

文章编号: 1001-0920(2006)07-0814-03

基于 PSO 和 BP 网络的 LF 炉钢水温度智能预测

王安娜^a, 陶子玉^b, 姜茂发^b, 田慧欣^a, 张丽娜^a
(东北大学 a 信息科学与工程学院; b 材料与冶金学院, 沈阳 110004)

摘要: 研究将粒子群优化算法与 BP 神经网络相结合, 建立新的钢水终点温度预报模型。确定加热功率、初始温度、精炼时间等 8 个影响钢水终点温度的主要因素作为神经网络的输入量。用粒子群优化算法优化神经网络参数, 改善神经网络温度预测模型的收敛性能。实验结果表明, 该算法可以提高预测速度和精度, 预测结果误差不大于 ± 5 的炉次大于 90%。

关键词: LF 精炼炉; 钢水温度预测; BP 神经网络; 粒子群优化
中图分类号: TP206 **文献标识码:** A

Intelligence Temperature Prediction of Molten Steel in LF Based on PSO Combined with BP Neural Network

WANG Anna^a, TAO Zi-yu^b, JIANG Mao-fa^b, TIAN Hui-xin^a, ZHANG Li-na^a

(a College of Information Science and Engineering; b College of Materials and Metallurgy, Northeastern University, Shenyang 110004, China Correspondent: WANG Anna, E-mail: wanganna@mail.neu.edu.cn)

Abstract: An algorithm of particle swarm optimization (PSO) combined with improved back-propagation neural network (BP) is studied. A prediction model of finish temperature of molten steel in Ladle Furnace (LF) is built by the algorithm. The inputs of neural network are the key factors of influencing the temperature such as power supplied to heat molten steel, initial temperature, blown-in argon quantity and refining time etc. PSO is used to optimize the parameters of BP neural network to improve convergence capability of BP. The speed and precision temperature prediction are improved. The results of real operation show that the number of furnace with the prediction error less than ± 5 degree is more than 90%.

Key words: LF refining temperature; Prediction of molten steel; BP neural network; Particle swarm optimization

1 引言

LF 炉钢水终点温度的准确预测, 是合理组织生产, 降低炼钢成本, 提高钢水质量的重要前提。图 1 为 LF 炉冶炼操作过程。影响温度的因素比较复杂, 许多影响因素无法准确测量; 各炉钢水进站时的钢水重量、钢包冷热状态等, 对钢水温度预报的影响很难用数学方程精确描述; 在 LF 炉冶炼过程中, 预测对象为非线性系统, 难以建立准确的机理模型^[1]。

本文以北钢 45 t LF 炉为研究对象, 提出将粒子群优化算法与 BP 神经网络相结合, 建立钢水温度预报模型的新方法。BP 神经网络结构简单, 算法

成熟, 具有精确寻优等优点^[2~6]。但标准 BP 算法存在易陷入局部极小、收敛速度慢和引起振荡效应等缺点。粒子群优化算法是一种基于迭代模式的优化算法, 具有很强的宏观搜索能力, 并且简单通用, 鲁棒性强, 用它来完成前期搜索, 能较好地克服 BP 算法的缺点。这种基于粒子群优化 BP 神经网络的温度预测算法, 其收敛性能和学习速度要优于传统的 BP 神经网络及其他改进算法, 具有寻优的全局性和精确性等特点。该模型可以缩短处理周期, 节约能源, 降低成本, 为实现 LF 炉终点温度的精确控制奠定了基础。

收稿日期: 2005-11-24; 修回日期: 2006-03-17

基金项目: 教育部暨辽宁省流程工业综合自动化重点实验室开放课题基金项目

作者简介: 王安娜(1956—), 女, 辽宁鞍山人, 教授, 从事智能信息处理等研究; 陶子玉(1959—), 男, 黑龙江绥化人, 教授级高级工程师, 从事现代冶金工艺等研究

