

文章编号: 1001-0920(2002)04-0443-04

具有 NN 分级误差补偿器的轧制力预报模型

袁枫华¹, 王贞祥¹, 徐心和¹, 华建新², 周 勇², 羌菊兴²

(1. 东北大学 信息科学与工程学院, 辽宁 沈阳 110004; 2. 宝山钢铁股份有限公司 设备部, 上海 201900)

摘 要: 为提高冷轧带钢质量, 必须建立精确的轧制力预报模型。介绍了带有神经网络参数辨识器的轧制力预报模型, 并采用神经网络构造误差补偿器。通过按时间跨度分级的数据处理过程, 形成长期和短期训练数据集, 结合相应的网络训练机制, 实现模型预报误差的分级补偿。仿真结果表明, 该预报模型能有效地提高预报精度。

关键词: 冷轧; 轧制力预报; 多级神经网络; 误差补偿

中图分类号: TP 183 **文献标识码:** A

Rolling force prediction model based on error compensation with multi-level NN

YUAN Feng-hua¹, WANG Zhen-xiang¹, XU Xin-he¹
HUA Jian-xin², ZHOU Yong², QIANG Ju-xing²

(1. School of Information Science and Engineering, Northeastern University, Shenyang 110004, China;

2. Department of Equipment, Baoshan Iron and Steel Company Ltd., Shanghai 201900, China)

Abstract: In order to get high quality strips, it is necessary to have a precise prediction model of rolling force of the strip cold rolling mill. A new method using multi-level NN to compensate the error is introduced to the prediction model of rolling force. Two kinds of data sets for NN training are formed according to the data collection interval. A special training mechanism is designed for this model. The final simulation chart shows the improved results.

Key words: strip cold rolling mill; rolling force prediction model; multi-level NN; error compensation

1 引 言

近年来, 随着我国汽车、电子电器等行业的发展, 对冷轧薄板需求逐年增多, 质量要求不断提高, 因此对冷轧过程轧制力模型的预报精度也提出更高的要求。传统模型采用的机理建模方式由于受假设条件等的制约, 很难精确反映实际轧制过程。近年来, 神经网络在轧钢领域得到广泛的应用, 尤其是神经网络与机理模型相结合的形式取得了较好的效

果^[1,2]。

在冷轧的轧制力预报模型中, 通过引入 NN 辨识器来辨识带钢变形抗力参数, 可在一定程度上提高模型的预报精度。但由于影响轧制力模型精度的因素众多且作用复杂, 因此该模型仍存在一定误差。通常, 这部分误差都是交由设定计算系统的模型自适应环节进行修正。由于自适应是个渐进修正过程, 当偏差较大时势必造成前一部分带钢设定效果不好, 从而影响了产品质量。

收稿日期: 2000-12-11; 修回日期: 2001-03-06

作者简介: 袁枫华(1974—), 女, 天津人, 博士生, 从事计算机控制与仿真等研究; 华建新(1957—), 男, 江苏无锡人, 教授级高工, 从事神经网络、板形控制等研究。

本文介绍的轧制力模型利用NN构造出模型的误差补偿器,通过特殊的训练机制对NN进行训练,得到网络输出的误差补偿因子,实现模型误差的分级补偿。这样无疑会减轻自适应环节的负担,加快设定计算的速度,从而提高带钢的质量。

2 NN 变形抗力参数辨识器

在实际生产中,冷连轧过程控制系统使用的轧制力模型属于稳态模型,反映的是影响轧制压力的一些主要因素与轧制力之间的定量关系。这些因素包括带钢的入口和出口厚度、入口和出口张力、带钢宽度、变形抗力、轧辊直径、摩擦力等。其建模机理大多是根据刚塑性变形条件建立力平衡方程,获得带钢变形区主应力的分布函数,在此基础上计算轧制力^[3]。

在众多影响因素中,带钢的变形抗力是决定模型计算精度的关键因素之一。传统方法是利用拉伸实验数据辨识变形抗力,而目前多采用轧制法^[4],即利用实测轧制力反推计算材料的变形抗力,然后用回归分析法建立变形抗力模型。

在本轧制力模型中, x 点处的变形抗力为

$$k_{f_x} = K_{F_0} + K_{F_T}(1 - h_x/H)^{K_{F_E}} \quad (1)$$

式中, K_{F_0} 为无压下量时的屈服强度, K_{F_T} 为压下率为100%(即 $h_x = 0$)时屈服强度增量极限值, K_{F_E} 为加工硬化曲线指数, h_x 为变形区 x 点处的厚度。

为精确辨识出非回归点的变形抗力参数,利用以上回归数据作为训练数据,并用NN建立起带钢材质、规格等参数与变形抗力参数 K_{F_0} 、 K_{F_T} 和 K_{F_E} 之间的多元映射关系,构成NN变形抗力辨识器。NN辨识器结构为

$$(K_{F_0}, K_{F_T}, K_{F_E}) = \text{NN}(C, \dots, Ca, H, h, T, t) \quad (2)$$

式中, C, \dots, Ca 为带钢中各合金元素含量, h 为带钢成品厚度, T 为热轧带钢出口温度, t 为冷却剂温度。

网络拓扑结构采用35-12-3的3层网络。为配合误差补偿器及其训练机制的设计,NN辨识器采用自适应线性环节(Adaline)前馈网络,该网络按 δ 学习规则进行网络节点权值的调整。由于Adaline网络中的节点模型采用线性转换函数,且只对经过筛选的节点进行权值调整,因此具有较快的网络训练速度^[5],适合于多级复杂网络。

