

轧制

基于改进的 BP 神经网络无缝钢管连轧轧制力的预测

张 坚^{1,2}, 双远华², 胡建华², 穆佳浩¹, 赵铁林³

- (1. 太原科技大学 重型机械教育部工程研究中心, 山西 太原 030024;
2. 太原科技大学 材料科学与工程学院, 山西 太原 030024;
3. 太原重工股份有限公司, 山西 太原 030024)

摘要: 无缝钢管连轧过程具有多变量、强耦合、非线性等特点, 传统的数学模型无法对一些参数进行精确地预测。为了提高连轧过程中轧制力预测的精度, 采用改进初始值选取方法来优化 BP 神经网络, 建立改进的 BP 神经网络的轧制力预测模型。首先, 采集某钢厂历史生产数据, 进行预处理, 通过灰色关联度确定影响轧制力的主要因素; 然后, 对初始值进行设置, 利用 MATLAB 编写仿真程序对连轧机组轧制力进行预测。结果表明: 基于改进的 BP 神经网络的轧制力预测模型具有很强的学习能力和表达能力, 轧制力预测精度得到了很大的提高, 对实际的生产具有重要意义。

关键词: 无缝钢管; 轧制力; 初始值选取方法; 灰色关联分析; 改进的 BP 神经网络

DOI: 10.13330/j.issn.1000-3940.2022.05.023

中图分类号: TP183 **文献标志码:** A **文章编号:** 1000-3940 (2022) 05-0153-08

Prediction on rolling force in continuous rolling of seamless steel pipe based on improved BP neural network

Zhang Jian^{1,2}, Shuang Yuanhua², Hu Jianhua², Mu Jiahao¹, Zhao Tielin³

- (1. Heavy Machinery Ministry of Education Engineering Research Center, Taiyuan University of Science and Technology, Taiyuan 030024, China;
2. School of Materials Science and Engineering, Taiyuan University of Science and Technology, Taiyuan 030024, China;
3. Taiyuan Heavy Industry Co., Ltd., Taiyuan 030024, China)

Abstract: The seamless steel pipe rolling process has the characteristics of multivariable, strong coupling and nonlinear, and the traditional mathematical model can not predict some parameters accurately. Therefore, in order to improve the accuracy of rolling force prediction during rolling process, BP neural network was optimized by the improved initial value selection method, and the improved BP neural network rolling force prediction model was established. First, the historical production data of a steel mill were collected and preprocessed, and the main factors affecting rolling force were determined by grey correlation degree. Then, the initial value was set, and the simulation program was written by MATLAB to predict the rolling force of continuous rolling mill. The results show that the rolling force prediction model based on the improved BP neural network has strong learning ability and expression ability, and the rolling force prediction accuracy is greatly improved, which is of great significance to the actual production.

Key words: seamless steel pipe; rolling force; initial value selection method; grey correlation analysis; improved BP neural network

无缝钢管在国民经济中占有重要地位, 是工业中的重要原材料, 在石油化工、航空航天、煤

炭开采、电力等行业应用广泛^[1]。连轧过程是无缝钢管生产过程中的重要环节, 轧制力是连轧过程中的重要参数, 在连轧过程中, 轧制力影响着无缝钢管生产的质量及稳定性^[2]。传统的轧制力模型是基于假设和理想的平衡条件建立的, 公式中的一些经验系数更是基于特定的实验确定的取值范围, 在实际计算时, 还需对边界条件进行简化。因此, 传统的轧制力模型很难通过计算获得精确的轧制力^[2]。

收稿日期: 2021-04-06; 修订日期: 2021-07-14

基金项目: 山西省科技重大专项 (20191102009); 山西省重点研发项目 (201903D121049)

作者简介: 张 坚 (1994-), 男, 硕士研究生

E-mail: S20190365@stu.tysut.edu.cn

通信作者: 双远华 (1962-), 男, 博士, 教授

E-mail: yhshuang@tysut.edu.cn

人工智能时代的到来拓宽了各行业发展的新思路,以大数据和云计算为核心的自学习模型被引入钢铁行业^[3]。其中,人工神经网络和工艺参数预测的相互契合引起学者们的广泛研究。人工神经网络是一种具有自适应学习特点的高度非线性智能信息处理系统,神经网络利用大量的数据,能够灵活、精确地解决多变量非线性系统问题,提高轧制力模型预测精度,成为人工智能研究的热点之一^[4]。刘翰培等^[5]利用 L-M 算法和多线程 CPU 优化法结合的神经网络进行预测建模;马威等^[6]利用深度学习的方法预测热连轧,预测精度得到了很大的提高。本文引入设置初始值的方法来改进 BP 神经网络。然后,利用改进后的 BP 神经网络对无缝钢管三辊六机架连轧机组轧制力预测进行研究。

