

基于 SSAE-LSTM 模型的冷连轧机扭振预测

张瑞成, 刘力菲, 梁卫征

(华北理工大学 电气工程学院, 河北 唐山 063210)

摘要: 轧机振动预测模型性能依赖于从输入变量中提取的特征。针对冷连轧机振动数据样本大、非线性强的特点, 且在时间上具有前后依赖关系, 提出了一种基于 SSAE-LSTM 的轧机扭振预测方法。首先, 对于同种参数数值差异较小、关系表征不明显的轧制过程参数, 使用栈式稀疏自编码 (SSAE) 网络进行无监督自适应特征提取, 挖掘生产数据的深层次特征。然后, 利用长短时记忆 (LSTM) 网络在处理时间序列上的优势, 将 SSAE 网络提取到的深层特征作为预测模型的输入, 将旋角加速度作为输出, 建立基于 LSTM 的轧机扭振预测模型。仿真结果表明: SSAE-LSTM 模型的预测精度达 98.5%, 与 RNN 模型和 LSTM 模型相比, 预测精度分别提高了 24.8% 和 12.2%, 验证了该方法的有效性, 为实时预测轧机扭振状态提供了参考。

关键词: 轧机; 扭转振动; 振动预测; 特征提取; 栈式稀疏自编码; 长短时记忆网络

DOI: 10.13330/j.issn.1000-3940.2023.04.025

中图分类号: TG335

文献标志码: A

文章编号: 1000-3940 (2023) 04-0193-06

Torsional vibration prediction on tandem cold rolling mill based on SSAE-LSTM

Zhang Ruicheng, Liu Lifei, Liang Weizheng

(College of Electrical Engineering, North China University of Science and Technology, Tangshan 063210, China)

Abstract: The performance of rolling mill vibration prediction model depends on the features extracted from input variables. Therefore, aiming at the characteristics of large sample size and strong nonlinearity for the vibration data of tandem cold rolling mill, and the forward and backward dependencies in the time, a prediction method of rolling mill torsional vibration based on SSAE-LSTM was proposed. Firstly, for the rolling process parameters with small numerical differences and indistinct relationship representation of the same parameters, a stacked sparse autoencoder (SSAE) network was used for unsupervised adaptive feature extraction to mine the deep-level features of production data. Then, taking the advantage of long short-term memory (LSTM) network in dealing with time series, the deep-level features extracted by SSAE network were used as the input of the prediction model, and the rotational angular acceleration was used as the output to establish the rolling mill torsional vibration prediction model based on LSTM. The simulation results show that the prediction accuracy of SSAE-LSTM model is 98.5%. Compared with RNN model and LSTM model, the prediction accuracy of SSAE-LSTM model is improved by 24.8% and 12.2% respectively, and the validity of the method is verified, which provides the reference for the real-time prediction of the rolling mill torsional vibration state.

Key words: rolling mill; torsional vibration; vibration prediction; feature extraction; stacked sparse autoencoder; long short-term memory network

随着钢铁工业的发展, 高速连轧机作为复杂的大机电液一体化设备, 轧制工序复杂, 机械设备众多, 生产过程中钢材跑偏、轧机振动等问题频出^[1], 特别是轧机轴系扭转振动造成的板材表面振纹、轧辊断裂、损坏等生产事故频出。因此, 对冷连轧机的扭

振现象进行研究具有重要意义。从 20 世纪 80 年代至今, 专家学者们主要从机理角度对扭振问题进行了大量理论分析及研究^[2-8], 然而, 轧机作为复杂的机电液一体化设备, 设备集成化程度高, 以及复杂的润滑条件促使该系统具有很强的非线性耦合特性, 因此, 建立轧机扭振力学模型的过程中提出大量假设及忽略某些因素, 使得其不能精确判断扭振的发生。

近年来, 随着机器学习、数据分析等技术的发展, 轧制过程监控、快速故障诊断和轧制工艺参数优化成为研究重心, 已有多位专家学者采用数据驱动的方法对机械性能预测和故障诊断进行了初步研究^[9-12]。

