

人工神经网络模型补偿 Consteel 电弧炉钢水称重系统的测算偏差

刘 平 李建宣 何 勇 岳彤彪
(贵阳特殊钢有限责任公司, 贵阳 550005)

摘 要 根据 Consteel 电弧炉的电能、氧气和碳粉消耗, 通过建立的 BP 人工神经网络模型和 Matlab 仿真软件计算补偿因炉衬耐火材料消耗而引起的 Consteel 电弧炉称重系统测算钢水重量的偏差。结果表明, 经过 Levevberg-Marquardt 优化算法训练后, BP 人工神经网络模型对钢水样本数据还原误差绝对值 ≤ 0.0008 t。

关键词 人工神经网络 Consteel 电弧炉 钢水重量 仿真计算

Artificial Neural Network Model to Compensate Measure Offset of Liquid Steel Weight System for Consteel Arc Furnace

Liu Ping, Li Jianxuan, He Yong and Yue Tongbiao
(Guiyang Special Steel Co Ltd, Guiyang 550005)

Abstract Based on consumption of electric power, oxygen and carbon powder of Consteel arc furnace, the offset of measuring of metal weight system for Consteel arc furnace due to consumption of refractory of furnace is compensated by established BP artificial neural network model and Matlab simulation software calculation. Results showed that the absolute value of metal sample data reduced error was ≤ 0.0008 t by Levevberg-Marquardt optimum calculation training with BP artificial neural network model.

Material Index Artificial Neural Network, Consteel Arc Furnace, Metal Weight, Simulation Calculation

贵阳特殊钢有限责任公司在 1998 年引进 Consteel 电弧炉, 此后国内已有 8 条类似的生产线, 但是普遍存在电弧炉称重系统测算值和炉中钢水实际重量相差甚远的问题。理论上说, 将冶炼时炉体的实测总重减去空炉体的重量就能够得到炉中钢水的实际重量(净重), 但实际上在电弧炉冶炼过程中, 由于化学和物理的浸蚀作用导致了耐火材料的消耗, 所以实际的空炉体重量已不是标定时值。通过 60 t Consteel 电弧炉的实际观测, 经过一个炉役后, 炉衬耐火材料消耗最大可达 51 t, 同时由于 Consteel 电弧炉留钢操作和连续生产的要求使得在冶炼过程中不可能实际对空炉体的重量进行标定, 在这种情况下, 考虑到对炉体浸蚀的各种作用因素的复杂性和不确定性, 要建立其数学模型几乎是不可能的。所以, 通过在实验数据的基础上结合人工神经网络对非线性关系描述能力好和融错能力强的特点, 找出耐火材料消耗量及其相关能源消耗量的映射关系, 从而对该偏差进行有效的补偿方法。

1 神经网络模型的建立

人工神经网络 (Artificial Neural Network 简称 ANN) 是一种数据驱动型非线性映射结构模型。它具有并行处理、联想记忆以及逼近任意非线性曲线

等特性。近年来, 研究人员提出了多种人工神经网络的模型, 其中 80% ~ 90% 采用的是基于前向传递的 BP 人工神经网络 (Back-Propagation Network) 基本结构的改进形式, 它们改善了 BP 网络的性能, 使得该人工神经网络在各运用领域得到了越来越多的重视^[1]。在本方案中设计了一个如图 1 所示的 BP 人工神经网络, 其输入是对炉衬耐火材料消耗有明显影响的因素。根据长期的观察和分析, 认为炉衬耐火材料的消耗和冶炼过程的电能消耗、碳粉和氧气的喷入量三者有直接的关系, 所以在该方案中以这 3 个数据作为人工神经网络的输入, 其输出是炉衬耐火材料消耗量。根据该实际情况, 网络拓扑结构设计成由 3 层神经元组成的 BP 人工网络: 3 个输




图 1 BP 人工神经网络拓扑结构
Fig. 1 Topology structure of BP artificial neural network

入层神经元,30 个中间层神经元和 1 个输出层神经元。该 BP 神经网络输入和输出的数学关系表达式如下^[2]:

(1) 隐含层各神经元节点的输出:

$$net_j = f_1 \left(\sum_{i=1}^3 x_i w_{ij} - \theta_j \right) \quad (1)$$

式中: net_j - 隐含层第 j 个神经元的输出; f_1 - 隐含层神经元的激励函数; x_i - 输入层第 i 个神经元的输入; w_{ij} - 输入层第 i 个神经元到隐含层第 j 个神经元的连接权值; θ_j - 隐含层第 j 个神经元的阈值。

