

改进混沌粒子群的动态模糊神经网络参数优化及应用

匡芳君^{1,2}, 张思扬², 徐蔚鸿^{1,3}

(1 南京理工大学 计算机科学与工程学院, 江苏 南京 210094;

2 湖南安全技术职业学院 电气与信息工程系, 湖南 长沙 410151;

3 长沙理工大学 计算机与通信工程学院, 湖南 长沙 410114)

摘 要: 动态模糊神经网络(DFNN)的性能和学习的稳定性取决于其预设参数的选择, 针对 DFNN 多参数优化问题, 提出了改进混沌粒子群优化算法, 并将其应用于 DFNN 神经网络预设参数寻优, 以获取最佳参数组合. 实验结果表明, 该方法能够快速有效地提取 DFNN 的最优参数组合, 具有精度高、收敛快、迭代次数少等特点; 利用改进混沌粒子群的动态模糊神经网络构建煤与瓦斯突出预测模型, 具有良好的建模效果和更高的预测精度.

关键词: 动态模糊神经网络; 混沌粒子群优化; 早熟处理机制; 参数优化; 煤与瓦斯突出

中图分类号: TP18

文献标识码: A

文章编号: 1000-7180(2015)01-0048-06

Application and Parameter Optimization of Dynamic Fuzzy Neural Network Based on Improved Chaotic Particle Swarm Optimization

KUANG Fang-jun^{1,2}, ZHANG Si-yang², XU Wei-hong^{1,3}

(1 School of Computer Science and Engineering, Nanjing University of Science and Technology, Nanjing 210094, China;

2 Department of Electronic and Information Engineering, Hunan Vocational Institute of Safety & Technology,

Changsha 410151, China; 3 College of Computer and Communications Engineering,

Changsha University of Science and Technology, Changsha 410114, China)

Abstract: The performance and the study stability of dynamic fuzzy neural network (DFNN) depend on its preset parameters selection. To the multi-parameter optimization problem of DFNN, improved chaotic particle swarm optimization (ICPSO) is proposed to find the best combination of the preset parameters of DFNN. The experimental results further demonstrate that the ICPSO provides an effective way to search the best parameters combination of DFNN, and has the better precision, the quicker convergence speed and the fewer iteration steps. DFNN model based on improved chaotic particle swarm optimization is built for coal and gas outbursts, which has good modeling and higher prediction accuracy.

Key words: dynamic fuzzy neural network; chaotic particle swarm optimization; premature processing mechanism; parameter optimization; coal and gas outbursts

1 引言

动态模糊神经网络(Dynamic Fuzzy Neural Network, DFNN)综合了神经网络和模糊逻辑的优点, 从而使得 DFNN 同时具有强的自适应能力和推

理能力. 然而动态模糊神经网络仍易陷入局部极小和预设参数难以选择等问题^[1-2]. 粒子群优化算法(Particle Swarm Optimization, PSO)是一种采用速度——位置搜索模型的群智能优化算法, 具有编码简单, 容易实现, 收敛速度快的特点^[3-5]. 却极易陷入

收稿日期: 2014-03-01; 修回日期: 2014-04-29

基金项目: 国家自然科学基金资助项目(61373063); 湖南省科技计划项目(2012SK4046, 2013FJ4217); 湖南省教育厅资助科研项目(13C086)

局部最优,求解精度较差.为提高 PSO 算法的性能,很多学者提出了各种改进算法,例如,唐贤伦^[6]提出了基于混沌优化思想的混沌粒子群优化算法;范会联等^[7]提出了改进的自适应进化粒子群优化算法;肖文显等^[8]提出了融合反向学习和量子优化的粒子群算法等.另外,混沌优化算法具有对初值敏感、易跳出局部极小、搜索速度快、计算精度高、全局渐近收敛的特点^[9].

鉴于上述原因,引入混沌思想和早熟收敛的判断及处理机制,提出了改进混沌粒子群优化(Improved Chaotic Particle Swarm Optimization, ICP-SO)算法以提高其收敛速度和避免后期振荡,并将改进的算法应用于 DFNN 的参数优化,进而得到性能更好的改进混沌粒子群优化动态模糊神经网络模型(ICPSO-DFNN).该模型用于煤与瓦斯突出预测,具有良好的建模效果和更高的预测精度.

