

基于CEEMDAN-RVM-EC的还原冶炼温度预报

廖亚楠^{1,2}, 王业林¹, 李萌³, 肖清泰^{1†}, 王华¹

(1. 昆明理工大学 省部共建复杂有色金属资源清洁利用国家重点实验室, 云南 昆明 650093;

2. 昆明理工大学 冶金与能源工程学院, 云南 昆明 650093; 3. 中佛罗里达大学 电气与计算机工程系, 奥兰多 32816)

摘要: 针对高炉炼铁还原过程中非线性和大时滞等特点造成温度监测难度大的困境, 提出一种融合数据分解、机器学习和误差修正的高炉铁水温度组合预测新模型. 首先, 引入带自适应白噪声的完备集合经验模态分解方法对铁水温度序列进行分解处理, 通过提取不同频率的规律特征, 使复杂的非线性序列转化为规律性较强的子序列; 随后, 采用相关向量机对子序列进行学习, 充分挖掘铁水温度序列的信息, 获得精度较高的预测结果; 最后, 将对铁水温度影响较大的硅含量和富氧率等相关因素作为辅助参数, 使用经主成分分析处理后的辅助参数序列对预测结果进行修正, 提高模型的预测准确性. 结果表明: 相较于整合移动平均自回归模型等传统模型, 所提出的新模型综合性能更优, 即平均绝对误差百分比减小53.57%, 铁水温度为 $\pm 10^\circ\text{C}$ 范围内的预测命中率提高25%. 所提出的模型为实现高炉温度实时精细化调控提供了理论支撑, 对保证炉况稳定、提升产品质量和降低冶炼能耗具有重大实际意义.

关键词: 机器学习; 相关向量机; CEEMDAN; 误差修正; 铁水温度; 预测

引用格式: 廖亚楠, 王业林, 李萌, 等. 基于CEEMDAN-RVM-EC的还原冶炼温度预报. 控制理论与应用, 2022, 39(11): 2177–2184

DOI: 10.7641/CTA.2022.10823

Prediction for the reduction smelting temperature based on CEEMDAN-RVM-EC

LIAO Ya-nan^{1,2}, WANG Ye-lin¹, LI Meng³, XIAO Qing-tai^{1†}, WANG Hua¹

(1. State Key Laboratory of Complex Nonferrous Metal Resources Clean Utilization, Kunming University of Science and Technology, Kunming Yunnan 650093, China ;

2. Faculty of Metallurgical and Energy Engineering, Kunming University of Science and Technology, Kunming Yunnan 650093, China;

3. Department of Electrical and Computer Engineering, University of Central Florida, Orlando 32816, United States)

Abstract: The reduction process of ironmaking is difficult to be controlled, which is caused by its characteristics of non-linearity and large time delay. Motivated by data decomposition, machine learning and error correction technologies, a novel hybrid prediction model is proposed for blast furnace hot metal temperature in this paper. Firstly, the complete ensemble empirical mode decomposition with adaptive noise is introduced to decompose the time series of hot metal temperature. The complicated non-linear time series are transformed into various sub-components by extracting the regular with different frequencies. Then, the relevance vector machine (RVM) is used to learn the rules of subsequences, and the information of the molten iron temperature sequence is fully mined to obtain a prediction result with high accuracy. Finally, the auxiliary parameter sequence processed by principal component analysis is used to modify the prediction results, improving the prediction accuracy of the model. The results show that compared with traditional models such as autoregressive integrated moving average model, the proposed model has better overall performance. The average absolute error percentage is reduced by 53.57%, and the predicted hit rate within the range of $\pm 10^\circ\text{C}$ for the hot metal temperature is increased by 25%. The model has important practical significance for ensuring stable furnace conditions, improving product quality and reducing smelting energy consumption.

Key words: machine learning; relevance vector machine; CEEMDAN; error correction; hot metal temperature; prediction

Citation: LIAO Yanan, WANG Yelin, LI Meng, et al. Prediction for the reduction smelting temperature based on CEEMDAN-RVM-EC. *Control Theory & Applications*, 2022, 39(11): 2177–2184

收稿日期: 2021–08–31; 录用日期: 2022–04–27.

†通信作者. E-mail: qingtai.xiao@kust.edu.cn; Tel.: +86 18213428497.

本文责任编辑: 李少远.

云南省教育科学基金研究基金项目(2021J0063), 云南省科技厅科技计划项目(202101AU070031), 云南省基础研究计划项目(202101BG070127)资助. Supported by the Scientific Research Fund Project of Yunnan Education Department (2021J0063), the Natural Science Foundation of Yunnan Province (202101AU070031) and the Yunnan Fundamental Research Project (202101BG070127).

1 引言

冶金行业是高耗能且高排放的行业,其耗能量占我国总能耗的10%左右,提升冶金生产能源利用效率是“碳达峰、碳中和”工作的重要内容之一。高炉炼铁是冶炼还原生产过程中最重要的步骤之一,铁水物理热约占转炉热收入的50%左右,将炉温控制在合理范围内是降低还原冶炼过程能耗的重要途径。高炉炉温预报模型是信息物理系统(cyber-physical system, CPS)的关键组成部分,常被用来对高炉冶炼过程中的炉温进行及时调控。因此,开发具有现场分析能力的高炉炉温预报模型是大幅提高生产效率和有效减少能源消耗的必要环节^[1]。由于冶炼过程中绝大部分反应具有动态性、复杂性和高温性的特点,高炉炉温不易由仪器直接测量得到^[2],而铁水温度是高炉炉内热的指示剂,所以铁水温度的精准预报能够为高炉温度监测和炉温精细化调节提供数据支撑。因此,对于陷入“高产能、高成本、低效益”阶段的我国冶金产业,研究冶炼过程智能预测是一个既紧迫又现实的课题。

