

融合工业大数据的热轧厚板轧制力模型研究

章顺虎^a, 姜兴睿^a, 尤凤翔^b, 李寅雪^a

(苏州大学 a. 沙钢钢铁学院; b. 机电工程学院, 江苏 苏州 215021)

摘要: **目的** 针对传统解法建立的轧制力模型精度不足的问题, 建立一个轧制力整合模型。**方法** 对工业大数据进行归一化处理, 系统优化了神经网络模型的结构形式, 建立了一个神经网络模型。在此基础上, 利用误差间距补偿的方法实现神经网络模型与已有理论模型的有机融合, 从而最终获得了轧制力的整合模型。**结果** 通过与已有的轧制力模型进行对比, 表明所提出整合模型预测结果与实测值吻合更好, 其中轧制力误差为-4.09%, 轧制力矩误差为-4.01%。**结论** 该模型整合方法能够实现理论模型与神经网络模型的优势互补, 从而给出物理概念与预测精度均可靠的计算结果。

关键词: 大数据; 神经网络; 误差补偿; 轧制力模型

DOI: 10.3969/j.issn.1674-6457.2020.02.002

中图分类号: TG331 **文献标识码:** A **文章编号:** 1674-6457(2020)02-0008-07

Investigation on the Model of Rolling Force by Integrating Industrial Big Data

ZHANG Shun-hu^a, JIANG Xing-rui^a, YOU Feng-xiang^b, LI Yin-xue^a

(a. Shagang School of Iron and Steel; b. School of Mechanical and Electrical Engineering, Soochow University, Suzhou 215021, China)

ABSTRACT: The paper aims to establish an integrated model of rolling force to solve the problem of low precision of rolling force model established in the traditional analytical method. In the paper, all the industrial big data were normalized; and the structure of the neural network model was optimized and a neural network model was established. On this basis, the neural network model was organically integrated with the existed theoretical model through the compensation of error space, and thus obtaining integrated model of rolling force. The comparison with the existed rolling form model showed that better agreement was found between the predicted results of the integrated model and the measured values. In which, the rolling force error was -4.09%, and the rolling torque error was -4.01%. The method of integrating the two models can achieve mutual complementation of theoretical model and neural network model, to provide the calculated results with definite concept and high prediction simultaneously.

KEY WORDS: big data; neural network; error compensation; rolling force model

在轧制生产中, 轧制力是过程控制最为重要的工艺参数。精准的轧制力预测是保证板带材尺寸精度与产品质量的前提条件。预测轧制力的方法主要有理论解析、有限元模拟、人工神经网络预测等几种方法。

早在 1954 年, Sims^[1]就曾在奥罗万方程的基础上提出了一种预测轧制力的解析模型, 并导出了轧件前、后滑区上的平均单位压力公式。该模型应用广泛, 结构简单, 但由于采用了较多简化, 因而预测精度不高。

收稿日期: 2020-01-30

基金项目: 国家自然科学基金(U1960105, 51504156); 江苏省优秀青年基金(BK20180095); 苏州市重点产业技术创新项目-前瞻性应用研究(SYG201806); 华中科技大学材料成形与模具技术国家重点实验室(P2019-015)

作者简介: 章顺虎(1986—), 男, 博士, 副教授, 主要研究方向为轧制理论、工艺及控制。

1973 年,小林史郎^[2]提出了一种求解三维轧制总功率泛函的积分框架,但碍于被积函数的非线性,仅通过计算机获得了数值结果。随后,Kato 等^[3]在 1980 年也提出了一个加权速度场,但同样没能获得解析解。Freshwater^[4]在经典平轧理论的基础上,提出了均匀变形和非均匀变形条件下轧制力的简化计算公式。2012 年,赵德文等^[5]率先提出采用应用应变矢量内积法和共线矢量内积法分析简化的二维流函数,获得了轧制力及轧制力矩的解析模型。此后,章顺虎等^[6]提出将轧制变形渗透率引入厚板轧制过程,并对速度场进行了修正,获得了更为精确的结果,最近,又根据厚板轧制特性提出了厚板轧制的二维椭圆形速度场^[7],成功获得了轧制力能参数的解析解。以上依赖传统解法获得的模型,其优势在于可以提供各种参数的显示表达式,直观反映各种物理量的函数制约关系。然而,由于在对轧制过程分析时不得不采用多个假设或简化,预测精度存在较大偏差,难以满足高精度的生产控制需要。

