

基于混沌离散粒子群优化的约束性多分类模型

计智伟^{1,2}, 吴耿锋², 胡珉³

(1. 浙江林学院信息工程学院, 临安 311300; 2. 上海大学计算机工程与科学学院, 上海 200072; 3. 上海大学悉尼工商学院, 上海 200072)

摘要: 约束性多分类问题是在某些工程和生产领域中存在的一类具有特殊约束条件的多分类模式识别问题。针对传统的有监督分类法无法解决约束性多分类问题, 提出一种基于混沌离散粒子群优化的约束性多分类模型(CBPSO-RMCM), 并将该模型应用于盾构隧道管片选型预测。仿真实验表明, CBPSO-RMCM 模型能有效地实现约束性多分类模式识别, 并且分类准确率较高。

关键词: 约束性; 多分类; 混沌; 粒子群优化

Restrictive Multi-classes Classification Model Based on Chaotic Binary Particle Swarm Optimization

Ji Zhi-wei^{1,2}, Wu Geng-feng², Hu Min³

(1. School of Information Engineering, Zhejiang Forestry University, Linan 311300; 2. School of Computer Engineering & Science, Shanghai University, Shanghai 200072; 3. Sydney Institute of Language & Commerce, Shanghai University, Shanghai 200072)

【Abstract】 The problem of restrictive multi-classes classification is a kind of multi-classes pattern recognition subject which contains specific restrictive condition in some engineering and production area. Aiming at the question that the traditional supervised classification method could not solve the problem of restrictive multi-classes classification, this paper proposes a Restrictive Multi-classes Classification Model based on Chaotic Binary Particle Swarm Optimization(CBPSO-RMCM), and uses this model to predict the selection of segment type in shield tunneling process. Simulation experiment shows that the CBPSO-RMCM model is capable of solving the problem of restrictive multi-classes classification, and has high classification accuracy.

【key words】 restrictive; multi-classes classification; chaos; Particle Swarm Optimization(PSO)

1 概述

在模式识别领域中, 分类方法按照是否有先验知识可以分为有监督分类(如 SVM, KNN 等)和无监督分类(常称聚类, 如 K-Means 等)2 类。有监督分类法是在给定的有类标标签的训练样本集的基础上, 采用监督学习算法对训练集进行学习, 得到一个分类器, 再用该分类器对未知类别的样本集进行类别预测^[1]。通常, 有监督分类具有更高的分类精度, 适用于有先验知识的模式分类问题^[2]。在适合使用有监督分类法的多分类问题中, 每个待测样本的类标取值通常是无条件约束的, 因此, 可认为待测样本属于每个子类的先验概率都是相同的。然而, 在某些应用领域中存在一种特殊的多分类问题: 不同的待测样本的类标取值必须满足不同的先验约束条件。这是约束性分类的一种表现形式, 它将领域知识以约束条件的形式嵌入到了分类过程中^[3]。盾构地铁隧道管片选型预测就是一个典型的约束性多分类问题。

由于目前的有监督分类法无法解决这种约束性多分类, 因此本文提出了一种基于混沌离散粒子群优化算法(Chaotic Binary Particle Swarm Optimization, CBPSO)的约束性多分类模型(Restrictive Multi-classes Classification Model, RMCM), 简称 CBPSO-RMCM。实验表明该模型能十分有效地实现约束性多分类模式识别。

2 约束性多分类问题及RMCM模型

2.1 约束性多分类问题的数学描述

已知训练集 $T = \{(x_1, y_1), \dots, (x_n, y_n)\} \in (X \times Y)^n$ 。对于 T 中的

任一样本 (x_i, y_i) : x_i 是长度为 D 的一维向量, 类标 $y_i \in A = \{1, 2, \dots, M\}$, M 为类别总数 ($M > 2$), $i \in [1, n]$ 。训练集 T 中包含取自各个子类的若干个样本。对于每个类标未知的待测样本 x_i , 其类标 y_i 的值必须满足式(1):

$$y_i \in R_i = \{r_{i1}, r_{i2}, \dots, r_{ij}\} \subset A \quad (1)$$

其中, $1 < j < M$ 。称集合 A 的真子集 R_i 为 y_i 值的先验约束集(不同待测样本的约束集往往不同); 称式(1)为 y_i 的约束条件; 把类标具有先验约束条件的多分类问题称为约束性多分类问题。这种多分类问题的目标是在给定训练集 T 和待测样本 x_i 及其类标约束集 R_i 的基础上, 求决策函数 $f_i(x)$, 使得 $y_i = f_i(x_i)$ 且 $y_i \in R_i \subset A$ 成立。

