J Z J, Zheng C H. A framework to express variant and invariant functional spaces for binary logic[J]. Frontiers of Electrical and Electronic Engineering in China, 2010, 5(2): 163-172
- [6] Wolfram S. Theory and Applications of Cellular Automata[M]. Singapore: Word Scientific, 1986
- [7] Wolfram. Cellular automata as models of complexity[J]. Nature, 1984, 311: 1-3
- [8] Zheng Z J. Conjugate Visualisation of Global Complex Behaviour [J]. Complexity International, 1996: 5-6
- [9] Powley E J. Global properties of cellular automata[J]. Journal of Statistical Physics, 1986, 43(1/2): 210-242
- [10] 晚洁, 郑智捷. 二元变值函数空间的穷举图像序列展示[C]// 2010 年亚太青年通信与技术学术会议, 2010
- [17] 蒋培. 基于共同进化遗传算法的机器学习[J]. 湖南师范大学(自然科学学报), 2004, 27(3): 33-38
- [18] Haralick R M, Shanmugam K. Texture features for image classification[J]. IEEE Transactions on Systems, Man and Cybernetics, 1973, 3(6): 610-621
- [19] Mandelbrot B B. The Fractal Geometry of Nature [M]. New-York: Wh Freeman, 1982
- [20] Russel, et al. Dimension of strange attractors [J]. Physical Review Letters, 1980, 45(14): 1175-1178
- [21] Tricot C. Curves and fractal dimension Springer [M]. Heidelberg: Springer, 1995
- [22] Sarkar N, Chaudhuri B B. An efficient differential box-counting approach to compute fractal dimension of image [J]. IEEE Trans. Syst. Man. Cybern. A, 1994, 24(1): 115-120
- [23] 陈果, 邓堰. 遗传算法特征选取中的几种适应度函数构造新方法及其应用[J]. 机械科学与技术, 2011, 30(1): 124-132
- [24] Kohonen T. Self-organized formation of topologically correct feature maps[J]. Biological Cybernetics, 1982, 43(1): 59-69

(上接第 133 页)

- [10] 高程, 惠晓威. 基于灰度共生矩阵的纹理特征提取[J]. 计算机系统应用, 2010, 19(6): 195-198
- [11] 唐秋华, 李杰, 周兴华, 等. 济州岛南部海域海底声呐图像分析与声学底质分类[J]. 海洋学报, 2014, 36(7): 133-141
- [12] Li Y, Xia C L, Huang Y, et al. Visual Features Extraction and Types Classification of Seabed Sediment[M]// 7th International Conference on Intelligent Robotics and Applications. Springer, 2015: 153-160
- [13] Li Y, Xia C L, Huang Y, et al. A Novel Visual Classification Method of Seabed Sediments[C]// Oceans-St. John's, 2014: 1-4
- [14] 冯莉, 李满春, 李飞雪. 基于遗传算法的遥感图像纹理特征选[J]. 南京大学学报(自然科学), 2008, 44(3): 310-319
- [15] 陈卫东, 刘素华. 基于遗传算法的图像特征选择[J]. 计算机工程与应用, 2007, 43(28): 78-80
- [16] 刘颖, 谷延锋, 张晔. 基于改进遗传算法的超光谱图像特征选择方法[J]. 哈尔滨工业大学学报, 2005, 37(6): 733-735