

应用回归和神经网络方法预测热轧带钢性能*

莫春立^{1,2)} 李强¹⁾ 李殿中¹⁾ 冯峰¹⁾ 詹志东¹⁾

1) 中国科学院金属研究所, 沈阳 110016

2) 沈阳工业学院材料科学与工程分院, 沈阳 110168

摘要 针对 Q235B 热轧带钢性能预测系统, 提出一种回归分析和神经网络相结合的方法来预测其力学性能. 首先, 测量材料最终相的组成与铁素体的晶粒度, 应用多重回归分析的方法, 建立成分、相体积分数、晶粒尺寸与抗拉强度、屈服强度、延伸率的对应关系. 另一方面, 采用 BP 神经网络方法, 结合相变动力学模型的计算数据, 通过大量数据的自学习训练, 完成神经网络模型对抗拉强度、屈服强度、延伸率的预测. 预测结果表明, 应用神经网络和回归分析方法, 具有较高的预测精度.

关键词 热轧带钢, 神经网络, 回归

中图分类号 TG335.11

文献标识码 A

文章编号 0412-1961(2003)10-1110-05

PREDICTION OF THE PROPERTIES OF HOT ROLLING STRIP BY USING REGRESSION AND NEURAL NETWORK

MO Chunli^{1,2)}, LI Qiang¹⁾, LI Dianzhong¹⁾, FENG Feng¹⁾, ZHAN Zhidong¹⁾

1) Institute of Metal Research, The Chinese Academy of Sciences, Shenyang 110016

2) Faculty of Materials Science and Engineering, Shenyang Institute of Technology, Shenyang 110168

Correspondent: MO Chunli, Tel: (024)29971979, E-mail: clmo@imr.ac.cn

Supported by National High Technical Research and Development Programme of China
(No.2001AA339030)

Manuscript received 2002-10-18, in revised form 2003-04-08

ABSTRACT In order to develop on-line or off-line predictive system of hot rolling process, a model combining the neural network and regression methods was proposed to predict the properties of hot rolled plain carbon steel Q235B. On the base of the measured data to the grain size of ferrite and the fraction of phases at room temperature, a multiple regression method is given to describe the relationship between mechanical property and chemical composition, grain size, fraction of phase and so on. In the present work, the error back-propagation network (BP) is adopted. Combined with the data calculated with the phase transformation kinetic model, a great deal of data were trained many times and compared with the experimental data to these steels, the BP model predicting yield strength, tensile strength, elongation was built. The results show that the properties of hot rolling strip can be precisely predicted using neural network and regression method.

KEY WORDS hot rolling strip, neural network, regression

控制轧制技术是使奥氏体中大量形成铁素体相变核并有效将铁素体晶粒细化的技术. 与控制冷却技术一样, 已成为生产具有良好力学性能钢板的主流工艺. 轧制过程涉及加热、粗轧、精轧, 冷却, 卷取等过程中的奥氏体再结晶、碳氮化物的析出、相变等复杂变化.

为精确预测和控制产品质量, 必须考虑热轧、冷却过程中的组织演化以及组织与力学性能之间的关系. Sellars 等人^[1,2] 提出热轧和冷却过程的复杂微观组织演变模型后, 大量的研究者以 Sellars 模式为基础. 采用各种方式对材料热轧过程中的沉淀析出行为、再结晶、晶粒长大、冷却相变提出计算模型, 并由此预测最终的性能^[3-6]. 这些工作往往从单个过程开始, 最后集成为整个的热轧过程热动力学模型. 随着微观组织演变模型的不开发, 现在应用这些模型对热轧产品性能预测已经成为可能, 以此为基础的预测软件应运而生, 如 VAIQ^[7], CANMET^[8],

* 国家高技术研究发展计划项目 2001AA339030 和沈阳工业学院基金项目 No.3200903 资助

收到初稿日期: 2002-10-18, 收到修改稿日期: 2003-04-08

作者简介: 莫春立, 男, 1971 年生, 博士

其精度已达到要求。组织性能模型是预测模型中最基本的环节，许多预测强度的模型建立在 Hall-Petch 方程的基础上，再引入化学成分，组成相的体积分数，或珠光体的片层距离，或相变的温度^[4,9]等因素。另一方面，由于人工智能技术的发展，采用神经网络的方法进行组织性能分析也得到应用^[10-12]。这种方法在拥有大量数据的场合可以克服线性回归所遇到的问题，提高预测精度。

