

基于特征融合的粗轧出口温度建模方法与应用

张 凯^{1,2†}, 王亚礼¹, 张晓雯¹, 彭开香^{1,2}

(1. 北京科技大学 自动化学院, 北京 100083;

2. 北京科技大学 工业过程知识自动化教育部重点实验室, 北京 100083)

摘要: 在带钢热连轧过程中, 粗轧出口温度受加热炉和粗轧工序共同影响, 其建模精度是提高成品带钢质量的关键。现有方法大多基于机理模型或仅将加热炉与粗轧数据融合, 对两个工序的特征提取不充分, 且不利于所提出方法在两工序的分布式部署。为此, 本文提出了一种基于特征融合的热连轧过程粗轧出口温度建模方法。该方法首先针对两个工序数据的特点构建了联合长短期记忆 (LSTM) 网络和时间卷积网络 (TCN) 的特征提取模型, 并利用 LSTM 实现了两部分特征的融合, 进而利用全连接模块构建粗轧出口温度的预测模型; 其次, 考虑到热连轧过程带钢品种和规格的多样性, 构建了预测模型的更新机制; 最后, 将所提出预测方法分布式部署到云边端协同的热连轧过程原型系统中, 利用某钢铁公司 2150 产线的实际数据验证了方法的有效性。验证结果表明, 本文方法与传统方法相比预测精度提高 35.69%, 且在采样周期 100 ms 下, 预测与更新机制满足实时性要求。

关键词: 热连轧; 温度预测; 特征融合; 自适应更新; 云边端

引用格式: 张凯, 王亚礼, 张晓雯, 等. 基于特征融合的粗轧出口温度建模方法与应用. 控制理论与应用, 2026, 43(4): 853 – 864

DOI: 10.7641/CTA.2024.40252

A feature fusion-based rough rolling exit temperature modeling method and its applications

ZHANG Kai^{1,2†}, WANG Ya-li¹, ZHANG Xiao-wen¹, PENG Kai-xiang^{1,2}

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

2. Key Laboratory of Knowledge Automation for Industrial Processes of Ministry of Education, University of Science and Technology Beijing, Beijing 100083, China)

Abstract: In the hot strip rolling mill (HSRM) process, the rough rolling exit temperature is affected by the heating furnace and the rough rolling process, and accuracy of the temperature model plays the key role in improving the quality of the steel products. Most of the existing methods are based on mechanism models or only fuse the heating furnace and rough rolling data, which is insufficient to extract the features of the two processes, and also these models are not easy to be deployed in real applications. To this end, a feature fusion-based method is proposed for modeling the rough rolling exit temperature in the HSRM process. Firstly, two feature extraction methods that using long short term memory (LSTM) and temporal convolutional network (TCN) are developed respectively by considering the characteristics of process data, and then a separate LSTM is used to fuse the obtained features, also a fully connected module is finally constructed to develop the prediction model. Furthermore, considering the differences between different types of steel products, an update mechanism for the developed prediction model is proposed. In the end, the applicability of proposed model is examined using a cloud-edge-end collaborative prototype system, where actual HSRM data from the 2150 production line of a steel company are used. The verification results show that the proposed method improves the prediction accuracy by 35.69% compared with traditional methods. At the sampling interval of 100 ms, the prediction and update mechanism meets the real-time requirements.

Key words: hot strip rolling mill; temperature prediction; feature fusion; adaptive update; cloud-edge-end

Citation: ZHANG Kai, WANG Yali, ZHANG Xiaowen, et al. A feature fusion-based rough rolling exit temperature modeling method and its applications. *Control Theory & Applications*, 2026, 43(4): 853 – 864

收稿日期: 2024-05-03; 录用日期: 2024-11-22.

†通信作者. E-mail: kaizhang@ustb.edu.cn; Tel.: +86 15600758678.

本文责任编辑: 吴敏.

国家重点研发计划项目(2021YFB3301200), 国家自然科学基金项目(62073032, U21A20483)资助.

Supported by the National Key R&D Program of China (2021YFB3301200) and the National Natural Science Foundation of China (62073032, U21A20483).

1 引言

轧件温度在热连轧过程中十分重要,越来越受到学术界和工业界的关注,粗轧出口温度作为热轧带钢生产过程中的温度控制环节之一,其变化会导致热轧带钢内部的微观组织发生变化,进而影响带钢产品的力学性能.此外,粗轧出口温度的控制还影响精轧入口温度,这关系到精轧机架能否加大压下量,从而直接影响精轧机可轧产品的下限厚度^[1].因此,构建精确的粗轧出口温度预测模型对优化热连轧工艺、提高产品质量具有重要意义.

传统的基于机理模型的方法需对过程机理深入理解并获得参数和初始条件,方法的精度受限于模型的复杂性和计算的准确性.基于数据驱动方法则不依赖于详细的物理或化学原理,而是直接从数据中学习并提取模式,能够处理高维、非线性、多因素的数据,揭示了系统内部的复杂关系.因此基于数据驱动的质量指标预测方法适用于复杂多变的工业领域,目前已在有色冶金^[2]、钢铁工业^[3]、城市污水^[4]、化工^[5]等行业成功应用,并取得良好效果.这些研究将数据驱动引入特征提取过程,以实现过程参数与质量指标之间规律的表征.随着机器学习算法不断发展和过程历史数据的不断累积,基于机器学习的方法已经得到了广泛的发展.例如, Xie等^[6]提出一种高级偏最小二乘法,用于关键绩效指标相关过程预测.同样, Jiang等^[7]提出了一种优化的稀疏偏最小二乘建模方法,用于同时进行批次末端质量预测和相关变量选择.这些方法从自变量系统中提取出对因变量具有最佳解释能力的主成分,然后对它们进行回归建模,有效解决了自变量之间的多重相关性,但是对于数据时序特征提取不充分,预测精度有限.

除了传统的基于机器学习的方法,许多基于智能优化算法的改进神经网络方法也被开发用于温度预测,如孙铁军等^[8]采用改进遗传算法优化神经网络,建立了卷取温度预报模型. Wang等^[9]建立基于遗传算法优化的热电偶传感器动态升温神经网络预测模型. Gao等^[10]基于非线性自回归外生神经网络,构建日光温室温度预测模型,准确预测日光温室内的温度趋势,实现对温度的精确控制.尽管上述方法得到了广泛的应用,但没有很好地考虑影响工序内部和工序之间数据的特征,不能保证粗轧出口温度预测具有较高的精度.

为了提取时序数据的时间特征,通常使用为时间序列数据建模开发的长短期记忆(long short term memory, LSTM)网络,同时注意力机制已经被纳入到各种LSTM模型中^[11-12]用以提取局部特征.为了更好地捕捉过程和质量数据之间的关系,文献[13]提出了一种有监督的LSTM模型;文献[14]提出了一种数据驱

动的自监督长短期记忆-深度因子分解机模型,用于工业软测量过程中提取时间序列中的低维、高维和时序特征;文献[15]提出一种带时间门的长短期记忆神经网络,实现输入填补和输出预测同步进行.因此,基于LSTM的质量预测方法广泛应用于工业过程. LSTM用于从时间序列数据中捕获长期依赖性,时间卷积网络(temporal convolutional network, TCN)用于在多变量中提取更高级的空间特征,两种算法结合使用,可以从原始数据中提取有效的空间和时间特征,充分挖掘数据内部信息. Hu等^[16]构建时间卷积网络-长短期记忆(TCN-LSTM)模型,准确估计不同温度条件下的锂离子电池的充电状态,验证了方法的泛化性和鲁棒性.方怡静等^[17]提出一种基于工况知识引导注意力时间卷积网络(attention mechanism TCN, AM-TCN),将其用于烧结终点的智能预测,充分考虑不同特征变量对烧结终点预测结果的重要性. Hu等^[18]则在TCN-LSTM模型基础上增加注意力机制,用于进一步完善预测结果,建立基于TCN-LSTM-Attention的工辊磨损预测模型,与现有的时间序列模型相比极大提升了预测的精度.然而,以上方法对粗轧出口温度影响因素考虑不全面,对多工序的特征提取不充分.考虑到加热炉工序和粗轧工序数据特征的不同,本文分别选用LSTM和TCN,对加热炉数据和粗轧数据进行特征提取,充分利用两个工序的原始数据,挖掘数据内部的特征,提高粗轧出口温度的预测精度.