数据驱动模型在连轧机组的很多方面已经得到应用, 但关于扭振预测的研究较少, 因此, 提出了一种

收稿日期: 2022-06-28; 修订日期: 2022-10-02

基金项目: 河北省自然科学基金资助项目 (F2018209201); 唐山市科技局科技计划项目 (22130213G); 河北省省属高校基本科研业务费资助项目 (JQN2021021)

作者简介: 张瑞成 (1975-), 男, 博士, 教授

E-mail: rchzhang@126.com

通信作者: 梁卫征 (1982-), 女, 硕士, 副教授

E-mail: 709010346@qq.com

基于数据驱动方法的扭振预测新思路：构建一种冷连轧机扭振的监测方法，针对多变量、强耦合的非线性 PDA 数据，使用栈式稀疏自编码（Stacked Sparse Autoencoder, SSAE）网络提取特征，并将长短时记忆网络（Long Short-term Memory Networks, LSTM）应用于扭振预测。

1 SSAE-LSTM 模型构建

1.1 栈式稀疏自编码

自编码器（Autoencoder, AE）是典型的 3 层前向无监督学习神经网络，主要包括编码阶段和解码阶段，训练目标是保证输出重构值与输入数据尽可能相同，可描述为：

编码过程：

$$\mathbf{h} = \sigma(\mathbf{W}_1 \mathbf{X} + \mathbf{b}_1) \quad (1)$$

解码过程：

$$\mathbf{X}' = \sigma(\mathbf{W}_2 \mathbf{h} + \mathbf{b}_2) \quad (2)$$

式中： \mathbf{h} 为中间向量； σ 为激活函数； \mathbf{X} 为 n 维的输入向量， $\mathbf{X} = (X_1, X_2, \dots, X_n)$ ； \mathbf{X}' 为 n 维的输出向量， $\mathbf{X}' = (X'_1, X'_2, \dots, X'_n)$ ； \mathbf{W}_1 、 \mathbf{b}_1 分别为编码层权重矩阵和偏差向量； \mathbf{W}_2 、 \mathbf{b}_2 分别为解码层权重矩阵和偏差向量，使用 Sigmoid 函数作为激活函数。

$$\sigma = \frac{1}{1 + e^{-x}} \quad (3)$$

式中： x 为定义变量，此处 $x = \mathbf{W}_2 \mathbf{h} + \mathbf{b}_2$ 。

经过不断调整训练参数 \mathbf{W} 、 \mathbf{b} ，使得输入数据 \mathbf{X} 和输出重构值 \mathbf{X}' 之间的误差 $J_{AE}(\mathbf{W}, \mathbf{b})$ 最小化。

$$J_{AE}(\mathbf{W}, \mathbf{b}) = \frac{1}{2} \|\mathbf{X}' - \mathbf{X}\|^2 \quad (4)$$

由于过多的神经单元会导致过拟合，因此引入稀疏惩罚项，对隐含层进行稀疏性约束，构成稀疏

自编码网络，从而提高 AE 的特征表达能力^[13]。

$$J_S(\mathbf{W}, \mathbf{b}) = \sum_{i=1}^D \rho \log \frac{\rho}{\hat{\rho}_i} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_i} \quad (5)$$

式中： $J_S(\mathbf{W}, \mathbf{b})$ 为系数惩罚项； D 为隐含层神经元个数； ρ 为稀疏性参数，趋近于 0； $\hat{\rho}_i$ 为第 i 个神经元的平均激活量，稀疏自编码 SAE 通过限制 $\hat{\rho}_i = \rho$ 以实现其惩罚方式，SAE 的整体代价函数 $J_{\text{Spares}}(\mathbf{W}, \mathbf{b})$ 即为：

$$J_{\text{Spares}}(\mathbf{W}, \mathbf{b}) = J_{AE}(\mathbf{W}, \mathbf{b}) + \beta J_S(\mathbf{W}, \mathbf{b}) \quad (6)$$

式中： β 为稀疏正则项权值。

在表征学习中，多层次表示会提取更有用的特征，因此，结合多层稀疏自编码网络逐层堆叠形成无监督学习模型，提取每层 SAE 的编码输出作为下一层 SAE 的输入，逐层提取更高阶的特征，结构如图 1 所示。




