

轧制

基于迁移学习和多方面特征提取的冷轧轧制力预测

张明^{1,2}, 牛国伟¹, 黄自豪¹, 张雄飞³, 杨彦博¹

(1. 河北工程大学机械与装备工程学院, 河北邯郸 056038; 2. 河北省冀南新区现代装备制造协同创新中心, 河北邯郸 056000;
3. 邯郸市永年区职业技术教育中心, 河北邯郸 056000)

摘要: 针对冷轧机各机架轧制工况复杂, 实际采集的工艺数据存在分布差异, 导致小数量样本下轧制力预测模型对不同机架预测时出现精度降低的问题, 提出一种基于迁移学习和多方面特征提取的轧制力预测模型。该方法通过迁移学习将建立的轧制力预测基准模型参数迁移至目标机架, 从而实现小数量样本下不同机架的轧制力快速预测。预测时, 利用源域数据建立了 Inception-LSTM-Attention 轧制力预测基准模型, 基准模型结合了 Inception 网络模块的空间特征提取能力和 LSTM 的时序特征预测能力, 同时引入注意力机制 Attention 调节神经网络学习到的信息向量权重, 基准模型预测精度高达 98.8%。然后将基准模型部分网络模块冻结迁移至目标域模型, 并对模型参数进行微调, 建立了最终的轧制力预测模型。实验结果表明, 小数量样本下采用迁移学习方法建立的模型在预测精度方面高于传统神经网络预测模型。

关键词: 轧制力; 冷轧; 迁移学习; 多方面特征提取; 预测精度

DOI: 10.13330/j.issn.1000-3940.2024.06.017

中图分类号: TF345

文献标志码: A

文章编号: 1000-3940 (2024) 06-0141-08

Prediction on cold rolling force based on transfer learning and multi-aspect feature extraction

Zhang Ming^{1,2}, Niu Guowei¹, Huang Zihao¹, Zhang Xiongfei³, Yang Yanbo¹

(1. School of Mechanical and Equipment Engineering, Hebei University of Engineering, Handan 056038, China;

2. Collaborative Innovation Center for Modern Equipment Manufacturing of Jinan New Area (Hebei), Handan 056000, China;

3. Handan Yongnian District Vocational and Technical Education Center, Handan 056000, China)

Abstract: Aiming at the problem of reduced prediction accuracy of rolling force prediction model under small number of samples when predicting the rolling force of different frames, which is caused by the complex rolling condition of each frame for cold rolling mill to make the distribution of actual collected process data different, a rolling force prediction model based on transfer learning and multi-aspect feature extraction was proposed. This method could transfer the parameters of established rolling force prediction benchmark model to the target frame by transfer learning to realize the rapid prediction of rolling force in different frames with small number of samples. When predicting, Inception-LSTM-Attention rolling force prediction benchmark model was established by using the source domain data, which combined the spatial feature extraction ability of Inception network module and the temporal feature prediction ability of LSTM. At the same time, the attention mechanism Attention was introduced to adjust the weight of information vector learned by the neural network, and the prediction accuracy of the benchmark model was as high as 98.8%. Then, some network modules of the benchmark model were frozen and transferred to the target domain model, and the model parameters were fine-tuned to establish the final rolling force prediction model. The experimental results show that the prediction accuracy of the model established based on the transfer learning method under small number of samples is higher than that of the traditional neural network prediction model.

Key words: rolling force; cold rolling; transfer learning; multi-aspect feature extraction; prediction accuracy

在带钢冷连轧生产过程中, 轧制力的设定至关重要, 其预测精度直接关系到产品的最终质量。精

准的轧制力预测模型可以有效减少带钢头尾长度, 提高成品带钢的厚度精度和板形精度^[1]。传统的轧制力预测模型通常使用机理建模方式, 对轧制过程中的多种条件进行假设, 并采用微分方程求解的方法获得轧制理论公式。然而, 由于轧制过程的复杂性、深度非线性以及众多影响因素, 导致计算结果与实际工况存在较大偏差^[2-3]。

收稿日期: 2024-03-06; 修订日期: 2024-05-26

基金项目: 国家自然科学基金青年项目 (52005148)

