基于遗传优化的 PCA-SVM 控制图模式识别*

李太福[1†]，胡　胜[2]，魏正元[2]，韩亚军[3]
(1. 重庆科技学院 电气与信息工程学院，重庆 401331；2. 重庆理工大学 数学与统计学院，重庆 400054；3. 重庆科创职业学院 机电技术中心，重庆 永川 402160)

摘　要：针对 SVM 和 PCA-SVM 进行质量控制图模式识别时泛化能力不足和识别精度不高的问题，提出一种基于遗传优化的 PCA-SVM 控制图模式识别方法。该方法的基本思想是首先基于特征子空间降维方法，运用 PCA 算法对原始特征样本进行主元分析，有效降低原始特征样本维数并突出聚类，提取各模式之间的主元特征；然后把此特征看成遗传算法中一组染色体，对支持向量机分类器核参数和惩罚因子进行二进制编码，通过对随机产生的一组染色体进行模式识别，并将此识别率作为遗传算法的适应度函数，通过选择、交叉和变异操作，对其参数进行自适应寻优；最后用优化的支持向量机分类器进行控制图模式识别。通过仿真进行验证，结果显示基于遗传优化的 PCA-SVM 分类器模型的控制图模式泛化能力强、识别精度高，可适用于生产现场质量控制。

关键词：控制图；模式识别；遗传优化；主元分析；支持向量机
中图分类号：TP183　　**文献标志码**：A　　**文章编号**：1001-3695(2012)12-4538-04
doi:10.3969/j.issn.1001-3695.2012.12.035

PCA-SVM for control chart recognition of genetic optimization

LI Tai-fu[1†], HU Sheng[2], WEI Zheng-yuan[2], HAN Ya-jun[3]
(1. *School of Electrical & Information Engineering, Chongqing University of Science & Technology, Chongqing* 401331, *China*; 2. *School of Mathematics & Statistics, Chongqing University of Technology, Chongqing* 400054, *China*; 3. *Center of Machinery & Electronic Technology, Chongqing Creation Vocational College, Yongchuan Chongqing* 402160, *China*)

Abstract: Considering the problem that the precision and generalization are not ideal when recognize the basic patterns of quality control chart in PCA and PCA-SVM modeling, this paper proposed a control chart pattern recognition method based on genetic algorithm and PCA-SVM. The basic idea of the method was that, firstly, in view of the dimensionality reduction in feature space, used principal component analysis algorithm to lower the sample dimension, it also highlighted the clustering features. Then regarded the component characteristics as a chromosome which was then performed with binary code. It used a support vector machine classifier to recognized a random chromosome and considered recognition accuracy as the fitness function to evaluate the fitness of individual feature. By the operations of selection, crossover and mutation, with GA self-adaptive optimizing for penalty parameter and kernel parameter. Finally, it introduced the optimized SVM modeling to identify the control chart pattern. The simulation experimental results demonstrate that the proposed method has higher detection accuracy and stronger generalization ability than other methods, so it is more suitable for quality control in production field.

Key words: control chart; pattern recognition; genetic optimization; principal component analysis(PCA); support vector machine(SVM)

0　引言

控制图是统计工序质量控制的重要工具，被广泛应用于生产现场的质量控制。控制图的模式识别对诊断加工异常因素起着至关重要的作用[1]。根据控制图所呈现的状态，可以判断加工过程是否正常，帮助加工人员找到引起加工异常的因素，揭示潜在的质量问题。但由于加工过程中人、机、料、法、环、测等诸多因素的存在，同时作为质量特性时间序列数据，它具有时变性、非线性、相关性和动态特性，使得对控制图模式精确识别非常困难。利用人工智能技术，捕捉数据之间的特征，从特征子空间的优化出发，减少变量数目是降低模型复杂度、提高识别精度的有效方法。因此，研究质量控制图模式识别中的人工智能方法具有重要价值。

