

基于时域卷积网络的精轧出口厚度预测^①

杨萍萍¹, 马亮²

(1.北京科技大学 高等工程师学院,北京 100083; 2.北京科技大学 自动化学院,北京 100083)

摘要:以精轧过程为研究对象,引入时域卷积网络算法,构建了基于时域卷积网络的精轧出口厚度预测模型。利用时域卷积网络模型提取精轧过程时序数据的特征信息,通过优化模型结构和参数,提升精轧出口厚度预测性能。实际钢种数据集仿真实验结果表明,相较于传统方法,本文所提出的时域卷积网络算法在均方根误差、平均绝对百分比误差及决定系数等评价指标方面存在较大优势,可为现场工程师提供重要的决策信息。

关键词:带钢; 热轧; 厚度预测; 时域卷积网络; 精轧过程; 时序数据; 特征提取; 均方根误差

中图分类号: TG335; TP29

文献标识码: A

doi: 10.3969/j.issn.0253-6099.2024.01.030

文章编号: 0253-6099(2024)01-0138-05

Thickness Prediction for Precision Rolling Exit Based on Time Domain Convolutional Network

YANG Pingping¹, MA Liang²

(1.School of Advanced Engineering, University of Science and Technology Beijing, Beijing 100083, China; 2.School of Automation and Electrical Engineering, University of Science and Technology Beijing, Beijing 100083, China)

Abstract: As for the precision rolling process, a thickness prediction model was constructed for precision rolling exit by introducing a time domain convolutional network algorithm. The feature information of time-series data of the precision rolling process was extracted by using this time-domain convolutional network model, and the prediction performance of the precision rolling exit thickness was improved by optimizing the structure and parameters of the model. The simulation results of the actual steel dataset show that the proposed time-domain convolutional network algorithm, compared to traditional methods, has significant advantages in evaluation indicators, such as root mean square error, average absolute percentage error, and coefficient of determination, which can provide critical information for decision of on-site engineers.

Key words: strip steel; hot rolling; thickness prediction; time-domain convolutional network; precision rolling process; time-series data; feature extraction; root mean square error

随着钢铁工业的发展,钢铁生产过程及设备趋向于复杂化和大型化,对生产运行的安全性和质量的稳定性要求越来越高。由于传感器及网络控制技术等原因,大部分质量变量难以实时监测和反馈。软测量技术成为解决上述问题的有效方法^[1-6],基于软测量的质量预测模型主要针对难以测量的关键质量变量,通过利用与其相关的易于测量的辅助变量建立软测量模型,从而实现关键质量变量的预测。

与基于机理模型的软测量建模方法相比,基于数据驱动的方法利用历史数据进行回归建模,减少了建模时间和成本,是当前的主流方法,其主要分为统计学习方法^[7-9]、机器学习方法^[10-12]及深度学习方法^[13-15]等,能充分提取工业过程变量和质量变量之间的关系,实现质量预测,具有良好的扩展性和自学习能力。然而,大多数方法在训练过程中需要采取正则化和优化策略避免过拟合,影响了质量预测性能。

① 收稿日期: 2023-09-08

基金项目: 国家自然科学基金(62003030)

作者简介: 杨萍萍(1986—),女,河北保定人,硕士,工程师,主要从事复杂工业系统建模、电工电子相关实验教学与管理等研究工作。
E-mail: yangpingping@ustb.edu.cn

通信作者: 马亮(1986—),男,黑龙江绥化人,博士,副教授,主要从事工业大数据分析及应用、工业过程产品质量预测等研究工作。
E-mail: liangma@ustb.edu.cn

基于此, 本文将时域卷积网络(temporal convolutional network, TCN)引入带钢热轧过程中的精轧出口厚度预测, 通过优化模型结构和参数, 提升精轧出口厚度预测性能, 并通过实际钢种的数据仿真与对比实验验证上述方法的可行性。

1 基于 TCN 的厚度预测架构

TCN 是卷积神经网络(convolutional neural networks, CNN)的改进与优化, 能有效提取时间序列中的关键质量特征, 适用于处理时序数据预测方面的问题^[16-18]。