3 NN 误差补偿器

3.1 误差补偿器的结构

采用NN辨识器提供的变形抗力参数计算变形抗力,使模型精度有了一定提高,但模型误差仍然无法完全消除。通过对轧制力模型结构及实际轧制过程的分析,发现模型误差主要与所轧带钢的变形抗力、规格、轧制过程中的温度、润滑、摩擦等多种条件有关。为辨识这种多维参数间的复杂非线性关系,进一步利用NN构成了误差补偿器。NN误差补偿器结构为

$$(k_{f_r}, k_{f_s}, k_{m_r}) = \text{NN}(k_f, h_0, h_1, H, \mu, t_0, B, \text{lub}, \text{eps}) \quad (3)$$

式中,lub表示润滑(用1~10的数字表示),eps表示基本的压下调节量, $k_{f_r}, k_{f_s}, k_{m_r}$ 为轧制力模型输出的轧制力、前滑及转矩的补偿因子。

网络拓扑结构采用9-4-3的3层Adaline前馈网络。

3.2 误差分级与相应训练数据集的形成

数据的采集与处理对于NN的训练效果起着至关重要的作用。在本模型中,根据冷轧机的运行特性,采用了按时间跨度大小对NN训练数据进行分级的方法,即用时间跨度大的长期数据去辨识轧制力模型中相对稳定的误差成分,用时间跨度小的短期数据去辨识由于某些参数在近期内波动引起的模型附加误差。为分别补偿这两级模型误差,设计了结构相同的两个NN。

用于训练两个NN误差补偿器的数据集形成过程如下:

1) 轧制过程数据的实时记录:在冷轧设定计算系统中,将计算中使用的过程实测数据以数据记录的形式实时保存到过程数据文件中。这些实测数据包括实测轧制力、入口出口厚度、前后张力等反推变形抗力时所需参数,以及训练NN误差补偿器所需的网络输入量的实测值,同时要记录数据保存时的系统时间。

2) 短期数据集的形成:首先对保存在数据文件中的轧制过程数据记录进行筛选,筛选条件有两个:

$\frac{h_{0\text{last}} - h_{1\text{last}}}{h_{0\text{last}}} < \text{eps}_{\text{Slast_max}}$,即要求最后一架的压下小于规定的极限值。

用此记录中的实测数据反算变形抗力参数,迭代计算的最终偏差应小于要求的极限。

满足条件 可保证所选数据均为正常轧制过

程的数据, 以便反映具有一般意义的误差非线性关系; 满足条件 可使数据中所反映的误差关系排除变形抗力误差部分。

最后, 将选出的数据记录按合金类型、入口和出口厚度划分成不同的等级, 并按所属等级顺次排列, 形成短期数据集。

3) 长期数据集的形成: 长期数据集是通过不断追加短期数据集中的数据形成的。长期数据集中的数据记录也按合金类型、入口和出口厚度等级排列。为了控制 NN 的训练时间, 长期数据集中的记录不能无限增加, 因此要为每一等级中的记录数 n_c 规定一个上限 N 。本文确定的数据记录追加原则如下:

当 $n_c < N_c$ 时, 直接在该等级的结尾处追加此数据记录;

当 $n_c = N_c$ 时, 即记录数已达到极限, 此时先在此等级中删除一条与前一记录时间跨度最小的数据, 再在结尾处追加新数据。

以上追加原则可保证不断增大数据记录的时间跨度, 而不超出数据集的容量。

3.3 误差补偿器训练机制

随着轧制过程的进行, 不断向过程数据文件中添加过程数据。根据所设计的短期数据集的最大容量, 需要确定数据集更新的时间间隔(如 1 天), 以便周期性更新短期数据集, 并追加长期数据集。

每当得到新的短期数据集和追加的长期数据集后, 使用它们对两级误差补偿器进行一次训练, 实现对 NN 补偿器的持续优化过程。训练步骤如下:

1) 利用长期数据集训练网络, 其原理如图 1 所示。




图 1 一级误差网络 NN_long 训练原理

将目标输出(模型输出量对应的实测值)与 NN 辨识器的轧制力模型输出值之比 K_1 作为 NN 的输出目标, 通过误差反传给训练网络。将训练得到的网络作为第一级误差补偿器, 它反映了长期以来轧机固有特性造成的误差, 记为 NN_long(长期特性网络)。网络输出为一级误差补偿因子 K_{long} 。

2) 利用短期数据集训练另一网络, 其原理如图 2 所示。




图 2 二级误差网络 NN_short 训练原理

训练原理与 1) 相同, 只是将目标输出与经过一级误差补偿的综合轧制力模型输出值之比 K_2 作为 NN 的输出目标, 得到的网络作为第二级误差补偿器。它反映了轧机近期特性造成的误差, 记为 NN_short(近期特性网络)。网络输出为二级误差补偿因子 K_{short} 。