目前国内外学者分别基于原始数据和基于特征两个方面对控制图模式进行智能识别并取得一定成果[2,3]。Psarakis 和 Guh 等人[4,5]使用 BP 神经网络识别控制图基本模式，得到不错的识别效果；Das 等人[6~8]提出运用支持向量机(SVM)对控制图模式进行识别，解决了多品种、小批量控制图模式识别问题；Ebrahimzadeh 等人[9]认为控制图模式的识别分为特征提取模块和模式分类模块，该文中采用径向基函数神经网络对控制图进行模式识别；杨元世等人[10]提出了基于主元分析(PCA)和支持向量机(SVM)的控制图失控模式智能识别方法，该方

收稿日期：2012-05-02；**修回日期**：2012-06-07　　**基金项目**：国家自然科学基金资助项目(61174015,51075418)；重庆市自然科学基金资助项目(CSTC2010BB2285)

作者简介：李太福(1971-)，男(通信作者)，四川资阳人，教授，硕导，博士，主要研究方向智能控制与模式识别(litaifuemail@qq.com)；胡胜(1988-)，男，湖北黄冈人，硕士研究生，主要研究方向为应用统计、质量管理；魏正元(1975-)，男，湖北襄阳人，副教授，硕导，博士，主要研究方向为应用概率、随机过程统计；韩亚军(1980-)，男，甘肃萧山人，讲师，硕士，主要研究方向为机电控制.

法优于直接使用 SVM 分类器进行识别效果。Wang 等人[11]将小波分析和支持向量机结合起来就基本模式进行识别,该方法首先将工序质量数据进行小波包分解,提取各个频带能量信息,然后通过 SVM 进行识别。问题的关键在于小波基函数的选择以及支持向量机参数的选取。

相关研究表明:基于特征的控制图模式分类器识别模型有效提取了样本特征信息,降低了分类器的复杂度,缩短了训练时间,具有一定的泛化能力,优于基于原始数据的分类器模型。但是作为一种新兴的学习机器,SVM 还存在有待完善的地方。其参数选取便是亟待解决的问题之一,惩罚因子 C、核函数以及核函数参数取值的好坏直接影响分类器的识别精度和效率。而遗传算法(genetic algorithm, GA)[12, 13]是一种基于群体的智能寻优算法,具有很强的鲁棒性、隐含并行性和全局搜索特性等优点。鉴于此,本文提出一种基于遗传优化的 PCA-SVM 控制图模式识别方法。从特征子空间的优化出发提取有效样本,采用遗传算法来搜索 SVM 中的最优参数,然后用 SVM 分类器对控制图模式进行识别。最后用实验数据加以验证,并与其他各种分类器识别模型进行了效果对比。

1　控制图模式基本类型与识别原理

在加工过程中,由于受多种因素的交互影响,导致控制图模式的基本类型分为正常模式、向上阶跃异常模式、向下阶跃异常模式、向上趋势异常模式、向下趋势异常模式以及周期模式等六种类型。其基本的数据描述为

$$y(t) = \mu + x(t) + d(t) \quad t = 1, 2, \cdots, N$$

其中:$y(t)$为 t 时刻工序质量特性值;μ 为受控条件下的统计量均值;$x(t)$为在 t 时刻由偶然因素引起的随即扰动,一般是均值为零、方差为 σ^2 的高斯白噪声序列;$d(t)$为异常干扰值。针对 $d(t)$建立各种模式如下:

a)正常模式:$d(t) = 0$。

b)趋势异常模式:$d(t) = \pm\gamma(t - t_0) \times \beta$。其中:+代表逐渐上升,-代表逐渐下降;$t_0$ 为发生趋势的起始点;γ 为趋势异常系数,$t > t_0$ 时,$\gamma = 1$,$t < t_0$ 时,$\gamma = 0$;β 为趋势斜率。

c)阶跃异常模式:$d(t) = \pm 1(t - t_0) \times \alpha$。其中:+代表向上阶跃,-代表向下阶跃;$t_0$ 为发生阶跃的起始点;$1(t - t_0)$为阶跃异常系数,$t > t_0$ 时,$1(t - t_0) = 1$,$t < t_0$ 时,$1(t - t_0) = 0$;α 为阶跃幅值。

d)周期型模式:$d(t) = A\ \sin(2\pi\sin(t - t_0)/T)$。其中:$A$ 为波动的幅值;t_0 为发生周期的起始点;T 为波动的周期长度,即每个周期包含的点子数量。

