

文章编号:1000-8055(2009)07-1639-05

基于免疫粒子群算法的滑油屑末 支持向量机预测模型设计

李本威, 张 赟, 孙 涛

(海军航空工程学院 飞行器工程系, 烟台 264001)

摘 要: 将人工免疫理论的克隆选择算法中的抗体克隆、变异和抑制策略引入粒子群优化算法中,提出了一种基于克隆选择的免疫粒子群优化算法,克服了基本粒子群算法易于陷入局部最优解的缺点. 针对支持向量机预测模型的参数选择影响其预测精度的问题,引入免疫粒子群优化算法设计了参数自适应优化的航空发动机滑油屑末支持向量机预测模型. 仿真结果表明:与传统的交叉验证试算法相比,基于免疫粒子群优化的预测模型实现了参数的自动择优,并且提高了预测精度.

关 键 词: 克隆选择; 粒子群优化; 支持向量回归; 预测模型

中图分类号: V231.3

文献标识码: A

Design of forecasting model for aero-engine lubrication debris support vector machines based on immune-particle swarm optimization algorithm

LI Ben-wei, ZHANG Yun, SUN Tao

(Department of Airborne Vehicle Engineering,
Naval Aeronautical Engineering Institute, Yantai, 264001, China)

Abstract: An immune particle swarm optimization algorithm (immune-PSO) based on clonal selection was proposed. In the method, the strategy of antibody clone, mutation and limit was introduced into PSO algorithm to avoid trapping in local minimum. To resolve the problem that the choice of parameters influences the forecast precision of support vector machine(SVM) forecasting model, the immune-PSO algorithm was used to design the aero-engine lubrication debris forecasting model based on SVM with self-adaptive optimized parameters. The simulation results show that the forecasting model optimized by immune-PSO algorithm can achieve automatic optimization of parameters, and increase forecasting accuracy than the conventional cross-validation algorithm.

Key words: clonal selection; particle swarm optimization; support vector regression; forecasting model

航空发动机滑油中的铁、镁、铜等金属含量值能较准确的反映出发动机的轴承、机匣及齿轮等零部件的工作情况,通过对滑油中各种金属含量

值及其趋势进行预测分析,可以有效地监视传动部件的磨损状况,预防故障的发生.

基于统计学习理论的支持向量机(SVM)采

收稿日期: 2008-06-03; **修订日期:** 2008-08-17

作者简介: 李本威(1962-),男,山东威海人,教授、博导,博士,主要从事航空发动机状态监控诊断与航空装备维修保障专业领域的研究.

用新型的学习机制,泛化能力很强,因此已被用于预测分析金属含量的变化趋势^[1].但是在具体应用中 SVM 的一些关键参数如惩罚系数 C 、不敏感损失函数参数 ε 、核函数参数的选择直接影响着预测精度.目前一般通过交叉验证试算的方法来进行 SVM 参数的选择,耗时且盲目性大.为此,本文提出一种免疫粒子群优化算法,通过引入人工免疫理论中的克隆选择算法增强了粒子群算法的全局搜索能力,并利用该算法建立了参数自适应优化的滑油金属含量支持向量机预测模型,以达到最佳的预测效果.

1 基于克隆选择的免疫粒子群优化算法

克隆选择原理是用来描述免疫应答基本特征的理论,该理论认为只有那些可以识别抗原的细胞才会被选择,发生增殖,而那些不能识别抗原的则不会被选择.被选择的细胞受制于亲和成熟过程. De Castro 博士基于克隆选择原理提出了克隆选择算法^[2],算法如下:

首先,产生初始群体 P ,包括记忆群体 M ;再根据亲和度大小从 P 中选择 n 个最好抗体;克隆这 n 个最好抗体,克隆的规模随亲和度的大小而改变;克隆后的抗体产生变异,变异概率与抗体的亲和度成正比/反比;在新产生的群体中重新选择一些好的抗体构成记忆群体.母体中的一些抗体被新群体中的其他好于母体的抗体取代;最后插入新抗体替换 n 个低亲和度抗体,以保持群体多样性.

粒子群优化 (particle swarm optimization, 简称 PSO) 算法是由 Kennedy 和 Eberhart 等于 1995 年提出的一种演化计算算法^[3-4].

