

# 基于 VMD-DBO-BiGRU 的多因素铁矿石期货价格预测

刘福国<sup>1,2</sup>, 刘圆梦<sup>3</sup>, 石玉峰<sup>3,4\*</sup>, 田茂再<sup>1</sup>

(1.新疆财经大学统计与数据科学学院, 新疆 乌鲁木齐 830012; 2.昌吉学院数学与数据科学学院, 新疆 昌吉 831100; 3.山东大学金融研究院, 山东 济南 250100; 4.山东大学数学学院, 山东 济南 250100)

**摘要:**提出一种结合变分模态分解(variational mode decomposition, VMD)、蜣螂优化算法(dung beetle optimization, DBO)与双向门控循环单元(bidirectional gated recurrent unit, BiGRU)的预测模型(VMD-DBO-BiGRU),旨在提升铁矿石期货价格预测精度。首先,采用VMD方法对铁矿石期货价格序列进行模态分解,提取不同时间尺度的价格特征并抑制噪声干扰;其次,引入DBO算法优化BiGRU模型的超参数,避免传统优化方法易陷入局部最优的问题;最后,将优化后的BiGRU模型应用于各模态分量的预测,并根据预测结果线性重构得到最终的期货价格预测值。实证研究表明,本文模型在单步和多步预测中均显著提高了铁矿石价格的预测精度,并较基准模型展现出持续的预测性能优势,为山东某钢厂等相关企业在套期保值策略制定和投资决策分析中提供了技术支持,有助于降低市场风险并提高决策效率。

**关键词:**铁矿石期货价格;变分模态分解;蜣螂优化算法;双向门控循环单元

**中图分类号:**O211; F830 **文献标志码:**A

**引用格式:**刘福国,刘圆梦,石玉峰,等.基于VMD-DBO-BiGRU的多因素铁矿石期货价格预测[J].山东大学学报(理学版),2025,60(9):121-132,142.

## Multi-factor iron ore futures price prediction based on VMD-DBO-BiGRU

LIU Fuguo<sup>1,2</sup>, LIU Yuanmeng<sup>3</sup>, SHI Yufeng<sup>3,4\*</sup>, TIAN Maozai<sup>1</sup>

(1. School of Statistics and Data Science, Xinjiang University of Finance and Economics, Urumqi 830012, Xinjiang, China; 2. School of Mathematics and Data Science, Changji College, Changji 831100, Xinjiang, China; 3. Institute for Financial Studies, Shandong University, Jinan 250100, Shandong, China; 4. School of Mathematics, Shandong University, Jinan 250100, Shandong, China)

**Abstract:** By integrating variational mode decomposition (VMD), the dung beetle optimization (DBO) and the bidirectional gated recurrent unit (BiGRU), a price prediction model (VMD-DBO-BiGRU) is proposed, aiming to enhance iron ore futures prediction accuracy. First, VMD is employed to decompose the iron ore futures price series into different modal components, extracting multi-scale price features while suppressing noise. Then, DBO is utilized to optimize the hyperparameters of the BiGRU model, mitigating the risk of local optimum associated with traditional optimization methods. Finally, the optimized BiGRU model is applied to predict each decomposed component, and the final futures price prediction is obtained by linear reconstruction of the predicted results. Experimental findings demonstrate that the proposed model significantly improves prediction accuracy in both single-step and multi-step forecasting, consistently outperforming benchmark models. Moreover, this model provides robust technical support for hedging and investment decision-making in enterprises such as a steel plant in Shandong, contributing to risk mitigation and improved decision efficiency.

**Key words:** iron ore futures price; variational mode decomposition; dung beetle optimization algorithm; bidirectional gated recurrent unit

收稿日期:2025-03-06; 网络出版时间:2025-05-14 12:00:55

基金项目:泰山学者工程(tstp20240803);国家重点研发计划项目(2023YFA1008903);山东省自然科学基金重大项目(ZR2023ZD33);大连商品交易所“百校万才”工程研究项目

第一作者:刘福国(1978—),男,教授,博士研究生,硕士生导师,研究方向为金融数学、数量经济学等. E-mail:lfq53880@cjc.edu.cn;

刘圆梦(1999—),女,硕士研究生,研究方向为金融统计与机器学习. E-mail:302578271@qq.com

\*通信作者:石玉峰(1970—),男,教授,博士生导师,博士,研究方向为随机分析、金融数学、金融科技等. E-mail:yfshi@sdu.edu.cn

## 0 引言

铁矿石作为钢铁生产的关键原料,其价格波动对钢铁产业链具有显著的传导效应。铁矿石价格波动不仅会通过进口成本渠道引发通胀压力,还可能冲击宏观经济的稳定,并影响政策实施的效果。近年来,我国的铁矿石需求持续增长,对外依存度不断提高,成为了全球最大铁矿石净进口国。因此,研究铁矿石价格的影响因素及预测方法,对维护产业链稳定和优化贸易策略具有重要意义。

铁矿石期货价格序列具有非平稳性、非线性和高噪声特性。非平稳性源于多尺度外部冲击,如经济政策不确定性、地缘政治风险等因素持续扰动价格的统计特性,导致其均值与方差呈现显著的时变性<sup>[1]</sup>。根据观察,全球铁矿石及其他几种商品的价格波动性极高<sup>[2]</sup>。2023年上半年,受到全球钢铁需求变化、主要生产国供应状况及国内市场波动等多重因素的影响,铁矿石期货价格波动幅度较大,区间在每吨100—130美元之间<sup>①</sup>。这些因素的复杂性和不确定性,进一步加剧了价格的非线性变化和高噪声特征,难以通过简单的线性模型进行预测<sup>[3]</sup>。以山东某大型钢厂为例,采用30%长期协议采购和70%港口现货采购的采购模式,市场价格波动直接影响其生产运营。该企业的铁矿石相关数据不仅可用于预测价格,还能为制定合理的采购策略提供实证支持。

目前已有许多关于铁矿石价格的影响因素方面的研究。李林泰等<sup>[4]</sup>基于Lasso回归模型识别出普氏价格指数、海运指数、美元指数和国内产量4个核心驱动因素。廖正卿<sup>[5]</sup>指出铁矿石价格受美元指数、钢材价格指数、库存及政治因素等影响。周慧勤等<sup>[6]</sup>采用多元线性回归模型揭示了铁矿石价格与美元指数、波罗的海指数、钢材指数及库存之间的长期均衡关系。王维<sup>[7]</sup>通过向量误差修正(vector error correction, VEC)模型发现港口库存、波罗的海干散货指数以及美元汇率是铁矿石价格的关键影响因素。邵留国等<sup>[8]</sup>采用向量自回归(vector autoregression, VAR)模型发现金融因素(如美元汇率、中美利率差)与市场投机行为在铁矿石价格波动中扮演了重要角色。

