

基于 FSVM 的起重机臂筒焊接变形测量研究*

钱承¹, 鄂加强²

(1. 嘉兴学院机电工程学院 嘉兴, 314001) (2. 湖南大学机械与运载工程学院 长沙, 410082)

摘要 为解决获取起重机臂筒固有焊接变形的不便利及复杂性问题,应用支持向量机模糊理论融合技术对起重机臂筒焊接变形测量方法进行研究,并采用遗传算法对支持向量机的核参数及惩罚因子进行寻优,以误差函数为评价指标,最终确定了核参数 $\sigma=1.8$ 和惩罚因子 $c=26$ 。将该测量模型应用于焊接变形的预测,同时采用智能图像检测法对相同预测点进行测量对比,结果显示所建立的融合模型对起重机臂筒焊接变形的测量和智能图像检测法的误差在 5% 以内,验证了该测量方法的准确性。

关键词 焊接变形;支持向量机;模糊理论;遗传算法

中图分类号 TH212; TG404

引言

起重机吊臂筒体通常由多节筒状部件焊接而成。在焊接过程中,由于不均匀温度场以及由它引起的局部塑性变形导致了焊接变形和残余应力,该焊接变形将影响结构尺寸精度,而残余应力则降低吊臂筒体承载能力,因此必须对焊接变形进行检测。目前常用的研究方法有试验法^[1]、基于数字图像的摄影技术^[2-3]及基于有限元的逆解析法等^[4-6]。针对起重机吊臂筒体焊接变形测量的不便利性,如完全采用上述方法必将消耗大量的试验经费或计算机资源,试验周期较长,不能满足研制要求。

针对某型起重机吊臂筒体,其结构和材料一致,因此可以假定在焊接过程中其焊接变形量只和焊接条件有关。笔者在基于数字图像的摄影技术上采集了焊接变形量及相应时刻影响焊接变形的 4 个关键影响因素作为参考量,提出采用智能预测方法开发基于支持向量机模糊融合理论(fuzzy support vector machines,简称 FSVM)的起重机臂筒焊接变形测量方法。本方法充分发挥智能预测理论的优点,只需采集少量的焊接固有变形量及相应的影响因素,在小样本、非线性事件中发挥支持向量机和模糊理论的特点。

1 支持向量机模糊融合原理

支持向量机模糊融合原理是以支持向量机和模糊理论为基础而结合的智能方法^[7-10]。支持向量机法(support vector machine,简称 SVM)是由 Vapnik^[11-12]等提出的专门研究小样本、非线性及高维数情况下的机器学习方法,其核心思想^[13]是通过核函数定义的非线性变换将 n 维样本空间映射到一个高维特征空间,在此高维空间中寻找输入量与输出量之间的一种非线性关系,其非线性回归原理如图 1 所示。




图 1 支持向量机原理

Fig. 1 Principle of support vector machine

假设非线性映射为 $\varphi(x_i)$,将 n 维样本数据 $(x_1, y_1), \dots, (x_l, y_l) \in R^n$ 映射到高维特征空间,根据结构风险最小化原则,求解如式(1)所示的最优化问题

* 国家自然科学基金青年资助项目(61603154);浙江省自然科学基金青年资助项目(LQ17E050010)
收稿日期:2017-03-20;修回日期:2017-06-27

$$\begin{cases} \min \frac{1}{2} \|w\|^2 + cR_e \\ \text{s. t. } |y_i - w^T \varphi(x_i) - b| \leq \epsilon \end{cases} \quad (1)$$

其中: R_e 为经验风险系数; c 为惩罚因子系数; ϵ 为样本误差, 也叫松弛变量; b 为偏移量; w 为所求超平面的法向量。

求解式(1)的优化问题, 将不等式约束改为等式约束, 引入拉格朗日算子 $a_i (i=1, 2, \dots, n)$, 建立式(2)的拉格朗日方程

$$L(\omega, b, \epsilon, a) = \frac{1}{2} \omega \omega + c \sum_{i=1}^n \epsilon_i^2 - \sum_{i=1}^n a_i [\varphi(x_i) \omega + b + \epsilon - y_i] \quad (2)$$

要使目标函数取最小值, 则使拉格朗日方程中变量的偏导数为 0, 即如式(3)所示

$$\begin{cases} \partial L / \partial \omega = \omega - \sum_{i=1}^n a_i \varphi(x_i) = 0 \\ \partial L / \partial \epsilon_i = c \epsilon_i - a_i = 0 \\ \partial L / \partial b = \sum_{i=1}^n a_i = 0 \\ \partial L / \partial a_i = \omega \varphi(x_i) + b + \epsilon_i - y_i = 0 \end{cases} \quad (3)$$

