基于改进时间序列模型的烧结机机头温度预测

汪向硕，赵 伟，高大伟，张艳兵，闫中华
（首钢集团有限公司 矿业公司，河北 迁安，064402）

摘要：针对烧结机机头温度异常变化会严重影响烧结矿质量的问题，本文采用一种基于 WD-ARIMAX-GARCH 的超短期温度预测模型。由于温度时间序列经常受外部因素的影响，而时间序列模型（ARIMA）只是对历史时间序列的回归，无法体现外部因素的影响，因此该模型加入了外生变量（ARIMAX），并通过引入小波分解（WD），将温度时间序列分解为若干子序列，将各分量进行残差序列检验，对存在异方差特性的分量建立 ARIMA-GARCH 模型，将该预测结果作为外生变量与分解后的数据重新组合预测。结果表明，基于 WD-ARIMAX-GARCH 模型的温度预测方法具有较高的精度。

关键词：温度预测；外生变量；ARIMA-GARCH 模型；小波分解
中图分类号：TF046.4 **文献标识码**：A **文章编号**：1000－8764（2024）04－0044－05
doi：10.13403/j.sjqt.2024.04.056

Temperature prediction of sintering machine head based on improved time series model

WANG Xiangshuo，ZHAO Wei，GAO Dawei，ZHANG Yanbing，YAN Zhonghua
（Mining Company，Shougang Group Mining Co.，Ltd.，Qian'an 064402，Hebei China）

Abstract：Aultra short term temperature prediction model based on WD-ARIMAX-GARCH is adopted to address the serious impact of abnormal temperature changes in the sintering machine head on the quality of sintered ore. Due to the frequent influence of external factors on temperature time series，and the fact that time series models（ARIMA）only regress historical time series and cannot reflect the impact of external factors，exogenous variables（ARIMAX）are added. By introducing wavelet decomposition（WD），the temperature time series is decomposed into several sub sequences，and residual sequence tests are performed on each component. ARIMA-GARCH models are established for components with heteroscedasticity characteristics，and the predicted results are combined with the decomposed data as exogenous variables for re prediction. The results indicate that the temperature prediction method based on WD-ARIMAX-GARCH model has high accuracy.

Key words：temperature forecast；external variable；ARIMA-GARCH model；wavelet decomposition

近年来随着钢铁需求的增加，烧结矿作为炼铁的重要原料，起着不可忽视的作用。如何实现烧结高效清洁生产，需要从不同生产环节进行优化[1]。目前我国积极推进“碳达峰碳中和”政策，烧结生产工序在钢铁生产中能耗占比约为 10%，是仅次于炼铁工序的生产环节，对节能需求更加迫切[2]。烧结机机头温度是否符合正常生产标准，对烧结矿产品质量起着至关重要的作用。目前，基于遗传算法（genetic algorithm，GA）优化反向传播（back propagation，BP）神经网络的烧结温度预测方法被广泛应用。该方法根据零件的尺寸及工艺参数，从而计算烧结终点温度[3]。或者使用极端梯度提升树（extreme gradient boosting，XGBoost）算法、因子相关分析与深度学习算法相结合的方

收稿日期：2023－05－15；**修回日期**：2023－06－07
作者简介：汪向硕（1992—），男，工程师，从事自动控制领域方面的工作。

法，最后建立深度神经网络算法模型[4-5]。目前预测模型主要有时间序列模型[6-7]及人工神经网络模型[8]，最小二乘支持向量机(least squares support vector machine，LSSVM)模型[9]等。但由于神经网络可能存在过学习的问题，每次训练得到的结果不尽相同；LSSVM 模型缺少稀疏性，对于每一次预测都需要所有训练数据参与。时间序列模型有效避免了神经网络出现的问题，同时具有结构简单、预测快速的特点，该模型较多的应用在故障诊断、风电功率预测等领域，但是通过仿真试验可知，如果单纯应用时间序列模型进行预测，效果不好，需要对时间序列模型进行改进。