铁矿石价格预测模型呈现从传统统计向智能算法演进的趋势。王忠康等<sup>[9]</sup>基于加权移动平均法,通过调整权重并结合铁矿石历史价格,得到铁矿石市场价格的改进预测值。许可等<sup>[10]</sup>通过VAR-TARCH模型刻画了期货市场与现货市场之间的波动溢出效应,但该模型在处理非线性和高维数据时存在局限性。近年来,深度学习方法在大宗商品价格预测领域取得了显著进展。如斯燕等<sup>[11]</sup>利用LSTM神经网络对铁矿石期货价格进行建模,证实该模型在处理高频数据时具有良好的拟合能力和预测精度。施焕伟等<sup>[12]</sup>比较ARIMA、灰色预测和BP神经网络的预测性能,发现BP神经网络在拟合能力和预测精度方面均优于传统统计方法。沈欣宜等<sup>[13]</sup>用SVM、MLP、LSTM和GRU4种机器学习模型对铜期货价格进行预测,验证了深度学习方法在该领域的有效性。尽管深度学习方法在铁矿石价格预测中表现出色,但单一模型的预测精度仍存在提升空间。邓龙鑫<sup>[14]</sup>提出了一种融合ARIMA模型、混沌理论和机器学习的方法,先提取数据的线性特征,再结合非线性建模方法提升预测能力。廖婧文<sup>[15]</sup>在国际原油价格预测中提出VMD-LSTM-ELMAN混合模型,利用变分模态分解(variational mode decomposition, VMD)去除噪声,并结合深度学习提升预测精度。王瑞等<sup>[16]</sup>提出了一种VMD、排列熵和蜣螂优化算法(dung beetle optimization, DBO)的BiLSTM模型,用于短期风电功率预测。研究表明,该方法能够有效降低噪声影响,并通过优化模型超参数提升预测精度。邹婕等<sup>[17]</sup>采用随机森林降维筛选关键因子,并结合自注意力机制和双向门控循环单元(bidirectional gated recurrent unit, BiGRU)进行股票价格预测,验证了BiGRU在时序数据建模中的优势。这些研究表明,结合数据分解技术、智能优化算法和深度学习模型可以有效提升预测模型的稳健性和精度,为大宗商品市场价格预测提供了新的方向。

基于现有研究,本文提出一种结合VMD、DBO和BiGRU的铁矿石期货价格预测模型。本研究的技术贡献主要体现在以下3个方面:1)采用VMD方法用于分解铁矿石期货价格序列,有效提取不同时间尺度的特征信息并抑制噪声,从而提升数据质量;2)引入DBO算法对BiGRU模型的超参数进行优化,克服传统优化方法易陷入局部最优的问题,进一步增强模型的预测能力;3)BiGRU能够同时建模时间序列数据的正

① <https://tks.mysteel.com/a/24010819/A3C7A085281A11C5.html>

向与反向依赖关系,提升了对复杂时序模式的学习能力。

## 1 理论介绍

### 1.1 变分模态分解

Dragomiretskiy 等<sup>[18]</sup>提出的VMD是一种新的适用于非平稳时间序列,用于自适应和非递归信号处理的方法。VMD分解可以获得多个不同频率尺度且相对平稳的子序列,且该方法克服了端点效应和模态分量混叠的问题。本文使用VMD算法对复杂且非平稳的期货价格序列进行分解,其算法步骤如下。

1) 将期货价格序列  $f(t)$  分解成  $K$  个本征模态函数 (intrinsic mode function, IMF), 通过 Hilbert 变换获取模态函数的单边频谱,并调整各自的中心频率,将其单边频谱移到基频带上,然后利用高斯平滑函数估计每个模态函数的带宽,为使带宽和最小,故所得约束变分问题如下:

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|^2 \right\}, \tag{1}$$

$$\text{s.t. } \sum_{k=1}^K u_k = f(t), \tag{2}$$

其中,  $\partial_t$  为偏导运算,  $\delta(t)$  为单位脉冲函数,“\*”为卷积计算符号,  $u_k, \omega_k$  分别为第  $K$  个 IMF 和相应的中心频率。

2) 为将上述问题转化为无约束优化问题,引入二次惩罚因子  $\alpha$  和拉格朗日乘子  $\lambda$ ,式(1)变为

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \rangle, \tag{3}$$

其中,  $\left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2$  是用于加速收敛速度的二次惩罚项,  $\langle, \rangle$  为内积运算。

3) 初始化  $\{\hat{u}_k^1\}, \{\hat{\omega}_k^1\}, \hat{\lambda}^1$  且  $n=0$ 。采用了交替方向乘子法解决以上变分问题,对于  $\omega > 0$ ,更新  $\{\hat{u}_k\}, \{\hat{\omega}_k\}, \{\hat{\lambda}_k\}$  如下:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \hat{\lambda}(\omega)/2}{1 + 2\alpha(\omega - \omega_k)^2}, \tag{4}$$

$$\hat{\omega}_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega}, \tag{5}$$

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \rho \left( f(\omega) - \sum_{k=1}^K \hat{u}_k^{n+1}(\omega) \right), \tag{6}$$

其中,  $\hat{f}(\omega), \hat{\lambda}(\omega), \hat{u}_i(\omega), \hat{u}_k^{n+1}(\omega)$  分别是  $f(\omega), \lambda(\omega), u_i(\omega), u_k^{n+1}(\omega)$  的傅里叶变换,  $n$  为迭代次数。

4) 直到达到如下收敛条件后停止更新:

$$\sum_{k=1}^K \left\| \hat{u}_k^{n+1} - \hat{u}_k^n \right\|_2^2 / \left\| \hat{u}_k^n \right\|_2^2 < \varepsilon \quad (\varepsilon > 0). \tag{7}$$

### 1.2 蜣螂优化算法

蜣螂优化算法是由 Xue 等<sup>[19]</sup>提出的一种群智能优化算法,其设计灵感源自蜣螂在自然界中的5种典型行为:滚球、跳舞、觅食、偷窃和繁殖。该算法具有多种优势,例如快速收敛到全局最优位置,有效避免陷入局部最优,参数较少,适应性强以及在面对多峰函数和动态变化的环境时,显示出良好的鲁棒性,能够保持稳定的优化性能等。蜣螂优化算法中蜣螂群主要由蜣螂滚动、蜣螂产卵、小蜣螂、偷窃蜣螂组成。

1) 在此算法中,负责滚动的蜣螂位置更新公式为

$$x_i(t+1) = x_i(t) + \alpha \times k \times x_i(t-1) + b \times \Delta x, \tag{8}$$

$$\Delta x = |x_i(t) - X^w|, \tag{9}$$

其中:  $t$  为当前的迭代次数;  $\alpha$  取值为 1 或者 -1, -1 表示偏离原方向, 1 表示无偏差;  $k \in (0, 0.2]$  为偏转系数;  $b \in (0, 1)$  为随机数;  $\Delta x$  用于模拟光强的变化(值越大, 光越弱);  $x_i(t)$  代表第  $i$  个蜚螂在第  $t$  次迭代的位置,  $X^w$  代表全局最差的蜚螂位置。