高度复杂的动态特性导致直接建立高炉冶炼过程机理模型十分困难,而数据驱动建模是充分认识和掌握高炉冶炼过程动态特性的有效手段之一,线性自回归^[3-4]、支持向量回归^[5]、极限学习机^[6]、神经网络模型^[7]等被广泛应用于高炉温度预测,但均存在一定的局限性。例如,最小二乘支持向量回归等模型较依赖指标的选取,难以在复杂炉况下进行高精度预测^[8]。极限学习机系统计算时间过长,无法实现在线预测^[9]。神经网络模型基于大容量样本学习来提高预测精度,对小样本问题预测效果不佳,模型泛化性能较差^[10]。相关向量机(relevance vector machine, RVM)是一种监督型机器学习算法,是Tipping基于Bayesian理论提出的^[11],具有学习能力强、泛化能力强、核函数选择灵活和参数设置简单等优点^[12]。RVM是一种更适用于小样本和非线性问题的高效机器学习算法,可以适应高炉高度非线性的预测情景,能够解决传统高炉炉温预测模型对样本量依赖大(例如文献[2, 8, 12]的样本容量分别为3000, 1700和1774组)的问题,在冶炼预测领域已被广泛应用。例如,韩敏等^[13]提出一种基于自适应神经模糊系统和鲁棒RVM的动态控制模型,可以准确预测转炉炼钢过程中钢水的终点碳含量和温度。张研等^[14]将基于主成分分析和RVM的露天矿边坡稳定性预测模型应用于工程实例,证明其具有预测精度高、离散性和可靠度高等优点。Acosta等^[15]通过与多种机器学习技术对比研究,认为RVM模型是预测炼钢过程中磷浓度水平的合适工具。

由于单一模型的预测精度无法满足高炉温度预测需要,将多种模型进行组合取长补短逐渐成为趋势,组合预测能够有效避免信息浪费和减少偶然因素的

影响,使预测结果具有更好的精度和稳定性。例如, Spirin等^[16]使用高炉过程的线性化模型和组合满量程的数学方法对铁水硅含量进行预测,从而评价铁水温度,基于该算法开发的信息系统已被集成到高炉车间的CPS中。崔桂梅等^[17]基于核极限学习机和粒子群算法建立高炉回旋区温度预测模型,所建立的模型与极限学习机等传统模型相比具有最高命中率和最低均方误差。桂卫华课题组在高炉炉温预报组合模型方面进行了深入探索,2016年利用复合差分进化算法快速定位全局最优解的能力来优化极限学习机在高炉温度预报中的表现^[18],2021年融合自适应密度峰值聚类算法和多源路径寻优算法建立高炉温度预测模型^[2],实现了冶炼过程中当前时刻硅含量最优预测值的求解。

分解理论可以很好地解决高炉环境波动频繁导致的预测模型精度低和误差大的问题,针对数据采样频率和各相物质滞留时间不同导致的数据多尺度问题,宋菁华等^[10]采用传统经验模态分解(empirical mode decomposition, EMD)将硅含量序列分解成有限个相对平稳的本征模态函数(intrinsic mode function, IMF)和剩余分量,崔桂梅等^[19]采用小波分解将铁水温度等高炉过程参数的平稳时间序列分解为3个不同频率的细节信号和1个逼近信号,证明对时间序列进行分解可以有效提高高炉温度预报模型的预测精度。带自适应白噪声的完备集合经验模态分解方法(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)是EMD的优化,通过向原始信号各阶段添加自适应白噪声来消除不真实的IMF,能够提取出非稳态信号中不同时间尺度的信息。相较EMD等分解模型,CEEMDAN有效克服模态混叠现象的能力更好、计算量更小且分解完备性更高。因此,使用CEEMDAN进行前置分解,可有效改善预测效果和提高预测速度^[20]。修正算法可以极大地弥补传统算法的不足,改善预测结果^[21],早在2014年就被应用到国内中型高炉(380~750 m³)预报领域^[22]。具有非常强学习能力的误差反向传播神经网络(back propagation neural network, BP-NN)可以对多维的数据进行较好的预测,在高炉喷煤优化^[23]和高炉铁水硅预报^[24]等高炉预测情境都有优秀的表现。主成分分析(principal component analysis, PCA)是一种可以剔除冗余信息、降低数据计算量且提高计算速度的降维方法^[25],采用PCA对数据进行降维是预测模型常用的优化手段。因此,引入BP-NN和PCA可以对铁水温度预测中的误差进行修正,提高模型的精度和效率。

鉴于上述,针对传统铁水温度预测模型存在的精度不高和可靠性差等问题,本研究在传统高炉铁水温度预测的基础上,引入CEEMDAN并结合RVM算法

对铁水温度变化规律进行学习. 采取误差修正技术, 利用PCA处理后的生产辅助参数对结果进行修正. 本文创新点是: 1) 提出了一种融合分解理论与修正技术的新型CEEMDAN-RVM-EC预测模型, 并将之用于解决高炉冶炼过程温度监测难度大、预测精度不高的难题; 2) 提出了全新的铁水温度预测模式, 即时间序列为主、外部因素修正为辅的预测模式, 该模式既能规避数据统计误差造成的预测风险, 又能实现对外部因素的考量, 获得全面可靠的预测结果; 3) 新模型可以提供高精度预测结果, 为冶炼智控系统的高炉温度在线监控工作提供支撑.