2.2 约束性多分类模型RMCM

在一般的多分类问题中, 待测样本 x_i 属于每个子类的先验概率均为 $1/M$ (M 是总类别数); 但是在约束性多分类问题中, 待测样本 x_i 属于第 c 类的先验概率表示为

$$P(y_i=c) = \begin{cases} 1/j, & c \in R_i = \{r_{i1}, r_{i2}, \dots, r_{ij}\} \subset A \\ 0, & c \in \overline{R_i} \subset A \end{cases}$$

其中, $1 \leq c \leq M$; $1 < j < M$ 。

基金项目: 国家自然科学基金资助项目(50778109); 上海市重点学科基金资助项目(J50103)

作者简介: 计智伟(1980-), 男, 硕士研究生, 主研方向: 模式识别; 吴耿锋, 教授、博士生导师; 胡珉, 副教授、博士

收稿日期: 2009-07-20 **E-mail:** jzw18@hotmail.com

由于不同待测样本的类标值的约束条件不同，因此不能使用传统的有监督分类法对样本进行分类。然而，每个待测样本类标的先验约束条件实际上也为分类提供了额外的先验知识：即待测样本 x_i 与那些类标属于 R_i 的训练样本的相似性应远远超过类标属于 \bar{R}_i 的样本。基于以上分析，本文提出了一种约束性多分类模型 RMCM，流程如图 1 所示。

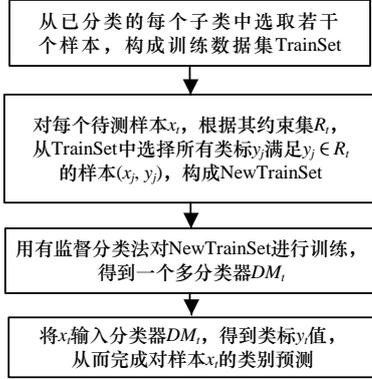


图 1 RMCM 流程

从图 1 可见，RMCM 模型是在普通多分类器的基础上构建起来的一种适用于约束性多分类问题的特殊多分类模型。

普通多分类器的构建，一般通过构建多个二分类器来实现^[4]。本文实验中采用二分类 SVM 构建普通的 SVM 多分类器，然后进一步构建 RMCM 多分类模型。

3 基于混沌离散粒子群的约束性多分类模型

通常原始特征集中含有冗余或不相关特征，若直接采用原始特征集构建 RMCM 模型，往往会影响其分类性能。因此，本文的 CBPSO-RMCM 模型首先用混沌离散粒子群优化算法 CBPSO 快速选取最优特征子集，再根据最优特征子集生成最优 RMCM 模型，最后用最优 RMCM 模型来完成约束性多分类模式识别。

粒子群优化算法(Particle Swarm Optimization, PSO)是 Kennedy 和 Eberhart 在 1995 年提出的一种基于群体的随机优化算法。由于 PSO 是通过个体间的协作来搜索全局最优解，且个体具有记忆功能，因此它的收敛能力较强。PSO 算法初始化为一群随机粒子(随机解)，然后通过迭代找到最优解。对于 D 维空间的由 P 个粒子组成的群落，其第 i 个粒子表示为一个 D 维实数向量 $X_i=(x_{i1}, x_{i2}, \dots, x_{iD})$ ，其中， $i=1, 2, \dots, p$ ，并通过适应度函数计算其适应度值来衡量 X_i 的优劣。第 i 个粒子速度记为 $V_i=(v_{i1}, v_{i2}, \dots, v_{iD})$ ，在每次迭代中，粒子通过跟踪自身最优解 $Pbest_i$ 和全局最优解 $Gbest$ 来更新自己的位置和速度。标准 PSO 按以下公式更新粒子：