随着人工神经网络(ANN)和大数据技术的发展,利用二者互补预测轧制力成为未来的一个方向。人工神经网络的优势在于无论多么复杂的轧制工艺,只要有足够多的数据样本,就可以建立神经网络来进行预测^[8]。为了解决传统方法预测连轧机组中第一组的轧制力存在较大误差的问题,Duckman 与 Yongsug^[9]训练了一个神经网络来预测第一组轧制力,该模型对轧制力的预测效果较好,减小了带钢前端的厚度误差。Dixit 与 Chandra^[10]使用了 BP 神经网络对轧制力和轧制力矩的上下界进行了预测,发现模型训练集和测试集的精度达到一定程度后就不再增加。Son 等^[11]为了提高热轧机轧制力的预测精度,提出融合神经网络和遗传算法的轧制力模型,其后,他们又提出了一种可以用于长期学习和短期学习的在线学习神经网络^[12],结果表明,在线学习神经网络预测的轧制力与实际轧制力非常接近,大大减小了带钢厚度误差。Moussaoui 等^[13]采用了 Matlab 中的贝叶斯证据(Bayesian Evidence)训练函数实现了轧制力的预测,并与传统的经验公式结果进行了对比。结果表明,该方法对实际轧机数据具有较平滑的拟合效果。Ghaisari 等^[14]开发了一种基于人工神经网络的智能间接检测方法,实现了对产品力学性能的监测。该智能系统的输入项包括各个生产阶段的多种参数,可以预测屈服强度、极限抗拉强度和伸长率等性能。Bagheripoor 与 Bisadi^[15]评估了具有不同隐含层结构的神经网络,优化出了能够准确预测轧制力的神经网络模型。Guo 等^[16]建立了有限元与人工神经网络相结合的镁合金板热轧轧制力预测模型,并用有限元模拟对预测模型进行了综合验证。所建立的神经网络模型适用于镁合金板热轧过程的在线控制和轧制规程优

化。何亚元^[17]使用数学模型和 BP 神经网络相结合的方法构建了 CSP 生产线轧制力预测模型。尽管如此,已有关于神经网络预测轧制力的研究由于数据规模不大,因而泛化能力差,并且这些模型都是黑箱模型,无法呈现输入-输出参量的函数映射关系,很难被生产现场所采用。

为了获得可靠实用的轧制力模型,文中利用工业大数据进行神经网络建模,并利用其结果对前期建立的理论模型进行误差补偿,获得二者相互补充的整合模型。通过与实测值进行对比,揭示理论模型、神经网络模型以及整合模型的精度情况。

1 已有理论模型

笔者前期提出了描述厚板轧制的椭圆速度场,并以比塑性功率取代法获得了该速度场上轧制能率的解析式^[7]:

$$\Phi = 4.731\sigma_s U \cdot \ln \eta + \frac{2kU\Delta h}{l} + 4mkb \left[v_R R(\theta - 2a_n) + \frac{UR}{bh_m} \ln \frac{\tan^2(\frac{\pi}{4} + \frac{a_n}{2})}{\tan(\frac{\pi}{4} + \frac{\theta}{2})} \right] \quad (1)$$

式中: Φ 为轧制总功率; σ_s 为屈服应力, η 为轧件入口厚度与出口厚度的比值; m 为摩擦因数; k 为剪切屈服强度; l 为变形区长度; Δh 为压下量; b 为板宽; v_R 为轧辊转速; R 为轧辊半径, θ 为变形区所占轧辊角度; a_n 为中性角; h_m 为轧件平均厚度; U 为变形区秒流量。