2) 蜚螂在遇到障碍物时, 会通过一种被称为“跳舞”的行为来调整其行进方向, 其位置更新如下:

$$x_i(t+1) = x_i(t) + \tan(\theta) |x_i(t) - x_i(t-1)|, \tag{10}$$

其中,  $\theta \in [0, \pi]$  是偏转角, 且当角度为  $0, \pi/2, \pi$  时, 保存位置不变。

3) 该算法中引入一种模拟雌性蜚螂选择产卵地点的边界选择策略, 其定义如下:

$$B_L^* = \max(X^* \times (1-R), b_L), \tag{11}$$

$$B_U^* = \min(X^* \times (1+R), b_U), \tag{12}$$

$$R = 1 - \frac{t}{T_{\max}}, \tag{13}$$

其中,  $X^*$  代表当前局部最优位置,  $B_L^*, B_U^*$  分别代表产卵区域的下界和上界,  $T_{\max}$  表示最大的迭代次数,  $b_L, b_U$  分别代表产卵区域的下界和上界。

4) 因为产卵区域是动态变化的, 雌性蜚螂选择产卵区域的卵球也是动态变化的, 定义如下:

$$B_i(t+1) = X^* + b_1 \times (B_i(t) - B_L^*) + b_2 \times (B_i(t) - B_U^*), \tag{14}$$

其中,  $B_i(t)$  代表第  $i$  卵球在第  $t$  次迭代的位置,  $b_1, b_2$  分别代表 2 个独立的  $1 \times N$  型随机向量,  $N$  表示优化问题的维数。

5) 接下来是小蜚螂通过最优觅食区域来进行觅食行为, 最优觅食区域定义如下:

$$b_L^b = \max(X^b \times (1-R), b_L), \tag{15}$$

$$b_U^b = \min(X^b \times (1-R), b_U), \tag{16}$$

其中,  $X^b$  代表当前全局最优位置,  $b_L^b, b_U^b$  别代表最优觅食区域的下界和上界。因此, 小蜚螂位置更新公式如下:

$$x_i(t+1) = x_i(t) + C_1 \times (x_i(t) - b_L^b) + C_2 \times (x_i(t) - b_U^b), \tag{17}$$

其中,  $C_1$  是服从正态分布的随机向量,  $C_2$  表示  $(0, 1)$  范围内的随机向量。

6) 在迭代中更新偷窃蜚螂的位置信息, 可以有效促进算法跳出局部最优, 增强全局搜索能力, 具有偷窃行为的蜚螂位置更新公式如下:

$$x_i(t+1) = X^d + S \times g \times (|x_i(t) - X^*| + |x_i(t) - X^d|), \tag{18}$$

其中,  $g$  代表服从正态分布的  $1 \times G$  型随机向量,  $S$  为常数,  $X^d$  为食物竞争的最优位置。

### 1.3 BiGRU 模型

BiGRU 网络的核心结构由 2 个 GRU 层组成, 分别负责处理序列的正向信息和反向信息, 这 2 个 GRU 层输出后被加权合并, 以形成最终的序列表示。这种结构可以捕捉输入序列中前后 2 个方向的信息, 从而提高模型的性能。BiGRU 计算公式如下:

$$\vec{h}_t = \text{GRU}(x_t, \vec{h}_{t-1}), \tag{19}$$

$$\overleftarrow{h}_t = \text{GRU}(x_t, \overleftarrow{h}_{t-1}), \tag{20}$$

$$h_t = w_t \vec{h}_t + v_t \overleftarrow{h}_t + b_t, \tag{21}$$

其中,  $\vec{h}_t, \overleftarrow{h}_t$  分别为  $t$  时刻 GRU 前向和后向隐藏层的输出值,  $w_t$  为正向权重系数,  $v_t$  为反向权重系数,  $b_t$  为偏置参数。BiGRU 的具体结构如图 1 所示。




图 1 BiGRU 模型结构  
Fig.1 BiGRU model structure

### 1.4 VMD-DBO-BiGRU 模型构建

图2是本文所提出VMD-DBO-BiGRU期货价格序列预测模型的流程图,其构建过程如下。

- 1) 使用VMD将期货价格序列分解为 $K$ 个模态分量;
- 2) 加载特征数据,划分训练集和测试集;
- 3) 对数据进行标准化处理,将数据传入到DBO中,返回最优参数;
- 4) 将最优参数引入到BiGRU模型,使用训练集数据重新训练模型;
- 5) 使用最优DBO-BiGRU模型对测试集数据进行预测;
- 6) 将 $K$ 个分量的预测结果进行线性相加得到最终的预测结果。