1.1 TCN 算法原理

因果卷积是 TCN 中的一种卷积操作。为了确保在预测时不会依赖未来的信息, 使网络具有因果性质, 卷积核被看作过去的输入, 故其只在当前和过去的时间步上滑动, 不会涉及未来的时间步。根据这一约束, t 时刻卷积操作所依赖的数据只是 t 时刻及部分之前的数据。假设时序数据的输入为 $X = (x_0, x_1, \dots, x_t, \dots, x_T)$, 则在 t 时刻, 输出 y_t 可表示为:

$$y_t = f(\dots, x_{t-3}, x_{t-2}, x_{t-1}) \quad (1)$$

为了确保 TCN 的输入与输出维度相同, TCN 在一维卷积中使用零填充序列以保证前后层长度相同。同时, 为了让未来的信息不被泄露, t 时刻的输出只与之前的元素进行卷积。因果卷积的结构如图 1 所示, 每一层的黑色神经元只与上一层之前的神经元有关。




图 1 因果卷积结构示意图

感受野是神经网络中神经元对输入数据局部区域的感知范围, 其大小决定了神经网络对输入数据的感知范围和建模能力。为了保证输出信息只受过去信息的影响, TCN 在因果卷积的基础上引入了膨胀卷积:

$$F_t = \sum_{i=0}^{k-1} f(i) x_{t-di} \quad (2)$$

式中 $f(i)$ 为滤波器的信息; k 为滤波器的尺寸; d 为膨胀系数; $t-di$ 为过去的方向。

通过改变滤波器的尺寸和卷积层的层数, 可以有效调整感受野的大小和数量。图 2 为滤波器尺寸为 2, 扩张因子为 1、2 和 4 时的膨胀卷积结构。可以看

出, 加入膨胀卷积后, 输出可以接受的输入信息增多, 扩大了信息输入的感受野。




图 2 膨胀卷积结构示意图

在实际应用中, TCN 网络不断加深时, 模型可能会发生梯度消失, 影响模型稳定性。为了解决这个问题, 在 TCN 模型中引入残差网络模块, 如图 3 所示。在使用 TCN 进行时序特征提取时, 首先通过膨胀因果卷积、权重归一化和 ReLU 函数激活进行处理。这些操作有助于捕捉序列中的长期依赖关系和重要特征。同时, 为了解决梯度爆炸等问题, 引入了 Dropout 方法进行随机失活以减少过拟合风险。此外, 为了解决卷积结果与恒等映射之间维度不一致的问题, 引入了额外卷积层, 保证了特征的连续性和一致性, 避免了信息丢失和不匹配。

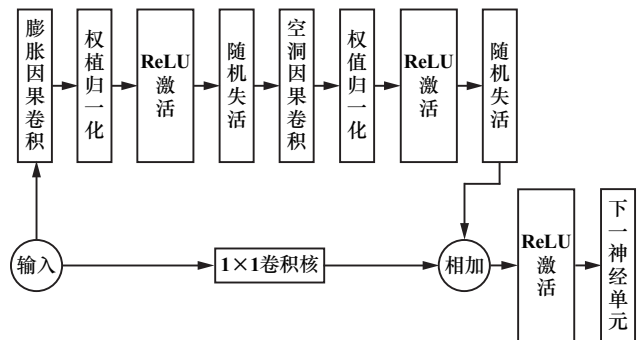


图 3 残差网络示意图

1.2 基于 TCN 的厚度预测

本文将 TCN 用于研究精轧出口厚度的预测, 所构建的基于 TCN 的厚度预测模型共有 4 层:

第 1 层为 TCN 层, 用于在时间序列维度上进行卷积操作。通过卷积操作, 提取输入序列厚度相关的特征表示。

第 2 层为全连接层, 使用 ReLU 激活函数。它的作用是将卷积层提取的厚度相关的特征进行组合和抽象, 以更好地捕捉输入数据的高级特征表示。

第 3 层为 Dropout 层, 用于减少模型的过拟合风险, 提高模型的泛化能力。

第4层为单神经元全连接层,用于执行输出,表示模型对厚度的预测值。

2 实验与结果分析

带钢热轧过程是一个典型的非线性、动态的复杂

工业过程。其生产线包括加热炉、粗轧、精轧、层流冷却等环节,如图4所示。精轧是整个热轧过程的核心环节。在精轧过程中,出口厚度是最重要的质量变量。准确的厚度预测可以帮助操作人员及时调整工艺参数,确保带钢的质量符合要求。

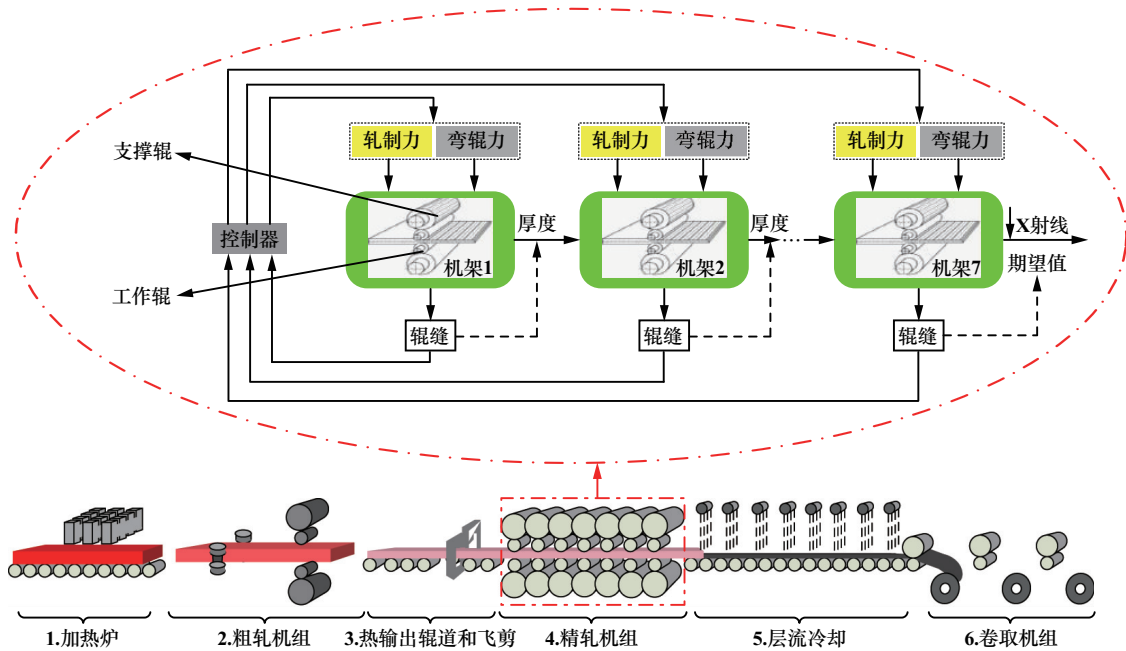


图4 带钢热轧生产线示意图

精轧机组通常由6~7个机架组成,每台机架主要由工作辊、支撑辊等部分构成,影响带钢出口厚度的因素通常包含辊缝、轧制力、弯辊力等。本文选择7个机架的辊缝、轧制力、弯辊力作为厚度预测的过程输入变量,其中第1机架无弯辊力,故共有20个过程输入变量。将精轧末机架的出口厚度作为厚度预测的质量变量,带钢热轧厚度预测的过程输入变量和质量变量分配情况如表1所示。

表1 过程及质量变量分配表

| 变量编号 | 变量类型 | 单位 | 描述 |
|-------|------|----|---------------------------------------|
| 1~7 | 过程变量 | mm | 第 <i>i</i> 机架的平均辊缝($i=1,2,\dots,7$) |
| 8~14 | 过程变量 | MN | 第 <i>i</i> 机架的轧制力($i=1,2,\dots$) |
| 15~20 | 过程变量 | MN | 第 <i>i</i> 机架的弯辊力($i=2,\dots$) |
| 21 | 质量变量 | mm | 精轧出口厚度 |