通过式(1),可按式(2)分别计算轧制力矩、轧制力以及应力状态系数:

$$M_{\min} = \frac{R}{2v_R} \Phi_{\min}, F_{\min} = \frac{M_{\min}}{\chi \sqrt{2R\Delta h}}, n_{\sigma} = \frac{F_{\min}}{4blk} \quad (2)$$

式中:力臂参数 χ 可以参考文献[18],一般对于热轧大取 0.5,冷轧取 0.45。

该模型已成功用于轧制力与轧制力矩的预测,然而,由于推导过程中采用了不少假定和简化,其预测精度还不能控制在 10%以下,尚有提升的空间。

2 基于大数据的神经网络建模

2.1 样本数据预处理

从实际生产数据中选取了 1213 组数据用来训练神经网络,所有数据均来自国内某厂的 Q345 钢的实际轧制数据。采用 Matlab 软件构建 BP 神经网络:输入层包括 5 个参量,依次为板厚 h_0 、压下率 r 、温度 T 、轧辊线速度 v_R 以及板宽 b ,输出层为轧制力 P 与轧制力矩 M 。该网络的结构如图 1 所示。

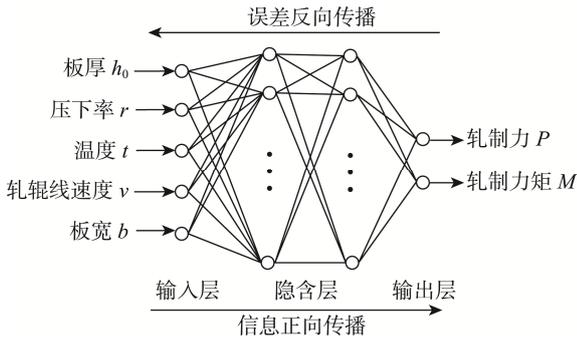


图1 BP神经网络结构
Fig.1 Structure of BP neural network

所有输入的数据被分为训练集 (train set)、验证集 (validation set) 以及测试集 (test set), 每个数据集的占比为 0.7 0.15 0.15。训练集用于模型拟合, 验证集用于初步评估模型的能力并调整模型的参数, 测试集用于最终评估模型的泛化能力。

在训练之前, 需要将数据进行归一化处理。所有输入和输出数据被缩小或放大到 [0, 1] 这个范围, 以符合 S 形函数的值域范围。这一步骤保证了所有参量都具有相同的重要程度, 同时可以减少网络的训练时间。文中采用的归一化的算法为:

$$x_i = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (3)$$

式中: x_i 表示经过归一化处理后的数据; x 为原始数据; x_{\min} 为所有 x 的最小值; x_{\max} 为所有 x 的最大值。

神经网络训练迭代次数最大值设为 1000, 训练目标为 1×10^{-3} , 学习率为 0.01。采用的训练函数是 Matlab 工具箱中的拟牛顿法 (BFGS Quasi-Newton)。

2.2 神经网络模型建立与分析

神经网络模型需要确定神经网络的结构形式, 包括确定网络层数和各层网络节点数, 主要是确定隐含层及其神经元的数量。网络的好坏可以用相关系数 R (correlation coefficient) 来评判, 它的平方为:

$$R^2 = \frac{(m \sum_{i=1}^m \hat{y}_i \cdot y_i - \sum_{i=1}^m \hat{y}_i \cdot \sum_{i=1}^m y_i)^2}{\left[m \sum_{i=1}^m \hat{y}_i^2 - (\sum_{i=1}^m \hat{y}_i)^2 \right] \left[m \sum_{i=1}^m y_i^2 - (\sum_{i=1}^m y_i)^2 \right]} \quad (4)$$

在 Matlab 中, 可以直接在神经网络结果中查看每一个集的 R 值。文中从单隐含层开始, 通过逐步增长法寻找最高 R 值的神经元组合。通过不断测试, 最终确定第一隐含层神经元个数为 7, 第二层隐含层神经元个数也为 7。该模型训练迭代次数为 121, 该组合的每个集合与总体的 R 值如图 2 所示。

由图 2 可见, 此时训练集、验证集、测试集上的 R 值以及总的 R 值均很高, 表明神经网络模型对实际数据具有很高的逼近程度。另外, 获得了该模型的误差分布直方图, 如图 3 所示。

