

基于改进 QPSO 优化 SVR 的某电源组合故障预测研究

王 成¹, 杨 森¹, 孟 晨¹, 贾 玺²

(1. 军械工程学院 导弹工程系, 石家庄 050003; 2. 78618 部队, 成都 062650)

摘要: 针对电源组合的故障特点, 提出了一种基于改进 QPSO 优化 SVR 的故障预测方法; 文中首先对 QPSO 算法进行了介绍; 然后对支持向量回归机 (Support Vector Regression, SVR) 性能影响因素进行了分析, 并给出了基于改进 QPSO 优化 SVR 参数的算法步骤; 最后以制导雷达波束系统中的某电源组合为例进行了仿真分析, 预测结果表明, 同 QPSO 算法相比该预测方法误差更小, 达到了预期效果。

关键词: QPSO; SVR; 电源组合; 故障预测

Research on Fault Prediction of Power Supply Based on SVR Optimized with Improved QPSO

Wang Cheng¹, Yang Sen¹, Meng Chen¹, Jia Xi²

(1. Department of Missile Engineering, Ordnance Engineering College, Shijiazhuang 050003, China;

2. Unit 78618, PLA, Chengdu 062650, China)

Abstract: Aiming at the character of power supply fault prediction, a prediction method based on SVR optimized with improved QPSO is put forward. Firstly, the QPSO algorithm is introduced in the paper; Then the performance impact factors of SVR are analyzed, and the steps of SVR parameters optimized with improved QPSO are given; Finally, taking a power supply of guidance radar beam control system as an example to simulate, the result shows that the error of this method is lower than QPSO algorithm, achieving the expected effect.

Key words: QPSO; SVR; power supply; fault prediction

0 引言

随着电子装备的复杂度和集成度的不断提高, 装备的可靠性、维修性、故障预测与健康管理等问题日渐突出。电源组合作为电子系统的重要组成部分, 其性能优劣将直接影响电子装备的正常运行。因此, 为了减少由于电源故障引发的严重后果, 降低维修保障费用, 对电源组合进行故障预测是我军必须解决的重要课题之一^[1-2]。

支持向量回归机 (Support Vector Regression, SVR) 是在统计学习理论基础发展起来的一种新的机器学习方法。与传统统计学方法相比, 统计学习理论 (Statistical learning theory, SLT) 是一种专门研究小样本情况下机器学习规律的理论。其核心思想是选择最小的结构风险, 解决学习机的学习能力和泛化能力之间的矛盾。SVR 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结构简单、全局最优、泛化能力强等许多特有的优势^[3]。

如何对 SVR 参数进行优化从而进一步提高其预测精度是一个值得研究的问题。关于 SVR 参数优化, 国际上并没有公认统一的最好方法, 较常用的方法是采用交叉验证来进行参数选择, 但该算法效率较低, 精度不高^[4]。

本文研究了基于改进 QPSO 优化 SVR 的电源组合故障预测方法。首先根据电源输出电压建立 SVR 故障预测模型, 然

后利用改进 QPSO 算法对 SVR 参数进行优化, 最后利用该模型对输出电压作出预测, 并与电源实际输出进行比较, 从而判断该方法预测结果是否准确。实验结果显示该方法准确有效, 达到了故障预测的目的。

1 QPSO 算法及其改进

1.1 QPSO 算法

在粒子群优化算法 (Particle Swarm Optimization, PSO) 的基础上, 从量子力学的角度出发, 以 DELTA 势阱为基础, 认为粒子具有量子行为, 从而形成了一种新的 PSO 算法——具有量子行为的粒子群优化算法 (Quantum-behaved Particle Swarm Optimization, QPSO)。

