

机理指导的 LSTM 网络及其在康斯迪电弧炉钢水 连续温度预测中的应用

李 闯¹, 毛志忠^{2†}, 欧 阳¹, 温远光¹

(1. 沈阳飞机工业(集团)有限公司, 沈阳 110850; 2. 东北大学 信息科学与工程学院, 沈阳 110819)

摘 要: 在康斯迪电弧炉的冶炼过程中, 及时准确地预测钢水温度对优化整个冶炼过程、节约生产成本起到至关重要的作用. 然而, 受制于电弧炉极限的生产条件以及相当稀疏的温度测量次数, 无论是复杂的机理模型还是基于数据的机器学习模型都无法获得理想的预测结果. 针对这一问题, 通过将机理知识与 LSTM 网络相结合, 提出一种机理指导的 LSTM 网络模型实现对钢水温度连续准确的预测. 首先, 根据康斯迪电炉的冶炼特点, 以 LSTM 网络为核心设计模型的基本结构; 然后, 提出一个约束层将模型中间层的输出限制在由冶炼机理确定的合理范围之内, 通过这种方式实现用冶炼知识指导网络的训练方向, 使模型的输出更符合冶炼实际, 同时又可弥补训练标签稀疏的问题; 最后, 使用现场收集的冶炼数据验证所提出的模型的有效性. 实验结果表明, 相比于其他温度预测模型, 所提出的模型的预测精度更高且与冶炼机理知识更相符.

关键词: 康斯迪电弧炉; LSTM 网络; 约束层; 连续温度预测; 冶炼知识; 稀疏标签

中图分类号: TF741.5 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2025.0361

引用格式: 李闯, 毛志忠, 欧阳, 等. 机理指导的 LSTM 网络及其在康斯迪电弧炉钢水连续温度预测中的应用 [J]. 控制与决策, 2025, 40(10): 3055-3064.

Mechanism-guided LSTM network for continuous temperature prediction in Consteel smelting process

LI Chuang¹, MAO Zhi-zhong^{2†}, OU Yang¹, WEN Yuan-guang¹

(1. Shenyang Aircraft Corporation, Shenyang 110850, China; 2. College of Information Science and Engineering, Northeastern University, Shenyang 110819, China)

Abstract: Temperature prediction of molten steel always plays a significant role in the smelting process of the Consteel electric arc furnace (EAF), as obtaining the accurate temperature timely contributes to refining the whole process and reducing the production cost. However, limited by the extreme smelting conditions of the EAF and the rather sparse temperature measurements, neither the physical-based model nor the data-based machine learning one alone is able to achieve precise prediction results. To address this problem, we provide a temperature prediction model by integrating mechanism knowledge with a LSTM network. First, the model framework is constructed according to intrinsic characteristics of the Consteel smelting process. We leverage a LSTM network as the core of the model to accomplish the basic task of continuous temperature prediction. Then, a special constraint layer is developed to limit the output of the intermediate layer of the model to a reasonable range, which is determined by the energy balance of molten steel. In this way, valuable smelting knowledge can be embedded in the training process of the network, and the problem of label insufficiency is compensated resultantly. Finally, a series of experiments are conducted based on a practical dataset collected from a Consteel EAF production site. The proposed model is compared with several state-of-the-art models, where the results illustrate its superiority.

Keywords: Consteel electric arc furnace; LSTM network; constraint layer; continuous temperature prediction; smelting knowledge; sparse labels

0 引 言

电弧炉是现代炼钢工业中一个关键的生产单元.

当前, 全世界粗钢总产量约 30% 经由电弧炉冶炼过程产出^[1]. 与转炉炼钢相比, 电弧炉展现出显著的低

收稿日期: 2025-04-08; 录用日期: 2025-07-07.

责任编辑: 阳春华.

[†]通信作者. E-mail: maozhizhong@ise.neu.edu.cn.

能耗、环保等特点,并且相关技术的不断完善也在持续地释放其生产潜力^[2]. 康斯迪工艺是电弧炉众多创新技术中的一个典型代表,通过这种工艺,废钢可以连续不断地送入到炉中进行冶炼,由此形成的平稳熔池可以使电炉的冶炼状态更加稳定,从而极大地提升电炉的生产效率.

在康斯迪电炉的冶炼过程中,钢水温度是最受关注的生产指标之一. 实时掌握钢水温度不仅有助于优化冶炼过程,获得高质量钢水,还可以指导电炉操作人员避免过热钢水,从而减少生产成本,提高冶炼效率. 然而,受制于实际生产过程对冶炼节奏的要求,以及炉内恶劣的冶炼条件,钢水温度通常只能在终点附近进行有限次数的测量,这意味着整个冶炼过程绝大多数时间内的钢水温度只能依靠电炉操作人员根据经验进行估计. 显然,由此得到的钢水温度的波动较大,其精度也无法得到保证.

为了弥补钢水温度测量不足的问题,学界提出了许多温度预测模型实现对钢水温度的软测量. 根据建模方法的不同,现有模型大致可以分为机理模型和数据模型两大类.

机理模型通常是将电弧炉作为一个热力学单元处理,通过分析炉内各物质的物料平衡及能量平衡描述钢水温度的实时变化情况. MacRosty等^[3]基于基本的热力学、动力学原理建立了一个动态的电炉模型,他们从空间维度将电弧炉内部分成多个区域,通过分析不同区域间的物质、能量交换建立包括钢水温度在内的多种冶炼变量的连续模型; Optiz等^[4]将电弧炉分成了熔池、电气系统、电极调节系统及废气处理系统4个子系统,根据系统内及系统间的物料、能量平衡建立了实用的冶炼模型. 虽然机理模型具有较强的可解释性,但是电弧炉极限的冶炼环境决定了这些模型总是不可避免地存在着大量的假设和简化,同时,一些关键的模型参数受现场试验成本和安全性等因素的限制通常也很难得到,这在很大程度上影响了它们的预测精度.

不同于机理模型,数据模型摒弃了复杂的冶炼机理,转而利用生产数据建立冶炼变量与钢水温度之间的映射关系. 这些模型通常更易于开发,并且各种先进机器学习模型的运用也为取得精确的预测结果提供了可能. Choi等^[5]通过详细的实验对比了6个传统机器学习模型对钢水终点温度的预测性能,其中RBF-SVR模型取得了最高的预测精度; Liu等^[6]提出了一个残差时空卷积神经网络动态预测钢水的温度分布,由于该模型能够从时间、空间两个维度考虑各变量对钢水温度的影响,其预测精度相比于传

统的多层神经网络取得了较大的提升; Wang等^[7]将PSO优化算法与LSTM网络相结合预测钢水的终点温度,在该模型中,PSO算法用于确定冶炼模型的最优超参数, LSTM网络用于描述时变冶炼变量与终点温度之间的映射关系,实验结果表明,该模型比传统的机器学习模型及人工确定冶炼参数的模型的预测精度更高. 在实际的冶炼过程中,钢水温度一般只在出钢点附近进行测量,冶炼中间过程温度测量值的缺乏意味着训练模型所必需的目标值是不足的,这导致很难建立钢水的连续温度预测模型. 事实上,这也是现有的数据模型仅能实现对终点温度或终点附近升温阶段的钢水温度进行预测的原因. 对康斯迪电炉冶炼全过程钢水温度的连续预测仍是一项极具挑战性的任务.