图 3 中, 横轴为目标值与输出值的差值, 即误差; 纵轴为 1213 组数据在各误差程度区间的分布数量。可以看出, 大部分数据的误差都集中在一个较小的范围, 误差较大的数据很少。综上所述, 文中建立的神经网络模型的预测精度很高, 可以实现轧制力、轧制力矩的精确预测。

为评估模型的泛化能力, 文中选取了另外一组轧制数据对已构建的神经网络模型进行了分析。选取的轧制数据来自国内某厂现场数据, 连铸坯尺寸为 $320 \text{ mm} \times 3470 \text{ mm} \times 2000 \text{ mm}$, 轧辊直径为 1120 mm。经过第一道次的整形轧制后, 厚度为 299.36 mm, 然后转钢 90° 进行展宽轧制。表 1 为第 2 道次至第 6 道次的轧制数据。

根据式 (1) 与式 (2), 可以通过理论模型计算出表 1 中的理论轧制力 P_T 与轧制力矩 M_T , 其中采用的变形抗力模型见式 (5)。

$$\sigma_s = 3583.195 e^{-2.233 \times 10^{-3} T} \cdot \varepsilon^{0.424 37} \cdot \dot{\varepsilon}^{-0.3486 \times 10^{-3} T + 0.463 39} \quad (5)$$

$$T = t + 273$$

式中: ε 为等效应变; $\dot{\varepsilon}$ 为等效应变速率; t 为轧制温度; T 为热力学温度。

表 1 实测轧制参数
Tab.1 Measured rolling parameters

道次	轧辊线速度 / (m·s ⁻¹)	温度 / °C	入口板厚 h_0 / mm	出口板厚 h_1 / mm	压下率 r / %	板宽 / mm	实测轧制力 P_M / kN	实测轧制力矩 M_M / (kN·m)
2	-1.64	1134	299.36	272.02	9.13	3472.03	43 607	2640
3	1.66	1130	272.02	245.37	9.79	3474.37	44 006	2694
4	-1.68	1128	245.37	218.80	10.82	3476.56	43 172	2665
5	1.82	1126	218.80	193.87	11.39	3478.65	42 269	2430
6	-1.97	1123	193.87	173.17	10.67	3480.51	39 061	2101