作者简介: 张明 (1988-), 男, 博士, 副教授

E-mail: zhangming@hebeu.edu.cn

目前,从机理角度提升已有轧制力预测模型的精度存在一定困难。随着人工智能的飞速发展,国内外学者将机器学习的方法引入到轧制力预测领域。人工智能方法避免了对轧制过程深层规律无休止的研究,通过模拟人脑处理发生的过程,基于实际生产中的大量历史数据对轧制力进行预测,有效解决了机理预测模型因简化各种影响因素而产生的误差问题,使得轧制力预测更为高效,不再受制于对复杂规律理论的深入挖掘,为轧制力预测提供了一种更为有效和可靠的途径。目前,越来越多的人工智能模型涌入到轧制力预测领域^[4-6]。陈树宗等^[7]提出了一种基于遗传算法优化反馈极限学习机算法的冷轧轧制力预测模型,通过在原极限学习机网络中增加反馈回路,构建了反馈极限学习机网络,有效提升了模型的预测精度;孙浩等^[8]针对浅层网络不能提取样本的深层次特征和传统回归模型长时间不更新导致的漂移问题,提出了一种基于长短期记忆神经网络(Long Short Term Memory, LSTM)和即时学习相关向量机(Just In Time Relevance Vector Machine, JITRVM)的LSTM-JITRVM的轧制力预测模型,该模型的预测误差可控制在3%以内;魏立新等^[9]充分利用生产过程中的无标签数据,使用半监督深度网络建立了冷轧轧制力预报模型;Liu J Y等^[10]通过遗传算法(Genetic Algorithm, GA)和粒子群算法计算多隐层极限学习机网络(Multiple Hidden Layer Extreme Learning Machine, MELM)的最优隐藏层数量,避免了人为选择网络结构层数的困难,建立了基于GA-MELM的热轧轧制力预测模型;Wang C L等^[11]通过将卷积神经网络(Convolutional Neural Networks, CNN)和长短期记忆神经网络相结合,加入批标准化(Batch Normalization, BN)以提高模型的泛化能力,并利用LSTM网络提取轧制过程的时序特征,建立了深度学习视域下驱动的

CNN-BN-LSTM轧制力预测模型;李维刚等^[12]通过考虑带钢连续轧制的特点,将连续生产、相关性高的带钢关联考虑,建立了基于图卷积神经网络的热轧轧制力预测模型。

上述预测模型相较于传统机理模型均表现出显著的预测准确度提升。然而,这一优势实现的前提在于大量、充足的模型训练数据。实际情况下,轧机工作状况的复杂多变使得提取的数据难以满足网络训练的要求,小数量样本下的参数训练会对预测模型的准确度产生影响。为解决这一问题,本文提出了基于迁移学习和多方面特征提取的轧制力预测模型。

1 轧制力机理模型

传统机理模型冷轧轧制力计算公式的基本形式如式(1)所示。

$$P = Bl'_c Q_p K K_T \quad (1)$$

式中: P 为轧制力; B 为轧件宽度; l'_c 为轧辊与轧件接触弧水平投影长度; Q_p 为外摩擦力状态系数; K_T 为前后张应力对轧制力的影响系数; K 为金属变形阻力,一般取 $K=1.15\sigma$; σ 为变形抗力。

由于传统机理模型中外摩擦力状态系数和变形抗力等因素无法直接测量,在计算过程中存在一定的假设问题,无法满足轧制力精准预测的要求。因此,本文基于冷轧现场生产大数据,通过结合Inception卷积神经网络、LSTM神经网络和添加注意力机制Attention的方法建立了精准的轧制力预测基准模型,再通过迁移学习的方法来提高预测模型的适用性。

2 轧制力预测基准模型建立

本文提出的轧制力预测基准模型由Inception模块、LSTM模块和Attention模块组成,通过输出层将轧制力结果转化为一维进行输出。模型结构如图1所示。




图1 基准网络模型结构

Fig. 1 Structure of benchmark network model

2.1 Inception 模块

冷轧生产工况复杂多变, 轧制力与各轧制工艺参数之间存在不同程度的耦合关系。常见单核卷积神经网络不能从输入参数中同时有效提取多种特征, 因此, 本文采用 Inception 卷积神经网络从轧制工艺参数(轧制速度、出口张力、入口张力、出口厚度、入口厚度、辊缝值和轧制力)中提取工艺参数特征, 传统卷积神经网络需要对卷积层的过滤器大小和池化层位置进行选择, 而主观的选择可能对模型的预测性能产生影响, Inception 卷积神经网络弥补了这种缺陷。Inception 卷积神经网络共有 4 个通道, 包含不同尺寸的卷积和池化操作, 不同尺寸的卷积核可进行并行计算, 可并行处理多个卷积和池化操作, Inception 卷积神经网络结构如图 2 所示。其中, 1×1 、 3×3 、 5×5 表示卷积和池化操作窗口大小。

