

文章编号:1004-9037(2012)05-0625-05

基于多输入层遗传神经网络的热轧产品性能预测

吕志民 隋筱玥

(北京科技大学高效轧制国家工程研究中心,北京,100083)

摘要:根据热轧产品加工流程的多阶段特点,建立了高维多输入层遗传神经网络机械性能预报模型。该模型根据工艺流程发生顺序在前馈人工神经网络的某些隐含层上增添了输入节点,能够更好地模拟热连轧生产过程。同时,为避免标准BP(Back propagation)算法陷入局部极值点,采用了遗传算法对神经网络权值和阈值进行全局预处理,再利用标准BP算法进行训练,使两者优缺点相互补偿,从而得到全局最优解。最后,利用某钢铁企业的热轧产品实际生产数据对模型进行测试,预测结果满足偏差要求,且与经典BP神经网络及径向基函数神经网络相比较,具有更高的精度和稳定性。

关键词:热轧;遗传算法;神经网络;机械性能预报

中图分类号:TP389.1;TG335.11 **文献标识码:**A

Prediction of Mechanical Properties of Hot-Rolling Steel Based on GA Neural Network with Multi-input Layers

Lü Zhimin, Sui Xiaoyue

(National Engineering Research Center of Advanced Rolling, University of Science and Technology Beijing, Beijing, 100083, China)

Abstract: According to the mutli-stage traits of manufacturing process of hot-rolling strip, a genetic neural network model with high-dimension multi-input layers is built to predict the mechanical properties of products. The model can be regarded as the result of adding input node to some hidden layers of neural network according to the order of technological process, so that it can simulate the manufacturing process better. Meanwhile, to avoid local extreme point caused by the standard BP algorithm, genetic algorithm is adopted to conduct global pretreatment for the weights and thresholds of neural network. Then standard BP algorithm is used to do the training to compensate mutually both advantages and disadvantages, and thereby get global optional solution. Finally, testing results given by the actual manufacture date of hot-rolled products from an iron and steel enterprise show that the predicted result satisfies the requirement of demand. Moreover, it has higher accuracy and stability than the classic BP and RBF neural networks.

Key words: hot-rolling; genetic algorithm; neural network; prediction of mechanical properties

引 言

中国作为钢铁大国,一直存在技术水平较低、产品结构性矛盾突出等问题,高端钢铁产品满足不了市场需求,产品质量有待进一步提高。由于钢铁生产过程的复杂性,仅仅依靠常规的控制思想与控

制方法很难对其生产过程进行有效地控制。要提高我国钢铁行业的核心竞争力,必须加大技术创新的力度和深度,采用综合的智能控制、智能监控及其他先进控制思想对生产过程进行有效指导,以期提高品质,降低成本,实现按目标进行质量控制。

热轧产品中机械性能指标是钢铁产品质量的主要衡量指标之一,它受多种因素综合影响,其指

标直接影响产品质量和用户的使用。根据物料参数、工艺过程参数对机械性能指标进行预测,可以使人们在生产前对产品组织性能做到预知,并可根据预报结果对钢种的成分和加工工艺进行设计,同时在生产中进行控制,提高机械性能指标命中率及合格率。这样既降低了研发成本,又缩短了研发时间,有助于企业实现生产优化,稳定并提高产品性能质量,实现按客户需求进行性能控制和工艺优化设计。目前,如何利用现代化热连轧生产线计算机控制系统中的大量工艺参数进行机械性能指标的预测和控制,是生产工艺人员迫切希望解决的问题。

1 相关研究进展

从上世纪 60 年代开始,国外就有很多学者以钢的物理和力学冶金学为基础,分析变形条件和温度条件对钢在热轧过程中内部显微组织演变规律和析出规律的影响,并采用数学模型的方法进行描述,开发了轧制过程的物理冶金模型^[1-3]。此外,对轧制及轧后冷却过程中碳氮化物析出行为的研究及其数学模型的开发也取得了一些成果^[4-5]。近年来,逐渐积累了一些能够较准确描述热轧过程中各物理冶金参量关系的数学模型,在这些模型的基础上,许多研究机构和公司开发了钢的组织性能计算机预报模拟和控制系统,如 HSMM, SLIMMER, VAI-Q Strip, METMODEL, STRIPCAM, SPPC 等,这些系统有的作为离线的模拟工具软件,有的已经成功在线应用到了热轧生产线上^[6],但由于热轧过程形变和相变的复杂性,这些模型和系统的适用性还有一定的局限。随着计算机技术和应用的发展,许多学者开始采用神经网络方法,尤其是 BP (Back propagation) 神经网络进行建模^[7-11],以建立材料成分、工艺与性能之间的非线性关系模型,通过先进的数学理论分析方法对实验数据进行分析,来提高模型的通用性和精度。然而,由于热轧生产过程是一多阶段加工过程,各阶段工艺参数对最终性能指标影响复杂,简单多层神经网络结构也存在局限性。文献[12]提出一种基于加工工序的高维多输入层神经网络,利用这种多输入层神经网络获得了比 BP 神经网络更加令人满意的结果。