2 方法描述

2.1 动态模糊神经网络模型

动态模糊神经(DFNN)一般包括输入层、模糊与递归层、规则层、归一层和输出层五层^[1-2],其网络结构如图 1 所示.为获得系统动态响应,本文在模糊与递归层引入递归神经元.其中,用 $u_s^{(i)}$ 表示第 s 层第 i 个节点的输入, $O_i^{(s)}$ 表示第 s 层第 i 个节点的输出, s 为网络的层数, n 是输入向量的维数.




图 1 DFNN 神经网络结构图

(1) 输入层:将各输入向量 $X = [x_1, \dots, x_n]^T$ 引入网络,各节点代表输入向量各分量.

$$O_i^{(1)} = u_i^{(1)} = x_i, i = 1, 2, \dots, n \quad (1)$$

(2) 模糊化与递归层:实现输入向量模糊化.每个节点代表一个隶属函数,本文采用高斯径向基函数:

$$O_{ij}^{(2)} = \exp\left\{-\frac{[u_{ij}^{(2)}(t) - c_{ij}(t)]^2}{[\sigma_{ij}(t)]^2}\right\} \quad (2)$$

式中, $i = 1, 2, \dots, n, j = 1, 2, \dots, r$; r 是模糊规则数; c_{ij}, σ_{ij} 分别是隶属函数的中心和宽度.

引入递归神经元,则第 t 时刻的输入为 $u_{ij}^{(2)}(t) = \beta_{ij}(t)O_i^{(1)}(t) + O_{ij}^{(2)}(t-1)\theta_{ij}(t)$, β_{ij} 表示与输入层之间连接权值, θ_{ij} 表示递归神经元连接权值.

(3) 规则层:实现模糊操作.每个节点代表一条模糊规则中的 IF 部分,输出为每条规则的适用度.

$$O_j^{(3)}(t) = \prod_{i=1}^n u_{ij}^{(3)}(t) = \prod_{i=1}^n O_{ij}^{(2)}(t) = \prod_{i=1}^n \exp\left\{-\frac{[u_{ij}^{(2)}(t) - c_{ij}(t)]^2}{[\sigma_{ij}(t)]^2}\right\} \quad (3)$$

式中, $j = 1, 2, \dots, r$, r 是模糊规则数.

(4) 归一化层:实现对规则层输出归一化,为去模糊做准备.该层节点数与规则层节点数相等,第 j 个节点的输出为

$$O_j^{(4)} = \frac{u_j^{(4)}}{\sum_{i=1}^r u_i^{(4)}}, j = 1, 2, \dots, r \quad (4)$$

(5) 输出层:该层采用中心平均法实现清晰化和去模糊计算,网络的输出为

$$y_j = O_j^{(5)} = \sum_{i=1}^r u_i^{(5)}(t)w_{ij}(t) = \sum_{i=1}^r O_i^{(4)}(t)w_{ij}(t) \quad (5)$$

式中, w_{ij} 为输出层权值, $j = 1, 2, \dots, m$, m 为输出层节点数.

(6) 误差代价函数为

$$E(t) = \frac{1}{2} [d(t) - y(t)]^2 \quad (6)$$

式中, $d(t)$ 和 $y(t)$ 分别表示期望输出和 DFNN 网络 t 时刻的实际输出.

2.2 改进的混沌粒子群优化(ICPSO) 算法

2.2.1 PSO 算法

假设在 D 维目标解空间中, $S = \{P_1, P_2, \dots, P_m\}$ 表示 m 个代表潜在解组成种群,粒子 i 在 D 维解空间的位置为 $P_i^d(t)$ ($i = 1, 2, \dots, m; d = 1, 2, \dots, D$);粒子 i 的当前飞行速度为 $V_i^d(t)$ ($i = 1, 2, \dots, S$);个体极值 $P_{\text{best}}^d(t)$ 表示粒子 i 自身经历的最好位置;全局极值 $G_{\text{best}}^d(t)$ 是整个群体中所有粒子经历的最好位置.粒子更新操作如下:

$$\begin{cases} V_i^d(t+1) = W \cdot V_i^d(t) + C_1 \cdot R_1 \cdot (P_{\text{best}}^d(t) - P_i^d(t)) + C_2 \cdot R_2 \cdot (G_{\text{best}}^d(t) - P_i^d(t)) \\ P_i^d(t+1) = P_i^d(t) + V_i^d(t+1) \end{cases} \quad (7)$$

