

文章编号: 1006-4710(2013)02-0172-04

# 基于 DPSO 优化支持向量机的 水轮机组振动故障诊断

张欣伟<sup>1</sup>, 陈文献<sup>2</sup>, 张锋利<sup>3</sup>

(1. 西安理工大学 水利水电学院, 陕西 西安 710048;

2. 安康供电局, 陕西 安康 725000; 3. 陕西地方电力设计有限公司, 陕西 西安 710075)

**摘要:** 针对 PSO 算法在寻找支持向量机最优参数的后期容易陷入局部最佳, 影响支持向量机在水轮机振动故障诊断中的正确率这一问题, 选用动态粒子群算法 (DPSO) 来优化支持向量机, 将水轮机组的故障特征向量输入优化后的支持向量机进行故障类型诊断。仿真结果表明, DPSO 优化的支持向量机有较好的分类识别准确率和较高的诊断精度, 可以寻找到全局最优解。

**关键词:** 水轮机; 振动故障诊断; 动态粒子群算法; 支持向量机

中图分类号: TK73.8

文献标志码: A

## Hydraulic Generating Vibration Faults Diagnosis by Support Vector Machine Based on Particle Swarm Optimization

ZHANG Xinwei<sup>1</sup>, CHEN Wenxian<sup>2</sup>, ZHANG Fengli<sup>3</sup>

(1. Faculty of Water Resources and Hydroelectric Engineering, Xi'an University of Technology, Xi'an 710048, China;

2. Ankang Power Supply Bureau, Ankang 725000, China;

3. Shaanxi Regional Electric Power Design Co. LTD, Xi'an 710075, China)

**Abstract:** According to the basic PSO algorithm, searching for optimum parameters of support vector machine in the late stage is easy to fall into local optimum, and further affects support vector machine in hydraulic turbine vibration fault diagnosis correct rate. With an aim at this problem, the dynamic particle swarm algorithm (DPSO) is selected to optimize the support vector machine. The hydraulic turbine fault feature vector is input into the optimized support vector machine fault diagnosis. The simulation results show that DPSO optimized SVM can find the global optimal solution, thereby having good classification accuracy. In the hydraulic turbine vibration fault diagnosis compared to the traditional PSO optimized support vector machine has higher diagnostic accuracy.

**Key words:** hydraulic turbine; vibration faults diagnosis; PSO; SVM

水轮发电机组结构复杂, 机组中若有一处设备故障, 如不及时处理, 会产生连锁反应而引起其他部分产生故障, 严重影响发电的可靠性。近年来, 随着水轮发电机组状态监测系统的投入运行, 人们认识到故障诊断的重要性<sup>[1]</sup>。根据作用机理的不同, 水轮机组的振动分为机械、电磁和水力三种, 机组的振动或者摆度都是由上面三种振动机理复合作用而成<sup>[2]</sup>。因此, 提取水轮机振动信号特征向量来诊断水轮机组的故障是简便有效的方法。

支持向量机作为一种新的模式识别方法, 采用结构风险最小化原则, 具有较强的泛化能力, 与神经网络相比, 其分类识别准确度不容易受到样本数量的影响, 克服了神经网络在训练中易于陷入局部极小等缺点<sup>[3]</sup>。但是在应用支持向量机时需要选定核函数宽度以及惩罚系数, 这两个参数的选择直接影响到支持向量机的分类准确度。针对支持向量机的参数选择问题, 应用较多的是粒子群算法来优化支持向量机。由于粒子群算法具有收敛速度快等优

收稿日期: 2013-03-08

基金项目: 国家自然科学基金资助项目(51279161)。

作者简介: 张欣伟, 男, 讲师, 研究方向为水力机组状态监测。E-mail: superzxw@163.com。

点,可以有效地解决支持向量机中参数优化的问题,但是该算法由于受到惯性权值的影响,前期收敛速度快,而后期容易陷入局部最优<sup>[4-5]</sup>。因此,为了使粒子群算法具有较强的局部搜索能力,而寻求到全局最优解,提高支持向量机的诊断精度,本文采用改进粒子群算法的动态粒子群算法(DPSO)来优化支持向量机的参数<sup>[6]</sup>。将优化后的支持向量机应用到水轮机的振动故障诊断中,通过仿真实验验证,改进后的粒子群算法使支持向量机在水轮机振动的故障诊断准确度上相比改进前的有所提高。

## 1 粒子群算法

### 1.1 基本粒子群算法

粒子群算法(PSO)是由 Kennedy 等人模拟鸟群捕食行为而提出的一种寻优算法。PSO 算法与其他寻优演化算法相似,均基于群体对环境的适应度,将种群中的个体移动到最佳的区域,通过个体协作来寻找最优解<sup>[7]</sup>。在 PSO 算法中,个体通过与种群不断的交互来修正自己在搜索空间中的知识,在交互过程中,个体不断修正模拟种群中成功的个体,最终导致种群中最优规范的出现。

