

# 基于 VMD-LSTM-ELMAN 模型的国际原油价格 人工智能预测研究

廖婧文

香港浸会大学 工商管理学院, 香港 999077

[摘要] 针对国际原油价格序列的高度非线性、非平稳性和时变性等复杂特征,本文提出一种基于变分模态分解(Variational modal decomposition, VMD)和组合预测模型 LSTM-ELMAN 的方法对国际原油价格进行预测。首先采用 VMD 方法将原始原油价格分解为不同频率的子序列;然后采用不同模型分别对高频和低频序列进行预测,利用 ELMAN 神经网络(Elman neural network, ELMAN)预测最后一个高频分量,长短期记忆网络(LSTM, Long short-term memory network)作为主要的预测模型来预测其他子序列;最后重构不同模型的子序列预测值,进而得到最终的预测结果。实证研究结果表明,本文所提出的 VMD-LSTM-ELMAN 混合模型相较于对比模型不仅能够明显提高国际原油价格的预测精度,而且在不同训练集长度和市场环境下仍能保持预测优势,具有较强的泛化性与可靠性。总体而言,基于国际原油价格的实验证明了 VMD-LSTM-ELMAN 是一种有效且稳定的预测模型,能够为政府和企业提供有效的智能技术支持。

[关键词] 原油价格预测;变分模态分解;长短期记忆网络;ELMAN 神经网络

[分类号] F416.2

[文献标志码] A

## Research on artificial intelligence predictions of international crude oil prices based on variational modal decomposition, long short-term memory, and the Elman neural network

LIAO Jingwen

School of Business, Hongkong Baptist University, Hongkong 999077, China

**Abstract:** Aiming at the complex characteristics of international crude oil prices, which are highly nonlinear, non-stationary, and time varying, this paper proposed a method based on variational modal decomposition (VMD), long short-term memory network (LSTM), and the Elman neural network (ELMAN) to predict international crude oil prices. First, the original crude oil prices were decomposed

[收稿日期] 2023-10-27。

[第一作者] 廖婧文(2000—),女,硕士,研究方向:经济预测, E-mail:18040356890@163.com。

[引用格式] 廖婧文, 2024. 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), 51(1):164-180.

Liao J W, 2024. Research on artificial intelligence predictions of international crude oil prices based on variational modal decomposition, long short-term memory, and the Elman neural network[J]. Journal of Chengdu University of Technology (Science & Technology Edition), 51(1):164-180.

into subsequences of different frequencies with the VMD method. Then, different models were used to predict high frequency and low frequency sequences. ELMAN was used to predict the last high frequency component, and LSTM was used as the main prediction model to predict other subsequences. Finally, the subsequence prediction values of different models were reconstructed to obtain the final prediction results. The empirical results showed that the VMD-LSTM-ELMAN hybrid model proposed in this paper not only significantly improved the prediction accuracy of international crude oil prices compared with the comparison model, but also maintained strong prediction advantage under different training set lengths and market conditions. It was shown that the model had strong generalization ability and was reliable. Overall, experiments based on international crude oil prices demonstrated that the VMD-LSTM-ELMAN method was an effective and stable forecasting model that provided effective intelligent technical support for governments and businesses.

**Key words:** crude oil price forecast; variational mode decomposition; long short-term memory; Elman neural network

原油作为一种基础能源、化工原料和战略物资,是当今世界不可或缺的资源。它不仅和人们的生活息息相关,而且对世界各国的政治、经济、环境等方面都具有极其重要的影响(Kilian and Vigfusson, 2011; 任泽平, 2012; 包湘海等, 2014; 张跃军, 2020)。1983年,纽约商业交易所推出的轻质低硫的西得克萨斯州中间基原油(West Texas Intermediate, WTI)期货合约拉开了原油期货交易的序幕。由于期货合约交易市场的迅速发展,逐渐使得能源价格与各个领域产生了密切的关系(Steve, 2010; 张金良等, 2013)。事实上,在市场供需博弈、美元汇率、投机交易、地缘冲突、自然灾害等因素的综合作用下,国际原油价格呈现出高噪声、非线性和非平稳的特征,导致对其的精确预测变得十分艰难。由此,构建科学的国际原油价格预测模型成为学术界关注的焦点(Huang et al., 2021; 王德运等, 2022; 刘玲等, 2022)。

也正因为如此,相当一部分学者运用计量经济学模型预测原油价格。徐凌等(2013)建立了自回归积分滑动平均模型(Autoregressive integrated moving average, ARIMA)对国际油价进行定量预测;包湘海等(2014)通过构建原油价格和世界人均国内生产总值的回归模型预测国际原油价格;熊熊等(2016)将季节因子加入 ARIMA 模型中,对 2014—2020 年的国际原油价格进行预测。尽管上述计量经济学模型能够较好地刻画原油价格序列中的线性特征,但却存在难以拟合原油价格序列中非线性特征的缺陷。为此,国内外学者

引入更为先进的人工智能模型对金融时间序列进行预测。

随着计算机技术的迅速发展,人工智能方法在预测领域广受国内外学者的关注,包括人工神经网络(Artificial Neural Network, ANN)及其相关模型(Guresen et al., 2011; Adhikari et al., 2014)。使用 ANN 对金融时间序列进行预测所得到的实证结果证实了 ANN 预测的有效性(Khashei et al., 2014);能源价格可以基于自适应学习处理的反向传播神经网络(Back propagation neural network, BPNN)被预测(Rumelhart et al., 1986)。此外,支持向量回归(Support vector regression, SVR)在现有研究中被认为是一种有效的预测方法(An et al., 2020),混沌映射、萤火虫算法和 SVR 可以用于对股票市场价格进行预测(Kazem et al., 2013)。虽然上述模型在预测金融时间序列方面具有优势,但不可避免地存在对短期信息保持记忆的缺陷。ELMAN(Elman neural network)神经网络的反馈结构有利于短期信息的保留,因此具有较强的优化计算和联想记忆功能,从而在能量价格的预测中具有优势(Li et al., 2019)。同时,混合量化 ELMAN 神经网络在短期负荷预测方面的应用证明了该模型的优越性(Li et al., 2014)。递归神经网络(Recurrent neural network, RNN)能够利用隐藏层的自反馈机制存储近期事件的记忆信息(Lin et al., 1998; Arjun et al., 2020),而 LSTM(Long short-term memory network)作为 RNN 的改进模型,不仅可以解决梯度爆炸和梯度消失的问题,而且可以学