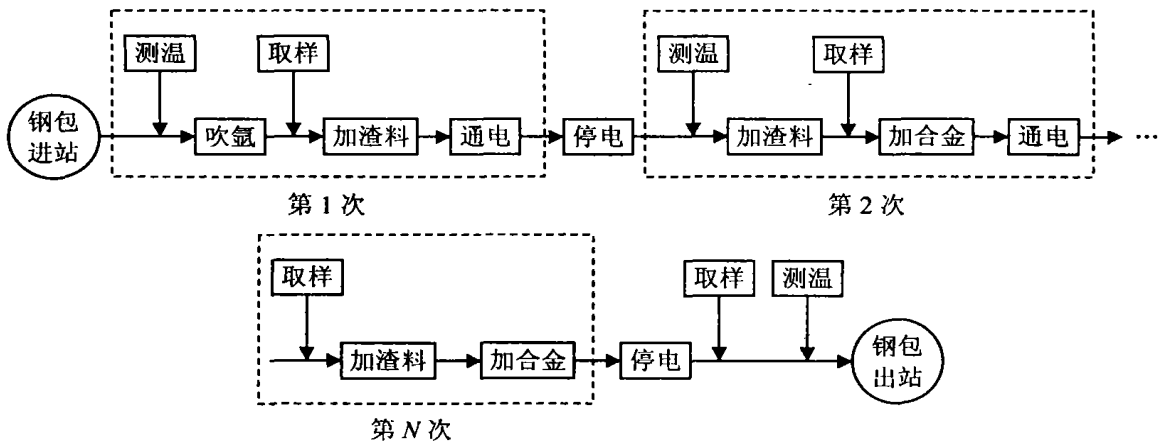


图 1 LF 炉精炼工艺流程

2 粒子群优化算法

Kennedy 和 Eberhart 提出一种新的群体智能计算技术——粒子群优化算法 (PSO)。它源于对鸟群和鱼群群体运动行为的研究, 是一种良好的优化算法。粒子群优化算法的基本思想是通过群体中个体之间的协作和信息共享来寻找最优解。PSO 算法概念简单且易于实现, 搜索速度快, 范围大^[7,8]。

粒子群优化算法在描述个体时, 将其看成 D 维寻优搜索空间中一个没有质量和体积的微粒 (点), 结合微粒的历史最佳位置和群体历史最佳位置信息, 以一定的速度向目标值逼近。粒子 i 在 D 维空间的位置表示为矢量 $X_i = [x_{i1}, x_{i2}, \dots, x_{iD}]$, 飞行速度表示为矢量 $V_i = [v_{i1}, v_{i2}, \dots, v_{iD}]$ 。每个粒子都有一个由适应函数决定的适应值, 并且知道到目前为止自己的最好位置 P_{best} 和现在的位置 X_i , 它们可以看作粒子自己的飞行经验。此外, 每个粒子还知道到目前为止整个群体中所有粒子的最好位置 g_{best} (g_{best} 是 P_{best} 中的最好值), 它可以看作粒子同伴的经验。粒子就是通过自己的经验和同伴中最好的经验来决定下一步运动。

第 i 个微粒从 k 代进化到 $k + 1$ 代, 通过下式进行更新:

$$v_{id}^{k+1} = w v_{id}^k + c_1 r_1^k (p_{id} - x_{id}^k) + c_2 r_2^k (p_{gd} - x_{id}^k), \quad (1)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1}. \quad (2)$$

其中: x_{id}^k 为第 k 次迭代粒子 i 位置矢量的第 d 维分量; p_{id} 为粒子 i 个体最好位置 P_{best} 的第 d 维分量; p_{gd} 为群体最好位置 g_{best} 的第 d 维分量; w 表示惯性权重, 它使微粒保持运动惯性, 具有扩展搜索空间的趋势, 有助于新区域的搜索; c_1 和 c_2 均为正实数, 称为加速度常数, 它们表示将每个微粒推向 P_{best} 和 g_{best} 的统计加速度的权重; r_1^k 和 r_2^k 为在 $[0, 1]$ 区间变化的随机数。