在粒子群算法中,每个粒子都以一定的速度在搜索空间中飞行,所有粒子都有一个被目标函数设定的适应值。粒子群开始初始化为一群随机粒子,每个粒子在一次寻优迭代过程中,都通过追踪 2 个极值来更新自己,一个是粒子本身找到的最优解,叫做个体极值  $p_{best}$ ,另一个是当前为止,种群所找到的最优解,叫做全局极值  $g_{best}$ 。对每个粒子来说,找到上述两个极值后,每个粒子的速度和位置更新方程为<sup>[8]</sup>:

$$V^{t+1} = wV^t + c_1 \times r_1 \times (p_{best}^t - x^t) + c_2 \times r_2 \times (g_{best}^t - x^t) \quad (1)$$

$$X^{t+1} = X^t + V^{t+1} \quad (2)$$

式中,  $t$  为迭代的次数;  $V^t$  为粒子第  $t$  次迭代的速度;  $X^t$  为粒子第  $t$  次迭代的位置;  $w$  为惯性权重;  $r_1$  和  $r_2$  为(0,1)区间内的随机数;  $c_1$  和  $c_2$  为学习因子,一般取  $c_1 = c_2 = 2$ 。

### 1.2 动态粒子群算法(DPSO)

在上述的传统粒子群算法中,惯性权重  $w$  是一个非常重要的参数,  $w$  取值较大有利于提高算法的全局搜索能力,但是过大会使运算量变大。而  $w$  取的较小有利于提高算法的局部搜索能力,但是过小又会使得算法陷入局部极值<sup>[9]</sup>。在基本粒子群算法中  $w$  取为 1,容易使算法在后期缺乏收敛能力。因此需要选取一个  $w$  既能保证粒子有最佳的局部搜

索能力也同时具有全局搜索能力。因此,DPSO 算法的核心就是惯性权重  $w$  是动态的。动态惯性权重  $w$  的公式为:

$$w = w_{max} - \frac{t(w_{max} - w_{min})^2}{M} \quad (3)$$

其中  $M$  代表最大迭代次数,  $w_{max}$  为迭代开始时的取值,  $w_{min}$  表示算法达到最大迭代次数时的取值。

## 2 支持向量机(SVM)

支持向量机 SVM 实现的基本思想是在初始阶段先选择好的一个非线性变换方法,将输入向量由低维非线性样本空间映射到高维或无穷维的线性特征样本空间<sup>[10]</sup>。在这一高维线性样本空间中构造一个最优分类超平面。

在考虑非线性映射方面,即  $x \Rightarrow \varphi(x)$ ,映射  $\varphi$  函数即内积核函数的是否存在,可由 Mercer 定理得到保证。通过样本空间的非线性变换得到的线性样本空间之后,SVM 就可以通过求解最优解的方法来寻找最优划分超平面的支持向量。

最优超平面推导过程如下<sup>[11]</sup>:

设训练样本  $\{x_i, y_i\}_{i=1}^N$ ,其中  $x_i$  是输入样本,  $y_i$  是待分类的两个类别;

分类超平面可用以下方程表示:

$$w \cdot x + b = 0 \quad (4)$$

式中  $b$  是超平面的常数项。寻找最优超平面,也就是寻找最优  $w$  和  $b$ 。两类待分的样本均满足  $|w \cdot x + b| \geq 1$ ,因此,  $|w \cdot x + b| = 1$  就是离分类平面最近的样本点。这样,问题就可归纳为求解:

$$\min \frac{\|w\|^2}{2} \quad (5)$$

寻找最优超平面最终归结为一个二次规划问题。

运用支持向量机就需要选择一种核函数,核函数不同构造的支持向量机也不同。本文选择的核函数为径向基核函数:

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

其中  $\sigma$  为径向基核函数的参数。

## 3 基于 DPSO 的支持向量机优化方法

在运用支持向量机进行模式识别应用时,需要对惩罚系数  $c$  以及径向基核函数的参数  $\sigma$  进行选择,而两个参数取值不同对支持向量机的分类准确度影响很大。传统的参数选择方法就是通过不断试验或者采用网格搜索法来寻找使支持向量机的诊断准确度达到最大的参数,这些方法不仅耗时,而且很难确定一个合理的参数范围<sup>[12]</sup>,而使最后 SVM 的