相应的控制图模式如图 1 所示,其中纵坐标为质量特征幅值,横坐标为质量特性时间序列(以连续 30 个时间序列为例)。

控制图模式识别的基本规则是系统根据已经掌握的每类若干样本的数据信息,总结出分类的规律性而建立的判别公式和判别规则,然后在遇到新的质量特性时间序列时,根据总结出的判别规则,确定控制图模式所属的类别。

在控制图模式识别过程中,需要识别的基本模式有六种。而 SVM 是一种有效解决小样本识别问题的分类器,在较少样本的情况下仍能获得较高的精度和较强的泛化能力,特别适合解决过程异常模式识别问题。基于以上考虑,本文采用支持向量机分类器进行控制图基本模式识别,并选取高斯核函数作为支持向量机的核函数来进行研究,因为高斯核函数不需要依赖任何先验知识,总是具有光滑而又简单的估计,并对任意分布的样本都表现出较好的泛化性能,可以逼近任意非线性核函数[14]。高斯核函数为

$$K(x_i, x) = \exp(-\| x - x_i \|^2 / 2\sigma^2)$$

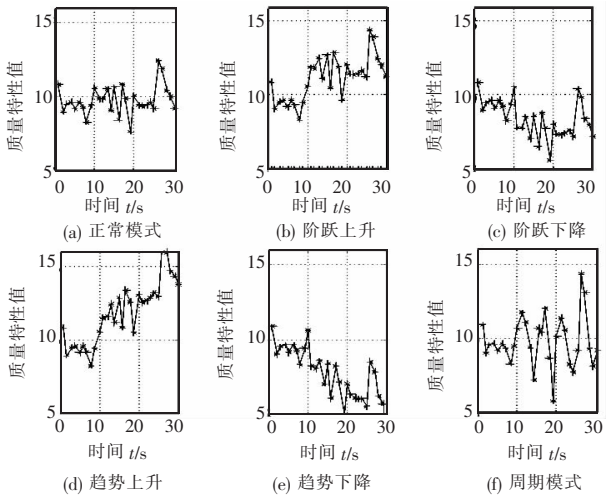

图 1　质量控制图的基本模式

2　遗传优化的 PCA-SVM 控制图模式识别方法

2.1　PCA-SVM 特征提取与模式识别

传统 SVM 方法在解决实际问题时,没有考虑输入变量之间的关系。由于控制图异常模式特征之间存在较大的相似性,导致样本信息过度重复的情况。因此本文首先运用 PCA 方法,对样本信息进行有效降维,改进训练样本的多重共线性,有效抑制测量数据中的噪声,剔除传感器列阵中的冗余信息,解决传统 SVM 方法特征指标解释冗余的问题,并在一定程度上突出聚类特征,为建立合适的多分类 SVM 分类器模型做准备。

2.2　遗传优化的 SVM 参数优化算法

相关研究表明[15],支持向量机的分类精度与其训练参数存在一定关系。因此在进行控制图模式识别时,如果核函数参数或惩罚因子 C 等参数选择不合理,就会降低 SVM 分类器的识别率。最优的 C 是随特征子空间的不同而变化,当 C 超过一定值时,SVM 的复杂度达到了样本空间允许的最大值,此时经验风险和泛化能力几乎不再变化。假设选择 RBF 核函数,其参数 σ 越大,样本的输出响应区间越宽,得到的最优分类面结构风险越小,但是经验风险会增大;而 σ 越小,样本的输出响应区间越窄,得到的最优分类面经验风险会越小,但是结构风险会增大,而且容易造成过拟合现象,降低 SVM 的性能。所以,选择合适的支持向量机参数就能获得性能优越的支持向量机分类器。因此本文拟采用遗传算法进行支持向量机的参数寻优。寻优流程如图 2 所示,具体实现步骤如下:

a)编码和产生初始种群。本文采用实数方式对支持向量机分类器的惩罚因子和径向基核参数进行二进制编码,且设定

C 和 σ 的搜索空间分别为(0,100)、(0,100),初始种群随机产生。

b)解码和计算识别率。对种群中的染色体进行解码,利用交叉验证原理,将一部分训练样本作为训练集,剩余训练样本作测试集,获得支持向量机分类器识别率。

c)确定适应度函数。一个适当的适应度函数是遗传算法能否成功解决问题的关键,直接影响到遗传算法的收敛速度以及能否找到最优解。本文充分考虑控制图识别的特点,以获得的识别率作为计算每个染色体的适应度值,计算公式为

$$f(X) = n/N$$

其中:n 为支持向量机分类器对染色体中控制图特征的正确识别数,N 表示染色体中控制图特征的识别总数。

d)遗传操作(选择、交叉、变异)。如果满足最大迭代数目或小于给定的精度,则停止计算,输出最优染色体;否则执行选择、交叉和变异等操作,以产生新一代种群。本文分别采用选择轮盘赌法,即基于适应度比例的选择策略进行选择操作;使用单点交叉进行交叉操作;而变异操作是遗传算法的一个辅助性操作,采用基本位变异算子。

e)获取最优参数。将最优染色体进行解码,从而获得最优参数。采用训练数据训练最优参数对应支持向量机分类器,最终获得优化的支持向量机分类器。

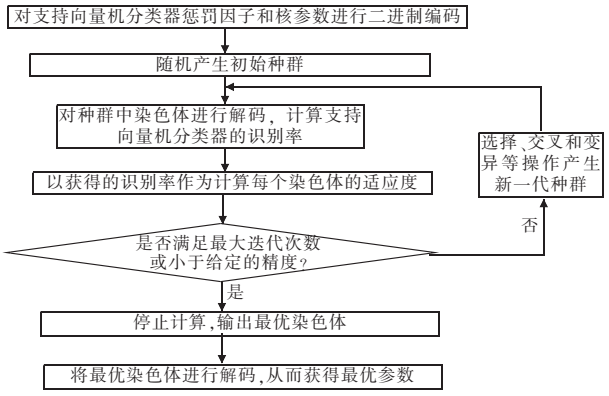

图 2 支持向量机参数优化流程图

2.3 遗传优化的 PCA-SVM 控制图模式识别模型基本框架

控制图模式识别是指利用统计分析或人工智能方法,对质量特性时间序列数据进行处理和分析,挖掘加工过程隐含工况信息的特性、状态和变化趋势,判断控制图所呈现的状态,并能对未来时刻的控制图模式进行识别,从而为确定异常过程发生的原因和部位、寻找和确定质量改进的措施提供更多的诊断信息。

本文首先根据控制图的基本模式随机模拟生成样本集,每种模式各生成 400 个样本组成受控样本集(R_1),周期样本集(R_2),趋势上升、下降样本集(R_3,R_4)和阶跃上升、下降样本集(R_5,R_6),并抽取每种模式样本集中的前 200 个样本组成训练样本集(S_1,S_2,S_3,S_4,S_5,S_6),余下样本组成检验样本集合(T_1,T_2,T_3,T_4,T_5,T_6)。将训练样本集合标准化处理,利用主元分析(PCA)方法对特征集合进行维度约简,并提取聚类特征,在特征子空间中组合成特征向量作为输入;然后基于遗传优化的 SVM 算法建立质量控制图模式识别模型,对下一采样时刻的控制图模式进行识别,以此判断加工工况正常与否。控制图模式识别模型的建立过程如图 3 所示。