图 1 栈式稀疏自编码网络拓扑结构

Fig. 1 Topology structure of SSAE network

1.2 LSTM 模型

长短时记忆网络（Long Short-term Memory Networks, LSTM）解决了传统循环神经网络（Recurrent Neural Network, RNN）的梯度弥散、梯度爆炸问题，在 RNN 的基础上增加了一组输入和输出，具有优秀的时间序列预测性能，LSTM 单元结构由细胞状态和遗忘门、输入门、输出门 3 种门控单元共同组成^[14]，原理如图 2 所示。

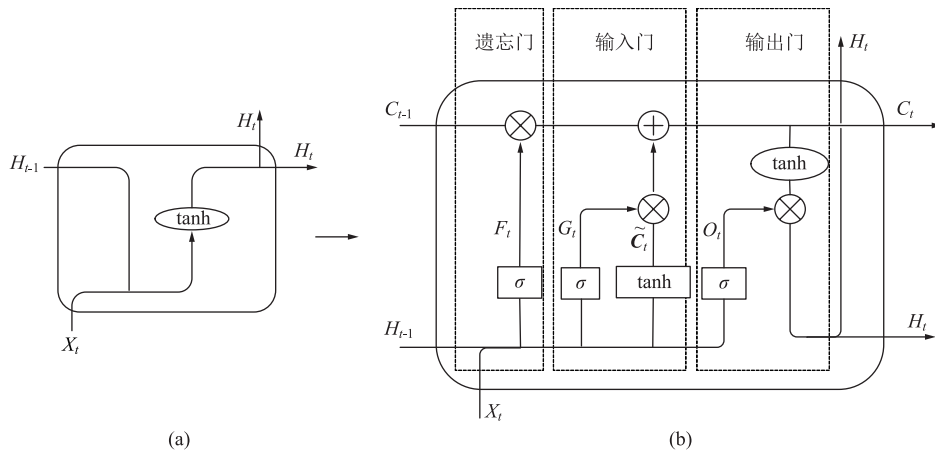


图 2 RNN 单元结构 (a) 与 LSTM 单元结构 (b)

Fig. 2 Unit structures of RNN (a) and LSTM (b)

(1) LSTM 的输入 X_t , 输入至遗忘门中计算输入信息的保留比重, 利用 Sigmoid 激活函数得到遗忘门的输出 F_t 。

$$F_t = \sigma(W_f \cdot [H_{t-1}, X_t] + b_f) \quad (7)$$

式中: W_f 、 b_f 分别为遗忘门的权重矩阵和偏置矩阵; t 为输入的这一时刻; H_{t-1} 为上一时刻的隐含层输出。

(2) 遗忘后的新信息传入输入门进行更新, 更新程度经由 Sigmoid 层和 tanh 层共同决定, 其中 Sigmoid 层计算新信息的获取范围 G_t , 双曲正切函数 tanh 生成存储所学新信息的候选值向量 \tilde{C}_t :

$$G_t = \sigma(W_s \cdot [H_{t-1}, X_t] + b_s) \quad (8)$$

$$\tilde{C}_t = \tanh(W_c \cdot [H_{t-1}, X_t] + b_c) \quad (9)$$

$$\tanh x = \frac{(1 - e^{-x})}{(1 + e^{-x})} \quad (10)$$

式中: W_s 、 b_s 分别为 Sigmoid 层的权重矩阵和偏置矩阵; W_c 、 b_c 分别为 tanh 层的权重矩阵和偏置矩阵; x 为定义变量, 此处 $x = W_c \cdot [H_{t-1}, X_t] + b_c$ 。

(3) 遗忘门和输入门的输出值进行合并, 更新细胞状态 C_t 。

$$C_t = F_t C_{t-1} + G_t \tilde{C}_t \quad (11)$$

(4) 信息流入输出门, 再次经由 Sigmoid 函数和 tanh 函数生成新的隐含层 H_t , 即为网络预测输出。

$$O_t = \sigma(W_o \cdot [H_{t-1}, X_t] + b_o) \quad (12)$$

$$H_t = O_t \cdot \tanh(C_t) \quad (13)$$

式中: O_t 为输出门的输出; W_o 、 b_o 分别为输出门的权重矩阵和偏置矩阵。

1.3 SSAE-LSTM 模型

轧机进行工业生产时, 设备持续快速运行, 且轧机振动状态与历史时刻的输入、输出紧密相关。因此, 为找到轧制过程中采集的设备状态、工艺参数等实时监测数据的“优良特征表示”, 并对时间序列上工作辊旋转角加速度幅值进行预测, 提出了一种基于 SSAE-LSTM 的轧机扭振预测模型, 具体步骤如图 3 所示。