针对现有模型的不足,本文提出一种钢水连续温度预测模型. 该模型的设计灵感来自于最近兴起的关于知信机器学习^[8]/机理指导的机器学习^[9]的研究. 虽然机器学习技术在建模方面展现出巨大的优势,但在处理训练数据不足或满足工程应用场景中的物理规律时仍存在局限性. 将领域知识融入机器学习过程是解决此类问题的一种有效方案. 当前,大量机理指导的机器学习模型已在包括制造业^[10]、材料科学^[11]、地质学^[12]、电力系统^[13]、环境工程^[14]在内的各领域取得了显著进展. 受这些成功的混合建模方法的启发,本文尝试将关键的冶炼机理知识嵌入到深度神经网络,以实现钢水温度的连续预测. 具体而言,本文的工作主要包括以下方面:

1) 提出一个约束层,该约束层可以在不影响网络训练的前提下整合到任何网络结构中以使网络的输出符合由机理知识确定的一个合理范围.

2) 建立一个基于LSTM网络的钢水温度连续预测模型. 该模型结构的设计融合了机理模型的建模方法,能够反映出实际冶炼过程中钢水温度的一般变化情况.

3) 利用所提出的约束层将钢水温度变化范围的信息嵌入到网络模型中来缓解稀疏的温度测量给模型训练造成的困难,从而实现钢水温度连续准确的预测.

1 问题描述

图1展示了康斯迪电炉的主要组成结构. 电炉的核心功能是快速熔化废钢,为下一个冶炼工序提供温度和成分合格的钢水. 冶炼过程启动后,经预热的废钢通过水平振料器被连续不断地送入炉中. 同时,三相电极下降至熔池表面产生高能电弧,作为熔

炼钢水的主要热源. 炉壁和炉门碳氧枪将碳粉和氧气注入熔池以形成泡沫渣, 泡沫渣的埋弧作用可以有效提升电弧的传热效率. 氧气除了参与造渣, 还通过对碳元素及少量金属元素的氧化提供额外的化学能, 以促进废钢的熔化. 炉底吹氩系统与冶炼过程同步启动, 上升的氩气气泡对熔池起到搅拌作用, 可以显著提升钢水内部的传热效率. 当熔池重量达到预设值以后, 进料停止, 冶炼进入升温阶段. 这一阶段的冶炼状态比较稳定, 钢水温度持续上升, 电炉操作人员会在该阶段根据经验进行几次采样测温, 一旦钢水温度和成分满足出钢要求便会执行出钢操作, 这也标志着整个冶炼过程的结束.

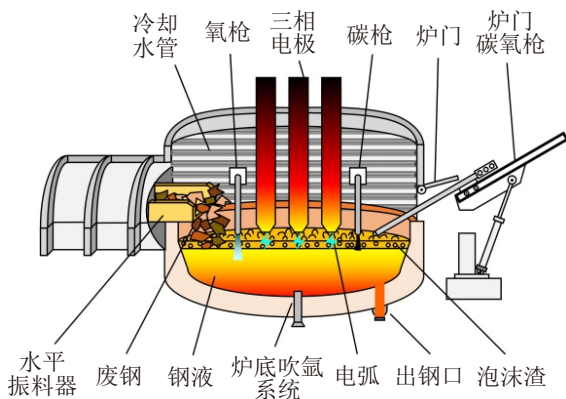


图1 康斯迪电炉的主要组成结构

在康斯迪电炉的冶炼过程中, 实时掌握钢水温度有助于对吹氧、喷碳、电极升降等关键工艺操作进行合理的控制, 从而维持冶炼过程的平稳运行并提升冶炼效率. 为了满足生产节奏的要求, 120 t 康斯迪电炉的冶炼周期通常被限制在 40 min 左右, 而受现有测量手段的限制, 单次测温操作一般耗时 1~2 min, 这导致在实际生产过程中仅能在出钢点附近进行必要的几次测温. 由于充足的带有标签的样本是机器学习模型得到有效训练的前提, 如此稀疏的温度数据使得应用机器学习模型实现钢水温度的连续预测面临巨大的挑战.

为了解决温度数据不足的问题, 本文提出一种融合机理与数据的混合建模方法, 即: 首先通过机理模型估计钢水温度合理的变化范围; 然后将这个范围知识嵌入到网络中指导其参数的训练方向. 如前所述, 由于炉内恶劣的冶炼环境, 机理模型本身必然存在着简化处理, 同时一些模型参数也难以准确测量. 因此, 这里利用温度变化的区间信息而非精确的温度值更具可操作性. 尽管这种温度变化的范围值是近似的, 但该区间所反映出的钢水温度的真实变化情况仍能有效指导网络的训练方向, 从而提升网

络的连续预测精度.

2 机理指导的钢水连续温度预测模型

2.1 机理模型

利用能量平衡原理建立钢水温度的连续预测模型. 具体而言, 将整个冶炼过程平均分为 N 个时间段, 对于任意的第 i 个时间段, 熔池的热量流入与流出相等, 可以按照下式表达:

$$E_{\text{arc}}^i + E_{\text{che}}^i = E_{\text{bat}}^i + E_{\text{wat}}^i + E_{\text{bot}}^i. \quad (1)$$

其中: E_{arc}^i 表示电弧释放的热量中被熔池吸收的那部分热量, E_{che}^i 表示熔池中发生的所有氧化反应释放的热量, E_{bat}^i 表示熔化废钢、加热钢水的被有效利用的热量, E_{wat}^i 表示炉壁及炉顶冷却管中循环冷却水带走的来自于熔池表面热辐射损失的热量, E_{bot}^i 表示炉底热损失的热量.