式中, $V_i^d(t), V_i^d(t+1), P_i^d(t), P_i^d(t+1)$ 分别表示

粒子 i 当前时刻、下一时刻的速度及所在位置; W 是惯性权重, 用来平衡全局搜索和局部搜索能力; R_1 和 R_2 是 $[0, 1]$ 上的随机数; C_1 和 C_2 是学习因子.

2.2.2 改进混沌粒子群优化算法

PSO 算法的性能受其自身参数设置的影响大, 且算法后期速度缓慢, 易陷入局部极小和早熟现象. 针对这些缺陷, 引入混沌优化思想和早熟收敛的判断及处理机制, 提出 ICPSO 算法以期有效提高算法的收敛速度, 同时部分避免算法后期振荡的作用. 混沌动力学中比较典型的混沌模型是 Logistic 映射^[2,6,10], 其表达式为

$$y_i = \mu y_i(1 - y_i) \quad (8)$$

式中, $y_i \in [0, 1]$ 的随机数; μ 是控制参数, 一般取 4.

(1) 混沌优化设计

对 PSO 算法中的参数 C_1 、 C_2 、 R_1 、 R_2 和 W 进行混沌优化处理如下:

$$W(t+1) = 4.0W(t)(1 - W(t)) \quad (9)$$

$$W(t) = W_{\min} + (W_{\max} - W_{\min})W(t) \quad (10)$$

$$R_i(t+1) = 4.0R_i(t)(1 - R_i(t)) \quad (11)$$

$$C_i(t+1) = 4.0C_i(t)(1 - C_i(t)) \quad (12)$$

$$C_i(t) = C_{\min} + (C_{\max} - C_{\min})C_i(t) \quad (13)$$

式中, $[W_{\min}, W_{\max}]$ 是惯性因子取值范围, 一般取 $[0.4, 0.9]$; $[C_{\min}, C_{\max}]$ 是学习因子的取值范围, 一般取 $[1.4, 2.0]$; $R_i(t) \in (0, 1)$, $i = 1, 2$.

(2) 早熟判断与处理机制

当 PSO 算法后期速度缓慢, 陷入局部极小时, 粒子群表现出强烈的趋同性, 即出现“聚集”现象. 平均粒距表示种群各个体相互之间的分布离散程度, 其表达式如下:

$$Dis = \frac{1}{N \cdot L} \sum_{i=1}^N \sqrt{\sum_{d=1}^D (P_{id} - \bar{P}_d)^2} \quad (14)$$

式中, L 为搜索空间对角最大长度; D 为解空间的维数; N 表示种群规模; P_{id} 表示粒子 i 的第 d 维坐标值; $\bar{P}_d$ 表示所有粒子第 d 维坐标值的均值. 由式 (14) 可知, Dis 越大, 种群越分散, 即种群的多样性越好; 反之相反.

另外, 粒子的位置决定粒子的适应度. 因此, 可根据粒子群中所有粒子适应度整体变化来跟踪粒子群状态. 粒子群群体适应度方差 δ^2 为

$$\delta^2 = \sum_{i=1}^N \frac{F_i - F_{\text{avg}}}{F} \quad (15)$$

式中, N 为种群规模, F_i 为粒子 i 的适应度, F_{avg} 为粒子群的平均适应度, F 为归一化因子, 用于限制 δ^2 的

大小, 其表达式如下:

$$F = \begin{cases} \max_{1 \leq i \leq m} |F_i - F_{\text{avg}}|, \max_{1 \leq i \leq m} |F_i - F_{\text{avg}}| > 1 \\ 1, \text{其他} \end{cases} \quad (16)$$

由式 (15) 可知, δ^2 反映的是种群个体的聚集程度. δ^2 越小, 聚集程度越大; 反之相反.