(1) 标准化处理: 由于原始数据各参数的量纲尺度相差较大, 网络训练时会影响迭代速度, 甚至过于依赖量纲较大的参数, 因此, 对采集的电流等轧制过程参数进行标准化处理, 标准化方法如式 (14) 所示:

$$z' = \frac{z - \mu}{\omega} \quad (14)$$

式中: z' 为标准化后的数据; z 为待标准化序列; μ 为序列 z 的均值; ω 为序列 z 的标准差。

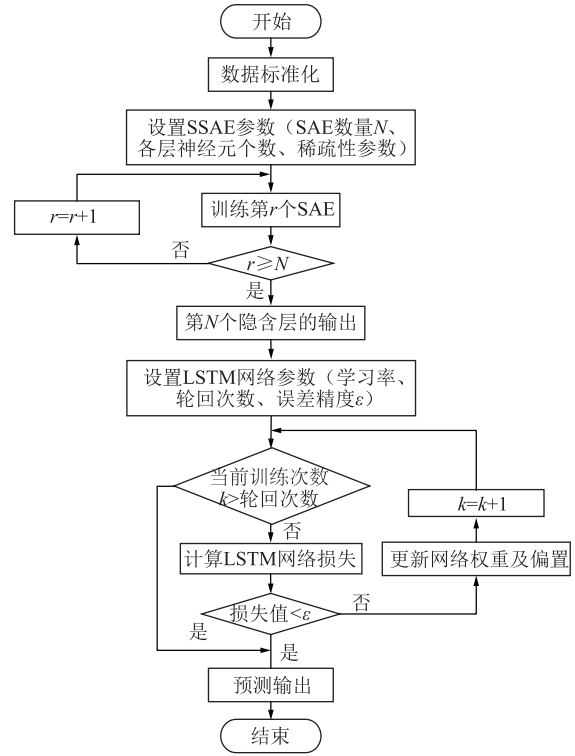


图 3 SSAE-LSTM 模型的预测流程图

Fig. 3 Prediction flow chart of SSAE-LSTM model

(2) SSAE 特征学习: 将标准化后的轧制过程参数输入 SAE 进行无监督的特征学习, 提取稀疏性特征表达, 堆叠多层 SAE 逐层学习, 获取更有益的多层次特征表达。

(3) 建立 LSTM 模型: 将电流、入口厚度等轧制过程参数作为输入, 上工作辊旋转角加速度作为预测输出, 建立 LSTM 轧机扭振预测模型。

(4) 性能评价指标: 采用平均绝对误差 MAE、均方根误差 RMSE、决定系数 R^2 这 3 种判定方法衡量预测值与实测值的误差, 公式如式 (15) ~ 式 (17) 所示:

$$MAE = \frac{1}{m} \sum_{j=1}^m |y_j - \hat{y}_j| \quad (15)$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{j=1}^m |y_j - \hat{y}_j|^2} \quad (16)$$

$$R^2 = 1 - \frac{\sum_{j=1}^m (y_j - \hat{y}_j)^2}{\sum_{j=1}^m (y_j - \bar{y}_j)^2} \quad (17)$$

式中: m 为测试集样本数; y_j 为实测值; \hat{y}_j 为模型预测值; \bar{y}_j 为实测值的平均值。

2 仿真分析

为了捕捉轧机发生扭振时的工艺参数等动态规

律,发现轧机的扭振特征,利用现代测试手段,在某冷轧厂某型号的冷连轧机的上工作辊安装加速度传感器,测量上工作辊旋转角加速度^[15],并从轧制过程监测计算机中提取对应时刻的生产工艺参数,得到如表 1 所示的 4665 组冷连轧机运行实测数据,上工作辊旋转角加速度信号曲线图如图 4 所示。