对于一些温度时间序列，经常会受其他外部因素的影响，而差分自回归滑动平均(auto regression integrated moving average，ARIMA)模型，即 ARIMA 模型只是对历史时间序列的回归，无法体现外生变量的影响。为此本文提出了基于 ARIMA 模型的一个扩展模型，即自回归积分滑动平均模型与外生变量(auto regression integrated moving average model with exogenous variables，ARIMAX)模型[10]。为了获得外生变量，本文对历史温度时间序列进行小波分解(wavelet decomposition，WD)，分解后的子序列存在异方差性，需要引入广义自回归条件异方差(generalized auto regressive conditional heteroskedasticity，GARCH)模型，即 GARCH 模型。本文提出的 WD-ARIMAX-GARCH 模型有效避免了神经网络训练不同导致结果不同的问题，可有效提高烧结机机头温度预测的精度。

1　WD-ARIMAX-GARCH 模型

1.1　小波分解(WD)

小波分解是一种基于时域和频域的局部分析方法[11]。该分解方法是构造两个滤波器，一个是低通滤波器，另一个是高通滤波器。小波分解的高频部分具有较高的时间分辨率，而低频部分具有较高的分辨率，从而可降低温度时间序列的波动性。对信号逐级分解，对于每一级的分解，可以看作是将上级分解得到的低频信号再次分解成低频和高频两部分。

小波分解方法能够有效分解非平稳信号，分解结果包含了细节分量和趋势分量，通过小波基的伸缩和平移，有效地将信号的时域特征和频域特征进行了保留。对于低频信号，它的窗口形状自动展现为扁平状态；对于高频信号，它的窗口自动展现为瘦长状态。小波分解理论上可以无限进行分解，分解的次数越多，分解得到的信号越能反映出信号的局部特征，并且经分解得到的信号更精细。但是随着分解的层数增加，建模时间增加，计算量增大，同时会使预测对象增多，预测时出现较大偏差。

信号 $x(t)$ 被小波分解后，可以表示为 n 个细节分量 $d_j(t)$ 与 1 个近似分量 $a_n(t)$ 之和：

$$x(t) = \sum_{j=1}^{n} d_j(t) + a_n(t) \tag{1}$$

1.2　差分自回归滑动平均模型(ARIMA)

通过样本自相关函数检验样本是否平稳。其中平稳时间序列指的是均值，方差和自相关函数不随时间变化的时间序列。数据样本如果是静止的，则该样本的自相关函数能够快速降至零。相反，如果数据序列不稳定，则需要差分操作。然而新序列仍有可能是非平稳序列，因此还需要再次执行差异计算，以便得到平滑的数据序列。一般情况下差分计算次数不超过 2 次，如果进行多次差分计算，会损失较多的信息。然后将新的数据序列作为样本进行建模。自回归模型 AR(p)与滑动平均模型 MA(q)是自回归滑动平均模型 ARMA(p,q)的特例，当 $q=0$ 时，ARMA(p,q)模型即变为 AR 模型；当 $p=0$ 时，ARMA(p,q)模型即变为 MA 模型。

$$Y_t = \varphi_1 Y_{t-1} + \cdots + \varphi_p Y_{t-p} + a_t - \theta_1 a_{t-1} - \cdots - \theta_q a_{t-q} \tag{2}$$

式中：Y_t 为时间序列；φ_p 和 θ_q 为待求解参数；p 为自回归阶数；q 为滑动平均阶数，a_t 为均值为零且方差恒定的白噪声序列。

本文引入广义自回归条件异方差模型[12]，使其方差随条件方差的过去值和滞后残差平方的变化而变化。GARCH 模型对方差 σ_t^2 的数学表达：

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^{m} \beta_i \sigma_{t-m}^2 + \sum_{j=1}^{n} \alpha_j e_{t-j}^2 \tag{3}$$