(2) 输出层各神经元节点的输出:

$$net_s = f_2 \left(\sum_{j=1}^{30} net_j w_{js} - \theta_s \right) \quad (2)$$

式中: net_s - 输出层第 s 个神经元的输出; f_2 - 输出层神经元的激励函数; w_{js} - 隐含层第 j 个神经元到输出层第 s 个神经元的连接权值; net_j - 隐含层第 j 个神经元的输出; θ_s - 输出层第 s 个神经元的阈值。

另外, (1)、(2) 两式中 $f_1(\cdot)$ 、 $f_2(\cdot)$ 分别表示隐含层和输出层神经元的激励函数, 在本方案中隐含层的输出特性函数采用具有非线性特征的双曲线正切激励函数 $y = \text{tansig}(x)$, 输出层的输出特性采用线性激励函数 $y = x$ 。

2 人工神经网络的训练

该神经网络建立后, 需要在离线状态下通过一定数量的样本训练和学习(图 2)才能够建立起其输入和输出的某种映射关系, 其方法是通过网络连接权值和阈值的调整, 使得网络的输出值更逼近于期望值, 其过程如下: 将样本的输入向量作为人工神经网络的输入算出其输出向量并将其与样本的输出向

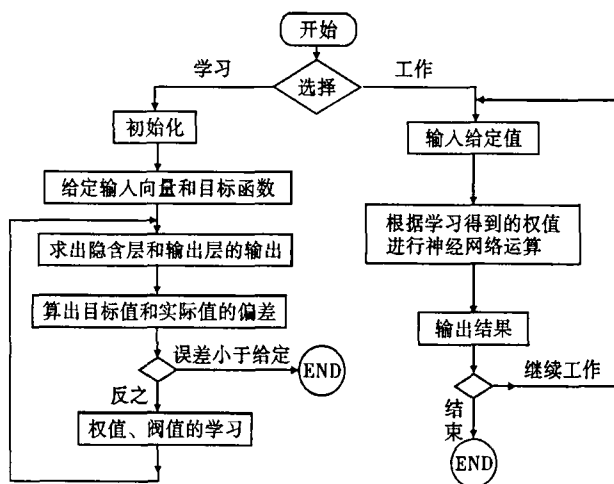


图 2 人工神经网络的学习、工作流程

Fig. 2 Learn and work flow sheet of artificial neural network

量进行比较得到误差信号, 在此基础上将该误差信号从输出端向输入端反向传播, 同时根据一定的数学方法调整网络权值和阈值, 以减小误差信号值。在本方案中选用 BP 人工神经网络的改进算法 Levenberg-Marquardt 优化算法来训练该 BP 神经网络, 该算法是牛顿法和最速下降法的折中, 它克服了原 BP 网络训练方法训练时间长、会收敛于局部最小值等缺点, 对于中、小型网络的训练, 采用该算法可以使学习时间缩短, 在实际运用中效果较好^[1]。其权值或阈值更新算法如式(3)所示:

$$X_{k+1} = X_k - (J^T J + \mu I)^{-1} J^T e \quad (3)$$

式中: X_{k+1} - 新的权值或阈值; X_k - 原先的权值或阈值; J - 误差对权值微分的雅可比矩阵; μ - 调节因子 ($\mu \rightarrow 0$ 时牛顿算法; $\mu \rightarrow \infty$ 时为最陡下降法); I - 各神经元的输出; e - 误差向量。

以上是该人工神经网络的一次学习, 获得了新的权值或阈值, 此后将其替换原先的对应值, 再计算网络的输出向量, 比较其与样本中的输出向量的误差。如此循环, 直到该 BP 人工神经网络的输出向量和样本中的输出向量的均方误差值小于或等于期望值为止, 此时将得到的网络各神经元的权值和阈值保存起来, 作为其实际工作时神经元的权值和阈值。