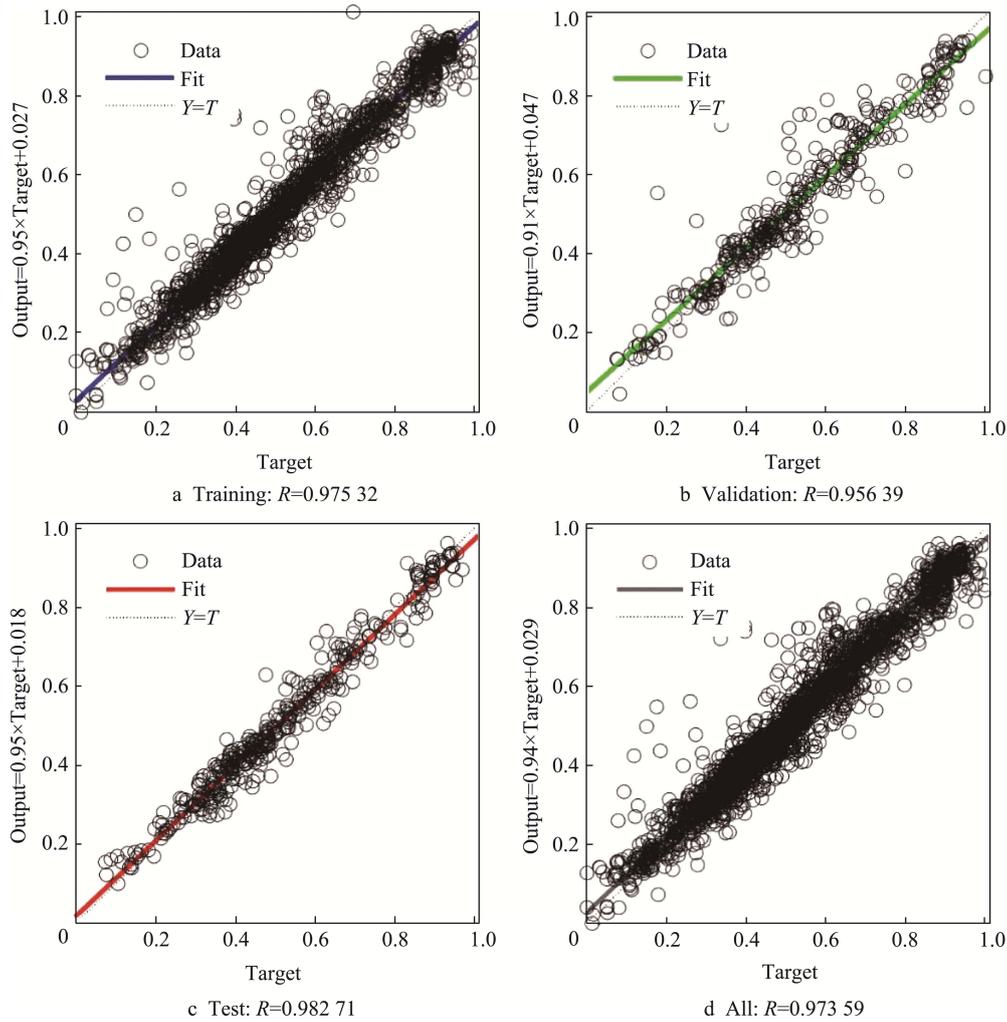


图 2 神经网络各数据集的预测精度

Fig.2 Prediction accuracy of each data set of the neural network

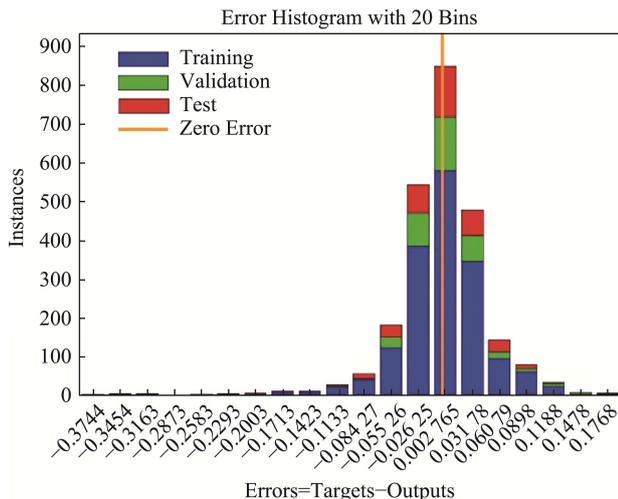


图 3 误差分布直方图

Fig.3 Histogram of error distribution

同时，将数据代入神经网络模型中进行计算，获得了神经网络预测轧制力 P_{ANN} 与轧制力矩 M_{ANN} 。以上两种模型的计算结果如表 2 所示，其中 ε_{P_T} 表达式

为 $(P_T - P_M)/P_M$ ； $\varepsilon_{P_{ANN}}$ 表达式为 $(P_{ANN} - P_M)/P_M$ 。

如表 2 所示，理论模型和神经网络模型都可以给出较为合理的结果。其中，理论轧制力平均误差为 $\bar{\varepsilon}_{P_T} = -10.77\%$ ，轧制力矩平均误差为 $\bar{\varepsilon}_{M_T} = -10.25\%$ ；神经网络轧制力平均误差 $\bar{\varepsilon}_{P_{ANN}} = -4.17\%$ ，轧制力矩平均误差为 $\bar{\varepsilon}_{M_{ANN}} = -4.12\%$ 。可以看出，神经网络预测值相对于理论计算值更加精确。