本文使用2个不同钢种的数据集,具体的数据集信息如表2所示。钢种1共有3990个样本数据,其平均出口厚度为3.949 mm;钢种2共有4400个样本数据,其平均出口厚度为2.697 mm。将2个钢种的所有样本分成训练集和验证集。训练集用于模型参数的学

习和训练,验证集用于选择最佳模型和优化模型的超参数配置。对于钢种1,选取500个数据作为验证集,3490个数据作为训练集;对于钢种2,选取600个数据作为验证集,3800个数据作为训练集。

表2 数据集信息

| 名称 | 总样本数 | 平均出口厚度/mm | 训练集样本数 | 验证集样本数 |
|-----|------|-----------|--------|--------|
| 钢种1 | 3990 | 3.949 | 3490 | 500 |
| 钢种2 | 4400 | 2.697 | 3800 | 600 |

2.1 模型评价指标

过程质量预测模型的性能一般依据测试样本集的预测输出结果进行预测效果评估。本文选用均方根误差(root mean square error, RMSE)、平均绝对百分比误差(mean absolute percentage error, MAPE)及决定系数(R^2)进行评价,其定义式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (3)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^m (\hat{y}_i - y_i)^2}{\sum_{i=1}^m (\bar{y}_i - y_i)^2} \quad (5)$$

式中 n 为测试集样本个数; \hat{y}_i 和 y_i 分别为第 i 个样本的预测值和实际值。

RMSE 和 MAPE 越小, 预测性能越好。 R^2 值与自变量和因变量之间的相关性成正比, R^2 越大, 自变量与因变量的相关性越高, 所得模型的效果越好。

2.2 参数选择与调整

划分完 2 个钢种数据集的训练集和验证集后, 选用 TCN 建模方法进行精轧出口厚度预测建模与预测。建立 TCN 模型时, 需要确定卷积核大小、TCN 层数、滤波器尺寸及扩张率。针对以上参数对 2 个数据集分别进行验证, 确定不同参数取值的变化对每次建立厚度预测模型的影响。此外, 测试了时间步长和迭代次数对参数拟合效果的影响。通过调整不同参数, 观察模型预测指标 RMSE 和 R^2 的变化, 获取最优参数。各个参数的选取结果如表 3 所示。

表 3 超参数设置

| 名称 | 卷积核大小 | TCN 层数 | 过滤器尺寸 | 迭代次数 | 时间步长 |
|------|-------|--------|-------|------|------|
| 钢种 1 | 3 | 1 | 32 | 140 | 25 |
| 钢种 2 | 3 | 1 | 64 | 140 | 20 |

2.3 仿真结果分析

根据 2 个钢种的数据集, 采用循环神经网络 (recurrent neural network, RNN)、门控循环单元 (gated recurrent unit, GRU) 和长短期记忆 (long short-term memory, LSTM) 对划分的训练集和测试集进行精轧出口厚度模型的建立和预测。2 个钢种的 4 种预测模型的评价指标如表 4 所示。从表 4 可以看出, 4 种方法中, TCN 方法在 2 个钢种的数据集上所得的各项预测评价指标均较好, 说明 TCN 模型的预测性能优异。

表 4 预测评价指标结果

| 预测方法 | 钢种 1 | | | 钢种 2 | | |
|------|-------|--------|-------|-------|--------|-------|
| | RMSE | MAPE/% | R^2 | RMSE | MAPE/% | R^2 |
| TCN | 0.796 | 0.013 | 0.954 | 0.765 | 0.021 | 0.925 |
| RNN | 1.004 | 0.015 | 0.942 | 0.862 | 0.025 | 0.915 |
| LSTM | 1.034 | 0.017 | 0.940 | 0.841 | 0.023 | 0.907 |
| GRU | 1.366 | 0.019 | 0.921 | 0.950 | 0.027 | 0.917 |