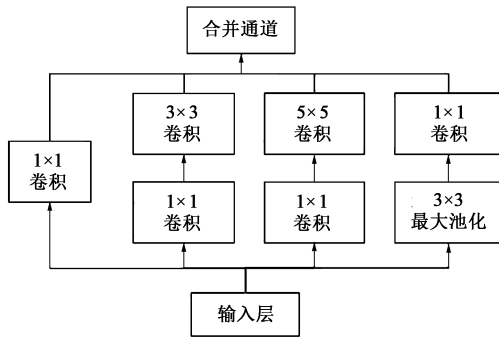


图 2 Inception 网络模型结构

Fig. 2 Structure of Inception network model

Inception 卷积神经网络采用不同尺寸的卷积核进行计算, 不同尺寸的卷积核可以从不同跨度的工艺参数中进行特征提取, 使网络可以学习到不同抽象程度的特征表示。这些特征在后续重组中可以提高网络对轧制工艺参数的理解能力^[13-15], 并行计算使网络在同一层级上获取不同尺度的特征, 有助于神经网络捕获更广泛范围的特征, 从而提高神经网络对工艺参数的理解能力, 并且可以避免网络中单一卷积核的参数过多^[16]。相比于传统卷积神经网络为提高模型预测精度深度堆叠而使用单一尺寸的卷积核, Inception 模块能够在保持有效感受野的情况下, 减少参数数量, 从而降低了计算复杂程度。在模型训练前使用 Python 语言将 Inception 卷积神经网络定义封装为函数模块, 训练模型中可直接进行调用。

2.2 LSTM 模块

LSTM 网络在循环神经网络的基础上引入了门控机制和细胞记忆结构, 成功地解决了循环神经网络

中存在的梯度消失和梯度爆炸等问题^[17-18]。LSTM 网络引入的细胞记忆单元赋予其出色的记忆能力, 因此, 在时间序列预测等任务中得到了广泛应用^[19]。LSTM 网络的循环单元结构如图 3 所示, 具体表达如式 (2) 所示。

$$\begin{cases} i_t = \text{sig}(W_i x_t + U_i h_{t-1} + b_i) \\ f_t = \text{sig}(W_f x_t + U_f h_{t-1} + b_f) \\ o_t = \text{sig}(W_o x_t + U_o h_{t-1} + b_o) \\ \tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \\ c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \\ h_t = o_t \odot \tanh(c_t) \end{cases} \quad (2)$$

式中: i_t 、 \tilde{c}_t 为输入门, 用于接收时序数据; f_t 为遗忘门, 可将部分数据选择性遗忘; o_t 、 h_t 为输出门, 用于将 LSTM 处理的数据进行输出; h_{t-1} 为 $t-1$ 时刻的输出; c_t 为 t 时刻的记忆单元; x_t 为 t 时刻的输入; W_i 、 W_f 、 W_o 、 W_c 、 U_i 、 U_f 、 U_o 、 U_c 为权重矩阵; b_i 、 b_f 、 b_o 和 b_c 为偏置项; \odot 为点乘; c_{t-1} 为 $t-1$ 时刻的记忆单元; sig 为 sigmoid 函数; tanh 为激活函数。

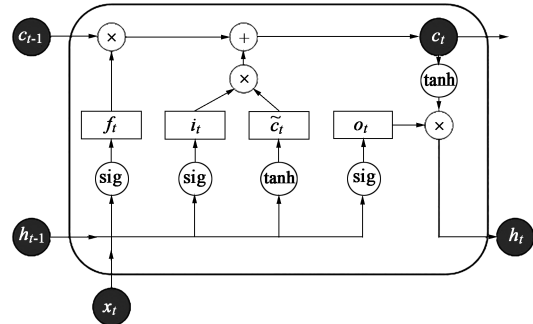


图 3 LSTM 网络模型结构

Fig. 3 Structure of LSTM network model

冷轧轧制力的变化和之前时刻的轧制力密切相关, 因此, 本文在 Inception 卷积神经网络层添加两层 LSTM 网络层对轧制力时序特征进行提取。

2.3 注意力机制模块

注意力机制可以针对网络所学到的信息, 不断更新注意力权重, 对数据分配权重后, 可提高模型的拟合能力, 优化模型学习并做出更优的选择, Attention 的结构如图 4 所示。其中, $j_1, j_2, j_3, \dots, j_t, \dots, j_{t'}$ 为输入特征; $d_1, d_2, d_3, \dots, d_t, \dots, d_{t'}$ 为输入特征对应的隐藏层的状态值; $a_1, a_2, a_3, \dots, a_t, \dots, a_{t'}$ 为历史输入的隐藏层状态对应的当前输入值; $S_{t'}$ 为注意力机制最终模块的输出; $d_{t'}$ 为最后时刻 t' 输出的隐藏层状态值。

