

基于细菌觅食特征改进粒子群算法优化 SVM 模型参数研究

李宝晨¹, 金赛赛¹, 仝蕊¹, 连光耀²

(1. 军械工程学院, 石家庄 050003; 2. 军械技术研究所, 石家庄 050003)

摘要: 针对粒子群算法优化 SVM 模型参数在进化后期容易陷入局部最优的问题, 研究了细菌觅食趋利避害机制, 提出了一种基于细菌觅食特性改进粒子群算法的方法, 并将改进方法应用于优化 SVM 预测模型参数的研究; 实验结果表明, 该方法能够弥补粒子群算法在进化后期容易陷入局部最优的缺陷, 具备更好的寻优性能。

关键词: 细菌觅食特征; 粒子群算法; 支持向量机; 故障预测

Improvement of Basic Particle Swarm by Using Bacterial Foraging Features for Optimizing the Parameters of SVM

Li Baochen¹, Jin Saisai¹, Tong Rui¹, Lian Guangyao²

(1. Ordnance Engineering College, Shijiazhuang 050003, China;

2. Ordnance Technological Research Institute, Shijiazhuang 050003, China)

Abstract: In order to solve the problem that the basic particle swarm algorithm to optimize the SVM model is easy to fall into local optimum in the late evolution, on the basis of studying mechanism of bacterial foraging theory, this paper proposes a method to improve the basic particle swarm by using bacterial foraging features, and applied it to optimize the parameters of SVM prediction model. The results show that it can remedy the defect of the basic particle swarm algorithm and has better optimization performance.

Key words: bacterial foraging features; particle swarm algorithm; support vector machine; fault prediction

0 引言

近年来, 因复杂装备系统的关键模块或元件故障而引起的灾难性事故时常发生, 导致大量的人力、物力与财力的损失。故障预测技术是“视情维修”技术的关键技术支撑^[1]。

支持向量机 (Support Vector Machine, SVM) 诞生于 AT&T Bell 实验室, 是由 Vapnik 领导的研究小组根据统计学学习理论中的结构风险最小化原则提出的一种机器学习方法, 由 SVM 引申出的支持向量回归模型能够很好地用于预测问题的研究^[2]。如何选取模型参数是 SVM 应用中的一个关键问题。粒子群算法是一种基于群体的智能优化算法^[3-4], 存在的问题是算法在进化后期种群多样性消失, 出现早熟停滞, 局部搜索能力较差, 最终陷入局部最优^[5]。

细菌觅食算法 (Bacterial Foraging Algorithm, BFA) 是 Passino 于 2002 年提出的一种新型的群体智能随机搜索算法^[6]。实验表明, 细菌觅食的这种特有机制能够弥补粒子群优化算法在进化后期容易陷入局部最优的缺陷。

1 SVM 预测模型

SVM 训练学习过程的基本思路: 通过用内积空间定义的非线性映射 Φ , 将输入空间的数据 \vec{x} 映射到高维特征空间 G 中, 并在这个空间进行线性回归^[7]。

设 $(x_i, y_i), i = 1, 2, \dots, n, x \in R^d, y \in R$ 为训练样本集,

那么 SVM 用来估计回归函数的公式为:

$$y = f(\vec{x}) = (\omega \cdot \Phi(\vec{x})) + b \quad (1)$$

此时, 要确定的回归函数待定参数值是 ω, b , 其中 ω 表示的是权值向量, b 表示偏置。公式 (1) 转化为关于损失函数的结构风险最小化:

$$R_{ref}(f) = C \cdot \sum_{i=1}^n \Gamma(f(\vec{x}_i) - y_i) + \frac{1}{2} \omega^2 \quad (2)$$

在上式中, n 代表训练样本集的个数, $\Gamma(\cdot)$ 代表的是损失函数, C 代表的是惩罚因子

待定参数 ω 为:

$$\omega = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \cdot \Phi(\vec{x}_i) \quad (3)$$

