

高强度管线钢焊接接头韧性参数 CVN 的神经网络预测系统

白世武¹, 童莉葛², 刘方明³, 王 立²

(1. 天津大学 材料科学与工程学院, 天津 300072; 2. 北京科技大学 机械工程学院, 北京 100083;

3. 中国石油天然气管道科学研究院, 河北 廊坊 065000)

摘 要: 使用 VC++ 6.0 建立了多层 BP 人工神经网络模型预测高强度管线钢焊接接头韧性参数夏比冲击(CVN)值。根据现场 X70 管线钢焊接参数, 选择平均线能量、壁厚、预热温度、焊接位置和取样位置作为模型输入量, 建立了节点数为 14 的一个隐层, 激活函数为 Sigmoid 型的接头韧性参数 CVN 预测程序。194 组样本数据均来自现场焊接数据, 随机选取 150 组样本作为训练样本, 其余 44 组样本作为预测结果的检验样本。分析了神经网络结构对预测结果的影响。预测值误差在 20% 以内的样本占测试样本数的 77%。结果表明, 在管强度管线钢焊接中, 基于 ANN(artificial neural network)的 CVN 预测方法可为合理选择焊接工艺参数提供一种有效途径。

关键词: 高强度管线钢; 夏比冲击韧性参数; 人工神经网络

中图分类号: TP202 **文献标识码:** A **文章编号:** 0253-360X(2008)01-0106-03



白世武

0 序 言

焊接在管道工程中得到广泛应用, 管线钢的焊接性能不仅与被焊材质有关, 而且还和焊接工艺有关^[1,2]。管线钢的供货状态及表面状态、焊接材料的选择、接头尺寸形状及其焊接方法、焊接工艺参数(焊接电流、电弧电压、焊接速度或热输入等)、预热、后热和焊后热处理以及环境条件均对焊接性能有影响。目前管道焊接接头的质量主要从两个方面加以保证: 一是采用超声波探伤的方法进行质量检测, 对有缺陷的焊接接头重焊, 该方法在质量保证方面有其必要性, 但费时, 而且不能根据外界条件的变化做出及时、相应的调整; 二是对焊接工艺进行优化, 从焊接工艺上保证接头质量。目前, 实际生产中, 焊接工艺参数的选择一直凭经验或近似公式, 其中存在较多的人为因素^[3]。

人工神经网络是基于模拟生物神经网络对外部环境进行学习过程的“突触假说”建立起来的智能化信息处理系统, 是理论化的人脑神经网络的数学模型, 具有自适应学习功能, 适合处理多参数的非线性问题^[4]。将人工神经网络技术应用到计算机预测系

统上, 依靠人工神经网络自学习的特点, 预测系统可以很好的适应各种复杂问题, 有较高的预测成功率。国内学者已成功将人工神经网络用于焊接质量的预测和评估^[5,6]。文中以高强度管线钢 X70 钢的焊接性能夏比冲击值(CVN)为研究对象, 建立了基于人工神经网络的 CVN 预测系统。该预测系统不仅为管道焊接参数的确定提供参考, 确保焊接质量, 还可为管线钢焊接过程中选择最佳的焊接工艺参数起到很好的辅助作用。

1 CVN 预测系统的神经网络结构

1.1 输入层参数的确定

由于管线钢的焊接性能和许多因素(如焊接工艺、母材化学成分、服役介质环境等)有关, 因此在研究和预测高强度管线钢的焊接性能之前, 首先要从各种复杂关系中提取对焊接性能有主要影响的因素, 即人工计算参数的确定。此外, 在使用计算机预测焊接性能时, 其数学模型往往受多种因素影响, 在这种情况下可采取两种方法分析: 一是取一个可变因素, 而保持其他因素不变的方案进行试验; 二是采用多因素分析法, 即若干因素同时变化来进行试验。后者可在较少的试验次数下获取较多的试验数据, 但在进行结果分析时却不如前者方便。总之, 管线