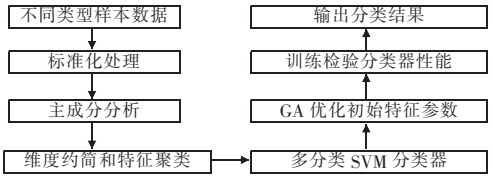

图 3 基于遗传优化的 PCA-SVM 控制图模式识别

3 仿真实验

3.1 PCA 算法质量特征数据聚类特征提取

将训练数据集合组成样本矩阵,并对其进行主成分分析。表 1 给出了 PCA 分析后各主成分特征值、贡献率以及累计贡献率。

表 1 PCA 分析后各主成分特征值和贡献率

主成分	特征值	贡献率/%	累计贡献率/%
PC_1	15.345 5	51.151 7	51.151 7
PC_2	1.30628	4.354 2	55.506 0
PC_3	1.2173 2	4.057 7	59.563 7
PC_4	1.1953 3	3.984 4	63.548 2
PC_5	1.1126 1	3.708 7	67.256 9
PC_6	1.0834 7	3.611 5	70.868 5
PC_7	1.0328 4	3.442 8	74.311 3
PC_8	0.9978 4	3.326 1	77.637 4
PC_9	0.9284 3	3.094 7	80.732 2
PC_{10}	0.8876 8	2.958 9	83.691 2
PC_{11}	0.8162 9	2.720 9	86.412 2
PC_{12}	0.7851 5	2.617 1	89.029 4
PC_{13}	0.4692 7	1.564 2	90.593 6
⋮	⋮	⋮	⋮
PC_{29}	0.086 5	0.288 2	99.724 6
PC_{30}	0.082 6	0.275 4	100

由表 1 可知,第 1 主成分的方差在总方差中的比重为 51.15%,它是控制图各个模式难以识别的重要因素。前 12 项主成分的方差在总方差中的比重为 89.03%,原始过程样本特征分布和使用 PCA 方法后的特征分布效果如图 4 所示(详见电子版)(每种模式均含 50 个样本)。因为原始过程样本特征共有 30 维,本文均匀抽取第 1 维、第 10 维和第 30 维特征进行投影(如图 4(a)(b)(c)所示),其余各维投影相似。经过 PCA 处理之后的样本在特征子空间投影如图 4(d)(e)(f)所示。显然,在图 4(d)中所有测试样本可清晰地分为六类,即受控类、周期类、阶跃上升类、阶跃下降类、趋势上升类和趋势下降类,而受控类和周期类样本之间有少量重叠,说明原始特征信息还有损失,因而又依次引入前 12 个主成分,用于区别受控类和周期类之间难以区别的信息,使识别信息增加到 89.03%,其效果见图 4(e)(f)。

显而易见,通过 PCA 方法不但降低了过程样本维数,而且使得混杂在一起的过程样本原始特征在主元空间中的分布有明显改善,而且在一定程度上突出了聚类特征,按照主成分的选取标准,说明这 12 项主成分可以代替原来的 30 项指标变量,从而可以更简单地利用它作为网络的输入节点数,精简化后续 SVM 分类器的网络模型结构。

3.2 SVM 参数寻优

取交互验证的次数 v 为 5,选取遗传算法操作过程的相关参数如下:种群个体数为 20,最大遗传代数为 200,遗传代沟为

$P_c=0.9$。单参数 ε 的选取相当于一个一维优化问题,给定 ε 的取值范围并离散化,取不同的离散值使遗传算法目标函数值最大,经计算选 ε 为 0.01。遗传算法进化的过程如图 5 所示,经 8 次遗传迭代后,种群的最佳适应度函数就几乎达到稳定,且检验样本的交互识别率达到了 99.91%,最优的支持向量机参数惩罚因子 $C=4.135\ 6$,径向基核函数参数 $\sigma=1.835\ 8$,此时可认为达到了近似最优解。而种群平均适应度函数的平均值上下波动表明种群是有活力的,平均适应度值接近最佳适应度值,说明种群中每个个体都在最优解周围。