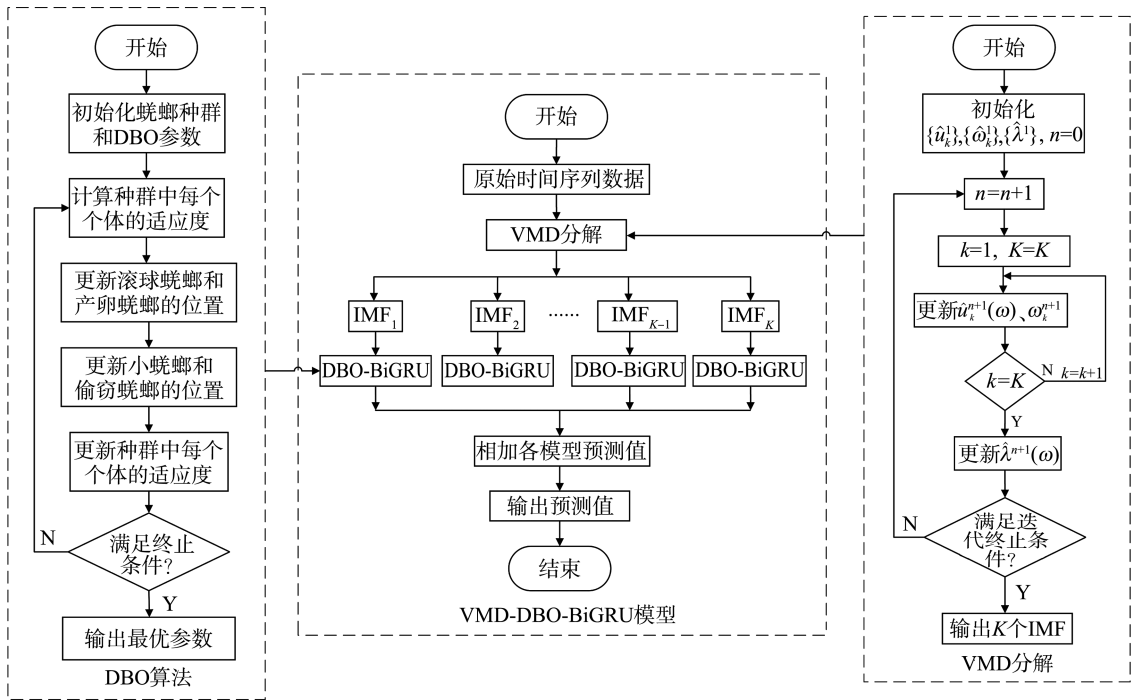


图2 VMD-DBO-BiGRU 模型构建  
Fig.2 VMD-DBO-BiGRU model construction

## 2 实证分析

### 2.1 数据来源

本文研究所使用的铁矿石期货价格数据来自其主力合约的日结算价,可通过大连商品交易所(Dalian Commodity Exchange, DCE)官方网站(<http://www.dce.com.cn/>)获取。铁矿石库存数据集来自山东某钢厂,包含了45个港口进口的铁矿石库存总量。此外,螺纹钢消费量数据、美元指数以及螺纹钢绝对价格指数来自钢联数据库。铁矿石期货价格、美元指数及螺纹钢绝对价格指数为日数据,因缺失值较少,本文采用前向填充法进行缺失值处理;而铁矿石库存数据和螺纹钢消费量数据为周数据,为避免数据波动过大且保留整体趋势,本文使用加权平均插值法对缺失的周数据进行插补得到每日数据。本研究的时间范围为2017年1月4日至2023年6月30日(公共节假日除外)。

### 2.2 指标的选取与说明

本文选取DCE铁矿石期货作为研究样本。DCE是中国重要的商品期货交易平台,其铁矿石期货市场交易活跃,价格波动对全球铁矿石市场具有重要影响。本文采用8个模型进行预测,其中单步预测使用10天的历史数据预测未来1天的价格,多步预测则针对未来6天的价格进行预测。

1) 铁矿石库存量。铁矿石库存量作为市场供需关系的重要指标,直接影响市场参与者对未来价格走势的预期。当库存增加时,通常表明市场供应充足,可能施加价格下行压力;反之,库存减少则可能推高价格。特别是铁矿石港口库存,它是铁矿石市场基本面状况的直接反映,且在钢铁行业中被高度关注。

2) 钢材需求量。钢材需求与铁矿石价格密切相关,因为铁矿石是钢材生产的主要原料,所以钢材需求

波动直接影响铁矿石的需求量及其期货价格。螺纹钢作为主要的钢材品种,广泛应用于建筑和基础设施,其消费量与整体钢材需求高度相关。在钢铁生产过程中,螺纹钢的需求波动直接反映了铁矿石需求的变化。因此,本文选取螺纹钢消费量数据作为钢材需求的衡量指标,以预测铁矿石期货价格。

3) 美元指数。美元指数衡量美元相对于一篮子主要货币的汇率波动。由于铁矿石期货通常以美元计价,因此美元指数的波动会直接影响铁矿石的价格。美元升值通常会导致以美元计价的铁矿石价格下跌,而美元贬值则可能推高价格。因此,美元指数是预测铁矿石期货价格的重要因素之一。

4) 钢材价格指数。钢材价格指数反映钢材市场的整体价格水平,是衡量钢材市场供需关系的重要指标。钢材价格上涨通常会推动铁矿石需求增加,从而推高铁矿石价格。考虑到螺纹钢在钢材中的重要性,本文选用螺纹钢绝对价格指数作为铁矿石期货价格预测的一个关键输入。综上所述,输入层和输出层指标如表1所示。

变量类型	变量名称
输入层指标	铁矿石库存量
	钢材需求量
	美元指数
	钢材价格指数
输出层指标	铁矿石期货价格

为了验证输入变量的合理性,计算铁矿石期货价格与各因素的 Pearson 相关系数,见表2。结果显示,贸易矿进口库存与铁矿石期货价格呈现显著正相关(相关系数为0.384,  $P < 0.01$ ),表明库存的增加反映了市场供应的充足性,从而对价格产生下行压力,这一结果与经济学理论一致,即库存水平的变化直接影响市场参与者对未来价格走势的预期;螺纹钢绝对价格指数与铁矿石期货价格也呈现显著正相关(相关系数为0.453,  $P < 0.01$ ),表明钢材价格的上涨通常意味着需求的增加,从而推动铁矿石价格上涨,这一发现进一步验证了铁矿石作为钢铁生产的关键原料,其价格与下游产品价格之间的紧密联系;美元指数与铁矿石期货价格呈弱负相关(相关系数为-0.046,  $P < 0.1$ ),虽未达到严格显著性水平,但方向性与“美元升值抑制以美元计价商品价格”的理论预期一致,还需结合其他因素综合分析;需要注意的是,螺纹钢消费量与铁矿石期货价格的相关系数仅为0.025,且统计上不显著,可能受数据频率(周数据插值为日数据)或需求传导滞后性影响,表明单一消费量指标对短期价格波动的解释力有限,需结合产业链多维度指标建模。总体而言,相关性分析结果支撑了文中选取输入指标的合理性,同时揭示了部分变量关系的复杂性,为 VMD-DBO-BiGRU 模型通过多因素融合与非线性建模提升预测精度提供了实证依据。

表2 铁矿石期货价格与各因素相关性分析结果  
Table 2 The correlation analysis results of iron ore futures prices and various factors

因素	相关系数	$P$	方向性
贸易矿进口库存	0.384	<0.001	正相关
螺纹钢消费量	0.026	0.325	正相关
美元指数	-0.046	0.065	负相关
螺纹钢绝对价格指数	0.453	<0.001	正相关

### 2.3 评价指标

在评估模型的预测效果时,本文选用4个评价指标:平均绝对误差(mean absolute error, MAE)、平均百分绝对误差(mean absolute percentage error, MAPE)、均方根误差(root mean square error, RMSE)和可决系数(coefficient of determination,  $R^2$ )。MAE和MAPE提供了预测误差的直观度量,而RMSE则进一步考虑了误差的方差, $R^2$ 则从模型拟合优度的角度提供了评价。综合以上指标能够全面地评价模型的预测准确性和可靠性,确保模型在实际应用中的有效性。计算公式分别如下:

$$E_{MAE} = \frac{1}{N} \sum_{t=1}^N |\hat{x}_t - x_t|, \quad (22)$$

$$E_{MAPE} = \frac{1}{N} \sum_{t=1}^N \left| \frac{x_t - \hat{x}_t}{x_t} \right| \times 100\%, \quad (23)$$

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{t=1}^N (\hat{x}_t - x_t)^2}, \quad (24)$$

$$R^2 = \frac{\sum_{t=1}^N (\hat{x}_t - \bar{x}_t)^2}{\sum_{t=1}^N (x_t - \bar{x}_t)^2} = 1 - \frac{\sum_{i=1}^N (x_i - \hat{x}_i)^2}{\sum_{i=1}^N (x_i - \bar{x}_i)^2}, \quad (25)$$