钢在焊接时,伴随着能量的传递、相态的变化以及机械运动存在许多不稳定过程,各种影响因素之间的关系极其复杂。所以计算机预测的准确与否,主要取决于用于分析各影响因素之间关系的试验数据。获得尽可能全面完整的高强度管线钢焊接试验数据,是管线钢焊接性能计算机系统预测的关键。一般而言,试验室的焊接数据要比现场数据规律性好。

经过大量的实践研究表明,影响焊接性能(夏比冲击值)的主要条件包括壁厚、预热温度、平均热输入、焊接位置和取样位置,因此采用如图 1 所示的含有一个隐含层的三层人工神经网络。第一层具有 5 个节点,包括的输入参数有:壁厚、预热温度、平均热输入、焊接位置和取样位置;第三层是有 1 个神经元的输出层,输出量为需要预测的主要焊接性能参数夏比冲击值;中间的隐含层先采用 8 个处理神经元,对预测数据进行学习分析,并对神经网络的结构对预测参数的影响进行了研究。

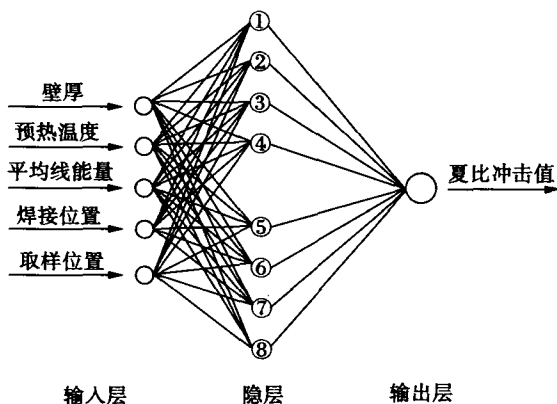


图 1 CVN 预测的 BP 神经网络结构图

Fig.1 Topology structure of BP neural network for welded joint CVN prediction

1.2 输入数据与输出数据的规范化处理

神经网络的样本数据共计 194 组,来自现场的不同焊接条件下焊接接头的夏比冲击值,训练时从中随机抽取 150 组样本用于神经网络的学习,其余 44 组样本用来检验神经网络的泛化能力。样本数据来自平焊及立焊的半自动、自动和手工焊三种,取样位置分为焊缝和热影响区。

建立的神经网络有 5 个输入(壁厚 D 、预热温度 T 、平均热输入 E 、焊接位置 L_1 和取样位置 L_2)和 1 个输出(夏比冲击值 CVN),样本数据的数值范围如表 1。神经网络预测程序需要将输入参数进行归一化处理。在归一化处理环节,通过单独改变神经网络输入单元的归一化处理系数,分析预测结果与学

习样本的吻合程度,以及满足误差要求的数据比例,最终确定适合的输入单元归一化系数。

表 1 神经网络输入参数和输出参数的数据范围

Table 1 Range of five inputs and one output of ANN

壁厚	预热温度	平均热输入	焊接位置	取样位置	夏比冲击值
D/mm	$T/^\circ\text{C}$	$E/(\text{kJ}\cdot\text{cm}^{-1})$	L_1	L_2	CVN/J
14.6~21.0	87~125	5.0~13.6	1~2	1~2	45.0~293.0

归一化系数的具体分析如下:

(1) 输入数据和输出数据的归一化系数取 1/500。训练预测程序后,得到的预测结果和学习样本差别较大,预测值误差在 $\pm 20\%$ 以内的样本数为 69 个,占学习样本数的 46%。

(2) 输入数据的归一化系数取 1/150,输出数据的归一化系数取 1/500。训练预测程序后,预测值误差在 $\pm 20\%$ 以内的样本数为 70 个,占学习样本数的 47%。

(3) 壁厚 D 、预热温度 T 、平均热输入 E 、焊接位置 L_1 和取样位置 L_2 的归一化系数分别取 1/22, 1/130, 1/15, 1/3 和 1/3,输出数据的归一化系数取 1/300。训练预测程序后,预测值和学习样本的变化趋势较一致,预测值误差在 $\pm 20\%$ 以内的样本数为 85 个,占学习样本数的 57%。本预测程序选用第三种归一化处理方法。