多输入层神经网络的训练算法可以采用传统 BP 算法,然而 BP 算法是基于误差函数梯度下降的搜索方法,当数据量大时其训练精度和时间难以保证,并且易于陷入局部极值点。根据某企业热连轧过程实际工艺数据及性能预测需求,本文采用高维多输入层神经网络模型进行性能预测模型建立,

采用两步训练方法训练神经网络,即遗传算法 (Genetic algorithm, GA) 加 BP 算法混合算法,以实现更高的模型预测精度。

2 高维多输入层遗传神经网络质量预测建模

2.1 网络模型结构及工艺参数

根据热连轧生产流程的多阶段性特点,本文采用高维多输入层前向神经网络,输入参数依照工艺流程中发生的顺序对应不同输入层,以更好地模拟热连轧生产过程。

与传统的前向传播神经网络不同,高维多输入层神经网络是在某些隐含层上增添一些输入节点后所成的神经网络。本模型中,将生产过程依工序划分为:加热区、粗轧区、精轧区和卷取区,分别对应 4 个不同的输入层,从而建立 4 输入层的 6 层神经网络模型。各输入层主要因素考虑,第 1 层考虑板坯厚度等 15 个物料参数及加热工艺;第 2 层考虑粗轧出口厚度等 4 个粗轧区工艺参数;第 3 层考虑目标终轧温度等 5 个精轧区工艺参数;第 4 层考虑卷取实际温度等 4 个卷曲过程工艺参数。输出变量取屈服强度及抗拉强度。具体工艺参数如表 1 所示。

表 1 高维多输入层神经网络参数表

	C, Si, Mn 等主要化学成分
第 1 输入层	板坯厚度 板坯切割温度 板坯加热时间
第 2 输入层	粗轧出口厚度 粗轧出口温度 精轧入口温度 精轧出口温度
第 3 输入层	目标终轧温度 终轧温度平均值 终轧温度合格率 钢卷厚度 钢卷目标厚度
第 4 输入层	卷曲实际温度 目标卷曲温度 卷曲温度平均值 卷曲温度合格率
输出层	屈服强度 抗拉强度

隐含层神经元个数确定方法有多种,本研究中设置隐含层的神经元数目为各输入层的 2 倍,这样建立的神经网络模型中隐含层神经元个数分别为 16, 6, 10, 8。建立网络模型及各层具体参数如图 1

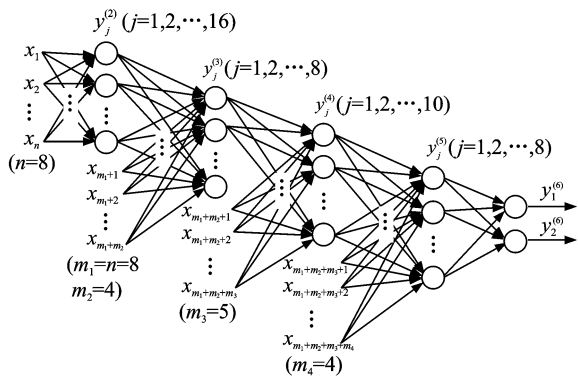


图 1 4 输入层 6 层前向神经网络结构示意图

所示。

图 1 是具有 6 层的 4 输入层神经网络结构图,在第 1 输入层有 8 个节点 x_1, x_2, \dots, x_8 , 第 q 层有 n_q 个隐节点 $y_j^{(q)} (j=1, 2, \dots, n_q; q=2, \dots, 5)$, 在第 r_q 个输入层分别添加 m_q 个输入节点 $x_{m_1+\dots+m_{q-1}+i} (q=1, 2, \dots, 4; i=1, 2, \dots, m_q)$ 。由第 q 层的第 i 个节点到第 $q+1$ 层的第 j 个节点的连接权值 $\omega_{ij}^{(q)} (i=1, 2, \dots, n_q; j=1, 2, \dots, n_{q+1}; q=1, 2, \dots, 5)$, $\theta_j^{(q)}$ 表示第 q 层第 j 个神经元的阈值。记网络的输入输出关系为

