

基于TST-LSTM模型的烧结料层透气性预测

刘梦园, 吴朝霞, 王金杨, 阎光磊

(东北大学秦皇岛分校 控制工程学院, 河北 秦皇岛 066004)

摘要: 烧结过程中烧结料层透气性对烧结矿的质量影响较大,因此需建立模型准确预测烧结料层透气性. 由于传统编码-译码模型不能够满足时间序列的依赖关系,提出一种模型时序转换与长短期记忆网络(time-series transformer-long short-term memory, TST-LSTM)模型. 此模型对变换神经网络模型的译码器部分进行处理,结合LSTM模型的优势,对烧结料层透气性进行了实时预测. 最终用预测模型与传统的反向传播神经网络(back propagation neural network, BPNN)模型、支持向量回归(support vector regression, SVR)模型和长短期记忆(long short-term memory, LSTM)模型的仿真结果进行比较. 结果表明, TST-LSTM模型预测性能较好且稳定. 根据实际烧结过程进行仿真预测,验证了所提方法的有效性.

关键词: 烧结料层; 透气性; 预测模型; 注意力机制; 神经网络; 变换神经网络模型

中图分类号: TF 046.4 文献标志码: A 文章编号: 1005-3026(2024)10-1379-07

Air Permeability Prediction of Sinter Layer Based on TST-LSTM Model

LIU Meng-yuan, WU Zhao-xia, WANG Jin-yang, XIA Guang-lei

(School of Control Engineering, Northeastern University at Qinhuangdao, Qinhuangdao 066004, China. Corresponding author: WU Zhao-xia, E-mail: ysuwzx@126.com)

Abstract: In the sintering process, the air permeability of the sinter layer significantly impacts sinter quality. Therefore, it is essential to construct a model for accurately air permeability prediction of the sinter layer. Due to the inadequacy of traditional coding-decoding models in handling time series dependencies, time-series transformer-long short-term memory network (TST-LSTM) model is proposed. This model leverages the decoding component of the transformer model and combines the advantages of LSTM to achieve realtime prediction of air permeability of the sinter layer. Comparative analysis with simulation results from traditional backpropagation neural network (BPNN), support vector regression (SVR), and long shortterm memory (LSTM) models demonstrates that TST-LSTM exhibits superior and more stable prediction performance. The proposed method is validated through simulation predictions based on actual sintering processes.

Key words: sinter layer; air permeability; prediction model; attention mechanism; neural network; transformer neural network model

随着钢铁冶炼技术的快速发展,自然界提供的矿源无法满足生产的需求. 贫矿的粒度较细,无法直接投入高炉使用,需制成块状投入使用. 铁矿石烧结技术是一项重大的突破,它将贫矿进行筛选、混料、点火烧结,为高炉冶炼提供了具有高强度和一定碱度以及化学成分均匀稳定的块状炉料^[1],使钢铁冶炼技术得到了更高质量的发

展. 本文提出了烧结过程的透气性问题,与现代化智能控制相结合,为烧结技术提供更科学高效的方法.

烧结过程中,烧结料层的透气性会影响烧结料层温度和最终烧结产物的质量. 烧结透气性指的是在一定的抽风负压下,每秒钟烧结台车单位面积通过的气体体积,或者烧结速度大小. 关于

收稿日期: 2023-05-22

基金项目: 河北省教育厅科学技术研究项目(BJ2021099).

作者简介: 刘梦园(1998-),女,贵州遵义人,东北大学硕士研究生; 吴朝霞(1969-),女,浙江嘉兴人,东北大学教授.

烧结料层透气性技术,已有学者进行了研究. Loo 等^[2]提出基于 Ergun 方程的实验方法来测量透气性的阻力,研究出透气性的气流阻力主要归因于惯性力等因素;冯根生等^[3]研究了烧结过程的温度分布和高温区出现的规律,提出烧结台车线速度和烧结料燃烧效率会对烧结透气性产生影响;周文胜等^[4]以钢铁厂烧结数据为例,简要分析了影响烧结混合料层透气性的主要因素,提出生产中预防混合料透气性变差的措施,以改善和稳定烧结生产条件,提高烧结矿产量,满足高炉用矿需求.由此可以看出,神经网络等机器学习相关的研究方法已经与烧结过程进行了结合,预测了烧结过程中的部分参数,证明了其可行性.