表 1 部分原始数据
Table 1 Partial raw data

样本点序号	电流 I/A	入口厚度 h_0/mm	出口厚度 h_1/mm	来料硬度 K/HB	前张力 $t_a/(\text{N} \cdot \text{mm}^{-2})$	后张力 $t_b/(\text{N} \cdot \text{mm}^{-2})$	旋转角加速度 $\ddot{\theta}/(\text{rad} \cdot \text{s}^{-2})$
1	1723.956	4.0018	3.2567	684.854	105.483	213.329	-0.0094
2	1724.945	4.0023	3.2584	686.479	105.603	213.047	-0.0133
3	1726.319	4.0029	3.2607	688.102	105.771	212.656	-0.1097
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
4663	1730.440	4.0042	3.2654	691.342	106.107	211.873	6.9812
4664	1732.304	4.0048	3.2677	693.535	106.274	211.482	7.2068
4665	1734.167	4.0057	3.2677	695.721	106.502	210.951	7.4244




图 4 上工作辊旋转角加速度曲线

Fig. 4 Rotation angular acceleration curve of upper work roll

将电流 I 、入口厚度 h_0 、出口厚度 h_1 、来料硬度 K 、前张力 t_a 、后张力 t_b 设定为预测输入,上工作辊旋转角加速度 $\ddot{\theta}$ 作为预测输出,7 种参数各 4665 组数据,将其中前 3231 组数据用作训练集,后 1434 组数据作为测试集。

经交叉实验验证,模型具体参数设置为: PDA 数据特征提取时建立两层 SSAE 网络,其中输入层维度为 6,隐含层单元数分别为 8 和 10,输出层维度为 6,稀疏正则项权值 $\beta = 4$,稀疏性参数 $\rho = 0.05$,学习率为 0.01;建立 LSTM 模型时,设定隐含层包含 8 个 LSTM 记忆单元,循环次数为 300,初始学习率为 0.005,在第 151 轮以后将学习率降为 0.01。

图 5 为原始数据直接训练 RNN 模型的预测结果,由于 RNN 模型只考虑最近的状态,长时间序列后部的梯度很难反向传播到前面的序列,从图 5 中




图 5 RNN 模型预测结果与实测值对比图

Fig. 5 Comparison diagram between prediction result of RNN model and actual test value

可以明显看出,预测结果较差,后期的预测值整体大幅度低于实测值。

使用 LSTM 网络对原始数据进行预测,结果如图 6 所示。加入门控记忆单元的 LSTM 网络有效地解决了 RNN 模型只能处理短期依赖的问题,序列后期的预测结果已经有明显地改善。

图 7 为 SSAE-RNN 模型的预测结果,从图 7 中可以看出,RNN 网络对经过 SSAE 特征学习后,数据整体趋势预测较为准确,但在旋转角加速度的峰值拐点处的预测效果稍有不足。

图 8 为 SSAE-LSTM 模型的预测结果,可以看出,通过使用 SSAE 稀疏性学习得到了特征更加明显的数据,降低了预测模型的输入信息的复杂程度,使得 LSTM 模型在峰值拐点处的预测效果也有了明显改善,与 RNN 模型、LSTM 模型、SSAE-RNN 模型相




图 6 LSTM 模型预测结果与实测值对比图

Fig. 6 Comparison diagram between prediction result of LSTM model and actual test value




图 7 SSAE-RNN 模型预测结果与实测值对比图

Fig. 7 Comparison diagram between prediction result of SSAE-RNN model and actual test value




图 8 SSAE-LSTM 模型预测结果与实测值对比图

Fig. 8 Comparison diagram between prediction result of SSAE-LSTM model and actual test value

比, SSAE-LSTM 模型的预测精度最高, 在峰值处的预测效果最好。

为了进一步验证提出的 SSAE-LSTM 模型的预测性能和优势, 与 RNN 模型、LSTM 模型、SSAE-RNN 模型 3 种轧机扭振预测模型的预测结果进行了对比分析, 具体模型预测指标如表 2 所示。

表 2 不同轧机扭振预测模型的性能指标对比

Table 2 Comparison of performance indicators for different torsional vibration prediction models of rolling mill