QPSO 算法的粒子运动轨迹由以下 3 个方程决定^[5]:

$$p_{id}^r(t) = rand \cdot p_{id}(t) + (1 - rand) \cdot p_{gd}(t) \quad (1)$$

$$p^{nb}(t) = (p_1^{nb}(t), p_2^{nb}(t), \dots, p_n^{nb}(t)) = \frac{1}{m} \sum_{i=1}^m p_i(t) = \left(\frac{1}{m} \sum_{i=1}^m p_{i1}(t), \frac{1}{m} \sum_{i=1}^m p_{i2}(t), \dots, \frac{1}{m} \sum_{i=1}^m p_{in}(t) \right) \quad (2)$$

$$x_{id}(t+1) = p_{id}^r(t) \pm \alpha(t) \cdot |p_{id}^{nb}(t) - x_{id}(t)| \cdot \ln(1/rand) \quad (3)$$

式中, $p_{id}^r(t)$ 是在 $p_{id}(t)$ 和 $p_{gd}(t)$ 之间的随机位置; $p^{nb}(t)$ 是所有个体当前最优位置的中心点; $p_i(t)$ 是粒子 i 当前最优位置; $\alpha(t)$ 是称为扩张-收缩因子, 用于控制算法的收敛速度; 式中的“±”在算法的迭代过程中随机确定。

α 在迭代过程中一般按线性递减的方式进行:

$$\alpha = (\alpha_{max} - \alpha_{min}) \cdot \frac{(iter_{max} - iter)}{iter_{max}} + \alpha_{min} \quad (4)$$

收稿日期: 2013 - 12 - 20; 修回日期: 2014 - 02 - 10。

作者简介: 王 成 (1980 -), 男, 湖北宜昌人, 讲师, 博士, 主要从事状态监测与故障预测方向的研究。

式中, α_{\max} 和 α_{\min} 分别为 α 的最大值和最小值, 一般取 1.0 和 0.5; $iter_{\max}$ 是最大迭代次数; $iter$ 是当前迭代次数。

1.2 QPSO 算法的改进

由式 (4) 可知, 算法的控制参数的调整是一个线性递减的策略, 为了更好地控制算法的收敛速度, 对收缩扩张系数进行改进, 算法运行初期, α 值较大并使其较慢的减小, 使粒子在较大的空间进行较长时间的搜索, 而在算法运行后期, α 值较小并使其较慢的减小, 使粒子在较小的空间进行较长时间的搜索, 防止算法早熟, 改进的收缩扩张系数如式 (5) 所示。

$$\alpha(t) = \begin{cases} \alpha_{\max} - \frac{\alpha_{\max} - \alpha_{\min}}{u \cdot (t_{\max})^3} \cdot t^3, & t \leq u \cdot t_{\max} \\ \alpha_{\min} + \frac{\alpha_{\max} - \alpha_{\min}}{(1-u) \cdot (t_{\max})^3} \cdot (t_{\max} - t)^3, & t > u \cdot t_{\max} \end{cases} \quad (5)$$

其中: u 取小于 1 的正数, 不同 u 值的曲线如图 1 所示。

从图 1 中可以看出, 对于较大的 u , 有利于全局搜索, 而对于较小的 u , 有利于局部搜索, 所以 u 设计为随迭代次数的增加而减小。




图 1 不同 u 的曲线

2 基于改进 QPSO 的 SVR 参数优化

2.1 SVR 性能影响因素分析

影响支持向量回归机预测性能好坏的因素包括核函数及其参数、惩罚系数 C 和不敏感损失系数 ϵ 。

(1) 核函数及其参数: 核函数、映射函数和特征空间是一一对应的, 确定了核函数, 就确定了映射函数和特征空间。核函数参数的改变实际上隐含改变了样本数据子空间的复杂程度。数据子空间的维数决定了能在该子空间构造线性分类面的最大 VC 维, 限制了在该数据子空间所能构造的最优分类面的复杂程度, 也就决定了线性分类面能达到的最小经验风险。

对于支持向量回归机中的核函数, 通常用得最多的是线性核函数、多项式核函数、RBF 径向基核函数和 sigmoid 函数等。相对 RBF 核函数, 线性核仅是 RBF 核的一种特例, RBF 核函数还可以将样本非线性地映射到高维空间; 多项式核函数比 RBF 核函数的参数多, 模型选择也更加复杂, 同时其次数较高时, 计算复杂度更大; sigmoid 核函数在某些参数下会出