因此, 粒子群发生早熟收敛的判断依据为: 当平均粒距 $Dis < \alpha$ 且群体适应度方差 $\delta^2 < H(\alpha, H$ 为预先给定常数) 时, 判断粒子群出现早熟收敛现象. 此时, 作如下早熟处理: 对于陷入早熟的粒子, 进行混沌扰动, 使其跳出局部最优值, 即:

$$V_i^d(t) = 4.0V_i^d(t-1)(1 - V_i^d(t-1)) \quad (17)$$

$$V_i^d(t) = V_{\min} + (V_{\max} - V_{\min})V_i^d(t) \quad (18)$$

式中, $[V_{\min}, V_{\max}]$ 是粒子速度的取值范围. 于是, 粒子早熟状态下的更新公式如下:

$$\begin{cases} V_i^d(t+1) = W(t) \cdot V_i^d(t) + C_1(t) \cdot R_1(t) \cdot (P_{\text{best}}^d(t) - P_i^d(t)) + \\ C_2(t) \cdot R_2(t) \cdot (G_{\text{best}}^d(t) - P_i^d(t)) \\ P_i^d(t+1) = P_i^d(t) + V_i^d(t+1) \end{cases} \quad (19)$$

以上各式中, $t = 1, 2, \dots, T$, T 为种群最大迭代次数.

3 ICPSO 优化动态模糊神经网络参数

应用 ICPSO 算法优化动态模糊神经网络的隶属度函数中心 c_{ij} 、宽度 σ_{ij} 和连接权值 β_{ij} 、 θ_{ij} 及 w_{ij} 等参数. 粒子群的适应度表示如下:

$$F(t) = 1/(1 + E(t)) \quad (20)$$

式中, $E(t)$ 是粒子对应的网络输出误差. ICPSO 优化动态模糊神经网络参数的具体步骤描述如下:

步骤 1 初始化 ICPSO 算法的控制参数, 包括粒子群体规模、最大迭代次数 T , 惯性因子的范围 $[W_{\min}, W_{\max}]$, 学习因子的范围 $[C_{\min}, C_{\max}]$, α , H 等. 根据式 (9) 至式 (13) 产生 W 、 C_1 、 C_2 、 R_1 和 R_2 的混沌时间序列.

步骤 2 混沌初始化粒子的位置和速度.

步骤 2.1 假设 DFNN 的预设参数个数为 D , 则随机产生 D 维各分量数值在 $(0, 1)$ 上的向量, 代入 Logistic 映射中, 产生 N 个不同轨迹的混沌序列 $Z_i^d(t)$ ($d = 1, 2, \dots, D; i = 1, 2, \dots, N; N > M$), 作为初始种群.

步骤 2.2 根据 $P_i^d(t) = P_{\min}^d + (P_{\max}^d - P_{\min}^d)Z_i^d(t)$ 将 $Z_i^d(t)$ 各个分量载波到对应变量的取值范围内.

步骤 2.3 计算粒子群的适应度值, 并从 N 个初

始群体中选择性能较好的 M 个解作为初始位置,随机产生 M 个初始速度。

步骤 2.4 求出个体极值 P_{best}^d 和全局极值 G_{best}^d 。

步骤 3 判断收敛准则是否满足,如果满足,则输出全局最优位置和其适应度值,算法结束。

步骤 4 根据式(7)进行迭代计算,更新粒子的速度和位置。

步骤 5 比较适应度 $F(P_i^d)$ 和 $F(P_{best}^d)$,如果 $F(P_i^d) < F(P_{best}^d)$,则更新 P_{best}^d 。

步骤 6 比较更新后的 $F(P_{best}^d)$ 和 $F(G_{best}^d)$,如果 $F(P_{best}^d) < F(G_{best}^d)$,则更新 G_{best}^d 。