在实际工业现场中,由于工艺参数、原料等的变化,过程往往具有时变特性.因此在进行在线预测时,由训练数据得到的预测模型可能并不完全适用于在线样本,因此模型需要自适应更新.模型自适应的方法有很多,如Wang等^[19]提出了基于多层卷积特征的在线尺度自适应视觉跟踪方法; Zhang等^[20]提出了一种动态自学习结构,动态调整极限学习机(extreme learning machine, ELM)中隐含层节点数; Wang等^[21]根据序列的波动选择,重新训练整个模型或解码层;易诚明等^[22]通过即时学习算法获得最佳学习子集的平均值,用以替换异常数据消除干扰;汪小勇等^[23]提出块式递推偏最小二乘(partial least squares, PLS)的限定记忆法,引入遗忘因子按数据块的新老程度赋予相应的可信度.本文结合基于特征融合的预测模型的结构特点,提出了一种自适应机制.

基于以上分析与总结,本文的主要贡献可以概括如下: 1) 提出了基于特征融合的热连轧过程粗轧出口温度预测模型.该预测模型采用融合注意力机制的LSTM层和TCN层,分别对热连轧过程加热炉数据和粗轧数据进行特征提取,之后利用LSTM层进行特征融合,挖掘更深层次动态特征; 2) 结合预测模型的特点和热连轧过程实时数据的特点,提出了一种基于加热炉粗轧两个工序数据的粗轧出口温度预测的自适

应机制,在一定程度上改善了在线预测的温度预测效果;3) 将提出的自适应更新参数的基于特征融合的预测模型,部署在云边缘协同原型系统中进行应用验证,加热炉和粗轧的特征提取模块分别部署在两个边侧,整个模型的训练在计算性能高的云侧实现,实时预测和自适应更新在灵活性强的边侧实现,证实了预测方法的有效性和实时性。

2 背景及问题描述

带钢轧制过程复杂多变,温度的连续变化受到多种因素的共同影响^[24],如原料成分、加热温度、轧制速度等。这些因素之间相互作用,相互影响,使得粗轧出口温度的预测变得异常复杂。为了满足生产过程中的实时控制需求,粗轧出口温度预测模型需要具有较

快的计算速度和较高的预测精度。因此,预测模型的准确性和实时性成为亟需解决的问题。

热连轧工艺流程如图1所示。该工艺一般由以下单元组成:加热炉、粗轧可逆轧机、保温罩、飞剪、除鳞机、精轧连轧机组、层流冷却、卷取机组。加热炉将板坯加热到开轧温度,粗轧可逆轧机的任务是给精轧机提供温度、几何尺寸合适的带坯,这两道工序决定粗轧出口温度。粗轧出口温度直接影响精轧厚度、凸度与温度控制,进而影响卷取温度与张力控制,最终影响到成品带钢的性能。因此,粗轧出口温度(RDT)对提升产品质量具有至关重要的意义,其预测模型的精度需综合考虑加热炉和粗轧两工序数据的影响。




图1 RDT对热连轧过程关键质量指标的影响

Fig. 1 Effect of RDT on key quality indicators in the hot strip rolling mill process

在实际工业现场中,由于过程参数、原料等因素的变化,过程数据往往是时变的,这导致实时数据与历史数据之间存在偏差,从而导致在历史数据上训练的模型与实时数据之间的不匹配^[25]。当粗轧出口温度预测的训练模型与实时数据不匹配时,会使得出口温度的预测精度下降,需要对模型进行更新,从而提升模型的预测精度。由于加热炉和粗轧工序之间具有一定的时间间隔,因此可以先在加热炉侧对加热炉数据进行特征提取,再在粗轧侧进行粗轧数据特征提取和特征融合预测,实现边与边的协同,保证预测的时效性。基于以上问题与分析,本文在基于特征融合的粗轧出口温度的预测模型的基础上,提出预测模型的自适应机制,解决训练模型与实时数据不匹配的问题,提升了模型预测的精度。

为了建立基于数据驱动的粗轧出口温度的预测模型,需要对模型的输入变量进行选择。结合轧制过程机理和传热学的相关知识,粗轧出口温度与原料成分、加热温度、轧制速度、温降时间等变量有关。基于实际生产过程已有的过程变量,筛选模型特征提取部分的输入变量如表1所示。根据传热学原理和辐射温降公式^[1],加热炉部分选取影响板坯内部热传导效率和热传导时间的材料相关变量,包括:板坯质量、板坯长度、板坯宽度和板坯厚度,直接影响温度的加热时间和加热温度相关变量,包括:在炉时间、预热段时间和温度、加热段时间和温度、均热段时间和温度等。

粗轧过程选取影响空冷和变形产生的温度的变量,包括:总轧制力、轧制功率、辊缝、轧制力、轧制力矩、穿带速度、运行速度、板坯宽度、板坯厚度、板坯长度等。最终粗轧出口温度预测模型共有87个输入变量,其中加热炉部分42个输入变量, $x^F \in \mathbb{R}^{42}$,粗轧部分45个输入变量, $x^R \in \mathbb{R}^{45}$ 。

表1 粗轧出口温度预测模型相关变量

Table 1 Variables for RDT prediction model

| 工序 | 描述 |
|-------------------------|--|
| 加热炉 | 板坯质量/t, 板坯长度/cm, |
| | 板坯宽度/mm, 板坯厚度/mm, |
| | 在炉时间/min, 预热段时间/s, |
| | 加热段时间/s, 均热段时间/s, |
| | 入炉温度/°C, 实际抽钢温度/°C, |
| | 预热段实际温度/°C, 预热段设定温度/°C, |
| | 加热段实际温度/°C, 加热段设定温度/°C, |
| 均热段实际温度/°C, 均热段设定温度/°C, | |
| 粗轧 | R1各道次总轧制力/kN, 辊缝/mm, |
| | 轧制力/kN, 轧制力矩/kNm, 穿带速度/(m·s ⁻¹), |
| | 运行速度/(m·s ⁻¹), 板坯宽度/mm, |
| | 板坯厚度/mm, 板坯长度/m, |
| | E1, E2各道次轧制力、辊缝、轧制功率 |

3 基于特征融合的RDT预测方法

为建立粗轧出口温度的预测模型,首先需要对其

际工业数据的批次数据进行截取和预处理,得到模型训练所需的样本,并分别利用LSTM和TCN网络提取加热炉数据和粗轧数据的特征,为了更深入地探究特征的动态特性,将得到的加热炉和粗轧特征利用LSTM层进行融合,最后通过两层全连接层得到粗轧出

口温度的预测.基于特征融合的粗轧出口温度预测模型结构如图2所示.针对前文提出的由实时数据生成的模型与历史数据不匹配的问题,引入了自适应调整参数机制.根据批次粗轧出口温度预测平均误差绝对值的大小,判断是否进行模型的自适应更新.

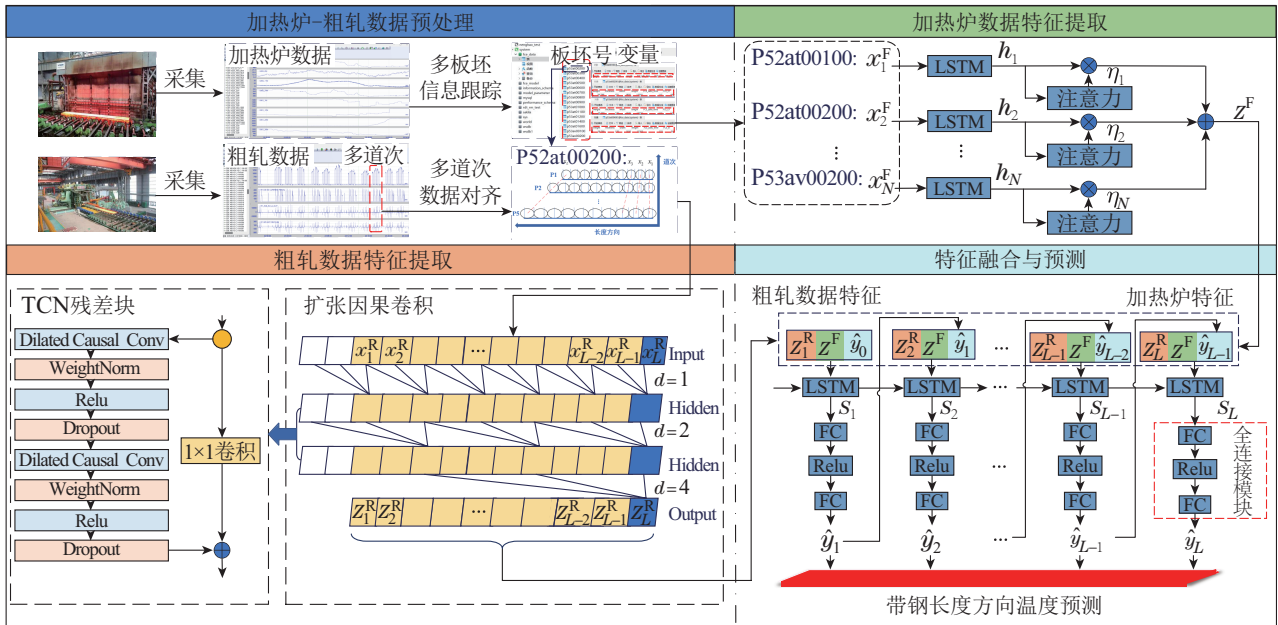


图2 基于特征融合的粗轧出口温度预测方法框架

Fig. 2 Framework for rough rolling exit temperature prediction based on feature fusion

