

文章编号:0559-9350(2011)03-0373-06

基于IPSO优化LSSVM的水轮发电机组振动故障诊断

贾嵘¹, 洪刚², 武桦¹, 薛建辉¹

(1. 西安理工大学 水利水电学院, 陕西 西安 710048; 2. 广西电网公司 北海供电局, 广西 北海 536000)

摘要: 提出改进的粒子群算法, 并与最小二乘支持向量机相结合, 得到基于IPSO-LSSVM的水轮发电机组故障诊断方法。改进后的粒子群算法能较好地调整算法在全局与局部搜索能力之间的平衡, 将其应用于LSSVM的参数优化, 可以提高故障诊断的精度和效率。实例分析结果表明, 本文模型不仅能够取得良好的分类效果, 而且诊断速度与精度均高于采用BP神经网络、LSSVM以及PSO-LSSVM等方法, 适合在实际工程中应用。

关键词: 水轮发电机组; 振动; 故障诊断; 最小二乘支持向量机; 改进粒子群算法

中图分类号: TM312

文献标识码: A

1 研究背景

据统计, 水轮发电机组约有80%的故障或事故都能够在振动信号中有所反映, 同时异常的振动也是损坏设备的重要原因之一, 因而对水轮发电机组振动状态进行监测和诊断具有重要意义。目前, 水轮发电机组故障诊断的常用方法有神经网络^[1-2]、支持向量机^[3-4]等。神经网络作为解决复杂非线性问题的有效工具已经在故障诊断领域中得到广泛应用。但由于神经网络技术只是一种依赖于经验的启发式技术, 缺乏坚实的理论基础, 它的学习过程采用经验风险最小化原理, 因而在小样本情况下, 容易出现过学习现象而导致低的泛化能力, 这些不足制约了神经网络在智能故障诊断中进一步的应用和发展^[5]。支持向量机(support vector machine, SVM)是在统计学习理论上发展起来的一种新的学习方法, 它是针对小样本, 采用结构风险最小化原则^[6-7], 具有很强的泛化能力, 并克服了神经网络中存在的过拟合、收敛速度慢、容易陷入局部极值等缺点, 在水轮发电机组故障诊断中有着很好的应用前景。然而, 支持向量机参数的选取困难影响了其实用性。

粒子群(particle swarm optimization, PSO)算法是一种基于群体智能的演化计算理论, 源于对鸟群捕食行为的研究^[8]。PSO算法收敛速度快、鲁棒性高、全局搜索能力强, 已经成功解决了函数优化、神经网络中参数优化等优化问题^[9-10]。本文通过对PSO算法中的重要参数惯性权值进行改进, 以使该算法能够较好地调整全局与局部搜索能力之间的平衡; 然后将改进后的PSO算法用于最小二乘支持向量机(least squares support vector machine, LSSVM)的参数优化。实例分析结果表明, IP-SO-LSSVM方法不仅能够取得良好的分类效果, 而且诊断速度与精度高于传统智能诊断方法, 更加适用于水轮发电机组振动故障的诊断。

2 计算模型

2.1 PSO算法的改进 在PSO算法中, 每个粒子都是解空间中具有一定速度的一个点, 不同粒子具有对应于与目标函数相关的个体适应度。群体中的粒子在每次迭代搜索的过程中, 跟踪两个极值来

收稿日期: 2009-06-25

基金项目: 霍英东高校青年教师基金(101076)

作者简介: 贾嵘(1971-), 陕西西安人, 博士, 教授, 主要从事电力系统自动化装置研究。E-mail: ja.rong@163.com

更新自己：一个是粒子本身找到的最优解——个体极值 $pbest$ ；另一个是整个种群目前找到的最优解——全局极值 $gbest$ 。在 PSO 算法中，粒子的速度和位置更新方程为：

