

文章编号: 1000-8055(2005)06-0969-04

基于离散粒子群优化算法的直升机 减速器齿轮故障特征选择

王新峰, 邱 静, 刘冠军

(国防科技大学 机电工程与自动化学院, 湖南 长沙 410073)

摘要: 粒子群优化算法自提出以来, 由于其容易理解、易于实现, 所以发展很快, 在很多领域得到了应用。本文针对机械故障特征选择问题, 提出基于离散粒子群优化(PSO)算法的特征选择方法, 并在直升机减速器齿轮故障诊断中进行了应用。实验结果表明, 离散 PSO 算法可以快速、有效的求得优化特征集, 是求解故障特征选择问题的一个较好方法。

关键词: 航空、航天推进系统; 特征选择; 离散粒子群优化; 减速器诊断

中图分类号: TH133

文献标识码: A

Discrete Particle Swarm Optimization Algorithm for Gearbox Fault Symptom Selection

WANG Xin-feng, Q U Jing, L U Guan-jun

(College of Mechatronics Engineering and Automation,

National University of Defense Technology, Changsha 410073, China)

Abstract: Particle swarm optimization (PSO) has been developed rapidly and has been applied widely since it is easy to understand and realize. Aimed at mechanical fault symptom selection, the paper proposed a discrete Particle Swarm Optimization (PSO) algorithm. In order to improve the ability to escape from the local optimum, the mutation operator was added to the algorithm. The discrete PSO algorithm was applied to helicopter gearbox gear fault symptom selection. Symptom set extracted by wavelet packet transform method was presented by binary-coded particle. The accuracy evaluated by k-fold cross-validation of the SVM classifiers was used as the particle fitness. Experimental results indicate that the discrete PSO can get the same optimal symptom subset as that from genetic algorithm, and achieve the better diagnosis accuracy, but the compute time consumed is only 0.4 time that of genetic algorithm, so the discrete PSO is a more effective method for mechanical fault symptom selection problem.

Key words: aerospace propulsion system; symptom selection;

discrete Particle Swarm Optimization (PSO); gearbox diagnosis

在机械故障诊断中, 由信号处理得到的故障特征集中常含有两类冗余特征: (1) 与分类目标无

关的特征; (2) 与其他特征量有较高相关性的特征。这些特征会影响最后的诊断性能。所以在故

收稿日期: 2004-11-26; 修订日期: 2005-03-14

基金项目: 国家部委级预研基金资助(41319040202)

作者简介: 王新峰(1977-), 男, 山东曲阜人, 国防科技大学机电工程与自动化学院博士生, 主要从事状态监控与故障诊断研究

障识别之前,必须对故障特征集进行特征选择,即从一组数量为 D 的特征中选择出数量为 d ($D > d$)的一组最优特征来,使得分类错误率最小^[1,2]。特征选择是一个组合优化问题,当特征维数较大时,为了避免大量的时间消耗,须采用某些搜索技术以缩小搜索域,获得次优解。先后出现了一般启发式算法和遗传算法、禁忌搜索和模拟退火等智能化启发式算法,也取得了一些较好的效果^[3,4]。

粒子群算法(PSO, Particle Swarm Optimization)是最近出现的一种模拟鸟群捕食行为的仿生算法,是由Eberhart与Kennedy发明的一种新的全局优化进化算法^[5,6]。它有着个体数目少、计算简单、鲁棒性好等优点。最初的PSO是用来解决连续优化问题,后来Mohan等又提出了离散PSO用来解决工程实际中的组合优化问题^[7,8]。本文把此算法应用到直升机减速器齿轮故障特征选择中,结果证明,该算法取得了很好的效果,提高了诊断精度,而且比常用的遗传算法具有更快的优化速度。

1 离散 PSO 算法

PSO算法源于对鸟类捕食行为的模拟^[5]。一群鸟在随机搜寻食物,如果这个区域里只有一块食物,那么找到食物的最简单有效的策略就是搜寻目前离食物最近的鸟的周围区域。PSO算法粒子群优化算法与遗传算法类似,同样基于群体与适应度的概念^[8],粒子位置代表问题的可能解,它通过粒子适应度来衡量粒子的优劣。假设在一个 D 维的目标搜索空间中,有 m 个粒子组成一个群落,其中第 i 个粒子表示为一个 D 维的向量 $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})^T$, $i = 1, 2, \dots, m$ 。即第 i 个粒子在 D 维的搜索空间中的位置是 x_{i0} 。换言之,每个粒子的位置就是一个潜在的解。将 x_i 带入一个目标函数就可以计算出其适应值,根据适应值的大小衡量 x_i 的优劣。第 i 个粒子的“飞翔”速度也是一个 D 维的向量,记 $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})^T$ 。记第 i 个粒子迄今为止搜索到的最优位置为 $pbest_i = (pbest_{i1}, pbest_{i2}, \dots, pbest_{iD})$,整个粒子群迄今为止搜索到的最优位置为 $gbest_0 = (gbest_1, gbest_2, \dots, gbest_D)$ 。粒子在找到上述两个极值后,就根据下面两个公式来更新自己的速度与位置^[1,2]:

$$v_{id}^{k+1} = w \cdot v_{id}^k + c_1 \cdot r_1^k \cdot (pbest_{id}^k - x_{id}^k) + c_2 \cdot r_2^k \cdot (pbest_d - x_{id}^k) \quad (1)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (2)$$

其中, $i = 1, 2, \dots, m$, $d = 1, 2, \dots, D$, v_{id}^k 是粒子在第 k 次迭代中第 d 维的速度; r_1, r_2 是 $(0, 1)$ 之间的随机数, c_1 和 c_2 被称作学习因子,通常 $c_1 = c_2 = 2$; w 是加权系数,取值在 0.1 到 0.9 之间。 x_{id}^k 是粒子 i 在第 k 次迭代中第 d 维的当前位置; $pbest_{id}$ 是粒子 i 在第 d 维的个体极值点的位置(即坐标); $gbest_d$ 是整个群在第 d 维的全局极值点的位置。为防止粒子远离搜索空间,粒子的每一维速度 $v_i \in [-v_{max}, v_{max}]$, v_{max} 是常数,由用户设定。粒子通过不断学习更新,最终飞至解空间中最优解所在的位置,整个搜索过程结束。最后输出的 $gbest$ 就是算法找到的全局最优解。迭代中止条件根据具体问题一般选为最大迭代次数或粒子群迄今为止搜索到的最优位置满足预定最小适应阈值。

上面PSO算法是解决连续优化问题的,为解决工程实际中的组合优化问题,Mohan and Arkazemi提出了一种离散PSO算法^[7]。他们在提出的模型中将每一维 x_{id} 限制为1或者为0,而速度 v_{id} 不作这种限制。速度看作粒子位置改变的概变大小,如果 v_{id} 高一些,粒子的位置 x_{id} 更有可能选0, v_{id} 低一点则 x_{id} 选1。

具体算法如下:

$$Pbest_{id}^k = \alpha \cdot pbest_{id}^{k-1} + \beta \cdot (1 - pbest_{id}^{k-1}) \quad (3)$$

$$Gbest_{id}^k = \alpha \cdot gbest_{id}^{k-1} + \beta \cdot (1 - gbest_{id}^{k-1}) \quad (4)$$

$$v_{id}^{k+1} = c_1 \cdot v_{id}^k + c_2 \cdot Pbest_{id}^k + c_3 \cdot Gbest_{id}^k \quad (5)$$

$$\text{if } v_{id}^{k+1} < \rho \begin{cases} \text{then } x_{id}^{k+1} = 1 \\ \text{else } x_{id}^{k+1} = 0 \end{cases} \quad (6)$$

其中, $\alpha + \beta = 1$, $0 < \alpha, \beta < 1$ 。 α 为粒子位置为1的控制度。 α 越小,粒子为1的可能性越大。 $c_1 + c_2 + c_3 = 1$, $0 < c_1, c_2, c_3 < 1$,代表对速度本身,局部最优,全局最优的加权。阈值 ρ 是 $[0, 1]$ 之间的随机数。此算法在解决组合优化问题中取得了较好的效果^[8],因此本文采用此算法解决特征选择问题。

在PSO运行过程中,如果某粒子发现一个当前最优位置,其他粒子将迅速向其靠拢。如果该最优位置为一局部最优点,粒子群就无法在解空间内重新搜索,此时算法陷入了局部最优。为了避免算法过早地陷入局部最优解,引入变异算子加以解决。在粒子群中选取除最优个体外的部分个体进行变异操作。由于过高的变异会使得搜索时间大大增加。选择每次平均一个粒子只有1维数据发生变异,即变异率为 $1/D$ 。