引入不敏感损失系数 ϵ , 由于 ϵ 较好的稀疏特性, 得到的结果可以具备较好的泛化能力。由此, 确定的 $\Gamma(\cdot)$ 为:

$$\Gamma(\cdot) = |y - f(\vec{x})|_{\epsilon} = \max\{0, |y - f(\vec{x})| - \epsilon\} \quad (4)$$

那么, 求解上述公式 (4) 等价于求解公式:

$$\begin{aligned} \max J = & \left\{ \sum_{i=1}^n \alpha_i^* \cdot (y_i - \epsilon) - \sum_{i=1}^n \alpha_i^* \cdot (y_i + \epsilon) \right\} - \\ & \frac{1}{2} \sum_{i=1, j=1}^n (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j) \cdot k(\vec{x}_i, \vec{x}_j) \\ \text{s. t. } & \sum_{i=1}^n \alpha_i = \sum_{i=1}^n \alpha_i^*; 0 \leq \alpha_i \leq C; 0 \leq \alpha_i^* \leq C \end{aligned} \quad (5)$$

求解上述公式, 得到的估计回归函数为:

$$f(\vec{x}) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) (\Phi(\vec{x}_i) \cdot \Phi(\vec{x})) + b \quad (6)$$

其中: α_i 和 α_i^* 对应支持向量, 用核函数 $k(\vec{x}_i, \vec{x}_j)$ 代替公

收稿日期: 2013 - 10 - 23; 修回日期: 2014 - 01 - 16。

作者简介: 李宝晨 (1983 -), 男, 山东济宁人, 主要从事测试性设计、故障诊断和故障预测方向的研究。

式 (6) 中的内积运算 $(\Phi(\vec{x}_i) \cdot \Phi(\vec{x}))$, 这样公式 (6) 即:

$$f(\vec{x}) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) k(\vec{x}_i, \vec{x}_j) + b \quad (7)$$

通过训练样本集对 SVM 进行训练就可以获得 α_i 、 α_i^* 以及 b 的数值组合。

2 基本粒子群算法

基本粒子群优化算法是由美国的电气工程师 Eberhart 和社会心理学家 Kennedy 提出来的智能优化算法。基本粒子群优化算法的生物学基础是一群鸟去寻找食物^[4]。在粒子群算法用数学语言叙述为: 搜索空间为 D 维, 粒子种群共包含 m 个粒子, x_i 表示第 i 个粒子的位置, $x_i = (x_{i1}, x_{i2}, \dots, x_{iD}), i = 1, 2, \dots, D$ 。引入目标函数的概念, 通过将 x_i 带入目标函数中得到目标函数适应值来比较 x_i 的优劣。第 i 个粒子的飞行速度也是一个 D 维的向量, 记为 $v_i = (v_{i1}, v_{i2}, \dots, v_{iD})$, 第 i 个粒子至今为止搜索到的最优位置为 $p_i^{best} = (p_{i1}^{best}, p_{i2}^{best}, \dots, p_{iD}^{best})$, 整个种群至今为止搜索到的最优位置为 $g^{best} = (g_1^{best}, g_2^{best}, \dots, g_D^{best})$ 。

基本粒子群算法使用下式对粒子的速度和位置进行更新:

$$v_{id}(t+1) = \omega v_{id}(t) + c_1 r_1 (p_{id}^{best}(t) - x_{id}(t)) + c_2 r_2 (g_d^{best}(t) - x_{id}(t)) \quad (8)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t) \quad (9)$$

其中: $i = 1, 2, \dots, m; d = 1, 2, \dots, D; \omega$ 为惯性权重系数; c_1 和 c_2 是两个非负常数; r_1 和 r_2 是属于区间 $[0, 1]$ 之间的随机数。

3 基于细菌觅食特征改进粒子群算法

细菌觅食算法的生物学基础是大肠杆菌在人类肠道中觅食过程中的智能表现: 即通过趋化、繁殖、驱散 3 个步骤来不断更新细菌的所在位置, 使细菌能够趋向营养丰富的地方。

