

基于深度学习的宽厚板热轧轧制力预测

郭金涛¹, 王 龙^{1,2,3}, 余建波^{1,2,3}, 冀秀梅¹

(1. 上海大学 材料科学与工程学院, 上海 200444; 2. 上海大学 上海市钢铁冶金新技术开发应用重点实验室, 上海 200444;
3. 上海大学 省部共建高品质特殊钢冶金与制备国家重点实验室, 上海 200444)

摘要: 为了提高宽厚板热轧生产过程控制中轧制力的预测精度, 构建了融合 SIMS 模型的深度学习网络模型, 对宽厚板热轧轧制力进行预测研究。利用深度学习框架, 构建了一种基于残差连接的深度学习网络模型, 并融合 SIMS 模型计算值, 通过误差反向传播计算损失函数的梯度, 同时使用 Mini-Batch 与 RMSProp 结合的优化算法对权重参数进行更新优化。利用残差连接引入纯线性的信息携带轨道, 从而创造一条捷径, 将较早的信号重新注入给下游的网络层, 使用早停机制、批标准化等策略抑制模型过拟合现象, 提高模型的预测精度。基于上述建模方法, 针对宽厚板热轧生产线的轧制数据进行了建模实验。结果表明, 以相对误差绝对值小于 5% 在测试集中的占比作为评价指标, 相比于传统 SIMS 模型, 融合 SIMS 模型、基于残差连接的深度学习网络可实现轧制力的高精度预测, 该模型的预测精度平均提升了 21.72%。

关键词: 宽厚板热轧; 轧制力预测; 残差连接; 过程控制; 深度学习; SIMS 模型

DOI: 10.13330/j.issn.1000-3940.2022.07.024

中图分类号: TG335.5⁺1

文献标志码: A

文章编号: 1000-3940 (2022) 07-0167-08

Prediction on rolling force in hot rolling of wide and thick plate based on deep learning

Guo Jintao¹, Wang Long^{1,2,3}, Yu Jianbo^{1,2,3}, Ji Xiumei¹

(1. School of Materials Science and Engineering, Shanghai University, Shanghai 200444, China;
2. Shanghai Key Laboratory of Advanced Ferrometallurgy, Shanghai University, Shanghai 200444, China;
3. State Key Laboratory of Advanced Special Steel, Shanghai University, Shanghai 200444, China)

Abstract: In order to improve the prediction accuracy of rolling force in the hot rolling production process control for wide and thick plate, a deep learning network model integrating SIMS model was constructed to predict the rolling force of wide and thick plate in hot rolling. Then, by using the deep learning framework, a deep learning network model based on residual connection was constructed, which integrated the calculated values of SIMS model, calculated the gradient of loss function through error back propagation, and updated and optimized the weight parameters by using the optimization algorithm combining Mini-Batch and RMSProp. Furthermore, a shortcut was created to inject the earlier signals into the downstream network layers by using the residual connection to introduce a pure linear information carrying track, and the over fitting phenomenon of the model was suppressed by using the early-stopping mechanism and batch normalization and other strategies to improve the prediction accuracy of the model. Based on the above modeling method, the rolling data of wide and thick plate in hot rolling production line was modeled experimentally. The results show that taking the ratio of absolute value for relative error less than 5% in the test set as the evaluation index, compared with the traditional SIMS model, the deep learning network integrating SIMS model based on residual connection can achieve high-precision prediction of rolling force, and the prediction accuracy of the model is improved by an average value of 21.72%.

Key words: hot rolling of wide and thick plate; prediction of rolling force; residual connection; process control; deep learning; SIMS model

热轧是钢铁生产加工过程中不可或缺的重要加

工环节, 它能减少或消除铸造缺陷, 并提高合金的加工性能。轧制力则是热轧过程中的重要工艺参数之一, 轧制力为轧机的设计和轧制工艺的制定提供参考依据^[1-2], 其分布也将直接影响板带的厚度与板形。精确地预报轧制力是热轧过程控制模型的核心问题。目前 SIMS 模型是应用最为广泛的轧制力预测模型之一。但实际轧制环境较为复杂, 轧制过程中各种因素变量之间存在线性、非线性以及耦合

收稿日期: 2021-07-29; 修订日期: 2021-10-19

基金项目: 基于数字化发展的制造业生态构建和路径研究 (2022-XY-100)

作者简介: 郭金涛 (1996-), 男, 硕士研究生

E-mail: kimtao@shu.edu.cn

通信作者: 余建波 (1982-), 男, 博士, 教授

E-mail: jbyu@shu.edu.cn

关系,从而导致 SIMS 模型的预测结果与实际轧制力之间存在偏离^[3],轧制力预测的精度依然不能满足实际工程的应用。

随着人工智能与机器学习的高速发展,神经网络在钢铁生产加工过程中的研究与应用也越来越普遍^[4-6]。窦博^[7]从实测数据中抽取出 700 组数据作为样本集,采用贝叶斯神经网络预测精轧轧制力,其预测精度较加法网络稍有改善。冀秀梅等^[8]采用基于极限学习机的综合神经网络对轧制力进行预报。王秀梅等^[9]运用一种综合网络,通过 BP 神经网络与数学模型相结合的方式对连轧机组的轧制力进行预报,其预报精度较传统数学模型和单独采用 BP 神经网络的预报精度有了较大提高。吕程等^[10]以实测数据为基础,在精轧预设定中采用 BP 神经网络的方法取代传统的轧制力数学模型,对 BP 神经网络输入项和训练样本进行分析,进一步改善了 BP 神经网络的预报精度。