离散PSO算法步骤为:(1)初始化粒子群位

置速度; (2) 对粒子群粒子进行性能评价, 并记录局部最优位置 p_{bestid}^k 和全局最优位置 g_{bestid}^k ; (3) 按公式 (5), (6) 计算 P_{bestid}^k 和 G_{bestid}^k ; (4) 由公式 (7), (8) 更新粒子速度和位置; (5) 选取除最优粒子外的粒子按概率 $1/d$ 进行变异操作; (6) 判断是否达到一定的迭代次数, 如果达到, 执行 (7); 否则转向 (2); (7) 输出最优目标值和粒子, 算法运行结束。

2 基于离散 PSO 的特征选择方法

使用离散 PSO 算法进行特征选择, 需要设定特征的粒子群表达和适应度计算方法。

2.1 基于小波包分解的故障特征生成与粒子群表达

直升机减速器齿轮故障类型包括两种最为常见的局部性故障——点蚀和裂纹。由于减速器工作时, 引起其振动的因素很多, 通过安装在减速器上的振动传感器所拾取的振动信号是非常复杂的宽带信号。所以采用小波包分解的方法来进行信号预处理。对信号经过小波包 5 层分解后, 可以得到 32 个特征频带的小波包系数。各频带宽为 $10 \text{ kHz}/32 = 156.25 \text{ Hz}$, 由低到高分布, 如频带 1 的范围为 $0 \text{ Hz} \sim 156.25 \text{ Hz}$, 频带 2 的范围为 $156.25 \sim 312.5 \text{ Hz}$, 依次类推。然后利用小波包能量谱的方法得到原始特征。在小波包能量谱中, 选取各个频带内信号的平方和作为能量的标志。对于频带 ω , 小波包变换结果用序列 $\{\omega(k), k = 1, 2, \dots, M\}$ 表示, 其中 M 为该频带的样本长度。由于小波包分解后的各频带宽度相同, 因此利用小波包分解的结果作为能量谱的输入, 则各频带的能量为:

$$G_i = \sum_{k=1}^M |\omega(k)|^2 \quad (7)$$

令 $G = \sum_{i=1}^{32} G_i$, 可以计算出各频带的相对能量比值, 即 $G_i = G_i/G$, 此作为故障样本特征, 由此得到含有 32 个特征的原始特征集合。

在离散 PSO 算法中, 特征向量可以用一个二进制向量来表示粒子 $X = (x_1, x_2, \dots, x_{32})^T$, $x_d \in \{0, 1\}$, $d = 1, \dots, 32$ 。如果 X 的第 d 位为 1, 则此特征被选中; 如果为 0, 则此特征未被选中。

2.2 粒子适应度计算

PSO 通过适应度来确定粒子当前位置的优劣, 这里适合度即为特征集性能评价, 特征集性能

评价准则可以分为 3 类: 准确性度量, 一致性度量以及经典度量。准确性度量用机器学习算法的准确率来评估特征子集的优劣。一致性度量用样本集中不一致样本率来评估特征子集的优劣。经典度量包括信息度量, 距离度量以及相关性度量等。这里采用准确性度量, 采用支持向量机 (Support Vector Machine, SVM) 作为学习分类器对特征样本进行训练并估计特征集的准确率。SVM 基于结构风险最小化原则, 它具有较强的推广能力, 可以在有限样本的基础上取得良好的分类效果^[9, 10], 所以目前得到越来越多的应用。

SVM 通过将低维的输入空间数据 $x \in R^n$ 通过非线性映射函数映射到高维属性空间 H , 映射记为 $x \rightarrow \Phi(x) \in H$, 在此高维空间找到最优分类超平面。这种映射是通过核函数实现的^[11]。

为简化计算, SVM 核函数选择 RBF 核函数, 相应的参数 $\sigma = 1$, 即核函数为:

$$K(x_i, x_j) = e^{-\frac{\|x_i - x_j\|^2}{2}} \quad (8)$$

为了得到较好的准确率估计, 采用样本划分法 (k -folds Cross-Validation) 来估计设计特征集的正确率。它把样本分为 k 个部分, 每次取其中一部分作为检验样本集, 剩下的为设计样本集, 得到一系列正确率估计, 最后取平均得到较合理的正确率估计。其中 k 越大, 估计的正确率也越精确, 同时计算时间越长。综合考虑计算精度和效率, 本文选择 $k = 5$ 。估计得到准确率作为特征的性能评价即粒子的适应度。