3.1 数据整理

热连轧轧制过程中同一批次板坏的数据是连续的,不同批次板坏的数据是不连续的.本文建立的粗轧出口温度预测模型主要基于有效轧制数据,因此需要截取不同批次有效轧制数据,并进行相应的预处理,得到部分批次数据.采集到加热炉温度跟踪数据之后,需要对加热炉数据进行板坏跟踪,即按不同批次的板坏号进行截取和处理,并将预处理后的数据按板坏号区分存储,板坏跟踪的批次数为 n .对于粗轧工序而言,首先,根据选定变量截取同一块钢材数据区间,涵盖图2中红色虚线范围所示的最早至最晚时刻;之后根据脉冲板坏号和布尔咬钢信号,提取5组信号的上升沿与下降沿间数据,对应粗轧5个道次的的数据.因为粗轧采用一架强力粗轧机进行5道次可逆轧制来满足精轧的坯料要求^[1],所以第2、4道次数据需逆序翻转;最后进行数据对齐,数据对齐需要先获取每块带钢通过每个道次的长度,然后再进行数据对齐,即按长度的百分比相对大小重新排列填充数据,将同一采样时间的数据转化为同一轧钢采样位置百分比的数据,数据对齐后采样长度为 L .此外,为实现对同一批次板坏的索引、加热炉和粗轧数据通过对应的板坏号进行索引.

3.2 基于多工序特征融合的预测方法

3.2.1 基于LSTM的加热炉数据特征提取

LSTM有效地解决了梯度消失和梯度爆炸的问题,在长期依赖问题中得到广泛应用,因此在加热炉数据特征提取部分选用LSTM进行特征提取,特征提取过程如图2加热炉特征提取部分所示.LSTM层输入为多板坏信息跟踪得到的 $X_n^F \in \mathbb{R}^{1 \times n \times 42}$,LSTM单元^[21]可以用如下数学表达式表示:

$$f_n = \sigma(W_{xf}x_n + W_{hf}h_{n-1} + b_f), \quad (1)$$

$$i_n = \sigma(W_{xi}x_n + W_{hi}h_{n-1} + b_i), \quad (2)$$

$$C_n = f_n C_{n-1} + i_n \tanh(W_{xc}x_n + W_{hc}h_{n-1} + b_c), \quad (3)$$

$$O_n = \sigma(W_{xo}x_n + W_{ho}h_{n-1} + b_o), \quad (4)$$

$$h_n = O_n \tanh(C_n), \quad (5)$$

式中: W 是权重矩阵; b 是偏置; i, o, f 分别为输入门、输出门和遗忘门; C_n 是记忆单元; σ 是sigmoid激活函数.设特征提取部分LSTM层输出维数为 λ_1 ,输出为 $H_n, H_n \in \mathbb{R}^{1 \times n \times \lambda_1}$.

之后采用注意力机制为LSTM层输出的不同部分分配权重,突出显示更多相关信息,有助于模型专注于输入序列中在当前任务更重要的部分. K, Q, V 分别表示注意力机制中的键、查询和值,注意力

机制中的输入由键值对 (K, V) 组成. 注意力机制的计算分为3个步骤: 首先, 计算 K 与 Q 之间的相关性; 之后, 得到每个 K 对应 V 的权重系数; 最后, 将得到的权重系数对 V 值加权求和得到注意力的输出. 注意力机制权重系数计算方法如下:

$$\theta = Q \times K^T, \quad (6)$$

$$\eta_j = \frac{\exp(\theta_j)}{\sum_{k=1}^n \exp(\theta_k)}, \quad (7)$$

式中: θ 是 Q 和 K 的相关性系数, η_j 是第 j 个批次的注意力权重系数, n 表示输入的键值对的个数. LSTM层的输出在注意力机制下加权求和得到作为特征融合层一部分输入的特征向量 z^F , z^F 计算如下:

$$z^F = \sum_{i=1}^n h_i \eta_i. \quad (8)$$

3.2.2 基于TCN的粗轧数据特征提取

为了在一定程度上提高处理速度, 使用TCN网络对粗轧数据进行特征提取, 在进行训练时, 可以选择模型并行处理来提高模型的运行速度, 节省时间. 同时, TCN通过扩大感受野和堆叠多层卷积来获取更广泛的时空特征, 由于其特殊的结构模式, 在卷积神经网络上添加了记忆功能, 能够灵活调控感受野的大小, 而且可以更好地解决梯度问题, 较为适合描述过程变量的非线性和长动态依赖性^[26]. TCN的结构如图2粗轧数据特征提取部分所示, 它集成了膨胀因果卷积和残差块, 与LSTM相比, 具有更高的并行处理能力、稳定的梯度和灵活的感知域. 膨胀卷积通过区间采样获得更大的感知域, 对于一维序列输入 $x^R \in \mathbb{R}^{64}$ 和滤波器 $f: \{0, \dots, k-1\} \rightarrow \mathbb{R}$, 序列元素 u 上的膨胀卷积运算 F 定义为

$$F(u) = (x^R *_d f)(u) = \sum_{i=0}^{k-1} f(i) \times x_{u-d \times i}^R, \quad (9)$$

式中: d 是膨胀因子, 一般随着网络加深呈指数增长; k 是滤波卷积核的大小; $u-d \times i$ 表示过去的方向; x^R 是粗轧数据输入序列; $f(i)$ 是卷积核中第 i 个元素; $x_{u-d \times i}^R$ 对应于卷积核操作的输入序列的元素. TCN的残差模块包含膨胀卷积层、权重归一化层、激活函数为线性整流函数(ReLu)和Dropout层. 权重的归一化消除了梯度爆炸问题, 并能有效加快计算速度. 为了使得TCN网络结构非线性且不过于简单, 使用ReLu激活函数, 并添加Dropout层以防止过拟合, 从而达到正则化效果. 残差张量维数通过 1×1 卷积进行不同的调整, 残差块方程如下所示:

$$x_{l+1} = h(x_l) + F(x_l, W_l), \quad (10)$$

式中: $F(x_l, W_l)$ 是残差部分, W_l 是输入的权重矩阵; $h(x_l)$ 是直接映射部分, 包括 1×1 卷积运算, x_l 是残差块的输入; x_{l+1} 是残差块的输出. 经过TCN网络特征

提取最终得到输出粗轧特征 z_L^R .

3.2.3 特征融合与参数学习

特征融合过程如图2特征融合与预测部分所示, 使用粗轧特征向量 z_L^R , 加热炉特征向量 z_n^F 和上一长度方向的温度预测值 \hat{y}_{L-1} 进行特征融合. 本文选用LSTM进行特征融合, 用于挖掘更深层次动态特征, LSTM层的输入记为 Z_L , $Z_L \in \mathbb{R}^{1 \times 1 \times (\lambda_1 + \lambda_2 + 1)}$ 满足

$$Z_L = [z_L^R \ z^F \ \hat{y}_{L-1}], \quad (11)$$

输入 Z_L , 经过LSTM层, 得到输出 s_L . LSTM的输出 $s_L \in \mathbb{R}^{1 \times 1 \times \lambda_3}$ 经过两个全连接层后, 得到模型的粗轧出口温度预测值. 假设第1层全连接层的输出维数为 λ_4 , 粗轧出口温度预测值 \hat{y}_L 计算如下:

$$\hat{y}_L = (\text{Relu}(s_L \vartheta_1^T + \varepsilon_1)) \vartheta_2^T + \varepsilon_2, \quad (12)$$

式中: $\text{Relu}(\cdot)$ 为Relu激活函数, ε_1 和 ε_2 是偏差, $\vartheta_1 \in \mathbb{R}^{\lambda_4 \times \lambda_3}$, $\vartheta_2 \in \mathbb{R}^{1 \times \lambda_4}$.

本文采用反向传播对模型参数进行训练, 并采用自适应矩估计(Adam)的优化算法对模型进行训练, 使用平均绝对误差作为损失函数, 计算公式为

$$\mathcal{L} = \frac{1}{L} \sum_{i=1}^L |y_i - \hat{y}_i|. \quad (13)$$

基于特征融合的预测算法实现步骤如下:

步骤1 采集加热炉和粗轧数据, 经过板坯跟踪和数据对齐形成数据矩阵 X_n^F 和 X_L^R .