2 理论与方法

2.1 RVM算法

本文中, RVM训练样本由输入数据 $\{x_i\}_{i=1}^N$ 和输出数据 $\{t_i\}_{i=1}^N$ 组成, 且各 t_i 相互独立. 通过上述关系, 设 ε_i 为零均值、方差为 σ^2 的附加高斯噪声, 建立数学回归模型^[26]

$$t_i = y(x_i, \omega) + \varepsilon_i, \quad (1)$$

其中: N 为样本容量, y 为未知的非线性回归函数. 进行回归计算的目的是找到给定数据集上的近似函数 y , 即

$$y(x_i, \omega) = \sum_{k=1}^N \omega_k K(x_i, x_k) + \omega_0, \quad (2)$$

其中: $\omega = (\omega_0 \ \omega_1 \ \cdots \ \omega_k \ \cdots \ \omega_N)^T$ 是权重向量, $K(x_i, x_k)$ 是核函数. 假设 $\{t_i\}_{i=1}^N$ 为独立随机变量, 目标 t 的条件概率为

$$P(t | \omega, \sigma^2) = (2\pi\sigma^2)^{-\frac{N}{2}} \exp\left\{-\frac{1}{2\sigma^2} - \Phi\omega^2\right\}, \quad (3)$$

其中: $\Phi = [\varphi(x_1) \ \varphi(x_2) \ \cdots \ \varphi(x_N)]^T$ 是设计矩阵, φ 为核函数组成的核矩阵. 直接采用最大似然法求 ω 与 σ^2 , 会产生“过拟合”现象, 因此定义一个零均值高斯先验概率分布, 即

$$P(\omega | \alpha) = \prod_{i=0}^N N(\omega_i | 0, \alpha_i^{-1}), \quad (4)$$

其中: $\alpha = [\alpha_0 \ \alpha_1 \ \cdots \ \alpha_N]^T$ 为 $N+1$ 维的超参数向量. 假设尺度参数 α 和 σ^2 服从高斯分布, 根据Bayesian定理, 得到目标 t 的后验分布和

$$P(\omega, \alpha, \sigma^2 | t) = P(\omega | t, \alpha, \sigma^2) P(\alpha, \sigma^2 | t). \quad (5)$$

后验分布的权值为

$$P(\omega | t, \alpha, \sigma^2) = (2\pi\sigma^2)^{-\frac{N+1}{2}} \exp\left\{-\frac{1}{2}(\omega - \mu)^T \Sigma^{-1}(\omega - \mu)\right\}, \quad (6)$$

其中: 条件分布协方差 $\Sigma = (\sigma^{-2}\Phi^T\Phi + A)^{-1}$, 对角阵

$A = \text{diag}\{\alpha_0, \alpha_1, \cdots, \alpha_N\}$, 后验均值 $\mu = \sigma^{-2}\Sigma\Phi^T t$ 为统一超参数, 对 $P(t | \alpha, \sigma^2)$ 进行以下定义:

$$P(t | \alpha, \sigma^2) = (2\pi\sigma^2)^{-\frac{N}{2}} |C|^{-\frac{1}{2}} \exp\left\{-\frac{1}{2}t^T C^{-1}t\right\}, \quad (7)$$

其中: 协方差矩阵 $C = \sigma^2 I + \Phi A^{-1} \Phi^T$, 通过迭代估计来计算 α 和 σ^2 , 迭代中的 α 表示为 α_i^{new} , σ^2 表示为 $(\sigma^2)^{\text{new}}$, 即

$$\alpha_i^{\text{new}} = \frac{1 - \alpha_i \Sigma_{ii}}{\mu_i^2}, \quad (8)$$

$$(\sigma^2)^{\text{new}} = \frac{\|t - \Phi\mu\|^2}{N - \sum_{i=0}^N (1 - \alpha_i \Sigma_{ii})}. \quad (9)$$

其中 Σ_{ii} 为条件分布协方差 Σ 的第 i 个对角元素. 通过计算式(8)–(9)迭代学习相关向量, 并不断更新 μ 和 Σ , 直到满足收敛要求.

2.2 CEEMDAN算法

CEEMDAN是由EMD发展而来的一种噪声辅助数据分析方法, 通过在信号中加入具有一定标准差的高斯白噪声来解决EMD的模态混叠问题, 很适合将非平稳、非线性信号自适应分解成若干个本征模态函数. 运用CEEMDAN进行分解的步骤如下^[27]:

1) 假设 $s(n)$ 为原始时间序列信号, ε_0 为噪声标准, 生成一组具有标准正态分布的白噪音序列 $w^{(i)}(n)$, 其中 $i = 1, 2, \cdots, I$ 为试验组数. 令 $n = 1, 2, \cdots, N$, 将生成的白噪音添加到原 $s(n)$ 中, 第 i 次添加噪声之后的信号序列为

$$s^{(i)}(n) = s(n) + \varepsilon_0 w^{(i)}(n). \quad (10)$$

2) 用EMD对 I 组初始值依次进行 I 次分解, 对各组第1阶IMF取平均, 得到第1个本征模态函数 $\overline{\text{IMF}}_1$, 即

$$\overline{\text{IMF}}_1(n) = \frac{1}{I} \sum_{i=1}^I \text{IMF}_1^i(n), \quad (11)$$