模型	R^2	MAE	RMSE
RNN	0.737	1.768	2.118
LSTM	0.861	1.358	1.973
SSAE-RNN	0.976	0.813	1.309
SSAE-LSTM	0.985	0.702	0.971

表 2 中, 决定系数 R^2 表示线性相关程度, R^2 越接近 1, 模型拟合度越高; 平均绝对误差 MAE 为预测值与实测值绝对误差的平均值, 均方根误差 RMSE 表示预测值与实测值之间残差的样本标准差, MAE 和 RMSE 用来比较同一个时间序列、不同方法得到的不同预测结果, 误差越小, 说明该方法的预测能力越强。由表 2 可以看出, LSTM 模型优于 RNN 模型, 解决了 RNN 模型梯度易弥散现象; 经过 SSAE 特征学习后的模型预测性能均优于单一模型, SSAE-LSTM 模型的预测精度达到了 98.5%, 可以比较好地实现主传动系统上工作辊旋转角加速度的精确预测。

3 结论

(1) 经过栈式稀疏自编码网络特征学习后, 解决了某些同种参数间数值差距不大、关系表征不明显的问题, 提取出各数组之间的深层次特征, 使得 SSAE-LSTM 模型的预测精度高达 98.5%, SSAE-RNN 模型的精度也达 97.2%。使用轧制过程原始数据时, RNN 模型、LSTM 模型的预测精度仅为 73.7%、86.1%。

(2) 利用 SSAE-LSTM 模型强非线性映射能力, 解决了以往振动预测过程中需要先验知识和准确数学模型的问题, 通过对实际生产数据的分析和学习, 即可对冷连轧机主传动系统扭振进行预测。

参考文献:

[1] 张义方, 肖彪, 闫晓强. 多源激励下冷连轧 F5 轧机振动问题研究 [J]. 工程力学, 2022, 39 (2): 235-243.
Zhang Y F, Xiao B, Yan X Q. Research on the vibration of cold