步骤2 基于LSTM网络, 结合式(1)–(8)构建加热炉板坯特征 z^F ; 基于式(9)–(10)构建TCN网络结构, 提取粗轧数据板坯长度方向上的特征 z_L^R .

步骤3 以板坯号为索引, 对加热炉和粗轧提取到的特征利用LSTM层进行特征融合, 之后通过两层全连接层得到粗轧出口温度预测值.

步骤4 采用反向传播并使用Adam优化算法对模型参数进行训练, 计算式(13)中的 \mathcal{L} 并对模型参数进行迭代更新.

3.3 预测模型更新

热连轧过程数据往往是时变的, 当使用历史数据离线训练模型时, 在线数据因工况变化有可能使粗轧出口温度的预测出现偏差. 一是在轧制过程中存在更换钢种的情况, 如钢种由Q235B变化为M3A42, 此时热连轧过程各个环节变化较大, 为实现准确预测需对整个模型进行重新训练; 二是轧制过程中存在板坯规格变化的情况, 包括厚度、宽度和长度; 三是坯料冷热装温度的差异. 此外还有粗轧出口温度设定变化的情况, 如从1080°C变化到1070°C, 此时各个环节的变化相对不大, 只需对模型部分参数进行更新. 对于这种情况, 本文提出了一种基于批次样本平均误差对模型进行自适应更新的机制, 对局部模型进行更新, 以提

高预测精度. 模型更新部分如图2特征融合与预测部分的全连接模块所示, 更新预测模型的最后两层全连接层的参数. 假设批次样本数量为 ρ , 批次粗轧出口温度预测平均误差为 δ , 满足

$$\delta = \frac{1}{\rho} \sum_{k=1}^{\rho} (y_k - \hat{y}_k), \quad (14)$$

自适应调整更新机制主要原理如下: 当 $|\delta| \leq \mu$ 时, 基于特征融合的预测模型的粗轧出口温度预测输出即为该批次的粗轧出口温度预测值; 当 $|\delta| > \mu$ 时, 需要进行模型自适应调整, 使用当前批次的数据对预测模型的最后两层全连接层进行再训练, 得到更适应当前批次数据的预测模型, 再训练后的模型用于后续批次粗轧出口温度的预测, 从而降低后续批次的预测误差.

3.4 方法特点分析

充分提取特征: 在考虑两工序对粗轧出口温度的影响时, 本文并未如文献[27]所述将数据拼接后采用统一方法预测, 而是根据两工序的独特性质进行了深入分析和区别处理. 考虑到加热炉温度场的稳定性, 在工况没有较大改变的时间段内, 板坯温度在相对稳定的范围内波动, 各区域环境温度变化缓慢. LSTM凭借其长期记忆能力, 能够有效捕捉炉内环境变化的长期趋势. 而粗轧数据的采样频率较快, 板坯内各变量动态变化快, 板坯间参数变化大. TCN的膨胀因果卷积卷积和残差连接结构能优化网络的处理速度和预测精度, 确保在充分提取数据特征的同时, 也提升了特征提取的速度, 从而保障了预测的实时性.

长度方向连续预测: 针对加热炉炉内板坯跟踪和粗轧多次道次板坯跟踪的需求, 本文通过步进梁动作原理确定板坯炉内位置, 通过数据对齐获得粗轧各道次长度方向的数据. 同时还借助板坯号索引, 实现加热炉与粗轧数据的对应关系. 最终通过以上方法实现整个板坯长度方向上的所有回放数据点处的连续预测.

分布式部署: 如图2所示, 本文提出的两工序特征融合方法分别使用LSTM和TCN进行特征提取. 这一方法有利于模型分别在加热炉和粗轧两个不同工序进行部署, 无需整合两工序数据即可独立进行特征提取. 这符合实际热连轧过程中加热炉与粗轧两道工序在位置上的分隔性, 避免了传输原始数据可能引发的风险. 此外, 提前对加热炉数据进行特征提取加快了整个预测的进程.

4 应用验证

4.1 数据描述及系统介绍

热连轧过程真实数据在云边端框架中的信息流向如图3所示. 图中模拟了工业现场的实时数据上传过程, 热连轧过程的实时数据由端侧可编程序控制器(programmable logic controller, PLC)接收, 之后端侧PLC将加热炉和粗轧数据分别上传至两个边侧的实时数据库, 该过程中PLC通过TCP/IP通信进行数据收发, 此外, 数据从端侧到边侧以及从边侧到云侧的上传方

式均为TCP通信. 原型系统云边端的硬件配置不同, 端侧的A021C是基于PowerPC架构MPC85系列的微控制器, 是热连轧实际生产过程中涉及使用的PLC, 它有两个以太网口, 支持以太网通信(1 Gbit/s), 最快处理速度到达2 ms. 云侧服务器比边侧服务器具有更高的硬件配置, 完成一些对服务器内存和计算性能要求较高的任务, 边侧服务器完成一些对实时性要求较高的任务.

基于云侧计算的高效性以及边侧计算的灵活性和实时性^[28-29], 分别在云侧和边侧对预测模型进行离线训练和在线自适应更新, 保证了预测方法的有效性和实时性. 本文使用的粗轧温度预测模型部署在云边端框架中, 加热炉和粗轧的特征提取模块分别部署在两个边侧服务器上, 反应工业现场加热炉和粗轧两道工序存在的空间位置差异.

在云侧集中训练基于特征融合的预测模型. 首先云侧接收边侧服务器的数据, 通过云侧历史数据库获取加热炉和粗轧的历史数据; 之后分别对加热炉数据和粗轧数据进行基于LSTM和TCN的特征提取; 然后进行特征融合; 最终得到粗轧出口温度的预测. 云侧训练的模型通过MySQL关系数据库部署于加热炉和粗轧两个边侧, 模型部署包含训练集数据的均值和标准差, 以及在边侧的参数数据库中部署模型所需的参数. 在加热炉边侧, 首先获取实时上传的加热炉数据, 之后从MySQL数据库中装载预先训练的模型进行加热炉辅助特征计算, 然后按照板坯号对结果进行存储并传输至粗轧边侧特征融合; 在粗轧边侧, 首先对实时粗轧数据进行在线数据预处理以满足模型输入的要求, 之后从MySQL数据库读取模型的参数和加热炉侧特征提取结果, 并部署模型的参数进行粗轧特征提取, 然后将粗轧特征提取的结果和加热炉侧特征提取结果融合预测, 最终得到粗轧出口温度预测值. 根据每个批次的粗轧出口温度预测的平均绝对误差绝对值 $|\delta|$ 是否大于阈值 μ 来决定是否进行模型的自适应更新. 若 $|\delta| > \mu$, 则边侧进行模型自适应更新, 即局部模型再训练, 之后将更新后的模型用于后续批次粗轧出口温度预测. 粗轧出口温度的预测结果可应用于端侧控制优化决策和质量分析.

4.2 模型训练

4.2.1 数据预处理

本文选用某钢厂热连轧生产线包括11种钢种、44种不同规格的数据进行训练和测试. 在此之前, 需要进行有效数据的截取、数据对齐、数据归一化等操作. 每个批次导出的数据具有时序性, 不同批次板坯的轧制在时间上并不连续, 需要截取各个板坯有效的轧制数据. 其次, 各批次不同道次的有效轧制数据在时间上不对齐, 且不同道次的样本数不同, 因此需要根据位置百分比对齐数据.