习长期依赖信息(Bengio et al., 1994; Hochreiter et al., 1997)。使用包含 LSTM 的混合模型预测碳价格,有效地提高了预测精度(Zhang et al., 2020)。因此,针对原油价格序列具有时变性与长记忆性的特点,本文引入 ELMAN 神经网络和 LSTM 模型进行预测。

需要进一步指出的是,原油价格通常在多因素的影响下具有非平稳、高噪声特征,而信号分解方法能捕捉其动态变化,为模型提供足够丰富的信息(Lin et al., 2022)。经验模态分解(Empirical mode decomposition, EMD)、集成经验模态分解(Ensemble empirical mode decomposition, EEMD)和其他基于 EMD 的算法被认为是数据分解的有效方法(Wang, 2017; Li et al., 2018; Cao et al., 2019; Yu et al., 2019)。然而,上述分解算法缺乏基础理论,存在边界效应对噪声敏感等缺点,可能严重影响预测结果的准确性(Liu et al., 2020)。VMD 是一种严格的非递归分解技术,通过在谱域对原始序列进行若干特定带宽模式的处理,将原始序列分解成多个具有不同特征的本征模函数(Intrinsic mode function, IMF)(Dragomiretskiy et al., 2014; Abdoos, 2016; Wang et al., 2017)。不仅如此,国内外学者通过大量实证分析同样证实了 VMD 模型在挖掘时间序列中隐藏的非线性和非平稳特征方面具有显著优势(Zhu et al., 2019; Sinvaldo et al., 2020; Sun et al., 2020; Huang et al., 2021)。

由于单一模型难以捕捉原油价格序列的多重特性,因此结合分解技术与预测模型而构建的混合模型受到许多学者的广泛关注(唐小我, 1992)。张金良等(2019)基于 VMD 和果蝇算法优化的最小二乘支持向量机(Least squares support vector machine, LSSVM)构建了混合预测模型,并证实了该预测方法对 WTI 价格具有良好的预测性能。前馈神经网络(Feedforward neural network, FNN)被用于分别对 EMD 分解的 IMFs 进行预测,最后应用自适应线性神经网络(Adaptive linear neural network, ALNN)模型集成多个 IMFs 的预测结果,实证结果表明分解集成方法的预测性能优于单一的神经网络模型(Yu et al., 2008)。杨云飞等(2010)结合 EMD 和支持向量机(Support vector machine, SVM)对原油价格进行预测。奇异谱分析(Singular spectrum analysis,

SSA)和 BPNN 模型结合后用于预测大宗商品价格(包括原油价格),证实了该混合模型的预测优越性(Wang et al., 2018)。而小波分解(Wavelet transform, WT)和多层 BPNN 模型结合,所得结果表明上述方法可以提升原油价格预测的准确性(Jammazi et al., 2012)。

众所周知,序列分解后得到的低频分量和高频分量能够呈现不同的特征。其中,高频分量表现出复杂性和不规则性,低频分量则表示序列中清晰的信息,因此恰当地处理非平稳成分能够有效提升原始序列的预测精度(Potts et al., 2016)。用 EMD 将原始序列分解成若干个 IMF,再用小波包分解(Wavelet packet decomposition, WPD)对第一个子序列进行分解,结果表明处理高频序列能够提高模型整体的预测准确性(Yin et al., 2017)。然而,由于低频序列通常能够准确反映原油价格的变化规律和总体趋势,因此本文基于高频序列和低频序列的不同特征分别构建预测模型。

基于以上分析和认识,本文提出了一种新颖的 VMD-LSTM-ELMAN 国际原油价格预测模型。首先利用 VMD 技术将原始原油价格序列分解成若干子序列;然后采用 ELMAN 神经网络和 LSTM 分别预测最后一个高频分量和其余分量;最后将子序列的预测值求和作为模型最终的预测结果。以 WTI 原油期货和上海国际能源交易中心的原油期货日交易价格作为研究对象,本文的目的是回答以下两个问题:相较于其他对比模型, VMD-LSTM-ELMAN 模型在处理非平稳和非线性特征时展现出了哪些独特的优势? VMD-LSTM-ELMAN 模型在预测新兴市场 and 成熟市场原油价格时的表现有何不同? 本文首先详细介绍基于国际原油价格的 VMD-LSTM-ELMAN 模型及预测效果评价方法;然后对实证结果进行分析与比较;最后提出本次研究的结论与对策建议。

## 1 研究方法

### 1.1 原油价格的 VMD 分解方法

引入变分模态过程对国际原油时间序列  $p(t)$  进行不同频率的分解,相关参数的更新步骤如下:首先,采用希伯特变换构造  $u_k(t)$  的解析信号,以

获得单侧频谱;其次,利用指数调谐确定  $u_k(t)$  的频谱到相应基带;然后,计算解析信号梯度的平方  $L_2$  范数,估计  $u_k(t)$  的带宽,构建的约束变分问题为:

$$\min\left\{\sum_{k=1}^K \left\| \partial_t \left[ \delta(t) + \frac{j}{\pi t} \otimes u_k(t) \right] e^{-j\omega_k t} \right\|_2^2\right\} \quad (1)$$

$$\sum_{k=1}^K u_k = p(t) \quad (2)$$

其中:  $K$  为模态个数,  $u_k$  为极限  $K$  阶模态,  $\delta(t)$  为 Dirac 分布,  $\omega_k$  为中心频率,  $\otimes$  为卷积算子。为了获得更优的分解结果,本文使用 ADMM (Alternate Direction of multiplier) 方法进一步改进分解过程,具体过程如下:

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

其中:  $\alpha$  为二次惩罚因子,  $\lambda(t)$  为 Lagrange 乘子。

$u_k^{n+1}$ ,  $\omega_k^{n+1}$  和  $\lambda_k^{n+1}$  的更新过程如下:

$$\hat{u}_k^{n+1}(\omega) = \left\{ \hat{p}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \hat{\lambda}(\omega)/2 \right\} / \left\{ 1 + 2\alpha(\omega - \omega_k)^2 \right\} \quad (4)$$

$$\omega_k^{n+1} = \left\{ \int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega \right\} / \left\{ \int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega \right\} \quad (5)$$

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau \left[ \hat{f}(\omega) - \sum_{k=1}^K \hat{u}_k^{n+1}(\omega) \right] \quad (6)$$