其中,  $N$  为样本个数,  $x_t$  为  $t$  时刻的真实值,  $\hat{x}_t$  为  $t$  时刻的预测值。

### 2.4 数据预处理

在模型训练前对原始数据进行了以下预处理步骤,以确保数据质量和模型的有效性。

1) 数据清理。对数据中的缺失值进行处理,确保数据的完整性和一致性。

本文的加权插值方法是基于逆距离加权(inverse distance weighting, IDW)的思想<sup>[20]</sup>,对于每个目标日期  $t$ ,计算其与所有已知数据点的日期差,取绝对值作为距离,并用距离的倒数作为权重,最终计算加权平均值。它本质上是一种基于邻近点的加权平均方法,可以有效处理不规则时间间隔的数据,有效避免了如线性插值等传统插值方法的过平滑或过拟合问题,保留了数据的原始趋势和波动特征。具体公式如下:

$$\hat{y}_t = \frac{\sum_{i=1}^n y_i / |t - t_i| + \varepsilon}{\sum_{i=1}^n 1 / |t - t_i| + \varepsilon}, \quad (26)$$

其中,  $\hat{y}_t$  为目标日期  $t$  的插值结果,  $y_i$  为第  $i$  个周数据的值,  $t_i$  为第  $i$  个周数据的日期,  $|t - t_i|$  为目标日期  $t$  与周数据日期  $t_i$  的时间差(以天为单位),  $\varepsilon$  为平滑参数,用于避免除零错误,通常取为  $1e-10$ 。权重函数与时间距离的倒数成正比,距离越近的周数据对插值结果影响越大。插值范围是从原始数据的起始日期到结束日期,按天生成插值点。

2) 特征选择。从特征集中选择与期货价格最相关的子集,以减少特征空间的维度,避免出现过拟合,并提高模型的泛化能力。

3) 数据标准化。为了确保不同特征在分析和建模时具有可比性,需要进行标准化处理来消除量纲和数值范围的影响,本文采用  $Z$  得分标准化方法,具体计算公式如下:

$$Z = \frac{x_i - \bar{x}}{s}, \quad (27)$$

其中,  $Z$  为标准化后的数据,  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$  为样本数据的平均值,  $s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$  为样本数据的标准差。

4) 训练集与测试集划分。本文按照 8:2 的比例划分数据集,其中训练集为 2017 年 1 月 4 日至 2022 年 3 月 29 日共 1 292 个数据,测试集为 2022 年 3 月 30 日至 2023 年 6 月 30 日共 323 个数据。

### 2.5 参数设置

在 VMD 参数选择阶段,本文对铁矿石期货的价格数据进行分解,并在固定惩罚因子  $\alpha$  下,通过比较不同  $K$  值下的 IMF 中心频率来选择最佳值,数据详见表 3。铁矿石品种的期货价格在  $K$  大于 7 时,中心频率值相近,表明此时已能捕捉足够频率成分,同时避免了频谱混叠,因此  $K$  确定为 7。其中,表 3 空白处表示当分解模态数  $K$  小于对应 IMF 序号时该模态分量未生成,故无中心频率数据。例如,  $K=3$  仅生成 IMF1—IMF3, IMF4—IMF8 因超出模态数范围而空缺。

表 3 期货价格数据在不同  $K$  值条件下的中心频率  
Table 3 Center frequencies of futures price data under different  $K$ -value conditions

$K$ 值	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8
3	0.000 653	0.023 226	0.093 513					
4	0.000 642	0.022 251	0.089 767	0.303 329				
5	0.000 268	0.006 400	0.035 640	0.101 979	0.305 347			
6	0.000 265	0.006 312	0.034 747	0.094 521	0.159 397	0.309 814		
7	0.000 264	0.006 302	0.034 705	0.094 298	0.158 865	0.305 864	0.431 213	
8	0.000 235	0.005 486	0.022 351	0.044 642	0.100 526	0.162 919	0.306 848	0.431 832

当惩罚因子取值不同时,VMD分解运行时间如表4所示。惩罚因子为2 000时提供了较好的运行时间表现,VMD算法能在合理时间内完成分解,同时保持良好的分解质量。因此,本文将VMD算法中的惩罚因子统一设为2 000。在上述参数下,对铁矿石期货品种的价格序列进行VMD分解,结果如图3。可知各分量是按照频率从低到高排列,每条分量反映出不同的信息:IMF1表示趋势分量,变化平缓,规律性易掌握,反映了原始数据的整体趋势;IMF2、IMF3表示细节分量,规律性较好,反映了原始数据具有较强的周期性;IMF4—IMF7表示随机分量,波动较大,规律性较差,具有随机性。

表4 不同惩罚因子下VMD分解期货价格数据结果  
Table 4 Results of VMD decomposition of futures price data with different penalty factors

惩罚因子 $\alpha$	VMD分解运行时间/s
500	0.602 4
1 000	0.601 4
1 500	0.710 1
2 000	0.660 2
2 500	0.674 2
3 000	0.678 2




图3 铁矿石期货价格序列VMD分解结果  
Fig.3 Results of VMD decomposition of iron ore futures price series

在本文构建的一系列期货价格预测模型中,都采用均方误差(mean squared error, MSE)作为损失函数,使用DBO算法对BiGRU模型中的学习率和神经元数量进行优化,以寻找最优参数组合,模型详细参数设置见表5。

表5 参数设置  
Table 5 Parameter settings

模型/算法	设置
BP	hidden_layer_sizes = (64,64), max_iter=100, random_state=10, alpha=0.001
LSTM	2 LSTM units = 64, activation = selu, loss = mean squared error, optimizer = adam, learning rate = 0.001, batch_size = 32, epochs = 100
GRU	GRU units = 64, activation = selu, loss = mean squared error, optimizer = adam, learning rate = 0.001, batch_size = 32, epochs = 100
BiGRU	BiGRU units = 64, activation = selu, loss = mean squared error, optimizer = adam, learning rate = 0.001, batch_size = 32, epochs = 100
CNN-BiGRU	Conv1D filters = 32, kernel_size = 3, activation = selu, MaxPooling1D pool_size = 2, BiGRU units = 64, optimizer = adam, learning rate = 0.001, batch_size = 32, epochs = 100
DBO	DBO pop = 3, MaxIter = 10, PballRolling = 0.2, PbroodBall = 0.4, PSmall = 0.2, Pthief = 0.2, dim = 2, lb = [0.001, 10], ub = [0.01, 100]
VMD	alpha = 2 000, tau = 0, K = 7, DC = 0, init = 1, tol = 1e-7

### 2.6 单步预测

图4展示了不同模型铁矿石期货价格预测值与真实值的对比,通过8个单步预测模型的对比,可知这些模型都能够实现较为准确的预测;表6列出了使用铁矿石期货价格影响因素预测期货价格的模型评价结果。