$$v_{id}^{new} = wv_{id}^{old} + c_1r_1(Pbest_{id} - x_{id}^{old}) + c_2r_2(Gbest_d - x_{id}^{old}) \quad (2)$$

$$x_{id}^{new} = x_{id}^{old} + v_{id}^{new} \quad (3)$$

其中， $d=1, 2, \dots, D$ ； $i=1, 2, \dots, p$ ； w 是惯性因子，通常取 $w=1$ ； c_1, c_2 为学习因子，通常取 $c_1=c_2=2$ ； r_1, r_2 是 $[0, 1]$ 之间的随机数。

由于标准粒子群算法通常采用实数编码，Kennedy 和 Eberhart 在 1997 年提出了用于解决组合优化问题的二进制粒子群(Binary Particle Swarm Optimization, BPSO)，也称离散粒子群算法。在 BPSO 中，粒子被表示成由 0, 1 构成的二进制向量，粒子每维的更新方法是根据每维的速度值用 *sigmoid* 函数转化为该维取 0 或 1 的概率。标准 BPSO 的粒子更新常采用以下公式：

$$v_{id}^{new} = wv_{id}^{old} + c_1r_1(Pbest_{id} - x_{id}^{old}) + c_2r_2(Gbest_d - x_{id}^{old}) \quad (4)$$

$$\text{if } v_{id}^{new} \notin (V_{\min}, V_{\max}) \text{ then } v_{id}^{new} = \max(\min(V_{\max}, v_{id}^{new}), V_{\min}) \quad (5)$$

$$S(v_{id}^{new}) = 1 / (1 + e^{-v_{id}^{new}}) \quad (6)$$

$$\text{if } (rand < S(v_{id}^{new})) \text{ then } x_{id}^{new} = 1; \text{ else } x_{id}^{new} = 0 \quad (7)$$

在式(5)中， V_{\max} 和 V_{\min} 限制粒子的速度，常设 $V_{\max}=6, V_{\min}=-6$ 。式(6)中的 S 函数为 *sigmoid* 函数。

BPSO 虽然收敛速度较快，但仍有可能出现早熟现象，从而无法搜索到全局最优解。然而混沌运动的遍历性恰好能弥补目前仿生优化算法(例如 GA, PSO 等)易陷入局部最优的缺陷。因此，本文提出 CBPSO，将混沌优化理论引入到 BPSO 进化的不同阶段，使它具有更快的收敛速度和跳出局部最优解的能力。

在 CBPSO 的基础上构建的约束性多分类模型 CBPSO-RMCM 的流程如图 2 所示。

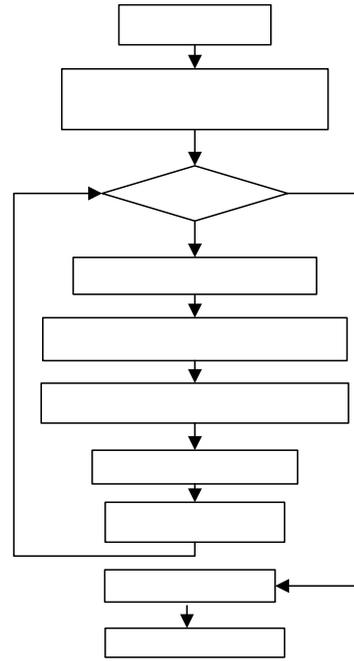


图 2 CBPSO-RMCM 流程

CBPSO-RMCM 的主要步骤如下：

(1)混沌初始化粒子群

用 CBPSO 进行特征选择时，每个粒子代表一种特征选择方案。设含有 D 个特征的原始特征集 $F=\{f_1, f_2, \dots, f_D\}$ ，对每个粒子进行二进制编码，得到长度为 D 的二进制串： $X = x_1x_2\dots x_D$ 。若 $x_i=1$ ，则表示选中第 i 个特征 f_i ，否则表示未选中。由于粒子群算法的收敛性能与初始群体有密切关系，如果随机产生的初始群体中有相当一部分个体远离最优解，将会影响算法的求解效率。利用混沌的遍历性进行粗粒度全局搜索后得到的初始粒子群，往往比随机初始化具有更好的群体质量。