式中：σ_t^2 为方差；α_0 为残差；e_t 为误差值；β_i 和 α_j 为待估未知参数；为了保证条件方差总是正数，

要求 $\beta_i \geqslant 0$，$i = 0$，1，…，m；$\alpha_j \geqslant 0$，$j = 0$，1，…，n；为了保证 e_t 平稳，则 $\sum_{i=1}^{m}\beta_i + \sum_{j=1}^{n}\alpha_j < 1$。

通常情况下随机序列并不是平稳序列，此时需要对非平稳序列做 d 阶差分处理，使其变为平稳随机序列，即：

$$\nabla^d Y_t = W_t \tag{4}$$

式中：W_t 为随机序列 Y_t 经 d 阶差分处理后的平稳时间序列；∇^d 为 d 阶差分算子。

1.3 ARMAX 模型

ARMA 模型在温度预测中得到广泛应用，但是预测波动范围大的时间序列时效果较差。因此，本文在 ARMA 的基础上引入外生变量，建立 ARMAX 模型[12]，可以提高时间序列模型的适应性，消除迟延问题，提高预测精度。

令 $y(t)(t=1,\cdots,\mathrm{T})$ 为平稳随机时间序列，或非平稳序列经差分后转变为平稳的序列。ARMAX $(p,\boldsymbol{N}_i,q)$ 模型[11]的数学表达式可写为

$$y(t) = \sum_{j=1}^{p}\varphi_j y(t-j) + \sum_{j=0}^{q}\theta_j e(t-j) + \sum_{i=1}^{J+1}\sum_{n_i=0}^{N_i}\lambda_{i,n_i}u_i(t-n_i) + \varepsilon_t \tag{5}$$

式中：$u_i(t)$ 为泛函级数；φ_j 和 θ_j 分别指系数；λ_{i,n_i} 为输入 $J+1$ 个外生变量的系数；$\boldsymbol{N}_i$ 为外生变量的滞后阶数，是 $1\times(J+1)$ 维矩阵；ε_t 为白噪声序列。

1.4 GARCH 模型

在时间序列中，测量误差的变化可能存在异方差，同时样本数据的处理过程也可能存在异方差。由于异方差性会导致回归模型不稳定且效率低，并且残差的方差将被严重低估，参数检验也会出现错误，模型的拟合精度低，最终不能得到准确的预测结果。由残差序列的异方差性可知，残差项中仍存在可利用的信息。因此，加入 GARCH 模型可降低温度时间序列的异方差特性。模型 GARCH 对方差 δ_t^2 的数学表达：

$$\delta_t^2 = \alpha_0 + \sum_{i=1}^{m}\varphi_i\delta_{t-m}^2 + \sum_{j=1}^{n}\alpha_j e_{t-j}^2 \tag{6}$$

式中：φ_i 和 α_j 为未知参数；为了保证条件方差是正数，要求 $\alpha_j \geqslant 0$，$j=0$，1，…，n；$\varphi_i \geqslant 0$，$i=0$，1，…，m；为了保证 e_t 平稳，要求 $\sum_{j=1}^{n}\alpha_i + \sum_{i=1}^{m}\varphi_i < 1$。

S_{LM}（拉格朗日乘子）检验是最常用的自回归条件异方差效应检验方法。S_{LM} 检验过程如下，首先假定检验的原假设：

$$H_0: \alpha_1 = \alpha_2 = \cdots = \alpha_q = 0 \tag{7}$$

S_{LM} 检验统计量：

$$LM = TR^2 : \chi^2(q) \tag{8}$$

式中：T 为样本数；R^2 为拟合优度。

在原假设下的 S_{LM} 统计量一般渐进服从 $\chi^2(q)$ 分布。因此，在给定的显著水平下，如果 $LM=0$，那么原假设被拒绝，这意味着存在 ARCH 效应。反之，则不存在 ARCH 效应。由于多阶 GARCH 模型参数估计非常复杂且具有多重共线性，因此本文选择 GARCH(1,1)模型。