以上模型在实际烧结过程中起到了指导性作用,但是在烧结过程中很多数据是无法直接测得的,模型的训练参数不够全面和精确导致了最后预测结果的欠拟合,即不够精确.由于烧结料层透气性在烧结过程中的影响较大,并且其数据相对于烧结过程透气性的数据来说更容易测量.本文采用提取烧结过程的数据进行预测烧结料层透气性的研究.数据驱动是一种基于模型、数理知识以及数据之间的学习方式,目前在生物^[5]、天文^[6]等领域的研究中也具有很强的技术优势.综上所述,本文采取数据驱动的方式对烧结数据进行分析.

传统的循环神经网络在烧结领域展现出高精度的预测能力,例如基于时间序列的混凝土抗压强度预测 BPNN 模型^[7],基于混合算法调整的 SVR^[8]模型预测管道故障率.本文基于 transformer 模型^[9],进行了结构上的改变.该模型的提出最初

是为了解决图像处理 and 语言翻译等问题,是一个利用注意力机制来提高模型训练速度的深度学习模型.随着该模型在各领域的应用发展,研究者发现其也适用时间序列的变换 TST 神经网络模型. LSTM^[10]为一种神经循环网络,可学习关于时间序列长短期相关信息,实现对非线性问题的处理.本文将 LSTM 与 transformer 模型相结合,将 LSTM 模型嵌于 transformer 模型的解码部分,取代了解码中的掩码多头与多头两部分结构. LSTM 模型使 transformer 模型更适用于时间序列预测问题,构成更强的模型来达到数据长期依赖目标.本文利用烧结过程中的实际数据,建立了 TST-LSTM 的烧结料层透气性预测模型,通过与常规的机器学习算法相比较,验证本文模型的可行性和高精度性.

1 数据采集及预处理

1.1 数据采集

本文以某烧结厂真实数据为研究对象,收集其实际生产的数据进行分析,数据由配料系统的原料参数、生产过程中的操作参数以及检测过程的状态参数组成.收集到的数据为文本类型数据,为了保证数据有效性,数据采集周期为 15 s/次,最终采集到 600 多万条数据,时间跨度为半个月.烧结过程的参数可以分为原料参数、混合料参数、操作参数、状态参数和输出参数,如表 1 所示.

表 1 列出了 53 个可能会影响烧结料层透气性的参数,其中原料参数指的是在配料时料仓中原料的下料量;混合料参数指的是所有的料仓原

表 1 烧结过程重要参数
Table 1 Important parameters of sintering process

参数类型	序号	参数名称及单位	序号	参数名称及单位
单位时间原料	1	石灰粉/(kg·s ⁻¹)	3	除尘矿/(kg·s ⁻¹)
	2	烧结用白煤/(kg·s ⁻¹)	4	铁粉/(kg·s ⁻¹)
混合料	5	混合料铁质量分数/%	6	混合料五氧化二钒质量分数/%
	7	混合料氧化钙质量分数/%	8	混合料二氧化硅质量分数/%
	9	混合料水分质量分数/%	-	-
操作	10	圆辊给料机线速度/(m·min ⁻¹)	11	九辊布料器线速度/(m·min ⁻¹)
	12	烧结机线速度/(m·min ⁻¹)	13	点火器温度/°C
	14	煤气流量/(m ³ ·min ⁻¹)	15	风机风量/(m ³ ·min ⁻¹)
	16	铺底料斗料量/t	17	2个风门开度/%
	18	助燃风温度/°C	19	助燃风压力/kPa
	20	助燃风流量/(m ³ ·min ⁻¹)	21	烧结料层厚度/mm
	22	南大烟道平均温度/°C	23	南大烟道平均负压/kPa
状态	24	北大烟道平均温度/°C	25	北大烟道平均负压/kPa
	26~39	14个风箱废气温度/°C	40~53	14个风箱负压/kPa
输出	54	透气性指数/(m ³ ·h ⁻¹ ·kPa)		