2 个钢种、4 种建模方法厚度预测结果折线图和散点图分别如图 5~8 所示。通过对比可以看出, TCN 曲线拟合程度最高, 采用 TCN 建模的样本点分布最集

中, 说明 TCN 的预测值与实际值极为接近, 预测精轧过程出口厚度时, TCN 法精度更高。




图 5 钢种 1 数据折线图




图 6 钢种 1 数据散点图

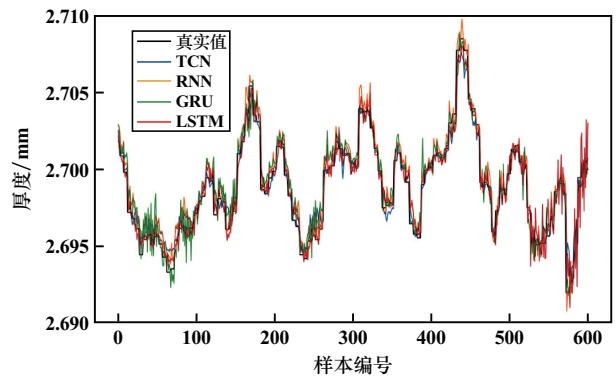


图 7 钢种 2 数据折线图

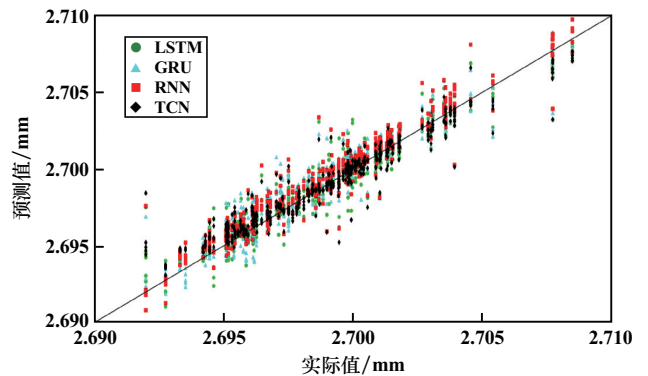


图 8 钢种 2 数据散点图

3 结 语

1) 通过合理的网络结构设计和参数设置,充分提取了时间序列中的关键质量特征,实现了带钢热轧过程的精轧出口厚度预测。

2) 通过仿真实验及对比分析,讨论了不同算法在质量预测性能上的异同,体现了所提出方法的有效性和实用性,可为现场工程师提供重要的参考信息。

3) 精轧过程数据具有复杂的多源异构及时空关联特性,使得质量预测问题具有挑战性。下一步将在已有研究基础上,充分考虑精轧过程数据的特性,研究融合多源异构和时空关联信息的质量预测方法。

参考文献:

- [1] 邵 健,何安瑞,陈雨来,等. 热轧智能工厂构架设计与实践:有形与无形的统一[J]. 中国冶金, 2022,32(1):1-10.
- [2] 蒋小平,雷佳玉,肖业祥. 基于软测量的水电机组功角在线测量的研究[J]. 仪表技术与传感器, 2022(8):108-114.
- [3] 何 坤,王 立. 中国钢铁工业生产能耗的发展与现状[J]. 中国冶金, 2021,31(9):26-35.
- [4] 马 亮,彭开香. 带钢热轧全流程质量建模与异常溯源的研究现状与展望[J]. 冶金自动化, 2022,46(6):16-24.
- [5] 孙 杰,汪龙军,任 辉,等. 轧制过程多工序指标建模及优化的研究现状与发展趋势[J]. 冶金自动化, 2022,46(2):57-64.
- [6] 邓怀勇,马 琴,陈国彬,等. 基于 AWOA 算法与 LSSVM 的主蒸汽流量软测量模型[J]. 仪表技术与传感器, 2018(12):78-82.