$$f(x) = 1 / (1 + e^{-\mu x}) \quad (1)$$

式中: $f(x)$ 为隐层神经元的激发函数; μ 为可调参数, 用以改变相应神经元输入输出特性。则此网络的输出为

$$y_1 = f(s_1^{(5)}), \quad y_2 = f(s_2^{(5)}) \quad (2)$$

$$s_j^{(5)} = \sum_{i=0}^8 \omega_{ij}^{(5)} y_j^{(5)}, \quad y_0^{(5)} = \theta_1^{(5)}, \quad \omega_{01}^{(5)} = -1 \quad (j=1, 2) \quad (3)$$

$$s_j^q = \sum_{i=0}^{n_q} \omega_{ij}^{(q)} y_j^{(q)} + \sum_{i=0}^{m_q} \omega_{ij} x_{m_1+\dots+m_{q-1}+i} \quad (4)$$

其中

$$y_0^q = \theta_j^q, \quad \omega_{0j}^q = -1 \quad j=1, 2, \dots, n_q; q=2, 3, 4$$

$$s_j^{(1)} = \sum_{i=0}^8 \omega_{ij}^{(1)} x_i, \quad x_0 = \theta_j^{(1)}, \quad \omega_{0j}^{(1)} = -1 \quad q=1 \quad (5)$$

$$y_j^{(q+1)} = f(s_j^{(q)}) \quad j=1, 2, \dots, n_q \quad (6)$$

2.2 神经网络两步训练方法

针对图 1 所示的神经网络的权值和阈值训练时, 采取两步训练方法, 即先全局再局部搜索, 将 GA 和 BP 算法的优缺点互为补偿。首先采用 GA 在整个解空间进行全局搜索, 以避开局部极值点, 在到达最优解附近后, 再采用微调能力很强的 BP 算法进行局部搜索, 最终得到最优解。同时, GA 学

习得到神经网络连接权值的收敛速度较快, 并且网络规模越大, 效果越明显。该算法流程如图 2 所示。

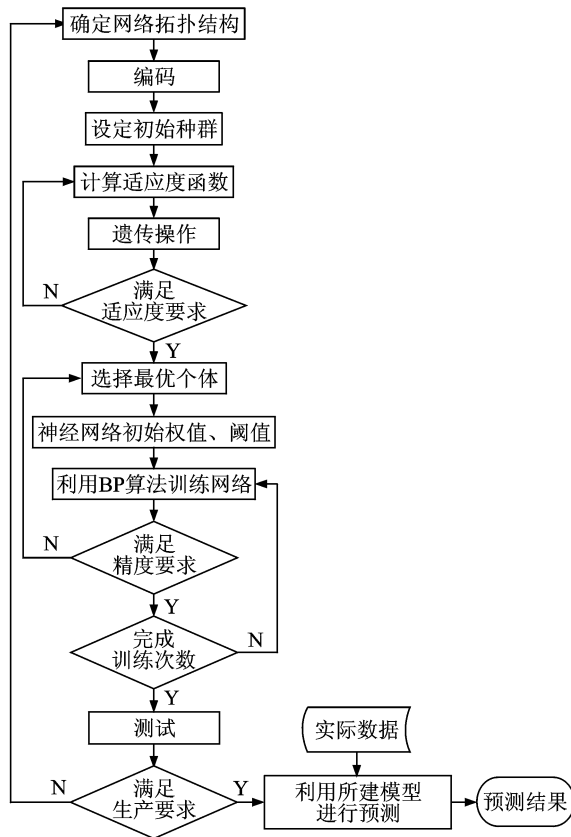


图 2 高维多输入层 GA 前向神经网络与预测流程

采用遗传算法训练图 1 所示的神经网络结构时, GA 的基本要素采用如下方法确定:

(1) 染色体编码: 采用实数编码方案, 即将各节点连接权值及各节点的阈值利用实数表示并按先后顺序排列, 形成染色体。将染色体解码后代入式 (7), 即可得当前个体的训练误差。

$$E = 1/2 \sum_{i=1}^M (y^{(i)} - y_i)^2 \quad (7)$$

(2) 适应度函数: 表示为训练误差的倒数, 即 $f = 1/E$ (8)

(3) 交叉操作: 采用算术交叉方法, 即 $a' = \alpha a + (1 - \alpha)b, b' = \alpha b + (1 - \alpha)a$ (9)