料按照比例混合后,各个原料的质量分数;操作参数指的是在烧结过程中,可以人工控制的变量,例如风机的风量;状态参数指的是描述烧结过程状态的量,可以通过状态参数的变化调节操作参数,从而得到更高质量的烧结矿。

输出参数为透气性指数 T_z ,由 Voice 公式^[11]计算得

$$T_z = \frac{Q}{A} \cdot \left(\frac{H}{\Delta p} \right)^m \quad (1)$$

式中: H 为烧结料层厚度; Q 为通风风量;抽风面积为 A ;抽风负压为 Δp ; m 为指数, m 与烧结料层粒度有关,此处取值为0.6。

1.2 数据预处理

烧结存在多变性和时变性等特点,检测设备在生产过程中会出现无法即时记录和设备损坏等问题,进而造成烧结数据损失,而数据的缺失会影响建模结果的精确性和有效性。因此在建模前,需对数据结合专业烧结知识具体分析并进行预处理,为后续建模做准备。

1.2.1 异常值与缺失值处理

异常值为偏离正常数据的异常点,异常值的存在会对建模结果产生一定的影响,所以需要先对其进行检验与处理。数据异常一般包括2种情况:一是异常数据量与总数据量相比较小;另一种情况则为异常数据的数值与正常数据的数值相差较大。数据缺失情况的处理一般分为删除存在缺失与插补数据缺失。为了达到算法的精确性,本文采用了插补缺失值的方法。检测异常数据的方法有 Z-score 法和 3σ 原则法等。本文使用箱形图法,该方法可处理非线性数据,处理便捷且效果清晰。箱形图法^[12]基于图的四分位距(interquartile range, IQR)对异常值进行检测,规定在上分位加 1.5 倍四分位距以外和下分位减 1.5 倍四分位距以外的所有值为异常值,并将其进行处理。本文把异常值和缺失值前后 5 个数据进行平均化,以此数据替换异常值。

由于输入值单位的区别,对数据进行标准化处理,可使其在箱形图中得到简洁直观表示。本文采用标准差公式,使处理后数据呈正态分布,计算式如下:

$$x^* = \frac{x - \mu}{\sigma} \quad (2)$$

式中: x 为输入值; x^* 为标准化后的输入值; μ 为样本均值; σ 为样本标准差。

因为标准化是一种线性变化,所以数据经过标准化处理后,其异常值的相对位置在箱形图上

不会发生改变。异常值处理后的箱形图如图 1 所示。因烧结料层厚度未发生改变,对模型的建立没有影响,所以在后续的数据预测中将不会再代入处理。




图 1 箱形图法对异常数据点的识别结果

Fig. 1 Identification results of abnormal data point by box plot

1.2.2 筛选特征变量

烧结生产过程复杂多变,其中的变量影响着烧结透气性的好坏,而造成烧结矿的质量参差不齐。因此,根据烧结过程中的机理与工作人员的经验筛选出合适的特征变量十分重要。

特征变量的选择为建模提供前期准备,主要有方差选择法、Pearson 系数法^[13]和最大信息系数(maximum information coefficient, MIC)算法^[14]等。方差选择法与 Pearson 系数法只对线性关系的数据较敏感。本文所研究的烧结料层透气性具有非线性和滞后性的特点,因此选择 MIC 算法对烧结料层透气性特征值进行筛选。MIC 算法对数据的分析具有较好的适应性和对称性,可以处理非线性的特征值,其计算式如下:

$$M_{IC} = \max_{|x|, |y| \leq B} \frac{\sum_{x,y} P(x,y) \log_2 \frac{P(x,y)}{P(x)P(y)}}{\log_2(\min(|x|, |y|))} \quad (3)$$

式中: M_{IC} 为最大信息系数; $|x|$ 和 $|y|$ 分别为 x 轴和 y 轴的区间划分数量; $P(x)$ 为 x 轴上的样本落点概率, $P(y)$ 为 y 轴上的样本落点概率; $P(x,y)$ 为变量 x 和 y 的联合概率; B 为划分的最大网格数量,是样本量的 0.6 次方。