3 粒子群优化 BP 神经网络算法

粒子群优化算法是一种基于群体进化的全局优化算法, 它能获得近似最优的全局解, 并且不会陷入局部极小。另外, 它的寻优过程不依赖于梯度信息, 并且搜索效率高, 具有很强的鲁棒性。采用 PSO 算法与 BP 算法相结合的方法训练 BP 网络的权值, 可以克服 BP 算法易于陷入局部极小和收敛速度慢的缺点, 从而更好地发挥 BP 神经网络在非线性系统中的应用^[9]。

PSO 算法的流程如下:

Step 1: 根据具体问题设置 PSO 有关参数。首先确定粒子群规模 (维数), 建立 PSO 粒子的维度空间与神经网络连接权值之间的映射。粒子群中每个粒子的维度分量都对应于神经网络中一个连接权值或阈值。即神经网络中有多少个连接权值和阈值, PSO 中的每个粒子就有多少维。PSO 中粒子的搜寻空间维数为

$$D = r s_1 + s_1 s_2 + s_1 + s_2 \quad (3)$$

其中: r 为输入层神经元个数, s_1 为隐含层神经元个数, s_2 为输出层神经元个数。然后设置初始惯性权重 w , 加速度常数 c_1 和 c_2 。最后初始化群体中的微粒, 包括微粒的初始位置和初始速度。

Step 2: 使用神经网络的均方误差作为 PSO 的适应函数, 通过 PSO 算法强大的搜索性能使网络的均方误差最小化, 即

$$\text{fitness} = \frac{1}{1 + E}, \quad (4)$$

$$E = \frac{1}{2} \sum_{k=1}^N (y_k - \hat{y}_k)^2. \quad (5)$$

训练误差越小, 粒子的适应度越高。算法迭代停止时, 适应度最高的粒子即为训练问题的最优解。

Step 3: 根据粒子确定的神经网络, 在训练样本下产生训练误差, 由 Step 2 计算其适应度。

Step 4: 对于每个微粒, 将其适应度值与历史最

好位置 P_{best} 相比较, 如果比当前适应度值更优, 则将当前适应度值更新为 P_{best}

Step 5: 对于每个微粒, 将其适应度值与群体经历过的历史最佳位置 g_{best} 相比较, 如果比当前群体中最好的适应度值更优, 则将其置为新的 g_{best} , 同时记录其索引号

Step 6: 根据算式 (1) 和 (2) 更新各微粒的位置和速度

Step 7: 由 Step 6 迭代生成的速度进行解的更新, 即调整神经网络的连接权值和阈值

Step 8: 对迭代产生的新的粒子种群进行适应度评价, 判断算法是否达到最大迭代次数 $Iter_{max}$, 即 $Iter > Iter_{max}$, 或者训练误差 E 小于规定的误差标准 e , 即 $E < e$ 条件满足则转到 Step 9, 否则返回 Step 4 继续迭代

Step 9: 算法迭代停止时, 全局极值所对应的神经网络的权值和阈值即为问题的最优解

4 L F 炉终点温度预报模型的建立

通过对 L F 炉能量传递过程的分析得出, L F 温度预报模型的建立可从能量平衡的角度出发, 将整个钢包体系作为一个系统, 系统输入能量 Q_{in} , 输出能量 Q_{out} 和体系内吸收的能量 Q_x 应达到平衡, 可表示为

$$Q_{in} - Q_{out} = Q_x \quad (6)$$

其中: Q_{in} 主要是电弧加热进入熔池的能量, Q_{out} 包括钢包表面散热、渣面散热等多种因素

在此能量平衡的基础上, 经过对 L F 冶炼过程的机理分析, 确定对钢水温度影响的主要因素为加热功率、初始温度、钢包状态、合金加入量、渣层厚度、氩气吹入量、精炼时间 8 个主要因素, 其中钢包状态是根据冷包、半冷包、周转包等并结合包底冷钢量等因素进行量化分类