1 传统的连轧轧制力数学模型

无缝钢管连轧过程中的弹塑性变形非常复杂,涉及变形力、速度、流量、温度等大量的物理参数^[7],轧辊、芯棒与钢管之间接触面积的变化和芯棒与轧辊速度的差异等因素均会对变形产生影响。三辊六机架连轧机沿轧制方向存在减径区和减壁区^[8],由于这两个区域的变形特点不同,单位压力也不尽相同,所以,轧制力 T 为这两部分的合力,计算公式为:

$$T = \bar{p}_1 F_1 + \bar{p}_2 F_2 \quad (1)$$

式中: \bar{p}_1 为减径区的平均单位压力, MPa; F_1 为减径区的接触面积的水平投影, mm^2 ; \bar{p}_2 为减壁区的平均单位压力, MPa; F_2 为减壁区的接触面积的水平投影, mm^2 。

实验研究的无缝钢管连轧线体生产的管坯外径范围为 $\Phi 90 \sim \Phi 150 \text{ mm}$,材料为 20 钢,成品外径精度要求为 $-1\% \sim +1\%$,成品壁厚精度要求为 $-12.5\% \sim +12.5\%$,连轧最低入口温度为 $1000 \text{ }^\circ\text{C}$ 。无缝钢管连轧的变形机理是当毛管开始进入轧辊后,纵向直径减小,处于减径区,但壁厚并未减小,甚至略有增大;当毛管被压缩至与芯棒发生接触时,在轧辊与芯棒的双重作用下毛管壁厚减小,发生减壁变形,金属大量延伸,毛管的轴向长度增大,处于减壁区^[8]。毛管进入连轧机组进行轧制时,每个机架对其进行轧制的轧制力有很大差异,采集的轧制力数据是从企业线体中的 Imapda 监控软件中提取并记录

的,机架的轧制速度也为从该监控软件采集得到。其中,成品外径、成品壁厚是产品规格,出口速度和芯棒直径均是生产设备的实际值。荒管外径、荒管壁厚是在连轧出口使用 X 射线测厚仪进行测量的。因此,将连轧过程中变化较多和容易采集的参数作为 BP 神经网络的输入,所以,神经网络的输入初定为轧制速度、成品外径、成品壁厚、轧件出口长度、芯棒直径、减径率、减壁率、延伸系数、荒管外径、荒管壁厚、荒管重量。

2 改进的 BP 神经网络

BP 神经网络是一种按误差反向传播训练的多层前馈神经网络模型,它的基本思想为梯度下降法,学习过程包括信号的正向传播与误差的反向传播两个过程^[9]。BP 神经网络的自学习、自适应、函数逼近映射能力、较强的容错性、快速并行信息处理及本身的结构特点,使其在无缝钢管连轧轧制力的预测中发挥着巨大作用^[10]。但是,由于 BP 神经网络自身结构的原因,存在着无法避免的缺陷。在 BP 神经网络的发展中,针对这些缺陷,分别从初始值的选择、加入动量项、采用共轭梯度法、学习速率渐小法和其他智能算法相结合的方法对 BP 神经网络进行改进。本文研究改进初始值的设置方法对 BP 神经网络进行改进。

初始值是 BP 神经网络的训练过程的基础和重要开端,它的选取影响着网络是否能顺利进行和网络训练精度。文献中网络选取初始值的常用方法是随机产生^[11],这样选取的初始值往往会增加结果的不确定性,无法确定网络训练的优劣,并且会使学习次数增加,甚至出现网络不收敛。因此,本文将小波网络设置初始值的方法引入到 BP 神经网络的初始值设置中,同样,将初始值的设置和学习样本、神经元传递函数建立联系,本文根据这一设想,建立了一种初始值的设置方法^[12]。网络初始参数设置步骤如下:

设 BP 神经网络的隐层节点数为 J ,输入层节点数为 I , w_{ji} 为隐层第 j 个神经元到输入层第 i 个神经元的连接权值, θ_j 为隐层第 j 个神经元的阈值。首先,进行 w_{ji} 的初始设置,步骤如下:

Step 1: 在 $[-1, 1]$ 区间随机选择均匀分布数作为 w_{ji} 的初始值 $w_{ji}^{(0)}$ 。

Step 2: 对 w_{ji} 按行进行归一化处理得到 $w_{ji}^{(1)}$:

$$w_{ji}^{(1)} = \frac{w_{ji}^{(0)}}{\sqrt{\sum_{i=1}^I w_{ji}^{(0)^2}}},$$

$$j = 1, 2, \dots, J; i = 1, 2, \dots, I \quad (2)$$

Step 3: 用输入层节点数 I 、隐层节点数 J 和传递函数相关的系数对 w_{ji} 进行修正得到 $w_{ji}^{(2)}$ 。计算公式式 (3) 为:

$$w_{ji}^{(2)} = C \cdot J^{1/I} \cdot w_{ji}^{(1)},$$

$$j = 1, 2, \dots, J; i = 1, 2, \dots, I \quad (3)$$

式中: C 为隐层传递函数相关的一个常数。传递函数为 Tansig 时, $C=1.9$; 传递函数为 Sigmoid 时, $C=2.1$ 。

Step 4: 设输入层第 i 个神经元的输入样本中最大值为 x_{imax} , 最小值为 x_{imin} , 连接权值和学习样本建立联系。则最终的初始权值 $w_{ji}^{(3)}$ 为:

$$w_{ji}^{(3)} = \frac{2w_{ji}^{(2)}}{x_{imax} - x_{imin}} \quad (4)$$

按照以上步骤得到的 $w_{ji}^{(3)}$ 即为理想的神元之间的初始权值。得到 $w_{ji}^{(3)}$ 之后, 再进行神经元阈值 θ_j 的初始值设置, 其过程如下:

Step 1: 在 $[-1, 1]$ 区间随机选择均匀分布数作为 θ_j 的初始值 $\theta_j^{(0)}$ 。

Step 2: 用输入层节点数 I 、隐层节点数 J 和传递函数相关的系数对阈值 θ_j 进行修正得到 $\theta_j^{(1)}$ 。计算公式式 (5) 为:

$$\theta_j^{(1)} = C \cdot J^{1/I} \cdot \theta_j^{(0)} \quad (5)$$

此处 C 值和式 (3) 取值规则一样: 传递函数为 Tansig 时, $C=1.9$; 传递函数为 Sigmoid 时, $C=2.1$ 。

Step 3: 最后再与学习样本以及 $w_{ji}^{(3)}$ 相联系得到最终的初始阈值 $\theta_j^{(2)}$ 为:

$$\theta_j^{(2)} = \theta_j^{(1)} - 0.5 \sum_{i=1}^I w_{ji}^{(3)} (x_{imax} - x_{imin}) \quad (6)$$

多隐层的初始值设置方法一致, 即把输入层看作第 1 隐层, 把隐藏层看作第 2 隐层。以此类推, 可以计算得出第 2 隐层的权值和阈值。

3 基于改进的 BP 神经网络的轧制力模型

3.1 数据的预处理

原始数据是在某钢厂轧制现场采集得到的, 共 220 组原始数据, 其中, 200 组为训练集和测试集, 剩下的 20 组为网络训练好后检验网络的检验集。部分实验预测数据样本如表 1 所示。它应用于 BP 神经网络之前必须做相应的预处理。