利用基本的冶炼知识及一些关键的工艺参数, 可以从工程应用的角度对式 (1) 中的各能量项进行合理地估算. 下面各式^[15-16] 给出了具体的估算方法:

$$E_{\text{arc}}^i = \eta E_{\text{ele}}^i, \quad (2)$$

$$E_{\text{che}}^i = \alpha V_{\text{oxy}}^i, \quad (3)$$

$$E_{\text{bat}}^i = C_s M_{\text{sc}}^i T_{\text{dev}}^i + H_{\text{lh}} M_{\text{sc}}^i + C_l M_{\text{bat}}^i \Delta T^i, \quad (4)$$

$$E_{\text{wat}}^i = \beta C_w \rho_w^i \Delta t \Delta T_w^i, \quad (5)$$

$$E_{\text{bot}}^i = (7 + 0.05 T_{\text{bot}}^i) \times F_{\text{bot}} \times (T_{\text{bot}}^i - T_{\text{aa}}^i) \times \Delta t. \quad (6)$$

其中: E_{ele}^i 表示电炉变压器一次测消耗的电能, V_{oxy}^i 表示氧气的消耗量, C_s 和 C_l 分别表示固态钢和钢水的热容, M_{sc}^i 和 M_{bat}^i 分别表示加入炉中的废钢的重量及熔池的钢水重量, T_{bot}^i 表示废钢熔点与预热温度之间的温差, H_{lh} 表示钢水的潜热, ΔT^i 表示钢水的温度增量, C_w 和 ρ_w^i 分别表示冷却水的热容和流速, Δt 表示时间间隔, ΔT_w^i 表示冷却水管入口与出口处的平均温差, T_{bot}^i 和 T_{aa}^i 分别表示炉底温度和周围环境温度, F_{bot} 表示炉底表面积. 这里 η , α 和 β 表示根据冶炼经验估计的 3 个过程参数.

根据式 (1)~(6), 可以推导出第 i 个时间段内钢水温度的增量 ΔT^i 的表达式为

$$\Delta T^i = \frac{E_{\text{arc}}^i + E_{\text{che}}^i - E_{\text{wat}}^i - E_{\text{bot}}^i - M_{\text{sc}}^i (C_s T_{\text{dev}}^i + H_{\text{lh}})}{C_l M_{\text{bat}}^i}. \quad (7)$$

根据 ΔT^i , 结合冶炼前钢水的初始温度 T_0 , 可以得到钢水连续温度预测模型为

$$T^n = T_0 + \sum_{i=1}^n \Delta T^i, \quad n = 1, 2, \dots, N, \quad (8)$$

其中 N 表示冶炼结束时总的时段数。

上文建立的机理模型揭示了钢水温度变化的基本规律, 同时避免了复杂的计算, 能够为电炉操作人员提供更多关于炉内当前冶炼状态的信息. 然而, 由于式 (2)~(6) 表达的能量项主要是根据冶炼经验建立的, 且过程参数 η , α , β 及一些冶炼变量如 T_{bot}^i 和 T_{dev}^i 通常以近似的范围值而非精确数值来描述, 同时, 一些对钢水温度有重要影响的复杂冶炼现象, 比如电弧长度随钢液表面波动的变化情况、实时发生的化学反应类型^[17]、氩气气泡对熔池的搅拌效应等均难以通过精确的表达式描述, 因此该模型无法用于精确的温度预测.

针对上述问题, 本文提出一种机理指导的深度神经网络. 机理知识的运用在该模型中发挥了重要作用. 一方面, 该模型引入 LSTM 网络, 以式 (8) 为基础构建其基本结构. 这种结构知识能够体现实际冶炼过程中钢水温度变化的一般规律, 有助于提升模型的预测精度. 另一方面, 所建模型的输出通过一个特别设计的约束层限制在合理的变化范围内, 而这些范围的上、下限则可根据式 (2)~(7) 所示的机理模型计算得到. 这种范围知识依据机理指导网络的训练方向, 可以有效解决温度测量数据不足的问题, 有助于网络实现合理的连续预测.

2.2 机理指导的 LSTM 模型

2.2.1 模型结构

图 2 展示了所提出模型的基本结构. 为了实现连续温度预测任务, 将康斯迪电炉的一个完整的冶炼过程平均分为 N 个时间段, 并采用 9 维时间序列向量作为模型的输入. 这 9 维向量的元素由对康斯迪电炉冶炼过程具有显著影响的冶炼变量组成, 其中前 5 个元素在式 (2)~(5) 中已经进行过介绍, 后 4 个元素 M_{car}^i , M_{mag}^i , M_{lim}^i 和 V_{ar}^i 分别代表第 i 个时间段内加入到炉中的碳粉质量、镁球质量、石灰质量及氩气体积. 石灰和镁球作为造渣剂直接参与炉内的造渣反应, 生成的泡沫渣通过埋作用显著影响电弧的传热效率, 从而影响钢水温度. 碳粉一方面参与熔池中的氧化反应, 放出大量热量; 另一方面其生成的大量 CO 气泡直接参与泡沫渣的发泡过程, 进而也通过泡沫渣埋弧影响钢水温度. 炉底喷吹的氩气则通过搅拌作用增强熔池的传热效率并提升熔池内的氧化反应速率. 这 4 个变量直接或间接影响钢水温度, 且它们所涉及的冶炼机理较复杂, 难以通过简单明确

的公式进行计算, 因此将这 4 个变量与前面 5 个变量一起作为模型的输入, 用以充分描述影响钢水温度的所有可能因素.

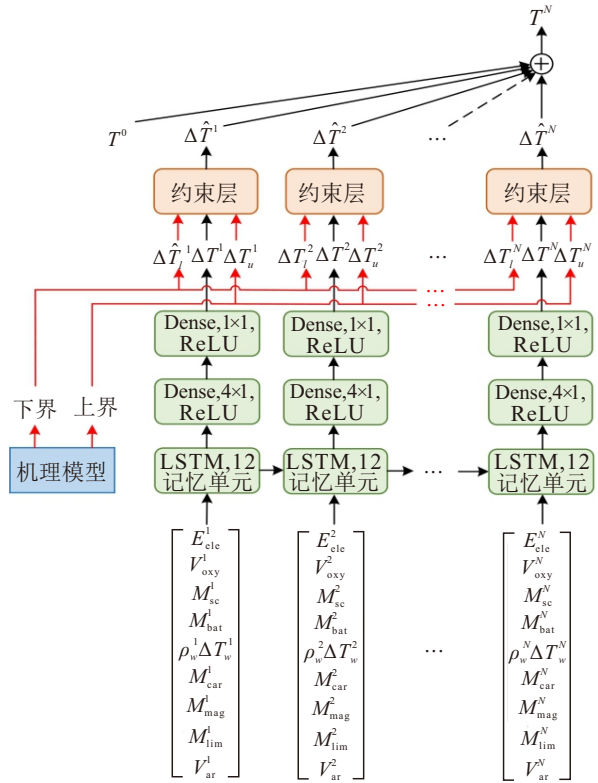


图2 机理指导的 LSTM 网络

采用带有 12 个记忆单元连接两个全连接层的 LSTM 网络建立时间序列输入与标量输出之间的复杂映射关系. 这里使用 LSTM 网络的动机在于其善于解决现实世界的时间序列问题^[18]. 第 2 个全连接层的输出被视为每个时间段内的温度增量, 这些增量通过一个约束层被限制在由机理模型确定的温度增量上、下限范围之内. 将所有约束层的输出 $\Delta \hat{T}^1 \sim \Delta \hat{T}^N$ 与冶炼初始温度 T^0 求和, 即可得到冶炼过程的终点温度, 从而可以使用收集的终点测温数据对模型进行训练. 该模型结构与式 (8) 保持一致, 能够真实反映康斯迪电炉实际冶炼过程的基本特征.