虽然上述研究一定程度上提高了轧制力的预测精度,但是多采用的是浅层网络,对复杂函数问题的拟合程度有限。在大数据时代,工业大数据与机器学习紧密结合,为钢铁生产加工过程中问题的解决提供了新途径^[11-14]。章顺虎等^[15]对工业大数据进行归一化处理,系统地优化了神经网络模型的结构形式,与已有的轧制力模型进行对比得出,所提出的整合模型预测结果与实测值吻合更好。魏立新等^[16]提出一种基于深度学习的多层感知机 (Multi-layer Perceptron, MLP) 轧制力预报模型。马威等^[17]在深度学习的多层感知机 (MLP) 的基础上融入数学模型,实现复杂函数逼近,并提高了轧制力预测的精度。马湧等^[18]利用基于 Keras 深度学习框架下的 BP 神经网络研究了热轧带钢力学性能的预测。Keras 是一个由 Python 编写的开源人工神经网络库, Keras 具有用户友好、模块化、可扩展性等优点,被认为是深度学习最受关注的工具之一。随着深度学习研究以及人工神经网络库的快速发展,深度学习在复杂函数的拟合回归问题上的优势越来越明显。因此,本文利用 Python 深度学习框架 Keras,构建融合了 SIMS 模型并基于残差连接的深度学习网络模型,将深度学习与数学模型结合并综合应用^[19]。残差连接有效地缓解了深度学习过程中的梯度消失和表示瓶颈。并通过误差反向传播计算损失函数的梯度,运用 Mini-Batch 与 RMSProp 相结合的优化算法加快权重参数更新优化,采用了早停机制、批标准化等策略抑制模型的过拟合现象。利用宽厚

板热轧生产线的实际历史数据进行模型的校验。

1 传统数学模型

计算轧制力的传统 SIMS 数学模型为:

$$F = 1.15\sigma_b L Q_p \quad (1)$$

式中: F 为轧制力, kN; σ 为金属变形抗力, MPa; b 为板宽, m; L 为轧辊压扁后变形区的长度, m; Q_p 为应力状态系数。

计算采用达涅利公司提供的数学模型:

$$\sigma = f(\sigma_0, T, \varepsilon, \varepsilon') \quad (2)$$

式中: σ_0 为基准变形抗力,即化学成分、组织状态及变形条件一定时的变形抗力; T 为变形温度; ε 为变形程度; ε' 为变形速率。

该模型仅考虑变形温度、变形程度与变形速率等几个主要影响因素,难以准确描述化学成分波动、残余应变、回复、再结晶等的影响,计算结果与真实轧制力之间存在较大误差。

2 深度学习网络模型

2.1 深度学习

深度学习拥有悠久的发展历史,随着对深度学习研究的深入,深度学习的应用场景丰富,精度也越来越高。目前,深度学习已经被广泛应用于图像识别、语音识别、手写体转录等领域。深度学习基本原理如图 1 所示,其中 X 为输入特征数据集合。深度学习通过一系列网络层进行数据变换、实现输入与目标的映射。通过损失函数衡量深度学习网络预测值与真实目标值之间的距离,利用预测值与真实目标值之间的距离值作为反馈信号对网络神经节

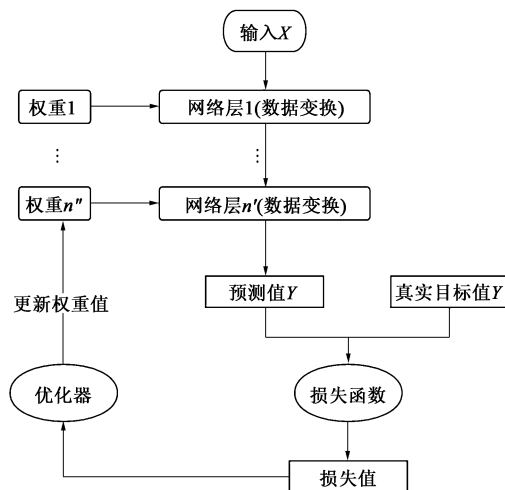


图 1 深度学习基本原理

Fig. 1 Fundamental principle of deep learning

点的权重进行更新与微调, 以降低损失函数的大小, 实现对理想映射的拟合逼近。

2.2 融合了 Mini-Batch 的 RMSProp

深度学习的本质是针对训练集数据计算损失函数, 寻找导致损失值极小的参数。从训练集数据中随机选出一批数据, 这部分数据即为 Mini-Batch 小批量。为了减少 Mini-Batch 损失值, 对 Mini-Batch 进行学习训练, 需要求出各个权重参数的梯度, 根据误差反向传播原理, 其中梯度代表着损失函数值减小最快的方向, 将权重参数沿着梯度方向进行更新。由于更新参数使用数据是随机生成的, 所以该方法又被称为随机梯度下降法^[20] (Stochastic Gradient Descent, SGD), 但随机梯度下降法对学习率较敏感, 学习率偏低将导致学习效率减慢, 学习效果过大将会导致振荡, 从而无法到达极值点。在较平坦的区域, 由于梯度接近于 0 而导致算法误判, 在未到达最小值时, 提前结束了迭代过程。并且该方法容易卡在鞍点的位置。因此学者们在随机梯度下降的基础上引入动量方法, 从而减少振幅, 较快地抵达极值位置。其中 RMSProp 是最常用的一种算法。RMSProp 算法已在实践中被证明是一种实用且

