

广义动态模糊神经网络焊接接头力学性能预测

张永志^{1,2}, 董俊慧¹, 侯继军¹

(1. 内蒙古工业大学 材料科学与工程学院, 呼和浩特 010051; 2. 内蒙古农业大学 机电工程学院, 呼和浩特 0100018)

摘 要: 建立广义动态模糊神经网络模型, 用来预测焊接接头力学性能. 模型结构不再是建模时预设, 而是在对逐个样本的学习过程中动态自适应调整. 引入椭圆基函数扩大函数的接收域, 利用系统误差和模糊规则 ε 完备性作为模糊规则增加的依据, 并将模糊规则 ε 完备性作为径向基单元的宽度确定准则. 以误差减少率评价模糊规则的重要性, 并以此为依据对模型的模糊规则进行修剪. 采用三种不同厚度、不同工艺 TC4 钛合金 TIG 焊接试验, 获得 17 组训练样本和 5 组仿真样本数据, 建模并仿真. 结果表明, 该模型能够对焊接接头力学性能进行较为准确的预测.

关键词: 广义动态模糊神经网络; 预测; 焊接; 建模; 力学性能

中图分类号: TG 407 **文献标识码:** A **doi:**10.12073/j.hjxb.20150911002

0 序 言

建立能够表征焊接工艺参数与接头力学性能之间关系的数学模型, 用来预测接头的力学性能和优化焊接工艺参数, 是提高接头质量和加速工艺制定的有效手段. 但是, 焊接是个复杂的冶金过程, 难以建立数学模型. 目前国内外采用的建模方法有线性回归方法、统计学方法、阶乘设计法^[1]、多重响应法^[2]、专家系统^[3]、Taguchi 方法^[4]、有限元法^[5]和神经网络等方法. 其中神经网络在非线性和多变量复杂系统建模方面具有优势, 在焊接接头力学性能预测方面取得了较好的效果^[6-7]. 近几年, 集合神经网络自学习能力和模糊逻辑推理能力的模糊神经网络, 具有更加优异的性能^[8-9], 动态模糊神经网络技术是目前研究的热点. 近期又有多种模糊神经网络技术被提出并应用到诸多领域.

建立广义动态模糊神经网络 (generalized dynamic fuzzy neural network, GD-FNN) 模型, 用于预测不同厚度、不同工艺条件下 TC4 钛合金 TIG 焊接接头力学性能. 引入椭圆基函数 (elliptic basis function, EBF) 和模糊规则 ε 完备性指标, 克服通常模糊径向基函数 (radial basis function, RBF) 神经网络采用反向传播 (back propagation, BP) 算法时, 全局学习容易陷入误差局部极小以及对于动态样本模型建模困难的不足, 开辟调控焊接接头质量的新途径.

1 焊接试验与力学性能测试

对 2、2.5 和 3 mm 三种不同厚度的 TC4 钛合金进行 TIG 焊接试验, 以获取建模与仿真所需样本数据. 焊丝从母材上剪取, 采用不开坡口的 I 形对接, 电极直径为 2.5 mm 钨钨极直流正接. 为避免氧化皮和水分等杂质影响接头质量, 在焊前进行机械和化学清理. 焊后按相关标准测试接头的力学性能参数: 抗拉强度、抗弯强度、焊缝硬度和热影响区硬度. 获得 22 组试验数据, 其中 17 组为训练样本, 用于建模, 另外 5 组作为仿真样本, 用于检验模型的预测精度与泛化能力等性能.

2 GD-FNN 的结构与算法

GD-FNN 本质是 RBF 神经网络与 TSK 型模糊推理系统融合而成的模糊 RBF 神经网络, 广泛用于信号过程、能源、控制决策、生物工程、结构分析等领域^[10], 模型由输入层、径向基单元层、T-范数层、输出层构成, 信息传递如图 1 所示. 输入层接收输入数据, 径向基单元层计算输入变量的隶属度函数为

$$\mu_j = \text{radbas}(\|x - c_j\|/r_j) \quad j = 1, 2, \dots, u \quad (1)$$

式中: μ_j 是输入参数 x 的第 j 个隶属函数; c_j 为第 j 个径向基单元中心; r_j 径向基单元的宽度; u 是径向基单元的数量.