一般地，混沌是指由确定性方程得到的具有随机性的运动状态，呈现混沌状态的变量称为混沌变量。常用的混沌模型即 Logistic 模型，数学表示为

$$x_{k+1} = \mu x_k(1 - x_k) \quad k = 0, 1, 2, \dots \quad (8)$$

式(8)可看作一个动力学系统， μ 为控制参数。当 μ 确定后，由任意初值 $x_0 \in [0, 1]$ ，可迭代出一个确定的时间序列 x_1, x_2, \dots, x_k 。当 $\mu=4$ 时，该系统没有稳定解，是 $[0, 1]$ 区间的满映射，呈现出完全的混沌状态。

随机生成 D 个有微小差异的初始值 $x_{01}, x_{02}, \dots, x_{0D}$ ， D 为

原始特征集规模。将以上 D 个初值分别代入式(8)迭代 k 次, 产生 D 个不同轨迹的混沌变量 $\{x_{ki}, i=1, 2, \dots, D\}$, 再将这 D 个混沌变量代入式(9):

$$g(x) = \begin{cases} 1, & x \geq 0.5 \\ 0, & x < 0.5 \end{cases} \quad (9)$$

通过式(9)的转换, 即可得到 k 个长度为 D 的二进制向量。对于每个固定的 k , $S = \{g(x_{k1}), g(x_{k2}), \dots, g(x_{kD})\}$ 为一个可行解, 即对应了一个粒子。为了保证混沌变量能充分地遍历, 混沌序列的迭代次数 k 一般取 500 左右, 最后选择适应度较高的 $N(N < k)$ 个粒子组成初始种群。

(2) 基于 RMCM 模型的粒子适应度计算

由于 CBPSO 中的每个粒子代表一个特征子集, 因此本文把每个粒子对应的特征子集在 RMCM 分类器上的分类准确率作为该粒子的适应度。粒子适应度计算公式如下:

$$fitvalue(X_i) = \frac{rno}{tno} \quad (10)$$

其中, X_i 为第 i 个粒子; $fitvalue(X_i)$ 为 X_i 的适应度值; tno 为测试样本总数; rno 是用粒子 X_i 对应的特征子集构建的分类器对待测样本集正确分类的样本数。适应度越高的粒子, 对应特征子的分类性能越好。

(3) 更新粒子的速度和位置

粒子速度和位置的更新方法采用式(4)~式(7)。由于惯性权重 w 对粒子群算法的搜索能力有很大的影响, 因此在 CBPSO 迭代过程中采用非线性权值递减策略来动态改变 w 的值。递减策略按照式(11):

$$w = w_l \times (w_s / w_l)^{1/(1+cx \frac{t}{t_{max}})} \quad (11)$$

其中, t_{max} 为最大迭代次数; t 为当前迭代次数; w_s 和 w_l 分别是初始和进化末代的惯性权值 ($w_s > w_l$), 本文实验设 $w_s = 1.2, w_l = 0.4$ 。由式(11)可见, 在 CBPSO 开始阶段, 用较大的权值加强算法的全局搜索能力; 在经过十几至几十代之后 w 迅速减小, 用较小的权值增强算法的局部搜索能力。

(4) 按概率对粒子进行重新初始化

粒子的运动轨迹受到自身局部最优解和全局最优解的影响, 在初始阶段收敛较快, 而后期运动变缓, 呈现聚集状态, 难以有效跳出局部最优解。为避免早熟现象, 在每代中按小概率对粒子进行重新初始化。被重新初始化的粒子, 其历史最优解 $Pbest$ 也被重置。每代群体的重新初始化如图 3 所示。