本文为开发特定钢种热轧过程组织性能预测系统，而在组织性能方面进行了预测，并阐述了预测方法和预测结果。对于钢厂环境来说，在保证产品性能的前提下，要求测试过程尽可能简单，快速，可靠，而微观组织的检验和定量分析不是日常操作，仅在开发新项目或特定产品时才应用。有鉴于此，直接对钢厂的试件进行组织性能分析，从而建立针对某特定钢种的经验公式，可以为生产过程提供预测服务。

1 回归分析方法与神经网络方法

1.1 回归分析模型

采用多元回归分析方法，就是建立各个影响因素与预测值之间比较明确的线性关系，其模型的一般形式为

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \cdots + \beta_p x_p + \varepsilon \quad (1)$$

式中 $\beta_0, \beta_1, \cdots, \beta_p$ 是 $p+1$ 个未知参数，称回归系数。Y 为因变量， x_1, x_2, \cdots, x_p 是自变量。 ε 是随机误差。

代入相关的自变量参数可以得到 $\beta_0, \beta_1, \cdots, \beta_p$ 等 $p+1$ 个未知参数，以及变量间的相关系数、方程的标准差，由此可以进行方程的显著性检验及各项系数的显著性检验。一旦建立起多元回归方程后，就可以利用该方程进行预测。应用回归模型，有大量的统计方法进行数据分析和模型开发。这一点非常重要，它使得回归分析成为最常用的方法。

1.2 人工神经网络模型

神经网络的类型很多，对轧制过程进行数据分析时大多采用 BP 网络^[10]，BP 网络一般由一个输入层、一个输出层和一个以上的隐含层组成，它是一种典型的多层前向网络，层与层之间多采用全互联，同层单元之间无连接。BP 网络的每层权值均是可调的。确定各层节点及各层内部算法的过程称为网络结构的设计，对一个设计好的神经网络确定其权值的过程称为网络训练，训练好的网络即可进行参数的预报。

针对实测的目标，采用 3 层 BP 网络。其输入模式根据测量的强度或韧性可分别采用 8 个或 10 个神经元，对强度，可采用碳含量、硅含量、锰含量、硫含量、磷含量、晶粒尺寸、铁素体体积分数以及板厚等，对韧性，除以上的因素外，还可采用终轧温度、卷曲温度、终轧与卷曲温度差等。输出层为 2 个或 1 个神经元，分别为抗拉强度、屈服强度、延伸率。由于输入层个数较多，为 10 个，中间层个数过少，学习过程将会不收敛或抗干扰性不

好，隐含层个数过多，网络学习和推理的效率下降，性能变差，据不同隐含层个数的误差对比，采用 15 个隐含层比较理想。计算 BP 网络的基本处理单元（输入层的各单元除外）均为非线性输入-输出关系，输入值和输出值均可连续变化，其作用函数要求采用可微分递减非线性连续函数，即，指数型的 S 型函数 (Sigmoid)

$$f(\text{net}_j) = 1/[1 + \exp(-\text{net}_j - \theta_j)] \quad (2)$$

式中 net_j 为隐含层第 j 个神经元的输入值， θ_j 为阈值。在网络的学习阶段，通过调整所有的连接权和阈值使系统的平均误差 E 达到最小

$$E = 1/2 \times \sum_{k=1}^m (t_k - c_k)^2 \quad (3)$$

式中 t_k 为计算的输出量； c_k 为实际的输出量； m 为样本数。

每一层权值按下式调整

$$\begin{aligned} \nu_{ij}(t+1) &= \nu_{ij}(t) + \eta \times a_j \times e_i + \\ &\alpha \times [\nu_{ij}(t) - \nu_{ij}(t-1)] \end{aligned} \quad (4)$$