通过求解式(3)得到 SVM 的回归函数为

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x) + b^* \quad (4)$$

其中: $K(x_i, x)$ 为径向基核函数。

$K(x_i, x)$ 可表示为

$$K(x, x_i) = \exp(-|x - x_i|^2 / \sigma^2) \quad (5)$$

模糊系统则是一种处理不确定性和非线性系统的强有力工具, 主要由模糊推理、输入量模糊化、输出量精确化和知识库几个环节构成。

假设对于一组有 n 条模糊推理规则

$$\begin{aligned} \text{if } x_1 \text{ is } A_{i1} \text{ and } x_2 \text{ is } A_{i2} \text{ and } \dots \text{ and } x_n \text{ is } A_{in}, \\ \text{then } y \text{ is } b_i \end{aligned} \quad (6)$$

其中: A_{ij} 为相应论域 X_j 上的模糊集; b_i 为实数。

将其转化为向量形式为

$$\text{if } x \text{ is } A_i, \text{ then } y \text{ is } b_i \quad (7)$$

其中: $x=(x_1, x_2, \dots, x_n)$; $A_i=(A_{i1}, A_{i2}, \dots, A_{in})$ 。

应用模糊推理可得推理结果为

$$y = \bigvee_i ((\bigwedge_x A_i(x)) \wedge b_i) \quad (8)$$

其中: \bigvee 和 \bigwedge 为模糊算子。

令隶属度函数为高斯函数, 模糊算子采用加法和乘法算子, 式(8)可转变为

$$y = \sum_{i=1}^n b_i \exp(-d(x - x_i)^2) \quad (9)$$

将径向基核函数 $K(x_i, x)$ 应用于式(4), 且过

超平面原点, 则式(4)就变化为

$$f(x) = \sum_{i=1}^n \alpha_i \exp(-d(x - x_i)^2) \quad (10)$$

对比模糊推理函数式(9)和支持向量机回归函数(10)可以发现, 两者是等价的。两者对应的关系可以描述为: 一个支持向量对应模糊逻辑系统的一条规则; 核函数对应模糊逻辑前件的隶属度函数; 支持向量机系数对应为模糊推理后件。

由以上分析, 可以得出支持向量机的模糊逻辑系统原理, 如图 2 所示。




图 2 支持向量机的模糊推理系统原理

Fig. 2 Principle of fuzzy inference system of SVM

2 基于支持向量机和模糊理论融合的起重机臂筒焊接变形测量方法

2.1 起重机臂筒焊接变形影响因素获取

焊接变形试验数据来自于某起重机企业基于多传感器融合的起重机臂筒焊接变形检测试验台架, 该装置通过起重机臂筒外形扫描检测, 本试验台架基于数字信号处理(digital signal processing, 简称 DSP)的功能模块(包括光源、摄像头、图像处理器、标准的控制与通讯接口)来完成图像的采集与处理。图像检测结果通过 I/O 接口送给处理机完成系统的其他控制功能, 首先, 系统从电荷耦合器件(charge coupled device, 简称 CCD)摄像头中读入起重机臂筒图像数据并进行预处理, 包括图像的增强、去噪等; 其次, 进行图像分割和形态学操作, 并对变形区域进行提取与锁定; 最后, 计算所提取出变形区域的特征, 统计变形信息, 并给出起重机臂筒变形区段的指标评价。智能图像检测法原理见图 3。

作为研究对象的某起重机臂筒截面规格如图 4 所示。其由上下两部分为厚度 10mm 的盖板, 通过盖面焊接构成。笔者采集如表 1 所示的 10 组不同焊接电流 I 、电压 U 、速度 v 及气流量 m 下所对应的焊接变形位移 d 的参数值。

2.2 起重机臂筒焊接变形计算模型的建立

基于上节试验所得到的焊接电流 I 、电压 U 、速度 v 和气流量 m 因素对焊接变形的影响, 将该 10

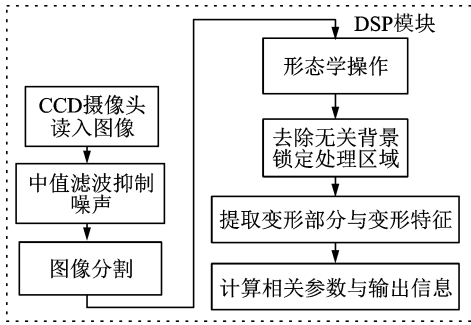


图 3 智能图像检测法原理

Fig. 3 Principle of intelligent image detection




图 4 起重机臂筒截面规格(单位:mm)