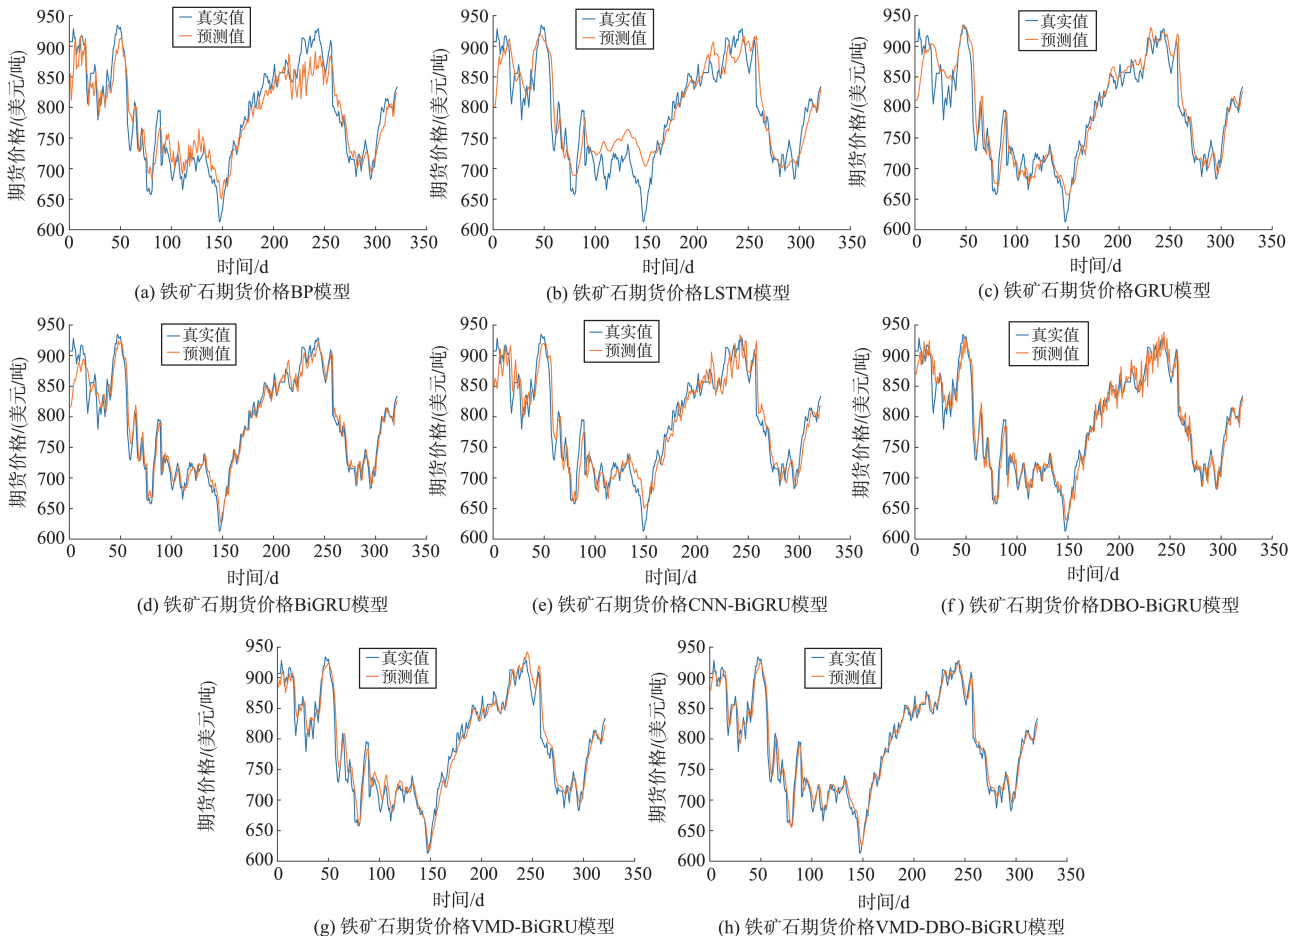


图4 单步预测模型真实值与预测值对比图

Fig.4 Comparison of actual and predicted values in the single-step prediction model

表6 单步预测模型对比评价表  
Table 6 Comparative evaluation table of single-step prediction models

模型	RMSE	MAE	MAPE	$R^2$
BP	28.159 1	22.646 5	2.867 4	0.876 8
LSTM	32.829 2	24.117 5	3.123 8	0.832 6
GRU	28.012 9	20.807 2	2.653 5	0.878 1
BiGRU	19.093 5	13.325 3	1.694 1	0.943 4
CNN-BiGRU	25.663 7	19.786 5	2.518 1	0.897 7
DBO-BiGRU	18.808 8	14.077 1	1.806 0	0.945 0
VMD-BiGRU	9.951 8	7.792 9	0.974 7	0.984 0
VMD-DBO-BiGRU	<b>3.458 2</b>	<b>2.800 0</b>	<b>0.360 2</b>	<b>0.998 1</b>

由图4及表6可知,首先,在5个基准模型中,综合MAE、RMSE、MAPE以及 $R^2$ 指标,BiGRU模型展现出最为出色的预测能力,紧随其后的是CNN-BiGRU、GRU模型。但期货价格预测值相对于真实值有一定的延迟。其次,分析VMD与DBO的独立作用发现,仅引入VMD分解的VMD-BiGRU模型较原始BiGRU的RMSE从19.0935大幅降至9.9518(降幅48%),凸显其通过降噪与多尺度特征提取显著提升非线性、非平稳数据预测精度的能力;而仅依赖DBO优化参数的DBO-BiGRU模型(RMSE=18.8088)较BiGRU仅提升1%,表明DBO虽能规避超参数局部最优陷阱,但单独优化效果有限。值得注意的是,VMD与DBO的协同作用使VMD-DBO-BiGRU模型的RMSE进一步降至3.4582,较VMD-BiGRU降低65%,其误差都得到了显著减小, $R^2$ 值都显著提高。综上可知,在所有模型中,VMD-DBO-BiGRU模型的RMSE、MAE、MAPE是最小的, $R^2$ 值是最高的,表明其预测效果最好,证实了该模型在期货价格预测领域的有效性。