2.2.2 约束层

虽然深度学习技术已在诸多领域取得了显著的成功, 但在某些应用场景下, 仍然难以获取足够数量且具有代表性的训练数据, 从而限制其预测精度. 将领域知识整合进模型的训练过程是解决这一难题的有效方法. 就知识的形式而言, 最常见的当属某一系统中特定的工艺变量具有一个正常运行的定量范围. 事实上, 之前已有研究提出领域自适应方法^[19] (DAM), 将此类范围约束整合进网络的学习过程中. DAM 的具体设计为

$$f^* = \arg \min \text{Loss}(Y, \hat{Y}) + \lambda_D \text{Loss}_D(\hat{Y}), \quad (9)$$

$$\text{Loss}_D(\hat{Y}) = \sum_{i=1}^m \text{ReLU}(y_i^i - y^i) + \text{ReLU}(y^i - y_u^i). \quad (10)$$

其中: f^* 表示训练后含有最优模型参数的神经网络; $\text{Loss}_D(\hat{Y})$ 表示领域相关损失; λ_D 表示该损失项的权重系数; y^i 是网络特定层的输出, 表示具有实际意义的工艺变量; y_l^i 和 y_u^i 分别表示领域专家提供的, 或者是根据经验估计的工艺变量的下界和上界.

从式 (9) 和 (10) 可以观察到, DAM 通过在损失函数中引入额外的惩罚项整合变量的范围约束信息. 尽管 DAM 能够获得更合理的学习结果, 但其本身仍存在着明显的缺陷. 首先, 当训练过程结束时, 领域损失项 $\text{Loss}_D(\hat{Y})$ 几乎不可能下降至零. 这意味着仍有某些样本违背领域知识; 其次, 在损失函数中引入额外的惩罚项会提高其在训练结束时的最优值, 这在一定程度上降低了模型的预测精度; 最后, DAM 中超参数的值通常需要根据不同的学习任务进行调整, 而对于某些特别复杂的任务, 最优超参数的确定可能比较困难且非常耗时.

针对上述问题, 开发一个约束层, 将工艺变量的定量范围信息完美地整合进网络的训练过程中. 该层的计算方法如下:

$$\hat{y}^i = y_u^i \text{Sigmoid}(wy^i + b) + y_l^i \text{Sigmoid}(-(wy^i + b)). \quad (11)$$

为清晰起见, 将其结构展示在图 3 中. 对于该约束层, 利用 Sigmoid 函数的对称特性及其输出总是在 0 ~ 1 范围内的特点, 将 \hat{y}^i 设计成 y^i 的下界 y_l^i 与上界 y_u^i 的线性组合. 通过这种方式, 约束层的输出将始终位于预期的范围内, 且其最优取值可以通过对内部参数 w 和 b 的训练得到.




图3 约束层的结构

由于式 (11) 是完全可微的, 该约束层可以嵌入到神经网络的任意位置而不影响其训练过程. 在所提出的钢水连续温度预测模型中, 在温度增量的输出层后面应用此层, 将温度增量值调整到由机理模型确定的合理范围内. 通过这一操作, 使模型不仅能够根据实际采集的终点温度数据进行训练, 还可以对缺乏温度测量的冶炼中间过程的钢水温度进行合理地估计, 从而实现了对钢水温度的连续预测.

3 实验研究

3.1 基于仿真数据集的实验

首先通过 Bohachevsky 函数生成仿真数据集来验证本文提出的约束层的有效性. Bohachevsky 函数是一个具有二维输入、一维输出的常用标准测试函数^[18], 其表达式为

$$y = k_1 x_1^2 + k_2 k_2^2 + a_1 \cos(p_1 \pi x_1) + a_2 \cos(p_2 \pi x_2) + K. \quad (12)$$

为了方便实验, 这里对该函数的每一个求和项均设置了一个正系数, 即取 $a_1 = 0.3$, $a_2 = 0.4$, $p_1 = 3$, $p_2 = 4$, $k_1 = 1$, $k_2 = 2$, $K = 0.7$.

该函数被用来模拟现实世界中的复杂非线性过程. 假设可以收集到该过程的多组输入-输出数据, 那么就可以通过使用神经网络对这些数据进行训练, 得到一个具有良好泛化性能的模型, 从而实现对新样本的准确预测. 由于现实世界的复杂性, 实际收集的数据很可能会受到噪声等因素的影响而偏离其真值, 从而使模型的预测精度大幅降低. 在这种情况下, 如果可以根据机理知识或专家经验确定收集的数据在其真值附近的一个合理的取值范围并将这种范围信息融合到网络的训练过程中, 则能提升模型的预测精度.

基于上述想法设计具体的实验过程. 首先, 在 $x_1 \in N(5, 1)$, $x_2 \in N(20, 1)$ 中随机选取 600 个点作为模型输入, 根据式 (12) 计算出对应的 y 值作为模型输出, 并取其中 400 个样本作为训练集, 100 个样本作为验证集, 100 个样本作为测试集. 然后, 对训练集样本的输出施加不同水平的随机噪声 $\sigma \in N(0, \rho \cdot \bar{y})$ 用以模拟现实数据的真实情况. 其中: \bar{y} 表示训练集样本输出值的平均值, ρ 表示噪声系数, 用于调整施加噪声的整体幅度, 在实验中取 ρ 值的范围为 $[0.1, 0.5]$. 接下来, 为每一个样本的输出值设定一个合理的变化范围, 并假设这些范围值是根据机理知识或专家经验确定的, 这里取每一个样本的上、下限分别为 $1.1y$ 和 $0.9y$. 最后, 使用一个含有两个隐藏层的前馈神经网络 (BP) 结合不同的范围值约束方法作为预测模型, 该网络的第 1 个隐藏层含有 64 个神经元, 第 2 个隐藏层含有 128 个神经元, 所有神经元均使用 Sigmoid 函数作为激活函数. 在实验时, 使用训练集数据对各模型训练 200 个回合, 取验证集上预测性能最好的模型对测试集数据进行预测. 为了消除特定样本组合带来的实验误差, 将上述实验重复 5 次, 取预测值的均方根误差 (RMSE) 的平均值作为最终的实验结果. 显然, 模型的预测误差越低, 对

应的融合范围知识的方法越有效。

在实验中引入两个额外的融合范围知识的方法作为本文提出的约束层的对比方法, 其中一个是第 2.2.2 节介绍过的 DAM 方法, 另一个是深度学习框架中的 Clip 函数. 该函数可以通过设置一个最小值和最大值将网络任意层的输出限制在给定的范围内. 为了方便展示实验结果, 这里使用 CL 作为约束层的简称.