诊断准确度并不能达到最优。本文采用 DPSO 优化 SVM 的参数,具体优化步骤为:①初始化种群规模;②用初始粒子向量对应的支持向量机对训练样本进行学习预测,得到初始粒子当前状态的预测误差作为粒子的适应度值,将各粒子的当前适应度值与这个粒子最优适应度值进行比较,选择粒子群体的最优位置;③计算惯性权重,并利用粒子的速度位置更新方程来更新粒子的速度位置;④检查最后是否达到最大的迭代次数以及精度是否满足要求,若满足,则得到最优解,若不满足,则从第二步开始重新迭代。

## 4 实例仿真

### 4.1 故障特征向量

水轮发电机的故障形式有多种,本文以转子不平衡、转子不对中,轴承间隙过大以及尾水管的偏心涡带为例,通过传感器测得机组振动信号后,进行频谱分析,频谱图中的不同频率成分都是由不同的故障特征频率所组成,反映了不同的故障原因<sup>[13]</sup>。通过这些频率基本能判断出故障产生的部位。

通过测得故障振动数据频谱图中的频率分量作为故障特征向量。设  $f$  为转子的转频,故障特征向量由  $0.5f$ ,  $1f$ ,  $2f$ ,  $3f$  以及  $> 3f$  频段上的分量组成。表 1 为四种故障编码,表 2 为针对每个故障列出 3 组特征向量。

表 1 水轮机组四种故障类型编码表

Tab.1 Four kinds of fault type and coding table

故障类型	转子不平衡	转子不对中	轴承间隙过大	尾水管偏心涡带
编码	1	2	3	4

表 2 水轮机组 4 种故障特征向量

Tab.2 Four kinds of fault feature vector

编码	$0.5f$	$1f$	$2f$	$3f$	$>3f$
1	0.05	0.90	0.11	0.05	0.15
1	0.01	0.98	0.10	0.02	0.21
1	0.02	1.00	0.08	0.03	0.18
2	0.02	0.69	0.96	0.75	0.21
2	0.01	0.85	0.98	0.71	0.07
2	0.09	0.71	0.88	0.65	0.10
3	0.06	0.14	0.15	0.05	0.98
3	0.04	0.16	0.08	0.06	0.93
3	0.07	0.13	0.11	0.02	0.99
4	0.92	0.21	0.03	0.23	0.28
4	0.90	0.20	0.05	0.02	0.18
4	0.88	0.21	0.12	0.04	0.10

## 4.2 诊断分析

在得到故障特征向量之后,每种故障特征向量选取 10 组作为训练样本,每种故障特征向量并选取 5 组作为测试样本。在选择完样本后,对 DPSO 算法进行参数设定,种群规模 20 个,进化次数 50 次,并用基本 PSO 算法与 DPSO 算法进行比较。两种方法的最佳适应度曲线如下图 1 所示,诊断结果如表 3 所示。

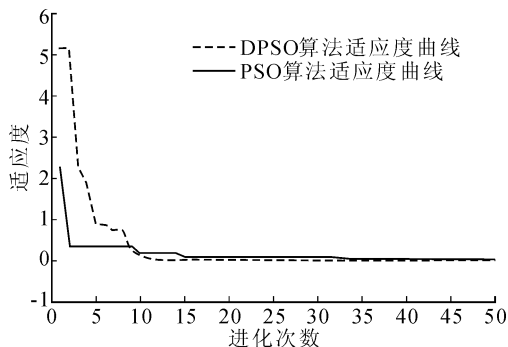


图 1 两种不同 PSO 最佳适应度曲线

Fig.1 Adaptation curve of two different PSO algorithm

表 3 诊断结果对比

Tab.3 Comparison of diagnostic result

诊断方法	核函数参数 $\sigma$	正规化参数 $\lambda$	诊断准确度/%
SVM	0.20	80.00	86.32
PSO-SVM	1.53	56.25	89.49
DPSO-SVM	0.97	35.15	92.68

从图 1 中的基本 PSO 与 DPSO 的适应度曲线可以看出, PSO 前期收敛速度较快,但后期容易陷入局部最优,而 DPSO 虽然在前期收敛速度慢,但是该算法可以跳出局部最优而寻找到全局最优值。同时从表 3 的诊断结果也可看出 DPSO 优化的支持向量机准确度高。

## 5 结论

本文针对 PSO 优化的支持向量机容易在寻找最优值时陷入局部最优,提出了采用 DPSO-SVM 的方法来诊断水轮机的振动故障。利用动态粒子群算法与支持向量机相结合,来优化支持向量机的参数,优化后的支持向量机诊断准确度相比基本粒子群算法优化的支持向量机的准确度有所提高,证明了 DPSO-SVM 算法可以更加有效的利用在水轮机振动的故障诊断中。

## 参考文献:

[1] 汪军,朱浩.水轮机组状态检修的现状和发展趋势[J].