2 WD-ARIMAX-GARCH 模型步骤

对于改进的时间序列模型 ARIMAX 需要外生变量，为了获取和原时间序列相关性较大的生变量，本文通过引入小波分解将原始温度时间序列分解为多层相关序列。由于序列可能存在异方差特性，因此引入 GARCH(m,n) 模型。WD-ARIMAX-GARCH 组合预测模型的建模流程如图 1 所示。

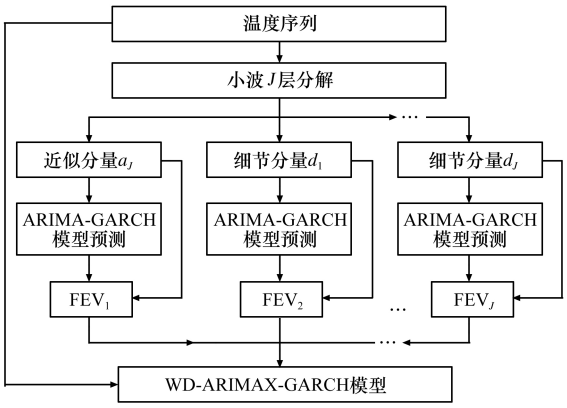


图 1 WD-ARIMAX-GARCH 模型流程

Fig. 1 Model flow of WD-ARIMAX-GARCH

3 温度预测算例分析

3.1 数据选取及模型预测

烧结机机头区域是点火炉区域，点火过程可以认为是烧结的起点，也是烧结工艺的关键环节，其能耗高低和点火质量高低直接影响生产能耗和

产品质量。点火设备点燃烧结台车上混合料表层，将混合料中的燃料点燃，形成燃烧层。在主抽风机的作用下，表层火焰及热量向下传递，进而燃烧下部固体燃料，使得初始燃烧层贯穿到所有料层，从而完成烧结过程。根据实际生产实践可知：烧结机机头料面点火温度需维持在 1 100 ℃左右、点火时间超过 1 min 才能保证烧结的正常运行和烧结矿质量，烧结机机头的温度控制作为生产工艺中的重要一环，合适的温度既可以避免燃料焦气的浪费，也能防止出现温度过高导致烧结矿糊料或者温度过低造成生料的现象。机头温度预测可以提前了解温度的变化情况，有助于生产，从而达到节能减排、降本增效的目的。选取某烧结厂 2023 年 2 月烧结机机头温度数据，采样间隔为1 min。将后 36 个数据作为测试样本，其余为训练样本。

第一步将原始温度序列进行 2 层小波分解。分解后得到 1 个近似序列 a_2 以及 2 个细节序列 d_2 和 d_1。温度时间序列经分解后结果如图 2 所示。

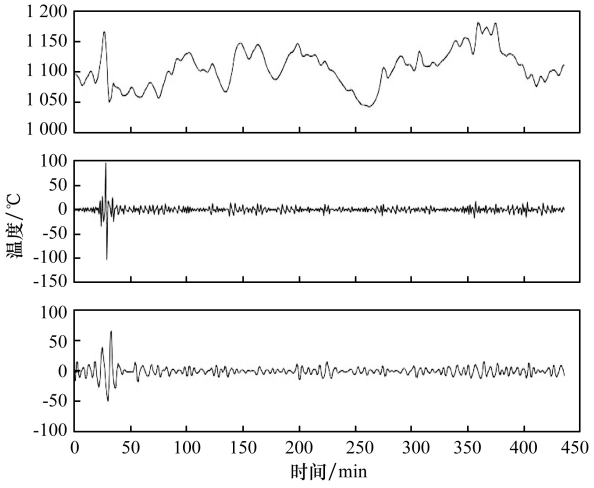


图 2　温度数据的小波分解结果

Fig. 2　Wavelet decomposition results of temperature data

第二步将小波分解后的 $a_2(t)$ 序列、$d_2(t)$ 序列和 $d_1(t)$ $(t=1,2,\cdots,T)$ 序列分别建立 ARIMA (p,D,q)-GARCH$(1,1)$。