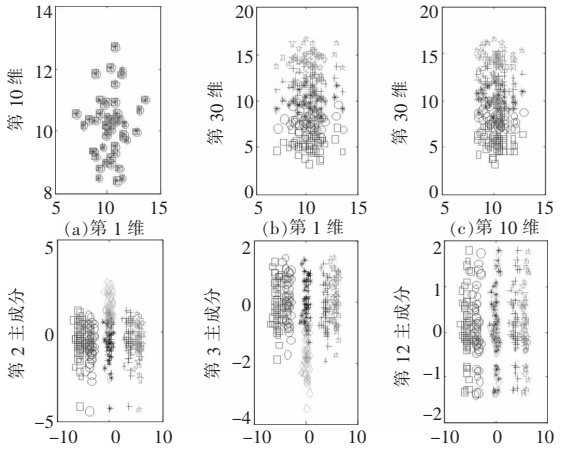

图 4　过程样本集主元分析前后效果对比

3.3　多分类 SVM 分类器控制图模式识别

针对控制图模式的特点以及过程样本 PCA 预处理后的特征分布情况,设计五个遗传算法优化的 SVM 分类器(GA-SVM),以识别正常模式和其他不同的类型异常模式。具体结构如下:第一个分类器($GA\text{-}SVM_1$)识别过程是否正常,当 $GA\text{-}SVM_1$ 输出为 1 时,过程处于正常受控状态;$GA\text{-}SVM_2$ 识别过程是否为周期,当 $GA\text{-}SVM_2$ 输出为 1 时,过程处于周期异常状态;$GA\text{-}SVM_3$ 识别过程异常是否为上升型异常,当 $GA\text{-}SVM_3$ 输出为 1 时,过程处于上升异常状态;最后再分别用 $GA\text{-}SVM_4$ 和 $GA\text{-}SVM_5$ 两个分类器识别趋势型和阶跃型异常状态,从而完成六种控制图的模式识别任务。

3.3.1　不同核函数的支持向量机分类器比较

为了验证本文选取高斯核函数的合理性,将其与常用的多项式核函数的控制图模式识别结果进行比较,统计其各自的总识别率。总体识别率是指被正确判断的模式总数占测试样本总量的百分比,可以反映模式识别的精确性和准确度。其测试结果如表 2 所示。

表 2　高斯核函数与多项式核函数识别率比较

核函数类型	核参数	总识别率	各种模式识别率/%					
			正常模式	周期模式	上升趋势	下降趋势	向上阶跃	向下阶跃
多项式核函数	$d=2$	99	100	100	98	100	99	97
高斯核函数	$\sigma=1.835\ 8$	99.77	100	100	100	100	99	100

3.3.2　与其他分类器模型的比较

为了进一步检验 PCA-GA-SVM 分类器模型性能的好坏,本文分别采用普通支持向量机分类器、基于 PCA 改进的支持向量机分类器以及 BP 神经网络分类器(BPNN)进行对比分析,识别精度作为评价检测模式性能优劣的标准,识别精度越高对应模型性能越好。四种不同模型的识别效果如图 6 所示,可以看出,基于遗传优化的 PCA-SVM 分类器模型识别精度达到了 99.8%,远高于 PCA-SVM 分类器(PCA-SVM)、支持向量机分类器(SVM)和 BP 神经网络分类器(BPNN)。

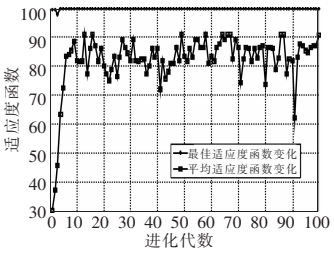

图 5　遗传进化的过程

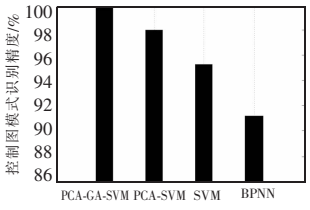

图 6　不同分类器模型识别效果对比

4　应用实例

现以某公司的电机自动流水生产线转子生产工序为例,采用基于遗传优化的 PCA-SVM 控制图模式识别方法对加工过程控制图进行模式识别。连续采集转子直径的 100 个数据,其均值控制图如图 7 所示,将样本数据进行归一化处理,滚动输入进行 PCA 特征提取,然后基于遗传优化的 SVM 分类器对其进行模式识别。识别效果如下:当输入到第 31 个样本数据时,识别出有阶跃上升异常常模式存在;当输入到第 64 个样本数据时,识别出趋势上升异常模式存在。