2.7 多步预测

图5展示了不同模型对铁矿石期货价格进行多步预测的预测值与真实值的对比情况,表7则详细列出了多步预测模型的评价结果。

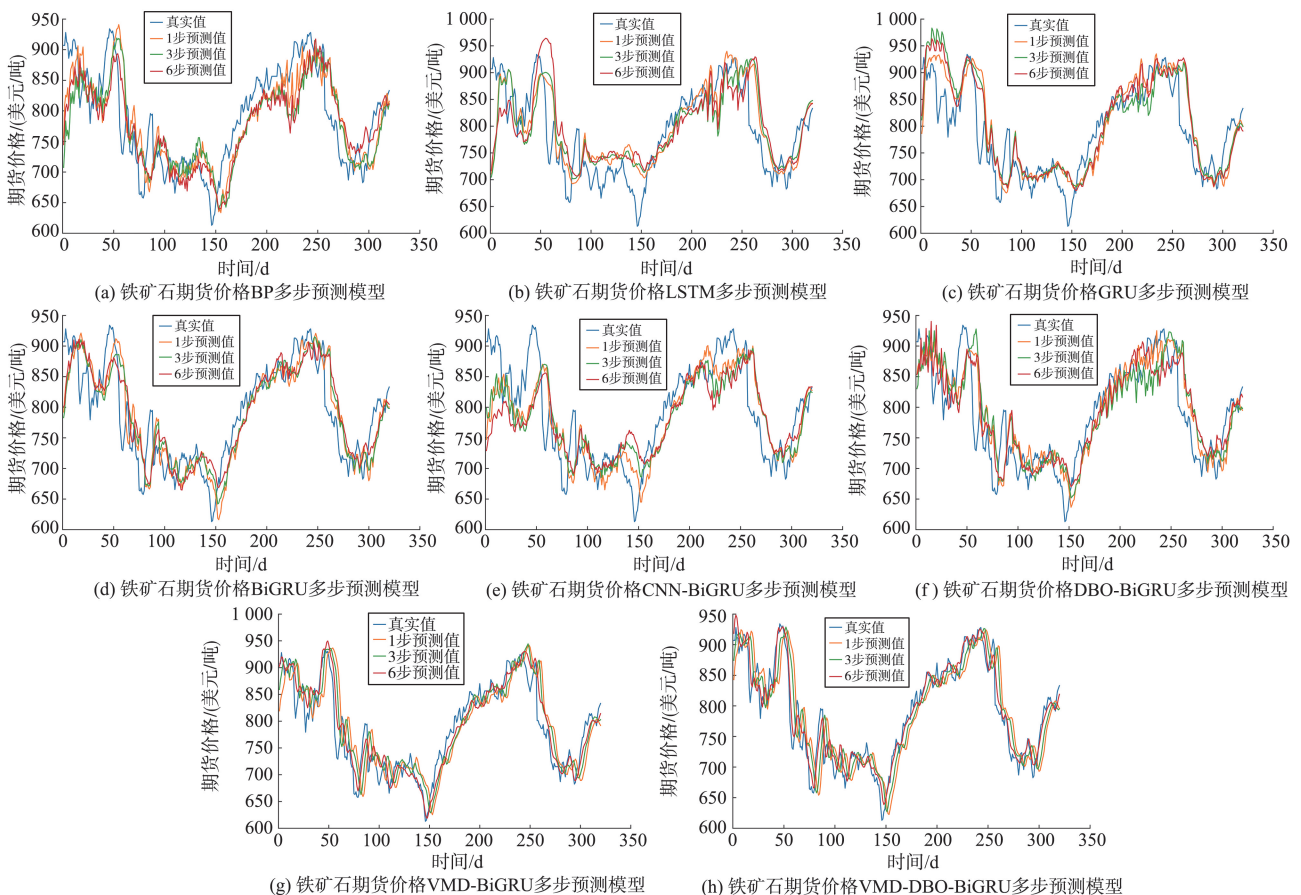


图5 多步预测模型真实值与预测值对比图

Fig.5 Comparison of actual and predicted values in the multi-step prediction model

表7 多步预测模型对比评价表  
Table 7 Comparative evaluation table of multi-step prediction models

评价指标	预测步长	BP	LSTM	GRU	BiGRU	CNN-BiGRU	DBO-BiGRU	VMD-BiGRU	VMD-DBO-BiGRU
RMSE	1	28.070 8	40.467 9	32.041 7	23.775 6	27.871 5	25.546 8	10.801 1	<b>4.466 2</b>
	2	35.471 8	40.199 5	38.174 3	28.962 3	34.646 8	29.177 4	13.132 1	5.437 3
	3	46.866 9	63.143 1	41.623 7	37.065 5	37.663 4	35.013 7	15.291 4	6.085 5
	4	41.961 8	51.469 8	51.730 3	43.622 4	43.763 7	39.293 9	15.439 6	7.284 8
	5	45.719 7	64.654 5	52.251 4	42.266 9	45.943 5	41.345 7	20.866 5	8.727 2
	6	50.753 8	63.512 9	47.625 7	47.115 4	48.732 3	45.992 4	21.364 5	<b>9.992 2</b>
MAE	1	22.690 9	30.924 2	23.595 1	18.522 3	20.201 4	19.307 5	7.998 9	<b>3.280 0</b>
	2	28.397 3	28.981 0	27.473 6	22.488 1	25.930 4	22.349 8	9.785 9	4.062 0
	3	36.758 3	44.672 2	31.279 4	29.617 4	28.345 0	26.992 8	11.940 9	4.442 0
	4	32.873 0	39.785 5	38.622 8	34.723 9	32.200 7	30.179 3	12.175 2	5.610 5
	5	36.832 4	47.253 5	38.793 3	32.895 5	33.659 8	32.692 2	16.957 5	6.767 2
	6	42.044 9	47.997 7	36.063 0	37.576 3	35.875 4	36.079 6	16.489 0	<b>7.665 0</b>
MAPE	1	2.853 8	3.888 3	3.040 2	2.344 9	2.600 0	2.437 7	0.989 2	<b>0.411 7</b>
	2	3.592 0	3.687 2	3.552 7	2.880 4	3.346 9	2.859 7	1.204 9	0.516 2
	3	4.607 4	5.514 3	4.001 8	3.783 9	3.659 5	3.471 2	1.483 8	0.562 4
	4	4.192 5	5.020 6	4.906 9	4.470 0	4.171 9	3.896 6	1.521 8	0.713 3
	5	4.669 3	5.891 5	4.932 3	4.280 2	4.338 8	4.224 7	2.120 4	0.865 3
	6	5.311 0	5.980 8	4.622 3	4.836 7	4.638 8	4.644 4	2.064 2	<b>0.979 6</b>
$R^2$	1	0.878 8	0.748 4	0.842 3	0.913 1	0.880 6	0.899 7	0.981 4	<b>0.996 8</b>
	2	0.806 0	0.751 7	0.776 1	0.871 1	0.815 6	0.869 2	0.972 4	0.995 3
	3	0.660 4	0.387 4	0.733 8	0.788 9	0.782 1	0.811 6	0.962 5	0.994 1
	4	0.727 1	0.593 0	0.588 8	0.707 6	0.705 7	0.762 8	0.961 7	0.991 5
	5	0.674 5	0.357 7	0.580 5	0.725 5	0.675 7	0.737 4	0.929 8	0.987 7
	6	0.596 5	0.380 2	0.651 5	0.658 9	0.635 1	0.675 0	0.926 1	<b>0.983 8</b>