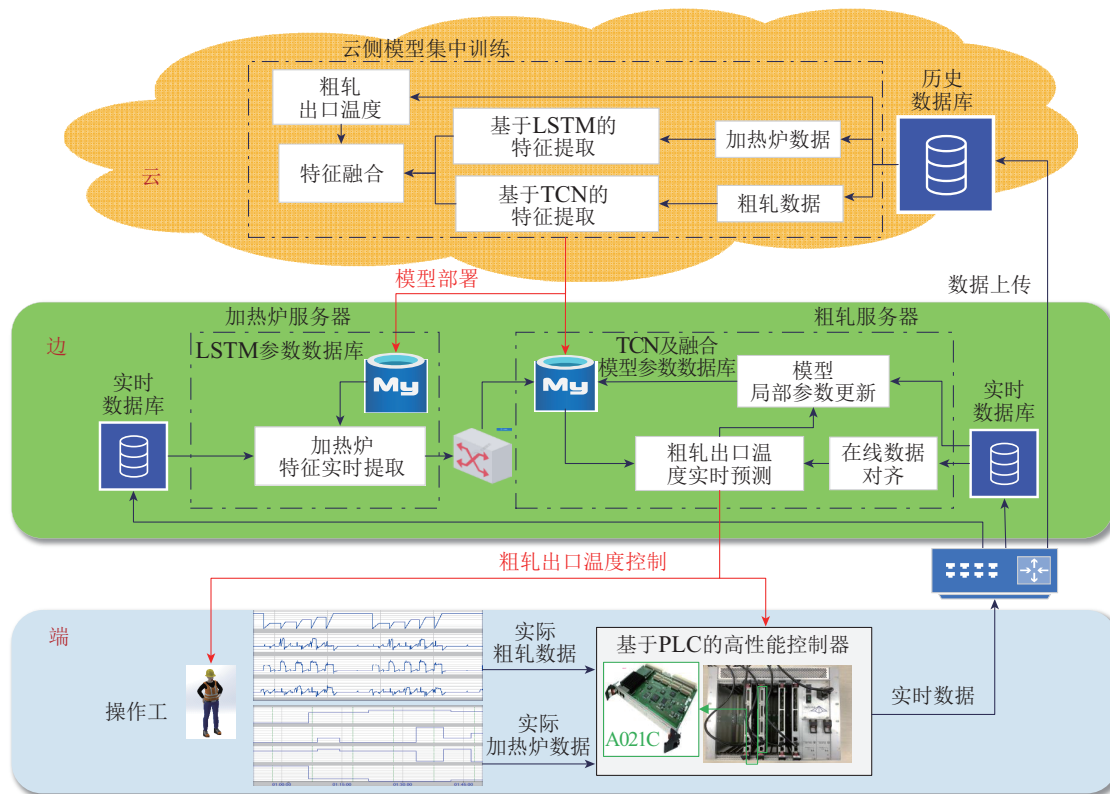


图3 云边端协同原型系统

Fig. 3 Cloud-edge-end collaborative prototype system

首先, 需要根据所选影响变量截取1块钢材的数据, 如图2中红色虚线所示在截取数据的时间区间内包含一块钢材对应变量的最早时刻和最晚时刻。粗轧不同道次的有效数据由脉冲信号粗轧板坯号和布尔信号粗轧咬钢信号确定, 获取脉冲信号板坯号时刻后的5组粗轧咬钢信号的上升沿和下降沿, 每组上升沿和下降沿之间的数据对应粗轧5个道次的有效数据。由于粗轧采用一架强力粗轧机进行5道次可逆轧制来满足精轧的坯料要求^[4], 第2、4道次板坯的传送方向与其余道次相反, 因此需对第2、4道次的数据进行逆序翻转操作以便后续的数据对齐。最后根据位置百分比对来自不同道次的数据进行对齐。数据对齐需要先获取每块带钢通过每个道次的长度, 然后再进行数据对齐, 即按长度的百分比相对大小重新排列填充数据, 将同一采样时间的数据转化为同一轧钢采样位置百分比的数据。为了消除量纲的影响, 需要根据标准公式对数据进行标准化处理, 同时还需存储训练集数据的均值和标准差用于边侧模型输入的处理。

4.2.2 评价指标

本文采用平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)、平均绝对百分比误差(mean absolute percentage error, MAPE)、决定系数 R^2 作为评价模型预测性能的指标^[12]。

4.2.3 模型参数的确定

由表2可知, 当训练批次增加到110时, 方法的平均绝对误差下降到10以内, 满足对预测精度的初步要求, 因此本文选用某钢厂热连轧生产线110个批次用于训练, 28个批次用于测试。本文提出的基于特征融合的预测模型使用Adam优化器进行300次迭代训练。主要参数包括加热炉特征提取部分LSTM层的输出维度 λ_1 , 粗轧特征提取部分TCN输出维度 λ_2 , 特征融合部分LSTM层的输出维度 λ_3 , 特征融合部分两个全连接层的隐藏层输出维度 λ_4 、学习率 lr 等, 均对模型的性能有影响, 下面通过实验确定参数的取值。

表2 不同训练批次 n 下的性能分析

Table 2 Results analysis of different training batches n

| n | MAE ↓ | RMSE ↓ | MAPE ↓ | R^2 ↑ |
|-----|---------------|---------|--------|---------|
| 50 | 12.9622 | 18.8207 | 0.0123 | 0.1670 |
| 70 | 15.0223 | 21.8739 | 0.0141 | 0.1251 |
| 90 | 12.1717 | 17.7450 | 0.0115 | 0.2595 |
| 110 | 9.9523 | 18.3474 | 0.0099 | 0.2084 |

考虑LSTM输出维度对模型性能指标的影响, 首先对 λ_1 和 λ_3 进行网格优化算法确定。经过多次实验, 取 lr 为{0.001, 0.0005}, 综合考虑训练样本数量和模型复杂度, 将 λ_1 取为{16, 24, 32}, λ_3 取为{16, 24, 32}。模型在不同参数组合下的预测结果如表3所示。从预

测结果可以看出,当 $lr = 0.001, \lambda_1 = 16, \lambda_3 = 16$ 时, MAE, RMSE, MAPE较小, R^2 较大, 模型的预测性能在目前的参数设置中相对最优.

表 3 不同 lr, λ_1, λ_3 下的性能分析

Table 3 Results analysis with different lr, λ_1 and λ_3

| lr | λ_1 | λ_3 | MAE ↓ | RMSE ↓ | MAPE ↓ | R^2 ↑ |
|--------|-------------|-------------|---------------|---------------|-----------------|---------------|
| | 16 | 24 | 5.2729 | 7.8443 | 0.004958 | 0.8553 |
| | 16 | 24 | 6.6350 | 9.9521 | 0.006267 | 0.7671 |
| | 32 | 24 | 5.9640 | 9.6879 | 0.005666 | 0.7793 |
| 0.001 | 16 | 24 | 6.3921 | 9.7231 | 0.006079 | 0.7777 |
| | 24 | 24 | 5.9555 | 8.2669 | 0.005611 | 0.8393 |
| | 32 | 24 | 7.3614 | 10.9586 | 0.006987 | 0.7176 |
| 0.0005 | 16 | 24 | 6.1153 | 9.4836 | 0.005775 | 0.7885 |
| | 32 | 24 | 5.8089 | 9.1388 | 0.005496 | 0.8036 |
| | 32 | 24 | 5.3768 | 8.7101 | 0.005100 | 0.8216 |
| 0.0005 | 16 | 24 | 6.0259 | 9.7937 | 0.005724 | 0.7744 |
| | 16 | 24 | 6.0790 | 9.0943 | 0.005767 | 0.8055 |
| | 32 | 24 | 7.0629 | 11.1114 | 0.006702 | 0.7097 |
| 0.0005 | 16 | 24 | 6.0544 | 9.3903 | 0.005741 | 0.7926 |
| | 24 | 24 | 6.6011 | 11.2632 | 0.006291 | 0.7017 |
| | 32 | 24 | 7.5776 | 11.7545 | 0.007222 | 0.6751 |
| 0.0005 | 16 | 24 | 5.6713 | 8.9317 | 0.005371 | 0.8124 |
| | 32 | 24 | 7.2239 | 11.4821 | 0.006856 | 0.6900 |
| | 32 | 24 | 6.4767 | 8.9564 | 0.006116 | 0.8114 |

之后, 改变 λ_2, λ_4 进行实验. 实验结果如图4所示. MAE, RMSE, MAPE尽可能小, R^2 尽可能大, 确定模型的参数为 $\lambda_2 = 24, \lambda_4 = 28$, 在目前的参数设置下, 模型参数数量相对较少. 在TCN特征提取部分卷积核大小为2. 对于模型的自适应部分, 阈值 μ 是根据训练批次预测误差均值的绝对值来确定的, 当预测误差均值的绝对值较大时适合进行局部模型再训练, 最终确定 $\mu = 7$.

4.3 预测结果分析

4.3.1 RDT预测结果

使用上述模型设定参数进行训练, 本文选用MAE作为损失函数对模型进行反向传播训练. 模型部分批次的预测结果如图5上半部分所示, 从图中可以看出在当前模型参数设置下, 粗轧出口温度预测值与实际值拟合程度较好, 二者偏差较小, 预测值在一定程度上符合实际值的变化趋势.