Fig. 4 Standard of tonnage crane boom section(unit:mm)

表 1 中小吨位起重机臂筒试验数据

Tab. 1 Experimental data of medium and small tonnage crane boom

编号	I/A	U/V	$v/(mm \cdot \min^{-1})$	$m/(L \cdot \min^{-1})$	d/mm
1	300	28.0	421	17.8	2.41
2	297	27.3	419	18.1	2.19
3	292	26.7	407	18.3	2.25
4	286	26.1	394	18.7	2.26
5	278	25.4	381	19.2	2.19
6	271	24.8	379	19.3	2.13
7	264	24.2	376	19.6	2.26
8	257	23.6	373	19.9	2.15
9	249	23.2	371	20.2	2.28
10	240	22.8	368	20.4	2.32

组数据分成 2 大组,其中前 8 组数据为样本数据用于训练模型,后 2 组数据为测试数据用于验证模型正确性。

将前 8 组数据的 4 个影响因子作为 FSVM 模型的输入,将对应的焊接变形平均位移作为 FSVM 模型的输出进行模型的训练。其主要思想为:通过训练样本对支持向量机进行训练,提取支持向量并作为模糊推理的规则库进行研究,并不断改善规则库使其达到最优。其步骤如图 5 所示。

将样本数据输入支持向量机模型获取支持向量,建立模糊规则库。定义回归后的支持向量对应的数据点值为 SV_i 及对应的系统输出数据为 y_i ,则




图 5 支持向量机模糊推理融合系统流程图

Fig. 5 Flow chart of SVM fusion of fuzzy reasoning system

可得模糊规则为

$$\text{if } X \text{ is } SV_i, \text{ then } y \text{ is } y_i \quad (11)$$

其中: i 为模糊规则的个数,由支持向量决定。

模糊规则前件的隶属度函数即为支持向量机的核函数,支持向量机的数量为模糊规则的数目,支持向量值为隶属度函数的中心。

2.3 起重机臂筒焊接变形测量模型参数优化

根据支持向量机理论,其惩罚因子 c 和核参数 σ 对模型的误差影响很大,这样也就影响了后续模糊规则的获取,必须在训练过程中加以优化。笔者采用遗传算法^[14-16]进行惩罚因子 c 和核参数 σ 的优选,具体步骤如下:

- 1) 选定训练样本和校验样本,设定惩罚因子 c 和核函数参数 σ 的区间 $(0, 80)$ 和 $(0, 10)$,随机生成初始种群个体;
- 2) 进行基因串解码为相应的核函数参数和惩罚因子,并带入 FSVM 模型进行训练;
- 3) 通过适应度函数进行个体适应度值的计算,如式(12)所示;
- 4) 根据式(13)的评价指标进行遗传算法优化终止判断,满足条件则结束循环,否则执行步骤 5;
- 5) 进行算子的选取,保存最优的,摒弃最差的;
- 6) 设定交叉概率为 0.5,变异概率为 0.2,形成新一代个体,返回步骤 2 进行计算

$$F(c, \sigma) = \frac{1}{\sum_{i=1}^n [y_i - f(x_i)]^2 + e} \quad (12)$$

其中: y_i 为期望输出; $f(x_i)$ 为实际输出; e 为防止分母为零的正数,此处为 10^{-3} 。

定义均方误差函数(mean square error,简称 MSE)作为模糊最小二乘支持向量机泛化性能的评价指标

$$MSE = \frac{1}{m} \sum_{i=1}^m [f(x_i) - y_i]^2 \quad (13)$$

初始交叉概率和初始变异概率的计算公式为

$$P_c^1 = \begin{cases} 0.9 - 0.3(f' - f_{avg}) / (f_{max} - f_{avg}) & (f \geq f_{avg}) \\ 0.9 & (\text{其他}) \end{cases} \quad (14)$$

$$P_m^1 = \begin{cases} 0.1 - 0.099(f_{max} - f) / (f_{max} - f_{avg}) & (f \geq f_{avg}) \\ 0.1 & (\text{其他}) \end{cases} \quad (15)$$