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

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

式中： t 为迭代次数； V^t 为粒子第 t 代的飞行速度； X^t 为粒子第 t 代的当前位置； w 为惯性权重，它使粒子保持运动惯性； r_1 、 r_2 为均匀分布在(0, 1)区间的随机数； c_1 、 c_2 为学习因子，分别调节向全局最优粒子和个体最优粒子方向飞行的最大步长，通常取 $c_1=c_2=2$ 。

惯性权值 w 代表粒子继承其父代粒子速度的程度，对 PSO 算法的收敛速度和精度有较大影响，较大的 w 使算法具有较强的全局搜索能力，而较小的 w 则更有利于局部搜索^[11]。基本的 PSO 算法中认为 $w=1$ ，因此在迭代后期缺乏局部收敛能力。为此本文提出了一种改进的非线性递减算法，以实现 PSO 算法能够较好地调整全局与局部搜索能力之间的平衡。惯性权值 w 的计算公式为：

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

式中： w_{\max} 、 w_{\min} 分别为最大惯性权值和最小惯性权值； t 为当前的迭代次数； t_{\max} 为最大允许迭代次数。

2.2 LSSVM 分类原理 LSSVM 是 J.A.K Suykens^[12]提出的一种回归预测算法，是标准 SVM 的一种扩展，优化指标采用平方项，并用等式约束代替标准 SVM 的不等式约束，即将二次规划问题转化为线性方程组求解，降低了计算复杂性，加快了求解速度。

LSSVM 方法采用如下形式的函数对未知函数进行估计：

$$f(x) = \omega^T \varphi(x) + b \quad (4)$$

式中： ω 为超平面的权值矢量； b 为偏置常数；非线性函数 $\varphi(\cdot)$ 将输入空间映射为高维特征空间。

给定训练样本集，LSSVM 定义如下优化问题：

$$\min J = \frac{1}{2} \omega^T \omega + \frac{1}{2} \lambda \sum_{i=1}^N \xi_i^2, \quad \lambda > 0 \quad (5)$$

式中： λ 为正规化参数。

约束条件为：

$$y_i = \omega \varphi(x_i) + b + \xi_i, \quad i = 1, 2, \dots, N \quad (6)$$

通过其对偶形式可以求它的最优解，对偶形式可以根据目标函数和约束条件建立拉格朗日函数：

$$L(\omega, b, \zeta, \alpha) = J - \sum_{i=1}^N \alpha_i (\omega^T \varphi(x_i) + b + \zeta_i - y_i) \quad (7)$$

式中： α 为拉格朗日乘子。

根据库恩-塔克(Karush-Kuhn-Tucker, KKT)条件有：

$$\frac{\partial L}{\partial \omega} = 0; \quad \frac{\partial L}{\partial b} = 0; \quad \frac{\partial L}{\partial \zeta} = 0; \quad \frac{\partial L}{\partial \alpha} = 0 \quad (8)$$

可得：

$$\omega = \sum_{i=1}^N \alpha_i y_i \varphi(x_i); \quad \sum_{i=1}^N \alpha_i = 0; \quad \omega = \lambda \zeta_i; \quad \omega^T \varphi(x_i) + b + \zeta_i - y_i = 0 \quad (9)$$

利用核函数的方法，令

$$K(x_i, x_j) = \varphi(x_i)^T \varphi(x_j) \quad (10)$$

其中 $K(x_i, x_j)$ 为满足 Mercer 条件的对称函数，根据式(6)优化问题转化为求解线性方程：

$$\begin{bmatrix} 0 & \mathbf{1}_v^T \\ \mathbf{1}_v & \Omega + C^{-1}I \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (11)$$

其中: $1_v = [1, \dots, 1]$, $\Omega_{ij} = K(x_i, x_j)$, $i, j=1, \dots, N$, 则回归函数为:

$$f(x) = \sum_{i=1}^N \alpha_i K(x_i, x_j) + b \quad (12)$$

选择不同的核函数 $K(x_i, x_j)$, 可构造不同的支持向量机。常用的核函数有径向基函数(RBF): $K(x_i, x_j) = \exp(-\|x_i - x_j\| / 2\sigma^2)$, 其中 σ 为 RBF 的参数; 多项式核函数: $K(x_i, x_j) = (x_i x_j + \theta)^d$, ($d \in N$); Sigmoid 核函数: $K(x_i, x_j) = \tanh(\beta(x_i, x_j) + \theta)$ 。本文选取 RBF 核函数来构造 LSSVM, 这样需要优化的参数最少, 只有正规化参数 λ 和核参数 σ 。