有效的深度学习神经网络的优化算法, 因此在深度学习中得到了广泛的应用。

2.3 批标准化

批标准化 (Batch Normalization, BN) 由 Ioffe S 和 Szegedy C^[21] 在 2015 年提出, 它通过调整和缩放激活来规范化输入层。BN 在训练过程中把每层神经网络任意神经元的输入值进行适应性标准化, 使其分布满足均值为 0、方差为 1 的标准正态分布。这将有助于梯度传播, 而且梯度传播的加快表示学习的收敛速度快, 并极大地加快了训练速度。

2.4 早停机制

早停机制表示在训练中, 监控训练过程损失函数值的变化, 若损失函数的值在一定训练周期内未有效减少, 则停止训练, 抑制过拟合结果的出现。在不同策略下, 训练集与验证集的损失函数均方误差 MSE 变化如图 2 所示, 其中, $MSE = \frac{1}{n} \times$

$$\sum_{i=1}^n (y_i - f(x_i))^2, y_i \text{ 为第 } i \text{ 个样本对应的真实值, } f(x_i) \text{ 为第 } i \text{ 个样本 } x_i \text{ 对应的预测值, } i = 1, 2, 3, \dots, n, n \text{ 为样本总数。}$$

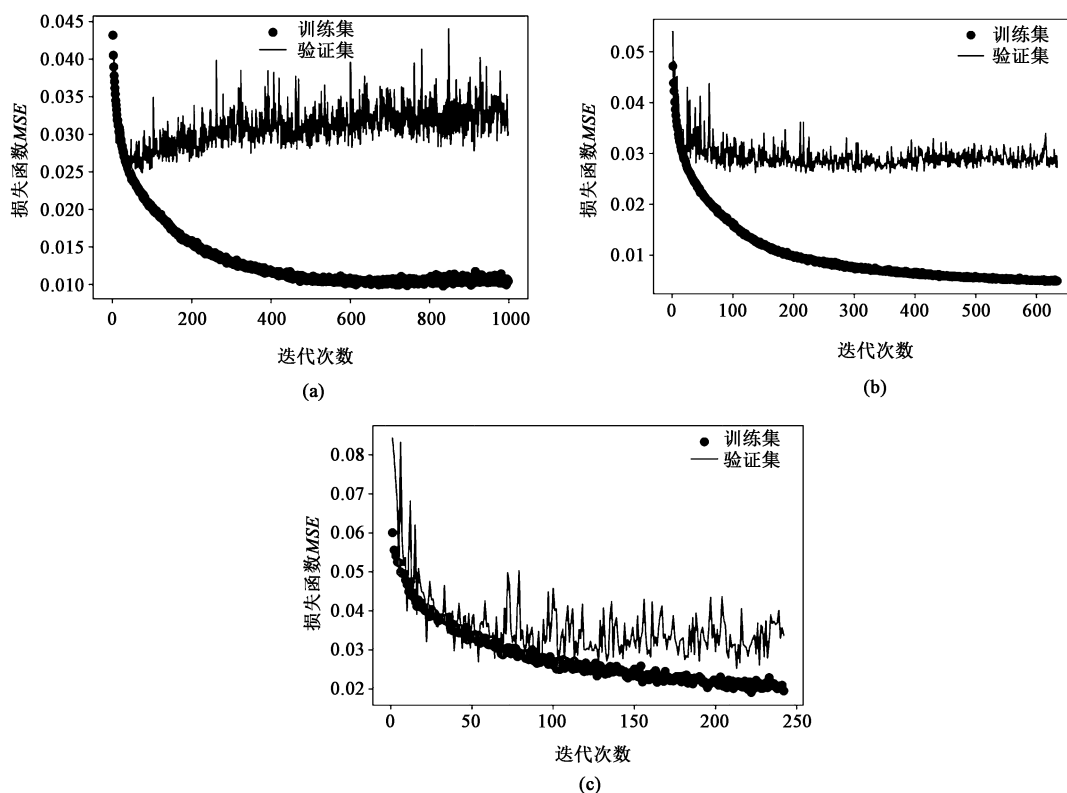


图2 在不同策略下的损失函数 MSE 变化曲线

(a) RMSProp (b) RMSProp, 早停机制 (c) RMSProp, 早停机制, BN

Fig. 2 Loss function MSE change curves under different strategies

(a) RMSProp (b) RMSProp, early-stopping mechanism (c) RMSProp, early-stopping mechanism, BN

由图 2a 可见, 在只有 RMSProp 的策略下, 损失函数 MSE 虽然快速下降, 但在验证集上的损失函数 MSE 呈现 U 形曲线, 模型严重过拟合; 而图 2b 在图 2a 的基础上加入早停机制后, 初步降低了过拟合风险, 验证集上的损失函数 MSE 无上升趋势; 图 2c 在图 2b 的基础上加入 BN 后, 训练集和验证集损失函数 MSE 的下降趋于一致, 未出现模型过拟合现象, 损失函数 MSE 也逐渐收敛至最小值。