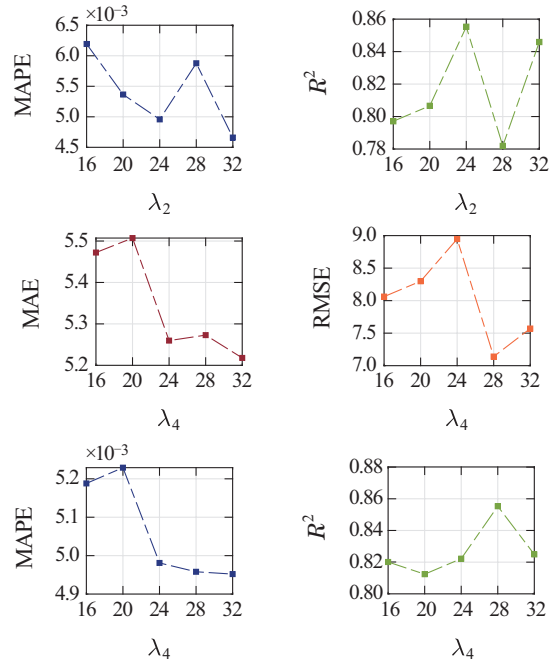



图 4 不同 λ_2, λ_4 下的性能分析

Fig. 4 Performance analysis of different λ_2, λ_4

本文提出的模型预测误差结果如图5下半部分所示. 从图可以看出, 方法预测结果的绝对误差较小, 温度测量值-温度预测值的样本点分布均匀, 且紧密分布在温度预测与温度测量相等的黑色直线以及黑色直线的两侧, 预测精度较高效果较好.

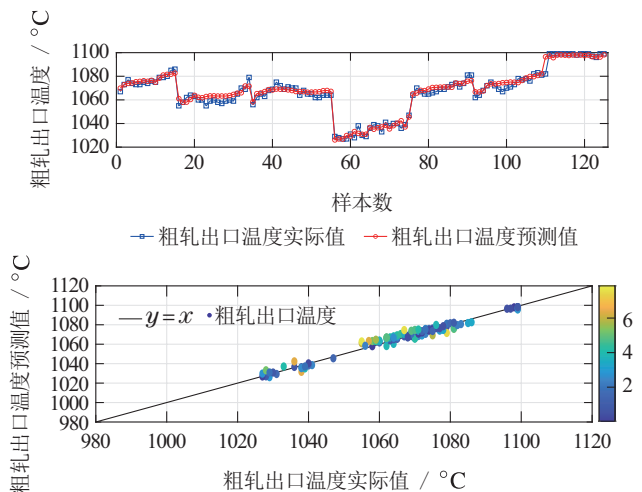


图 5 粗轧出口温度预测误差

Fig. 5 Rough rolling exit temperature prediction error curves

4.3.2 与常见方法对比

将训练好的模型在28个批次的测试集上进行测试, 并使用基于粗轧特征(TCN)、两工序数据融合(PLS、递归神经网络(recurrent neural network, RNN)、LSTM、两工序特征融合预测方法和本文提出的方法进行粗轧出口温度预测结果的比较. 其中, 基于粗轧特征的模型通过TCN对粗轧数据进行特征提取, 之后

经过LSTM层和两层全连接层得到温度输出. PLS经过5折交叉有效性验证, 并使用MAE的负值作为评分标准, 确定潜在变量数为26. RNN和LSTM均将加热炉数据和粗轧数据的拼接作为模型的输入, 之后分别经过RNN层和LSTM层, 最后进行两层全连接得到粗轧出口温度输出, 两种方法的 r 为0.000 5.

两工序特征融合预测模型通过LSTM对加热炉数据进行特征提取, 并通过TCN对粗轧数据进行特征提取, 之后通过LSTM层进行两部分特征的融合, 最后进行两层全连接得到温度输出. 自适应更新参数的两工序特征融合的预测模型是在特征融合预测模型基础上加入自适应机制后的预测模型, 对模型进行局部更新.

本文所述方法的粗轧出口温度预测结果图如图6所示, 其中训练和测试使用的数据包括不同粗轧出口温度设定值. 如第16、19批次粗轧出口温度设定值为 1040°C , 第17批次粗轧出口温度设定值为 1030°C , 第18批次粗轧出口温度设定值为 1070°C . 从粗轧出口温度预测值与温度实际值的曲线图中可以得知, 特征融合预测模型对不同粗轧出口温度设定的批次能有较好的预测结果, 并且总体预测效果比单一的TCN, PLS, RNN, LSTM方法要好, 体现本文提出的预测模型有较好的预测性能. 同时自适应更新参数的特征融合预测模型第5、19批次的温度预测结果比特征融合预测模型好, 这体现了本文提出的自适应调整机制的有效性.

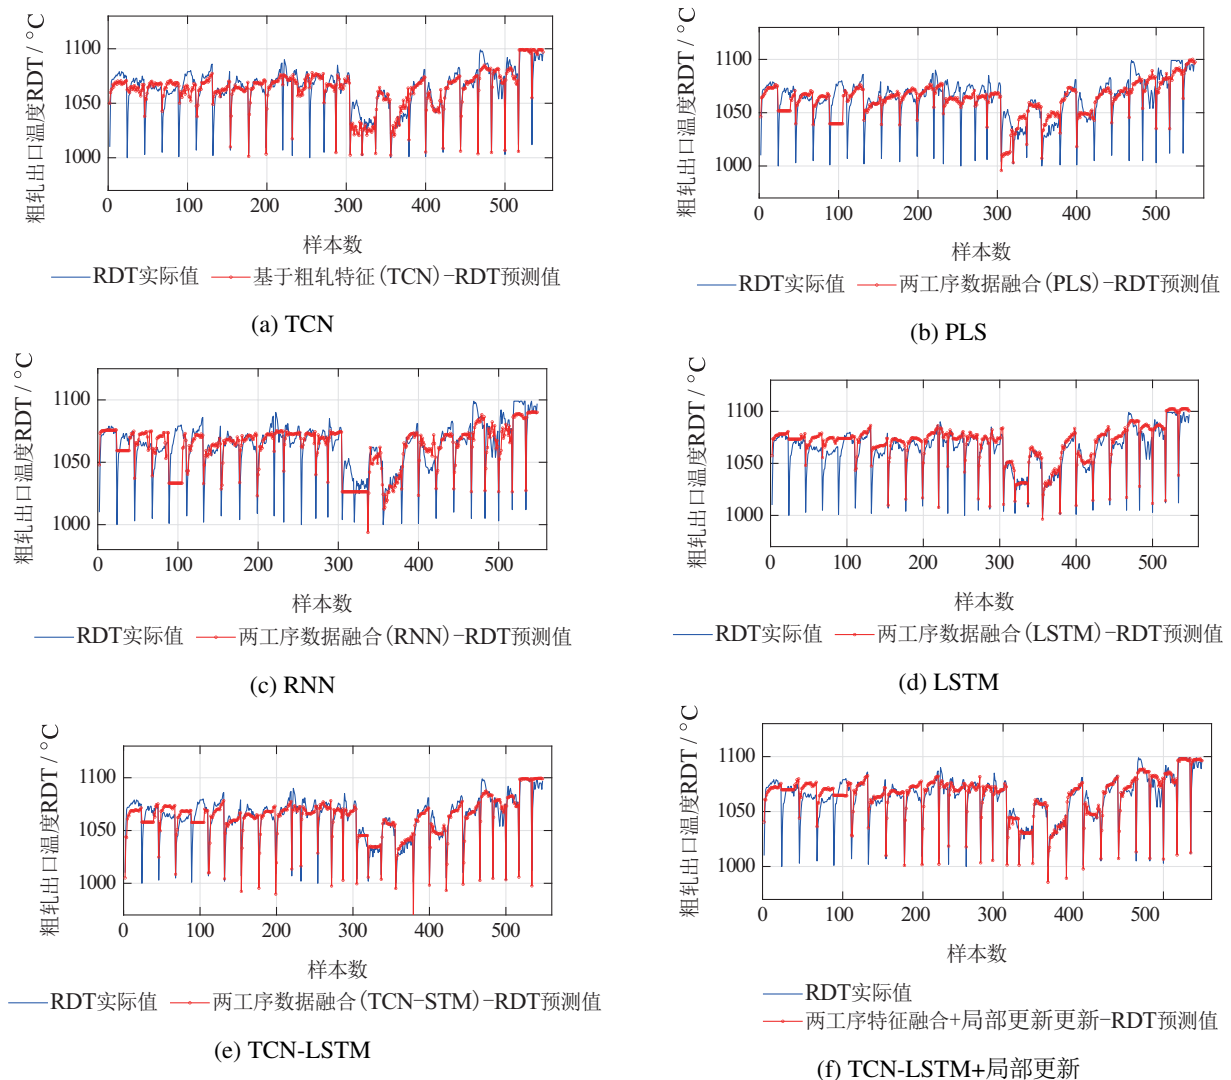


图6 不同方法多个板坯连续预测结果的对比

Fig. 6 Comparison of continuous prediction results of multiple slabs by different methods

4.3.3 多板坯预测误差分析

本文所述6种方法的粗轧出口温度预测结果的性能指标如表4所示. 根据预测结果可以得到, 本文所提方法的预测结果比基于粗轧特征(TCN)、两工序数据

融合方法(PLS, RNN, LSTM)和两工序特征融合方法的预测结果具有更高的预测精度, 具有更低的MAE, RMSE和MAPE, 以及更高的 R^2 . 这表明分别提取加热炉数据特征和粗轧数据特征并进行融合得到预测

值的预测模型相比于只使用粗轧数据的预测模型(单工序)、不分别提取加热炉和粗轧特征(PLS, RNN, LSTM)的预测模型具有更好的预测性能. 特征融合预测模型的预测性能MAE, MAPE和RMSE与不进行特征融合的模型相比平均提高了37.62%, R^2 平均提高了0.2068. 这反映了分别对加热炉和粗轧数据进行特征提取能够更好的挖掘温度影响变量和温度测量值的内在关系, 提高粗轧出口温度的预测精度. 加入自适应调整参数机制的特征融合方法的预测结果优于特征融合方法, 体现了本文自适应机制的有效性.