表 1 给出所有方法的预测结果.

表1 基于仿真数据集的模型预测结果

ρ	0	0.1	0.2	0.3	0.4	0.5
BP	5.2±1.3	7.9±0.8	17.9±1.6	26.0±4.0	35.5±2.2	51.6±4.5
BP + DAM	5.9±0.8	6.8±0.4	15.5±1.8	23.4±1.4	30.0±2.3	42.0±3.7
BP + Clip	5.7±0.3	7.7±0.5	22.8±3.7	68.0±5.4	81.0±1.4	82.0±1.2
BP + CL	0.4±0.2	1.0±0.4	1.4±0.4	1.2±0.5	1.3±0.3	1.5±0.4

从该结果中可以观察到, 无论整体的噪声幅度如何变化, 嵌入约束层的网络均取得了一致、最低的预测误差. 这一优越性能得益于约束层的特殊设计使其可以将网络的输出值完全限制在由机理确定的范围内, 从而使网络不受大幅度噪声的影响. 相比之下, 虽然 DAM 也对噪声具有一定的抑制作用, 但是其效果却相当有限. 这体现在随着噪声幅度的增大, 嵌入 DAM 的网络的预测误差也相应增大, 且其对不使用任何范围约束方法的原始网络 BP 的预测误差的降低幅度相对较小. 这主要是由于 DAM 方法本质上是通过在网络的损失函数中增加额外的惩罚项来融合范围机理. 取值为正的惩罚项本身就会降低网络的预测精度, 同时, 由于惩罚项很难降低到 0, 这意味着总是存在不符合机理的样本, 当样本的噪声幅度不断增大时, 网络的预测误差也会随之增大. 对于 Clip 函数, 即便是噪声幅度很小时, 它对噪声的抑制作用也不明显, 且随着噪声幅度的增大, 其预测误差显著增大, 甚至远超过不使用融合范围知识的方法的情况. 出现这一现象的原因在于 Clip 函数通过简单截断的方式限制网络输出的范围可能导致有用信息的丢失. 比如在网络训练的初始阶段, 超出设定范围的样本可能是不含噪声的样本, 其超出设定范围部分的信息对模型的学习是有帮助的, 截断这样的样本可能会破坏网络对数据的拟合能力, 从而限制网络的预测精度.

从对比结果中可以得到的另一个结论是, 当对训练集样本的输出值不施加噪声时, 约束层的应用仍能够提升网络的预测精度. 这可能是由于约束层可以通过对其内部参数 w 和 b 的训练提升网络对困

难样本的学习能力. 在根据机理知识或专家经验确定出样本输出值的合理范围的前提下, 约束层可以在将这些困难样本限制在给定范围内的同时使网络对它们的预测值尽可能接近其真值, 从而提升网络的预测性能.

以上仿真实验结果说明, 应用约束层有助于提升网络的预测精度. 接下来使用现场收集的实际冶炼数据进行实验, 以进一步验证本文提出的模型结构及约束层的有效性.

3.2 基于冶炼数据集的实验

3.2.1 实验数据描述

使用某厂一台 120 t 康斯迪电炉的生产数据对所提出的模型的有效性进行验证. 考虑到实际生产过程中偶发的设备故障及恶劣的冶炼环境可能对现场的测量装置产生干扰, 首先对收集的原始数据中的异常值及缺失值进行剔除, 然后再用清洗后的数据进行模型训练.

表 2 给出了实验所用数据集的具体信息.

表2 数据描述

项目	取值
样本个数	1060
采样周期 / min	1
冶炼周期范围 / min	[24 ~ 47]
平均冶炼周期 / min	35
钢水终点温度范围 / °C	[1560 ~ 1659]
平均终点温度 / °C	1602
η 的取值范围	[0.55, 0.85]
α 的取值范围	[3.2, 6.8]
β 的取值范围	[0.1, 0.5]
T_{dev}^i 的取值范围 / °C	[1230, 1430]
T_{bot}^i 的取值范围 / °C	[200, 300]

经过对数据的预处理, 共得到 1060 个有效样本. 图 4 展示了这些样本冶炼周期的分布情况, 受到废钢成分、冶炼钢种、操作人员的操作偏好等因素的影响, 每炉钢水的实际冶炼时长各不相同. 在本实验中, 取采样周期 Δt 为 1 min, 则这些样本的输入值即为长度在 24 ~ 47 之间的时间序列向量, 其中每一个时间步包含 9 维特征.

图 5 展示了每炉次冶炼终点测得的钢水温度. 由于不同的冶炼操作人员根据经验对钢水温度是否达到出钢要求的判断各不相同, 实际测得的终点温度值也存在较大差异. 这些温度值即为每个样本对应的输出值. 在实验中, 随机选取样本中的 80% 作为训练集, 剩余 20% 作为测试集, 并重复 5 次随机划分, 使用 5 次实验结果的平均值和标准差对模型

的性能进行评价.




图4 冶炼周期的分布情况




图5 终点温度的分布情况

表 2 还给出了根据现场冶炼经验结合专家建议确定的模型参数 η, α, β 及变量 T_{dev}^i, T_{bot}^i 的取值范围. 将这些范围值的上、下限和现场采集的输入变量的具体取值代入式 (2) ~ (7) 即可计算出冶炼过程中每个时间段内钢水温度增量 ΔT^i 的上、下限. 考虑到机理模型的精度有限, 由此计算出的上、下限可能出现与实际的冶炼过程偏离过大的情况. 为了消除这种异常的范围值带来的不利影响, 根据冶炼经验对机理模型计算出的范围值进行限制, 以使网络能够融合合理的温度增量变化范围的知识, 从而得到有效的训练. 在实验中, 将计算出的偏差过大的温度增量值限制在 $-5^{\circ}\text{C} \sim 5^{\circ}\text{C}$ 范围内.

3.2.2 消融实验

本文工作的主要创新之处在于:

- 1) 基于式 (8) 所示的机理模型, 采用时间序列建模方式构建了钢水连续温度预测模型;
- 2) 提出了一个可以将神经网络任意层的输出限制在指定范围内的约束层, 通过将该约束层嵌入到所建模型中来融合钢水温度变化范围的机理知识, 从而指导网络的训练方向.

为了评价以上工作对模型预测性能的不同影响, 首先进行消融实验.