Attention 机制的详细计算公式如式 (3) 所示。




图 4 注意力机制 Attention 单元结构示意图

Fig. 4 Schematic diagram of unit structure for attention mechanism Attention

$$\begin{cases} e_t = \text{utanh}(wd_t + b) \\ a_t = \frac{\exp(e_t)}{\sum_{r=1}^n \exp(e_r)} \\ S_t = \sum_{i=1}^{r'} e_i a_i \end{cases} \quad (3)$$

式中： e_t 为 t 时刻输入值 d_t 所决定的注意力概率分布值； S_t 为 t 时刻注意力机制模块的输出； w 、 u 为权值参数； b 为偏置； e_r 为第 r 个元素的注意力概率分布值； $r=1, 2, \dots, n$ ； n 为输入元素的数目。

2.4 输出层

Adam 优化算法是一种常用的自适应学习率优化算法，它结合了动量优化和自适应学习率调整的特点，因此，本文建立的轧制力预测模型中使用 Adam 优化算法。Rule 函数是机器学习中常用的激活函数，有效解决了 Sigmoid 等激活函数存在的梯度消失问题，本文在注意力机制后添加激活函数为 Rule 的输出层，得到最终的轧制力输出结果。

$$y = \partial(\mathbf{W}_a \mathbf{A} + b_a) \quad (4)$$

式中： y 为轧制力输出结果； ∂ 为 Rule 激活函数； \mathbf{W}_a 为权值矩阵； \mathbf{A} 为上层输出； b_a 为偏置项。

2.5 建模数据预处理

轧制力预测模型的数据均为邯郸钢铁集团有限责任公司酸轧产线精轧机组的生产数据，选取 E 机架工艺参数作为轧制力预测基准模型的源域数据，共 49654 条数据，将 F 机架和 G 机架数据作为目标域数据，共 4000 条数据，用于小数量样本轧制力预测的实验。由于轧机工艺数据的采集、存储以及传输过程会存在数据异常和缺失问题，这些异常数据会造成模型的预测精度降低，需使用数据预处理技术改进数据质量，本文使用 3sigma 法则筛选数据集中的异常值，并使用向前填充对数据缺失值进行填补处理。部分生产数据如表 1 所示。

表 1 冷轧工艺参数部分数据

Table 1 Partial data for cold rolling process parameters

参数	轧制速度/(m·s ⁻¹)	入口张力/kN	出口张力/kN	入口厚度/m	出口厚度/m	辊缝值/mm	轧制力/MN
数值	2.98974	263.024	477.389	0.004376	0.003608	3.98074	9.042090
	2.99090	262.401	480.213	0.004370	0.003608	3.98140	9.011900
	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	4.92974	262.296	478.499	0.004346	0.003606	3.95617	9.226780

此外，从表 1 分析可得不同特征值之间的数量级存在巨大差异，为取消各数据之间的数量级差别，避免数据数量级差别大对模型预测精度造成干扰，使用式 (5) 对轧制数据进行归一化处理。

$$Z = \frac{X - \mu}{\delta} \quad (5)$$

式中： Z 为标准化后的数据值； X 为原始数据； μ 为样本均值； δ 为样本的标准差。

将标准化后的 60% 数据作为训练集数据，30% 数据作为验证集数据，10% 为测试集数据。

本文采用平均绝对误差 MAE、均方根误差 RMSE 和决定系数 R^2 来衡量轧制力模型的可靠性。

MAE 和 RMSE 的值越小，代表预测模型的误差越低； R^2 的值越接近 1，说明模型预测轧制力与实际轧制力值的拟合程度越高。评价指标计算公式见式 (6)。

$$\begin{cases} MAE = \frac{1}{p} \sum_{g=1}^p |\hat{y}_g - y_g| \\ RMSE = \sqrt{\frac{1}{p} \sum_{g=1}^p (\hat{y}_g - y_g)^2} \\ R^2 = 1 - \frac{\sum_{g=1}^p (\hat{y}_g - y_g)^2}{\sum_{g=1}^p (y_{\text{mean}} - y_g)^2} \end{cases} \quad (6)$$