在分解的第1阶段得到的第1阶余量序列 r_1 为

$$r_1(n) = s(n) - \overline{\text{IMF}}_1(n). \quad (12)$$

3) 假设 $E(\cdot)$ 是EMD获得第 k 阶IMF所需的算子, 在式(1)的基础上, 继续对第 k 阶段($k = 2, \cdots, K$)剩余分量进行分解, 得到第 k 个本征模态函数 $\overline{\text{IMF}}_k$, 即

$$\overline{\text{IMF}}_k(n) = \frac{1}{I} \sum_{i=1}^I E_1(r_{k-1}(n) + \varepsilon_{k-1} E_{k-1}(w^{(i)}(n))), \quad (13)$$

此时, 在分解第 k 阶段得到的剩余分量 r_k 为

$$r_k(n) = r_{k-1}(n) - \overline{\text{IMF}}_k(n). \quad (14)$$

4) 不断重复步骤3直到得到的剩余分量不可再分解, 得到残差 $R(n)$, 即

$$R(n) = s(n) - \sum_{k=1}^K \overline{\text{IMF}_k}(n), \quad (15)$$

其中 K 为总模态数. 最终 $s(n)$ 被分解为

$$s(n) = R(n) + \sum_{k=1}^K \overline{\text{IMF}_k}(n). \quad (16)$$

2.3 CEEMDAN-RVM-EC模型

受多因素影响, 高炉铁水温度变化复杂, 趋势常呈现非平稳、非线性和高波动等特征. 为了能够充分提取信号所包含的信息和进一步提高预测精度, 根据CEEMDAN和RVM的特性并融合误差修正技术, 本文提出了一种CEEMDAN-RVM-EC的组合预测模型. 首先, 引入CEEMDAN将复杂的铁水温度时间序列处理为规律性更强的IMF和残余项(R); 其次, 使用RVM对获得的子序列进行预测得到初步预测结果; 最后, 基于BP-NN, 使用经PCA处理后的辅助参数进行误差修正, 得到高精度预测结果. 图1所示为融合CEEMDAN和RVM的高炉铁水温度组合预报模型, 主要包含以下步骤.

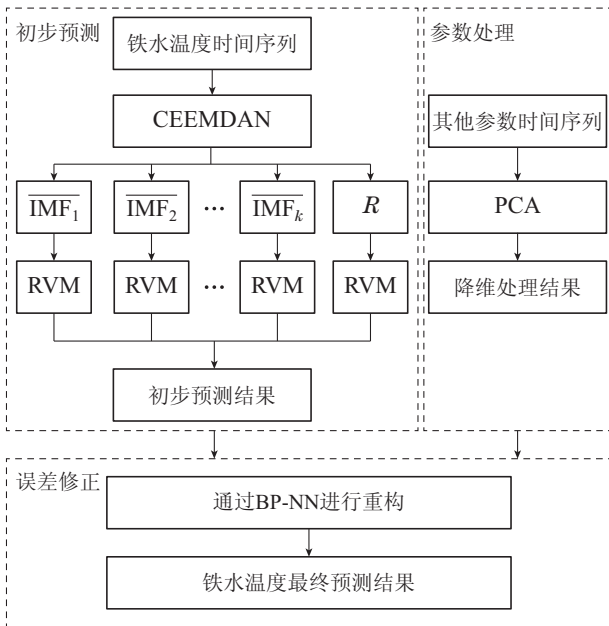


图1 CEEMDAN-RVM-EC模型的流程图
Fig. 1 Flow chart of CEEMDAN-RVM-EC

1) 数据预处理: 对于铁水温度时间序列进行缺失值处理, 对辅助参数数据进行标准化处理, 统一数值量纲, 并通过PCA对影响参数进行处理, 降低数据维度, 提高模型运行速度;

2) CEEMDAN分解: 引入CEEMDAN对铁水温度时间序列进行分解, 通过将非平稳和非线性的复杂序列分解为较为规律的子序列, 为后续预测模型创造更好的应用环境, 从而改善预测效果;

3) RVM初步预测: 使用RVM模型对经过分解后

的全部铁水温度模态分量和残差分量时间序列分别进行学习和预测, 充分挖掘铁水温度信息自身的规律, 获得各子序列的预测结果;

4) 误差修正: 将预处理后的辅助参数时间序列与初步预测结果同时作为输入, 充分发挥现场参数信息的价值, 使用BP-NN模型对预测结果进行修正, 可以有效提高对炉温的预测精度;

5) 模型测试效果评价: 通过对输出预测结果和测试集之间的误差进行指标分析, 评估模型精度, 与其他经典模型进行对比, 验证模型性能的改善, 证明多模型融合的必要性.

3 铁水温度预测模型的建立与分析

3.1 平稳性检验

为验证CEEMDAN结合RVM方法的有效性和准确性, 本文采用了某冶金企业的现场数据集, 共80组数据. 白云鄂博矿石具有复杂的成分, 给高炉的冶炼带来了巨大的影响, 炉况时常会发生较大的波动, 提高了建模难度, 使用其进行建模能够有效考验模型的泛化性能. 选取硅含量等对高炉温度影响较大的参数, 数据特征参量如表1所示.