第三步将温度序列训练样本小波分解后的序列与 ARIMA(p,D,q)-GARCH$(1,1)$ 模型样本外预测的 36 个数据组合为最终的外生变量序列 FEV。

第四步将 FEV$u_i(t)$ $(i=1,2,3;\ t=1,2,\cdots,T)$ 作为 ARIMAX 模型的 3 个外生变量，建立 ARIMAX 模型，对烧结机机头温度序列进行单步预测。

3.2　误差比较与分析

计算平均绝对误差（δ_{MAE}）、均方根误差（δ_{RMSE}）和平均相对误差（δ_{MRE}）共 3 个误差指标以及仿真曲线对预测结果进行综合评估，3 个误差指标的表达式如下所示：

$$\delta_{MAE}=\frac{1}{M}\sum_{t=1}^{M}|y(t)-z(t)| \tag{6}$$

$$\delta_{RMSE}=\sqrt{\frac{1}{M}\sum_{t=1}^{M}[y(t)-z(t)]^2} \tag{7}$$

$$\delta_{MRE}=\frac{1}{M}\sum_{t=1}^{M}\frac{|y(t)-z(t)|}{z(t)} \tag{8}$$

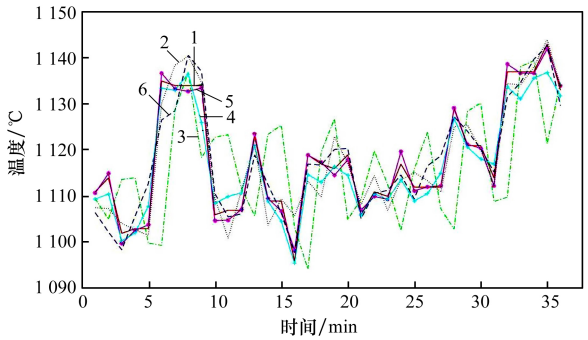
式中：$y(t)$ 为预测值；$z(t)$ 为实际值；M 为样本数量。

引入基于遗传算法优化的 BP 神经网络预测模型做对比分析，表 1 给出了 ARIMA 模型、ARIMA-GARCH 模型、ARIMAX-GARCH 模型、GA-BP 模型、WD-ARIMAX-GARCH 模型预测结果的 δ_{MAE}、δ_{RMSE}、δ_{MRE} 误差性能指标。各预测模型的结果如图 3 所示。

表 1　2023 年 2 月的温度预测误差

Table 1　Temperature prediction error for February 2023

预测模型	δ_{MAE}	δ_{RMSE}	δ_{MRE}
ARIMA	7.854 4	9.493 7	1.55
ARIMA-GARCH	4.604 9	6.635 3	0.42
ARIMAX-GARCH	4.237 4	6.157 6	0.39
GA-BP	3.626 5	7.741 5	0.31
WD-ARIMAX-GARCH	2.713 7	3.257 2	0.25



1—实际值；2—WD-ARIMAX-GARCH；3—ARIMA；4—ARIMA-GARCH；5—ARIMAX-GARCH；6—GA-BP。

图 3　2023 年 2 月各预测模型预测结果

Fig. 3　Prediction results of various prediction models in February 2023

从图3中可以直观地看出，模型预测的温度时间序列变化趋势与实际结果一致，但是WD-ARIMAX-GARCH模型的预测曲线更贴合于实际温度值，而ARIMA、ARIMA-GARCH模型的预测曲线偏离实际温度曲线较大，存在较为明显的迟延，GA-BP预测模型精度稍低于WD-ARIMAX-GARCH模型预测精度。可见，本文提出的WD-ARIMAX-GARCH模型预测精度明显更高。