优化算法中可以引入大肠杆菌的这种趋利避害机制。将一群游动的大肠杆菌看作是解空间中的设计变量, 将环境中的营养丰富源看成是待求问题的最优解, 定义不利刺激为在优化问题求解过程中所满足的某种不利条件, 解空间中的设计变量在寻优过程中能够根据最优解的求解情况, 及时调整自己的运动行为, 不断逼近待求问题的最优解。

基于此, 提出一种基于细菌觅食特征的改进粒子群优化算法。本文定义优化求解过程连续 5 代寻找到的最优值变化在 0.01% 以内, 认为算法陷入了局部最优。

结合粒子群算法, 引入调节因子 Z , 其中驱散操作采用:

$$v_{id}(t+1) = \omega v_{id}(t) + c_1 r_1 (p_{id}^{best}(t) - x_{id}(t)) + c_2 r_2 (g_d^{best}(t) - x_{id}(t)) - Z \quad (10)$$

趋化操作采用:

$$v_{id}(t+1) = \omega v_{id}(t) + c_1 r_1 (p_{id}^{best}(t) - x_{id}(t)) + c_2 r_2 (g_d^{best}(t) - x_{id}(t)) + Z \quad (11)$$

其中: $Z = c_3 r_3 (p_{id}^{best}(t) - x_{id}(t))$, 其它参数的含义与式 (8) 和 (9) 对应相同, 下标 k 和 d 分别表示第 k 个粒子和第 d 维, 且 $k \neq i$, 学习因子 c_3 用来引导粒子的运动并调节粒子对个体经验、群体最优个体经验以及群体中其它个体经验继承的多少。

利用细菌觅食特征改进粒子群算法优化 SVM 模型参数的步骤为:

Step1: 设置 SVM 模型的初始参数, 包括设置最大迭代次数、微粒初始速度 v_i^0 、微粒最大允许速度 v_d^{max} 、随机生成初始微粒 x_i^0 、群体规模等。微粒向量的元素分别对应的是惩罚

因子 C 、不敏感损失系数 ϵ 和核函数参数 σ 。

Step2: 计算每个微粒的适应值。以预测样本的实际值与预报值误差最小为目标函数, 采用如下这种形式:

$$F(x_i) = \frac{1}{m} \sum_{i=1}^m \left| \frac{\overline{A(i)} - \overline{F(i)}}{\overline{A(i)}} \right| \times 100\% \quad (12)$$

其中: m 为预测样本的总个数, $\overline{A(i)}$ 表示测试集中第 i 个预测样本实测值, $\overline{F(i)}$ 为第 i 个预测样本预测值。

Step3: 比较自身的最优值 $F(p_i^{best})$ 与按照公式 (12) 计算的适应函数值 $F(x_i)$, 如果 $F(x_i) < F(p_i^{best})$, 则 $F(p_i^{best}) = F(x_i)$, $p_i^{best} = x_i$ 。

Step4: 比较所有微粒的最优适应值 $F(g^{best})$ 与每个微粒的最优适应值 $F(p_i^{best})$, 如果 $F(p_i^{best}) < F(g^{best})$, 则 $F(g^{best}) = F(p_i^{best})$, $g^{best} = p_i^{best}$ 。

Step5: 基于细菌觅食特征的微粒移动操作。判断是否满足不利刺激, 即粒子群体在寻优过程中是否连续 5 代寻找到的最优值变化在 0.01% 以内。若是, 则认为陷入了局部最优, 用公式 (10) 和 (9) 对适应度值较差的粒子实施驱散操作移动; 若否, 用公式 (11) 和 (9) 对适应度值较差的粒子实施趋化操作移动, 从而产生新的微粒。