式中： \hat{y}_g 为轧制力预测值； y_{mean} 为轧制力平均值； y_g 为轧制力真实值； $g=1, 2, \cdots, p$ ； p 为预测样本数量。

2.6 基准模型预测结果分析

为证明本文提出的基准模型可以满足实际生产中对轧制力预测精度的需求以及体现模型在预测时的优势，将基准模型预测结果与机理模型、轧制力预测领域应用广泛的卷积神经网络（CNN）和长短期记忆（LSTM）神经网络以及 CNN-LSTM 模型进行对比，各模型预测误差对比结果如表 2 所示。从表 2 可以看出，本文提出的基准模型在评价指标上均优于其他轧制力预测模型。

表 2 各模型性能评价结果

模型	MAE	RMSE	R^2
机理模型	65934	82914	0.575
CNN	46906	59956	0.778
LSTM	42415	54544	0.816
CNN-LSTM	24232	33945	0.912
本文模型	10440	13619	0.988

本文建立的轧制力预测基准模型结合了以下 3 种模块的优势：Inception 模块中不同尺度卷积核的特征提取通过串行叠加和并行拼接的方式完成特征融合，形成多尺度邻域特征，实现了对轧制工艺参数的多重特征提取；LSTM 模块中隐藏层通过权重反向传播，逐步优化训练权重；Attention 模块通过对数据分配权重后优化训练数据。

轧机实际轧制力与基准模型预测轧制力对比如图 5 和图 6 所示。




图 5 基准模型预测值与实际轧制力折线对比图
Fig.5 Line comparison diagram of rolling force between predicted values of benchmark model and actual values




图 6 基准模型预测值与实际轧制力散点对比图
Fig.6 Scatter comparison diagram of rolling force between predicted values of benchmark model and actual values

通过图 5 和图 6 可知，轧制力预测曲线和实际轧制力波动曲线拟合良好，说明可以使用 Inception-LSTM-Attention 预测模型作为其他机架轧制力预测模型的基准模型。

3 迁移学习预测模型建立

3.1 迁移学习

冷轧机机组长期在高转速、高负载下持续运行，不同机架之间采集到的数据存在分布差异，导致使用相同的神经网络模型对不同机架轧制力进行预测时会出现预测精度下降的问题，对此，可以使用迁移学习的方法优化本文使用的基准模型，提高模型在不同机架上预测的准确率。迁移学习是一种利用数据、任务或模型之间的相似性将从某一领域学习到的经验应用到其他相似领域的机器学习方法，该方法已应用在多个领域，包括故障诊断、图像分类和数据预测等，取得了显著的成果。依据迁移学习理论，将不同机架的工艺数据划分为源域数据集（E 机架）和目标域数据集（F 机架和 G 机架）。利用源域数据训练轧制力预测基准模型，通过冻结基准模型各层结构和参数，将目标域数据和源域数据进行相同的预处理操作，使用目标域数据并对模型进行微调训练，得到目标域轧制力输出。迁移学习的整体流程如图 7 所示。

3.2 迁移学习模型预测结果分析

使用 2000 组数据，模拟小数量样本下使用迁移学习预测模型和使用基准模型分别对 F 机架和 G 机架进行轧制力预测，迁移学习轧制力预测模型的预测精度分别为 94.2% 和 95.1%，远高于基准模型直接进行预测的 62.2% 和 66.0%。模型预测评价见

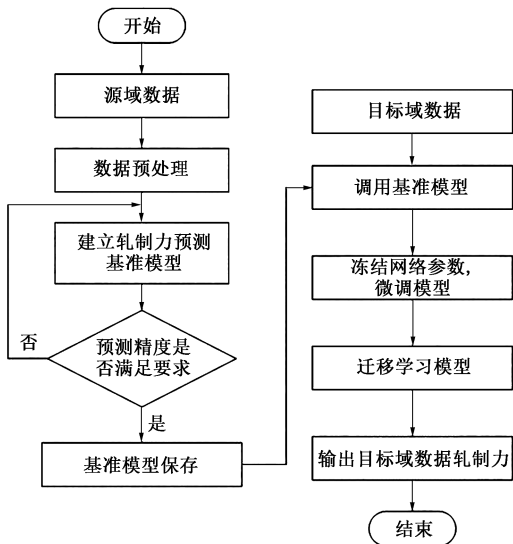


图 7 迁移学习流程图

Fig. 7 Flow chart of transfer learning

表 3, 基准模型预测效果变差是由于数据样本数量小,

表 3 迁移学习模型预测性能对比
Table 3 Comparison of prediction performance for transfer learning models