表 1 BP 神经网络训练的部分实验样本

Table 1 Part of experimental samples for BP neural network training

参数	数值			
成品外径/mm	Φ48	Φ57	Φ60	Φ89
成品壁厚/mm	4.0	4.5	4.5	6.0
荒管外径/mm	Φ71.00	Φ135.00	Φ136.00	Φ134.99
减径率/%	28.3	18.2	17.6	18.2
荒管壁厚/mm	3.92	3.92	3.92	10.92
芯棒外径/mm	Φ63.00	Φ127.00	Φ128.00	Φ113.00
轧件出口长度/mm	14585	21494	20642	7874
荒管重量/kg	92.5	266.3	257.7	257.0
延伸系数	4.38	4.24	4.08	2.28
减壁率/%	70.9	72.9	71.9	49.2
第 1 机架轧制速度/ (r · min ⁻¹)	883.94	877.98	870.23	820.25
第 2 机架轧制速度/ (r · min ⁻¹)	935.94	920.95	900.25	877.69
第 3 机架轧制速度/ (r · min ⁻¹)	915.98	927.96	906.96	890.21
第 4 机架轧制速度/ (r · min ⁻¹)	911.98	927.56	890.22	806.23
第 5 机架轧制速度/ (r · min ⁻¹)	778.02	754.62	780.44	744.21
第 6 机架轧制速度/ (r · min ⁻¹)	806.97	777.83	780.16	744.56
第 1 机架轧制力/kN	183.26	176.43	174.98	168.93
第 2 机架轧制力/kN	172.99	170.69	169.32	152.61
第 3 机架轧制力/kN	142.65	139.23	137.96	117.79
第 4 机架轧制力/kN	128.66	124.32	123.25	109.07
第 5 机架轧制力/kN	99.05	92.52	92.08	65.91
第 6 机架轧制力/kN	61.35	57.45	56.27	36.35

3.1.1 数据的筛选

可以根据数理统计方法中的“ 3σ ”原则进行 220 组原始数据的筛选^[13]。由于生产型数据服从正态分布, 故有:

$$P[(\bar{K} - 3\sigma) < K_m < (\bar{K} + 3\sigma)] = 99.7\% \quad (7)$$

$$\bar{K} = \frac{1}{n} \sum_{m=1}^n K_m, \quad \sigma = \sqrt{\frac{1}{n-1} \sum_{m=1}^n (K_m - \bar{K})^2} \quad (8)$$

式中: P 为概率函数; \bar{K} 为样本均值; σ 为样本的标准差; K_m 为样本数据; m 为样本序号, $m=1, 2, \dots, n$; n 为样本总个数。

数据落在 $(\bar{K} - 3\sigma) \sim (\bar{K} + 3\sigma)$ 之间为正常数据, 否则为异常数据。将异常数据剔除, 经过计算

本实验所取的数据均符合“ 3σ ”原则。

3.1.2 数据的转换

由于筛选后的样本集数据间的数量级差别较大,为了提高网络的训练效率及网络的泛化能力。采用 Mapminmax 函数对整个样本集进行归一化处理^[14]。

Mapminmax 函数的数学表达式为:

$$y = \frac{(y_{\max} - y_{\min})(x - x_{\min})}{(x_{\max} - x_{\min})} + y_{\min} \quad (9)$$

式中: y 为归一化后的样本数据; x_{\max} 、 x_{\min} 为待归一样本数据的最大值和最小值; y_{\max} 、 y_{\min} 为样本数据映射的最大值和最小值,这里分别取 1、-1; x 为待归一的样本数据。

3.2 输入变量和输出变量的确定

在第 1 节中初步选取的神经网络的输入为: 机

架的轧制速度、成品外径、成品壁厚、出口长度、芯棒直径、减径率、减壁率、延伸系数、荒管外径、荒管壁厚、荒管重量 11 个参数。在应用 BP 神经网络建模时,输入变量太多会使得网络的结构复杂,学习速率降低。因此,本节采用灰色关联分析^[13],结合实验中的实际数据,计算了各工艺参数与轧制力的关联度,得出主要的工艺参数作为输入变量。具体方法如下:

Step 1: 确定参考数列和比较数列。定义轧制力数列 X_0 为参考数列, $X_0(k)$, $k=1, 2, \dots, N$, N 为样本集容量; 定义选定的与轧制力相关的工艺参数数列 X_l 为比较数列, $X_l(k)$, $l=1, 2, \dots, M$, M 为样本集维数。

Step 2: 计算各工艺参数与钢管壁厚之间的关联系数, 关联系数 $\gamma_i(k)$ 的表达式为:

$$\gamma_i(k) = \begin{cases} \frac{\min_l \min_k |X_0(k) - X_l(k)| + \rho \max_l \max_k |X_0(k) - X_l(k)|}{|X_0(k) - X_l(k)| + \rho \max_l \max_k |X_0(k) - X_l(k)|}, & X_0(k) - X_l(k) \neq 0 \\ 1, & X_0(k) - X_l(k) = 0 \end{cases} \quad (10)$$