在本实验中, 除了使用终点温度预测值与实际测量值之间的均方根误差 (RMSE) 作为评价指标以外, 还采用机理一致性 (MC) 指标评估模型预测温度与冶炼机理知识的符合程度. MC 的计算如下:

$$MC = \frac{\sum_{i=1}^n \hat{N}_i}{\sum_{i=1}^n N_i} \times 100\% \quad (13)$$

其中: n 表示测试集样本个数; N_i 表示第 i 个样本的冶炼时间段数; \hat{N}_i 表示第 i 个样本的所有时间段数中, 模型预测温度位于机理模型确定的温度上、下限范围内的段数.

表 3 展示了消融实验结果的对比情况. 这里 MIBP 表示不使用任何机理知识的 BP 网络模型. 由于 BP 网络无法处理时间序列数据, 在实验时, 将图 2 所示的每个冶炼时间段对应的输入进行求和, 即取整个冶炼周期中各冶炼变量的总消耗量作为模型输入对网络进行训练. MBLSTM 表示基于机理模型的 LSTM 网络模型. 该模型采用与图 2 相同的模型结构, 唯一区别是不使用约束层. MBLSTM + CL 为本文提出的模型结构, 这里 CL 表示约束层.

表3 消融实验结果

预测模型	RMSE / $^{\circ}\text{C}$	MC / %
MIBP	23.7 ± 2.1	54.2 ± 0.7
MBLSTM	18.3 ± 1.4	53.0 ± 0.9
MBLSTM + CL	16.1 ± 0.8	100 ± 0

从实验结果中可以观察到, MBLSTM 和应用 CL 的 MBLSTM 的 RMSE 值均小于 MIBP 的 RMSE 值, 这说明基于机理模型建立的网络结构有助于取得更高的预测精度. 如前文所述, 电弧炉的冶炼过程是一个高度复杂的动态非线性过程, 钢水温度与冶炼变量之间存在着复杂的长期依赖关系. 由于 MIBP 未采用时间序列形式的数据作为输入, 导致其丢失了一些重要的动态冶炼信息, 无法捕捉实时变化的冶炼变量对钢水温度的影响, 这可能是 MIBP 取得较差预测效果的原因. 此外, 嵌入约束层的 MBLSTM 的预测精度得到了进一步的提升, 这说明融合温度变化范围的知识为网络的训练过程提供了更多有益的信息, 有助于网络得到更好的训练结果. 而引入约束层对 MBLSTM 预测精度提升的幅度小于 MBLSTM 对 MIBP 预测精度的提升幅度, 说明相对于约束层而言, 合理的模型结构是提升网络预测性能的关键因素.

从表 3 中还可以看出, MBLSTM + CL 的 MC 值达到了 100%, 而 MIBP 和 MBLSTM 的 MC 值则相对较低且相差不大, 这说明即便是这种简单的范围知识, 对于神经网络而言也很难学习到. 在钢水温度预测的背景下, 本文提出的约束层可以将网络的输

出有效限制在由机理确定的合理范围内,从而使网络的预测值能够反映出实际冶炼过程的真实情况,有助于网络实现准确的连续温度预测。

3.2.3 对比实验结果与讨论

在上一节,通过消融实验验证了本文提出的模型结构及约束层有助于提升网络的预测精度,帮助网络实现符合实际冶炼过程的连续温度预测。为了进一步验证本文方法的有效性,引入两个更前沿的时间序列模型,即基于注意力机制的 LSTM 网络^[20](AttLSTM)和卷积 LSTM 网络^[21](ConvLSTM),并与不同的融合范围知识的方法相结合进行对比实验。AttLSTM 通过在一般的 LSTM 网络中引入注意力机制赋予网络聚焦关键信息的能力,能够提升网络在长序列任务中的表现。ConvLSTM 使用卷积计算代替 LSTM 网络中的全连接计算,可以帮助网络实现对空间相关性和时间依赖性的同时捕捉。这两个模型可以很方便地替代图 2 所示模型结构的 LSTM 网络。对于融合范围知识的方法,本实验采用与第 3.1 节实验相同的配置,即 Clip、DAM 和 CL。将上述模型与融合范围知识的方法分别结合进行对比实验。

表 4 展示了所有模型的预测结果,从表 4 中可以观察到一些重要的结论。首先,对于不使用任何融合范围知识的方法的网络模型而言,AttLSTM 和 MBLSTM 取得了相近的更高的预测精度,而 ConvLSTM 的预测精度则相对较差。这说明每个冶炼时间步的 9 维输入变量之间可能不存在明显的空间相关性,从而导致 ConvLSTM 的应用效果有限。同时,由于引入注意力机制使网络更擅于捕捉动态变化的冶炼变量与钢水温度之间的长时间依赖关系,AttLSTM 取得了比 MBLSTM 更好的预测效果。

表4 模型预测结果的比较

预测模型	RMSE / °C	MC / %
ConvLSTM	19.4±1.5	54.8±0.6
MBLSTM	18.9±1.7	53.0±0.9
AttLSTM	18.5±1.8	52.4±1.0
ConvLSTM + Clip	30.3±3.8	100±0
MBLSTM + Clip	29.7±4.3	100±0
AttLSTM + Clip	27.6±4.1	100±0
ConvLSTM + DAM	16.9±1.4	65.4±4.1
MBLSTM + DAM	16.1±1.1	67.7±3.8
AttLSTM + DAM	15.8±1.1	67.1±5.5
ConvLSTM + CL	15.7±0.7	100±0
MBLSTM + CL	15.0±1.0	100±0
AttLSTM + CL	14.8±0.9	100±0

其次,对于使用融合范围知识的方法的情况,使用 CL 的模型对原网络结构的预测精度的提升幅度

要高于使用 DAM 的模型对预测精度的提升幅度,而使用 Clip 的模型,其预测精度却出现了一定幅度的下降。这一现象的原因在于 CL 通过将网络的输出限制在由机理确定的合理范围内,对网络参数的训练方向进行了有效的指导,从而使网络的预测精度得到了较大提升,且这种提升不受特定的模型结构的限制。相比之下,DAM 对模型预测精度的提升幅度比较有限,这源于其在网络的损失函数中增加额外的惩罚项来融合范围机理的方式本身会降低网络的预测精度。而 Clip 函数通过简单截断的方式限制网络的输出可能导致有用信息的丢失,从而使网络的预测精度出现下降。这些结论与第 3.1 节实验中得到的结论基本一致。

最后,对于 MC 指标,使用 CL 或 Clip 函数的 MB-LSTM, AttLSTM 和 ConvLSTM,其 MC 值均达到了最大的 100%。这说明 CL 和 Clip 均可使网络的预测输出与范围机理知识完全相符。CL 取得这一优异性能的原因在于本文对约束层的特殊设计,而 Clip 则是通过将超出范围的预测值直接截断为范围的边界值实现这一功能的,考虑到其带来的使模型预测精度降低的负面效果,其取得最大 MC 值的意义不大。从表 4 中可以看出,使用 DAM 方法也会提升网络的 MC 值。然而,由于 DAM 是通过在损失函数中增加惩罚项的方式来融合输出的范围信息,其对 MC 值的提升幅度有限。同时,稀疏的温度测量数据也在一定程度上增加了模型训练过程的不确定性,这也导致了其 MC 值的标准差相对较大。