4 结 论

（1）在进行建模前，首先对原始温度序列进行小波分解，并对各层序列单独预测，最后组合成为最终预测值，与直接预测相比效果更好。

（2）采用WD-ARIMAX-GARCH模型进行温度预测，通过引入外生变量，消除了ARIMA-GARCH模型预测存在的迟延现象，显著提高了温度预测精度。

（3）WD-ARIMAX-GARCH模型避免了神经网络存在过学习的问题，以及每次训练得到的结果不尽相同的问题。

参考文献：

[1] 王新东,刘洋,胡启晨. 河钢唐钢新区绿色节能高效型360 m^2 烧结机的设计[J]. 河北冶金,2021(6):30－36.
WANG Xindong, LIU Yang, HU Qichen. Design of 360 m^2 sintering machine with green energy saving and high efficiency[J]. Hebei Metallurgy,2021(6):30－36.

[2] 刘颂,赵亚迪,甘丽,等. 烧结系统智能制造与大数据技术应用探讨[J]. 钢铁,2021,56(10):54－64.
LIU Song, ZHAO Yadi, GAN Li, et al. Discussion on intelligent manufacturing of sintering system and application of big data technology[J]. Iron & Steel, 2021,56(10):54－64.

[3] 解瑞东,朱尽伟,钟琪,等. 基于神经网络的激光选区烧结温度预测[J]. 激光与光电子学进展,2022,59(19):1916005.
XIE Ruidong, ZHU Jinwei, ZHONG Qi, et al. Temperature prediction based on neural network for selective laser sintering[J]. Laser & Optoelectronics Progress,2022,59(19):1916005.

[4] 黎芬芳,崔桂梅. 基于PSO优化T-S模糊神经网络的磨矿粒度预测[J]. 烧结球团,2022,47(4):64－70.
LI Fenfang, CUI Guimei. Grinding size prediction of optimization of T-S fuzzy neural network based on PSO [J]. Sintering and Pelletizing,2022,47(4):64－70.

[5] 刘月明,刘小杰,吕庆,等. 基于烧结大数据预测小于10 mm烧结矿含量模型[J]. 中国冶金,2019,29(11):31－38.
LIU Yueming, LIU Xiaojie, LÜ Qing, et al. Prediction model of sinter content less than 10mm based on sintering big data[J]. China Metallurgy,2019,29(11):31－38.

[6] 崔亦然,裴润森. 基于长时间序列检测算法的煤矿电力设备故障检测研究[J]. 长江信息通信,2022,35(2):43－46.
CUI Yiran, PEI Runsen. Research on fault detection of coal mine power equipment based on long time series detection algorithm[J]. Changjiang Information & Communications,2022,35(2):43－46.

[7] 黄伟,张泽发. 基于多元线性回归与时间序列分析的燃烧室故障预警研究[J]. 汽轮机技术,2021,63(3):212－214.
HUANG Wei,ZHANG Zefa. Early warning of combustion chamber faults based on multiple linear regression and time series analysis [J]. Turbine Technology, 2021, 63(3):212－214.

[8] 张铭,修晓波,周峰,等. 链算机预热段温度场模型的贝叶斯－BP神经网络系统辨识[J]. 烧结球团,2020,45(5):44－48.
ZHANG Ming, XIU Xiaobo, ZHOU Feng, et al. Identification on Bayes-BP neural network system for temperature field model of preheating section of chain grate[J]. Sintering and Pelletizing,2020,45(5):44－48.

[9] 李暖群,陈冬洋,林佳亮. 基于EEMD-LSSVM的超短期负荷预测研究[J]. 自动化应用,2017(10):100－102.
LI Nuanqun,CHEN Dongfeng,LIN Jialiang. Research on ultra-short-term load forecasting based on EEMD-LSSVM [J]. Automation Application,2017(10):100－102.

[10] 邢艳春,高腾飞. ARIMAX多元时间序列和BP神经网络组合模型在居民消费结构预测中的应用[J]. 吉林师范大学学报(自然科学版),2021,42(3):56－67.