2.5 残差连接

残差连接多用于图像识别的深度学习网络中, 最早出现于 ResNet 系列网络^[22], 该方法提高了图像识别的精准度, 在图像识别的深度学习网络中得到了广泛应用。残差连接有效地解决了深度学习过程中的两个关键问题: 表示瓶颈与梯度消失。在深度学习中, 每个连续的表示层均建立在前一层之上, 即某一层只能访问上一层中包含的信息, 并易于出现表示瓶颈。而且反馈信号的一些微弱的信号通过许多层传递, 最终出现丢失的可能并导致最终训练失败, 这就是梯度消失现象。残差连接通过引入一个纯线性的信息携带轨道, 其与主要层连接方向平行, 从而创造一条捷径, 将较早的信号重新注入给下游网络层, 这也有助于跳过任意深度的层来传播梯度。最终有效地缓解了梯度消失与表示瓶颈。

3 轧制力建模实验

3.1 建模平台与工具

选用 Python 作为开发语言, 并使用基于其开发的科学计算库 Numpy 和 Pandas, 实现对数据的读取、删除、修改、查找、保存等操作。基于 Keras 机器学习框架, 搭建深度学习网络模型。模型检验阶段采用 Matplotlib 对结果进行可视化, 并直观地反应模型训练的结果, 有利于结果对比分析。

3.2 数据处理

建模数据采集自 4300 mm 宽厚板热轧生产线, 该生产线主要以满足高技术含量的低合金高强度结构板、管线钢、桥梁板、高建结构板、压力容器板、锅炉板、造船板及采油平台用板为产品定位, 配套钢板热处理淬火、正火、回火设备, 年生产钢板 2.85×10^6 t。采集生产数据共 42889 条。

3.2.1 数据清洗

数据清洗是指丢弃包含缺失值的数据、去除异

常数据、去除非关联的特征。若 $|RE - \overline{RE}| \geq 3\sigma$, 则将其视为异常数据, 其中 RE 为 SIMS 模型的相对误差, \overline{RE} 为所有建模数据样本 RE 的平均值, σ 为所有建模数据 RE 的标准差。

数据清洗后剩余数据为 40641 条, 影响轧制力的因素主要有金属的化学成分以及热力学条件等^[23], 因此, 选取的输入变量包括 23 个化学成分变量 ($w(\text{Al})$ 、 $w(\text{C})$ 、 $w(\text{Cr})$ 、 $w(\text{Cu})$ 、 $w(\text{Mn})$ 、 $w(\text{Mo})$ 、 $w(\text{Nb})$ 、 $w(\text{Ni})$ 、 $w(\text{Si})$ 、 $w(\text{V})$ 、 $w(\text{P})$ 、 $w(\text{S})$ 、 $w(\text{As})$ 、 $w(\text{B})$ 、 $w(\text{Ti})$ 、 $w(\text{Ca})$ 、 $w(\text{TiN})$ 、 $w(\text{W})$ 、 $w(\text{Bi})$ 、 $w(\text{Co})$ 、 $w(\text{Pb})$ 、 $w(\text{Sb})$ 、 $w(\text{Zr})$) 和 6 个物理变量 (入口厚度 H_0 、出口厚度 H_1 、轧制平均温度 t 、轧辊半径 D 、每道次入口宽度 W 、每道次入口长度 l), 其中 $w(\)$ 为某化学成分的质量分数。

3.2.2 数据归一化与数据集划分

由于各个样本特征数据的量纲存在差异, 对应的数据值区间相差较大, 因此采用 z-score 的方法对特征数据进行标准化, 达到提升数据收敛速度以及有效避免特征失效的目的。

z-score 公式^[24]为:

$$x = \frac{x - \bar{x}}{a} \quad (3)$$

式中: x 为原始数据; \bar{x} 为原始数据平均值; a 为原始数据标准差。

模型得到预测值, 需对其进行去归一化处理恢复为 y , 公式为:

$$y = y_{\text{predict}} \times a + \bar{x} \quad (4)$$

式中: y_{predict} 为模型的预测值。

按照 8 : 2 的比例将数据集划分为训练集和测试集。再将 20% 的训练集作为验证集, 用于验证评估所训练的模型, 从而进一步优化超参数。最后用测试集进行检验, 测试集是建模过程中未使用的数据样本, 可真实反映模型的泛化能力与预测精度。

3.3 模型与超参数设置

为了验证融合了 SIMS 模型且基于残差连接的深度学习网络的有效性, 设置传统 SIMS 模型、浅层神经网络模型、深层神经网络模型、SIMS+深层神经网络模型、SIMS+残差连接的深层神经网络模型作对照实验, 其中 4 种神经网络模型对应的结构参数见表 1。

表1 各模型对应的结构参数

轧制力模型	输入特征个数	隐藏层数	各层神经元个数 (输入层, 隐藏层, 输出层)
浅层神经网络模型	29	1	(29, 150, 1)
深层神经网络模型	29	3	(29, 150, 150, 150, 1)
SIMS+深层神经网络模型	30	3	(30, 150, 150, 150, 1)
SIMS+残差连接的深层神经网络模型	30	3	(30, 150, 150, 150, 1)