式中: $\alpha \in (0, 1)$, 并且 α 是随机数; a, b 为父代个体; a', b' 为子代个体。

(4) 变异操作: 采用随机变异方式, 即将个体基因依概率 P_m 由 0 变为 1, 或由 1 变为 0。其中 P_m 若太低则会使 GA 趋于随机搜索。

3 实验结果及分析

3.1 实验数据预处理

以从某企业获取的 17 368 条低合金带钢的生

产数据对网络模型进行测试和验证,其中每条数据包括 215 个数据字段(变量),从中提取模型中涉及相应参数,共计 28 个变量。由于技术上的种种原因,生产实际数据中的特殊记录,如缺失值和奇异值等现象不可避免,需要对记录和变量进行必要的整理和筛选,主要操作有:

(1)根据标准对部分元素含量进行限制,元素成份不合格的数据排除,例如根据样本中涉及的钢种标准成份,确定碳元素的含量在 $[0.1, 0.2]$ 之间,将 $[0.1, 0.2]$ 范围外的数据排除掉;

(2)删除数据有明显错误的观测值,例如抽钢温度为零的观测记录;

(3)根据常识处理,例如在炉时间超过某个阈值后将其强行置为阈值。

对于筛选出的数据,本文用卷曲温度命中率和终轧温度命中率作为选取样本指标,以这两个命中率为 90%作为标准,把可建模的热轧数据集市中没有缺省项的观察取出,其中 2/3 的数据用于训练,1/3 的数据用于测试。同时,为了提高神经网络的建模质量,对数据进行归一化处理,把数据变换在 $[-1, 1]$ 之间。方法如下

$$x' = -1 + 2(x - x_{\min}) / (x_{\max} - x_{\min}) \quad (10)$$

式中: x' 为归一化后的变量值; x 为原始变量值; x_{\max} , x_{\min} 分别为原始变量的最大值与最小值。

3.2 实验结果

通过对高维多输入层 GA 前向神经网络算法进行反复的训练,最终达到网络训练终止条件时,建立了从成分、工艺参数到产品机械性能指标的映射,获得了应用于产品机械性能预报的神经网络模型。针对训练集及测试集进行 1 000 次实验,实验结果均值分别如表 2,3 所示。

对测试集预测结果进行数据统计分析知,在 1 000 次测试中,预测值偏差控制在 $\pm 5\%$ 以内的抗拉强度预测命中率为 87.11%~90.11%间波动,屈服强度预测命中率为 76.04%~80.16%;预测值偏差控制在 $\pm 10\%$ 以内的抗拉强度预测命中率为

表 2 高维多输入层 GA 前向模型训练集预测结果

力学性能	预测值偏差 err /%				
	err ≤5	5< err ≤10	10< err ≤15	15< err ≤20	err >20
	命中率/%				
抗拉强度 σ_b	91.10	8.71	0.19	0	0
屈服强度 σ_s	81.95	16.9	1.09	0.06	0

表 3 高维多输入层 GA 前向模型测试集预测结果

力学性能	预测值偏差 err /%				
	err ≤5	5< err ≤10	10< err ≤15	15< err ≤20	err >20
	命中率/%				
抗拉强度 σ_b	89.95	9.69	0.33	0.03	0
屈服强度 σ_s	79.78	18.7	1.33	0.16	0.03

为 98.71%~99.72%,屈服强度预测命中率为 96.89%~98.62%,预测结果相对稳定。

为了对比,本文同时采用经典 BP 神经网络模型进行了试验分析,多次实验发现,当隐含层神经元个数为 56 个,实验结果最好。针对训练集及测试集进行 1 000 次实验,测试集预测结果均值见表 4。

表 4 标准 BP 模型测试集预测结果

力学性能	预测值偏差 err /%				
	err ≤5	5< err ≤10	10< err ≤15	15< err ≤20	err >20
	命中率/%				
抗拉强度 σ_b	80.23	18.73	1.02	0.02	0
屈服强度 σ_s	68.29	26	5.45	0.26	0

对测试集预测结果进行数据统计分析知,在 1 000 次测试中,预测值偏差控制在 $\pm 5\%$ 以内的抗拉强度预测命中率为 77.73%~83.55%间波动,屈服强度预测命中率为 66.18%~70.63%;预测值偏差控制在 $\pm 10\%$ 以内的抗拉强度预测命中率为 98.66%~99.2%,屈服强度预测命中率为 93.44%~95.56%。

比较试验结果可以发现,高维多输入层 GA 前向预测模型的预测结果明显优于标准 BP 预测模型,尤其是抗拉强度、屈服强度预测值偏差小于 5%的命中率分别由 80.23%,68.29%提高到 89.95%,79.78%,效果明显。抗拉强度、屈服强度的预测值偏差均控制在 $\pm 10\%$ 以内的命中率分别为 99.64%,98.48%,预报精度都满足偏差要求。另外在试验的过程中发现,前者比较稳定,不会出现 BP 模型预测时过拟合现象。