（下转第56页）

kinetics of pellets prepared from iron concentrate with different specific surface areas[J]. The Chinese Journal of Process Engineering,2023,23(5):755 – 762.

[12] 朱辛州,吴南勇,陈方,等. $MgO\text{-}Fe_3O_4$ 比例对磁铁矿氧化动力学的影响机制[J]. 矿业工程,2023,21(1):60 – 65.
ZHU Xinzhou, WU Nanyong, CHEN Fang, et al. Influencing mechanism of $MgO\text{-}Fe_3O_4$ ratio on oxidation kinetics of magnetite[J]. Mining Engineering, 2023, 21(1):60 – 65.

[13] ERIKSSON A, ANDERSSON C, AHMED H, et al. Effect of varied oxygen levels on the oxidation of a magnetite pellet bed during pot furnace induration[J]. ISIJ International,2021,61(5):1439 – 1449.

[14] ZHANG H Q, FU J T. Oxidation behavior of artificial magnetite pellets[J]. International Journal of Minerals, Metallurgy, and Materials,2017,24(6):603 – 610.

[15] 黄希祜. 钢铁冶金原理[M]. 4版. 北京:冶金工业出版社,2013:138 – 141.
HUANG Xihu. Principle of iron and steel metallurgy [M]. 4th ed. Beijing: Metallurgical Industry Press,2013: 138 – 141.

[16] 庄剑鸣. 用化学分析法对球团氧化动力学的研究[J]. 烧结球团,1993,18(3):7 – 11.
ZHUANG Jianming. Research on pellet oxidation kinetics through chemical analysing[J]. Sintering and Pelletizing,1993,18(3):7 – 11.

[17] CHEN W B, DONG Z Q, JIAO Y, et al. Preparation, sintering behavior and consolidation mechanism of vanadium-titanium magnetite pellets[J]. Crystals, 2021, 11(2):188.

[18] 陈许玲,刘树,甘敏,等. 高钛球团焙烧行为及其强化技术[J]. 工程科学学报,2016,38(7):920 – 929.
CHEN Xuling, LIU Shu, GAN Min, et al. Roasting behavior and enhancing technology of high-titanium pellets[J]. Chinese Journal of Engineering, 2016, 38(7):920 – 929.

[19] ZHANG H, BAI K K, LIU W G, et al. Effect of magnetite concentrate particle size on pellet oxidation roasting process and compressive strength[J]. ISIJ International, 2022,62(9):1792 – 1801.

[20] LIU J S, XING Z X, CHENG G J, et al. Oxidation behavior of low-grade vanadiferous titanomagnetite concentrate with high titanium[J]. Journal of Iron and Steel Research International,2024,31(2):329 – 341.

(上接第48页)

XING Yanchun, GAO Tengfei. Application of ARIMAX multivariate time series and BP neural network combined model in the prediction of resident consumption structure [J]. Journal of Jilin Normal University (Natural Science Edition),2021,42(3):56 – 67.

[11] 荆锴,周苗苗,王宏文. 基于WDR和Elman神经网络的烧结风箱废气温度预测[J]. 烧结球团,2013,38(6):11 – 14.
JING Kai, ZHOU Miaomiao, WANG Hongwen. Prediction of exhaust gas temperature of sintering windbox based on WDR and Elman neural network[J]. Sintering and Pelletizing,2013,38(6):11 – 14.

[12] 吴江斌,王璐,夏正兰,等. 基于MS-GARCH-MIDAS的组合预测模型的研究及应用[J]. 重庆理工大学学报(自然科学),2022,36(9):288 – 296.
WU Jiangbin, WANG Lu, XIA Zhenglan, et al. Research and application of commination forecasting model based on MS-GARCH-MIDAS[J]. Journal of Chongqing University of Technology (Natural Science), 2022, 36(9):288 – 296.