其中： f' 为交叉两个个体较大的适应度函数值； f 为个体对应的适应度函数大小； f_{avg} 、 f_{max} 分别为样本的平均适应度和最大适应度。

图6(a)显示了在初始参数情况下的误差图，由图可以看到，评价指标函数的值比较大，明显不能满足要求。图6(b)为引入遗传算法对参数进行180步迭代后的误差图。图6(c)显示了300步迭代优化稳定后样本的误差图，优化前后评价函数的值大幅度下降。图中 n 为样本点，是无量纲量。

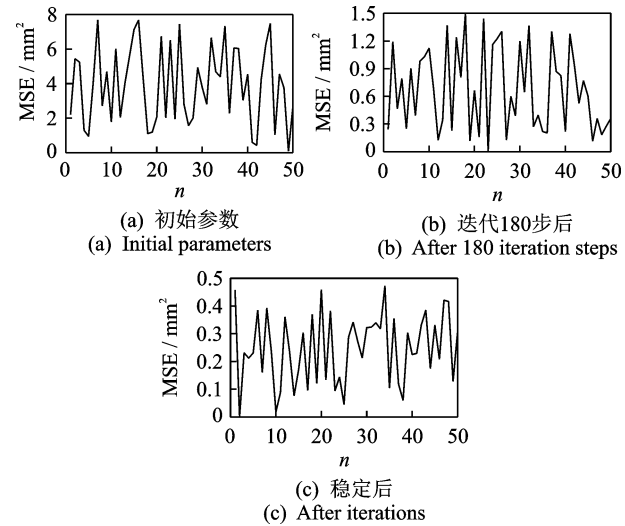


图6 样本误差
Fig. 6 Error of sample data

经过计算，最终确定了惩罚因子 $c=26$ 和核参数 $\sigma=1.8$ ，至此确定了焊接变形平均位移计算模型的参数，建立了最终的计算预测模型。

3 基于支持向量机模糊理论融合的起重机械臂筒焊接变形测量模型应用

应用智能图像检测法测量焊接过程中的焊接变形量及相应时刻焊接过程中的4个影响因素，选取影响因素数据集中随机10个时间点的4个因素作为支持向量机和模糊融合理论预测模型的输入，通过计算得到该10个时间点的焊接变形预测量。为

了验证所建立的智能融合预测模型具有较高的预测精度，在建立本研究智能融合预测模型的同时建立了单独采用支持向量机法的预测模型。表2列出了采用2种智能预测方法的焊接变形量及图像检测法所得到的结果，图7直观地显示了三者的对比情况，图8为两种预测模型的计算相对误差。

表2 智能预测模型和图像检测结果对比

Tab. 2 Comparison between intelligent prediction model and image detection method mm

样本点	SVM 预测	融合模型预测	图像检测法
1	2.19	2.25	2.3
2	2.45	2.52	2.5
3	1.83	2.12	1.9
4	2.71	2.73	2.8
5	2.66	2.58	2.6
6	2.44	2.46	2.5
7	1.89	2.07	2.0
8	2.24	2.27	2.3
9	2.16	2.05	2.1
10	2.42	2.44	2.5




图7 3种方法的测量对比

Fig. 7 Comparison between three methods




图8 智能预测模型的相对计算误差

Fig. 8 Relative error of intelligent predicting models

图7和图8中： l 表示每种测量方法的测量结果值； e 表示相对误差，为无量纲量； n 表示样本点，为无量纲量。由表2、图7及图8可知，采用智能方法所建立的焊接变形预测模型和采用图形检测法所得到的计算结果基本一致，且从图7和图8的对比中发现，支持向量机模糊融合理论建立的预测模型比单纯采用支持向量机法具有更高的预测精度，其相

对误差在5%以内,验证了笔者所建立的焊接变形融合预测模型为一种有效的预测方法,可以采用焊接过程中的焊接电流 I 、焊接电压 U 、焊接速度 v 及气流量 m 因素作为参考来预测焊接变形量。

4 结 论

1) 融合了支持向量机理论及模糊理论,建立了起重机吊臂筒体焊接变形的计算模型,以焊接电流 I 、电压 U 、速度 v 及气流量 m 为融合预测模型的输入,以焊接变形位移为系统输出进行模型训练。

2) 引入遗传算法对模型的核函数和惩罚因子参数进行寻优,确定了预测模型的最终形式。

3) 采用融合预测模型、SVM预测模型和图像检测法进行起重机臂筒相同点的焊接变形测量,结果显示智能法建立的焊接变形预测模型能较好地预测焊接过程变形量,且通过对比发现,笔者所提出的采用支持向量机和模糊理论的融合测量模型具有更好的预测精度,其相对误差在5%以内,验证了所建立的融合预测模型是可行的。