- rolling mill F5 under multi-source excitation [J]. Engineering Mechanics, 2022, 39 (2): 235-243.
- [2] 侯福祥, 张杰, 曹建国, 等. 带钢冷轧机振动问题的研究进展及评述 [J]. 钢铁研究学报, 2007, 19 (10): 6-10.
Hou F X, Zhang J, Cao J G, et al. Review of chatter studies in cold rolling [J]. Journal of Iron and Steel Research, 2007, 19 (10): 6-10.
- [3] Zheng Y J, Shen G X, Li Y G, et al. Spatial vibration and its numerical analytical method of four-high rolling mills [J]. Journal of Iron and Steel Research International, 2014, 21 (9): 837-843.
- [4] 时培明, 夏克伟, 刘彬, 等. 多自由度轧机传动系统非线性非主共振扭振特性 [J]. 振动与冲击, 2015, 34 (12): 35-41.
Shi P M, Xia K W, Liu B, et al. Non-main resonance characteristics of nonlinear torsional vibration of rolling mill's multi-degree-of-freedom main drive system [J]. Journal of Vibration and Shock, 2015, 34 (12): 35-41.
- [5] Mosayebi M, Zarrinkolah F, Farmanesh K. Calculation of stiffness parameters and vibration analysis of a cold rolling mill stand [J]. Int. J. Adv. Manuf. Technol., 2017, 91: 4359-4369.
- [6] 彭荣荣. 液压缸非线性作用下轧机辊系振动特性及机理研究 [J]. 锻压技术, 2022, 47 (11): 172-178.
Peng R R. Research on vibration characteristics and mechanism for rolling mill rolls under nonlinear action of hydraulic cylinder [J]. Forging & Stamping Technology, 2022, 47 (11): 172-178.
- [7] 王桥医, 崔明超, 王瀚, 等. 基于辊系多模态模式的连轧机机架间耦合振动系统模型的建立及仿真分析 [J]. 中南大学学报: 自然科学版, 2020, 51 (10): 2834-2843.
Wang Q Y, Cui M C, Wang H, et al. Establishment and simulation analysis of coupled vibration system model between stands of tandem rolling mills based on rollers multi-modal mode [J]. Journal of Central South University: Science and Technology, 2020, 51 (10): 2834-2843.
- [8] 李聪, 张义方, 童靳于, 等. 1580 热连轧机 F2 轧机异常振动问题分析 [J]. 噪声与振动控制, 2021, 41 (5): 103-108.
Li C, Zhang Y F, Tong J Y, et al. Analysis of abnormal vibration of F2 mill in the 1580 hot strip mill set [J]. Noise and Vibration Control, 2021, 41 (5): 103-108.
- [9] 彭艳, 张明, 刘宣亮, 等. 基于数据驱动的轧机振动预测研究 [A]. 中国金属学会. 第十一届中国钢铁年会论文集——S18. 冶金自动化与智能管控 [C]. 北京: 中国金属学会, 2017.
Peng Y, Zhang M, Liu X L, et al. Research on rolling mill vibration prediction based on data drive [A]. Chinese Society of Metals. Proceedings of the Eleventh China Iron and Steel Annual Conference-S18. Metallurgical Automation and Intelligent Control [C]. Beijing: China Institute of Metals, 2017.
- [10] Pian J, Tamanna M R, Abdulmajid A U. Study on HS-RNN in vibration prediction of mechanical spindle [A]. 2021 33rd Chinese Control and Decision Conference (CCDC) [C]. Kunming, 2021.
- [11] 李福进, 刘尚瑜, 史涛. LSTM-RNN 在连铸下渣预测系统中的应用 [J]. 机械设计与制造, 2022, (1): 181-183.
- Li F J, Liu S Y, Shi T. Application of LSTM-RNN in continuous casting slag prediction system [J]. Machinery Design & Manufacture, 2022, (1): 181-183.
- [12] 刘阳, 邵志英, 周晓敏, 等. 工业数据驱动下薄板冷轧颤振的 LSTM 智能预报 [J]. 机械工程学报, 2020, 56 (11): 121-131.
Liu Y, Gao Z Y, Zhou X M, et al. Industrial data-driven intelligent forecast for chatter of cold rolling of thin strip with LSTM recurrent neural network [J]. Journal of Mechanical Engineering, 2020, 56 (11): 121-131.
- [13] 李世银, 朱媛, 刘江, 等. 基于 SAE-RF 的三维 UWB 室内定位方法研究 [J]. 传感器与微系统, 2021, 40 (8): 46-49.
Li S Y, Zhu Y, Liu J, et al. Research on 3D UWB indoor positioning method based on SAE-RF [J]. Transducer and Microsystem Technologies, 2021, 40 (8): 46-49.
- [14] 邓丽, 邹群勇, 杨水荣. 融合 SSAE 深度特征学习和 LSTM 网络的 PM_{2.5} 小时浓度预测 [J]. 环境科学学报, 2020, 40 (9): 3422-3434.
Deng L, Wu Q Y, Yang S R. Use of stack sparse auto-encoder (SSAE) deep feature learning and long short-term memory (SSAE-LSTM) neural network for the prediction of hourly PM_{2.5} concentration [J]. Acta Scientiae Circumstantiae, 2020, 40 (9): 3422-3434.
- [15] 米凯夫, 张杰, 曹建国, 等. 基于小波和小波分形的冷连轧机振动识别方法 [J]. 北京科技大学学报, 2013, 35 (8): 1064-1071.
Mi K F, Zhang J, Cao J G, et al. Vibration identification technology of tandem cold rolling mills based on wavelet and fractal analysis [J]. Journal of University of Science and Technology Beijing, 2013, 35 (8): 1064-1071.

警惕不法网站，保障投稿安全

近期，本刊接到多名作者投诉，网络上出现冒充《锻压技术》杂志官方网站的伪网站，如 www.dyjszz.cn，这些网站盗用本杂志官网内容及相关行业信息，误导和欺骗广大投稿作者，骗取文章版面费、套取作者文章及个人信息，侵犯了广大作者的切身权益。

特此声明，本刊唯一官方网站为 www.fstjournal.net，投稿方式为网站注册登录投稿，不接受邮箱投稿。请作者投稿时务必认准杂志官方网站，谨防受骗。

本刊郑重警告伪网站相关人员尽快停止违法行为，否则将严肃对待，并将运用一切法律手段维护本刊的权利。

请广大读者协助本刊监督网络上的不法行为，一经发现，请联系本刊，本刊将及时处理，共同努力营造良好的期刊网络氛围。

《锻压技术》杂志联系方式：fst@263.net；010-62920652。

《锻压技术》编辑部