表1 铁水温度预测特征参量

Table 1 Character parameters for hot metal temperature prediction

序号	特征参量	序号	特征参量
1	铁水温度	6	透气性
2	煤气利用率	7	富氧率
3	综合负荷	8	喷煤
4	炉顶压	9	风量
5	风温	10	铁水硅含量

为验证基于铁水温度的高炉炉温预报模型的建模困难度和新模型的泛化能力, 采用常用的统计检验方法单位根检验 (augmented dickey-fuller test, ADF) 对建模使用的铁水温度序列进行平稳性检验. 检验结果表明, ADF统计量为0.1345, 大于在1%显著水平下的-2.5949, P 值为0.7221, 证明高炉铁水温度序列不平稳, 波动性较大, 故采用此数据可以有效检测模型在复杂情况下的表现和泛化性能.

3.2 数据预处理

高炉冶炼环境复杂, 测量设备和传输设备故障等情况可能导致样本数据存在缺失值, 使得样本数据不稳定并影响建模精度和预测可信度. 由于数据样本较小且均在高炉稳定运行状态下采集, 因此采取平均值法对缺失数据进行填补. 预处理后的铁水温度及辅助参数样本散点图如图2所示.




图 2 预处理后的铁水温度及辅助参数样本散点图

Fig. 2 Scatter diagram of hot metal temperature and auxiliary parameters after data preprocessing

由图2知, 经过预处理之后的铁水温度序列数值范围为 $1492.5\sim 1519^{\circ}\text{C}$, 煤气利用率为 $40.97\%\sim 46.04\%$, 综合负荷为 $3.10\sim 3.22\text{ kPa}$, 炉顶压为 $0.184\sim 0.186\text{ kPa}$, 风温为 $1040\sim 1060^{\circ}\text{C}$, 透气性为 $26585\sim 26294\text{ mL}$, 富氧率为 $0.79\%\sim 1.19\%$, 喷煤为 $13\sim 17\text{ kg/t}$, 铁水硅含量为 $0.43\%\sim 0.73\%$, 风量为 $5050\sim 4775\text{ m}^3/\text{min}$. 为了降低参数数据的数据维度和提高运算效率, 采用PCA模型对输入高炉铁水组合模型的9个变量(铁水温度影响因素)进行分析, 结果如表2所示.

依据方差贡献率和累计方差贡献率两个评价指标进行参数筛选, 删除对预测效果影响较小的特征参量. 前6个主成分的累计方差贡献率在90%以上, 能够有效描述全部变量的信息, 因此提取这6个主成分为BP-NN模型的输入变量, 用以对RVM模型预测的时间序列进行修正.

3.3 基于CEEMDAN的序列特征规律分析

为充分提取复杂信号中的规律特征以增强预测的性能, 利用CEEMDAN算法对80个数据进行分解, 分

解时添加5000组标准差为0.1的白噪声信号, 并与EMD算法的分解结果进行对比. 图3展现了分解获得的原始铁水温度序列的IMF, 得到的不同频率尺度的4个模态分量和1个残差分量.

表 2 辅助参数主成分分析结果
Table 2 PCA results of auxiliary parameters

	特征值	方差贡献率/%	累积方差贡献率/%
1	3.42	37.95	37.95
2	1.33	14.72	52.67
3	1.09	12.12	64.8
4	1.02	11.34	76.13
5	0.81	9.02	85.15
6	0.72	7.99	93.13
7	0.25	2.78	95.92
8	0.24	2.69	98.61
9	0.13	1.39	100

由图3可知, 在进行CEEMDAN和EMD分解获得的子序列中, IMF_1 的相似程度最高, 而频率较低的 IMF_2 和 IMF_3 出现较为显著的差别. 通过对比分析波

形的规律,由EMD获得的IMF₂和IMF₃变换规律存在较为严重的“模态混叠”现象,而添加白噪音后的CEEMDAN对“模态混叠”现象有了显著的削弱,不同频率的子序列之间的界限更为明显.尽管添加白噪

音的环节显著增加了CEEMDAN的计算量和运算时间,但从挖掘复杂序列规律角度,CEEMDAN可以更好地根据变化频率提取规律信息,为后续的预测工作营造适宜的环境,有利于组合模型预测精度的提升.




图3 基于CEEMDAN和EMD的铁水温度分解结果对比

Fig. 3 Comparison of results of hot metal temperature decomposition based on CEEMDAN and EMD

3.4 CEEMDAN-RVM-EC预测结果及对比分析

3.4.1 CEEMDAN-RVM-EC模型性能检测

经CEEMDAN分解后的高炉铁水温度数据集将用于RVM的训练与测试,训练集与测试集的比例设置为8:2,每个样本单次输入RVM模型的样本长度为4,即用前4个数据预测后1个数据.通过学习来有效构建特征参量与目标参量间的映射关系,获得初步预测结果.并采用经PCA处理的辅助参数序列对该结果进行修正并获得最终结果,CEEMDAN-RVM-EC组合模型预测结果如图4所示.由图4知,所提出的组合模型能够准确预判温度增减变化趋势,模型输出结果曲线和实际结果曲线之间的吻合程度较高.另外,预测误差控制在±10℃以内,对铁水温度的追踪效果佳,有助于炉温的有效前位调控.




图4 CEEMDAN-RVM-EC铁水温度预测结果

Fig. 4 Prediction of hot metal temperature based on CEEMDAN-RVM-EC

为了充分验证所提出的模型性能,本文引入4种经典预测方法与所提出模型作对比研究,对比模型分别为整合移动平均自回归模型(autoregressive integrated

moving average, ARIMA)、BP-NN模型、支持向量机(support vector machine, SVM)和RVM模型.此外,采用EMD-RVM-EC模型进行对比实验,对比验证CEEMDAN算法对模型性能的改进.为定量地评价模型的性能,选取平均绝对误差百分比(mean absolute percentage error, MAPE)评价预测结果较真实结果的平均偏离程度,选取均方根误差(root mean square error, RMSE)表征模型预测值相较测量基准值的偏差变化程度,选取皮尔逊相关系数(Pearson correlation coefficient, PCC)表征预测曲线与实际曲线之间的相关度,以此评价模型综合性能;选取命中率检验模型预测准确度,各预测结果如表3所示.