利用 PSO 优化的 BP 神经网络对 L F 炉钢水温度进行预测, 将上述影响钢水温度的 8 个因素作为输入量, 即 BP 网络的输入层节点数为 8, 输出层节点数为 1 (温度). 训练网络选择适应性较强的三层 BP 网络, 隐含层使用 S 型函数

$$f(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

输入层使用线性神经元, 隐含层节点数设为 16. 经过反复实验, PSO 和 BP 网络的参数设置如下: BP 网络的学习速率 $\eta = 0.7$, 动量因子 $\mu = 0.8$; 基于粒子群优化的训练算法种群规模 $n = 40$, 初始惯性权重 $w(0) = 0.9$, 并随迭代次数线性递减至 0.5 , $c_1 = c_2 = 2$, 连接权值为 $[-1, 1]$ 区间变量

因为收集的数据往往不在同一个数量级, 所以在训练前要将收集的数据映射到 $[-1, 1]$ 之间进行归一化处理. 在训练样本的处理上选择最大最小型函数

用同样的数据分别对 BP 神经网络和 PSO 改进 BP 网络算法进行实验, 结果表明, PSO 与 BP 神经网络相结合的方法比普通神经网络算法性能好. 用此算法对 L F 炉钢水温度预测的精度要高于普通 BP 网络 (参见表 1).

表 1 两种算法的预测结果比较

算 法	相对误差的绝对平均值	预测精度 (± 5)
BP 神经网络	1.13	77%
PSO 优化的 BP 网络	0.83	91%

取北钢 45 t L F 炉 2005 年 1~6 月 200 炉生产数据, 分成两组: 160 炉用来训练网络, 40 炉用来测试网络预测精度. 预测结果误差不大于 ± 5 的炉次大于 90% (参见图 2).




图 2 预测结果与实际温度的比较

5 结 语

在 L F 炉冶炼过程中, 对钢水温度的影响因素较多, 具有一定的非线性. 如果单纯使用 BP 算法, 要达到较高精度则需要很长的收敛时间, 并且初值选择不当还可能陷入局部极小值. 鉴于粒子群优化算法能在复杂的解空间寻找最优解的特点, 本文先由粒子群优化算法优化神经网络, 再用改进的优化 BP 算法进行精度训练, 使网络的收敛速度加快, 且避免局部极小问题, 增强了自动获取和积累搜索空间知识以及自适应控制搜索过程的能力. 训练结果表明, 该模型的预测精度和速度都是令人满意的

参考文献 (References)

- [1] 孙彦广, 王代先, 陶白生, 等. 智能钢包精炼炉控制系统 [J]. 冶金自动化, 1999, (6): 9-12
(Sun Y G, Wang D X, Tao B S, et al. An Intelligent Ladle Furnace Control System [J]. Metallurgical Industry Automation, 1999, (6): 9-12)

(下转第 820 页)

上的传播行为,旨在研究需要免疫掉多大比例的节点,最终使病毒无法传播扩散 因此这里的免疫针对的仅是易染(状态S)节点

4 结 论

局域世界特性是许多现实复杂网络的一个重要特性 本文对局域世界演化网络的病毒传播进行仿真研究,从初始感染节点、传播临界值和免疫机制3个方面考察了局域世界模型中的病毒传播特性 初始被感染节点选择的不同导致的传播行为差异,从一个侧面反映了网络拓扑结构对病毒传播的影响 在局域世界演化模型中,随着参数 M/m 的增大,网络节点的度分布表现出从指数到幂律的变化过程,病毒传播临界值呈下降趋势,而随机免疫和目标免疫两种策略之间的差异更加明显 从病毒传播的角度看,反过来也验证了局域世界模型所体现出的在均匀网络与非均匀网络之间的演化特性

局域世界中病毒传播特性的理论分析值得进一步深入研究 本文的局域世界演化模型对局域世界的选择是随机选取固定数目的节点作为局域世界,今后应进一步考虑更复杂的情况

参考文献(References)