深度神经网络模型的训练过程需设置多个超参数, 根据验证集评估结果进行下一步调整。超参数包括: 激活函数、早停机制的判断条件、Mini-Batch 的大小。实验结果表明, 设置每个隐藏层有 150 个神经元, 激活函数为 ReLU^[25], 早停机制设为: 当连续迭代 50 次损失值不改善则停止, Mini-Batch 设为 128, 各个神经网络模型的结构示意图如图 3 所示。

3.4 评价指标

本文使用平均绝对误差 MAE 、均方误差 $RMSE$ 、决定系数 R^2 、相对误差 RE 作为模型的评价指标。

3.4.1 平均绝对误差 MAE

平均绝对误差是预测值与真实值的误差绝对值的平均值。计算公式为:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - f(x_i)| \quad (5)$$

3.4.2 均方根误差 $RMSE$

均方误差是预测值与真实值偏差的平方和与 n 比值的平方根, 对误差的大小极为敏感。计算公式为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - f(x_i))^2} \quad (6)$$

3.4.3 决定系数 R^2

决定系数可以用于判断回归方程的拟合程度, 衡量模型的预测能力。决定系数越大, 则模型的预测能力越高。其计算公式为:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - f(x_i))^2}{\sum_{i=1}^n (y_i - \text{mean})^2} \quad (7)$$

式中: mean 为 y_i 的均值。

3.4.4 相对误差 RE

相对误差用百分数形式表示, 预测值减去真实值得到绝对误差, 再将绝对误差除以真实值乘以 100%, 即可求得相对误差, 相对误差更能反映预测

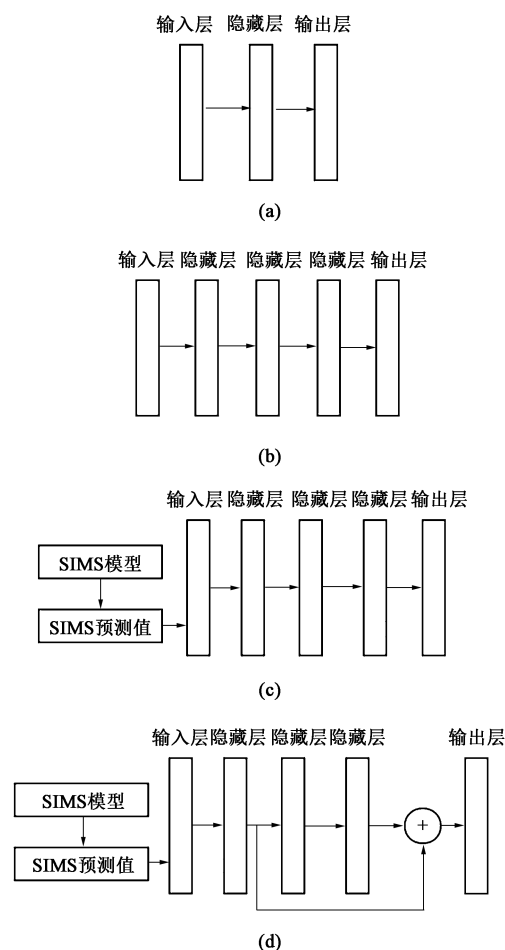


图3 各实验模型结构示意图

(a) 浅层神经网络模型 (b) 深层神经网络模型

(c) SIMS+深层神经网络模型

(d) SIMS+残差连接的深层神经网络模型

Fig. 3 Schematic diagrams of structure for each experimental model

(a) Shallow neural network model (b) Deep neural network model

(c) SIMS+deep neural network model

(d) SIMS+deep neural network model with residual connection

的可信程度。其计算公式为:

$$RE = \frac{f(x_i) - y_i}{y_i} \times 100\% \quad (8)$$

3.5 结果分析

传统 SIMS 模型、浅层神经网络模型、深层神经网络模型、SIMS+深层神经网络模型、SIMS+残差连接的深层神经网络模型的预测结果如表 2 所示。

由表 2 可以得出, 通过传统 SIMS 模型得到的轧制力预测值与真实值的误差较大, 各项评价指标均差于其他模型。浅层神经网络模型对轧制力的预测精度相比于传统 SIMS 模型得到了一定提高, 深层神经网络模型在浅层神经网络模型的基础进一步提高了预测精度, 相对误差绝对值小于 5% 在测试集中占比

表 2 各轧制力模型的预测精度

Table 2 Prediction accuracies of each rolling force model

模型	MAE/kN	RMSE/kN	R ²	相对误差绝对值小于 3% 在测试集中占比/%	相对误差绝对值小于 5% 在测试集中占比/%
传统 SIMS 模型	1999.45	2816.06	0.9437	45.22	64.72
浅层神经网络模型	1775.84	2535.62	0.9543	49.72	70.04
深层神经网络模型	1450.14	2240.80	0.9643	59.50	78.36
SIMS+深层神经网络模型	1110.90	1928.60	0.9736	71.37	85.92
SIMS+残差连接的深层神经网络模型	1089.05	1849.06	0.9757	72.53	86.44