表3 CEEMDAN-RVM-EC及对比模型预测结果的评价指标

Table 3 Evaluation indices of predictions obtained by CEEMDAN-RVM-EC and other comparative models

模型	MAPE	RMSE	PCC	命中率(±10)/%
ARIMA	0.28	6.13	0.36	56.25
BP-NN	0.26	5.5	0.58	62.50
SVM	0.28	6.31	0.35	56.25
RVM	0.26	5.75	0.65	50.00
EMD-RVM-EC	0.24	4.52	0.76	43.75
CEEMDAN-RVM-EC	0.13	2.43	0.91	81.25

由表3可知,1)从预测精度和可靠性角度,本文所提出的CEEMDAN-RVM-EC组合模型MAPE为0.13, RMSE为2.43,均远小于ARIMA(MAPE和RMSE分别

降低 53.57% 和 60.36%)、BP-NN(MAPE 和 RMSE 分别降低 50% 和 55.82%)、SVM(MAPE 和 RMSE 分别降低 53.57% 和 61.49%)和 RVM(MAPE 和 RMSE 分别降低 50% 和 57.74%), 证明新组合模型的预测精度和可靠性较传统模型有大梯度的上升. 2) 从模型整体性能的角度, 所提出模型预测结果的 PCC 为 0.91, 说明该结果与真实值之间为强相关关系, 而传统模型仅为弱相关关系(较传统模型高 0.55, 0.33, 0.56 和 0.26), 所提出模型对规律的学习能力更强. 3) 从命中率的角度, 所提出模型在允许误差 ± 10 时的命中率达 81.25%, 对比传统模型有显著提升(较传统模型提高了 25%, 18.75%, 25% 和 31.25%). 该结果证明在可接受误差范围内, 所提出模型对所有预测点都能较好的命中, 更为可靠. 4) 与 EMD-RVM-EC 模型相比较, CEEMDAN 分解技术通过添加自适应白噪声等方式显著削弱了传统 EMD 模型的模态混叠现象, 使得组合模型的预测精度和命中效果有非常明显的改善效果(MAPE 和 RMSE 分别降低 45.83% 和 46.24%, 在允许误差 ± 10 时的命中率提高 41.25%), 对模型稳定性的影响较小(PCC 提高 16.48%).

3.4.2 CEEMDAN-RVM-EC 模型消融实验

为了研究组合模型各策略(融合 CEEMDAN 算法进行前置分解和融合 BP-NN 算法对预测结果进行误差修正)对预测结果的具体影响, 对这两策略分别进行消融实验, 即在原 RVM 的基础上每次实验加一个改进点, 实验环境和参数选择均保持不变, 对这两处改进点分别做消融实验, 即在原 RVM 的基础上每次实验加一个改进点, 实验环境和参数选择均保持不变, 结果如图 5 所示.

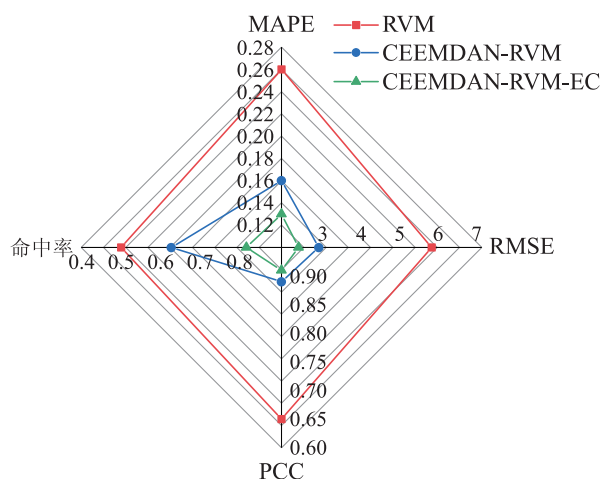


图 5 CEEMDAN-RVM-EC 消融实验结果

Fig. 5 Results of ablation experiments for CEEMDAN-RVM-EC

1) 在原 RVM 的基础上增加 CEEMDAN 前置分解, 相较于单一预测模型, CEEMDAN-RVM 的 MAPE 降低了 38.4%, RMSE 降低 48.79%, 模型精度得到显著提

升, 证明了分解技术对模型性能有较大程度的提升. CEEMDAN-RVM 模型的 PCC 同样是强相关关系, 这证明了分解针对模型稳定性的提升也有显著成效. 2) CEEMDAN-RVM 和 CEEMDAN-RVM-EC 模型的整体预测性能相差不大, 但从命中率的角度比较, CEEMDAN-RVM 在允许误差为 ± 10 以内的命中率仅为 62.5%, 相较于 CEEMDAN-RVM-EC 模型, 其可靠性相对较弱, 证明了误差修正技术可以有效提高模型的可靠性. 3) 实验结果证明, 当条件受限时(辅助参数不可获取), CEEMDAN-RVM 模型满足预测需求, 可以胜任高炉铁水温度的预测工作. 当条件允许时, 所提出的 CEEMDAN-RVM-EC 模型在可接受误差范围内命中率达 81.25%, 相较于其他模型的可靠性有显著提升, 可以更好地满足冶炼过程的高炉温度监测需求.