Step6: 判断迭代次数是否已经达到最大迭代次数, 若是, 计算结束; 若否, 则返回 Step2。

利用细菌觅食特征改进粒子群算法优化 SVM 的算法流程如图 1 所示。

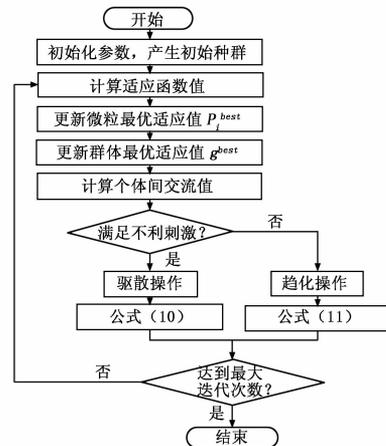


图 1 算法流程图

4 仿真研究

4.1 输入向量

本文实验对象为某型底盘液泵, 每日于 10:00 ~ 12:00 时间段采集 30S 振动信号, 信号图形如图 2 所示。训练集为: 5 月 1 日 ~ 5 月 30 日每日采集的 30S 振动信号利用 EMD 方法得到的 IMF1 分量在固有频率区间 $0 \sim 200$ Hz 特征能量值 \bar{S}_1 ; 测试集为: 5 月 31 日 ~ 6 月 5 日每日采集的 30S 振动信号利用 EMD 方法得到的 IMF1 分量在固有频率区间 $0 \sim 200$ Hz 特征能量值 \bar{S}_1 。

4.2 参数设置

(1) 依据先验知识, 设定的基本粒子群算法优选 SVM 模型的搜索范围是: $C \in [0, 100]$, $\epsilon \in [0.0001, 1]$, $\sigma \in [0.001, 10]$ 。种群规模即粒子数 $m = 30$ 。

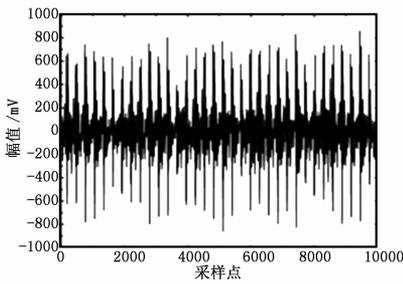


图 2 振动信号示意图

(2) 解空间设置为 3 维, 即微粒向量的元素分别对应的是 SVM 的 3 个待定参数惩罚因子 C , 不敏感损失系数 ϵ 和核函数参数 σ 。

(3) 加速常数 c_1 和 c_2 一般取为相等的数值, 并且范围满足 $c_1, c_2 \in [0, 4]$ 。考虑到随机的因素对算法所造成的影响, c_1 和 c_2 常常取作 2。本文确定的 $c_1 = c_2 = 2, c_3 = 0.5$ 。

(4) 最大迭代次数设置为 $T = 100$ 。

$$\omega = \omega_{\max} - \frac{t}{T} \times (\omega_{\max} - \omega_{\min}) \quad (13)$$

其中: ω_{\min} 为惯性权重初值, ω_{\max} 为惯性权重终值, T 和 t 分别为最大迭代次数和当前迭代次数。据此, 确定的惯性权重初值 $\omega_{\max} = 0.9$, 惯性权重终值 $\omega_{\min} = 0.4, \omega = 0.9 - \frac{t \times 0.5}{100}$ 。

4.3 实例分析

在 Matlab 7.9 环境下分别运行两种方法优化 SVM 模型参数的程序, 经过在训练集上的数次迭代, 5 月 31 日~6 月 5 日的测试集样本优化结果如表 1 所示。

表 1 两种方法的预测误差

时间点	实测值	基本粒子群算法		改进粒子群算法	
		预测值	误差/%	预测值	误差/%
1	4.97	4.68	5.83	4.94	0.60
2	5.01	4.70	6.19	4.99	0.40
3	5.05	4.74	6.14	5.02	0.60
4	5.11	4.76	6.85	5.07	0.78
5	5.17	4.82	6.77	5.14	0.58
6	5.23	4.88	6.69	5.16	1.33

基本粒子群算法的参数优化结果为 $C = 45.384, \epsilon = 0.00468, \sigma = 5.105$; 基于细菌觅食特征改进粒子群算法的参数优化结果为 $C = 44.056, \epsilon = 0.00501, \sigma = 4.726$ 。对应的测试误差随迭代次数的变换曲线如图 3 和图 4 所示。