1.3 激活函数对输出结果的影响

神经网络的激活函数是网络运算功能的核心,它在很大程度上决定了网络的执行能力。由于输入参数与 CVN 是非线性关系,本神经网络分别对输入层到隐含层、隐含层到输出层的激活函数分别选取正切 Sigmoid 函数和线性函数,分析预测结果与学习样本的吻合程度,以及满足误差要求的数据比例,最终确定适合的激活函数。正切 S 型函数为 $f(x) = 1/(1 + e^{-x})$ 。各层间激活函数选择的具体分析如下:

(1) 输入层到隐含层使用正切 S 型函数,隐含层到输出层用线性函数 $f(x) = x$ 。训练预测程序后,曲线符合程度较差,预测值误差在 $\pm 20\%$ 以内的样本数为 54 个,占学习样本数的 36%。

(2) 输入层到隐含层使用正切 S 型函数,隐含层到输出层用线性函数 $f(x) = 0.5x$ 。训练预测程序后,曲线符合程度依然不理想,预测值误差在 $\pm 20\%$ 以内的样本数为 58 个,占学习样本数的 39%。

(3) 输入层到隐含层、隐含层到输出层均使用正切 S 型函数。训练预测程序后,曲线的符合程度比较好,预测值误差在 $\pm 20\%$ 以内的样本数为 78,占学习样本数的 51%,图 2 为该激活函数下预测值

(粗线)和学习样本(细线)之间的对照图,其中横坐标是学习样本数,纵坐标为 CVN 值(单位:J)。




图 2 激活函数采用正切 Sigmoid 函数的预测结果

Fig.2 Prediction results of ANN when activation functions are Sigmoid

通过比较分析,本预测程序最终选择各层间的激活函数均为正切 Sigmoid 函数。

1.4 隐含层层数对输出结果的影响

在设计多层神经网络时,需要确定隐含层数。一般而言,增加隐含层数可增加人工神经网络的处理能力,但会使训练复杂化,并引起训练时间增加。通常三层网络在隐含层中使用 S 形传输函数时,只要保证隐含层中有足够的节点数,在输出层中使用线性激活函数,就可以以任意精度逼近任何非线性函数。隐含层数选择的具体分析为:

(1) 使用含 2 个隐含层的神经网络模型,训练预测程序后,预测值误差在 $\pm 20\%$ 以内的样本数为 73 个,占学习样本数的 49%。

(2) 使用含 1 个隐含层的神经网络模型,训练预测程序后,预测值误差在 $\pm 20\%$ 以内的样本数为 78 个,占学习样本数的 52%。

通过比较,本预测程序最终选择包含 1 个隐含层的神经网络结构。

1.5 隐含层神经元个数对输出结果的影响

采用适当的隐含层节点数也很重要,隐含层节点数太少,网络所能获取解决问题的信息太少,网络难以处理复杂的问题;若隐含层节点数过多,将使网络训练时间急剧增加,也容易使网络训练过度。作者依次将隐含层节点数从 5 个取到 20 个,分别计算每个网络模型误差小于 $\pm 20\%$ 的样本数。通过比较分析,当节点数取 14 个时,网络相应的标准偏差和平均绝对误差最小,而且误差小于 $\pm 20\%$ 的样本数最大,最符合要求。

1.6 学习效率对输出结果的影响

学习效率 η 对输出结果的影响见表 2。可见 η

≈ 0.3 比较符合要求。

表 2 学习效率 η 不同时神经网络的输出结果

Table 2 Output results of ANN in different learning effect

学习效率 η	0.6	0.3	0.1	0.9
误差小于 $\pm 20\%$ 的样本数	80	89	82	67

2 基于 ANN 的 CVN 预测结果分析

神经网络预测系统最终确定的神经网络结构为:隐含层数为 1,隐含层节点数为 14 个;层间的激活函数均采用正切 Sigmoid 函数;学习效率为 0.3。

使用 150 组学习样本进行神经网络训练后,对 44 组测试样本进行测试,结果如图 3 所示,其中横坐标是测试点数,纵坐标为 CVN 值(单位:J)。测试结果为:预测值误差在 $\pm 20\%$ 以内的样本数为 35 个,占测试样本数的 77%。