在 PSO 中,对于第 i 个粒子,它的当前位置表示为 $x_i = (x_{i1}, x_{i2}, \dots, x_{in})$, 飞行速度 $v_i = (v_{i1}, v_{i2}, \dots, v_{in})$, 它所经历过的最好位置记为 $p_i = (p_{i1}, p_{i2}, \dots, p_{in})$. 整个粒子群体所经历过的最好位置为 $p_g = (p_{g1}, p_{g2}, \dots, p_{gn})$. 计算每个粒子的适应度,适应度函数一般由实际问题中被优化的目标函数决定.根据每个粒子的适应度来更新 p_i 和 p_g .在每一步迭代中,粒子根据以下公式更新自己的速度和位置

$$v_{id}(t+1) = w v_{id}(t) + c_1 r_1 [p_{id}(t) - x_{id}(t)] + c_2 r_2 [p_{gd}(t) - x_{id}(t)] \quad (1)$$

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

其中 $d = 1, 2, \dots, n$; t 为当前迭代次数; $i = 1, 2, \dots, S$, S 为种群规模; r_1 和 r_2 为分布于 $[0, 1]$ 之间的随机数; w 为惯性权重; c_1 和 c_2 称为加速因子.

PSO 算法在搜索的初期有较快的收敛速度,但在后期往往容易陷入局部最优解.因此,本文将克隆选择算法中的抗体克隆、变异和抑制策略引入 PSO 算法.把被优化的目标函数视为抗原,粒子群视为所有抗体的集合,粒子的适应度视为抗体与抗原的亲和度.具体实现如下:

步骤 1 在搜索空间随机初始化抗体群 (粒子群),确定每个抗体 (粒子) 的初始位置和初始速度,种群规模为 S .

步骤 2 计算每个抗体与抗原的亲和度 (粒子适应度),更新抗体本身的最好位置 p_i 和抗体群的最好位置 p_g .

步骤 3 根据公式 (1) 和公式 (2) 更新每个抗体 (粒子) 的位置和速度.

步骤 4 选择亲和度较高的 m 个抗体克隆出 k 个子抗体,将每个母体与其克隆的 k 个子抗体分为一组,共有 m 组.其中 $m = \alpha S$, $k = \beta S$, α 和 β 为克隆常数,用于控制克隆的规模.

步骤 5 对每组的 k 个子抗体进行变异,变异的方法为:对抗体速度的各分量配置分布于 $[0, 1]$ 的随机数 r ,如果 r 小于给定变异率 τ ,则将该抗体速度的分量在解空间重新初始化.

步骤 6 在每一组内,再根据公式 (1) 和公式 (2) 更新所有抗体的位置和速度,然后重新计算每个抗体与抗原的亲和度,选择亲和度最大的抗体作为该组的最佳抗体.

步骤 7 根据抗体抑制原理,除保留每一组的最佳抗体之外,清除其余抗体.

步骤 8 返回步骤 2,直到到达最大迭代次数或满足最小误差条件为止.

从步骤 4 到步骤 7 中,通过对粒子的克隆、变异操作,在候选解附近产生了新的子群体,扩大了搜索范围,同时通过抗体抑制策略清除亲和度低的粒子,保持了种群的多样性,从而提高了 PSO 算法跳出局部最优解的能力.

2 基于免疫粒子群算法优化的支持向量机预测模型

对给定的训练样本 (x_i, y_i) , $x_i \in \mathbf{R}^d$, $y_i \in \mathbf{R}$, $i = 1, 2, \dots, n$,运用支持向量机学习算法可以得到

回归函数^[5]

$$f(\alpha, \alpha^*, x) = \sum_{i=1}^n (\alpha - \alpha^*) K(x, x_i) + b \quad (3)$$

在上式中 α 和 α^* 满足

$$\sum_{i=1}^n (\alpha - \alpha^*) = 0 \quad \text{且} \quad 0 \leq \alpha, \alpha^* \leq C \quad (4)$$

b 的表达式如下:

当 $\alpha_j \in (0, C)$

$$b = y_j - \sum_{i=1}^n (\alpha^* - \alpha) (x_i \cdot x_j) - \varepsilon$$

当 $\alpha^* \in (0, C)$

$$b = y_j - \sum_{i=1}^n (\alpha^* - \alpha) (x_i \cdot x_j) + \varepsilon \quad (5)$$