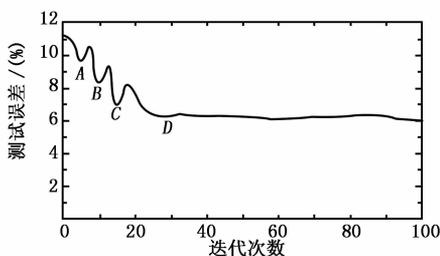


图 3 基本粒子群算法测试误差迭代曲线图

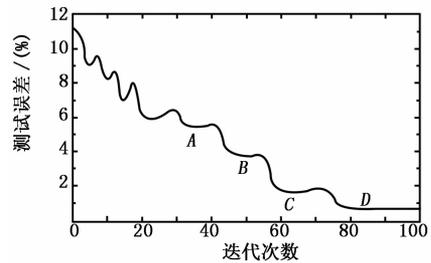


图 4 改进粒子群算法测试误差迭代曲线图

由图可知:

(1) 由图 3 测试误差的迭代优化曲线能够看出, 测试误差总体呈波动下降趋势, 说明随着迭代次数增加, 模型的精度同时随之提高。但在图中所示的 D 处, 算法的寻优结果基本不再变化, 此时测试误差值为 6.02%, 对比利用细菌觅食特征改进粒子群算法优选 SVM 模型参数得到的测试误差结果 0.66%, 可判断此时算法陷入局部最优。

(2) 在图 4 所示 A, B, C 处, 利用细菌觅食特征改进粒子群算法优选 SVM 模型参数得到的测试误差结果均有陷入局部最优的可能性, 此时算法触发了不利刺激条件: 连续 5 代寻找到的最优值变化在 0.01% 以内。算法判断满足不利刺激条件后对适应度值较差的粒子实施驱散操作移动, 在图示 A, B, C 处数次跳出局部最优, 在图中 D 处对测试误差的寻优结果达到了最优值 0.59% 直至最后, 优化结果基本不再变化, 证明本文提出改进算法的有效性。

5 结束语

惩罚因子 C , 不敏感损失系数 ϵ 和核函数参数 σ 等参数直接影响到 SVM 的学习性能和泛化能力, 如何选取上述参数是 SVM 应用中的一个关键问题。本文通过对基本粒子群算法引入细菌觅食机制, 引导粒子跳出局部最优, 提高了粒子在搜索后期的遍历性。实验结果表明, 本文提出的改进粒子群算法的性能优于单一的粒子群算法。

参考文献:

- [1] 连光耀, 吕晓明, 黄考利, 等. 基于 PHM 的电子装备故障预测系统实现关键技术研究 [J]. 计算机测量与控制, 2010, 18 (9): 1959 - 1961.
- [2] Vapnik V N, Golowich S, Smola A. Support vector method for function approximation, regression estimation and signal processing. Advances in neural information processing systems [M]. MIT Press, 1997: 281 - 287.
- [3] 张 弦, 王宏力. 基本粒子群优化的最小二乘支持向量机在时间序列预测的应用 [J]. 中国机械工程, 2011, 22 (21): 2572 - 2576.
- [4] 曾劭伟, 徐知海, 吴 键. 基于粒子群优化和支持向量机的电力负荷预测 [J]. 微电子学与计算机, 2011, 28 (1): 147 - 149.
- [5] 彭 令, 牛瑞卿, 赵艳南, 等. 基于核主成分分析和粒子群优化支持向量机的滑坡位移预测 [J]. 武汉大学学报, 2013, 38 (2): 148 - 152.
- [6] 乔 英, 高岳林, 江巧永. 基于细菌觅食行为的多目标分布估计算法 [J]. 计算机应用研究, 2011, 28 (10): 3681 - 3683.
- [7] 连光耀, 吕晓明, 黄考利, 等. 基于最小二乘支持向量机的复杂装备故障预测模型研究 [J]. 计算机测量与控制, 2011, 19 (5): 1030 - 1032.