其中:  $n$  为迭代值,  $\hat{p}(\omega)$ ,  $\hat{u}_i(\omega)$ ,  $\hat{\lambda}(\omega)$  和  $\hat{u}_k^{n+1}(\omega)$  分别为对  $p(t)$ ,  $u_i(t)$ ,  $\lambda(t)$  和  $u_k^{n+1}(t)$  的傅里叶变换,  $\tau$  为噪声边际。将公式(4)、(5)、(6)的过程与停止条件相结合:

$$\sum_k \left\| \hat{u}_k^{n+1} - \hat{u}_k^n \right\|^2 / \left\| \hat{u}_k^n \right\|^2 < \epsilon (\epsilon > 0) \quad (7)$$

其中:  $\epsilon$  为收敛精度,如果不满足公式(7)中的停止条件,  $n$  增加到  $n+1$ 。至此,通过 VMD 的分解方法,将原油时间序列  $p(t)$  分解为从低频向高频排列且具有独立特征的  $N$  个 IMF。

### 1.2 原油价格的预测方法

原油期货价格预测需要对训练数据构建合适的模型,建立序列的内在关系,进而为后续预测过程提供准确支撑。本文提出的 VMD-LSTM-EL-

MAN 预测模型主要设计步骤如下:

首先,对原始原油期货价格数据进行去除异常值与填补缺失值等数据预处理,之后采用 VMD 技术将复杂的原油期货价格分解成为  $N$  个代表不同频率成分的 IMF,以降低原始序列的随机波动性,从而使后续的预测模型能够更准确地捕捉价格趋势和周期性成分。

其次,对分解得到的每个 IMF 进行归一化处理,确保其在相同的尺度上进行比较和分析。接下来,选择适当比例划分训练集与测试集,以便于模型的训练和性能验证。在本研究中,利用 ELMAN 神经网络预测最后一个高频分量 IMF<sub>n</sub>,以处理高频序列不规则的特性;利用 LSTM 模型预测其余 IMF,以处理包含长期趋势的信息。

最后,将  $N$  个利用 ELMAN 和 LSTM 模型预测后的 IMF 重构,以得到最终的预测序列。同时,基于损失函数 MSE, MAE 和 MAPE, MDM 统计检验及稳健性检验中评价本文提出的 VMD-LSTM-ELMAN 预测模型与对比模型的预测性能。

为了更直观地展示本文提出的 VMD-LSTM-ELMAN 模型的整体架构和各步骤之间的逻辑关系,本文将绘制的框架图展示在图 1 中,包括数据分解、模型训练和模型集成 3 个步骤,旨在提供清晰的视觉参考,有助于理解本文提出模型的工作机制和流程。

#### 1.2.1 LSTM 神经网络

LSTM 神经网络的关键之处是其门控单元系统,它使网络能够有效地存储和处理历史信息。这种机制包括负责维持和更新历史数据状态的内部存储单元。LSTM 神经网络通过使用不同的“门”(包括输入门、遗忘门和输出门)动态控制信息流,能够让网络有选择性地忘记历史信息或使用新信息更新单元状态。需要说明的是,在先前基于 ANN 模型的预测研究中,时间序列的特征通常需要事先计算并作为输入。与之相比, LSTM 神经网络的优势在于其能够自动检测和提取对特定任务最有效的特征模式,因此适用于原油价格的预测。LSTM 神经网络的结构及原理如图 2 所示。

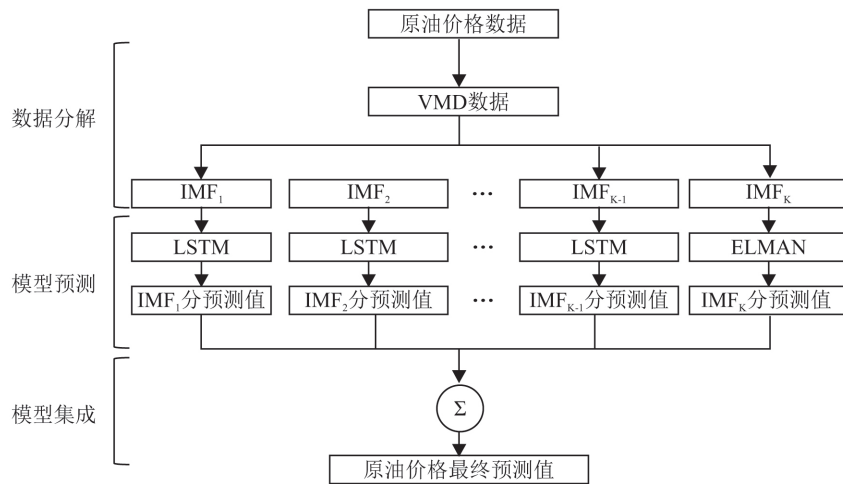


图 1 VMD-LSTM-ELMAN 模型框架图

Fig. 1 Framework of the VMD-LSTM-ELMAN model




图 2 LSTM 神经网络单元图

Fig. 2 Diagram of an LSTM neural network cell

LSTM 结构由记忆细胞、输入门、输出门和遗忘门组成,计算原理如下:

(1)输入门。记忆目前状态的信息,计算输入门  $i_t$  的值和在  $t$  时刻输入细胞的候选状态值  $a_t$ :

$$i_t = \sigma(W_i \cdot (h_{t-1}, X_t) + b_i) \quad (8)$$

$$a_t = \tanh(W_c \cdot (h_{t-1}, X_t) + b_c) \quad (9)$$

其中:  $W_i, W_c$  代表相应的权重,  $b_i$  与  $b_c$  代表相应的偏置。

(2)遗忘门。控制遗忘的信息,计算在  $t$  时刻遗忘门的激活值  $f_t$ :

$$f_t = \sigma(W_f \cdot (h_{t-1}, X_t) + b_f) \quad (10)$$

其中:  $W_f, b_f$  分别表示遗忘门的权重和偏置,  $\sigma$  表示 sigmoid 函数。

(3)更新细胞状态。根据输入门和遗忘门的计算结果,对细胞状态进行更新,从而得出  $t$  时刻的细胞状态更新值  $C_t$ :

$$C_t = i_t \cdot a_t + f_t \cdot C_{t-1} \quad (11)$$

(4)输出门。控制输出的信息,根据计算得到的细胞状态更新值  $C_t$ ,从而得出输出门  $o_t$  的计算公式:

$$o_t = \sigma(W_o \cdot (h_{t-1}, X_t) + b_o) \quad (12)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (13)$$