机架	是否迁移学习	MAE	RMSE	R^2
F	否	58062	72204	0.622
F	是	21968	28168	0.942
G	否	56186	68777	0.660
G	是	20876	26079	0.951

直接建立的轧制力预测模型网络未能学习到足够的知识, 导致预测精度偏低、预测误差较大。

F 机架和 G 机架迁移学习和直接使用基准模型轧制力预测对比图如图 8~图 10 所示, 在只有少量板坯数据的情况下, 直接使用基准模型进行预测, 轧制力的预测精度将会受到影响。在基准模型的基础上, 使用迁移学习的方法可以有效提升模型的准确率, 因此, 迁移学习在小数量样本训练下具有非常明显的优势。




图 8 轧制力预测折线图

(a) F 机架 (b) G 机架

Fig. 8 Prediction line charts of rolling force

(a) F frame (b) G frame

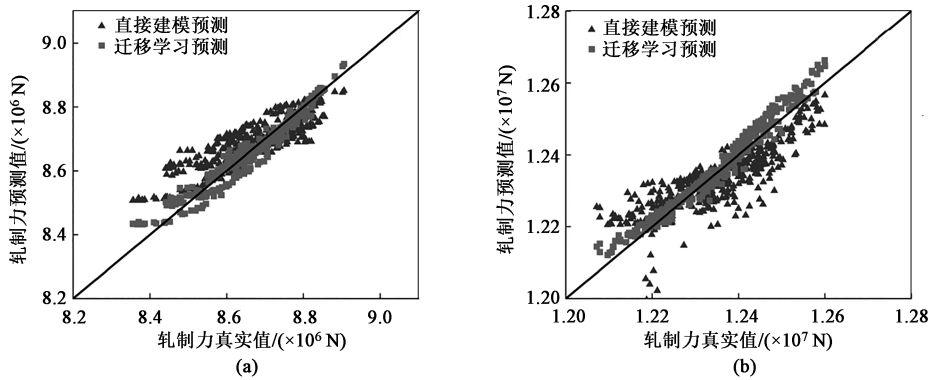


图 9 轧制力预测散点图

(a) F 机架 (b) G 机架

Fig. 9 Prediction scatter plots of rolling force

(a) F frame (b) G frame




图10 部分轧制力预测放大折线图

(a) F 机架 (b) G 机架

Fig. 10 Enlarged line charts of partial rolling force prediction

(a) F frame (b) G frame

4 结论

(1) 本文建立的基准模型中 Inception 模块使用不同大小的卷积核对轧制过程各工艺参数特征进行特征提取, 利用 Inception 提取数据多尺度特征的能力和 LSTM 在处理长序列数据中保持长期记忆的优势, 并添加注意力机制对模型学习参数进行优化, 使得基准模型的轧制力预测精度达到 98.8%, 各项评价指标均优于其他传统神经网络预测模型。

(2) 采用迁移学习的方法, 在小数量样本下有效提升了预测模型的预测精度和适用范围, 预测精度均达到 94% 以上。解决了小数量样本下模型训练样本不足导致的预测精度不高的问题, 在实际生产中具有潜在的应用价值。

参考文献:

- [1] 魏立新, 王恒, 孙浩, 等. 基于改进深度信念网络训练的冷轧轧制力预报 [J]. 计量学报, 2021, 42 (7): 906-912.
Wei L X, Wang H, Sun H, et al. Research on cold rolling force prediction model based on improved deep belief network [J]. Acta Metrologica Sinica, 2021, 42 (7): 906-912.
- [2] Hu Z Y, Wei Z H, Sun H, et al. Optimization of metal rolling control using soft computing approaches: A review [J]. Archives of Computational Methods in Engineering, 2019, 28 (2): 405-421.
- [3] Shen S H, Guye D, Ma X P, et al. Multistep networks for roll force prediction in hot strip rolling mill [J]. Machine Learning with Applications, 2021, 7 (4): 100245.
- [4] 郭金涛, 王龙, 余建波, 等. 基于深度学习的宽厚板热轧轧制力预测 [J]. 锻压技术, 2022, 47 (7): 167-174.
Guo J T, Wang L, Yu J B, et al. Prediction on rolling force in hot rolling of wide and thick plate based on deep learning [J]. Forging & Stamping Technology, 2022, 47 (7): 167-174.
- [5] 崔桂梅, 刘伟, 张帅, 等. 基于差分进化支持向量机的轧制力预测 [J]. 中国测试, 2021, 47 (8): 83-88.
Cui G M, Liu W, Zhang S, et al. Rolling force prediction based on differential evolution support vector machine [J]. China Measurement & Test, 2021, 47 (8): 83-88.
- [6] 吴爽, 闫奕, 李爽, 等. 冷连轧轧制力深度神经网络模型泛化能力并行优化 [J]. 机械设计与制造, 2023, (8): 171-174.
Wu S, Yan Y, Li S, et al. Parallel optimization of generalization capability of rolling force deep neural network model in tandem cold rolling mill [J]. Machinery Design & Manufacture, 2023, (8): 171-174.
- [7] 陈树宗, 白芸松, 侯佳琦, 等. 基于 GA-FELM 算法的冷轧轧制力预测模型 [J]. 燕山大学学报, 2022, 46 (3): 224-229.
Chen S Z, Bai Y S, Hou J Q, et al. Rolling force prediction model for cold rolling based on GA-FELM [J]. Journal of Yanshan University, 2022, 46 (3): 224-229.
- [8] 孙浩, 赵明达, 李静, 等. 基于 LSTM-JITRVM 的冷轧轧制力建模方法研究 [J]. 计量学报, 2023, 44 (9): 1409-1416.
Sun H, Zhao M D, Li J, et al. Research on modeling method of cold rolling force based on LSTM-JITRVM [J]. Acta Metrologica Sinica, 2023, 44 (9): 1409-1416.
- [9] 魏立新, 翟博豪, 赵志伟, 等. 基于半监督深度网络的冷连轧轧制力预报 [J]. 塑性工程学报, 2020, 27 (11): 70-76.
Wei L X, Zhai B H, Zhao Z W, et al. Prediction of cold continuous rolling force based on semi-supervised deep network [J]. Journal of Plasticity Engineering, 2020, 27 (11): 70-76.
- [10] Liu J Y, Liu X X, Le T B. Rolling force prediction of hot rolling based on GA-MELM [J]. Complexity, 2019, (2019): 1-11.
- [11] Wang C L, Zhang M. Research on dynamic rolling force prediction model based on CNN-BN-LSTM [J]. Journal of Advanced

- Mechanical Design, Systems and Manufacturing, 2022, 16 (3): 1-14.
- [12] 李维刚, 刘玮汲, 谢璐, 等. 基于图卷积网络的热轧带钢轧制力预测 [J]. 钢铁, 2023, 58 (3): 89-96, 127.
- Li W G, Liu W J, Xie L, et al. Rolling force prediction of hot rolled strip by graph convolutional networks [J]. Iron and Steel, 2023, 58 (3): 89-96, 127.
- [13] 欧阳福莲, 王俊, 周杭霞. 基于改进迁移学习和多尺度 CNN-BiLSTM-Attention 的短期电力负荷预测方法 [J]. 电力系统保护与控制, 2023, 51 (2): 132-140.
- Ouyang F L, Wang J, Zhou H X. Short-term power load forecasting method based on improved hierarchical transfer learning and multi-scale CNN-BiLSTM-Attention [J]. Power System Protection and Control, 2023, 51 (2): 132-140.
- [14] 那峙雄, 孙涛, 来广志, 等. 多尺度特征融合的光伏电站故障诊断 [J]. 计算机工程与应用, 2022, 58 (10): 300-308.
- Na Z X, Sun T, Lai G Z, et al. Fault diagnosis for photovoltaic power station by multi-scale features fusion [J]. Computer Engineering and Applications, 2022, 58 (10): 300-308.
- [15] Li M T, Lu Y, Cao S X, et al. A hyperspectral image classification method based on the nonlocal attention mechanism of a multi-scale convolutional neural network [J]. Sensors, 2023, 23 (6): 3190.
- [16] 梁涛, 陈春宇, 谭建鑫, 等. 基于多方面特征提取和迁移学习的风速预测 [J]. 太阳能学报, 2023, 44 (4): 132-139.
- Liang T, Chen C Y, Tan J X, et al. Wind speed prediction based on multiple feature extraction and transfer learning [J]. Acta Energiae Solaris Sinica, 2023, 44 (4): 132-139.
- [17] Md Rashedul Islam, Momotaz Begum, Md Nasim Akhtar. Recursive approach for multiple step-ahead software fault prediction through long short-term memory (LSTM) [J]. Journal of Discrete Mathematical Sciences and Cryptography, 2022, 25 (7): 2129-2138.
- [18] Jörges C, Berkenbrink C, Stumpe B. Prediction and reconstruction of ocean wave heights based on bathymetric data using LSTM neural networks [J]. Ocean Engineering, 2021, 232: 109046.
- [19] 贾睿, 杨国华, 郑豪丰, 等. 基于自适应权重的 CNN-LSTM-MGRU 组合风电功率预测方法 [J]. 中国电力, 2022, 55 (5): 47-56, 110.
- Jia R, Yang G H, Zheng H F, et al. Combined wind power prediction method based on CNN-LSTM&GRU with adaptive weights [J]. Electric Power, 2022, 55 (5): 47-56, 110.