2.3 基于IPSO的LSSVM参数优化 LSSVM 参数 λ 和 σ 对其分类精度有较大的影响, 通常采用参数空间穷尽搜索法对 LSSVM 的参数进行优化, 其缺点是很难确定一个合理的参数范围, 这在一定程度上影响了故障诊断速度和精度^[13]。因此, 本文利用 IPSO 对 LSSVM 的重要参数进行优化调整, 其整个优化步骤如下: (1)对 PSO 进行初始化设置, 包括粒子维数、群体规模、迭代次数、粒子初始位置和速度等; (2)分别用每个粒子向量所对应的 LSSVM 对学习样本进行预测, 得到各粒子当前位置值的预测误差, 并将其作为各粒子的适应度值; (3)将各粒子的当前适应度值与该粒子自身的最优适应度值进行比较, 如果更优, 则将粒子当前的位置作为该粒子的最优位置; (4)将各粒子的自身最优位置适应度值与群体最优位置的适应度值比较, 如果更优, 则将该粒子的最优位置作为群体的最优位置; (5)根据式(3)计算惯性权值, 并利用式(1)、式(2)更新粒子的速度和位置; (6)检查是否满足终止条件, 如不满足则返回步骤(2)继续计算, 如满足则计算结束并输出结果。

3 实例分析

3.1 故障特征向量的提取 应用 IPSO-LSSVM 模型诊断水轮发电机组振动所引起的故障, 关键在于机组振动故障特征向量的提取。本文首先对采集到的振动数据进行去噪处理; 其次对各种状态下振动数据分别进行 3 层小波包分解, 提取了振动频谱中 $0.5f$ 、 $1f$ 、 $2f$ 、 $3f$ 和 高频频段上的幅值分量能量 (f 为机组转速对应的频率, 简称转频), 以及上导轴承、下导轴承、水导轴承、上机架、振动与转速的关系、振动与流量的关系共 11 种特征向量作为故障征兆属性; 最后选取水轮发电机组常见的 6 种故障作为 IPSO-LSSVM 模型的输出。对于这 6 种故障分别选取 3 组特征向量值, 其中 2 组作为学习样本用于模型的训练, 1 组作为测试样本用于训练后模型的验证。为了简化模型结构, 对故障特征向量进行了归一化处理。表 1 与表 2 分别是对应于 6 种故障的学习样本和测试样本。

3.2 诊断模型构建 由于 LSSVM 是二元分类器, 对于多个故障类型的水轮发电机组, 必须构造多元分类器才能进行故障诊断。本文采用“一对多”多分类法构建多元分类器, 将一种状态下的样本与其他状态样本组合, 共构建 6 个 IPSO-LSSVM 分类器识别水轮发电机组 6 种常见故障, 最终结果由分类距离最大的向量机决定, 定义有该故障为 +1, 无该故障为 -1。诊断模型如图 1 所示。

3.3 故障诊断 将表 1 所示的各种故障类型下的特征向量输入 IPSO-LSSVM 分类器中进行训练, 经多次调整训练后, 最终选定 IPSO-LSSVM 分类器的参数为: $\lambda=134.85$, $\sigma=0.59$ 。为了检验经过训练后的 IPSO-LSSVM 分类器对故障的分类能力, 将表 2 中水轮发电机组的各种故障类型的特征向量作为测试样本输入已经训练好的 IPSO-LSSVM 分类器中, 诊断结果如表 3 所示。可以看出, IPSO-LSSVM 分类器能够成功地实现水轮发电机组各种故障类型的分类。