T-范数层引入 EBF, 用乘法计算每个规则的触发权, 每条模糊规则的 T-范数如式 (2) 所示, 即

$$\varphi_j = \exp\left[-\sqrt{(x - c_j)^T \sum_j^{-1} (x - c_j)}\right] \quad (2)$$

收稿日期: 2015-09-11
基金项目: 国家自然科学基金资助项目 (51165027); 内蒙古自治区自然科学基金资助项目 (2017MS (LH) 0512)

式中: φ_j 是第 j 个节点的模糊规则. 模型的接收域不再是 RBF 单元的超球体而是超椭球体^[11]. 输出层每个节点代表上一层各输入节点数据的加权和,由式(3)表示,即

$$y(x_1, x_2, \cdots, x_r) = \sum_{j=1}^u w_j \varphi_j \tag{3}$$




图 1 GD-FNN 的结构
Fig. 1 Structure of GD-FNN

则产生的依据是系统误差和模糊规则的 ε 完备性. 不同于 BP 算法的全局学习,新增样本可以直接参与训练,而不用重新从头建模,适用于动态样本建模. 对任意一个训练样本 (X_k, t_k) , y_k 是 GD-FNN 的输出. 系统误差为 $\|e_k\| = \|t_k - y_k\|$, 当 $\|e_k\| > k_e$. 系统误差大于预设值,应新增一条模糊规则. k_e 是预定义的误差阈值,在训练过程中按以下的准则调整为

$$k_e = \begin{cases} e_{\max}, & 1 < k < n/3 \\ \max[e_{\max}\beta^k, e_{\min}], & n/3 \leq k \leq 2n/3 \\ e_{\min}, & 2n/3 < k \leq n \end{cases} \tag{5}$$

式中: $e_{\min}$ 是 GD-FNN 的期望输出精度; $e_{\max}$ 是预设的最大系统误差; k 是学习次数; β 为收敛常数.

模糊规则的 ε 完备性的定义详见文献[12],当新增的训练样本满足 ε 完备性,那么 GD-FNN 不会新生模糊规则,而是更新现有模糊规则参数来适应该训练样本. 同时以模糊规则的 ε 完备性作为径向基单元宽度确定准则,避免了初始化参数选择的随机性. 根据误差减少率(ERR)作为模糊规则重要性的评价指标对模糊规则进行修剪. 从而使模型结构的辨识和相关参数的调整同时进行,训练速度快,而且模型的结构更紧凑.

3 GD-FNN 建模与仿真

3.1 GD-FNN 建模

影响焊接接头力学性能的因素众多,对厚度不同的 TC4 钛合金 TIG 焊来说,焊接工艺参数与板厚

式中: y 是模型的运算结果;对应于每组输入数据的一个输入响应; r 表示输入参数的维数; w_j 是第 j 个规则的连接权. TSK 模型,由式(4)表示为

$$w_j = \alpha_{0j} + \alpha_{1j}x_1 + \cdots + \alpha_{rj}x_r, j = 1, 2, \cdots, u \tag{4}$$

GD-FNN 模型起初没有一条模糊规则,在对训练样本的逐个学习过程中动态增加或删除,模糊规

为可变参数,在预测建模中起关键作用,而其它影响因素,诸如化学成分,在建模中基本为常量,对模型的性能影响较小. 故选择焊接电流、焊接电压、焊接速度、氩气流量和板厚作为网络模型的输入参数,以焊后接头抗拉强度、抗弯强度、焊缝硬度和热影响区硬度作为网络模型输出参数. 利用 17 组训练样本进行 GD-FNN 建模, GD-FNN 模型模糊规则从 1 个开始在训练过程中步增加. 需要指出的是在模糊神经网络的训练过程中会出现较大的输入变量抑制较小输入变量的现象^[13],通常用数据归一化来克服,文中将数据归一化到 $[0.5, 5.5]$. 模型初始参数的选择对 GD-FNN 模型的性能有较大的影响,首先需要设置训练样本的作用区间 $[d_{\min}, d_{\max}]$, $d_{\min}$ 表示建模输入样本最小欧氏距离,设 $d_{\min} = 0.3$, $d_{\max}$ 表示样本空间的边界,设为训练样本数据间最大欧氏距离. 预定义模型最大系统误差为 $e_{\max} = 1$, 望精度 $e_{\min} = 0.5$, 收敛常数 $\beta = 0.3$. 第一条模糊规则比较重要,赋予其较大的响应区间,设置第一个径向基单元的宽度 $\sigma_0 = d_{\max}/2$, 径向基单元之间的重叠系数设为 $k = 0.01$. 模糊规则的重要性阈值 $k_{\text{err}} = 0.02$. 按上述初始参数对模型进行训练,训练过程中模糊规则动态变化情况如图 2 所示,模糊规则数 N 只能为整数. 由图 2 可以看出,初期模糊规则增加较慢,前 6 个训练样本共用一条模糊规则,之后模糊规则数逐渐增加,直到训练完成.