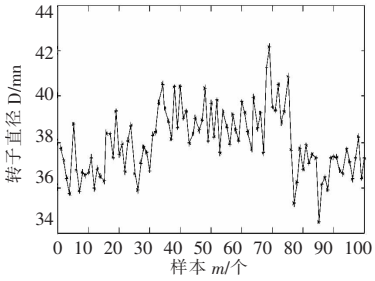

图 7　某电机转子直径的均值控制图

将上述识别结果对比控制图,其分析结果与控制图显示的状态基本相符。可见,利用基于遗传优化的 PCA-SVM 控制图模式识别方法来识别加工过程异常状态是可行的。

5　结束语

控制图的模式识别对诊断加工异常因素有着至关重要的作用,本文提出了一种基于遗传优化的 PCA-SVM 控制图模式识别方法。PCA-GA-SVM 方法以测量质量特性的时间序列作为识别模型的输入,具有以下特点:

a)首先利用 PCA 方法对时间序列进行特征提取,不仅有效抑制了测量数据中的噪声,而且能够剔除传感器列阵中的冗余信息,降低分类器模型的复杂度。

b)利用自适应遗传算法的全局搜索能力对 SVM 的参数进行动态选取,实现了 SVM 分类器参数的自动最优选择,解决了对其性能有重大影响的核函数参数的确定问题。

c)SVM 模式识别方法采用结构风险化原理,兼顾训练误差和泛化能力,克服了神经网络的不足。在解决小样本、非线性及高维模式识别问题中表现出许多优势。

因此,采用 PCA-GA-SVM 进行模式识别,既发挥了 PCA 的特征提取能力、GA 全局搜索能力和 SVM 良好的分类能力,又避免了复杂的计算,精简化分类器的　(下转第 4545 页)

路径 1:(0,0)-(8,2)-(2,1)-(0,0)

路径 2:(0,0)-(4,1)-(0,0)

路径 3:(0,0)-(1,1)-(11,1)-(6,1)-(5,2)-(0,0)

路径 4:(0,0)-(12,1)-(7,1)-(3,2)-(10,2)-(0,0)

实验结果如图 2 所示。

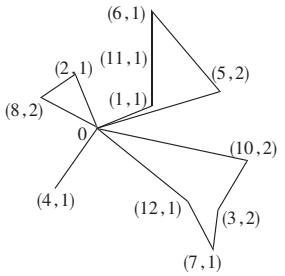

图 2　客户点连接路径

将本文方法与文献[5,6]以及经典禁忌算法进行比较,得到的路径长度随着迭代次数增加的变化如图 3 所示。

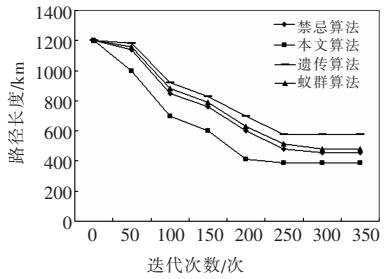

图 3　路径长度随迭代次数变化曲线

从图 3 可以看出,本文的协同自适应算法在迭代 200 次时趋于收敛,得到的路径长度为 386.38;遗传算法在迭代 250 次时趋于收敛,但其路径长度为 576.89,很显然算法陷入了局部最优;蚁群算法和禁忌算法在迭代到 300 次时趋于收敛,得到的路径长度分别为 481.57 和 453.62,显然本文方法最优。这是由于禁忌算法采用记忆机制从而具有较强的局部搜索能力,同时本文采用 C-W 方法求解初始值,并采用协同禁忌算法进行寻优,所以使得全局寻优能力更强,结果更符合真实值。

4　结束语

多时间窗的 VRP 是一个 NP 难题,本文在对传统禁忌算法改进的基础上提出了一种协同自适应算法用于解决多时间窗 VRP。采用 C-W 算法求初始解,提出了采用四种邻域算子进行邻域搜索,在此基础上采用子禁忌算法和主禁忌算法进行协同寻优,并自适应地修改禁忌长度以满足算法需要。通过实例仿真证明,该算法提高了全局搜索能力,改善了解的质量,同时具有计算效率高、计算结果稳定的优点。

参考文献:

[1] LANTUEJIUL C, MAISONNEUVE F. Geodesic methods in quantitative image analysis[J]. Pattern Recognition, 1984, 17(2): 177-187.

[2] BLANTON J L, WAINWRIGHT R L. Multiple vehicle routing with time and capacity constraints using genetic algorithms[C]//Proc of the 5th International Conference on Genetic Algorithms. 1993: 452-459.