为了检验本文方法在水轮发电机组振动故障诊断中的优势, 利用 Matlab 构造反向传播(back propagation, BP)神经网络, 网络输入层 11 个节点, 输出层 6 个节点。利用上述特征向量训练网络, 最终选定隐层为 9 个节点, 当迭代 450 次后, 达到期望误差, 输出诊断结果如表 4 所示。

同时, 将这些特征向量分别输入 LSSVM 和 PSO-LSSVM 中进行诊断比较, 对比结果如表 5 所示。由表 5 明显可以看出, IPSO-LSSVM 明显优于其他几种方法, 不仅更快地收敛于最优解, 而且很大程度地提高了诊断的精度。

表1 故障诊断学习样本

故障类型	0.5f	1f	2f	3f	高频	上导轴承	下导轴承	水导轴承	上机架	振动与转速的关系	振动与流量的关系
转子不平衡	0.01	0.97	0.12	0.03	0.24	0.09	0.02	0.04	0.81	0.08	0.03
转子不平衡	0.02	0.93	0.10	0.02	0.19	0.07	0.14	0.02	0.90	0.11	0.08
转子不对中	0.02	0.71	0.91	0.77	0.17	0.02	0.05	0.11	0.91	0.90	0.43
转子不对中	0.09	0.73	0.85	0.63	0.12	0.17	0.08	0.06	0.82	0.87	0.47
轴承间隙过大	0.04	0.17	0.11	0.08	0.91	0.05	0.06	0.17	0.15	0.82	0.03
轴承间隙过大	0.06	0.14	0.15	0.04	0.96	0.04	0.08	0.16	0.12	0.94	0.13
动静碰磨	0.11	0.83	0.44	0.56	0.04	0.11	0.02	0.94	0.85	0.02	0.04
动静碰磨	0.28	0.96	0.52	0.49	0.23	0.08	0.04	0.89	0.13	0.05	0.25
涡带偏心	0.92	0.23	0.03	0.21	0.27	0.05	0.85	0.27	0.21	0.09	0.18
涡带偏心	0.88	0.21	0.02	0.14	0.13	0.05	0.82	0.13	0.16	0.02	0.15
水力不平衡	0.05	0.33	0.09	0.17	0.12	0.04	0.06	0.03	0.23	0.17	0.86
水力不平衡	0.03	0.12	0.05	0.13	0.08	0.11	0.08	0.18	0.35	0.32	0.93

表2 故障诊断测试样本

故障类型	0.5f	1f	2f	3f	高频	上导轴承	下导轴承	水导轴承	上机架	振动与转速的关系	振动与流量的关系
转子不平衡	0.02	0.91	0.10	0.01	0.05	0.12	0.03	0.15	0.89	0.03	0.02
转子不对中	0.95	0.11	0.03	0.01	0.08	0.02	0.84	0.06	0.13	0.02	0.13
轴承间隙过大	0.03	0.02	0.06	0.12	0.05	0.17	0.09	0.09	0.32	0.18	0.91
动静碰磨	0.01	0.68	0.81	0.72	0.26	0.03	0.21	0.07	0.87	0.83	0.28
涡带偏心	0.12	0.04	0.02	0.01	0.94	0.03	0.05	0.02	0.15	0.82	0.03
水力不平衡	0.22	0.83	0.42	0.48	0.02	0.12	0.07	0.87	0.21	0.13	0.07