其中:  $W_o$  和  $b_o$  代表输出门的权重和偏置,  $h_t$  为当前单元的输出值。

### 1. 2. 2 ELMAN 神经网络

ELMAN 神经网络是一种典型的全局前馈、局部递归网络模型,它由 BP 神经网络改进而来,在网络结构上具有相似之处。ELMAN 神经网络由 4 个主要层组成:输入层、隐含层、连接层与输出层。输入层负责传递原油期货价格中的信息;隐含层通常采用非线性函数处理信息;连接层的作用是存储和记忆隐含层的输出,并将这些信息在下一时刻传回输入层,从而实现局部反馈;最后,输出层负责对信息进行线性加权处理。

由于连接层的引入,ELMAN 神经网络能够记忆并处理过去的状态,使其适合于原油期货价格的时变特性,其结构如图 3 所示。




图 3 ELMAN 神经网络图  
Fig. 3 Diagram of the ELMAN neural network

ELMAN 神经网络的数学模型为:

$$\begin{cases} Y(k) = G[\omega_3 X(k)] \\ X(k) = F\{\omega_2 X_c(k) + \omega_1 [u(k-1)]\} \\ X_c(k) = X[(k-1)] \end{cases} \quad (14)$$

其中: \$k\$ 为当前时刻状态, \$Y(k)\$, \$X(k)\$, \$u(k-1)\$, \$X\_c(k)\$ 分别为 \$m\$ 维输出节点向量、\$n\$ 维中间层节点单元向量, \$r\$ 维输入向量和 \$n\$ 维反馈状态向量, \$\omega\_3, \omega\_2, \omega\_1\$ 分别为隐含层到输出层、输入层到隐含层、连接层到隐含层的连接权值, \$G(\cdot)\$ 为输出神经元的传递函数, \$F(\cdot)\$ 为隐含层神经元的传递函数, 常采用 sigmoid 函数。

ELMAN 神经网络采用误差平方和函数作为学习指标函数。

$$E(\omega) = \sum_{k=1}^n [Y_k(\omega) - \tilde{Y}_k(\omega)]^2 \quad (15)$$

其中: \$\tilde{Y}\_k\$ 为目标输出向量。

### 1.3 预测性能的评价指标

首先本文采用均方根误差 (Mean square error, MSE)、平均绝对误差 (Mean average error, MAE) 和平均绝对百分比误差 (Mean absolute percentage error, MAPE) 为标准, 对 VMD-LSTM-ELMAN 模型的性能进行评估, 具体公式如下:

$$MSE = \sum_{t=1}^N (d_t - y_t)^2 / N \quad (16)$$

$$MAE = \sum_{t=1}^N |d_t - y_t| / N \quad (17)$$

$$MAPE = 100\% * \sum_{t=1}^N |d_t - y_t / d_t| / N \quad (18)$$

其中: \$d\_t\$ 为原油期货实际价格, \$y\_t\$ 为预测价格, \$N\$ 表示样本个数。采用 MSE, MAE 和 MAPE 标准来评估实际价格与预测价格的偏差, 其数值越小, 表明模型的预测性能越优异。不仅如此, 本文还通过构建线性回归方程 \$Y = aX + b\$ (其中 \$Y\$ 和 \$X\$ 分别代表原油期货实际价格和预测价格) 来进一步解释预测模型的性能。在这一方程中, 斜率 \$a\$、截距 \$b\$ 和决定系数 \$R^2\$ (R-square, \$R^2\$) 起到关键作用。具体地, \$R^2\$ 的定义如式 (19) 所示:

$$R^2 = 1 - \frac{\sum_{i=1}^n (d_i - y_i)^2}{\sum_{i=1}^n (d_i - \bar{d})^2} \quad (19)$$

其中: \$\bar{d}\$ 为实际价格的平均值, \$n\$ 为测试集样本个数。\$R^2\$ 越接近于 1, 即 \$a, b\$ 分别趋近于 1, 0, 表明 VMD-LSTM-ELMAN 模型对原油期货价格的预测拟合程度越高, 则该模型在预测准确性上具有突出的优势。

除此之外, 本次研究采用修正的 Diebold-Mariano 检验 (Modified Diebold and Mariano, MDM) 来评估模型间的预测差异是否具有统计学意义。如果各模型间的损失函数误差在统计上存在差异, 则表明各模型间的预测能力存在显著差异。假设原始序列为 \$\{f\_t\}\$, 预测值为 \$\{\hat{f}\_i, i=1, 2\}\$, 其中 \$i\$ 表示序列顺序, 且模型间的预测偏差为 \$\{e\_{it}, i=1, 2\}\$:

$$e_{it} = f_t - \hat{f}_i \quad i=1, 2 \quad (20)$$

$$Loss_i = L(f_t, \hat{f}_i) = L(e_{it}) \quad i=1, 2 \quad (21)$$

$$d_t = L(e_{1t}) - L(e_{2t}) \quad t=1, 2, \dots, T \quad (22)$$

$$H_0: E(d_t) = 0 \quad t=1, 2, \dots, T \quad (23)$$

其中: \$Loss\_i\$ 为第 \$i\$ 个模型的损失函数, \$d\_t\$ 为损失微分级数, \$T\$ 为测试集长度。将真实值与预测值之间的损失函数简化为 \$\{L(e\_{it}), i=1, 2\}\$, 即 \$\{L(f\_t, \hat{f}\_i) = L(e\_{it}), i=1, 2\}\$。原假设 \$H\_0\$ 表示模型间具有相同的预测性能。为了预测长记忆序列, 定义 \$\omega^2\$ 表示为 \$d\_t\$ 的长记忆方差, MDM 统计量的表达如下式:

$$\sqrt{T}(\bar{d} - E(d_t)) \xrightarrow{d} N(0, \omega^2) \quad (24)$$

$$\hat{\omega}^2 = \hat{\gamma}_0 + 2 \sum_{j=1}^{h-1} \hat{\gamma}_j \quad (25)$$

$$MDM = \sqrt{T+1-2h+T^{-1}h(h-1)} (\bar{d}/\hat{\omega}) \quad (26)$$

其中： $\bar{d} = T^{-1} \sum_{t=1}^T d_t, \omega^2 = \sum_{j=\infty}^{\infty} \gamma_j, \gamma_j = Cov(d_t, d_{t-j})$ 。此外， $\hat{\omega}^2$  定义为更加一致的长记忆指标， $\hat{\gamma}_j = T^{-1} \sum_{t=j+1}^T (d_t - \bar{d})(d_{t-j} - \bar{d}), h$  为预测步长。MDM 检验将选择  $t$  临界值代替 DM 检验的标准正态分布，相比而言修正后的 MDM 检验更适合不同数据集长度的验证。在本研究中，采用 3 种最常见的损失函数 MSE, MAE 和 MAPE 进行 MDM 检验。