其中 C 为惩罚系数, ε 为不敏感损失函数参数, $K(x, x_i)$ 为核函数。

对于平稳时间序列 $\{x_1, x_2, \dots, x_n\}$, 利用以前 p 个时刻的值, 对当前时刻 t 的值进行预测。如果 x_t 是预测的目标值, 则需要将先前 p 个目标值 $x_t = \{x_{t-1}, x_{t-2}, \dots, x_{t-p}\}$ 与输出 x_t 之间建立一一映射关系: $f: \mathbf{R}^p \rightarrow \mathbf{R}$, 其中 p 为嵌入维数。由此形成训练样本集

$$X = \begin{bmatrix} x_1 & x_2 & \dots & x_{n-p} \\ x_2 & x_3 & \dots & x_{n-p+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_p & x_{p+1} & \dots & x_{n-1} \end{bmatrix} = \begin{bmatrix} x_1 & x_2 & \dots & x_{n-p} \end{bmatrix} \quad (6)$$

$$Y = \begin{bmatrix} x_{p+1} & x_{p+2} & \dots & x_n \end{bmatrix} = \begin{bmatrix} y_{p+1} & y_{p+2} & \dots & y_n \end{bmatrix} \quad (7)$$

利用公式(3) 建立 SVM 预测模型如下:

$$y_t = \sum_{i=1}^{n-p} (\alpha - \alpha^*) K(x_i, x_t) + b \quad (t = p+1, \dots) \quad (8)$$

用 SVM 方法进行预测, 模型参数的选择对预测精度有着重要的影响。

1) 损失函数参数 ε 表明了系统对估计函数在样本数据上误差的期望, ε 值越大, 支持向量数目越少, 解的表达就越稀疏, 但大的 ε 也能降低回归估计的精度。

2) 惩罚系数 C 是在特征空间中对回归曲线的平滑度和经验风险进行折中, 即可以控制回归模型的鲁棒性。 C 值过大或过小都会因过学习或欠学习使系统的泛化性能变差。

3) 对于不同类型的核函数, 所产生的支持向

量的个数变化不大, 但是核函数的相关参数对模型的预测精度有重要影响。本文选择径向基核函数式, 对其参数 σ 进行优化。

4) 嵌入维数 p 关系到能否重构非线性系统的相空间, 对时间序列预测精度有重要影响。

通过以上分析可知, 惩罚系数 C 、不敏感损失函数参数 ε 、核函数参数 σ 以及嵌入维数 p 对支持向量机模型预测精度影响很大。如何合理选择 SVM 的参数, 目前尚未有有效的方法, 一般通过交叉验证试算。由于 PSO 算法具有并行性和强大全局搜索能力, 可以在很短的时间内搜索到全局最优点, 为此, 本文提出采用免疫粒子群优化算法来对支持向量机的参数进行自动优化选择, 以提高预测的准确性并减少试算的盲目性。

将粒子向量取为四维, 分别对应支持向量机预测模型的不同参数, 即惩罚系数 C 、不敏感损失函数参数 ε 、核函数参数 σ 和嵌入维数 p 。适应度函数是寻优的依据, 根据适应度的大小衡量粒子的优劣。SVM 预测模型的参数优化旨在使预测误差达到最小, 本文采用平均相对变动值 (ARV)^[6] 作为预测误差来衡量预测值与实测值的差别, 其定义为

$$ARV = \frac{\sum_{i=1}^N [y(i) - \hat{y}(i)]^2}{\sum_{i=1}^N [y(i) - \bar{y}]^2} \quad (9)$$

其中 $y(i)$ 为第 i 个数据的实测值, $\hat{y}(i)$ 为第 i 个数据的预测值, $\bar{y}$ 为实测数据平均值, N 为测试数据个数。平均相对变动值 ARV 越小表明预测误差越小。

由于免疫粒子群算法的适应度函数越大越好, 因此选取适应度函数如下:

$$F = 1 - ARV \tag{10}$$

基于免疫粒子群优化算法的 SVM 预测模型参数优化流程如图 1 所示.




图 1 参数优化流程图
Fig. 1 Flow of parameters optimization

3 基于免疫粒子群优化的滑油金属含量支持向量机预测仿真

本文选取某型发动机两次换油之间的工作阶段的滑油光谱分析数据作为算例,按光谱分析时间排序得到金属含量时间序列(共计 83 个),以 Fe 金属含量为主要监控对象进行时间序列分析. Fe 含量的时间序列如图 2 所示.




图 2 Fe 含量时间序列
Fig. 2 Time series of Fe amount

将数据分为两组,前 50 次作为训练数据,后 33 次作为测试数据.取粒子种群规模为 20,搜索空间为 4 维,最大迭代次数为 300,加速因子 $\alpha_1 = \alpha_2 = 2$,惯性权重 $w = 0.7$,最大速度向量为 $(1, 10, 0.1,$

$0.2)$,克隆常数 $\alpha = 0.8$, $\beta = 0.4$,变异率 $\tau = 0.5$,嵌入维数 p 的取值区间为 $[1, 10]$,惩罚系数 C 的取值区间为 $[1, 1000]$,不敏感损失函数 ε 的取值区间为 $[0.0001, 0.5]$,核参数 σ 的取值区间为 $[0.1, 4]$.由于 p 为整数,对 p 取整后输入预测模型.