表 2 为 MIC 算法处理后的过程参数均值,根据研究需求列出排名前 25 位的输入变量。由表 2 可知,风机风量和风门开度与烧结料层透气性具有极强的相关性,而助燃风流量等因素与烧结料层透气性具有极弱的相关性。一般情况下,对相关系数在 0~0.04 范围内被认作极弱相关或者

不相关,因此对数据中助燃风流量和煤气流量进行剔除.除此之外,烧结原料的当量直径、原料的孔隙率、烧结过程是否产生液相和烧结台车的阻力系数等变量对烧结料层透气性也有一定的影响,但是在实际现场测量中无法对此进行数据监

测以及记录,因此参数无法利用.烧结原料的当量直径和原料的孔隙率等参数可以间接通过原料参数与操作参数等反映,因此可不放入模型搭建过程.

表 2 烧结料层透气性相关参数的 MIC 均值
Table 2 MIC mean values of parameters related to sinter layer air permeability

过程参数	M_{IC} 均值	过程参数	M_{IC} 均值
风机风量	0.766	九辊布料器线速度	0.100
1号风门开度	0.454	混合料五氧化二钒质量分数	0.099
2号风门开度	0.429	铺底料斗料量	0.086
除尘矿	0.238	南大烟道平均温度	0.085
铁粉	0.180	烧结用白煤	0.063
石灰粉	0.176	混合料总铁质量分数	0.062
混合氧化钙质量分数	0.155	北大烟道平均温度	0.053
烧结机线速度	0.149	混合料水分质量分数	0.050
南大烟道平均负压	0.127	点火器温度	0.046
混合料二氧化硅质量分数	0.124	助燃风压力	0.043
圆辊给料机线速度	0.123	煤气流量	0.030
北大烟道平均负压	0.120	助燃风流量	0.026
助燃风温度	0.101		

2 烧结料层透气性预测模型

Transformer 模型一般用于计算机视觉 (computer vision, CV) 等领域,近年来开始在时间序列方面进行应用.

2.1 LSTM 模型

LSTM 是循环神经网络 (recurrent neural network, RNN) 的改进版,解决了后者存在的长期依赖问题,具有更好地捕捉时间序列的特点,如图 2 所示.其中, C_{t-1} 和 C_t 分别是上一时间步和当前步的记忆单元状态; h_{t-1} 和 h_t 分别是上一时间步和当前时间步的隐藏状态,也是 LSTM 单元的输入和输出.




图 2 LSTM 结构示意图

Fig. 2 Schematic diagram of LSTM structure

对比 RNN 新增了一个状态值 C , 每层的神经元接收到上一时刻传递的 C_{t-1} 和 h_{t-1} , 再经过计算得到 C_t 和 h_t 用于下一时刻的传输.

LSTM 由 3 个门来控制信息传递状态, 分别为遗忘门、输入门和输出门. 状态门如式 (4) 所示, 将 $t-1$ 时刻的 h_{t-1} 与 t 时刻的输入 x_t 进行拼接, 再进行权值矩阵 W_f 转换, 加入遗忘门偏置项 b_f , 最后由 sigmoid 函数映射到 $[0, 1]$ 空间.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f). \quad (4)$$

式中: f_t 为遗忘门激活值; σ 表示的是 sigmoid 函数, 其输出值范围为 0~1, 0 为放弃当前输入的值, 1 为保留当前输入的值.

输入门如式 (5) 所示, 与状态门类似, 输入门激活值 i_t 从 σ 映射出后与输入门候选值 \tilde{C}_t 进行点乘, 得到输出数据.

$$\left. \begin{aligned} i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \\ \tilde{C}_t &= \tanh(W_c \cdot [h_{t-1}, x_t] + b_c). \end{aligned} \right\} \quad (5)$$

式中: b_i 与 b_c 分别为输入门与输出门的偏置值; W_i 和 W_c 分别为输入门和输出门的权重矩阵.

LSTM 输出为 h_t , 如式 (6) 所示.

$$h_t = o_t \cdot \tanh(C_t). \quad (6)$$

式中: o_t 为输出门激活值; C_t 为输出门输出值.