现不合法的情况。因此, 多数情况下选择 RBF 核函数效果较好^[6]。

(2) 惩罚系数 C : 惩罚参数 C 的作用是在结构风险和样本误差之间作出折衷, 使模型有较好的推广能力。 C 过小, 对样本数据中误判的样本惩罚就小, 训练误差就变大, 系统的推广能力变差, 就会出现“欠学习”现象; C 过大, 学习精度就相应提高, 模型接近实际经验风险最小化, 但模型的泛化能力变差, 就会出现“过学习”现象。另外, C 的值影响到样本中孤立点的处理, 选取合适的 C 就能在一定程度上抗干扰, 从而保证模型的稳定性^[7]。

(3) 不敏感参数 ϵ : 不敏感参数 ϵ 控制模型的预测能力, 影响构造回归函数的支持向量个数。 ϵ 值过大, 支持向量的个数会减少, 可能导致模型过于简单, 学习精度不够, 回归估计不准确; ϵ 过小, 支持向量数的个数会增多, 可能导致模型过于复杂, 训练时间增加^[8]。

2.2 基于改进 QPSO 的 SVR 参数优化

本文使用 RBF 核函数, 采用改进 QPSO 算法联合优化核函数参数、惩罚系数 C 和不敏感损失系数 ϵ , 寻找合适的回归模型, 使得预测精度更高。

基于改进 QPSO 优化 SVR 参数的具体步骤如下。

Step1: 初始化。包括初始化学习常数, 种群规模, 收缩扩张系数参数, 最大迭代次数; SVR 的初始参数, 并输入训练、预测数据, 进行数据归一化。

Step2: 计算各个粒子的适应度;

Step3: 若满足迭代次数条件进行下一步, 否则进行预测, 然后反归一化、输出结果;

Step4: 按照式 (5) 自行改变收缩扩张系数并产生新的粒子;

Step5: 计算新粒子的适应度, 如果新粒子的适应度小于旧粒子的适应度, 更新粒子适应度, 否则保留, 并计算新的全局最优适应度;

Step6: 若新的全局最优适应度小于旧的全局最优适应度, 更新, 否则全局最优适应度不变;

Step7: 转向 step3;

其中, 粒子适应度设计为 SVR 的预测误差值。

3 相关理论在某电源组合中的应用

下面以制导雷达波束控制系统中 P11 电源系统为例, 在模拟训练车中对 P11 电源系统中最复杂部分的电源组合进行电压数据采集, 分析其特点并进行故障预测^[9]。图 2 为采集到的电压数据曲线。

采用 QPSO 以及改进 QPSO 优化 SVR 的方法对该电源组合进行预测, 以最后 10 个数据点为例进行仿真对比, 各算法的预测值与实际值比较如图 3 所示, 预测值与实际值的误差比较如表 1 所示。

表 1 QPSO 与改进 QPSO 优化 SVR 的预测结果误差比较

序号	1	2	3	4	5
误差(QPSO)	0.003 0	0.001 9	0.001 4	0.003 0	0.000 6
误差(改进 QPSO)	0.001 1	0.000 7	0.000 2	0.000 4	0.000 2
序号	6	7	8	9	10
误差(QPSO)	0.002 1	0.001 7	0.001 0	0.001 3	0.000 8
误差(改进 QPSO)	0.000 3	0.000 7	0.000 2	0.000 4	0.000 0




图 2 某电源组合电压采集数据




图 3 不同算法优化 SVR 的预测结果比较

从表 1 和图 3 可以看出, 采用改进 QPSO 优化 SVR 的故障

预测方法在预测精度上明显优于 QPSO 算法, 预测误差更小。

4 结论

本文将 QPSO 算法和 SVR 结合起来, 并对 QPSO 算法中的收缩扩张系数进行了改进, 建立了基于改进 QPSO 优化 SVR 的故障预测模型。以某电源组合的输出电压信号为研究对象进行了仿真分析, 通过比较预测值与实际值的误差判断预测精度, 仿真结果表明, 该方法相较于传统 QPSO 算法预测精度更高, 达到了预期目的。

参考文献:

- [1] Antoni J, Danieret J. Effective vibration analysis of ic engines using cyclostationarity—part I: a methodology or condition monitoring [J]. Journal of Sound and Vibration, 2002, 257 (5): 815-837.
- [2] 郭阳明, 蔡小斌, 张宝珍, 等. 故障预测与健康状态管理技术综述 [J]. 计算机测量与控制, 2008, 16 (9): 1213-1218.
- [3] Vapnik V. The Nature of Statistical Learning Theory [M]. New York: Springer-Verlag, 1999.
- [4] Chapelle Olivier, Vapnik Vladimir, Bousquet Oliver, et al. Choosing Multiple Parameters for Support Vector Machines [J]. Machine Learning, 2002, (46): 131-159.
- [5] Sun J, Xu W B. A Global Search Strategy of Quantum-behaved Particle Swarm Optimizations [A]. IEEE 2004 Conference on Cybernetics and Intelligent System [C], Singapore: 111-116.
- [6] 何学文. 基于支持向量机的故障智能诊断理论与方法研究 [D]. 长沙: 中南大学, 2004.
- [7] 叶苗, 王勇. 基于支持向量回归学习机的网络流量预测 [J]. 桂林工学院学报, 2007, 27 (2): 282-284.
- [8] 胡丹. 小波支持向量回归模型及其应用研究 [D]. 成都: 西南交通大学, 2006.
- [9] 李万领, 孟晨, 等. 基于改进灰色模型的故障预测研究 [J]. 中国测试, 2012, 38 (2): 26-28.

(上接第 1335 页)

(37 针) 的多功能采集卡, 由于该类型采集卡只能输入电压信号, 而扭矩传感器输出的是 10~15 kHz 的频率信号, 因此, 也会进行相应信号类型的转换。该测试系统的采集程序同样采用 LabVIEW 软件进行编程, 由于程序与流体参数测试系统相类似, 此处不再赘述。

3 结论与讨论

国产的离心式血泵尚无成功的临床应用, 课题组以体外循环用无叶片离心式血泵为研究对象, 设计了一套完整的对体外循环用离心式血泵流量、压力和扭矩进行测试的测试平台。

本测试系统实现了血泵流量、压力和扭矩信号的准确采集和动态特性的测试, 并为血泵其它相关性能参数如效率、 $N-P-F$ (转速-压力-流量) 曲线的测试提供了重要的手段。血泵的功率和效率由测得的数据计算得到, 从考核血泵设计优劣的角度来说, 关心的是血泵的有效功率和泵效率, 相关计算公式为

$$P_i = M\omega$$

$$P_o = p q$$

$$\eta = \frac{P_o}{P_i} \times 100\%$$

式中, P_i 为离心泵的输入功率, M 为扭矩, ω 为转速; P_o 为离心泵的有效输出功率, p 为输出压力, q 为输出流量; η 为离心泵的效率。

通过试验计算的方法分析得出的数据, 以此对设计制造的离心泵的重要性能参数进行评价, 并通过对测试参数进行分析计算来对离心泵的结构进行进一步的优化。

参考文献:

- [1] 路力军, 胡兆燕, 陈正龙, 等. 体外循环用血泵的研究进展 [J]. 北京生物医学工程, 2012, 31 (4): 433-439.
- [2] 杨明. 人工心脏血泵检测 [J]. 电子测量与仪器学报, 2009, 23 (10): 1-7.
- [3] 柳光茂, 周建业, 胡盛寿, 等. 左心辅助泵体外测试的研究 [J]. 中国生物医学工程学报, 2010, 29 (1): 106-110.
- [4] 马小翠, 彭朝琴, 刘秋生, 等. 基于 LabVIEW 的电液伺服阀测试系统设计与实现 [J]. 计算机测量与控制, 2012, 20 (6): 1476-1479.
- [5] 王玲玲, 张辉. 基于 LabVIEW 的计算机辅助水泵测控实验系统 [J]. 仪器仪表学报, 2007, 28 (4): 230-232.
- [6] 陈数学, 刘萱. LabVIEW 宝典 [M]. 北京: 电子工业出版社, 2011.