## 2 实证结果与分析

### 2.1 数据样本与分析

由于 WTI 原油和国内原油分别在北美和中国能源市场占据重要地位，因此本文选取纽约商品交易所交易的 WTI 原油期货价格与上海国际能源交易中心交易的原油期货价格的日交易价格为研究对象。WTI 原油期货价格选自 2000 年 1 月 4 日至 2021 年 9 月 30 日的 5 555 个数据(数据来源于美国 U. S Energy Information Administration);国内原油期货价格选择 2018 年 3 月 26 日至 2021 年 9 月 30 日共 858 个数据(数据来源于东方财富 choice)，其中前 90% 的数据为训练集，后 10% 的数据为测试集。图 4 展示了 WTI 和国内原油期货序列的走势。

原油期货价格序列及其 IMF 的描述性统计如表 1 所示，虽然两种原油序列的偏度方向不同，但仍呈现出明显的有偏胖尾特征。J-B 统计量证明在 1% 显著性水平下，两种原油期货价格及其

IMF 均拒绝正态假设的零假设，表明序列都不服从正态分布。本研究进行 Ljung-Box 检验时选择了 10 个滞后期，旨在实现对时间序列自相关特性的有效检测，同时避免由于过多的滞后期而导致数据过拟合问题。值得注意的是，L-B(10) 统计量在 1% 显著性水平下中拒绝第 10 阶无自相关的零假设，不仅支持了本文对滞后期选择的合理性，而且还进一步证明了原油期货价格信息具有长记忆性的特征。

为减少原油期货价格数据中噪声对训练过程产生的影响，本文采用 0—1 归一化对序列进行预处理：

$$\hat{x}_t = [x_t - \min x_t] / [\max x_t - \min x_t] \quad (27)$$

其中： $\min x_t, \max x_t$  分别为原油期货价格的最小值与最大值，接下来通过公式(28)反归一化出测试集的最终预测值：

$$x_m = (\max x_t - \min x_t) \hat{x}_m + \min x_t \quad (28)$$

其中： $\hat{x}_m$  表示经过 0—1 归一化后的原油期货价格预测值， $x_m$  表示模型的最终预测值。

### 2.2 分解结果

VMD 的分解效果受模态个数的限制具有不稳定性，如果  $K$  值较小，容易导致序列分解不充分；如果  $K$  值较大，则会出现模态混频的缺点。因此本文采用观测中心频率的方法预设  $K$  值。不同  $K$  值下 IMF 对应的中心频率如表 2 所示，可以发现当  $K$  预设设为  $[1, 10]$  时，WTI 和国内原油期货中 IMF10 的中心频率最大值分别为 0.470 4 与 0.468 2，中心频率最小值分别为  $2.28 \times 10^{-5}$  和  $1.43 \times 10^{-5}$ ，趋于稳定。因此，本文将 WTI 和国内原油期货的最佳模态个数设置为 10，分解结果见图 5。

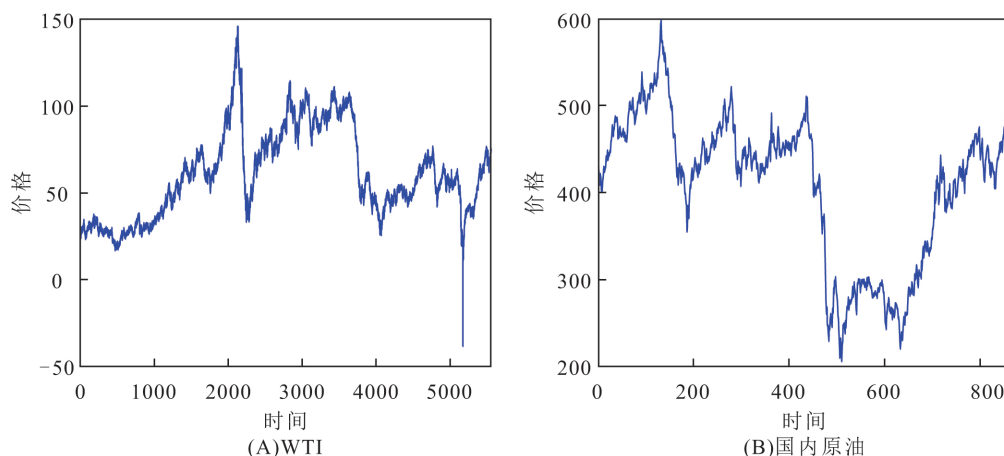


图 4 原油价格序列图  
Fig. 4 Diagram of crude oil prices

表 1 原油价格及其子序列的描述性统计分析  
Table 1 Descriptive statistical analysis of the crude oil prices and different subseries

序列	标准差	偏度	超峰度	J-B	L-B(10)
<b>序列 1 WTI</b>					
原始序列	25.6054	0.4284***	-0.5473***	239.2922***	81231.6769***
IMF1	23.2656	0.1781***	-1.1057***	312.3273***	83168.5011***
IMF2	7.2209	0.2400***	7.3404***	12524.7573***	79823.0989***
IMF3	1.8676	-0.0725*	0.6048***	89.5368***	42457.0646***
IMF4	1.0841	-0.0390	3.5354***	2894.3783***	35376.5845***
IMF5	0.7293	-0.0597*	4.5846***	4868.2251***	27425.7234***
IMF6	0.5666	-0.1033***	30.4266***	214288.2756***	20732.0432***
IMF7	0.4764	-0.0215	65.8704***	1004276.6969***	18079.4177***
IMF8	0.4341	-1.8790***	84.2362***	1645637.0496***	18076.9946***
IMF9	0.3572	-0.0922***	116.2549***	3128211.3623***	16477.2171***
IMF10	0.3386	0.0664**	114.7941***	3050088.0559***	18165.8440***
<b>序列 2 国内原油</b>					
原始序列	84.8339	-0.5885***	-0.6930***	66.7041***	11739.0537***
IMF1	65.2979	-0.5811***	-1.1489***	95.4717***	12771.0504***
IMF2	32.9706	0.0800	-0.4872***	9.4024***	11617.9018***
IMF3	13.1330	0.2279***	-0.3834**	12.6849***	6890.5693***
IMF4	8.8397	-0.0422	3.3075***	391.3376***	5814.2171***
IMF5	4.6397	0.0037	-0.0245	0.0235	4907.6890***
IMF6	3.0381	0.0028	0.3732***	4.9811*	3835.5753***
IMF7	2.3822	-0.0044	0.6228***	13.8697***	3348.6179***
IMF8	2.1304	-0.0012	1.6658***	99.1975***	2449.3697***
IMF9	1.9429	-0.0045	0.1379	0.6831	2210.9410***
IMF10	1.5794	-0.0009	0.3431**	4.2107**	2634.5646***