2.2 TST-LSTM 模型

TST^[15] 是基于 transformer 模型在时间序列领

域进行改进的模型, transformer 模型结构图共有 4 个部分, 分别为编码块、译码块、输入部分和输出部分, 如图 3 所示。

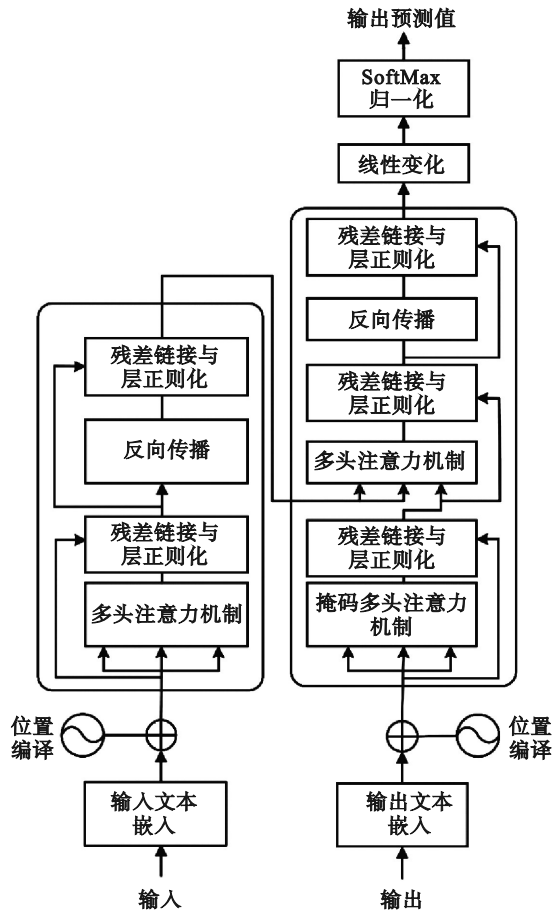


图 3 Transformer 模型结构图

Fig. 3 Diagram of transformer model structure

输入部分和输出部分都是序列数据, 可以接收任意形式的词向量. 由于词向量在输入时会被打乱顺序, 所以对单词进行编码, 即位置编码 P_E , 使用余弦和正弦生成不同频率的 P_E , 如式 (7) 所示.

$$\left. \begin{aligned} P_E(p, 2i) &= \sin\left(\frac{p}{10^{\frac{2i}{d_m}}}\right), \\ P_E(p, 2i+1) &= \cos\left(\frac{p}{10^{\frac{2i}{d_m}}}\right). \end{aligned} \right\} \quad (7)$$

式中: p 表示词语位置; d_m 表示维度; i 表示向量的维数.

编码块(encoder block)一般由多个编码器组成, 每个编码器包含多头注意力(multi-head attention, MHA)机制和全连接神经网络两部分. MHA 搭建于自注意力机制的基础上, 相比于自注意力机制的单组权重矩阵查询向量 W_Q , 键向量 W_K 和值向量 W_V , 其使用了多组权重矩阵得到

了相应的查询向量(query), 键向量(key)和值向量(value), 再进行内部计算. 前馈神经网络(feedforward neural network, FNN)是一种双层神经网络, 分别经过首位两次线性变换和中间的一次非线性变换得到.

译码块(decoder block)与编码块相似, 是由多个译码器构成. 不同的是多了一个掩码多头注意力(masked multi-head attention, MMHA)机制, 包括填充掩码(padding mask, PM)和序列掩码(sequence mask, SM)两种. 因为每次输入的序列长度不同, 需要把输入序列对齐, 其中处理非定长系列掩码负责填充短序列, 舍弃相对较长的序列. 防止标签泄露掩码的作用是对不需要的数据进行隐藏处理, 为译码器做准备. 译码后的数据通过 SoftMax 函数进行处理, 得到输出概率分布并进行最终的预测.

时序性变换(time-series transformer, TST)模型主要是针对 transformer 模型中的译码器部分进行改变, 在图片和翻译领域通常会使用 MMHA 机制对不同长度的数据进行处理, 但是在本文的滑动窗口内不需要对数据进行填补或者删除, 所以去掉掩码层, 如图 4 所示.