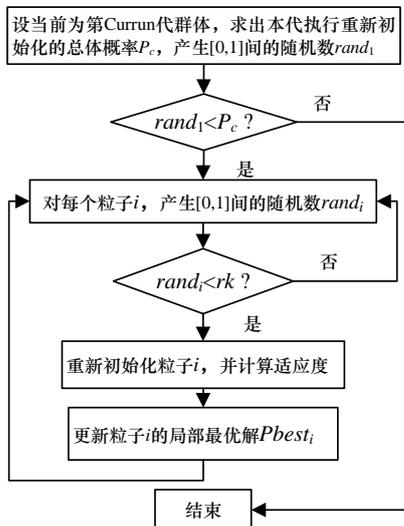


图 3 粒子重新初始化的操作流程

在图 3 中, P_c 表示本代群体重新初始化的总体概率; r_k 表示每个粒子重新初始化的概率, 一般取 $[0,1]$ 之间的一个较小的常数, 本文实验设 $r_k = 0.3$ 。 P_c 的值可按式(12)来计算:

$$P_c = 1 - 1 / (1 + \ln(currun)) \quad (12)$$

其中, $currun$ 为当前迭代次数。由式(12)可见, 在进化的初始阶段, 整个群体被重新初始化的概率较低, 从而使粒子有更多的机会寻找全局最优解; 而在后期进化往往容易陷入局部最优, 加大重新初始化的概率可以使粒子搜索新的解空间。

(5) 更新全局最优和局部最优位置

在每代迭代过程中, 若当前粒子 X_i 优于其历史最优解 $Pbest_i$, 则更新 $Pbest_i$ 。若当前粒子 X_i 优于全局最优解 $Gbest$, 则更新全局最优位置 $Gbest$ 。

(6) 优秀个体的混沌变异

利用混沌进行细粒度局部搜索, 对每代最优个体 $Gbest$ 进行微小的混沌变异, 优化全局最优解的品质, 引导群体快速进化。 $Gbest$ 的混沌变异分以下 4 个步骤:

1) 将粒子进行退化, 得到混沌变量。

设粒子 $X_i = x_{i1}, x_{i2}, \dots, x_{iD}$, x_{ij} 等于 0 或 1, 按式(13)进行退化, 得到混沌变量。

$$t(x_{ij}) = \begin{cases} rand \times 0.1 + 0.9, & x_{ij} = 1 \\ rand \times 0.1 + 0.4, & x_{ij} = 0 \end{cases} \quad (13)$$

由上式可见, 粒子 X 中为 1 的位置转化为 $(0.9, 1)$ 之间的实数; 为 0 的位置转化为 $(0.4, 0.5)$ 之间的实数。因此, 得到了混沌变量 $T_i = t_{i1}, t_{i2}, \dots, t_{iD}$ 。

2) 混沌扰动。

对 T_i 的每个分量按式(14)进行混沌扰动。

$$t_{k,j}^* = t_{ij} + \alpha \mu_{k,j} \quad 1 \leq j \leq D \quad (14)$$

其中, k 为迭代次数(一般取 $k=50$); $t_{k,j}^*$ 为 t_{ij} 经过微小扰动得到的混沌变量; $\alpha = 1 - \frac{k-1}{k}$ (α 为比例系数), m 为一整数;

$\mu_{ij} = (1 + \ln(currun)) \times \varepsilon$, μ_{ij} 为 t_{ij} 上的微小扰动值, $currun$ 为当前种群代数, ε 为一个很小的常数, 本文实验取 $\varepsilon = 0.03$ 。

3) 编码转换。

将变量 $t_{k,j}^*$ 按式(15)重新转换为二进制编码:

$$x_{kj}^* = \begin{cases} \text{round}(t_{k,j}^*) - 1, & \text{round}(t_{k,j}^*) > 1 \\ \text{round}(t_{k,j}^*), & \text{round}(t_{k,j}^*) \leq 1 \end{cases} \quad (15)$$