《锻压技术》杂志征稿简则

1 征稿范围

《锻压技术》(月刊)于 1958 年创刊,由中国机械总院集团北京机电研究所有限公司和中国机械工程学会塑性工程分会共同主办,是学会会刊。《锻压技术》是全国中文核心期刊,被以下检索系统收录:中文核心期刊要目总览(北京大学)、中国科学引文数据库(CSCD)、中国科技期刊引证报告(核心版, CJCRC)、中国学术期刊文摘数据库(核心版, CSAD-C)、中国学术期刊文摘数据库(英文版)、中国学术期刊综合评价数据库、中国学术期刊(光盘版)、中国知网、万方数字化期刊群、RCCSE 中国核心学术期刊、美国剑桥科学文摘(CSA)、美国化学文摘(CA)、日本科学技术振兴机构数据库(JST)、俄罗斯文摘杂志(AJ)等。

《锻压技术》主要报道金属塑性成形理论、工艺与装备,模具设计与制造技术、材料与成形性能、工业加热技术及设备、摩擦与润滑、测试技术、计算机应用、标准等方面的科研成果、实验研究、现场经验、技术革新等,同时,还辟有综合评述、专题讲座及行业信息等栏目。

2 来稿格式及要求

(1) 摘要选用小 5 号字,正文选用 5 号字,单倍行距;页面设置选用 A4 纸,上下左右页边距均选用 2 cm。

(2) 格式(按下列顺序排列,要求内容齐全)

● 论文的中文题目(不超过 30 字)、作者姓名、单位的全称(应包括院、系、科室等二级单位)、省名、城市名、邮政编码。

● 中文摘要:约 300 字,主要表达文章中有创新意义的内容,应含有研究目的、过程和方法、结果、结论 4 个层次;摘要中不要重复题目中已经表述过的信息,也不使用评论性语言。

● 中文关键词(5 个以上),中图分类号 1~2 个(参见《中国图书馆分类法(第四版)》一书)。

● 论文的英文题目、作者姓名(如 Zhang Yahong)、单位的全称(不得用缩写,应包括院、系、科室等二级单位)、城市名、邮政编码、国家名。

● 英文摘要:务必与中文摘要完全对应;摘要中涉及文章研究、阐述、设计、试验等内容时宜选用过去时、被动语态撰写(例如: A die was designed……),结果、结论宜选用一般现在时撰写(例如: The results show that……),不要使用“ The paper studies……”或“ The author studies……”这类语句。

● 英文关键词(5 个以上),要求与中文关键词完全对应。

● 首页页脚需注明以下内容:

收稿日期:年-月-日(例如: 2007-01-01);修订日期:此项可空缺,由编辑部填写

基金项目:省部以上基金资助项目及批准号(此项非常重要,请勿遗漏)

作者简介:第一作者姓名(出生年—),性别,学位,职称

E-mail: xx@xx

通讯作者:姓名(出生年—),性别,学位,职称(第一作者不是通讯作者时,请增加此项。)

E-mail: xx@xx

● 正文的“引言”部分不编号,亦不列出“引言”二字,直接陈述即可;一级标题用“1, 2, ……”排序;二级标题用“1.1, 1.2, ……”, 2.1, 2.2, ……排序;三级标题用“1.1.1, 1.1.2, ……”排序。

● 图片、表格、公式、定理等的序号均要按其 在正文中引用、的顺序,分别用阿拉伯数字顺序编码,例如:图 1、图 2……,表 1、表 2……。

(下转第 183 页)