- 水电厂自动化,2005(2):14-17.
- Wang Jun, Zhu Hao. Current situation and development trend of conditional overhaul of hydropower generator sets [J]. Hydro electric Power Station Automation. 2005(2): 14-17.
- [2] 贾嵘,陈晓芸,李辉,等. 基于粒子群优化 RBF 神经网络的水轮发电机组振动故障诊断[J]. 西北农林科技大学学报,2009,37(6):229-234.
- Jia Rong, Chen Xiaoyun, Li Hui, et al. Hydraulic generating vibration faults diagnosis by RBF neural network based on particle swarm optimization [J]. Journal of Northwest A&F University, 2009, 37(6): 229-234.
- [3] 彭文季,罗兴铸. 基于小波包分析和支持向量机的水轮发电机组振动故障诊断研究[J]. 中国电机工程学报, 2006, 26(24):164-168.
- PENG Wenji, LUO Xinqi. Research on vibrant fault diagnosis of hydro-turbine generating unit based on wavelet packet analysis and support vector machine [J]. Proceedings of the CSEE, 2006, 26(24): 164-168.
- [4] 谢晓锋,张文俊,杨之廉. 微粒群算法综述[J]. 控制与决策,2003,18(2):129-134.
- Xie Xiaofeng, Zhang Wenjun, Yang Zhilian. Overview of particle swarm optimization [J]. Engineering Science, 2003, 18(2): 129-133.
- [5] Shi Yuhui, Eberhart R. A modified particle swarm optimizer [C]//IEEE World Congress on Computational Intelligence, Anchorage, 1998:69-73.
- [6] 武桦,王小宇,张丽. 水轮发电机组状态监测与故障诊断系统研究[J]. 西北水力发电. 2006,22(3):4-8.
- Wu Hua, Wang Xiaoyu, Zhang Li. Study on state monitoring and fault diagnosis system of hydraulic generator [J]. Journal of Northwest Hydroelectric Power. 2006, 22(3): 4-8.
- [7] 沈东,褚福涛,陈思. 水轮发电机组振动故障诊断与识别[J]. 水动力学研究与进展,2000,15(1):129-133.
- Shen Dong, Chu Futao, Chen Si. Diagnosis and identification of vibration accident for hydro-generator unit [J]. Journal of Hydrodynamics, 2000, 15(1): 129-133.
- [8] 吴晓辉,刘炯,梁永春. 支持向量机在电力变压器故障诊断中的应用[J]. 西安交通大学学报, 2007, 41(6): 722-726.
- Wu Xiaohui, Liu Jiong, Liang Yongchun. Application of support vector machine in transformer fault diagnosis [J]. Journal of Xi'an Jiaotong University, 2007, 41(6): 722-726.
- [9] 饶泓,虞国全,胡倩如. 基于支持向量机的径向基网络结构优化[J]. 计算机工程与应用,2008,44(5):67-69.
- Rao Hong, Yu Guoquan, Hu Qianru. RBF neural network structure optimization method based on SVM [J]. Computer Applications, 2008, 44(5): 67-69.
- [10] 张亚楠,魏武,武林林. 基于小波包 Shannon 熵 SVM 和遗传算法的电机机械故障诊断[J]. 电力自动化设备, 2010, 30(1): 87-91.
- Zhang Yanan, Wei Wu, Wu Linlin. Motor mechanical fault diagnosis based on wavelet packet Shannon entropy SVM and GA [J]. Electric Power Automation Equipment, 2010, 30(1): 87-91.
- [11] 贾嵘,张云,洪刚. 基于改进 PSO 的 LSSVM 参数优化在变压器故障诊断中的应用[J]. 电力系统保护与控制, 2010, 38(17): 120-124.
- Jia Rong, Zhang Yun, Hong Gang. Parameter optimization of least squares support vector machine based on improved particle swarm optimization in fault diagnosis of transformer [J]. Power System Protection and Control, 2010, 38(17): 120-124.
- [12] 黄戈,崔建武,陈晓芸,等. 基于粒子群优化神经网络的水轮机振动故障诊断[J]. 电网与清洁能源, 2009, 25(4): 54-57.
- Huang Ge, Cui Jianwu, Chen Xiaoyun, et al. Hydraulic Turbines Vibration Fault Diagnosis by Neural Network Based on Particle Swarm Optimization [J]. Power System and Clean Energy, 2009, 25(4): 54-57.
- [13] 苏立,南海鹏,余向阳,等. 关联规则分类的数据挖掘方法在水电机组故障诊断中的应用[J]. 西安理工大学学报, 2012, 28(1): 106-110.
- Su Li, Nan Haipeng, Yu Xiangyang, et al. The application of data stream mining method of associative rule classification in fault diagnosis of hydro-turbine generating unit [J]. Journal of Xi'an University of Technology. 2012, 28(1): 106-110.

(责任编辑 杨小丽)