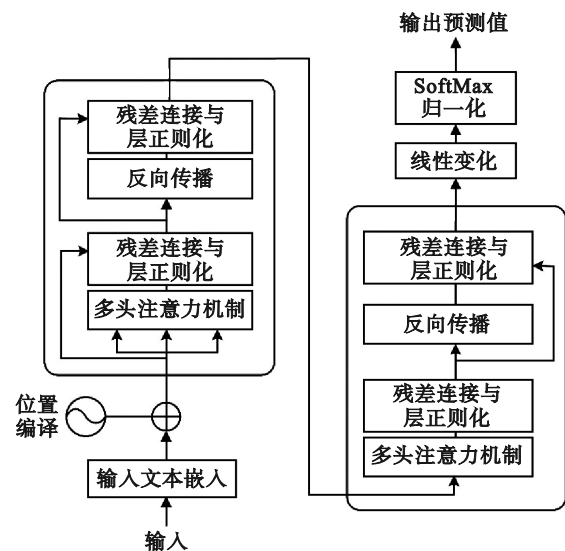


图 4 TST 模型结构图

Fig. 4 Diagram of TST model structure

TST 结构在 transformer 模型基础上进行了改进, 因为 transformer 模型本身是 Seq2Seq 结构的, 即需要学习一个序列到另一个序列的映射, 且这种序列的长度并不固定. 而本文烧结料层透气性是 [标签, 数据] 的类型, 所以需要将标签变成序列类型的数据, 如图 5 所示.

LSTM 解决了 RNN 的长期依赖问题, 可以捕

提到较长序列的时间特点, 本文将其代替译码器部分的 MHA 机制, 更有利于时间序列的预测建模, 如图 6 所示.




图 5 基于 TST 的标签序列化过程

Fig. 5 Label serialization process based on TST

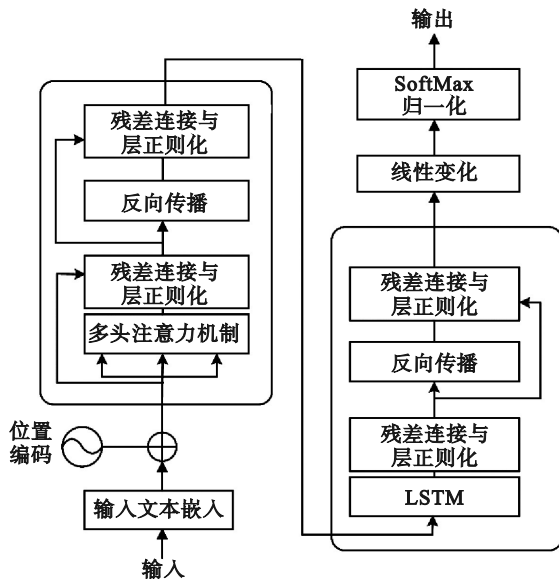


图 6 TST-LSTM 模型结构图

Fig. 6 Diagram of TST-LSTM model structure

2.3 混合模型预测流程图

由于 LSTM 具有捕捉时间序列的特点, 而 transformer 模型的编码部分具有输出的特性, 所以本文将 LSTM 加入译码部分, 建立 TST-LSTM 模型对烧结料层透气性进行预测, 4 种模型对比流程图如图 7 所示.

2.4 模型评估标准

鉴于模型为时序性建模, 本文引用评估指标均方差 (M_{SE})、平均绝对误差 (M_{AE}) 和决定系数 (R^2) 对模型的预测性能进行评估. M_{SE} 反映了模型的性能, 值越小越好; M_{AE} 反映了模型的误差, 值越小越好; R^2 反映模型的拟合能力, 取值在 $[-1, 1]$ 之间, 值越大越好.

$$M_{AE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (8)$$

$$M_{SE} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2, \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}. \quad (10)$$

式中: n 为测试集的样本个数; \bar{y} 为测试集的样本平均值; y_i 表示第 i 个测试集的样本值; \hat{y}_i 表示第 i

个测试集的预测值.