同时,与径向基函数神经网络预测结果进行比较,后者抗拉强度和屈服强度的预测值偏差在 $\pm 10\%$ 以内的记录分别占全部记录的 97.8%和 91.7%,结果远不如高维多输入层前向神经网络的

预测结果^[13]。

4 结束语

针对实验中的样本数据,通过对高维多输入层GA前向神经网络模型的训练,获得了满足目标精度的网络结构及参数,实现了热轧产品成分、工艺参数和产品机械性能指标的映射。并利用该模型实现了热轧产品机械性能预报和工艺参数优化,解决了现场生产热轧产品成分、工艺参数对力学性能影响复杂及其之间关系难于精确描述的问题。实验结果表明,高维多输入层遗传神经网络在热轧产品性能预测方面与BP网络相比,其预测精度、稳定性等方面更具优势。

参考文献:

- [1] Beynon J H, Sellars C M. Modelling microstructure and its effects during multipass hot rolling[J]. ISIJ International, 1992,32(3):359-367.
- [2] Sellars C M, Whiteman J A. Recrystallization and grain growth in hot rolling[J]. Metal Science, 13, 1979,3(4):187-194.
- [3] Sellars C M. Computer modelling of hot working processes[C]//Perspectives in Metallurgical Development, Proceedings of the Centenary Conference. Sheffield, Engl: Metals Soc (Book 318), 1984:209-217.
- [4] Militzer M, Samarasekera I V, Jin D Q, et al. 热轧带钢组织性能预报模型的进展[C]//1999中国钢铁年会论文集(下). 北京:中国金属学会,1999:658-664.
Militzer M, Samarasekera I V, Jin D Q, et al. Advances in the prediction of microstructure and mechanical properties of hot-rolled steel strip [C]//CSM 1999 Annual Meeting Proceedings. Beijing; the Chinese Society for Metals, 1999:658-664.
- [5] Samarasekera I V, Jin D Q, Brimacombe J K. The application of microstructural engineering to the hot rolling of steel[C]//38th Mechanical Working and Steel Processing Conference Proceedings. Cleveland, USA: [s. n.], 1996:313-327.
- [6] 刘正东,唐广波,干勇. 热轧组织性能预报技术的回顾与展望[C]//2010年全国轧钢生产技术会议论文集. 内蒙古:中国金属学会,2010:21-25,46.

Liu Zhengdong, Tang Guangbo, Gan Yong. Advancement of microstructure engineering technology for hot rolling products: review and outlook[C]//CSM 2010 Annual Meeting Proceedings. Inner Mongolia; the Chinese Society for Metals, 2010:21-25, 46.

- [7] Muirhead R J. Aspects of multivariate statistical theory[M]. New York, USA: John Wiley & Sons, 1982.
- [8] Sanner R M, Slotine J J E. Gaussian networks for direct adaptive control [J]. IEEE Transactions on Neural Networks, 1992,3(6):837-863.
- [9] 孙增圻,张再兴. 智能控制的理论与技术[J]. 控制与决策,1996,11:1-8.
Sun Zengqi, Zhang Zaixing. Intelligent control theory and technology [J]. Control and Decision, 1996, 11:1-8.
- [10] 王永骥,涂健. 神经元网络控制[M]. 北京:机械工业出版社,1998.
- [11] Zou Qinghua, Chen li, Xiong Naixue, et al. Prediction and key computer programming of mechanical properties of hot rolled plate based on BP neural network[C]//Computational Science and Engineering, 2009. Vancouver, Canada: [s. n.], 2009:967-971.
- [12] 邢进生,刘人境,汪应洛,等. 基于加工工序的高维多输入层神经网络及应用[J]. 系统工程理论与实践, 2004,2:63-67.
Xing Jinsheng, Liu Renjing, Wang Yingluo, et al. Neural network with high-dimension multi-input layers based on process of working procedure and its application [J]. Systems Engineering—Theory & Practice, 2004,2:63-67.
- [13] 马文博,吴斌,朱天,等. 基于径向基函数神经网络的热轧产品性能预测[J]. 广西师范大学学报:自然科学版,2010,3:182-186.
Ma Wenbo, Wu Bin, Zhu Tian, et al. Predict mechanical properties of hot-rolling steel by using RBF neural network[J]. Journal of Guangxi Normal University: Natural Science Edition, 2010,3:182-186.

作者简介:吕志民(1971-),男,研究员,博士生导师,研究方向:生产计划与调度优化、产品质量建模与质量诊断, E-mail:lvzhimin@nercar.ustb.edu.cn;隋筱玥(1985-),女,博士研究生,研究方向:产品质量建模与质量诊断。