式中: ρ 为分辨系数, $\rho \in (0, 1)$, 这里取 $\rho=0.8$; \min_k 为当 k 取固定值时, $|X_0(k) - X_l(k)|$ 取最小值; \min_l 为当 l 取固定值时, $\min_k |X_0(k) - X_l(k)|$ 取最小值; \max_k 为当 k 取固定值时, $|X_0(k) - X_l(k)|$ 取最大值; \max_l 为当 l 取固定值时, $\max_k |X_0(k) - X_l(k)|$ 取最大值;

Step 3: 计算各工艺参数与各机架轧制力的关系, 关联度越大证明对应的工艺参数对机架轧制力的影响越大。根据以上步骤, 结合实验数据, 得出影响轧制力的工艺参数的关联度如表 2 和表 3 所示(以第 1 和 4 机架轧制力为例)。对于其他 4 个机架的轧制力预测, 采用同样的方法进行 BP 神经网络的建立和预测, 采用灰色关联度确定输入变量, 应用试凑法确定网络结构, 然后分析检验数据和实际数据的相对关系, 最后分析轧制力预测结果是否符合工业生产要求。

由表 2 和表 3 可以得出: 与第 1 机架轧制力相关的工艺参数中, 荒管壁厚和荒管重量关联度相对较低。与第 4 机架轧制力相关的工艺参数中, 荒管

表 2 第 1 机架轧制力输入变量关联度

Table 2 Correlation degree of rolling force input variables for the first stand

序号	变量	关联度
1	第 1 机架的轧制速度	0.8762
2	成品外径	0.7984
3	成品壁厚	0.7846
4	轧件出口长度	0.8147
5	芯棒直径	0.8239
6	减径率	0.8918
7	减壁率	0.8872
8	延伸系数	0.8456
9	荒管外径	0.8212
10	荒管壁厚	0.6832
11	荒管重量	0.5487

重量和荒管外径关联度相对较低。同样, 计算了其他机架的轧制力和相关的工艺参数的关联度, 每一机架的轧制力和相关的工艺参数的关联度有很大的不同。例如, 在第 1 机架中荒管外径的关联度很大, 而在第 4 机架中很小, 可以忽略不计。相反, 荒管壁厚与第 4 机架轧制力关联度大, 与第 1 机架轧制力关联度小。这一结果是由轧制机理决定的, 第 1 机架减径占比较大, 而第 4 机架减壁占比较大。所以, 造成了荒管外径和荒管壁厚在不同机架轧制

表 3 第 4 机架轧制力输入变量关联度
Table 3 Correlation degree of rolling force input variables
for the fourth stand

序号	变量	关联度
1	第 4 机架的轧制速度	0. 8922
2	成品外径	0. 7663
3	成品壁厚	0. 7976
4	轧件出口长度	0. 8147
5	芯棒直径	0. 8239
6	减径率	0. 8774
7	减壁率	0. 9044
8	延伸系数	0. 8686
9	荒管外径	0. 5492
10	荒管壁厚	0. 8432
11	荒管重量	0. 5214

力相关度有较大差别。所以，六机架的 BP 神经网络预测轧制力时计算相关度有重大意义，它决定了 BP 神经网络的输入变量。故最终选定的两个 BP 神经网络均为 9 个工艺参数作为预测轧制力模型的输入变量。第 1 机架轧制力的输入变量为：机架轧制速度、成品外径、成品壁厚、轧件出口长度、芯棒直径、减壁率、减径率、延伸系数和荒管外径。第 4 机架的轧制力的输入变量为：机架轧制速度、成品外径、成品壁厚、轧件出口长度、芯棒直径、减壁率、减径率、延伸系数和荒管壁厚。输出变量为各机架的轧制力。

3.3 BP 神经网络结构

在 BP 神经网络中，最重要的任务之一为确定与隐藏层数和其中神经元数量有关的最优网络结构，通常采用试错法^[14]。在本研究中，通过尝试不同数量的隐层和神经元来获得最佳的网络结构。实验从一个包含 3 个神经元的隐层开始，用相关系数 R 来检验每个网络的性能，目标为最大化相关系数^[15]，从而得到一个泛化效果的网络，本研究尝试了许多不同的网络模型结构，并计算了他们的相关系数。表 4 列出了不同实验中获得的最佳 R 值。