4.4 原型系统在线部署及应用

基于特征融合的粗轧出口温度预测模型部署在云边端协同原型系统中, 原型系统利用PLC在端侧上传数据, 通过端侧的服务器接收来自PLC的数据并上传至实时数据库. 端侧服务器通过TCP通讯将实时数据上传到边侧服务器的实时数据库中, 云侧服务器将离线训练参数部署在边侧服务器的MySQL数据库中, 其中包含训练数据的变量名、变量标准差和均值, 以及特征融合预测模型的模型参数. 边侧服务器根据模型参数分别进行加热炉和粗轧数据的特征提取, 并在粗轧侧进行特征融合和实时预测更新. 基于云侧计算的高效性以及边侧计算的灵活性和实时性, 进行模型的训练以及特征提取模型参数的边侧分布式部署.

边侧服务器通过MySQL存储训练得到的模型参数和加热炉特征. 端侧与边侧的实时数据库通过TCP通信传输数据, 边侧实时读取当前时刻传输的过程变

量. 边侧读取MySQL中训练集变量序列的标准差和均值, 并对实时数据进行预处理. 部署模型参数后, 加热炉侧和粗轧侧分别对同一钢卷号的加热炉数据和粗轧数据进行特征提取, 之后加热炉特征传递给粗轧侧与粗轧特征进行融合, 并经过两层全连接层得到实时粗轧出口温度的输出.

板坯数据实时传输到边侧, 边侧实时读取传输数据进行预测. 图7展示了2024年3月26日19:02–19:12分3个板坯的RDT实时预测情况及原型系统所记录的事件情况. 不同钢卷号的板坯先是经过粗轧咬钢事件进入粗轧第1道次的轧制过程, 当获取第5道次的数据之后开始逐条数据的数据对齐和实时预测, 数据对齐所需时间约0.01 s 小于采样周期0.1 s, 满足实时预测的实时性要求. 图中双向箭头展示相同时间段内粗轧第5道次轧制和粗轧出口温度实时预测两个事件的同步性, 体现了本文所述方法实时预测的可行性.

图7中边侧更新事件表明批次误差均值的绝对值 $|\delta|$ 触发更新. 模型相关时间如表5所示, 加热炉工序采样周期和间隔4个采样点回放一次的粗轧工序采样周期为0.1 s, 与采样周期一致. 云侧模型训练总时长约为20.8 min, 边侧更新和预测的平均时间分别为4.2 s和0.015 s, 边侧预测的时间小于采样周期, 符合实时性要求. 粗轧相邻板坯的轧制过程是依次分别进行的, 时间间隔平均时间为75 s, 自适应更新模型的平均时间远远小于相邻板坯的间隔时间, 因此本文自适应更新模型符合实际过程更新模型的时间要求.

表4 预测误差的统计特性比较

Table 4 Comparison of statistical characteristics of prediction errors

| 方法 | MAE ↓ | RMSE ↓ | MAPE ↓ | R^2 ↑ |
|-------------|-------------------|--------------------|-------------------|----------------------|
| 1) TCN | 7.303 9 | 12.433 7 | 0.007 0 | 0.636 5 |
| | 7.235 8 ± 3.077 5 | 11.186 7 ± 5.245 0 | 0.006 8 ± 0.002 9 | -15.368 1 ± 30.748 6 |
| 2) PLS | 9.697 4 | 14.433 2 | 0.009 2 | 0.512 0 |
| | 9.708 3 ± 4.501 5 | 13.273 7 ± 5.258 8 | 0.009 2 ± 0.004 3 | 0.087 68 ± 0.750 3 |
| 3) RNN | 8.672 0 | 12.199 2 | 0.008 2 | 0.650 0 |
| | 8.567 1 ± 3.992 7 | 11.079 0 ± 4.907 9 | 0.008 1 ± 0.003 8 | -8.152 4 ± 29.060 9 |
| 4) LSTM | 6.635 1 | 11.035 5 | 0.006 3 | 0.713 6 |
| | 6.661 5 ± 2.982 5 | 9.858 2 ± 4.924 0 | 0.006 2 ± 0.002 8 | -12.882 4 ± 43.064 3 |
| 5) TCN-LSTM | 5.582 3 | 8.218 3 | 0.005 3 | 0.841 2 |
| | 5.510 7 ± 2.194 0 | 7.358 8 ± 3.539 1 | 0.005 2 ± 0.002 1 | -5.451 9 ± 22.343 1 |
| 6) 本文方法 | 4.939 5 | 7.551 9 | 0.004 7 | 0.865 9 |
| | 4.885 4 ± 2.298 7 | 6.500 0 ± 3.760 8 | 0.004 5 ± 0.002 4 | -6.112 6 ± 21.315 3 |

5 结论

为了提高热连轧过程粗轧出口温度的预测精度, 本文提出了一种基于特征融合的热连轧过程出口温度建模方法. 使用LSTM和TCN分别对热连轧过程加

热炉数据和粗轧数据进行特征提取, 使用基于LSTM的融合层对提取的特征进行融合, 以挖掘更深层次的动态特征, 并融合注意力机制增强模型的自适应性. 本文使用138批次数据进行训练和测试, 在对数据进

行数据对齐、归一化等预处理后得到构建模型输入所需的样本, 之后使用网格搜索算法和对比实验确定了模型所需设置的超参数和自适应更新框架的结构。

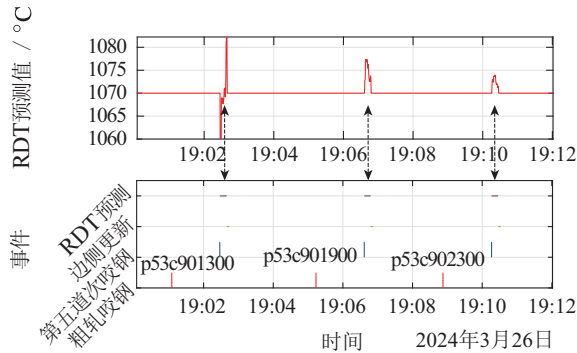


图 7 部分批次实时预测和事件触发图

Fig. 7 Real-time prediction and event triggering

表 5 模型训练与预测相关时间

Table 5 The time for model training and prediction

| 服务器 | 时间 | 时间长度 |
|-----|----------|------------------------|
| 云侧 | 集中模型训练时间 | 20.815 5 ± 0.382 9 min |
| | 局部模型更新时间 | 4.210 9 ± 0.213 5 s |
| 边侧 | 单个样本预测时间 | 0.015 27 ± 0.004 92 s |
| | 采样周期 | 100 ms |

将本文所述方法与 TCN, PLS, RNN, LSTM 等预测方法的预测精度进行对比. 通过计算 MAE, RMSE, MAPE 和 R^2 等性能指标揭示模型预测的性能, 并对各个方法预测和误差曲线的结果进行分析和比较. 实验结果表明, 本文提出的基于特征融合的预测模型具有较好的预测性能, 自适应机制可以改善粗轧出口温度的预测结果, 在一定程度上提高出口温度预测精度. 此外, 将本文提出的自适应预测方法部署在云边端协同原型系统中进行应用验证, 体现了本文提出预测方法的有效性和实时性, 有望在实际生产中得到应用.

未来将进一步考虑被轧制板坯在训练数据中没有对应钢种和规格的情况, 设计整个模型的迁移规则或重训练, 完善自适应更新机制, 提升方法的泛化能力.

参考文献:

[1] LIU Jie, YANG Weidong, LIU Wenzhong. *Automation Technology for Hot Rolling Production*. Beijing: Metallurgical Industry Press, 2017.
(刘玠, 杨卫东, 刘文仲. 热轧生产自动化技术. 北京: 冶金工业出版社, 2017.)