说明:\*, \*\*, \*\*\* 分别表示在 10%, 5%, 1% 显著性水平下显著; J-B 是 Jarque-Bera 统计量; L-B(10) 是 10 阶序列相关的 Ljung-Box 统计量。

表 2 不同 K 值下 IMF 的中心频率  
Table 2 Central frequency of the IMF under different K values

K	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8	IMF9	IMF10
<b>序列 1 WTI</b>										
1	0.0001									
2	$7.81 \times 10^{-5}$	0.4731								
3	$6.33 \times 10^{-5}$	0.0499	0.4559							
4	$5.85 \times 10^{-5}$	0.0273	0.1066	0.4703						
5	$3.21 \times 10^{-5}$	0.0054	0.0498	0.1855	0.4148					
6	$2.78 \times 10^{-5}$	0.0045	0.0492	0.1259	0.2425	0.4434				
7	$2.55 \times 10^{-5}$	0.0040	0.0277	0.0863	0.2098	0.3096	0.4403			
8	$2.46 \times 10^{-5}$	0.0038	0.0252	0.0641	0.1288	0.1976	0.2882	0.4672		
9	$2.41 \times 10^{-5}$	0.0037	0.0236	0.0571	0.1069	0.1696	0.2594	0.3361	0.4457	
10	$2.28 \times 10^{-5}$	0.0034	0.0149	0.0379	0.0786	0.1455	0.2294	0.3184	0.3980	0.4704
<b>序列 2 国内原油</b>										
1	$8.10 \times 10^{-5}$									
2	$4.68 \times 10^{-5}$	0.0476								
3	$3.92 \times 10^{-5}$	0.0240	0.0994							
4	$2.13 \times 10^{-5}$	0.0077	0.0385	0.1173						
5	$1.90 \times 10^{-5}$	0.0069	0.0350	0.0883	0.1928					
6	$1.82 \times 10^{-5}$	0.0067	0.0340	0.0812	0.1469	0.2987				
7	$1.80 \times 10^{-5}$	0.0067	0.0347	0.0802	0.1466	0.2449	0.3718			
8	$1.79 \times 10^{-5}$	0.0066	0.0333	0.0763	0.1274	0.1904	0.2789	0.4033		
9	$1.78 \times 10^{-5}$	0.0066	0.0326	0.0714	0.1089	0.1626	0.2641	0.3477	0.4390	
10	$1.43 \times 10^{-5}$	0.0051	0.0136	0.0352	0.0760	0.1194	0.1677	0.2410	0.3742	0.4682

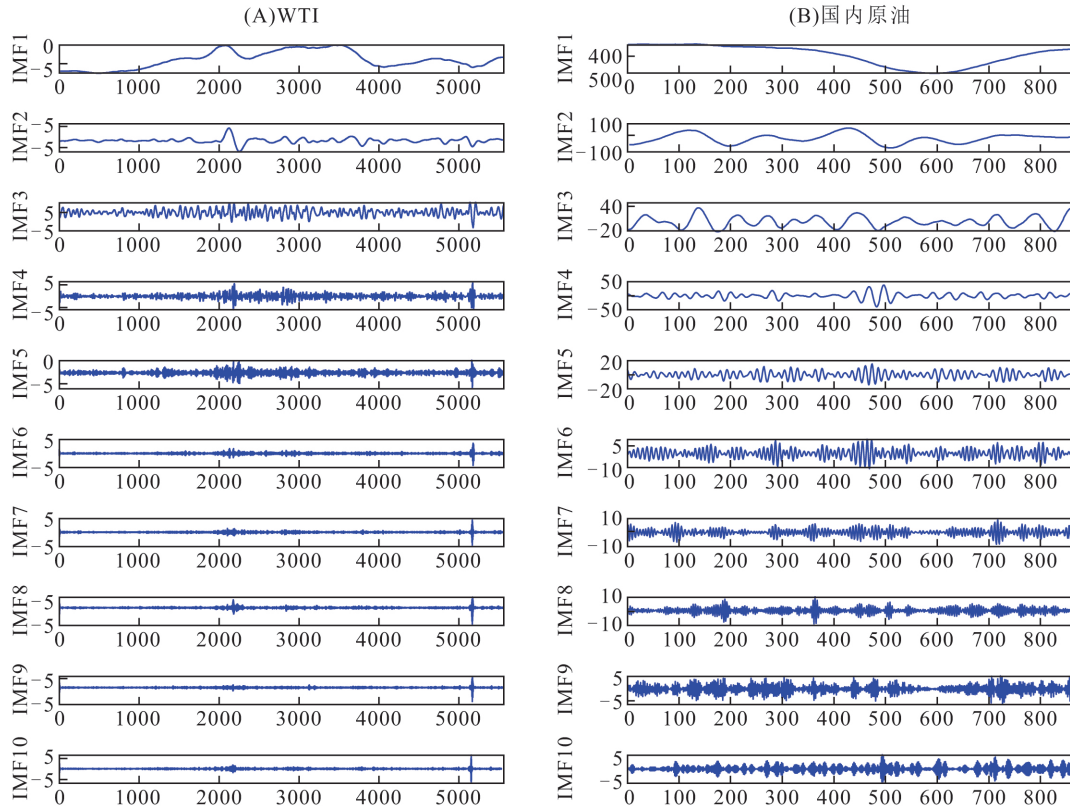


图 5 原油价格分解图

Fig. 5 Decomposition graph of crude oil prices

以上分析表明,由于多种驱动的耦合,原油价格呈现出多种多样的特征,具体表现在高频和低频分量之间的特性。具体而言,一方面,原油市场作为一种商品市场,其价格的波动在短期内容易受到内部市场机制(如供求机制和风险机制)的影响,因此对原油期货价格的长期趋势影响较小;另一方面,非市场因素,即原油市场的外部环境因素(如政策调整、经济危机和政治形势变化)成为导致原油价格长期波动的原因。