步骤 7 判断收敛准则是否满足,如果满足,则输出全局最优位置和其适应度值,算法结束。

步骤 8 根据式(14)、(15)和(16)计算平均粒距 Dis 和群体适应度方差 δ^2 ,并判断 $Dis < \alpha$ 且 $\delta^2 < H$ 是否成立,若不成立,转步骤 4。

步骤 9 根据式(17)、(18)和(19)更新粒子的速度和位置,对陷入局部最优的粒子进行早熟处理,使其跳出局部最优。

步骤 10 对最优位置 G_{best}^d 进行混沌优化。

步骤 10.1 根据 $z_i^d(t) = (G_{best}^d - P_{min}^d) / (P_{max}^d - P_{min}^d)$,将 G_{best}^d 映射到 $(0, 1)$ 。

步骤 10.2 将 $z_i^d(t)$ 代入到 Logistic 映射中,迭代产生混沌变量序列。

步骤 10.3 将产生的混沌变量通过逆映射载波到原解空间。

步骤 10.4 在原解空间对混沌变量的每一个可行解计算其适应度值,得到性能最优的可行解 G_{best}^d 。

步骤 11 用 G_{best}^d 替代当前群体中任意一个粒子的位置。

步骤 12 判断算法是否达到最大迭代次数或满足求解精度要求,若满足则输出全局最优位置和其适应度值,算法结束;否则返回步骤 3。

4 实验及仿真结果分析

4.1 UCI 数据集测试

为了验证算法的有效性,应用 ICPSO 优化动态模糊神经网络(DFNN)模型对 UCI 数据集^[11]进行分类。本文选取其中五个数据集进行分类,ICPSO-DFNN 输入层节点数等于数据集的维数;输出层节点数等于数据集的类别数。所有数据集均采用随机抽样的方法选取 60% 的样本作为训练样本,40% 的样本作为测试样本,各算法在重复运行 50 次后,各测试样本的平均分类准确率和分类均方误差如表 1 所示。

表 1 ICPSO-DFNN 分类结果

数据集	样本数	维数	类别数	平均准确率/%	均方误差
Iris	150	4	3	97.62	0.1456
Credit-card	690	14	2	91.08	0.0075
Glass	214	9	6	88.13	0.0492
Wine	178	13	3	99.69	0.0068
B_cancer_w	683	9	2	94.57	0.4984

对比混沌动态模糊神经网络(Chaotic Dynamic Fuzzy Neural Network CDFNN)^[2]、DFNN、RBFNN、BPNN、CPSO-DFNN 和 ICPSO-DFNN 六种算法在 UCI 上五种数据集的分类效果。实验中各算法对应数据集都选用相同的训练集和测试集,各种算法平均分类准确率比较如图 2 所示。




图 2 测试数据集下各算法平均准确率比较

由表 1 和图 2 可知,ICPSO-DFNN 的分类准确率明显优于其他五种分类算法,通过 ICPSO 能够很快地找出 DFNN 神经网络预设参数的最优组合,而且 ICPSO 也可以缓解标准 PSO 的后期收敛慢且存在振荡的现象。

4.2 煤与瓦斯突出预测模型

针对煤与瓦斯突出预测知识具有模糊性、复杂性、不确定性和非线性的特性,利用改进混沌粒子群优化动态模糊神经网络构建煤与瓦斯突出预测模型,为实现瓦斯治理提供新思路和有效的技术手段,并与其他神经网络预测方法进行了对比。煤与瓦斯突出的影响因素很多,如地应力、地质构造、瓦斯参数、煤体结构及煤质等^[12-13],根据煤与瓦斯突出机理的综合致因理论和先前的研究成果,选取煤与瓦斯突出预测的 5 个主要指标因素作为动态模糊神经网络模型的输入向量,即瓦斯放散初速度 ΔV 、煤的坚固性系数 f 、瓦斯压力 p/MPa 、地质破坏程度 D 、开采深度 H/m ,为了提高训练速度和预测精度,对样本数据按式(21)进行归一化处理:

$$x_{ij} = x_{ij} / (\sum_{j=1}^5 x_{ij}), i = 1, 2, \dots, 5 \quad (21)$$

网络的输入为 $X_i = [x_{i1}, x_{i2}, x_{i3}, x_{i4}, x_{i5}]^T$, $x_{i1} \sim x_{i5}$ 分别为 5 个主要指标因素归一化后的值. 本文收集了 40 个煤与瓦斯突出样本, 部分样本数据如表 2 所示, 取前 28 个作为 ICPSO-DFNN 的训练样本, 后 12 个作为测试样本. 煤与瓦斯突出类型作为动态模糊神经网络的输出, 突出等级分为四个等级: 即无突出(无)、突出区(50 吨以下, 弱)、突出危险区(50 吨至 100 吨, 中)、突出威胁区(100 吨以上, 强), 故网络输出 $Y = [y_1, y_2, y_3, y_4]^T$. 综上, 网络输入层神经元数等于特征向量维数为 5, 输出层神经元数等于突出类型为 4. 在训练过程中, 如果输入的特征向量是第 m 类突出, 则相应的期望输出的第 m 个神经元输出为 1, 而其他神经元输出都为 0. 即期望输出向量可表示为 $Y = [0, \dots, 1, \dots, 0]^T$, 其中, 第 m 个元素是 1. 动态模糊神经网络利用前述算法进行训练, 当收敛后, 保存权值和阈值, 再用训练好的网络去测试.

表 2 部分样本数据

序号	瓦斯放散初速度 ΔV	煤的坚固性系数 f	瓦斯压力 p/MPa	地质破坏程度 D	开采深度 H/m	突出等级
1	4.8	0.6	1.04	2	478	无
2	3	0.5	1.4	3	402	无
3	6	0.25	0.94	5	446	弱
4	14	0.35	2.15	4	512	弱
5	6	0.24	0.95	3	458	中
6	9	0.34	1.66	4	708	中
7	13	0.32	3.87	5	589	强
8	6	0.54	3.95	5	545	强
...	...	...	...	...	...	...

表 3 7 种预测方法仿真结果比较

预测方法	ICPSO-DFNN	CPSON-DFNN	CDFNN	DFNN	PSO-RBFNN	RBFNN	BPNN
错误预测个数	0	2	4	6	4	5	5
预测准确率/%	100	83.333 3	66.666 7	50	66.666 7	58.333 3	58.333 3
均方误差(MSE)	0.005 364	0.015 658	0.065 639	0.356 573	0.054 674	8.125 459	9.474 463
运行时间/s	1.437 327	4.786 403	9.043 184	10.543 252	5.626 365	16.279 541	19.037 968

从表 3 可以看出, ICPSO-DFNN 的预测精度优于其他六种预测方法. 因此, ICPSO-DFNN 具有更好的适应性和突出预测能力, 具有处理复杂、模糊和不确定性的非线性映射能力强, 且对网络初始值不敏感, 收敛速度快的优势, 能有效提高煤与瓦斯突出预测精度.

5 结束语

本文提出基于改进混沌粒子群优化动态模糊神经网络参数, 使网络结构优化和参数调整同时进行, 且收敛速度快, 不易陷入局部极小. 分类测试结果表

综上所述可知, 网络输入层的神经元个数 $n = 5$, 输出层神经元个数煤与瓦斯突出类型 $m = 4$, 其它各层节点数根据学习情况调节确定. 在提出的煤与瓦斯突出预测模型中动态模糊神经网络待确定的参数初始值均取 $(0, 1)$ 区间内的随机数, ICPSO 参数设置如下: 粒子种群规模为 20, 最大迭代次数为 200, 惯性因子 $W_{\min} = 0.4, W_{\max} = 0.9$, 学习因子 $C_{\min} = 1.4, C_{\max} = 2.0$, 以 $E(t) \leq 10^{-3}$ 作为全局收敛条件, 整个算法在 MATLAB R2012a 平台上编程实现.

对同样的训练样本和测试样本分别利用 ICPSON-DFNN、CPSON-DFNN、CDFNN、DFNN、PSO-RBFNN、RBF 和 BPNN 方法等进行训练和预测, 实验中各预测方法分别运行 50 次, 选取其最佳预测结果, 如表 3 所示.