2.3 整合模型的构建与讨论

由 2.2 节分析可知，虽然神经网络模型的精度高于理论模型，但神经网络模型无法呈现输入-输出参数间的函数制约关系，因此，文中提出利用神经网络模型对理论模型进行修正，融合构造出优势互补的整合模型。该模型融合的基本思想是以理论模型预测轧制力的主值，以大数据模型预测轧制力的偏差，按照偏差补偿的原则把两者整合起来，作为轧制力的预测值，即：

$$P = P_T + \delta P_d = P_T + \delta P_{ANN} - \delta P_T \quad (6)$$

表2 理论与神经网络对轧制力、轧制力矩的预测值与实测值误差
Tab.2 Rolling force and rolling torque between theoretical model and neural network prediction and the errors with measured data

理论预测值				神经网络预测值			
轧制力 P_T /kN	轧制力矩 M_T /(kN·m)	轧制力相对 误差 ε_{P_T} /%	轧制力矩相对 误差 ε_{M_T} /%	轧制力 P_{ANN} /kN	轧制力矩 M_{ANN} /(kN·m)	轧制力相对 误差 $\varepsilon_{P_{ANN}}$ /%	轧制力矩相对 误差 $\varepsilon_{M_{ANN}}$ /%
38 170	2347	-12.47	-11.10	43 350	2618	-0.59	-0.82
38 544	2354	-12.41	-12.64	41 849	2554	-4.90	-5.20
39 182	2390	-9.24	-10.33	41 750	2483	-3.29	-6.84
38 516	2276	-8.88	-6.36	39 994	2367	-5.38	-2.58
34 824	1874	-10.85	-10.81	36 439	1993	-6.71	-5.15

式中： $\delta P_{ANN} = P_M - P_{ANN}$ ， $\delta P_T = P_M - P_T$ ，称为轧制力平均误差； δP_d 为理论模型与神经网络模型误差的间距； δM_T 与 δM_{ANN} 为神经网络与理论轧制力矩平均误差； δM_d 为理论与神经网络轧制力矩误差的间距。这种模型融合方法称为加法补偿，原理示意图如图4所示。

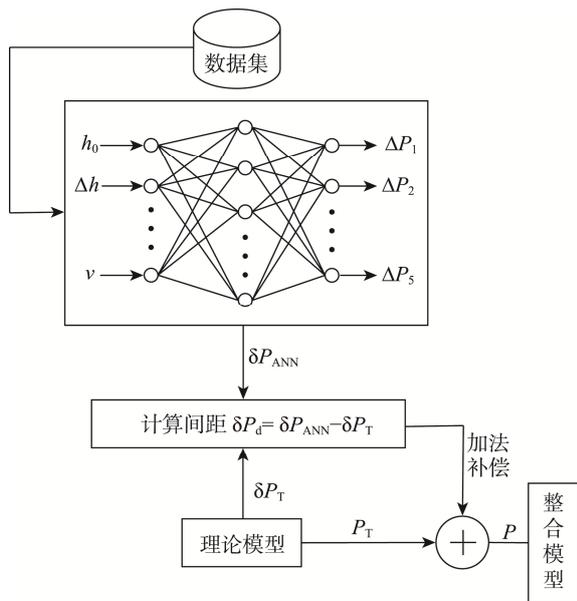


图4 神经网络误差补偿原理

Fig.4 Schematic diagram of neural network error compensation principle

根据式(2)，可得误差补偿后的轧制力矩与轧制力表达式见式(7)。

$$\begin{cases} M = M_{\min} + \delta M_d = \frac{R}{2v_R} \Phi_{\min} + \delta M_d \\ P = P_{\min} + \delta P_d = \frac{M_{\min}}{\chi \sqrt{2R\Delta h}} + \delta P_d \end{cases} \quad (7)$$

根据表1的轧制参数，计算可得 δP_{ANN} 的均值为-1747 kN， δP_T 的均值为-4576 kN，故而 $\delta P_d = 2829$ kN，同理可得 $\delta M_d = 155$ kN·m，因此，经过整合后的轧制力、轧制力矩以及其误差如表3所示。

表3 整合模型预测轧制力与轧制力矩
Tab.3 Prediction of rolling force and rolling torque of the integrated model