[2] GUI Weihua, YUE Weichao, XIE Yongfang, et al. A review of intelligent optimal manufacturing for aluminum reduction production. *Acta Automatica Sinica*, 2018, 44(11): 1957 – 1970.
(桂卫华, 岳伟超, 谢永芳, 等. 铝电解生产智能优化制造研究综述. 自动化学报, 2018, 44(11): 1957 – 1970.)

[3] CHAI T Y, ZHANG J W, YANG T. Demand forecasting of the fused magnesia smelting process with system identification and deep

learning. *IEEE Transactions on Industrial Informatics*, 2021, 17(12): 8387 – 8396.

[4] HAN Honggui, ZHANG Linlin, WU Xiaolong, et al. Data-knowledge driven multiobjective optimal control for municipal wastewater treatment process. *Acta Automatica Sinica*, 2021, 47(11): 2538 – 2546.
(韩红桂, 张琳琳, 伍小龙, 等. 数据和知识驱动的城市污水处理过程多目标优化控制. 自动化学报, 2021, 47(11): 2538 – 2546.)

[5] LI Y X, YANG C J, SUN Y X. Dynamic time features expanding and extracting method for prediction model of sintering process quality index. *IEEE Transactions on Industrial Informatics*, 2022, 18(3): 1737 – 1745.

[6] XIE X C, SUN W, CHEUNG K C. An advanced pls approach for key performance indicator-related prediction and diagnosis in case of outliers. *IEEE Transactions on Industrial Electronics*, 2016, 63(4): 2587 – 2594.

[7] JIANG Q C, YAN X F, YI H, et al. Data-driven batch-end quality modeling and monitoring based on optimized sparse partial least squares. *IEEE Transactions on Industrial Electronics*, 2020, 67(5): 4098 – 4107.

[8] SUN Tiejun, YANG Weidong, CHENG Yanming, et al. Improved genetic algorithm for optimizing prediction model of strip coiling temperature. *Control Theory & Applications*, 2015, 32(8): 1106 – 1113.
(孙铁军, 杨卫东, 程艳明, 等. 用改进遗传算法优化的带钢卷取温度预报模型. 控制理论与应用, 2015, 32(8): 1106 – 1113.)

[9] WANG H Y, DONG H L, ZHANG L, et al. Prediction of dynamic temperature rise of thermocouple sensors based on genetic algorithm-back propagation neural network. *IEEE Sensors Journal*, 2022, 22(24): 24121 – 24129.

[10] GAO M S, WU Q L, LI J, et al. Temperature prediction of solar greenhouse based on NARX regression neural network. *Scientific Reports*, 2023, 13(1): 1563.

[11] WEN X Y, LI W B. Time series prediction based on LSTM-Attention-LSTM model. *IEEE Access*, 2023, 11: 48322 – 48331.

[12] YUAN X F, LI L, SHARDT Y A W, et al. Deep learning with spatiotemporal attention-based LSTM for industrial soft sensor model development. *IEEE Transactions on Industrial Electronics*, 2021, 68(5): 4404 – 4414.

[13] YUAN X F, LI L, SHARDT A W, et al. Nonlinear dynamic soft sensor modeling with supervised long short-term memory network. *IEEE Transactions on Industrial Informatics*, 2022, 16(5): 3168 – 3176.

[14] REN L, WANG T, LAILI Y J, et al. A data-driven self-supervised LSTM-deepfm model for industrial soft sensor. *IEEE Transactions on Industrial Informatics*, 2022, 18(9): 5859 – 5869.

[15] CHEN Zhonglin, YANG Cuili, QIAO Junfei. The prediction of incomplete time series via TG-LSTM neural network. *Control Theory & Applications*, 2022, 39(5): 867 – 878.
(陈中林, 杨翠丽, 乔俊飞. 基于TG-LSTM神经网络的非完整时间序列预测. 控制理论与应用, 2022, 39(5): 867 – 878.)

[16] HU C S, CHENG F J, MA L, et al. State of charge estimation for lithium-ion batteries based on TCN-LSTM neural networks. *Journal of the Electrochemical Society*, 2022, 169(3): 30544 – 30556.

[17] FANG Yijing, JIANG Zhaohui, GUI Weihua, et al. Burning through point prediction based on working condition knowledge guided attention mechanism temporal convolutional network. *Control Theory & Applications*, 2024, 41(3): 447 – 453.
(方怡静, 蒋朝辉, 桂卫华, 等. 基于工况知识引导注意力时间卷积网络的烧结终点预测. 控制理论与应用, 2024, 41(3): 447 – 453.)

[18] HU X K, ZHOU X M, LIU H F, et al. Enhanced predictive modeling of hot rolling work roll wear using TCN-LSTM-attention. *The International Journal of Advanced Manufacturing Technology*, 2024, 131: 1335 – 1346.

- [19] WANG X, HOU Z Q, YU W S, et al. Online scale adaptive visual tracking based on multilayer convolutional features. *IEEE Transactions on Cybernetics*, 2019, 49(1): 146 – 158.
- [20] ZHANG W, WU Z B, ZENG X J, et al. An ensemble dynamic self-learning model for multiscale carbon price forecasting. *Energy*, 2023, 263: 125820.
- [21] WANG Z Q, LIU N, CHEN C L, et al. Adaptive self-attention LSTM for RUL prediction of lithium-ion batteries. *Information Sciences*, 2023, 635: 398 – 413.
- [22] YI Chengming, ZHOU Ping, CHAI Tianyou. Data-driven just-in-time learning based adaptive predictive control for blast furnace iron-making. *Control Theory & Applications*, 2020, 37(2): 295 – 306. (易诚明, 周平, 柴天佑. 基于即时学习的高炉炼铁过程数据驱动自适应预测控制. *控制理论与应用*, 2020, 37(2): 295 – 306.)
- [23] WANG Xiaoyong, LIANG Jun, LIU Yuming, et al. Recursive PLS based adaptive soft-sensor model and its application. *Journal of Zhejiang University (Engineering Science)*, 2005, (5): 676 – 680. (汪小勇, 梁军, 刘育明, 等. 基于递推PLS的自适应软测量模型及其应用. *浙江大学学报(工学版)*, 2005, (5): 676 – 680.)
- [24] CHEN J Y, HAO P F, SONG J P, et al. Study on temperature prediction model of cold rolling strip. *International Conference on Artificial Intelligence and Big Data (ICAIBD)*. Chengdu, China: IEEE, 2018: 214 – 217.
- [25] HUANG K K, TAO Z, WANG C, et al. Cloudedge collaborative method for industrial process monitoring based on error-triggered dictionary learning. *IEEE Transactions on Industrial Informatics*, 2022, 18(12): 8957 – 8966.
- [26] YUAN X F, QI S B, WANG Y L, et al. Quality variable prediction for nonlinear dynamic industrial processes based on temporal convolutional networks. *IEEE Sensors Journal*, 2021, 21(18): 20493 – 20503.
- [27] YI Chengxin, LI Weigang, LÜ Lihua, et al. Prediction of rough rolling exit temperature in hot strip continuous rolling based on RF-LSTM model. *Journal of Iron and Steel Research*, 2021, 33(9): 952 – 959. (易成新, 李维刚, 吕立华, 等. 基于RF-LSTM的热连轧板坯粗轧出口温度预报. *钢铁研究学报*, 2021, 33(9): 952 – 959.)
- [28] REN L, JIA Z D, WANG T, et al. LM-CNN: A cloudedge collaborative method for adaptive fault diagnosis with label sampling space enlarging. *IEEE Transactions on Industrial Informatics*, 2022, 18(12): 9057 – 9067.
- [29] GAO Suting, CHAI Tianyou. Intelligent forecasting method of caustic concentration in alumina production process based on end-edge-cloud coordination. *Acta Automatica Sinica*, 2023, 49(5): 964 – 973. (高慷婷, 柴天佑. 端边云协同的氧化铝生产过程苛性碱浓度智能预报方法. *自动化学报*, 2023, 49(5): 964 – 973.)

作者简介:

张凯 副教授, 硕士生导师, 目前研究方向为故障诊断与先进控制、智能运维与优化决策, E-mail: kaizhang@ustb.edu.cn;

王亚礼 硕士研究生, 目前研究方向为数据驱动的质量预测, E-mail: wyl2264393062@163.com;

张晓雯 硕士研究生, 目前研究方向为工况评估与预测, E-mail: a18zxw@163.com;

彭开香 教授, 博士生导师, 目前研究方向为工业智能与智能制造、故障诊断与容错控制, E-mail: kaixiang@ustb.edu.cn.