式中 η 为增益项，也称学习率， $\eta \in (0, 1)$ ； a_j 为节点 j 的误差项； α 为比例常数，也称惯性项系数， $\alpha \in (0, 1)$ ； e_i 为节点 i 的输出值。在样本的学习过程中， η 和 α 对学习效率有很大的影响， η 较大时有助于加快网络的学习过程，但易发生振荡， α 可抑制振荡，但可能使学习速度变慢，兼顾二者，设定 η 为 0.5 和 α 为 0.1。在训练的过程中，初始的权值设定在 0—0.2 之间，目的是保证网络训练不过早的达到饱和，初始权值选择过大，会导致网络不可训练^[12]。网络训练的各项输入值要经过归一化处理，以保证在 ± 1 之间。

2 实验分析步骤

2.1 样本数据的选取与制作

无论是回归分析和神经网络方法，都需要大量的样本数据，用于回归分析和训练网络。这里不仅需要工艺数据，还需要晶粒度和相的体积分数等数据。试样取自钢厂的热轧生产线，从热轧管理处的三级计算站可以得到每一钢种各个参数的记录。带钢板厚不同，长度可达 200—500 m，而热轧过程相对于每个不同部位，轧制力、变形和冷却强度是不同的，因此，所提取的数据要求其性能、工艺参数要对应。一般在距离带钢尾部特定位置取样，测试样品的成分、工艺数据也以取点位置为准。这里选取的钢种是 Q235B，其成分范围（质量分数，%）为：(0.13—0.16)C，(0.16—0.24)Si，(0.27—0.36)Mn，(0.009—0.023)S，(0.007—0.02)P。每个试件要切割，打磨，抛光，并用 3% 的硝酸酒精腐蚀，制备成金相试样，在 400 倍下应用定量分析仪器测量晶粒尺寸和铁素体的体积分数。每个试件至少测量 5

次,取平均值作为进一步计算的标准,所得的晶粒尺寸大致范围是 9.8—16 μm ,珠光体的体积分数范围是 9%—33%,有些试样中心部位存在偏析带,测量时尽量避免,以统一的标准来处理这些数据,以保证数据的有效性。

2.2 回归分析预报结果

理论上说,材料的每一个力学性能指标都是显微组织参量的函数,钢材的强韧化机制主要有固溶强化、析出强化、相变强化、位错强化和细晶强化等,因而,影响室温组织的力学性能的组织参数可归纳为:(1)溶质元素在钢中固溶的质量分数;(2)各组成相的体积分数;(3)铁素体的晶粒尺寸等。

屈服强度的通式可表示为

$$\sigma_s = \sigma_c + \sigma_{GD} + \sigma_{s'} + \sigma_p \quad (5)$$

其中 σ_c , σ_{GD} , $\sigma_{s'}$, σ_p 分别是待定系数项,细晶强化与位错强化项、固溶强化项、析出强化项。本文研究的 Q235B 钢,其固溶强化各元素采用名义成分,因此其系数要修正,同时,根据实际生产条件,引入铁素体晶粒直径 d 和铁素体的体积分数 V_f ,得屈服强度

$$\sigma_s = 10 + 313[\text{Si}] + 107[\text{Mn}] - 54[\text{S}] - 1050[\text{P}] + 25.7d^{-1/2} - 2.7V_f \quad (6)$$

式中 $[\text{Si}]$, $[\text{Mn}]$... 等元素含量按质量分数计算,同理,抗拉强度

$$\sigma_b = 206 + 103[\text{Si}] + 330[\text{Mn}] - 44[\text{S}] - 500[\text{P}] + 17.7d^{-1/2} - 11V_f \quad (7)$$

从式中看,晶粒尺寸和 Si, Mn 的含量对强度的影响占主导地位。由于影响强度的机制与韧性的机制有一定的差异,与屈服和抗拉强度相比,延伸率的预测要困难得多,基体成分,晶粒度,工艺参数,合金元素的含量等,都或多或少的影响延伸率。