3 基于离散 PSO 的特征选择结果

实验对象为某直升机中减速器中的齿轮, 数据在中减速器试车台测得。故障部位为输入齿轮, 齿数为 29。额定啮合频率为 1689 Hz 。选定采样频率为 10 kHz 。根据直升机的工作状况, 对 5 种工作 (负载) 状况下减速器进行了试验, 每种工况 10 次重复采样, 总共有 3 种状况即: 正常、点蚀和裂纹, 得到 150 个样本, 每种情况 50 个样本。

为了说明此离散 PSO 的优化能力, 与遗传算法作对比。对于离散 PSO 而言, 作如下的参数设定: 群体大小为 30, $\alpha = 0.3$, $c_1 = c_2 = 0.1$, 粒子群的最大进化代数设置为 30。对于 GA 而言, 作如下的控制参数设定: 群体规模大小为 30, 杂交概率为 0.9, 变异概率为 0.09, 最大遗传代数为 30。最后得到的优化结果如图 1、图 2 所示。

从图 1、图 2 中可以看出, 遗传算法和离散

PSO 算法都能在有限的进化代数内找到其最优解, 经过特征选择后, 准确率得到了提高。又遗传算法是在迭代 22 次找到优化特征, 而粒子群优化




图 1 遗传优化结果

Fig 1 Result of genetic optimization




图 2 粒子群优化结果

Fig 2 Result of discrete particle swarm optimization




图 3 特征随迭代次数的变化

Fig 3 Features selected change with optimization iterations

算法仅 9 次迭代找到优化结果。所以粒子群优化算法的优化效率较高。通过 10 次计算测试, 离散 PSO 算法的平均计算时间为 4.438 s, GA 算法的

平均计算时间为 10.848 s。图 3 为离散 PSO 算法特征随迭代次数的变化, 其最后的优化结果为最优特征集为第 9, 14 频带能量特征。

4 结 论

机械故障特征选择是一个组合优化问题。本文介绍了一种新的优化算法—离散 PSO 算法, 并对其作了改进, 应用在机械故障特征选择中。减速器齿轮故障特征选择结果表明, 离散 PSO 算法相比遗传算法除了有同样的全局优化性能外, 它的优化效率要比遗传算法高, 能够以更短的时间搜索出最优特征。

参考文献

- [1] 边肇祺, 张学工. 模式识别[M]. 第二版. 北京: 清华大学出版社, 2000.
- [2] Liu H, Motoda H. Feature Selection for Knowledge Discovery and Data Mining[M]. Boston: Kluwer Academic Publishers, 1998.
- [3] 张鸿宾, 孙广煜. Tabu 搜索在特征选择中的应用[J]. 自动化学报, 1999, 25(4): 458~466.
Zhang Hong-bin, Sun Guang-yu. Tabu Search Algorithm for Feature Selection[J]. Acta Automatica Sinica, 1999, 25(4): 458~466.
- [4] 史东锋, 屈梁生. 遗传算法在故障特征选择中的应用研究[J]. 振动、测试和诊断, 2000, 20(3): 171~176.
Shi Dong-feng, Qu Liang-sheng. Application of Genetic Algorithm to Fault Feature Selection[J]. Journal of Vibration, Measurement and Diagnosis, 2000, 20(3): 171~176.
- [5] Kennedy J, Eberhart R C. Particle Swarm Optimization[A]. IEEE International Conference on Neural Networks[C]. Perth, Australia: 1995: 1942~1948.
- [6] Shi Y, Eberhart R C. A Modified Swarm Optimizer[A]. IEEE International Conference of Evolutionary Computation[C]. Anchorage, Alaska: 1998: 69~73.
- [7] Kennedy J, Eberhart R C. A Discrete Binary Version of the Particle Swarm Algorithm[A]. Proc Conf on Systems, Man, and Cybernetics[C]. Piscataway, NJ, 1997: 4104~4108.
- [8] Mohan C K, Alkazen i B. Discrete Particle Swarm Optimization[A]. Proc Workshop on Particle Swarm Optimization, Indianapolis, IN: Purdue School of Engineering and Technology[C]. IUPUI, 2001.
- [9] Vapnik V N. Statistical Learning Theory[M]. New York: Wiley, 1998.
- [10] Burges J C. A Tutorial on Support Vector Machines for Pattern Recognition[J]. Data Mining and Knowledge Discovery, 1998, 2: 121~167.
- [11] Hsu C W, Lin C J. A Comparison of Methods for Multi-Class Support Vector Machine[J]. IEEE Transactions on Neural Networks, 2002, 13(2): 415~425.