### 2.3 预测结果

本研究采用 VMD-LSTM-ELMAN 作为预测模型,并纳入 SVR, ELM, MLP, LSTM, EL-AMN, VMD-SVR, VMD-ELM, VMD-MLP, VMD-LSTM 和 VMD-ELMAN 进行比较。其中组合预测模型的参数选择采用试错法,具体结果见表 3。可以看出,LSTM 结构的第一层为具有 128 个神经元的 LSTM 层,结构第二层为 64 个神经元的 LSTM 层,最后一层为全连接层,学习率为 0.01,各层的激活函数均采用修正线性单元(Rectified linear unit, ReLU)。ELMAN 神经网络由输入层、包含 16 个单元的隐含层、连接层和

输出层构成,误差容限设置为 0.0005,且 LSTM 与 ELMAN 神经网络的窗口大小都设置为 5。

基于上述参数选择结果,本文构建 LSTM 和 ELMAN 神经网络预测模型,并开展实证分析。

表 3 预测模型的参数选择

Table 3 Parameter selection for the prediction models

模型	参数选择	WTI	国内原油
LSTM	窗口	5	5
	神经元个数 1	128	128
	神经元个数 2	64	64
	激活函数	ReLU	ReLU
	学习率	0.01	0.01
	迭代次数	200	200
ELMAN	Batchsize	64	32
	误差容限	0.0005	0.0005
	窗口	5	5
	神经元个数	16	16
	迭代次数	400	200

采用损失函数 MSE, MAE 和 MAPE 评价模型对原油期货价格的预测准确性,在数值上更具说服力,结果见表 4。VMD-LSTM-ELMAN 模型的 MSE, MAE 和 MAPE 值均小于其他对比模

型(包括单一模型和使用相同预测技术的分解集成模型),WTI 原油价格的 MSE,MAE 和 MAPE 值分别为 1.513 6,1.063 7 和 0.023 2,国内原油价格的 MSE,MAE 和 MAPE 值分别为 6.841 2,2.000 1,0.004 4。为了更直观地展示这些结果,本文绘制了雷达图来比较不同模型在 WTI 原油价格和国内原油价格预测中的 MSE,MAE 和

MAPE 值。图 6-A,B,C 分别表示模型在同一损失函数下,对 WTI 与国内原油数据集的预测表现。具体而言,图中每个轴代表一个预测模型,而轴的长度代表损失函数的大小。由此可见,雷达图清晰地展示了 VMD-LSTM-ELMAN 模型在这些关键指标上的优势,从而证明了其在原油期货价格预测中的有效性。

表 4 三种损失函数下原油价格的预测评价结果

Table 4 Forecasting evaluation results of crude oil prices under three loss functions

模型	WTI			国内原油		
	MSE	MAE	MAPE	MSE	MAE	MAPE
SVR	33.7839	4.6251	0.1141	167.3618	11.4966	0.0255
ELM	11.3248	1.7147	0.0443	141.0589	10.2908	0.0229
MLP	18.4812	1.5209	0.0474	72.0836	6.7694	0.0151
LSTM	15.1632	2.1709	0.0528	74.2380	6.8698	0.0154
ELMAN	31.0505	4.3082	0.0916	76.7156	.9499	0.0155
VMD-SVR	11.6617	2.5003	0.0711	142.6775	10.9189	0.0241
VMD-ELM	6.6960	1.7925	0.0412	68.5694	6.1059	0.0138
VMD-MLP	48.2020	5.4156	0.1382	8.5388	2.6177	0.0059
VMD-LSTM	1.9083	1.0097	0.0251	6.9637	2.0274	0.0044
VMD-ELMAN	26.8179	4.9317	0.0996	8.0219	2.2358	0.0051
MODEL A	1.5136	1.0637	0.0232	6.8412	2.0001	0.0044

说明:MODEL A 表示本文提出的 VMD-LSTM-ELMAN 模型;训练集与测试集比例为 9 : 1。




图 6 原油价格预测模型性能雷达图

Fig. 6 Radar chart of the crude oil price forecasting model performance

与此同时,为进一步比较 VMD-LSTM-ELMAN 模型与对比模型的预测性能,本文基于 MSE,MAE 和 MAPE 损失函数进行 MDM 检验,结果见表 5。对于 WTI 原油期货价格,30 种检验中存在 27 种表明原油期货价格的损失函数在 1%显著性水平下拒绝原假设;对于国内原油价格,所有损失函数都在 1%显著性水平下拒绝原假设。结果表明,本文所提出的 VMD-LSTM-ELMAN 模型与其他相关模型的误差具有统计学显著性,这也表明 VMD-LSTM-ELMAN 模型预测能力优于其他模型。

除了利用 MSE,MAE,MAPE 和 MDM 检验评价模型的预测准确性之外,本文进一步采用线性回归方法分析不同模型的预测能力,参数结果见表 6。在 VMD-LSTM-ELMAN 模型的线性回归结果中,WTI 和国内原油期货价格的斜率  $a$  分别为 0.980 3 和 0.938 9,几乎趋近于 1,截距  $b$  分别为 0.016 2 和 25.550 0,相较于对比模型更加趋近于 0。另外,VMD-LSTM-ELMAN 模型的  $R^2$  计算结果分别为 0.997 9 和 0.994 9,几乎接近 1。上述分析均表明 VMD-LSTM-ELMAN 模型是一种高准确性的原油期货价格预测方法。