在现有数据的基础上,经过分析,引入不同的板厚尺寸 h ,经过大量数据的回归分析,得到延伸率公式

$$\delta = 57.48 - 32[\text{Si}] - 40[\text{Mn}] + 4[\text{S}] + 35[\text{P}] - 0.45d^{-1/2} - 0.14V_f + 0.7h \quad (8)$$

测试结果见图 1 和 2a,抗拉强度、屈服强度和延伸率的标准差分别为 ± 12 MPa, ± 17 MPa 和 $\pm 2.2\%$,相当于抗拉、屈服和延伸率的相对误差分别是 3%, 4.5% 和 7.5%。应该说,这个精度对工艺人员是可以接受的。

从以上的分析可以看出,延伸率的预测指标仍不尽人意,为此,考虑引入精轧出口温度 $FT7$ 和卷曲温度 CT ,经过大量数据的回归分析,得到的延伸率公式如下:

$$\delta = 66.8 + 10V_f + 0.2d^{-1/2} + 14\ln h + 19[\text{Si}] + 4[\text{Mn}] + 58[\text{P}] + 53.5[\text{S}] - 37\ln FT7 + 35.5\ln CT \quad (9)$$

应用这个公式预测延伸率的标准差为 $\pm 2.0\%$ (图 2b)。值得一提的是,工厂测试的 δ 数据范围在 27%—38%,而这里预测值通常范围是 28%—34%,对工厂测试值为 38% 的几个试件,其预测值都达到约 34% 的较大值。对个别各项指标都居于均值而只有延伸率偏高的试件,预测的值也居中,表明实测有一定的偏差,可以据此要求重新测量。

实验中测得的铁素体体积分数和晶粒度还有另一方面的意义。预测的带钢的长度方向的铁素体体积分数和晶粒分布不同,在试样截取点位置的预测和实验值可以比较。对热轧预测系统来说,包含静态、动态再结晶模型、冷却相变模型,晶粒长大以及卷取过程相变等模型,虽然每个模型都有相应的实验验证,但最终的相组成和晶粒度可由此时的实验来验证。

2.3 人工神经网络的预报结果

为提高预测热轧过程组织性能软件的预测精度,除采用回归分析方法外,还应用 BP 神经网络预测强度和延伸率,二者用不同的网络输入模式,对于抗拉和屈服强度,输入的节点是成分、晶粒尺寸、铁素体相的体积分数以及试件的板厚等 7 项;对于延伸率,输入的节点包括成

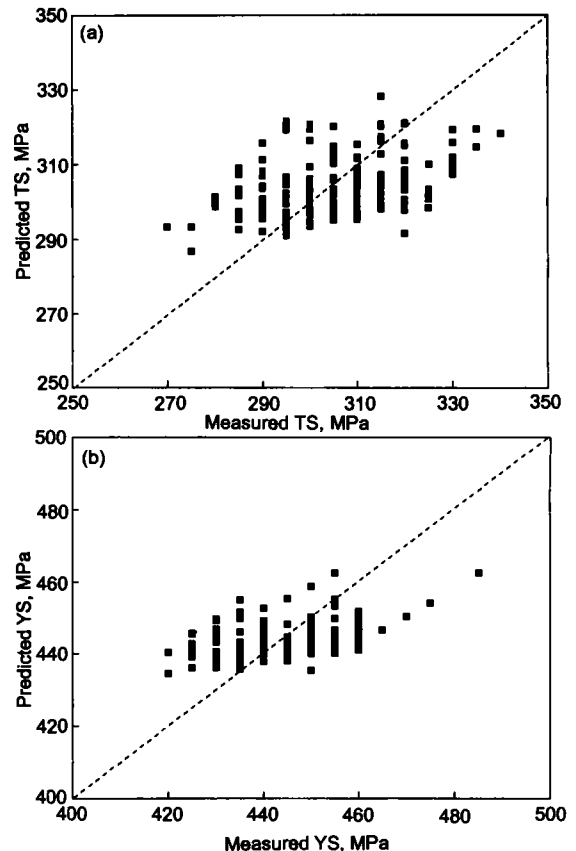


图 1 屈服强度与抗拉强度预测值与实测值的比较

Fig.1 Comparisons of predicted and measured tensile strength (a) and yield strength (b)