整合模型预测的轧制力 P /kN	整合模型预测的轧制力相对 误差 ε_P /%	整合模型预测的轧制力矩 M /(kN·m)	整合模型预测的轧制力矩相对 误差 ε_M /%
40 999	-5.98	2502	-5.22
41 373	-5.98	2509	-6.88
42 011	-2.69	2545	-4.51
41 345	-2.19	2431	0.02
37 652	-3.61	2030	-3.42

整合模型预测的轧制力平均误差为 $\bar{\varepsilon}_P = -4.09\%$ ，轧制力矩平均误差为 $\bar{\varepsilon}_M = -4.01\%$ 。整合模型的误差均小于理论模型和神经网络模型，具有更高的预测精度。

对轧制力与轧制力矩的实测值、理论计算值、神经网络预测值以及整合模型计算值进行对比，如图5和6所示。可以看出，整合模型的轧制力、轧制力矩显著优于理论模型。神经网络预测值在第一道次时较高，但之后下降较快。当道次数大于3时，整合模型更加接近实测值，预测结果更为稳定。

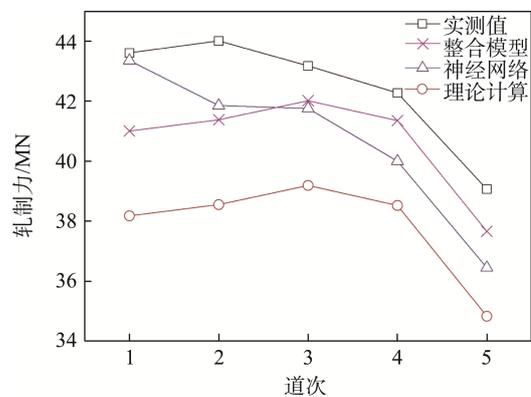


图5 轧制力对比

Fig.5 Comparisons of rolling force

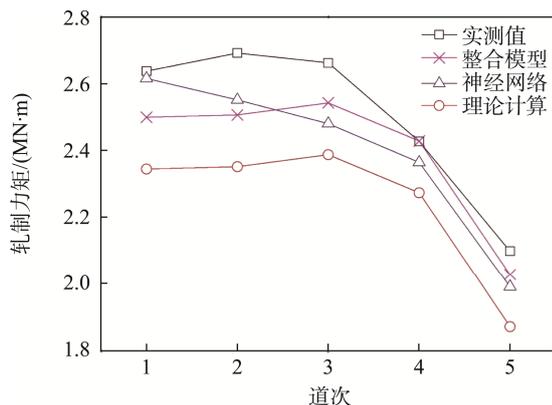


图6 轧制力矩对比

Fig.6 Comparisons of rolling torque

3 结论

1) 对1213组轧制数据进行预处理,选用BP神经网络构建轧制力的预测模型,获得了输入层、隐含层、输出层神经元数以5-7-7-2的组合形式。该神经网络模型的相关系数 R 值为0.973 59,可以精确预测轧制力与轧制力矩。

2) 通过对比理论模型、神经网络模型以及实测值,表明提出的神经网络模型预测的轧制力精度为-4.17%,轧制力矩预测精度为-4.12%,优于理论模型的轧制力预测精度-10.77%和轧制力矩的预测精度-10.25%。

3) 提出了融合两类模型的误差补偿方法,获得了轧制力的整合模型。经计算,该整合模型的轧制力平均误差为-4.09%,轧制力矩平均误差为-4.01%,优于理论模型与神经网络模型的预测值。

参考文献:

[1] SIMS R B. The Calculation of Roll Force and Torque in Hot Rolling Mills[J]. Proceedings of the Institution of Mechanical Engineers, 1954, 168(1): 191—200.

[2] KOBAYASHI Shiro. Analysis of Elastic-plastic Fracture Forms by Matrix Method[J]. Plasticity and Processing, 1973, 153(14): 770—779.

[3] KATO K, OSAKADA K. Finite Element Simulation of Three Dimensional Deformation in Shape Rolling[J]. International Journal for Numerical Methods in Engineering, 1990, 30: 1431—1440.