4 结论

为提高高炉温度预报模型的预测精度, 从而降低还原冶炼过程能耗, 提出融合 CEEMDAN、RVM 和误差修正算法的预测模型(CEEMDAN-RVM-EC), 应用于高炉实际生产数据的预测, 研究结果表明: 1) 所提出模型能对铁水温度变化趋势进行有效跟踪. 相较于整合移动平均自回归模型这些现有的预测模型, MAPE、RMSE、PCC 和命中率等评价指标显示, 所提出模型在精度、稳定性和可靠性等方面表现更优; 2) 对比研究证明, 分解技术可以有效提升模型的预测性能, 误差修正技术提升性能相对较小. 在条件受限的情况下(辅助参数不可获取), CEEMDAN-RVM 可以胜任高炉铁水温度的预测工作. 在条件允许下, 所提出的 CEEMDAN-RVM-EC 在可接受误差范围内命中率达 81.25%, 相较于其他模型可靠性有显著提升, 对于保障高炉安全稳定运行和冶炼过程降低能耗具有重要意义.

参考文献:

- [1] HE K, WANG L. A review of energy use and energy-efficient technologies for the iron and steel industry. *Sustainable Energy Reviews*, 2017, 70(4): 1022 – 1039.
- [2] JIANG Chaohui, XU Chuan, GUI Weihua, et al. Method for predicting silicon content of molten iron in blast furnace based on migration of optimal working conditions. *Acta Automatica Sinica*, 2022, 48(1): 194 – 206.
(蒋朝辉, 许川, 桂卫华, 等. 基于最优工况迁移的高炉铁水硅含量预测方法. *自动化学报*, 2022, 48(1): 194 – 206.)
- [3] ÖSTERMARK R, SAXÉN H. VARMAX-modelling of blast furnace process variables. *European Journal of Operational Research*. 1996, 90(1): 85 – 101.
- [4] ZHANG Y, ZHAO Z, CUI G. Auxiliary model method for transfer function estimation from noisy input and output data. *Applied Mathematical Modelling*, 2015, 39(15): 4257 – 4265.
- [5] DAI Peng, ZHOU Ping, LIANG Yanzhuo, et al. Adaptive nonlinear predictive control and application based on multi-output least squares