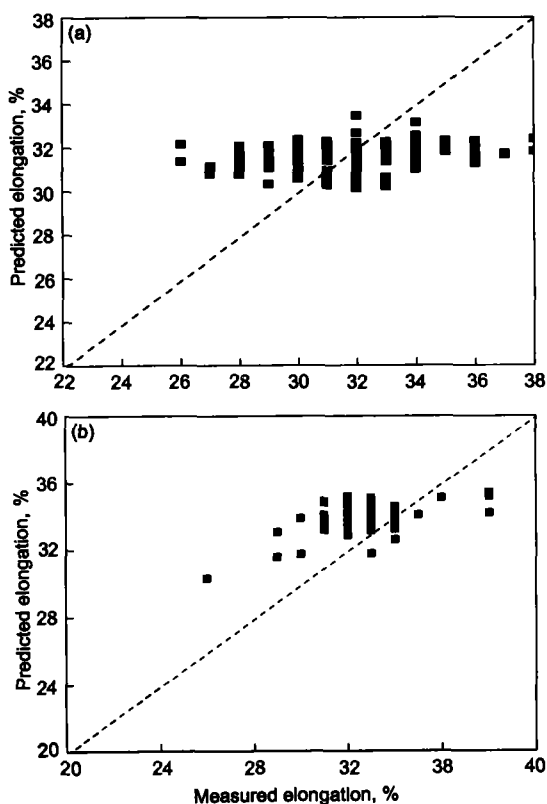


图 2 未考虑与考虑温度情况下延伸率预测值与实测值的比较

Fig.2 Comparisons of predicted and measured elongation without (a) and with (b) considering temperature

分、晶粒尺寸、相体积分数、板厚、终轧温度、卷曲温度、终轧与卷曲温度差等 10 项。其中对应带钢不同部位的晶粒尺寸和相体积分数,是通过开发的软件 Rollan 预测的,其计算过程采用铁素体相变模型^[13]。隐含层可以从 5—50 个节点中选取,经过多次的训练,确定节点数 15 个,既照顾计算的速度,又保证训练的精度。预测强度的网络的输出节点为 2 个,即抗拉和屈服强度,预测延伸率的网络输出节点只有延伸率。应用 160 组实验数据分别对屈服强度和抗拉强度进行网络的训练,训练后进行预测验证。所得的结果如表 1 所示。应用神经网络的计算得到的抗拉强度标准差 12 MPa,屈服强度标准差 16 MPa,延伸率的预测标准差是 1.76%,比回归分析的误差要小。

应该明确,回归分析的各个数据有一定的相关性,有时很难甚至不可能识别单个参量对强度的影响,回归分析的方法可以利用已有冶金知识,获得简单、明了的关系式,其合理性容易检测和与其它的参考文献结果进行比较。这里预测的屈服和抗拉强度标准差比较高,表明在分析过程中还有些不确定因素的影响未考虑,如工艺因素,但从预测的结果看,在预测模型中应用再结晶和相变理论计算,充分考虑成分与晶粒尺寸,相体积分数的影响,可以达到较好的预测结果。而延伸率的预测运用物理冶金的方法不尽人意,因为影响延伸率的因素更多,可以通过引入工艺参数的方法提高预测的精度。相比之下,用神经网络预测的延伸率要准确一些,但它的前提是大量的已知数据的训练和学习,并保证输入数据如晶粒尺寸和体积分数的预测

表 1 神经网络预测值与实测值比较

Table 1 Comparison of mechanical properties predicted by neural network and measured