达到 78.36%。而 SIMS+深层神经网络模型在深层神经网络模型的基础上融合了 SIMS 公式值,使得预测精度进一步提高。由于残差连接将较早的信号重新注入给下游的网络层, SIMS+残差连接的深层神经网络模型的各项指标是 5 个模型中最优的,相对误差绝对值小于 5% 在测试集中占比高达 86.44%。

用散点图表示各个模型预测结果与真实值之间的散列程度,如图 4 所示。由图 4 可以得出,相比于对照组模型, SIMS+残差连接的深层神经网络模型的预测结果与真实值之间的散列程度最小。SIMS+残差连接的深层神经网络模型的预测结果的相对误差百分比直方图如图 5 所示。

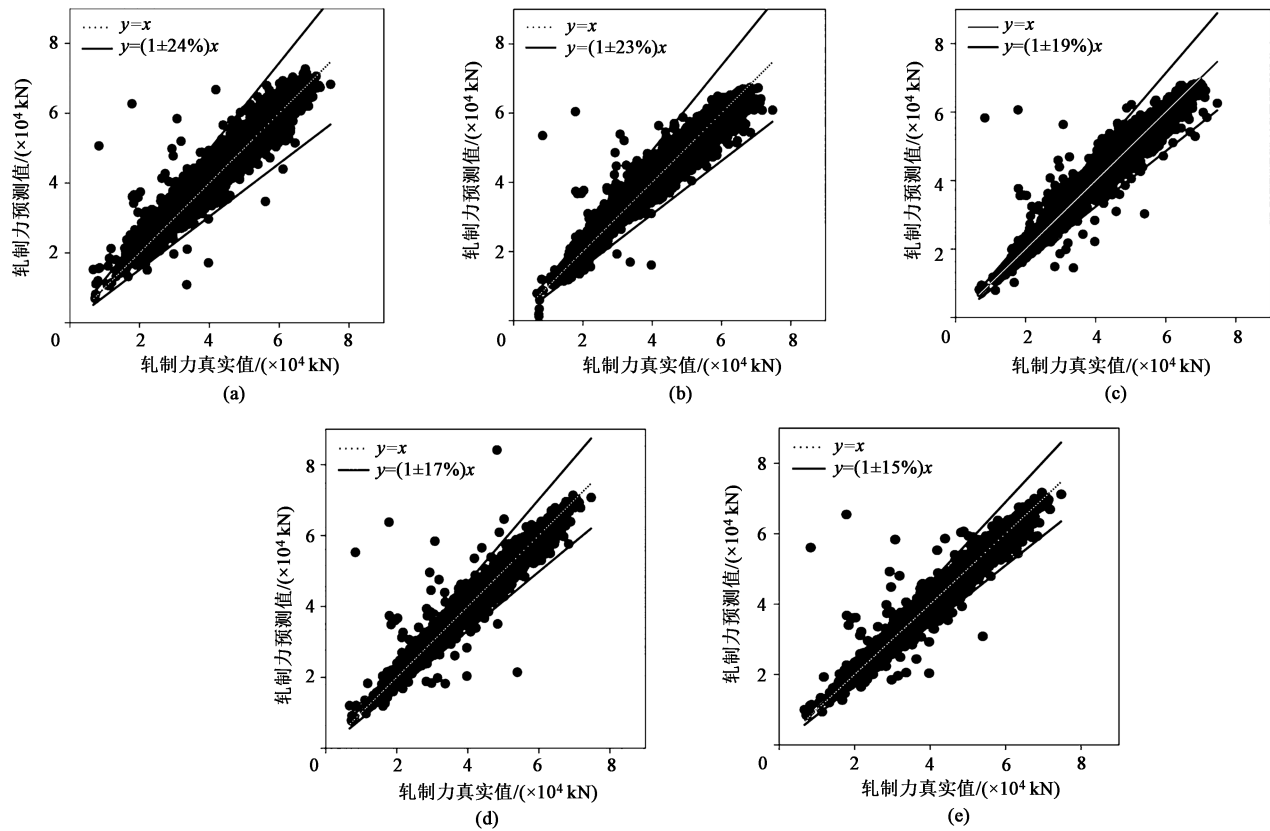


图 4 各模型的轧制力预测值与真实值的散点分布

(a) 传统 SIMS 模型 (b) 浅层神经网络模型 (c) 深度神经网络模型 (d) SIMS+深度神经网络模型 (e) SIMS+残差连接的深层神经网络模型

Fig.4 Scatter distributions of predicted values and true values for rolling forces in each model

(a) Traditional SIMS model (b) Shallow neural network model (c) Deep neural network model

(d) SIMS+deep neural network model (e) SIMS+deep neural network model with residual connection

4 结论

(1) 本文重点研究了宽厚板热轧过程控制模型

中轧制力的预测,建立融合了 SIMS 模型、基于残差连接的深度学习网络模型。将 23 个化学成分、6 个物理量、SIMS 模型计算值作为神经网络的特征输入,采用 Mini-Batch 与 RMSProp 相结合的优化算法




图5 相对误差百分比直方图

Fig. 5 Relative error percentage histogram

对参数进行优化, 利用批标准化 (BN), 有效地提高了模型的收敛速度。采用残差连接的方式, 引入一个纯线性的信息携带轨道, 与神经网络层连接的方向平行, 将较早的信号重新注入给下游的网络层, 提高了模型的预测精度。