对于 DAM,本文通过实验确定其超参数 λ_D 的最优值。应用 DAM 的模型的预测性能随 λ_D 值的变化情况如表 5 所示。

表5 应用 DAM 的模型预测性能随超参数的变化情况

λ_D	RMSE / °C			MC / %		
	ConvLSTM	MBLSTM	AttLSTM	ConvLSTM	MBLSTM	AttLSTM
0	19.0±1.2	18.4±1.7	18.5±1.5	54.1±0.9	53.7±0.4	53.0±0.7
2	18.1±1.7	16.1±1.1	15.8±1.1	60.3±1.0	67.7±3.8	67.1±5.5
4	16.9±1.4	16.4±1.3	16.1±0.8	65.4±4.1	69.8±4.3	69.9±5.0
6	17.0±1.4	17.4±0.9	18.7±1.2	70.0±8.5	71.5±3.7	76.3±7.5
8	18.3±2.5	19.7±2.1	19.2±2.2	74.4±7.2	73.4±5.1	79.1±6.1
10	23.5±4.0	30.2±5.7	27.2±4.3	76.1±5.7	74.3±6.7	80.5±7.1
30	33.3±6.0	37.2±5.4	39.8±7.4	81.7±4.1	79.7±8.1	85.5±6.7
50	48.7±9.0	38.8±6.7	44.3±9.1	86.2±3.8	88.7±4.7	89.4±5.1

从表 5 中可以观察到,对于不同的模型,其 MC 指标均随 λ_D 的增大单调递增,而 RMSE 值则呈现出先下降后上升的情况。这一现象表明 DAM 方法通

常只能在预测精度和机理一致性之间取得折中, 而无法同时使两者达到最优结果. 这主要是由于在 DAM 中, λ_D 实际上反映了模型训练过程中对领域损失和偏差损失的相对侧重程度, 因此仅通过调整 λ_D 无法实现两种损失同步最小化. 此外, 应用 DAM 模型, 其 RMSE 值与 MC 值的标准差在大多数情况下也比较大. 这表明 DAM 对特定的样本比较敏感. 根据实验结果, 对各模型取使其 RMSE 值最小的

λ_D 值, 而此时这些模型的预测精度仍小于使用 CL 的情况. 该结果说明通过在损失函数中增加额外损失项的方式融合机理知识存在一定的不足, 本文提出的约束层是对该方法的有效改进.

为了更直观地对比不同的模型结构以及融合范围知识的方法的有效性, 在图 6 中给出这些模型对测试集中的某一炉次完整冶炼周期的连续温度预测结果.

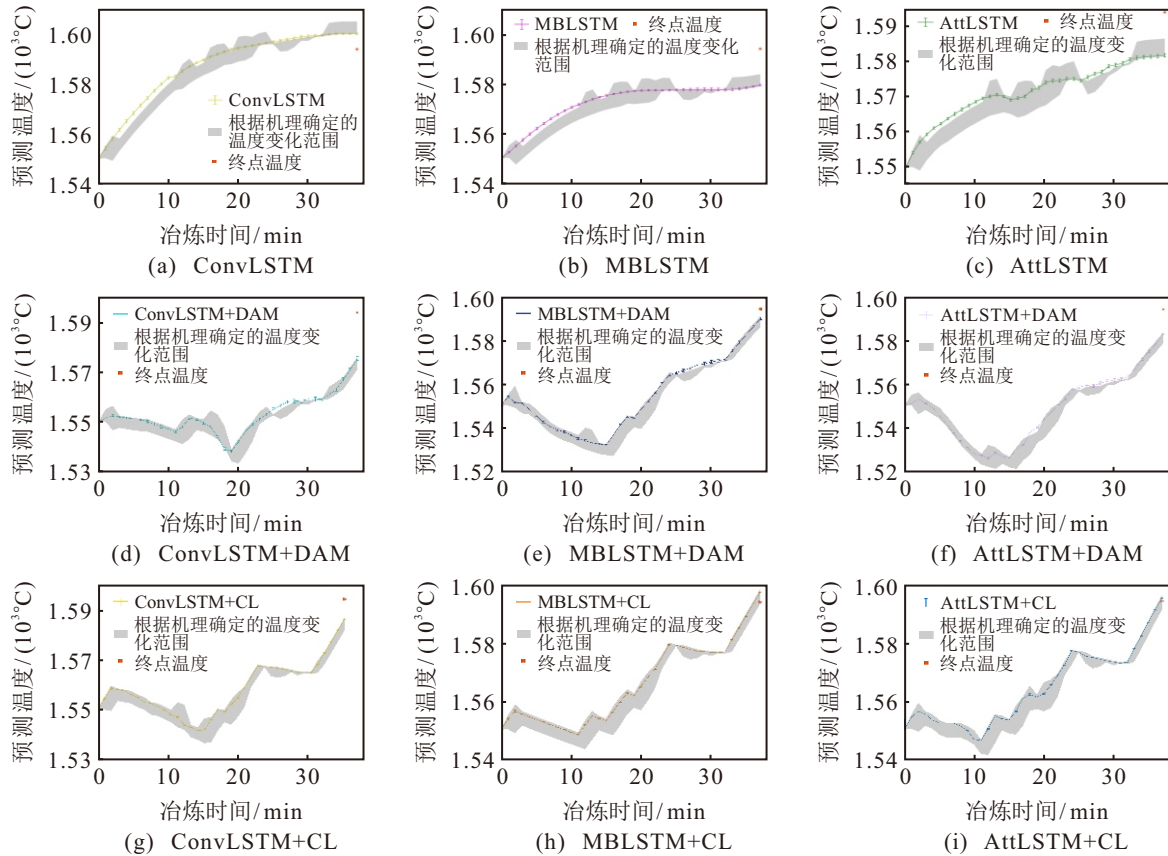


图6 一个完整冶炼周期的钢水温度连续预测结果比较

图 7 展示了根据机理确定的该炉次每个冶炼时间步温度增量的变化范围. 由于前面的实验结果已经验证了 Clip 的应用效果较差, 这里不再对其应用情况进行展示.




图7 每个冶炼时间步温度增量的变化范围

图 6 所示结果与表 4 得出的结论基本一致. 应用本文提出的约束层不仅可以提升对终点温度的预

测精度, 还能确保冶炼中间过程的连续温度预测值符合冶炼机理确定的合理范围. 值得一提的是, 即使在第 25 min 和第 31 min 这种很窄的温度区间内, 应用约束层的模型仍能符合机理要求. 因此, 使用约束层嵌入机理知识指导网络的训练方向, 既缓解了温度标签不足的问题, 又提升了模型整体的预测性能.