从表 4 可以看出，当预测第 1 机架轧制力时，网络结构为 9-6-5-1 的相关系数最高；当预测第 4 机架轧制力时，网络结构为 9-7-6-1 的相关系数最高。因此，实验确定两个 BP 神经网络的结构和函数如表 5 所示。

3.4 轧制力模型的训练

利用已建好的两个 BP 神经网络分别对第 1 机

表 4 隐层数及节点数与相关系数的关系
Table 4 Relationship between numbers of hidden layers and
nodes and correlation coefficient

神经网络 编号	第 1 隐层 神经元数	第 2 隐层 神经元数	第 1 机架轧制力 相关系数 R		第 4 机架轧制力 相关系数 R	
			训练集	测试集	训练集	测试集
1	3	—	0. 94867	0. 95691	0. 95408	0. 94965
2	4	—	0. 96589	0. 89496	0. 96847	0. 97658
3	6	—	0. 96846	0. 94587	0. 94571	0. 93746
4	7	—	0. 97618	0. 93319	0. 95874	0. 96463
5	9	—	0. 97884	0. 94584	0. 96548	0. 96687
6	11	—	0. 98145	0. 96567	0. 97465	0. 95983
7	12	—	0. 99547	0. 96547	0. 97631	0. 94672
8	13	—	0. 99012	0. 96129	0. 97776	0. 95679
9	14	—	0. 98645	0. 93654	0. 98654	0. 97462
10	15	—	0. 98745	0. 94265	0. 99113	0. 99156
11	16	—	0. 97548	0. 97693	0. 97468	0. 95647
12	3	3	0. 97165	0. 95421	0. 97654	0. 96346
13	4	3	0. 97058	0. 95141	0. 95687	0. 96573
14	5	5	0. 97884	0. 94784	0. 98654	0. 91657
15	5	4	0. 94781	0. 92354	0. 97942	0. 98431
16	5	3	0. 98471	0. 97221	0. 98746	0. 95874
17	6	6	0. 96315	0. 95165	0. 96874	0. 95998
18	6	5	0. 99849	0. 99291	0. 98659	0. 95647
19	6	4	0. 96894	0. 94683	0. 98746	0. 96544
20	6	3	0. 94872	0. 92441	0. 97857	0. 95674
21	7	6	0. 96398	0. 93618	0. 99541	0. 99125
22	7	5	0. 95416	0. 93851	0. 98568	0. 97651
23	7	3	0. 94664	0. 93278	0. 98016	0. 95415
24	9	6	0. 94513	0. 94687	0. 96487	0. 96644
25	9	4	0. 94547	0. 93994	0. 96333	0. 96108

表 5 两个 BP 神经网络的结构和函数
Table 5 Structures and functions of two BP neural networks

BP 神经网络	轧制力预测网络	
	第 1 机架	第 4 机架
隐层数	2	2
输入层神经元数	9	9
输出层神经元数	1	1
第 1 隐层单元数	6	7
第 2 隐层单元数	5	6
输入层与第 1 隐层之间的传递函数	Tansig	Tansig
第 1 隐层与第 2 隐层之间的传递函数	Tansig	Tansig
第 2 隐层之间与输出层之间的传递函数	Purline	Purline
训练函数	Trainlm	Trainlm

架和第 4 机架轧制力进行预测。先采用改进的初始值设置方法对初始值进行取值。本实验从样本随机选取 180 组作为训练样本, 20 组作为测试样本, 检验数据是在网络训练结束、在连轧无缝钢管的各生产线上重新随机采集, 用来检验网络的预测精度是否符合工业生产要求, 分别对 20 组检验数据进行预测, 并且和真实数据进行比较, 如图 1 和图 2 所示。




图 1 第 1 机架轧制力实际值与预测值对比折线图
Fig. 1 Broken line chart of comparison between actual and predicted rolling force values for the first stand

比较 BP 神经网络轧制力预测模型的预测值和实际值, 可以看出: 在绝大多数样本序列下轧制力




图 2 第 4 机架轧制力实际值与预测值对比折线图
Fig. 2 Broken line chart of comparison between actual and predicted rolling force values for the fourth stand

的预测值与实际值十分接近, 为了验证是否符合工业现场的实际需要, 还需要对模型进行进一步的分析验证。

4 模型的分析 and 讨论

本实验建立的神经网络, 有 180 组训练数据和 20 组测试数据对网络进行训练和测试。绘制建立的 BP 神经网络模型的第 1 机架轧制力和第 4 机架轧制力的性能曲线分别如图 3 和图 4 所示。分析图 3 和图 4 可以直观得出: 所建立的网络具有较好的泛化能力。