在网络训练时, 首先对备份网络进行训练。若训练后网络的训练误差小于训练前网络, 即网络得到改进, 则用当前网络替换在线使用的网络, 参与下一次预报计算; 否则, 清除训练结果, 等待下一次网络训练。

4 引入 NN 分级误差补偿器的轧制力模型

在实际系统的设定计算过程中, 使用的是如图 3 所示的综合轧制力预报模型, 以经过两级误差补偿的模型输出值作为轧制力的预报值。




图 3 具有 NN 分级误差补偿器的轧制力模型
图 1 ~ 图 3 中的符号说明如图 4 所示。




图 4 图 1 ~ 图 3 的符号说明

5 仿真结果分析

为验证采用 NN 误差分级补偿器后轧制力模型的预报效果, 利用 VC++ 5.0 设计并编制了“轧制力模型研究”仿真软件。在此软件中, 对引入 NN 误

差补偿器前、后模型计算结果进行了比较。

以 0430550600 号带钢为例,带钢合金号为 AP1056E1,带宽 1 023 mm,入口和出口厚度分别为 2 820 mm 和 0 500 mm,取其 30 组实测数据作为对比标准,计算并绘制的仿真结果曲线如图 5 所示。其中,横坐标为实测数据组数(n),纵坐标为轧制力(f/N);曲线 ① 为实测轧制力,曲线 ② 为引入分级(两级)NN 误差补偿的轧制力模型输出,曲线 ③ 为引入一级 NN 误差补偿器(长时)的轧制力模型输出,曲线 ④ 为无 NN 误差补偿器的轧制力模型输出。




图 5 轧制力仿真结果

由图 5 可以看出,未经补偿的轧制力模型计算结果偏小;经 NN 误差补偿器修正后,计算结果更加接近实测轧制力。

针对图 5 仿真曲线的相关统计数据列于表 1,其中相对偏差计算公式为(实测值-计算值)/实

测值。

表 1 仿真计算结果统计数据

轧制力	最大值	最小值	平均值	相对偏差
实测值	1.212 2e+ 007	1.192 0e+ 007	1.200 8e+ 007	
计算值	1.084 0e+ 007	1.075 1e+ 007	1.079 3e+ 007	10.12%
修正值	1.166 6e+ 007	1.157 1e+ 007	1.161 5e+ 007	3.27%

利用编制的仿真程序,对不同钢种和不同规格的 10 卷带钢进行上述仿真计算。计算结果表明,引入 NN 分级误差补偿器后,轧制力模型的预报偏差可降低(5~7)%。

参考文献(References):

- [1] 王国栋,刘相华,吕程,等 人工智能在轧钢中的应用与性能预报[J] 钢铁,2000,35(增刊):24-31
(Wang Guodong, Liu Xianghua, Lu Cheng, et al Application of artificial intelligence to steel rolling and performance prediction [J]. *Iron & Steel*, 2000, 35(S): 24-31.)
- [2] J Larkiola, P M ylykoski, J N ylander, et al Prediction of rolling force in cold rolling by using physical models and neural computing [J] *J of Materials Processing Technology*, 1996, 7(60): 381-386
- [3] 赵志业 金属塑性变形与轧制理论[M] 北京:冶金工业出版社,1982 349-369
- [4] 杨节 轧制过程数学模型[M] 北京:冶金工业出版社,1993 29-32
- [5] 张立明 人工神经网络的模型及其应用[M] 上海:复旦大学出版社,1993 24-32

(上接第 442 页)

参考文献(References):

- [1] Powell W. Neither market nor hierarchy: Network forms of organization [J] *Res in Organ Beh*, 1990, 12(4): 295-336
- [2] Symon G. Information and communicational technologies and network organization: A critical analysis [J] *J of Occup & Organ Psyc*, 2000, 73(4): 389-414
- [3] Podolny J, K Page. Network forms of organization [J] *Ann Rev of Soci*, 1998, 24(1): 57-76
- [4] Vidal C J, M Goetschalckx. Strategic production distribution models: A critical review with emphasis on global supply chain models [J] *Europ J of Oper Res*, 1997, 98(1): 1-18
- [5] 赵道致 企业内部供应链产量联合优化决策研究[J] 系统工程学报,1999,14(2):162-166
(Zhao Daozhi The study on decision making of joint optimal production quantity in supply chain within a firm [J]. *J of Syst Eng*, 1999, 14(4): 162-166.)
- [6] Alfredsson P, J Verrijdt. Modeling emergency supply flexibility in a tow-echelon inventory system [J] *Manag Sci*, 1999, 45(10): 1416-1431.
- [7] Cachon G P, P H Zipkin. Competitive and cooperation inventory policies in a tow-stage supply chain [J] *Manag Sci*, 1999, 45(7): 936-953
- [8] 钟契夫,陈锡康 投入产出分析[M] 北京:中国财政经济出版社,1987. 677-680