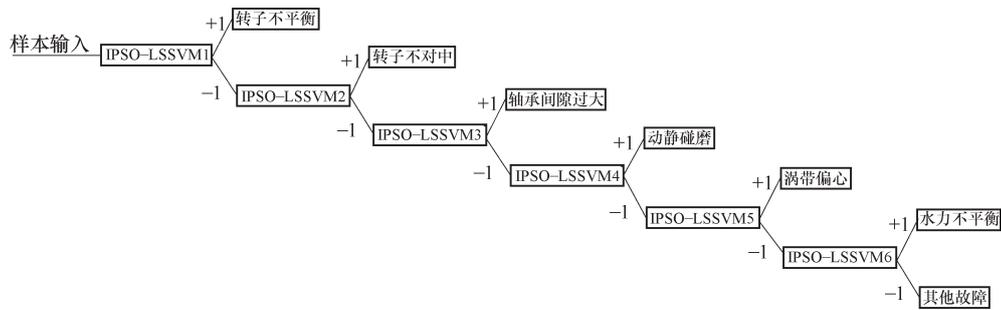


图1 IPSO-LSSVM 诊断模型

表3 IPSO-LSSVM 诊断结果

输出	转子不平衡	转子不对中	轴承间隙过大	动静碰磨	涡带偏心	水力不平衡
IPSO-LSSVM ₁	0.912 5	-0.944 5	-0.971 3	-1.085 0	-0.991 3	-0.842 1
IPSO-LSSVM ₂	-0.911 7	0.940 5	-0.954 8	-0.922 3	-0.889 1	-0.892 7
IPSO-LSSVM ₃	-0.924 8	-0.876 9	0.968 6	-0.861 8	-0.904 3	-0.962 4
IPSO-LSSVM ₄	-0.901 3	-0.904 1	-0.966 4	1.041 7	-0.951 7	-0.974 9
IPSO-LSSVM ₅	-1.007 4	-0.801 2	-0.841 0	-0.911 3	1.012 4	-1.009 0
IPSO-LSSVM ₆	-1.124 1	-1.263 4	-0.900 6	-1.121 0	-0.901 1	0.921 4

表4 BP神经网络诊断结果

输出	转子不平衡	转子不对中	轴承间隙过大	动静碰磨	涡带偏心	水力不平衡
y_1	0.811 6	-0.092 1	0.045 1	0.031 7	0.062 8	-0.055 1
y_2	-0.072 4	0.807 1	0.012 5	-0.011 6	0.058 1	0.016 8
y_3	0.031 6	-0.041 5	0.796 2	0.082 1	-0.023 6	-0.065 3
y_4	0.117 4	0.011 7	-0.062 5	0.890 1	-0.091 5	-0.039 1
y_5	-0.081 6	0.022 7	-0.024 7	-0.032 1	0.851 2	0.051 2
y_6	-0.092 4	0.101 3	0.053 7	-0.021 1	-0.023 6	0.816 6

表5 诊断结果对比

	σ	λ	迭代次数	平均诊断精度/%
BP神经网络			450	82.86
LSSVM	0.14	80.21	240	87.13
PSO-LSSVM	0.42	44.17	120	91.64
IPSO-LSSVM	0.59	134.85	80	94.85

4 结论

惯性权值对 PSO 算法的收敛速度和精度有较大影响, 因此本文对其进行了改进, 以使该算法能够较好地调整全局与局部搜索能力之间的平衡; 同时针对 LSSVM 在水轮发电机组振动故障诊断中存在参数选取困难的问题, 将改进后的 PSO 算法与 LSSVM 相结合, 即利用 IPSO 算法对 LSSVM 进行参数优化。优化后的 LSSVM 具有较高的分类精度, 并通过诊断实例证明了该方法的有效性。

参 考 文 献:

- [1] 符向前, 刘光临, 蒋劲. BP神经网络在水轮发电机组状态监测与诊断系统中的应用[J]. 武汉大学学报(工学版), 2002, 35(1): 24-25.
- [2] 贾嵘, 白亮, 罗兴铸, 等. 基于神经网络的水轮发电机组振动故障诊断专家系统[J]. 水力发电学报, 2004, 23(6): 120-123.
- [3] 彭文季, 罗兴铸. 基于粗糙集和支持向量机的水电机组振动故障诊断[J]. 电工技术学报, 2006, 21(10): 117-121.
- [4] 彭文季, 罗兴铸. 基于小波包分析和支持向量机的水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.
- [5] 彭文季, 罗兴铸. 基于小波神经网络的水电机组振动故障诊断研究[J]. 水力发电学报, 2007, 26(1): 123-127.
- [6] 邓乃扬, 田英杰. 数据挖掘中的新方法—支持向量机[M]. 北京: 科学出版社, 2004.
- [7] Yuan Sheng-fa, Chu Fu-lei. Support vector machines-based fault diagnosis for turbo-pump rotor[J]. Mechanical Systems and Signal Processing, 2006, 20(4): 939-952.
- [8] Eberhart R C, Kennedy J. A new optimizer using particle swarm theory[C]//Proc 6th Int Symposium on Micro Machine and Human Science, Nagoya, 1995: 39-43.
- [9] Brits R, Engelbrecht A P, Van Den Bergh F. Locating multiple optima using particle swarm optimization[J]. Applied Mathematics and Computation, 2007, 189(2): 1859-1883.
- [10] 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(自然科学版), 2009, 37(6): 229-233.
- [11] 张俊, 程春田, 廖胜利, 等. 改进粒子群优化算法在水电站群优化调度中的应用研究[J]. 水利学报, 2009, 40(4): 435-441.

- [12] Suykens J A K, Vandewalle J. Least squares support vector machine classifiers[J]. *Neural Processing Letters* (S1370-4621), 1999, 9(3): 293-300.
- [13] 张树团, 张晓斌, 雷涛, 等. 基于粒子群算法和支持向量机的故障诊断研究[J]. *计算机测量与控制*, 2008, 16(11): 1573-1574.

Vibration fault diagnosis of hydroelectric generating unit by Least Squares Support Vector Machine based on Improved Particle Swarm Optimization

JIA Rong¹, HONG Gang², WU Hua¹, XUE Jian-hui¹

(1. Xi'an University of Technology, Xi'an 710048, China;

2. Beihai Power Supply Bureau, Guangxi Power Company, Beihai 536000, China)

Abstract: In order to diagnosis the vibration faults of hydroelectric generating unit quickly and accurately, an Improved Particle Swarm Optimization (IPSO) algorithm is proposed. The new method of fault diagnosis was combined with the Least Squares Support Vector Machine (LSSVM) to form the IPSO-LSSVM algorithm. The algorithm can adjust the balance between global and local search capabilities suitably, which optimize the parameters of LSSVM to improve the precision and efficiency of the faults diagnose. The comparison with experiment result shows that the IPSO-LSSVM method not only has attained good classification results, but also the precision and rate of diagnostic is better than BP network, LSSVM and PSO-LSSVM. Consequently, the IPSO-LSSVM model is a proper alternative for vibration fault diagnosis of hydroelectric generating unit.

Key words: hydroelectric generating unit; vibration; faults diagnosis; least squares support vector machine; improved particle swarm optimization algorithm

(责任编辑: 韩 昆)

(上接第 372 页)

Vertical vibration characteristics of pipe pile in saturated soil

LIU Lin-chao, YAN Qi-fang

(Xinyang Normal University, Xinyang 464000, China)

Abstract: There are important differences in the mechanical properties, especially dynamic behaviors of a pile in saturated soil and single-phase soil, because of the flow quality of pore water in saturated soil and the different permeability of the soil and the pile. The soil around the pile is regarded as saturated porous medium, and the macro-mechanical properties of saturated soil is described by the theory of porous medium. Applying the Novak plane assumption to saturated soil, the Novak plane strain model was spread to pipe pile in saturated soil, and the vertical vibration of soil layer was solved; the vertical vibration of pipe pile in saturated soil was analyzed, and the influences of mechanical parameters of soil around the pile and inner soil on the vibration were investigated. The results indicate that the changes of complex stiffness and admittance of pipe pile with frequency are different with solid pile; the soil around the pile has a greater influence than the inner soil, and the frictional resistance of outer soil is larger than that of the inner soil.

Key words: porous medium; saturated soil; vertical vibration; complex stiffness

(责任编辑: 韩 昆)