图 3 训练集样本的性能曲线
(a) 第 1 机架轧制力 (b) 第 4 机架轧制力

Fig. 3 Performance curves for training set samples
(a) Rolling force of the first stand (b) Rolling force of the fourth stand

为了进一步分析神经网络的预测轧制力的总体性能, 计算和比较了 20 组检验集数据轧制力的实际值和预测值的相对误差大小, 分别如图 5 和图 6 所示。

由图 5 和图 6 可知, BP 神经网络对第 1 机架轧

制力预测最大相对误差为 2.46%, 平均相对误差为 1.53%, 最小相对误差为 0.16%; 对第 4 机架轧制力预测的最大相对误差为 2.9%, 平均相对误差为 1.46%, 最小相对误差为 1.56%。全部相对误差均




图 4 测试集样本的性能曲线
(a) 第 1 机架轧制力 (b) 第 4 机架轧制力
Fig. 4 Performance curves for test set samples
(a) Rolling force of the first stand (b) Rolling force of the fourth stand




图 5 检验集第 1 机架轧制力相对误差图
Fig. 5 Relative error diagram of rolling force for the first stand in inspection set




图 6 检验集第 4 机架轧制力相对误差
Fig. 6 Relative error diagram of rolling force for the fourth stand in inspection set

在 3% 之内，故所建立的 BP 神经网络轧制力预测模型预测精度较高，能满足现场生产对模型精度的要求。应用同样的方法对其他 4 机架进行预测，得到的相对误差均在 4% 之内。

5 结语

利用改进的 BP 人工神经网络并采集三辊六机架连轧的生产数据进行第 1 机架和第 4 机架轧制力的预测。从两个模型对轧制力预测结果的分析，预测的精度较高，可以满足工业现场的实际需求。经过同样的方法训练和分析其他 4 机架的轧制力预测结果也符合工业现场的实际需要。表明改进的 BP 神经网络对无缝钢管连轧中各机架的轧制力精确预

测具有一定的可行性和实用性。

改进的 BP 神经网络对网络进行训练的过程中，网络具有记忆和自学习功能，会自动寻找连接输入参数和输出参数的最优网络权值和阈值，从而使网络预报达到最优。并且借助 MATLAB 神经网络的工具箱建立的网络预测，只需简单的编程且容易实现，有很大的发展前景。基于改进的 BP 神经网络连轧轧制力的预测模型收敛速度和预报精度均较高，所以，下一步研究 BP 神经网络和智能算法的结合在无缝钢管轧制中的应用。

参考文献：

[1] 肖成. 无缝钢管连轧过程建模与轧制规程优化 [D]. 长沙：中南大学，2014.