其中, $\text{round}()$ 函数为四舍五入运算。可见, 若粒子 X_i 的第 j 个位置为 x_{ij} , 经过式(13)~式(15)的转化后得到 x_{kj}^* 。 x_{kj}^* 可能等于 x_{ij} , 也可能等于 $1 - x_{ij}$, 从而实现了局部混沌变异。

4) 更新粒子

经过上述迭代 k 次后得到的 k 个可行解 $X_{k,i} = x_{k,i1}, x_{k,i2}, \dots, x_{k,iD}$, 若其中适应度最高的个体优于 $Gbest$, 则更新全局最优解。

(7) 用最优特征子集建立最优 RMCM 模型

当 CBPSO 迭代到指定代数或 $Gbest$ 值保持稳定后, 得到最优解 X_b , 即最优特征子集。最后, 用最优特征子集构建 RMCM 分类器模型即得到最优 RMCM 模型。

4 实验及结果分析

本文实验将 CBPSO-RMCM 模型用于盾构隧道管片选型预测。该问题的数学描述如下: 设 $X_i = x_{i1}, x_{i2}, \dots, x_{iD}$ 表示第 i 环的施工状态向量; Y_i 是该环管片封顶块的位置编号。 X_i 中各个分量是与 Y_i 值有关的施工参数。对于整条隧道而言,

封顶块的位置共有 M 种可能(用 $A=[1,2,\dots,M]$ 表示),而对于具体的第 i 环来说,其 Y_i 的值需满足先验约束条件: $Y_i \in R_i = \{r_{i1}, r_{i2}, r_{i3} | r_{i1} \in A, r_{i2} \in A, r_{i3} \in A, \text{且 } r_{i1}, r_{i2}, r_{i3} \text{ 各不相同}\} \subset A$; 另外,对于第 j 环($j \neq i$),则约束条件 R_i 和 R_j 可能不同。管片选型的任务就是在给定训练集和待测样本 X_i 及其先验约束集 R_i 的基础上,确定类标 Y_i ,并使 $Y_i \in R_i \subset A$ 。

实验采用的原始数据为上海某隧道施工现场监测数据。与管片选型有关的施工参数(原始特征)共 25 个,并且 $M=19$ 。选取 1 000 环~1400 环中有效样本共 391 个,其中,291 个作为训练集 Trainset,100 个作为测试集 Testset(其中,Trainset 中含有 19 个子类的样本)。选用 1 701 环~1 800 环、1 901 环~2 000 环、2 151 环~2 250 环 3 段的有效数据作为验证集(3 个验证集分别记为 VdSet1, VdSet2, VdSet3,样本规模分别为 90, 92, 91)。

采用 Matlab2007 编制 CBPSO 程序,粒子群规模为 100,迭代 100 代。使用 OSUSVM 软件包建立多分类 SVM,并按前文方法构建 RMCM 模型,支持向量分类机为 C-SVC,选用 RBF 为核函数,并用二维网格法寻优惩罚参数 C 和核半径 σ [5]。

用 CBPSO 选择最优特征子集,其中训练集为 TrainSet,测试集为 TestSet。此外,还用标准二进制粒子群算法 BPSO 以及自适应遗传算法 AGA 进行同样的实验,比较三者对特征子集的寻优能力(图 4)。

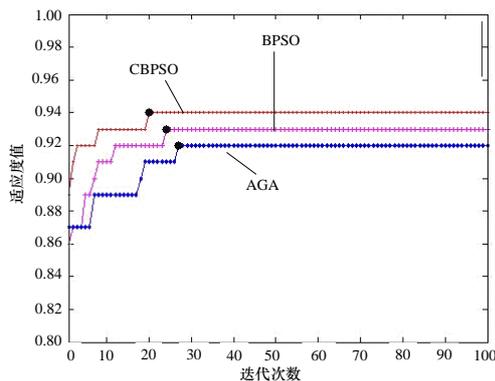


图 4 CBPSO, BPSO, AGA 寻优能力比较

从图 4 可见, CBPSO 收敛速度最快,在第 20 代时就搜索到全局最优解 001010001100100001010111,其适应度值高达 0.94; BPSO 的寻优能力居中; AGA 收敛速度最慢。