- [1] Wang C, Knight J C, Elder M C. On Computer Viral Infection and the Effect of Immunization [A]. *IEEE 16th Annual Computer Security Applications Conf* [C]. New Orleans, 2000: 246-256
- [2] Alexei V áquez, Romualdo Pastor Satorras, Alessandro Vespignani. Large - scale Topological and Dynamical Properties of the Internet [J]. *Physical Review E*, 2002, 65(6): 130-142
- [3] Li X, Chen G, Li C G. Stability and Bifurcation of Disease Spreading in Complex Networks [J]. *Int J of Systems Science*, 2004, 35(9): 527-536
- [4] 许丹,李翔,汪小帆. 复杂网络理论在互联网病毒传播研究中的应用 [J]. *复杂系统与复杂性科学*, 2004, 1(3): 10-26
(Xu D, Li X, Wang X F. Application of Complex Network Theory to the Study of Virus Spreading on the Internet [J]. *Complex Systems and Complexity Science*, 2004, 1(3): 10-26)
- [5] Barab ái A L, Albert R. Emergence of Scaling in Random Networks [J]. *Science*, 1999, 286: 509-512
- [6] Li X, Jin Y Y, Chen G. Complexity and Synchronization of the World Trade Web [J]. *Physica A*, 2003, 328(2): 287-296
- [7] Li X, Chen G. A Local World Evolving Network Model [J]. *Physica A*, 2003, 328(2): 274-286
- [8] Pastor Satorras R, Vespignani A. Epidemics and Immunization in Scale-free Networks [A]. *Handbook of Graphs and Networks: From the Genome to the Internet* [C]. Berlin: Wiley-VCH, 2002: 113-132
- [9] Moreno I Y, Pastor Satorras R, Vespignani A. Epidemic Outbreaks in Complex Heterogeneous Networks [J]. *European J of Physica B*, 2002, 26(4): 521-529
- [10] Mari á Bogu ñá Romualdo Pastor Satorras. Epidemic Spreading in Correlated Complex Networks [J]. *Physical Review E*, 2002, 66(4): 104-108

(上接第 816 页)

- [2] 王旭,王宏,王文辉. *人工神经网络原理与应用* [M]. 沈阳: 东北大学出版社, 2000: 13-65
(Wang X, Wang H, Wang W H. *Theory and Application of Artificial Neural Network* [M]. Shenyang: Publishing House of Northeastern University, 2002: 13-65)
- [3] 阎平凡,张长水. *人工神经网络与模拟进化计算* [M]. 北京: 清华大学出版社, 2000
(Yan P F, Zhang C S. *Artificial Neural Network and Simulation Evolution Computing* [M]. Beijing: Publishing House of Tsinghua University, 2000)
- [4] Chow W S, Fang Y. A Recurrent Neural-network-based Real-time Learning Control Strategy Applying to Nonlinear System with Unknown Dynamics [J]. *IEEE Trans on Neural Network*, 1998, 45(1): 151-161
- [5] Shen W X, Chan C C, Lo E W C, et al. A New Battery Available Capacity Indicator for Electric Vehicles Using Neural Network [J]. *J of Power Sources*, 2002, 43(6): 817-826
- [6] Zhong L, Liu L S, Zou C M, et al. The Application of Neural Network in Life Time Prediction of Concrete [J]. *J of Wuhan University of Technology*, 2002, 17(1): 79-81
- [7] Kennedy J, Eberhart R C. Particle Swarm Optimization [A]. *Proc IEEE Int Conf on Neural Networks* [C]. Perth: IEEE Piscataway, 1995: 1942-1948
- [8] Kannana S, Mary S, Slochanal R, et al. Application of Particle Swarm Optimization Technique and Its Variants to Generation Expansion Planning Problem [J]. *Electric Power Systems Research*, 2004, 70(8): 203-210
- [9] Yi D, Ge X R. An Improved PSO-based ANN with Simulated Annealing Technique [J]. *Neurocomputing*, 2005, 63(11): 527-533