Measured YS, MPa	Predicted YS, MPa	Error, MPa	Measured TS, MPa	Predicted TS, MPa	Error, MPa	Measured elongation, %	Predicted elongation, %	Error	
310	311.32	1.322	455	450.12	4.878	33	29.537	3.463	
300	311.72	11.728	455	450.29	4.703	30	30.782	0.782	
290	296.48	6.486	430	446.99	16.994	31	31.233	0.233	
310	289.70	20.300	430	429.94	0.051	32	29.816	2.184	
300	289.74	10.259	440	424.46	15.540	30	30.461	0.461	
305	298.54	6.456	440	424.46	15.532	32	29.547	2.453	
300	296.67	3.330	435	433.28	1.719	34	30.403	3.597	
305	296.43	8.562	440	442.63	2.637	32	30.676	1.324	
330	309.46	20.531	460	442.36	17.633	29	29.487	0.486	
270	292.93	22.931	430	431.89	1.893	34	31.564	2.436	
315	300.14	14.853	450	440.76	9.235	32	29.782	2.218	
285	293.46	8.464	435	435.78	0.788	34	31.051	2.949	
280	299.25	19.253	440	453.49	13.494	32	32.13	0.136	
325	289.38	35.611	450	424.84	25.159	32	29.396	2.604	
305	295.45	9.548	435	433.98	1.017	32	30.860	1.140	
Standard error		16.463 MPa	Standard error		12.083 MPa	Standard error			1.764

的准确性. 综合运用回归分析和神经网络的自学习方法, 可以达到较好的预测精度. 由于采用的性能预测模型简单, 实用, 将其集成到热轧过程组织性能预报系统之中, 已经实现离线的性能预报.

在应用过程中对于强度和塑性的预测都是针对普碳钢 Q235B 的, 其适用的成分和工艺条件是相对固定的, 在未来要进行的其它钢种组织性能的预测过程中, 采用的公式的系数或参数会有一些的区别, 这是可以理解的, 随着预测精度要求的提高和钢种的不断开发, 相信会有更精确的模型出现.

3 结论

在进行热轧过程的组织性能预测软件开发时, 应用回归分析和人工神经网络方法预测普碳钢 Q235B 热轧带钢的性能, 既考虑物理冶金因素又考虑工艺因素对最终组织性能的影响. 针对强度预测, 采用回归分析方法可以达到要求的预测精度, 过程相对简单. 而延伸率, 由于影响的因素多, 尤其是工艺因素的影响, 用回归分析的方法精度较差. 采用神经网络方法, 结合相变过程模型并考虑工艺因素、板厚等条件可提高预测能力, 这些模型在离线的性能预报系统中得到应用并得到较好的预测效果.

参考文献

- [1] Sellars C M, Davies G J. *Met Soc*, London, 1980: 3
- [2] Sellars C M, Whiteman J A. *Met Sci*, 1979; 13: 187
- [3] Hodgson P D. *J Mater Proc Technol*, 1996; 60: 27
- [4] Majta J, Kuziak R. *J Mater Proc Technol*, 1996; 60: 581
- [5] Trowsdale A J, Anderson K R. *Proc Conf 'Thermomechanical Processing of Steels'*, London, 2000; 1: 332
- [6] Denis S, FaRias D, Simon A. *ISIJ*, 1992; 32(3): 316
- [7] Vaiq S. VOEST-ALPINE Industrieanlagenbau GmbH, Automation Department, Linz, Austria
- [8] Baragar D L, *Canadian Metals Technology Laboratories Report MTL 95-20(CF)*, 1995
- [9] Kwon O. *ISIJ*, 1992; 32(3): 350
- [10] Zheng H, Wang Z D, Wang G D, Zhang P J. *Iron and Steel*, 2002; 37(7): 37
(郑 晖, 王昭东, 王国栋, 张丕军. 钢铁, 2002; 37(7): 37)
- [11] Sourmail T, Bhadeshia H K D H, Mackay D J C. *Mater Sci Technol*, 2002; 18(6): 655
- [12] Abihijit S P, Translated by Xu Y, Jing T. *Pattern Recognition with Neural Networks in C++*, Beijing: Electronics Industry Press, 1999: 57
(Abihijit S P 著, 徐 勇, 荆 涛译. 神经网络模式识别及其实现. 北京: 电子工业出版社, 1999: 57)
- [13] Zhang Y T, Li D Z. *Acta Metall Sin*, 2002; 15(3): 267
(张玉妥, 李殿中, 金属学报, 2002; 15(3): 267)