CBPSO 特征选择结果见表 1。

表 1 用 CBPSO 选择的最优特征子集

| 序号 | 最优特征子集 |
|------|------------------------|
| 1 | 盾尾偏差 Y 坐标 |
| 2 | 盾构姿态的航偏角 |
| 3 | 68.7 度处的管片间隙 |
| 4 | 333.9 度处的管片间隙 |
| 5 | 管片相对 DTA 的 Y 坐标 |
| 6 | 管片相对盾尾的 Z 坐标 |
| 7~10 | 左下,左上,右上,右下 4 个千斤顶的行程值 |

现在用 CBPSO 得到的最优特征子集建立最优 RMCM 模型(CBPSO-RMCM),并在 3 个验证集上进行测试。同时,用原始特征集直接建立 RMCM 模型,比较 CBPSO-RMCM 与 RMCM 在 3 个验证集上的分类性能(训练集均用 Trainset),结果见表 2。

表 2 CBPSO-RMCM 和 RMCM 的分类准确率比较 (%)

| 验证集 | CBPSO-RMCM | RMCM |
|--------|------------|-------|
| VdSet1 | 88.89 | 80.00 |
| VdSet2 | 88.04 | 81.52 |
| VdSet3 | 86.81 | 81.32 |

从表 2 可见,基于特征选择的 CBPSO-RMCM 模型的分类型性能比 RMCM 有明显提高。

5 结束语

本文提出的 CBPSO-RMCM 模型能有效地解决约束性多分类问题,并且分类型性能比 RMCM 模型有明显提高。CBPSO-RMCM 在管片选型预测中取得了很好的实验效果,进一步验证了本文方法是完全可行的。此外,实验中得到的最优特征子集与领域专家的意见基本一致,对今后的盾构管片衬砌施工有较强的现实指导意义。

参考文献

- [1] Theodoridis S. 模式识别[M]. 3 版. 李晶皎,译. 北京: 电子工业出版社, 2006.
- [2] 赵春霞, 钱乐祥. 遥感影像监督分类与非监督分类的比较[J]. 河南大学学报: 自然科学版, 2004, 34(3): 90-93.
- [3] 冯兴杰, 黄亚楼. 带约束条件的聚类算法研究[J]. 计算机工程与应用, 2005, 41(12): 12-15.
- [4] 曹兆龙. 基于支持向量机的多分类算法研究[D]. 上海: 华东师范大学, 2007.
- [5] 赵莹. 支持向量机中高斯核函数的研究[D]. 上海: 华东师范大学, 2007.

编辑 索书志

(上接第 189 页)

参考文献

- [1] Zitzler E, Künzli S. Indicator-based Selection in Multiobjective Search[C]//Proc. of the 8th Int'l Conf. on Parallel Problem Solving from Nature. [S. l.]: Springer, 2004.
- [2] Wagner T, Beume N, Naujoks B. Pareto-, Aggregation-, and Indicator-based Methods in Many-objective Optimization[C]//Proc. of EMO'07. [S. l.]: Springer, 2007.
- [3] Knowles J, Thiele L, Zitzler Z. A Tutorial on the Performance Assessment of Stochastic Multiobjective Optimizers[R]. Computer Engineering and Networks Laboratory(TIK), Tech Rep.: 214, ETH Zurich, 2006.
- [4] Deb K, Pratap A, Agrawal S, et al. A Fast and Elitist Multiobjective

Genetic Algorithm: NSGA-II[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2): 182-197.

- [5] Zitzler E, Laumanns M, Thiele L. SPEA2: Improving the Strength Pareto Evolutionary Algorithm[C]//Proceedings of Evolutionary Methods for Design, Optimization and Control with Applications to Industrial Problems. NY, USA: [s. n.], 2001: 95-100.
- [6] Deb K, Thiele L, Laumanns M, et al. Scalable Test Problems for Evolutionary Multi-objective Optimization[C]//Proceedings of Evolutionary Multiobjective Optimization: Theoretical Advances and Applications. [S. l.]: Springer, 2005: 105-145.

编辑 索书志