网络模型的均方根误差如图 3 所示,其数值都比较小,表明网络模型达到了较高的训练精度. 对于完成训练的 GD-FNN 模糊神经网络,可以提取出




图 2 GD-FNN 模型模糊规则数
Fig. 2 Fuzzy rule number of GD-FNN model




图 3 GD-FNN 模型训练均方根误差

Fig. 3 Training root mean square error of GD-FNN model

每一个输入变量的隶属度函数,结合焊接专家的经验知识,对每一个变量的隶属度函数值进行适当的微调,使模型具有更好的适应性和泛化能力,调整方法可参考文献[14].

在研究中发现,所建模型的期望精度 $e_{\min}$ 在其它参数值不变的情况下与模糊规则数量 N 具有一定的关联性,总结得出式(6),并利用图 4 对二者对应关系的进行近似描述. 由于 N 的取值只能是整数,所以并不是任意一个初始期望精度 $e_{\min}$ 值都会

对 N 造成影响,而是在某个取值范围内, N 保持不变,当超出这个临界时, N 才会改变,导致在建模过程中参数设置比较灵活,只要在合适的范围内便不会影响模型的结构与性能,即

$$N = \begin{cases} 12, & 0 \leq e_{\min} \leq 0.2 \\ -10e_{\min} + 14, & 0.2 < e_{\min} \leq 0.7 \\ 3, & 0.72 \leq e_{\min} \leq 0.76 \\ 2, & 0.77 \leq e_{\min} \leq 1 \end{cases} \quad (6)$$




图 4 初始参数与模糊规则数量的关系
Fig. 4 Relationship between initial parameters and number of fuzzy rules

3.2 GD-FNN 仿真

利用 5 组仿真样本数据对已完成建模的 GD-FNN 进行仿真,检验其预测精度和泛化能力,仿真结果如表 1 所列. 由表 1 可知,抗拉强度预测值逼近期望值,平均相对误差为 6.8%,预测精度较高. 抗弯强度的仿真结果除 4 号仿真结果误差较大外,其它样本的仿真结果均逼近期望值,该样本可能为病态样本. 焊缝硬度和热影响区硬度仿真预测值均逼近期望值,平均相对误差为 7.8% 和 8.7%,具有较高的预测精度. GD-FNN 模型模糊规则并不是越多越好,关键是找到有效的模糊规则,需要在建模过程中多次试验才能确定网络模型的结构与参数.

表 1 GD-FNN 模型焊接接头力学性能仿真结果
Table 1 Simulation results of mechanical properties of welded joints by GD-FNN model

样本序号	抗拉强度 R_m /MPa		抗弯强度 R_w /MPa		焊缝硬度 H_w (HRC)		HAZ 硬度 H_{HAZ} (HRC)	
	期望值	预测值	期望值	预测值	期望值	预测值	期望值	预测值
1	841	799	987	1 080	38.5	40.6	42.0	33.7
2	881	838	1 157	1 030	43.7	37.3	44.3	38.6
3	900	791	2 445	2 407	37.1	40.3	36.9	35.3
4	879	784	2 483	1 448	40.5	37.0	35.9	34.0
5	901	910	1 270	1 386	44.2	44.9	38.4	38.8
平均相对误差 (%)	6.8		14.6		7.8		8.7	

综上所述, GD-FNN 模型可以实现不同板厚与焊接工艺参数的焊后接头力学性能较为准确的预测. 模型结构依据训练样本动态自适应调整, 结果表明模型具有建模容易、训练速度快、结构紧凑、适应性好、泛化能力强和预测精度高的特点. 其逐个样本参与训练的学习算法, 导致对于新增样本可以直接参与训练, 故可以用于在线过程学习, 为在线控制焊接过程提供了一条有效的途径.

4 结 论

(1) 基于 GD-FNN 建立焊接接头力学性能预测模型, 对抗拉强度、抗弯强度、焊缝硬度和热影响区硬度的预测平均相对误差分别为 6.8%, 14.6%, 7.8% 和 8.7%, 能够指导工程实际.

(2) GD-FNN 具有结构紧凑、建模容易、训练速度快、适应性好、泛化能力强和预测精度高等特点, 能够对焊后接头力学性能进行较为准确的预测.