- support vector regression modeling. *Control Theory & Applications*, 2019, 36(1): 43 – 52.
(戴鹏, 周平, 梁延灼, 等. 基于多输出最小二乘支持向量回归建模的自适应非线性预测控制及应用. 控制理论与应用, 2019, 36(1): 43 – 52.)
- [6] HUANG Chenlin, TANG Yaling, ZHANG Xuefeng, et al. Prediction and simulation of silicon content in hot metal of blast furnace by PCA and PSO-ELM. *Computer Simulation*, 2020, 37(2): 398 – 402.
(黄陈林, 汤亚玲, 张学锋, 等. PCA和PSO-ELM在高炉铁水硅含量中的预测仿真. 计算机仿真, 2020, 37(2): 398 – 402.)
- [7] LI Wenpeng, ZHOU Ping. Robust regularization random weight neural network modeling for molten iron quality in blast furnace. *Acta Automatica Sinica*, 2020, 46(4): 721 – 733.
(李温鹏, 周平. 高炉铁水质量鲁棒正则化随机权重神经网络建模. 自动化学报, 2020, 46(4): 721 – 733.)
- [8] ZHOU Ping, LI Ruifeng, GUO Dongwei, et al. Multi-output support vector regression modeling of multiple molten iron quality indicators in blast furnace ironmaking process. *Control Theory & Applications*, 2016, 33(6): 727 – 734.
(周平, 李瑞峰, 郭东伟, 等. 高炉炼铁过程多元铁水质量指标多输出支持向量回归建模. 控制理论与应用, 2016, 33(6): 727 – 734.)
- [9] WANG Zhenyang, JIANG Dewen, WANG Xindong, et al. Hot metal temperature prediction of blast furnace based on support vector regression and extreme learning machine. *Journal of Engineering Science*, 2021, 43(4): 569 – 576.
(王振阳, 江德文, 王新东, 等. 基于支持向量回归与极限学习机的高炉铁水温度预测. 工程科学学报, 2021, 43(4): 569 – 576.)
- [10] SONG Jinghua, YANG Chunjie, ZHOU Zhe. Application of improved EMD-Elman neural network in prediction of silicon content in molten iron. *CIESC Journal*, 2016, 67(3): 729 – 735.
(宋菁华, 杨春节, 周哲. 改进型EMD-Elman神经网络在铁水硅含量预测中的应用. 化工学报, 2016, 67(3): 729 – 735.)
- [11] LIU Bao, MU Kun, YE Fei, et al. Coal spontaneous combustion prediction method based on correlation vector machine. *Industry & Mine Automation*, 2020, 46(9): 104 – 108.
(刘宝, 穆坤, 叶飞, 等. 基于相关向量机的煤自燃预测方法. 工矿自动化, 2020, 46(9): 104 – 108.)
- [12] LI D, DENG L, CAI Z. Statistical analysis of tourist flow in tourist spots based on big data platform and DA-HKRVM algorithms. *Personal & Ubiquitous Computing*, 2020, 24(1): 87 – 101.
- [13] HAN Min, ZHAO Yao, YANG Xilin, et al. Prediction model of converter steelmaking endpoint based on robust relevance vector machine. *Control Theory & Applications*, 2011, 28(3): 343 – 350.
(韩敏, 赵耀, 杨溪林, 等. 基于鲁棒相关向量机的转炉炼钢终点预报模型. 控制理论与应用, 2011, 28(3): 343 – 350.)
- [14] ZHANG Yan, WU Zhekang, WANG Pengpeng, et al. The prediction model of open-pit mine slope stability based on PCA-RVM. *Mining Research & Development*, 2021, 41(3): 13 – 18.
(张研, 吴哲康, 王鹏鹏, 等. 基于PCA-RVM的露天矿边坡稳定性预测模型. 矿业研究与开发, 2021, 41(3): 13 – 18.)
- [15] ACOSTA S M, AMOROSO A L, SANTANNA A, et al. Relevance vector machine with tuning based on self-adaptive differential evolution approach for predictive modelling of a chemical process. *Applied Mathematical Modelling*, 2021, 2021(95): 125 – 142.
- [16] SPIRIN N A, POLINOV A A, GURIN I A, et al. Information system for real-time prediction of the silicon content of iron in a blast furnace. *Metallurgist*, 2020, 63(9): 898 – 905.
- [17] CUI Guimei, ZHANG Yunqiang, ZHANG Yong. Research on temperature prediction of blast furnace gyrozone based on improved PSO-KELM. *Chinese Test*, 2020, 46(4): 25 – 30.
(崔桂梅, 张运强, 张勇. 基于改进PSO-KELM的高炉回旋区温度预测研究. 中国测试, 2020, 46(4): 25 – 30.)
- [18] JIANG Chaohui, YIN Juping, GUI Weihua, et al. Prediction of silicon content in molten iron of blast furnace based on compound differential evolution algorithm and extreme learning machine. *Control Theory & Applications*, 2016, 33(8): 1089 – 1095.
(蒋朝辉, 尹菊萍, 桂卫华, 等. 基于复合差分进化算法与极限学习机的高炉铁水硅含量预报. 控制理论与应用, 2016, 33(8): 1089 – 1095.)
- [19] CUI Guimei, CHEN Rong, YU Kai, et al. Research on prediction of ELM furnace temperature based on multi-scale decomposition. *Control Engineering of China*, 2020, 191(11): 53 – 58.
(崔桂梅, 陈荣, 于凯, 等. 基于多尺度分解的ELM炉温预测研究. 控制工程, 2020, 191(11): 53 – 58.)
- [20] HAMMAMI A, HMIDA A, KHABOU M T, et al. Applications of CEEMDAN in dynamic behavior of defected spur gearbox running under Acyclism regime. *Journal of Mechanics*, 2020, 36(6): 825 – 839.
- [21] LI Shaoyuan, LIU Hao. Generalized predictive control based on neural network error correction. *Control Theory & Applications*, 1996, 13(5): 677 – 680.
(李少远, 刘浩. 基于神经网络误差修正的广义预测控制. 控制理论与应用, 1996, 13(5): 677 – 680.)
- [22] GAO Chuanhou, ZHOU Zhimin. Modified chaotic weighted first-order local prediction of Si content in blast furnace hot metal. *Chinese Journal of Physics*, 2004, 53(12): 4092 – 4097.
(郜传厚, 周志敏. 高炉铁水Si含量的修正混沌加权一阶局部预报. 物理学报, 2004, 53(12): 4092 – 4097.)
- [23] CUI Guimei, GAO Cuiling, HOU Jia. Optimization of blast furnace coal injection based on genetic algorithm optimized BP neural network. *Computer Measurement & Control*, 2015, 23(5): 1568 – 1570.
(崔桂梅, 高翠玲, 侯佳, 等. 基于遗传算法优化BP神经网络的高炉喷煤优化. 计算机测量与控制, 2015, 23(5): 1568 – 1570.)
- [24] GAO Xudong. Application of BP neural network in the prediction of hot metal silicon in blast furnace. *China Metallurgy*, 2014, 2014(6): 24 – 26.
(高绪东. BP神经网络在高炉铁水硅预报中的应用. 中国冶金, 2014, 2014(6): 24 – 26.)
- [25] CHENG T, CHEN G. Prediction of mechanical properties of hot-rolled strip steel based on PCA-GBDT method. *Journal of Physics Conference Series*, 2021, 1774(1): 12002 – 12008.
- [26] CHEN Z, SHI N, JI Y, et al. Lithium-ion batteries remaining useful life prediction based on BLS-RVM. *Energy*, 2021, 2021(234): 121269 – 121281.
- [27] TORRES M, COLOMINAS M, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise. *International Conference on Acoustics, Speech & Signal Processing*. Prague: IEEE, 2011, 8: 4144 – 4147.

作者简介:

廖亚楠 硕士研究生, 目前研究方向为冶金过程强化与节能减排、数据驱动智能建模, E-mail: liaoyanan6@163.com;

王业林 硕士研究生, 目前研究方向为机器学习与数据驱动智能建模、预测控制, E-mail: wngyelin0@163.com;

李萌 博士研究生, 目前研究方向为机器学习与数据驱动智能建模、预测控制, E-mail: mengli@knights.ucf.edu;

肖清泰 特聘副教授, 目前研究方向为冶金过程强化与节能减排、数据驱动智能建模, E-mail: qingtai.xiao@kust.edu.cn;

王华 教授, 目前研究方向为冶金过程强化与节能减排, E-mail: wanghua65@163.com.