明, 此方法的分类识别效果较好. 最后, 针对煤与瓦斯突出预测知识具有模糊性、复杂性、不确定性和非线性, 利用 ICPSO 优化动态模糊神经网络参数, 并构建了煤与瓦斯突出预测模型. 比其他神经网络预测方法, ICPSO-SVM 的建模效果良好, 在煤与瓦斯突出预测中具有较好的优越性, 下一步工作将在实际应用中结合实际煤与瓦斯突出数据对算法进行完善和优化.

参考文献:

- [1] 伍世虔, 徐军. 动态模糊神经网络—设计与应用[M].

- 北京:清华大学出版社,2008.
- [2] 张思扬,匡芳君,徐蔚鸿.混沌动态模糊神经网络及变压器故障诊断的应用[J].湖南科技大学学报:自然科学版,2012,27(1):35-39.
- [3] Bergh F. An analysis of particle swarm optimizers [D]. South Africa, Department of Computer Science, University of Pretoria, 2006: 118-123.
- [4] Gheitanchi S, Ali F, Stipidis E. Particle swarm optimization for adaptive resource allocation in communication networks [J]. EURASIP Journal on Wireless Communications and Networking, 2010(4): 1-13.
- [5] 刘道华,原思聪,兰洋,等.混沌映射的粒子群优化方法[J].西安电子科技大学学报,2010,37(4):764-768.
- [6] 唐贤伦.混沌粒子群优化算法理论及应用研究[D].重庆:重庆大学,2007.
- [7] 范会联,陶维安.一种改进的自适应进化粒子群优化算法[J].微电子学与计算机,2011,28(5):11-14.
- [8] 肖文显,刘震.一种融合反向学习和量子优化的粒子群算法[J].微电子学与计算机,2013,30(6):126-130.
- [9] 任小波,杨忠秀.一种动态扩散粒子群算法[J].计算机应用,2010,30(1):159-161.
- [10] 李祥飞,邹莉华,彭可.一类模糊神经网络结构的混沌优化设计[J].计算机应用,2007,26(6):1411-1414.
- [11] University of California. UCI Machine Learning Repository: Data Sets [EB/OL]. (2012-06-10). [2014-04-05]. <http://archive.ics.uci.edu/ml/datasets.html>.
- [12] Wang Chao, Wang En Yuan, Xu Jiankun, et al. Bayesian discriminant analysis for prediction of coal and gas outbursts and application [J]. Mining science and technology, 2009(3): 520-523.
- [13] 陈全秋.遗传算法与神经网络相结合在煤与瓦斯突出危险预测中的应用研究[D].太原:太原理工大学,2010.

作者简介:

匡芳君 女,(1976-),博士,副教授.研究方向为模式识别、智能信息处理技术及应用、信息安全等. E-mail: kfjztb@126.com.

张思扬 男,(1973-),硕士,高级工程师.研究方向为人工智能、故障诊断、电子技术等.

徐蔚鸿 男,(1963-),博士,教授,博士生导师.研究方向为人工智能、模式识别、软件工程等.

(上接第47页)

- [6] 李爱国,覃征.在线分割时间序列数据[J].软件学报,2004,15(11):1671-1678.
- [7] 朱天,白似雪,王柏,等.基于时间段的时序规则发现[J].通信学报,2009,30(8):112-115.
- [8] Park S, Kim S, Chu W. Segment-based approach for subsequence searches in sequence databases[C] // Proceedings of the 16th ACM Symposium on Applied Computing. New York: ACM Press, 2001: 248-252.
- [9] Xiao H, Hu Y F Data mining based on segmented time warping distance in time series database[J]. Journal of Computer Research and Development, 2005, 42(1): 72-78.
- [10] 喻高瞻,彭宏,胡劲松,等.时间序列数据的分段线性表示[J].计算机应用与软件,2007,24(12):17-18.

作者简介:

刘永志 男,(1973-),博士研究生,副教授,高级工程师.研究方向为数据挖掘. E-mail: y_zliu@163.com.

皮德常 男,(1971-),博士,教授,博士生导师.研究方向为数据挖掘.

贾学萍 女,(1977-),硕士,讲师.研究方向为农业数据处理.