3 人工神经网络的工作及钢水重量修正

通过上述训练过程后, 该人工神经网络就具有了体现训练样本所蕴涵的电能消耗量、碳粉和氧气的喷入量和炉衬耐火材料消耗量之间的数量关系能力。在此基础上通过图 2 所示的工作流程, 该 BP 人工神经网络就能以当前上述电能等 3 项消耗量作为输入运算得出实时的炉衬耐火材料消耗量。在实际使用过程中可以将负责人工神经网络运算的计算机和现场控制级计算机 (PLC) 通过工业以太网连接起来使用, 从而实现数据的采集、运算、输出全过程自动: PLC 负责采集实时的电功率、碳粉、氧气以及炉体称重数据的瞬时值, 并将前 3 个数据作积分运算得到它们对应的累计消耗总量, 然后将该数据送到负责神经网络运算的计算机上, 计算机按照图 2 所示的工作流程计算得到耐火材料的消耗量, 在此基础上将其作为修正量带入式(4)就可以算出炉体中钢水的实际重量:

$$G_{net}(k) = [G_{gross}(k) - G_{tare}(k)] + dG(k) \quad (4)$$

式中: $G_{net}(k)$ - 炉中钢水的净重; $G_{gross}(k)$ - 实测炉体的重量(含钢水); $G_{tare}(k)$ - 标定空炉体的重量

(不含钢水); $dG(k)$ - 通过神经网络运算得到的耐火材料消耗量。

4 仿真结果

为了进一步检验该方案的效果, 运用 Matlab 仿真软件对方案进行了仿真运算。通过对 Consteel 电弧炉的电能、碳粉和氧气的消耗量以及耐火材料消耗量(在同一炉役或是不同炉役内)作了统计后, 获得 60 组数据(表 1)。

表 1 训练样本输入、输出
Table 1 Input and output of trained sample

编号	输入消耗			输出消耗
	电能/kWh	氧气/L	碳粉/kg	耐火材料/t
1	45 792	2 521	220	0.102
2	260 063	23 584	1 308	1.02
3	500 048	46 921	2 534	2.04
4	1 005 860	95 958	5 026	4.182
5	1 462 242	140 541	7 345	6.12
6	1 940 150	187 365	9 747	8.16
⋮				
60	12 020 552	1 170 023	60 125	51

Matlab 仿真软件平台上有 Leveberg-Marquardt 优化算法的训练函数(trainlm. m)可供调, 在其中设目标误差函数指标为 5×10^{-4} t(0.5 kg), 然后用表 1 中的输入和输出作为训练样本, 通过该训练函数对图 1 所示的 BP 神经网络进行训练, 其结果如图 3 所示, 从图 3 可以看出, 当该神经网络训练到 14 次




图 3 BP 网络的 Leveberg-Marquardt 训练结果

Fig. 3 Trained results of artificial neural network by Leveberg-Marquardt

表 2 训练后 BP 神经网络对样本的还原误差
Table 2 Reduced error of sample trained by BP artificial neural network model

编号	耐火材料消耗量/t		误差值/t
	实际值	计算值	
1	0.102	0.101 8	0.000 2
2	1.02	1.020 7	-0.000 7
3	2.04	2.039 5	0.000 5
4	4.182	4.181 8	0.000 2
5	6.12	6.120 7	-0.000 7
6	8.16	8.159 2	0.000 8
⋮			
60	51	51.00	0

后, 该神经网络对样本中输入、输出关系还原的均方误差已经小于设定的 1.0×10^{-8} t 达到 $9.415 6 \times 10^{-9}$ t, 此时在表 1 各组样本的输入激励下该神经网络的输出值和样本实际值(实际的耐火材料消耗量)的误差如表 2 所示。从中可以明显地看出, 经过 Leveberg-Marquardt 优化算法训练后, 该 BP 神经网络对所有的 60 个样本数据的还原误差的绝对值不超过 0.000 8 t(即 0.8 kg), 其出现在 6# 样本上。

5 结论

对于一个具有合理结构的 BP 神经网络, 在通过一定数量的样本训练后, 能够有效地表达在一个炉役内, 电弧炉本体因为炉衬耐火材料消耗而引起的耐火材料重量改变和冶炼电量消耗及氧气、碳粉的喷入量之间存在的某种非线性关系。在此基础上只需通过简单的数学运算就能够科学地补偿由于炉衬耐火材料消耗而引起的钢水重量测算值偏差, 从而有效地解决了 Consteel 电弧炉在冶炼过程中钢水实际重量不确定的问题。

参考文献

- 1 苏高利, 邓方萍. 论基于 MATLAB 语言的 BP 神经网络的改进算法. 科技通报, 2003, 19(2): 130
- 2 张建民, 王 涛. 智能控制原理及运用. 北京: 冶金工业出版社, 2003

刘 平(1972-), 男, 硕士, 工程师, 1993 年贵州大学毕业, 从事自动化设备控制方面的研究和工。

收稿日期: 2007-09-17

欢迎订阅 2008 年《特殊钢》杂志

(邮发代号: 38-183)