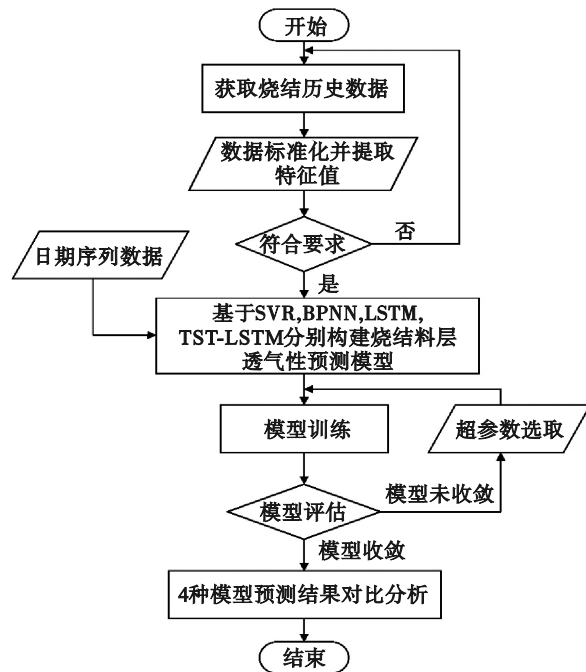


图 7 4 种模型对比流程图

Fig. 7 Flowchart of four models comparison

3 结果分析与讨论

本文从某烧结厂获得真实数据, 并将几类常见的机器学习模型与提出的混合模型对比, 来验证模型的准确性与有效性.

将数据按数量比例划分为 8:2, 前部分用来训练数据, 后部分用来测试模型的训练能力. 用传统机器学习 SVR, BPNN, LSTM 对烧结料层透气性指标进行预测, 发现预测效果不够理想. 因为 BPNN 模型与 SVR 模型没有精准捕捉到时间维度的有用信息, 而 LSTM 虽然解决了梯度消失的问题, 但因为结构复杂所以训练时间缓慢且参数不好调节. 接着提出将运用在图片和翻译领域的 transformer 模型进行改变用于时间序列的预测, 再加上 LSTM 模型获取输入的编码进行预测, 即 TST-LSTM 模型. 与基础模型进行对比, 发现其预测精度明显提升, 且训练速度较快. 如表 3 所示, 本文提出的 TST-LSTM 预测模型的 M_{SE} , M_{AE} 皆小于其他 3 种模型, 决定系数达到 99.86%, 高于其他模型. 模型的计算时间影响到是否可以快速得到烧结料层透气性的预测结果, 所以本文记录了不同模型对测试集的训练时间. SVR 模型、BPNN 模型、LSTM 模型和 TST-LSTM 模型的计算时间分别为 1.879, 1.291, 2.021 和 2.172 s, 存

在一定差异. 因为 TST-LSTM 网络结构较为复杂, 计算时间较长, 得到的模型预测结果更好, 所以选用此模型. 表 3 的预测指标反映了模型的平均性能, 不能完全说明模型的可靠性, 因此计算 TST-LSTM 模型的预测结果, 如图 8 所示. 可看出透气性指数的误差值都在 0 附近, 证明模型的预测能力不仅平均性能较好, 还具有较强的可靠性.

表 3 不同模型的烧结料层透气性预测性能比较
Table 3 Comparison of different models for air permeability prediction of sinter layer

模型	M_{SE}	M_{AE}	R^2
BPNN	0.112 8	0.131 4	0.938 7
SVR	0.062 3	0.043 5	0.946 4
LSTM	0.052 8	0.010 9	0.969 1
TST-LSTM	0.033 8	0.006 2	0.998 6

从表 3 可看出 TST-LSTM 模型对烧结料层透气性有精确且稳定的预测, 为了更加清晰地表现出 TST-LSTM 模型的性能, 本文对比 4 种模型的部分数据预测效果, 如图 8 所示. TST-LSTM 模型的预测能力较强, 对烧结料层透气性的预测提供了较好的数据支持.