(3) 利用椭圆基函数和模糊规则 ε 完备性优化 GD-FNN 模型, 其结构动态自适应调整, 适用于动态样本建模, 为焊接过程控制开辟了新途径.

参考文献:

- [1] Koganti R, Karas C, Joaquin A, *et al.* Metal inert gas (MIG) welding process optimization for joining aluminum sheet material using OTC/DAIHEN equipment[J]. *Proceedings of IMECE*, 2003, 10(3): 15–21.
- [2] Benyounis K Y, Olabi A G, Hashmim S J. Multi-response optimization of CO₂ laser-welding process of austenitic stainless steel[J]. *Optics & Laser Technology*, 2008, 40(3): 76–87.
- [3] Benyounis K Y, Olabi A G. Optimization of different welding processes using statistical and numerical approaches-A reference guide[J]. *Advances in Engineering Software*, 2008, 39(3): 483–496.
- [4] Pan L K, Wang C C, Hsiao Y C, *et al.* Optimization of Nd-YAG laser welding onto magnesium alloy via Taguchi analysis[J]. *Optics and Laser Technology*, 2005, 37(2): 33–42.
- [5] Peyre P, Sierra G, Deschaux B, *et al.* Generation of aluminum-steel joints with laser-induced reactive wetting[J]. *Materials Science and Engineering*, 2007, 44(1): 327–338.
- [6] Shojaefard M H, Behnagh R A, Akbari M, *et al.* Modeling and pareto optimization of mechanical properties of friction stir welded

AA7075/AA5083 butt joints using neural network and particle swarm algorithm[J]. *Materials & Design*, 2013, 44(2): 190–198.

- [7] 张永志, 董俊慧, 张艳飞. 基于径向基神经网络焊接接头力学性能预测[J]. *焊接学报*, 2008, 29(7): 81–84.
Zhang Yongzhi, Dong Junhui, Zhang Yanfei. Prediction of mechanical properties of titanium alloy welding joints based on RBF neural network[J]. *Transactions of the China Welding Institution*, 2008, 29(7): 81–84.
- [8] 张永志, 董俊慧. 两种预测焊接接头力学性能的模糊神经网络[J]. *焊接学报*, 2011, 32(11): 104–107.
Zhang Yongzhi, Dong Junhui. Research on two fuzzy neural networks to predict mechanical properties of welded joints[J]. *Transactions of the China Welding Institution*, 2011, 32(11): 104–107.
- [9] 张艳飞, 董俊慧, 张永志. 基于自适应模糊神经网络焊接接头力学性能预测[J]. *焊接学报*, 2007, 28(9): 5–8.
Zhang Yanfei, Dong Junhui, Zhang Yongzhi. Prediction mechanical properties of welded joints based on ANFIS[J]. *Transactions of the China Welding Institution*, 2007, 28(9): 5–8.
- [10] 罗 薇. 基于广义回归神经网络的广西农业机械需求预测[J]. *农机化研究*, 2013, 35(1): 49–52.
Luo Wei. Agricultural machinery demand forecasting in guangxi province based on generalized regression neural network[J]. *Journal of Agricultural Mechanization Research*, 2013, 35(1): 49–52.
- [11] 伍世虔, 徐 军. 动态模糊神经网络——设计与应用[M]. 北京: 清华大学出版社, 2008.
- [12] Chuen C L. Fuzzy logic in control systems; fuzzy logic controller part. I[J]. *IEEE Transactions on Systems, Man and Cybernetics*, 1990, 20(2): 404–418.
- [13] Daya R, Lai S, Manjaree P, *et al.* Corrective action planning using RBF neural network[J]. *Applied Soft Computing*, 2007(7): 1055–1063.
- [14] 唐正魁, 董俊慧, 张永志, 等. 混合聚类 RBF 神经网络焊接接头力学性能预测[J]. *焊接学报*, 2014, 35(12): 105–108.
Tang Zhengkui, Dong Junhui, Zhang Yongzhi, *et al.* Prediction of mechanical properties of welding joints by hy-brid cluster fuzzy RBF neural network[J]. *Transactions of the China Welding Institution*, 2014, 35(12): 105–108.

作者简介: 张永志, 男, 1982 年出生, 博士. 主要从事模糊神经网络技术在焊接中的应用等方面的研究工作. 发表论文 10 篇. Email: zyzstu@sina.com

通讯作者: 董俊慧, 男, 博士, 教授, 博士研究生导师. Email: jhdong1009@163.com