4 结 论

本文提出了一种机理指导的深度学习模型实现康斯迪电炉冶炼过程钢水温度的连续预测. 该模型的结构遵循由能量守恒定律推导出的机理温度预测模型, 并通过引入 LSTM 网络描述机理模型难以明确表达的钢水温度与重要的冶炼变量之间的时序关系. 为了缓解温度标签不足的问题, 提出了一个约束层, 该层可将网络任意一层的输出限制在指定的范围内. 通过将该层嵌入所提出的模型, 可将钢水温度

的升温过程依据机理知识动态调整到合理的区间范围内. 这一设计有效指导了网络的训练过程, 既提高了模型的预测精度, 又使模型的输出与实际冶炼过程相符.

虽然与几个具有代表性的模型的对比实验结果验证了所提出的模型的有效性, 但本文工作仍存在一定的不足, 可作为未来潜在的研究方向. 首先, 本文使用的代数方程形式的机理模型仅能反映冶炼过程的基本特征, 未来可开发更精细的微分方程形式的机理模型, 以提供更具指导意义的动态冶炼信息来优化网络的训练过程; 其次, 康斯迪电炉恶劣的冶炼环境导致采集的样本中可能存在多种复杂的噪声, 未来可同步展开对噪声处理和连续温度预测问题的研究, 以进一步提高模型的预测性能.

参考文献 (References)

- [1] Hay T, Visuri V V, Aula M, et al. A review of mathematical process models for the electric arc furnace arc process[J]. *Steel Research International*, 2021, 92(3): 2000395.
- [2] Blažič A, Škrjanc I, Logar V. Soft sensor of bath temperature in an electric arc furnace based on a data-driven Takagi-Sugeno fuzzy model[J]. *Applied Soft Computing*, 2021, 113: 107949.
- [3] MacRosty R D M, Swartz C L E. Dynamic modeling of an industrial electric arc furnace[J]. *Industrial and Engineering Chemistry Research*, 2005, 44(21): 8067-8083.
- [4] Opitz F, Treffinger P. Physics-based modeling of electric operation, heat transfer, and scrap melting in an AC electric arc furnace[J]. *Metallurgical and Materials Transactions B*, 2016, 47: 1489-1503.
- [5] Choi S W, Seo B G, Lee E B. Machine learning-based tap temperature prediction and control for optimized power consumption in stainless electric arc furnace (EAF) of steel plants[J]. *Sustainability*, 2023, 15: 6393.
- [6] Liu H X, Li M J, Guo J Q, et al. Temperature prediction of submerged arc furnace in ironmaking industry based on residual spatial-temporal convolutional neural network[J]. *Energy*, 2024, 309: 133024.
- [7] Wang H, Wang M, Liu Q, et al. Prediction of ladle furnace refining endpoint temperature based on particle swarm optimization algorithm and long short-term memory neural network[J]. *The Minerals, Metals and Materials Society*, 2025, 77(1): 282-293.
- [8] Rueden L V, Mayer S, Beckh K, et al. Informed machine learning—a taxonomy and survey of integrating prior knowledge into learning systems[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2021, 35(1): 614-633.
- [9] Karniadakis G E, Kevrekidis I G, Lu L, et al. Physics-informed machine learning[J]. *Natural Reviews Physics*, 2021, 3: 422-440.
- [10] Guo S, Agarwal M, Cooper C, et al. Machine learning for metal additive manufacturing: Towards a physics-informed data-driven paradigm[J]. *Journal of Manufacturing Systems*, 2022, 62: 145-163.
- [11] Liu D, Wang Y. Multi-fidelity physics-constrained neural network and its application in materials modeling[J]. *Journal of Mechanical Design*, 2019, 141(12): 121403.
- [12] Chen Y, Zhang D. Physics-constrained deep learning of geomechanical logs[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(8): 5932-5943.
- [13] Hu X, Hu H, Verma S, et al. Physics-guided deep neural networks for power flow analysis[J]. *IEEE Transactions on Power Systems*, 2021, 36(3): 2082-2092.
- [14] Hanson P C, Stillman A B, Jia X, et al. Predicting lake surface water phosphorus dynamics using process guided machine learning[J]. *Ecological Modelling*, 2020, 430: 109136.
- [15] Toulouevski Y N, Zinurov I Y. Electric arc furnace with flat bath—achievements and prospects[M]. Switzerland: Springer, 2015: 45-115.
- [16] Toulouevski Y N, Zinurov I Y. Innovation in electric arc furnaces—scientific basis for selection[M]. Berlin: Springer, 2010: 67-83.
- [17] Huang X A, Ng K W, Giroux L, et al. Carbonaceous material properties and their interactions with slag during electric arc furnace steelmaking[J]. *Metallurgical and Materials Transactions B*, 2019, 50: 1387-1398.
- [18] 杨新彪, 陈彦如, 秦娟, 等. 基于VMD-EWT-QWLSTM-TPE深度学习模型的超短时物流需求多步预测[J]. *控制与决策*, 2024, 39(6): 1859-1868.
(Yang X B, Chen Y R, Qin J, et al. Multi-step prediction of ultra-short-term logistics demand based on VMD-EWT-QWLSTM-TPE deep learning model[J]. *Control and Decision*, 2024, 39(6): 1859-1868.)
- [19] Muralidhar N, Islam M R, Marwah M, et al. Incorporating prior domain knowledge into deep neural networks[C]. *Proceedings of the 2018 IEEE International Conference on Big Data*. Seattle, 2018: 36-45.
- [20] Kumar I, Tripathi B K, Singh A. Attention-based LSTM network-assisted time series forecasting models for petroleum production[J]. *Engineering Applications of Artificial Intelligence*, 2023, 123: 106440.
- [21] Shi X, Chen Z, Wang H, et al. Convolution LSTM network: A machine learning approach for precipitation nowcasting[C]. *Proceedings of Advances in Neural Information Processing Systems*. Montreal, 2015: 2802-2810.

作者简介

李闯 (1991–), 男, 助理工程师, 博士, 主要研究方向为深度学习、复杂工业过程的建模, E-mail: lcdsg66@163.com;

毛志忠 (1961–), 男, 教授, 博士, 博士生导师, 主要研究方向为复杂工业过程的建模、控制与优化, E-mail: maozhizhong@ise.neu.edu.cn;

欧阳 (1974–), 女, 正高级工程师, 主要研究方向为先进制造技术、智能建模、质量管理, E-mail: zaiwei123456@163.com;

温远光 (1983–), 男, 高级工程师, 主要研究方向为智能检测技术、质量管理, E-mail: 13390166211@163.com.