[4] FRESHWATER I J. Simplified Theories of Flat Rolling-I the Calculation of Roll Pressure, Roll Force and Roll Torque[J]. International Journal of Mechanical Sciences, 1996, 38(6): 633—648.

[5] ZHAO De-wen, ZHANG Shun-hu, LI Can-ming, et al. Rolling with Simplified Stream Function Velocity and Strain Rate Vector Inner Product[J]. Journal of Iron and

Steel Research, International, 2012, 19(3): 10—24.

[6] ZHANG Shun-hu, DENG Lei, ZHANG Qin-yu, et al. Modeling of Rolling Force of Ultra-heavy Plate Considering the Influence of Deformation Penetration Rate[J]. International Journal of Mechanical Sciences, 2019, 159: 373—381.

[7] 姜兴睿, 章顺虎, 王春举, 等. 积分中值屈服准则解析厚板椭圆轧制速度场[J]. 哈尔滨工业大学学报, 2020, 52(5): 1—5(in press).

JIANG Xing-rui, ZHANG Shun-hu, WANG Chun-ju, et al. Analysis of Elliptical Velocity Field in Heavy Plate Rolling by Integral Mean Value Yield Criterion[J]. Journal of Harbin Institute of Technology, 2020, 52(5): 1—5 (in press).

[8] 刘相华, 赵启林, 黄贞益. 人工智能在轧制领域中的应用进展[J]. 轧钢, 2017(4): 7—11.

LIU Xiang-hua, ZHAO Qi-lin, HUANG Zhen-yi. Prospect of Artificial Intelligent Application in Rolling, Steel Rolling, 2017(4): 7—11.

[9] DUCKMAN L, YONGSUG L. Application of Neural-network for Improving Accuracy of Roll-force Model in Hot-rolling Mill[J]. Control Engineering Practice, 2002, 10(4): 473—478.

[10] DIXIT U S, CHANDRA S. A Neural Network Based Methodology for the Prediction of Roll Force and Roll Torque in Fuzzy Form for Cold Flat Rolling Process[J]. The International Journal of Advanced Manufacturing Technology, 2003, 22(11/12): 883—889.

[11] SON J S, LEE D M, KIM I S, et al. A Study on Genetic Algorithm to Select Architecture of a Optimal Neural Network in the Hot Rolling Process[J]. Journal of Materials Processing Technology, 2004, 153: 643—648.

[12] SON J S, LEE D M, KIM I S, et al. A Study on On-line Learning Neural Network for Prediction for Rolling Force in Hot-rolling Mill[J]. Journal of Materials Processing Technology, 2005, 164: 1612—1617.

[13] MOUSSAOUI A, SELAIMIA Y, ABBASSI H A. Hybrid Hot Strip Rolling Force Prediction Using a Bayesian Trained Artificial Neural Network and Analytical Models[J]. American Journal of Applied Sciences, 2006, 3(6): 1885—1889.

[14] GHAISARI J, JANNESARI H, VATANI M. Artificial Neural Network Predictors for Mechanical Properties of Cold Rolling Products[J]. Advances in Engineering Software, 2011, 45(1): 91—99.

[15] BAGHERIPOOR 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, 2003, 37(7): 4593—4607.

- [16] GUO Z Y, SUN J N, DU F S. Application of Finite Element Method and Artificial Neural Networks to Predict the Rolling Force in Hot Rolling of Mg Alloy Plates[J]. Journal of the Southern African Institute of Mining and Metallurgy, 2016, 116(1): 43—48.
- [17] 何亚元, 严翔, 李立新, 等. 基于BP神经网络的CSP生产线轧制力预测模型[J]. 机械工程材料, 2014, 38(10): 79—82.
- HE Ya-yuan, YAN Xiang, LI Li-xin, et al. Prediction Model of Rolling Force of CSP Line Based on BP Neural Network[J]. Materials for Mechanical Engineering, 2014, 38(10): 79—82.
- [18] HARRIS J N, JOHN N. Mechanical Working of Metals: Theory and Practice[M]. Pergamon Press, Oxford, 1983.