参 考 文 献

- [1] Okano S, Kobayashi S, Kimura K, et al. Experimental and numerical investigation on generation characteristics of welding deformation in compressor impeller [J]. *Materials & Design*, 2016, 101: 160-169.
- [2] 冯超, 梁晋, 郭楠, 等. 板料焊接屈曲变形测量[J]. *焊接学报*, 2016, 37(7): 61-64.
Feng Chao, Liang Jin, Guo Nan, et al. Measurement of sheet welding buckling deformation [J]. *Transactions of the China Welding Institution*, 2016, 37(7): 61-64. (in Chinese)
- [3] 陈参, 万里瑞, 郭楠. 焊接焊缝变形的测量研究[J]. *机床与液压*, 2016, 44(4): 137-138, 160.
Chen Can, Wan Lirui, Guo Nan. Research on measurements of welding line deformation [J]. *Machine Tool & Hydraulics*, 2016, 44(4): 137-138, 160. (in Chinese)
- [4] 梁伟, 夏洋, 冯伟, 等. 焊接变形的高精度测量方法及预测方法研究[J]. *机械工程学报*, 2016, 52(16): 65-70.
Liang Wei, Xia Yang, Feng Wei, et al. Investigations on high-precision methods to measure and predict welding deformation [J]. *Journal of Mechanical Engineering*, 2016, 52(16): 65-70. (in Chinese)
- [5] Park J, An G. Prediction of the welding distortion of large steel structure with mechanical restraint using equivalent load methods [J]. *International Journal of Naval Architecture and Ocean Engineering*, 2017, 9(3): 315-325.
- [6] Wang Jiangchao, Zhao Hongquan, Zou Jiasheng, et al. Welding distortion prediction with elastic FE analysis and mitigation practice in fabrication of cantilever beam component of jack-up drilling rig [J]. *Ocean Engineering*, 2017, 130: 25-39.
- [7] Esme E, Karlik B. Fuzzy c-means based support vector machines classifier for perfume recognition [J]. *Applied Soft Computing*, 2016, 46: 452-458.
- [8] 曹愈远, 张建, 李艳军, 等. 基于模糊粗糙集和SVM的航空发动机故障诊断[J]. *振动、测试与诊断*, 2017, 37(1): 169-173.
Cao Yuyuan, Zhang Jian, Li Yanjun, et al. Aero-engine fault diagnosis based on fuzzy rough set and SVM [J]. *Journal of Vibration, Measurement & Diagnosis*, 2017, 37(1): 169-173. (in Chinese)
- [9] Fan Qi, Wang Zhe, Li Dongdong. Entropy-based fuzzy support vector machine for imbalanced datasets [J]. *Knowledge Based Systems*, 2017, 115: 87-99.
- [10] Ding Jian, Cao Yan, Enock M, et al. A hybrid support vector machine and fuzzy reasoning based fault diagnosis and rescue system for stable glutamate fermentation [J]. *Chemical Engineering Research and Design*, 2012, 90(9): 1197-1207.
- [11] Vapnik V N. *The nature of statistical learning theory* [M]. New York: Springer, 1995: 180-218.
- [12] Vapnik V N. *Statistical learning theory* [M]. New York: Wiley, 1998: 19-55.
- [13] Zhang Xiekai, Ding Shifei, Yu Xue. An improved multiple birth support vector machine for pattern classification [J]. *Neurocomputing*, 2015, 225: 119-128.
- [14] Yuan Fongching, Lee C. Using least square support vector regression with genetic algorithm to forecast beta systematic risk [J]. *Journal of Computational Science*, 2015, 11: 26-33.
- [15] Mehraein I, Riahi S. The QSPR models to predict the solubility of CO₂ in ionic liquids based on least-squares support vector machines and genetic algorithm-multi linear regression [J]. *Journal of Molecular Liquids*, 2017, 225: 521-530.
- [16] Cada P, Dac B, Add N. A multi-level approach using genetic algorithms in an ensemble of least squares support vector machines [J]. *Knowledge-Based Systems*, 2016, 106: 85-95.



第一作者简介: 钱承,男,1987年1月生,博士、讲师。主要研究方向为机械动力学、机械状态监测与诊断、机械减振结构设计。曾发表《Parameters identification on the improved hysteretic preisach model based on the RBF neural network》(《Journal of Information and Computational Science》2015, Vol. 12, No. 14)等论文。

E-mail: qiancheng_hn@sina.com