(2) 利用深度学习框架 Keras 实现了深度学习网络模型, 极大地提高了建模效率。对比分析了传统 SIMS 模型、浅层神经网络模型、深层神经网络模型、SIMS+深层神经网络模型、SIMS+残差连接的深层神经网络模型的预测结果。SIMS+残差连接的深层神经网络模型的各项评价指标均优于其他模型, 在不考虑数据集中和钢种差异的情况下, 实现了对宽厚板热轧轧制力的高精度预测。以相对误差绝对值小于 5% 在测试集中占比作为评价指标, 相比与传统 SIMS 模型, 该模型的预测精度平均提升了 21.72%。

(3) 将深度学习与钢铁工业大生产结合, 将有助钢铁工业的精细发展, 前景广阔, 值得更多的投入和探索。

参考文献:

- [1] Liu X, Liu X H, Song M, et al. Theoretical analysis of minimum metal foil thickness achievable by asymmetric rolling with fixed identical roll diameters [J]. Transactions of Nonferrous Metals Society of China, 2016, 26 (2): 501-507.
- [2] Zuo Y B, Xing F U, Cui J Z, et al. Shear deformation and plate shape control of hot-rolled aluminium alloy thick plate prepared by asymmetric rolling process [J]. Transactions of Nonferrous Metals Society of China, 2014, 24 (7): 2220-2225.
- [3] 李海军, 徐建忠, 王国栋. 热轧带钢精轧过程高精度轧制力预测模型 [J]. 东北大学学报: 自然科学版, 2009, 30 (5): 669-672.
- Li H J, Xu J Z, Wang G D. High-precision rolling force prediction

model for hot strip continuous rolling process [J]. Journal of Northeastern University: Natural Science, 2009, 30 (5): 669-672.

- [4] 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.
- [5] 朱永波, 张飞, 张勇军, 等. 基于粒子群优化的带钢凸度神经网络预测模型研究 [J]. 冶金自动化, 2019, 43 (2): 11-15, 28.
- Zhu Y B, Zhang F, Zhang Y J, et al. Particle swarm optimized neural network for strip crown prediction model research [J]. Metallurgical Industry Automation, 2019, 43 (2): 11-15, 28.
- [6] 熊文韬, 谢三山, 黄兆飞, 等. 基于神经网络遗传算法函数寻优与回弹补偿技术的某型汽车前幅拉延成形优化 [J]. 塑性工程学报, 2020, 27 (6): 38-45.
- Xiong W T, Xie S S, Huang Z F, et al. Optimization of drawing forming for front panel of an automobile based on neural network genetic algorithm function optimization and SCP technology [J]. Journal of Plasticity Engineering, 2020, 27 (6): 38-45.
- [7] 窦博. 热连轧轧制力贝叶斯神经网络预测与模型优化 [J]. 金属制品, 2017, 43 (6): 42-48.
- Dou B. Prediction of rolling force and model optimization with Bayes neural network [J]. Metal Products, 2017, 43 (6): 42-48.
- [8] 冀秀梅, 王龙, 高克伟, 等. 极限学习机在中厚板轧制力预报中的应用 [J]. 钢铁研究学报, 2020, 32 (5): 393-399.
- Ji X M, Wang L, Gao K W, et al. Application of ELM to predict plate rolling force [J]. Journal of Iron and Steel Research, 2020, 32 (5): 393-399.
- [9] 王秀梅, 王国栋. 综合神经网络在热连轧机组轧制压力预报中的应用 [J]. 钢铁研究学报, 1998, 10 (4): 72-74.
- Wang X M, Wang G D. Application of combination neural network to the prediction of the rolling load in the finishing train of hot strip mill [J]. Journal of Iron and Steel Research, 1998, 10 (4): 72-74.
- [10] 吕程, 王国栋, 刘相华, 等. 基于神经网络的热连轧精轧机组轧制力高精度预报 [J]. 钢铁, 1998, (3): 35-37.
- Lyu C, Wang G D, Liu X H, et al. High-precision prediction of rolling load of finishing stands with neural networks [J]. Iron & Steel, 1998, (3): 35-37.
- [11] 刘元铭, 王振华, 王涛, 等. 热轧带钢出口凸度数据驱动建模及智能化预测分析 [J]. 中国机械工程, 2020, 31 (22): 2728-2733.
- Liu Y M, Wang Z H, Wang T, et al. Data-driven modeling and intelligent prediction analysis for hot strip outlet crowns [J]. Chi-