由图5和表7可知, BP、LSTM、GRU、BiGRU、CNN-BiGRU和DBO-BiGRU模型的预测效果随着预测步长的增加而下降,预测曲线的波动性也随之增加,且所有模型的误差指标均呈上升趋势, $R^2$ 同步降低,印证了多步预测任务的复杂性。然而,VMD-BiGRU和VMD-DBO-BiGRU模型在不同步长下均保持较高的预测精度,并能较好地跟随真实曲线的波动。特别是VMD-DBO-BiGRU模型,其预测效果显著优于其他模型,预测结果更为稳定,显示出其在捕捉长期依赖关系和多步预测方面的优势。具体而言,VMD-BiGRU模型的6步预测RMSE较BiGRU降低55%,DBO-BiGRU模型的6步预测RMSE较BiGRU降低2.4%,虽单独提升有限,但与VMD结合后,VMD-DBO-BiGRU的6步RMSE较VMD-BiGRU进一步降低53%,验证了DBO在参数优化中的关键作用。图5显示,VMD-DBO-BiGRU预测结果在6步内仍紧密跟随真实值波动,进一步证明VMD抑制噪声干扰与DBO优化参数的协同作用,两者共同增强了模型对复杂长期依赖关系的捕捉能力,从而在多步预测中实现显著优势。表明所提出的模型能够更准确地捕捉期货价格的动态变化,进一步证实了本文方法在期货价格预测问题上的良好性能。

### 3 结论

本文构建了基于VMD、DBO和BiGRU的铁矿石期货价格预测模型VMD-DBO-BiGRU,为铁矿石期货价格预测提供了新的方法。实证结果表明,该模型在单步及多步预测任务中均表现优异,相较于其他基准方法,能够显著提升预测精度,同时展现出较强的稳定性。在单步预测方面,该模型在RMSE、MAE及MAPE等评价指标上均取得最优结果,且拟合优度最高,验证了其卓越的预测性能。多步预测实验进一步表明,该

模型能够有效捕捉长期依赖关系,保持预测结果的稳定性,在复杂时间序列预测任务中展现出显著优势。

在实际应用方面,该模型可为山东某钢厂等企业在套期保值与投资决策过程中提供精准的价格预测支持,从而优化风险管理策略,提高市场决策的科学性。此外,该方法可推广至其他大宗商品、股票及外汇市场等金融时间序列预测领域,为相关研究与实践提供新的思路和工具支持。

#### 参考文献:

- [1] JIA Lijun, XU Ruoyu, WU Jian, et al. Impacts of geopolitical risk and economic policy uncertainty on metal futures price volatility: evidence from China[J]. Resources Policy, 2023, 87:104328.
- [2] PUSTOV A, MALANICHEV A, KHOBOTOLOV I. Long-term iron ore price modeling: marginal costs vs. incentive price [J]. Resources Policy, 2013, 38(4):558-567.
- [3] PAN Weixu, LIU Shiqian, KUMRAL M, et al. Iron ore price forecast based on a multi-echelontandem learning model[J]. Natural Resources Research, 2024, 33(5):1969-1992.
- [4] 李林泰,崔巍. 铁矿石价格波动的因果推断:影响因素与效应分析[J]. 技术经济,2024,43(8):36-45.  
LI Lintai, CUI Wei. Causal inference of iron ore price fluctuations: analysis of influencing factors and effects [J]. Technological Economics, 2024, 43(8):36-45.
- [5] 廖正卿. 铁矿石价格影响因素及价格预测[J]. 环渤海经济瞭望,2020,34(4):51-52.  
LIAO Zhengqing. Influencing factors and price forecasting of iron ore [J]. Economic Outlook of the Bohai Economic Rim, 2020, 34(4):51-52.
- [6] 周慧勤,陈婷,何建军. 铁矿石价格影响因素及价格预测研究[J]. 中国物价,2018,6:55-57.  
ZHOU Huiqin, CHEN Ting, HE Jianjun. Research on influencing factors and price forecasting of iron ore [J]. China Price, 2018, 6:55-57.
- [7] 王维. 我国进口铁矿石价格影响因素分析[J]. 中国物价,2017,2:58-61.  
WANG Wei. Analysis of influencing factors of imported iron ore prices in China [J]. China Price, 2017, 2:58-61.
- [8] 邵留国,许自花,张仕璟. 新市场格局下铁矿石价格影响因素研究[J]. 管理评论,2018,30(2):13-24,41.  
SHAO Liuguo, XU Zihua, ZHANG Shijing. Research on influencing factors of iron ore prices under the new market pattern [J]. Management Review, 2018, 30(2):13-24,41.
- [9] 王忠康,顾晓薇,胥孝川,等. 基于加权移动平均法的铁矿石价格预测[J]. 中国矿业,2017,26(7):31-34.  
WANG Zhongkang, GU Xiaowei, XU Xiaochuan, et al. Iron ore price forecasting based on weighted moving average method [J]. China Mining, 2017, 26(7):31-34.
- [10] 许可,刘静怡. 基于 VAR-TARCH 模型的铁矿石期货价格发现功能实证研究[J]. 中国证券期货,2020,3:21-31.  
XU Ke, LIU Jingyi. Empirical study on the price discovery function of iron ore futures prices based on VAR-TARCH model [J]. China Securities and Futures, 2020, 3:21-31.
- [11] 斯燕,陈艺. 基于 LSTM 神经网络模型的铁矿石期货市场实证研究[J]. 中国集体经济,2024(2):100-103.  
SI Yan, CHEN Yi. Empirical study on iron ore futures market based on LSTM neural network model [J]. China Collective Economy, 2024(2):100-103.
- [12] 施焕伟. 铁矿石期货价格预测及其套期保值策略研究[D]. 北京:中国石油大学(北京),2021.  
SHI Huanwei. Research on iron ore futures price forecasting and hedging strategy [D]. Beijing: China University of Petroleum (Beijing), 2021.
- [13] 沈欣宜,李旭,沈虹. 基于机器学习的铜期货价格预测分析[J]. 扬州大学学报(自然科学版),2021,24(5):1-7.  
SHEN Xinyi, LI Xu, SHEN Hong. Forecasting analysis of copper futures prices based on machine learning [J]. Journal of Yangzhou University (Natural Science Edition), 2021, 24(5):1-7.
- [14] 邓龙鑫. 基于混沌时间序列和机器学习的铁矿石价格预测模型研究[D]. 长沙:中南大学,2022.  
DENG Longxin. Research on iron ore price forecasting model based on chaos time series and machine learning [D]. Changsha: Central South University, 2022.
- [15] 廖婧文. 基于 VMD-LSTM-ELMAN 模型的国际原油价格人工智能预测研究[J]. 成都理工大学学报(自然科学版), 2024,51(1):164-180.  
LIAO Jingwen. Research on artificial intelligence forecasting of international crude oil prices based on VMD-LSTM-ELMAN model [J]. Journal of Chengdu University of Technology (Natural Science Edition), 2024, 51(1):164-180.