[3] 宋伟刚,王聪,赵玲. 大规模客户车辆调度问题启发式算法研究[J]. 系统仿真学报,2008,20(14):3696-3701.

[4] CHEN J F, WU T H. Vehicle routing prob lem with simultaneous deliveries and pickups[J]. Journal of the Operational Research Society, 2006, 57(5): 579-587.

[5] 黄明,林广智,梁旭,等. 改进的遗传算法在车辆路径问题中的应用[J]. 大连交通大学学报,2010,31(1):95-99.

[6] 段征宇,杨东援,王上. 时间依赖型车辆路径问题的一种改进蚁群算法[J]. 控制理论与应用,2010,27(11):1557-1563.

[7] 娄山佐, 史忠科. 有限车辆调度问题的模型和改进遗传算法[J]. 计算机应用研究,2006,23(4):61-62.

[8] 葛金辉. 有时间窗的车辆路径问题及改进禁忌搜索算法[J]. 吉林大学学报, 2011,49(1):105-111.

[9] 王训斌,陆慧娟,张火明. 物流动态车辆调度问题的混合禁忌搜索算法[J]. 计算机工程与应用,2010,46(8):228-231.

[10] 李建,鲁植雄,高谋荣. 大规模同时集散货物路线问题的新禁忌搜索算法设计[J]. 西南交通大学学报,2009,44(5):787-793.

(上接第 4541 页)网络结构、提高分类器泛化能力和识别效率。

参考文献:

[1] BAIK J W, KANG H W, KANG C W, *et al*. The optimal control limit of a G-EWMAG control chart[J]. The International Journal of Advanced Manufacturing Technology, 2011, 56(1): 161-175.

[2] RANAEE V, EBRAHIMZADEH A. Control chart pattern recognition using neural networks and efficient features: a comparative study[J]. Pattern Analysis & Applications, 2011, 10(1): 1-12.

[3] GAURI S K, CHAKRABORTY S. Recognition of control chart patterns using improved selection of features[J]. Computers & Industrial Engineering, 2009, 56(4): 1577-1588.

[4] PSARAKIS S. The use of neural networks in statistical process control charts[J]. Quality and Reliability Engineering International, 2011, 27(5): 641-650.

[5] GUH R S, HSIEH Y C. A neural network based model for abnormal pattern recognition of control charts[J]. Computers & Industrial Engineering, 1999, 36(1): 97-108.

[6] DAS P, BANERJEE I. An hybrid detection system of control chart patterns using cascaded SVM and neural network-based detector[J]. Neural Computing and Applications, 2011, 20(2): 287-296.

[7] 杨元世,吴德会,苏海涛. 基于支持向量机技术的智能工序诊断研究[J]. 微电子学与计算机, 2006,23(5):42-45.

[8] 吴常坤,赵丽萍. 基于小波分析和支持向量机的控制图模式识别[J]. 中国机械工程, 2010,21(13):1572-1576.

[9] EBRAHIMZADEH A, RANAEE V. Control chart pattern recognition using an optimized neural network and efficient features[J]. ISA Transactions, 2010, 49(3): 387-393.

[10] 杨元世,吴德会,苏海涛. 基于 PCA 和 SVM 的控制图失控模式智能识别方法[J]. 系统仿真学报, 2006,18(5):1314-1318.

[11] WANG C H, KUO W. Identification of control chart patterns using wavelet filtering and robust fuzzy clustering[J]. Journal of Intelligent Manufacturing, 2007, 18(3): 343-350.

[12] HOUCK C R, JOINES J A, KAY M G. A genetic algorithm for function optimization: a matlab implementation NCSU-IE TR 95-09[R]. 1995.

[13] HARVEY I. The microbial genetic algorithm[J]. Advances in Artificial Life. Darwin Meets von Neumann, 2011, 5778: 126-133.

[14] SCHÖLKOPF B, SMOLA A J. Learning with kernels[M]. Cambridge: MIT Press, 2002.

[15] VAPNIK V. 统计学习理论的本质[M]. 张学工,译. 北京:清华大学出版社,2000.