- na Mechanical Engineering, 2020, 31 (22): 2728-2733.
- [12] 陈丹, 邵健, 殷实, 等. 基于大数据平台的冷连轧制力自学习模型优化 [J]. 冶金自动化, 2020, 44 (6): 25-29.
- Chen D, Shao J, Yin S, et al. Optimization of self-learning model of cold rolling force based on big data platform [J]. Metallurgical Industry Automation, 2020, 44 (6): 25-29.
- [13] 曹建国, 江军, 赵秋芳, 等. 基于数据挖掘的宽厚板板凸度控制 [J]. 中南大学学报: 自然科学版, 2019, 50 (11): 2743-2752.
- Cao J G, Jiang J, Zhao Q F, et al. Wide and heavy plate crown control based on data mining [J]. Journal of Central South University: Science and Technology, 2019, 50 (11): 2743-2752.
- [14] 刘明华, 张强, 刘英华, 等. 基于机器学习的热轧轧制力预测 [J]. 锻压技术, 2021, 46 (10): 233-241.
- Liu M H, Zhang Q, Liu Y H, et al. Prediction of rolling force in hot rolling based on machine learning [J]. Forging & Stamping Technology, 2021, 46 (10): 233-241.
- [15] 章顺虎, 姜兴睿, 尤凤翔, 等. 融合工业大数据的热轧厚板轧制力模型研究 [J]. 精密成形工程, 2020, 12 (2): 8-14.
- Zhang S H, Jiang X R, You F X, et al. Investigation on the model of rolling force by integrating industrial big data [J]. Journal of Netshape Forming Engineering, 2020, 12 (2): 8-14.
- [16] 魏立新, 魏新宇, 孙浩, 等. 基于深度网络训练的铝热轧轧制力预报 [J]. 中国有色金属学报, 2018, 28 (10): 2070-2076.
- Wei L X, Wei X Y, Sun H, et al. Prediction of aluminum hot rolling force based on deep network [J]. The Chinese Journal of Nonferrous Metals, 2018, 28 (10): 2070-2076.
- [17] 马威, 李维刚, 赵涛涛, 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.
- [18] 马湧, 王晓鹏, 马莎莎. 基于 Keras 深度学习框架下 BP 神经网络的热轧带钢力学性能预测 [J]. 冶金自动化, 2019, 43 (2): 6-10.
- Ma Y, Wang X P, Ma S S. Prediction of mechanical properties of hot rolled strip based on BP neural network under Keras deep learning framework [J]. Metallurgical Industry Automation, 2019, 43 (2): 6-10.
- [19] 王秀梅, 王国栋, 刘相华. 人工神经网络和数学模型在热连轧机组轧制力预报中的综合应用 [J]. 钢铁, 1999, (3): 39-41.
- Wang X M, Wang G D, Liu X H. Application of neural networks in combination with mathematical models to prediction of rolling load of hot strip rolling mill [J]. Iron & Steel, 1999, (3): 39-41.
- [20] Zhou B C, Han C Y, Guo T D. Convergence of stochastic gradient descent in deep neural network [J]. Acta Mathematicae Applicatae Sinica: English Series, 2021, 37 (1): 126-136.
- [21] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift [A]. International Conference on Machine Learning [C]. PMLR, 2015.
- [22] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [A]. IEEE Conference on Computer Vision & Pattern Recognition [C]. IEEE Computer Society, 2016.
- [23] 贺毓辛. 轧制工程学 [M]. 北京: 化学工业出版社, 2010.
- He Y X. Rolling Engineering [M]. Beijing: Chemical Industry Press, 2010.
- [24] 李飞飞, 宋勇, 刘超, 等. 热轧带钢力学性能预报模型的误差分布建模研究 [J]. 冶金自动化, 2019, 43 (6): 28-33.
- Li F F, Song Y, Liu C, et al. Research on error distribution modeling of mechanical performance prediction model for hot rolled strip [J]. Metallurgical Industry Automation, 2019, 43 (6): 28-33.
- [25] Yarotsky D. Error bounds for approximations with deep ReLU networks [J]. Neural Networks: The Official Journal of the International Neural Network Society, 2017, 94 (2): 94-103.

(上接第 166 页)

- Yu W, Cai Q W, Wu W, et al. Rolling technology for stainless steel/carbon steel composite rebar with seawater corrosion resistance [A]. Proceedings of the 11th CSM Steel Congress [C]. Beijing: 2017.
- [8] 高亚男. 不锈钢/碳钢覆层钢筋轧制理论及实验研究 [D]. 秦皇岛: 燕山大学, 2011.
- Gao Y N. Rolling Theory and Experimental Research of Stainless Steel/Carbon Steel Cladding Bar [D]. Qinhuangdao: Yanshan University, 2011.
- [9] 余伟, 张泽宇, 吴伟, 等. 不锈钢/碳钢耐蚀海水带肋钢筋轧制复合工艺 [J]. 钢铁研究学报, 2019, 31 (4): 380-386.
- Yu W, Zhang Z Y, Wu W, et al. Rolling bonding process of stainless steel/carbon steel rebar with seawater corrosion resistance [J]. Journal of Iron and Steel Research, 2019, 31 (4): 380-386.
- [10] 张少坤. 不锈钢包覆铁屑复合轧制实验及有限元模拟 [D]. 秦皇岛: 燕山大学, 2014.
- Zhang S K. The Composite Rolling Experiment and Finite Element Simulation of the Iron Scrap with Stainless Steel Coating [D]. Qinhuangdao: Yanshan University, 2014.
- [11] Dyja H, Mróz S, Stradomski Z. Properties of joint in the bimetallic rods Cu-Al and Cu-steel after explosive cladding and the process of rolling [J]. Metalurgija, 2003, 42 (3): 185-191.
- [12] Xie B, Sun M, Xu B, et al. Evolution of interfacial characteristics and mechanical properties for 316LN stainless steel joints manufactured by hot-compression bonding [J]. Journal of Materials Processing Technology, 2020, 283: 1-14.