- Xiao C. Modeling and Rolling Schedule Optimization of Seamless Steel Tube Rolling Process [D]. Changsha: Central South University, 2014.
- [2] 汤涛. 无缝钢管连轧过程数值模拟及参数优化 [D]. 衡阳: 南华大学, 2013.
- Tang T. Numerical Simulation and Parameter Optimize for Tandem Rolling Process of Seamless Steel Tube [D]. Hengyang: University of South China, 2013.
- [3] 孟代江. 人工神经网络技术及其应用 [J]. 电子技术与软件工程, 2016, (23): 16.
- Meng D J. Artificial neural network technology and its application [J]. Electronic Technology & Software Engineering, 2016, (23): 16.
- [4] 杨源杰, 黄道. 人工神经网络算法研究及应用 [J]. 华东理工大学学报: 自然科学版, 2002, 28 (5): 551-554.
- Yang Y J, Huang D. Research and application of artificial neural networks [J]. Journal of East China University of Science and Technology: Natural Science Edition, 2002, 28 (5): 551-554.
- [5] 刘翰培, 汪宇轩, 王亚琴, 等. 深度神经网络轧制力建模及其并行优化研究 [J/OL]. 控制工程: 1-8 [2021-03-24]. DOI: 10.14107/j.cnki.kzgc.20200277.
- Liu H P, Wang Y X, Wang Y Q, et al. Research on rolling force modeling and parallel optimization of deep neural network [J/OL]. Control Engineering of China: 1-8 [2021-03-24]. DOI: 10.14107/j.cnki.kzgc.20200277.
- [6] 马威, 李维刚, 赵云涛, 等. 基于深度学习的热轧轧制力预测 [J]. 钢铁研究学报, 2019, 31 (9): 805-815.
- Ma W, Li W G, Zhao Y T, et al. Prediction of hot-rolled roll force based on deep learning [J]. Journal of Iron and Steel Research, 2019, 31 (9): 805-815.
- [7] Bagheripour M, Bisadi H. Application of artificial neural networks for the prediction of roll force and roll torque in hot strip rolling process [J]. Applied Mathematical Modelling, 2013, 37 (7): 4593-4607.
- [8] 陈鑫, 朱明杰, 吴敏, 等. 结合机理计算与神经网络预测的无缝钢管轧制力建模 [J]. 冶金自动化, 2015, 39 (4): 32-37.
- Chen X, Zhu M J, Wu M, et al. Rolling force modeling for seamless steel pipe combining mechanism model and neural network prediction [J]. Metallurgical Industry Automation, 2015, 39 (4): 32-37.
- [9] 宋勇, 苏岚, 荆丰伟, 等. 热轧带钢轧制力模型自学习算法优化 [J]. 北京科技大学学报, 2010, 32 (6): 802-806.
- Song Y, Su L, Jing F W, et al. Self-learning algorithm optimization for the rolling force model of hot strips [J]. Journal of University of Science and Technology Beijing, 2010, 32 (6): 802-806.
- [10] 周富强, 曹建国, 张杰, 等. 基于神经网络的冷连轧机轧制力预报模型 [J]. 中南大学学报: 自然科学版, 2006, 37 (6): 1155-1160.
- Zhou F Q, Cao J G, Zhang J, et al. Prediction model of rolling force for tandem cold rolling mill based on neural networks and mathematical models [J]. Journal of Central South University: Science and Technology, 2006, 37 (6): 1155-1160.
- [11] 郭立伟, 杨荃, 郭磊. 冷连轧过程控制轧制力模型综合参数自适应 [J]. 北京科技大学学报, 2007, 29 (4): 413-416.
- Guo L W, Yang Q, Guo L. Comprehensive parameters self-adapting for a rolling force model of tandem cold rolling process control [J]. Journal of University of Science and Technology Beijing, 2007, 29 (4): 413-416.
- [12] 何飞, 石露露, 黎敏, 等. 基于多模态和加权支持向量机的热轧轧制力智能预报 [J]. 工程科学学报, 2015, 37 (4): 517-521.
- He F, Shi L L, Li M, et al. Intelligent prediction of rolling forces in hot rolling based on a multi-modal and weighted support vector machine [J]. Chinese Journal of Engineering, 2015, 37 (4): 517-521.
- [13] 曹建国, 张杰, 张少军. 轧钢设备及自动控制 [M]. 北京: 化学工业出版社, 2010.
- Cao J G, Zhang J, Zhang S J. Rolling Equipment and Automatic Control [M]. Beijing: Chemical Industry Press, 2010.
- [14] 胡贤磊, 王昭东, 于解民, 等. 结合模型自学习的 BP 神经网络的轧制力预报 [J]. 东北大学学报: 自然科学版, 2002, 23 (11): 1089-1092.
- Hu X L, Wang Z D, Yu J M, et al. Prediction of rolling load by BP neural networks integrating with self-adaption of traditional model [J]. Journal of Northeastern University: Natural Science, 2002, 23 (11): 1089-1092.
- [15] 朱其萍, 徐红玉, 王晓强, 等. 基于 PSO-BP 的超声滚挤压轴承套圈表面加工硬化程度预测 [J]. 锻压技术, 2021, 46 (11): 190-196.
- Zhu Q P, Xu H Y, Wang X Q, et al. Prediction on degree of work hardening for surface of bearing ring by ultrasonic rolling extrusion based on PSO-BP [J]. Forging & Stamping Technology, 2021, 46 (11): 190-196.

更正

《锻压技术》杂志 2021 年第 46 卷第 2 期第 173 页,《温锻压力机肘杆机构的自适应粒子群算法优化》一文中,将第二单位“上海通用东岳电力总成有限公司”修改为“上汽通用东岳动力总成有限公司”。

《锻压技术》编辑部