- [7] 李 浩,杨 敏,石向荣,等. 基于主曲线的软测量方法及其在精馏塔上的应用[J]. 化工学报, 2012,63(8):2492-2499.
- [8] 田 睿,李燕卿,刘占宁,等. 基于改进樽海鞘算法优化支持向量机的岩爆预测模型[J]. 矿冶工程, 2023,43(2):5-9.
- [9] 郭 磊,阎高伟,乔铁柱. 基于监督等距映射和支持向量回归的料位软测量[J]. 仪表技术与传感器, 2016(5):37-39.
- [10] 阳 俊,曾维伟. 基于 GA-BP 神经网络的采空区地表沉降预测模型[J]. 矿冶工程, 2022,42(2):42-45.
- [11] 王文广,徐 芳,李兴波. 基于轧制机理和混合神经网络的热轧精轧带宽预测[J]. 中国冶金, 2022,32(2):97-101.
- [12] 董志奎,梁朋伟,嵇超越,等. 基于 DBN 算法的热轧高强钢薄板轧机振动预报研究[J]. 矿冶工程, 2020,40(4):135-141.
- [13] 钱金花,郑文娟,吴文彬,等. 基于小波去噪和循环神经网络-k重-整合移动平均自回归模型的转炉煤气柜位预测[J]. 中国冶金, 2023,47(3):24-34.
- [14] 孙 浩,叶国良,翟博豪,等. 基于循环自编码网络的冷轧轧制力建模方法[J]. 计量学报, 2022,43(9):1172-1177.
- [15] 李志刚,张 鑫. CNN-GRU 模型预测高炉煤气产生量[J]. 机械设计与制造, 2022(4):69-72.
- [16] Kok C, Jahmunah V, SHU L O, et al. Automated prediction of sepsis using temporal convolutional network[J]. Computers in Biology and Medicine, 2020,127:103957.
- [17] 杨汪洋,魏云冰,罗程浩. 基于 CVMD-TCN-BiLSTM 的短期电力负荷预测[J/OL]. 电气工程学报, 1-10[2023-08-06]. <http://kns.cnki.net/kcms/detail/10.1289.TM.20230601.1229.002.html>.
- [18] 郭 玲,徐青山,郑 乐. 基于 TCN-GRU 模型的短期负荷预测方法[J]. 电力工程技术, 2021,40(3):66-71.

引用本文: 杨萍萍,马 亮. 基于时域卷积网络的精轧出口厚度预测[J]. 矿冶工程, 2024,44(1):138-142.

(上接第 137 页)

- [13] 刘秉宁,赵 旭,孙本双,等. ITO 靶材烧结行为研究[J]. 材料科学, 2019,9(8):749-759.
- [14] 吕志伟,陈志飞,姚吉升. 纳米 ITO 粉体的制备及其性能表征[J]. 矿冶工程, 2004,24(3):70-72.
- [15] Sunde T O L, Einarsrud M A, Grande T. Solid state sintering of nano-crystalline indium tin oxide[J]. Journal of the European Ceramic Society, 2013,33(3):565-574.
- [16] Shinohara N, Okumiya M, Hotta T, et al. Morphological changes in process-related large pores of granular compacted and sintered alumina[J]. Journal of the American Ceramic Society, 2000,83(7):1633-1640.
- [17] Slamovich E B, Lange F F. Densification of large pores: I, experiments[J]. Journal of the American Ceramic Society, 1992,75(9):2498-2508.
- [18] Slamovich E B, Lange F F. Densification of large pores: II, driving potentials and kinetics[J]. Journal of the American Ceramic Society,

1993,76(6):1584-1590.

- [19] Deyu G K, Hunka J, Roussel H, et al. Electrical properties of low-temperature processed Sn-doped In_2O_3 thin films: The role of microstructure and oxygen content and the potential of defect modulation doping[J]. Materials, 2019,12(14):2232.
- [20] González G B, Mason T O, Quintana J P, et al. Defect structure studies of bulk and nano-indium-tin oxide[J]. Journal of Applied Physics, 2004,96(7):3912-3920.
- [21] Frischbier M V, Wardenga H F, Weidner M, et al. Influence of dopant species and concentration on grain boundary scattering in degenerately doped In_2O_3 thin films[J]. Thin Solid Films, 2016,614:62-68.

引用本文: 姜 峰,谭泽旦,黄誓成,等. 模压成型压力对氧化铟锡(ITO)靶材性能影响研究[J]. 矿冶工程, 2024,44(1):134-137.