图 8 烧结料层透气性 TST-LSTM 预测结果
Fig. 8 TST-LSTM prediction results of sinter layer air permeability

4 结 语

对烧结料层透气性指数进行预测, 并与 BPNN 模型、SVR 模型和 LSTM 模型进行对比. TST-LSTM 模型拟合能力达到了 99.86%, 高于其他 3 种传统模型, M_{SE} 和 M_{AE} 皆小于其他模型, 并且预测误差主要分布在 0 附近, 证明了 TST-LSTM 模型预测的精确性和稳定性.

将 TST-LSTM 模型运用到烧结过程, 可以为

现场提供定性和定量的数据支持, 辅助工作人员判断烧结料层透气性的状态, 提前调节原料参数与控制参数, 减低烧结过程的损失.

参考文献:

- [1] Wright C S. Supersolidus sintering of high speed steels-comparison of sintering theory with experimental observations[J]. *Solid State Phenomena*, 1992, 25/26: 463-470.
- [2] Loo C E, Wong D J. Fundamental insights into the sintering behaviour of goethitic ore blends [J]. *ISIJ International*, 2005, 45(4): 459-468.
- [3] 冯根生, 吴胜利, 赵佐军. 改善厚料层烧结热态透气性的研究[J]. *烧结球团*, 2011, 36(1): 1-5. (Feng Gen-sheng, Wu Sheng-li, Zhao Zuo-jun. Study on improving thermal air permeability of sintering of thick material layer [J]. *Sintering and Pelletizing*, 2011, 36(1): 1-5.)
- [4] 周文胜, 王梅菊. 改善烧结混合料透气性的途径探析[J]. *冶金与材料*, 2021, 41(6): 185-186. (Zhou Wen-sheng, Wang Mei-ju. Pathway to improve the air permeability of sintered mixture [J]. *Metallurgy and Materials*, 2021, 41(6): 185-186.)
- [5] Shomorony I. Data-driven precision medicine through the analysis of biological functional modules [J]. *Cell Reports Medicine*, 2022, 3(12): 100876.
- [6] Fluke C J, Hegarty S E, MacMahon C O M. Understanding the human in the design of cyber-human discovery systems for data-driven astronomy [J]. *Astronomy and Computing*, 2020, 33: 100423.
- [7] Tipu R K, Panchal V R, Pandya K S. An ensemble approach to improve BPNN model precision for predicting compressive strength of high-performance concrete [J]. *Structures*, 2022, 45: 500-508.
- [8] Kalanaki M, Soltani J. Performance assessment among hybrid algorithms in tuning SVR parameters to predict pipe failure rates [J]. *Advances in Computer Science*, 2013, 2(5): 40-46.
- [9] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [C]//The 31st Conference on Neural Information Processing Systems. Long Beach: 2017: 6000-6010.
- [10] Hochreiter S, Schmidhuber J. Long short-term memory [J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [11] 邱先彩, 蔡汝卓, 付守澄. Voice 公式在烧结实践中的应用 [J]. *烧结球团*, 1986(3): 16-27. (Qiu Xian-cai, Cai Ru-zhuo, Fu Shou-cheng. Application of Voice formula in sintering practice [J]. *Sintering and Pelletizing*, 1986(3): 16-27.)
- [12] Cartan J. Methods and systems for displaying graphical markers in a mixed box chart: U.S. patent 8451271 [P]. 2013-05-28.
- [13] Felipe H, Viol A, De Araujo D B, et al. Threshold-free estimation of entropy from a Pearson matrix [EB/OL]. [2023-03-06] <https://arxiv.org/pdf/2106.05379v2>.
- [14] Liu M D, Yang Z W, Guo Y, et al. MICAR: nonlinear association rule mining based on maximal information coefficient [J]. *Knowledge and Information Systems*, 2022, 64(11): 3017-3042.
- [15] 李文, 陈佳伟, 刘瑞雪, 等. 张量时间序列预测 T-transformer 模型 [J]. *计算机工程与应用*, 2023, 59(11): 57-62. (Li Wen, Chen Jia-wei, Liu Rui-xue, et al. Tensor time series prediction T-transformer model [J]. *Computer Engineering and Applications*, 2023, 59(11): 57-62.)