图 3 为粒子种群的最大适应度随迭代次数的变化规律,从图 3 中可以看出,通过 124 次迭代后,最大适应度达到了最大值,得到了最优的预测模型参数.其优化结果为: $p = 5$, $C = 156$, $\varepsilon = 0.0015$ 和 $\sigma = 0.64$.最优的适应度值为 0.7521,相应的预测误差 ARV 为 0.2479.图 4 和图 5 分别为采用免疫粒子群优化算法和传统交叉验证试算法建立的 SVM 预测模型对 33 个测试数据的预测结果,表 1 为两者的预测误差值 ARV 的比较结果.从图 4、图 5 和表 1 中可以看出:与传统交叉验证试算法相比,使用免疫粒子群优化算法不但实现了对 SVM 预测模型参数自动优化,而且提高了预测精度.




图 3 最大适应度随迭代次数的变化关系
Fig. 3 Relation between largest fitness and iterative numbers




图 4 采用免疫粒子群优化算法的预测结果
Fig. 4 Forecasting result using immune-PSO algorithm

为了将免疫粒子群和基本粒子群优化算法进

行性能比较,分别使用基本粒子群算法和免疫粒子群算法进行 50 次的滑油金属含量支持向量机预测模型的参数优化,得出了 50 次的平均最优适应度、相应的平均预测误差 ARV 以及平均迭代次数,见表 2。可以看出:与基本粒子群优化算法




图 5 采用传统交叉验证试算法的预测结果
Fig.5 Forecasting result using conventional cross-validation algorithm

表 1 两种方法的预测误差比较

SVM	免疫粒子群 算法	传统交叉验证 试算法
C	156	100
ϵ	0.0015	0.0020
σ	0.64	0.50
p	5	5
预测误差 ARV	0.2479	0.3124

表 2 基本粒子群与免疫粒子群算法比较结果

	基本粒子群 算法	免疫粒子群 算法
平均最优适应度	0.7258	0.7470
平均预测误差 ARV	0.2742	0.2530
平均迭代次数	145	132

相比,使用免疫粒子群优化算法进行 SVM 预测模型参数优化,更容易跳出局部最优解,具有更快的收敛速度和更高的预测精度。

4 结 论

本文提出了一种基于克隆选择的免疫粒子群优化算法,并利用该算法建立了参数自适应优化的滑油金属含量支持向量机预测模型,从而自动获取具有最佳预测效果的 SVM 预测模型。用某型发动机滑油的 Fe 金属含量数据进行了仿真,结果表明:与传统交叉验证试算法相比,使用免疫粒子群算法优化的支持向量机的滑油金属含量预测模型具有更高的预测精度。最后将免疫粒子群优化算法与基本粒子群优化算法作了性能比较,结果表明前者的效果更好。

参考文献:

[1] 尉询楷,李应红,王硕,等. 基于支持向量机的航空发动机滑油监控分析[J]. 航空动力学报,2004,19(3):392-397.
WEI Xunkai, LI Yinghong, WANG Shuo, et al. Aero-engine lubrication monitoring analysis via support vector machines[J]. Journal of Aerospace Power, 2004, 19(3): 392-397. (in Chinese)

[2] De Castro L N, Von Zuben F J. Learning and optimization using the clonal selection principle [J]. IEEE Transactions on Evolutionary Computation, Special Issue on Artificial Immune Systems, 2002, 6(3): 239-251.

[3] Kennedy J, Eberhart R C. Particle swarm optimization [C]// Proceedings of IEEE International Conference on Neural Networks. Perth, Australia: IEEE, 1995: 1942-1948.

[4] Eberhart R C, Kennedy J. A new optimizer using particle swarm theory[C]// Proceedings of the Sixth International Symposium on Micro Machine and Human Science, Nagoya, Japan:[s. n.],1995: 39-43.

[5] Smola A J, Scholkopf B. A tutorial on support vector regression[R]. London, U. K.: Royal Holloway College, University of London, NeuroCOL T Technical Report NC-TR-98-030, 1998.

[6] 陈果. 航空器检测与诊断技术导论[M]. 北京:中国民航出版社,2007.