图 3 测试样本的预测值与测试值对比分析

Fig.3 Contrast of prediction value and experimental value for CVN in testing data

3 结 论

使用 VC++ 6.0 建立基于人工神经网络的高强度管线钢 X70 钢焊接性能夏比冲击值(CVN)的预测系统,并针对不同焊接条件下的现场焊接数据进行了学习和预测。人工神经网络方法是预测管线钢焊接接头韧性参数 CVN 的一种有效途径。需要说明的是所有样本数据均来自实际工程,分别来自平焊和立焊的半自动焊、自动焊和手工焊,即样本数据本身存在一些人 为和环境不可知因素,这些都会增加焊接数据分析的难度,同时也是造成神经网络的预测结果误差偏高的主要原因。如果采用全自动焊接

[下转第 112 页]




图 6 析出物的电子衍射斑点

Fig. 6 Electron diffraction pattern of precipitates

改善熔敷金属的晶界条件,增强晶界的抗变形能力,提高熔敷金属抗 DDC 能力,(Nb,Ti)C 的最佳尺寸为 100 ~ 120 nm。

(3) (Nb,Ti)C 提高熔敷金属抗 DDC 能力的作用

[上接第 108 页]

方法的数据训练本神经网络预测系统,训练样本的预测结果误差将会大幅度降低。

参考文献:

- [1] 刘雪梅,高连才,张彦华. X70 管线钢焊接性能分析[J]. 电焊机, 2004, 34(7): 14-16.
- [2] Bayraktar E, Kaplan D. Parametric approach model for determining welding conditions: New type of welding limit diagrams (WLD)[J]. Journal of Materials Processing Technology, 2005, 170: 477-486.

最明显;开裂最小临界应变 E_{\min} 主要出现在 900 ~ 1 100 ℃,此温度区间是 DDC 敏感区域。

参考文献:

- [1] Nissely N E, Lippold J C. Ductility - dip cracking susceptibility of austenitic alloys[C]// Proceedings of 6th International Conference on Trends in Welding Research. USA, Pine Mountain Georgia, 2002.
- [2] Nissely N E, Collins M G, Guaytima G, et al. Development of the strain-to-fracture for evaluating ductility-dip cracking in austenitic stainless steels and ni-base alloys [J]. Welding in the World, 2002, 46(7-8): 32-40.
- [3] Collins M G, Ramirez A J, Lippold J C. An investigation of ductility dip cracking in nickel based weld metals part I [J]. Welding Journal, 2003, 82(10): 288s-295s.

作者简介: 唐正柱,男,1980 年出生,硕士。主要从事镍基合金焊接材料的研制工作。发表论文 1 篇。

Email: hhs_tangzhengzhu@163.com

- [3] 王 玉,高大路,廖明夫,等. 优化异种材料摩擦焊接工艺参数的神经网络模型[J]. 焊接学报, 2005, 26(4): 33-36.
- [4] 韩力群. 人工神经网络理论、设计及应用[M]. 北京:化学工业出版社, 2002.
- [5] 徐培全,杨德新,赵秀娟,等. ANN 在焊接接头抗弯强度预测中的应用[J]. 焊接学报, 2005, 26(5): 41-45.
- [6] 吕其兵,戴 虹,谭克利,等. 基于 BP 人工神经网络的钢轨交流闪光焊焊接接头质量预测[J]. 焊接学报, 2005, 26(5): 65-68.

作者简介: 白世武,男,1959 年出生,博士研究生,高级工程师。主要从事金属材料检测与分析领域的研究工作。发表论文 20 余篇。

Email: bsw2557@126.com