表 5 三种损失函数下 MDM 检验结果  
Table 5 MDM test results under three loss functions

模型	MSE	MAE	MAPE
序列 1 WTI			
SVR	-4.0761***	-17.2690***	-24.0646***
ELM	-1.6708*	-5.5537***	-5.6114***
MLP	-1.7404*	-2.5251	-2.8121***
LSTM	-2.0428**	-3.5847***	-8.9271***
ELMAN	-4.9478***	-13.6973***	-23.0769***
VMD-SVR	-9.1154***	-11.7434***	-14.0534***
VMD-ELM	-2.2544**	-8.6496***	-9.9061***
VMD-MLP	-10.3458***	-15.1426***	-24.1752***
VMD-LSTM	-1.3402	-1.1887	2.0417**
VMD-ELMAN	-38.2220***	-34.2308***	-58.1455***
序列 2 国内原油			
SVR	-10.3219***	-14.9765***	-14.9219***
ELM	-7.8009***	-13.8197***	-13.8155***
MLP	-6.3767***	-8.3868***	-8.4739***
LSTM	-6.1616***	-8.5251***	-8.7000***
ELMAN	-6.2918***	-8.0746***	-8.0967***
VMD-SVR	-12.4212***	-21.0627***	-20.4655***
VMD-ELM	-4.9350***	-6.4440***	-6.5733***
VMD-MLP	-1.3508**	-3.2509**	-2.9478**
VMD-LSTM	-1.1953***	-1.2200***	-1.1759***
VMD-ELMAN	-0.7191***	-1.1493***	-0.8837***

说明: \*, \*\*, \*\*\* 分别表示在 10%, 5%, 1% 显著性水平下显著; 训练集与测试集比例为 9 : 1。

表 6 不同模型的线性回归结果  
Table 6 Linear regression results for the different models

模型	WTI			国内原油		
	$R^2$	$a$	$b$	$R^2$	$a$	$b$
SVR	0.9546	0.8437	12.6730	0.7665	0.7752	92.3910
ELM	0.9528	0.9676	2.7370	0.7442	0.5880	180.1600
MLP	0.9198	0.9804	1.6150	0.8383	0.8853	49.5900
LSTM	0.9439	0.9301	1.8600	0.8244	0.7955	91.0620
ELMAN	0.9430	1.0919	-1.0359	0.8378	0.8953	44.2470
VMD-SVR	0.9930	0.8188	11.2400	0.9610	0.8330	63.9400
VMD-ELM	0.9794	0.9916	1.9289	0.8961	0.6891	141.5900
VMD-MLP	0.8353	0.6263	20.5070	0.9949	1.0008	-2.8647
VMD-LSTM	0.9947	0.9771	0.3462	0.9945	0.9392	25.3990
VMD-ELMAN	0.9814	0.8997	0.5514	0.9887	0.9042	43.4560
MODEL A	0.9979	0.9803	0.0162	0.9949	0.9389	25.5500

说明: MODEL A 表示本文提出的 VMD-LSTM-ELMAN 模型; 训练集与测试集比例为 9 : 1。

为了更加直观地比较各个模型的预测效果, 本文将原始原油期货价格序列真实值与不同模型

的预测值绘制在图 7 中。可以发现, 代表原始序列的蓝色粗线与代表 VMD-LSTM-ELMAN 模

型预测值的红色粗线举例最接近,由此可见 VMD-LSTM-ELMAN 模型相较于其他对比模型具有更优秀的拟合程度。

综上所述,无论是通过模型预测值曲线相近程度,还是基于 MSE,MAE,MAPE 与  $R^2$  值进行

比较分析,实证结果均表明相较于 SVR,ELM,MLP,LSTM,ELAMN,VMD-SVR,VMD-ELM,VMD-MLP,VMD-LSTM 和 VMD-ELMAN 模型,本文采用的 VMD-LSTM-ELMAN 模型在预测原油期货价格上具有更高的预测精度与适用性。




图 7 不同模型的预测结果对比图  
Fig. 7 Comparison of the prediction results from different models

### 2.4 稳健性检验

为证明 VMD-LSTM-ELMAN 模型的稳健性,本节选取前 60% 的序列作为训练集,后 40% 的序列作为测试集。该数据划分比例旨在实现两个关键目标:首先,通过保留足够多的数据作为训练集,以确保模型具有充分的数据来学习和捕捉原油时间序列的关键特征和动态。其次,将 40% 的数据保留作为测试集,可以在不同的数据子集上验证模型的预测能力,这有助于评估模型在实

际应用中的泛化能力和稳健性。通过这种方式,可以进一步探索在不同训练集和测试集长度下模型的预测性能。具体的实验结果展示在表 7 中。

WTI 原油价格 MSE、MAE 和 MAPE 值分别为 3.104 1,1.470 5 和 0.025 6,国内原油价格 MSE、MAE 和 MAPE 值分别为 51.166 7,6.792 4 和 0.019 4,表明 VMD-LSTM-ELMAN 模型在 MSE、MAE 和 MAPE 损失函数的计算结果上仍然优于其他对比模型。

表 7 三种损失函数下原油价格的预测评价结果  
Table 7 Forecasting evaluation results of crude oil prices under three loss functions

模型	WTI			国内原油		
	$R^2$	$a$	$b$	$R^2$	$a$	$b$
SVR	22.0775	3.9816	0.0834	233.1061	13.1645	0.0381
ELM	7.5496	1.9763	0.0366	211.8526	11.9897	0.0377
MLP	111.0032	6.0020	0.0898	82.3177	6.9536	0.0205
LSTM	6.1025	1.7434	0.0346	322.7081	15.7782	0.0498
ELMAN	16.5315	2.8990	0.0472	93.2733	7.6332	0.0225
VMD-SVR	14.9853	2.9876	0.0547	301.7507	14.4635	0.0484
VMD-ELM	8.6994	2.5529	0.0456	109.4487	8.6792	0.0272
VMD-MLP	134.2910	9.5805	0.1623	82.5792	8.1742	0.0252
VMD-LSTM	3.5375	1.6091	0.0286	52.8363	6.9152	0.0198
VMD-ELMAN	33.5395	5.5185	0.0978	86.6116	7.4917	0.0251
MODEL A	3.1041	1.4705	0.0256	51.1667	6.7924	0.0194

说明:MODEL A 表示本文提出的 VMD-LSTM-ELMAN 模型;训练集与测试集比例为 6 : 4。

测试集中的 MDM 检验结果如表 8 所示。对于 WTI 原油期货价格,所有损失函数都在 1% 显著性水平下拒绝原假设;对于国内原油价格,30 种检

验中存在 28 种表明原油期货价格的损失函数在 1% 显著性水平下拒绝原假设。结果同样表明 VMD-LSTM-ELMAN 模型的预测优势是显而易见的。

表 8 三种损失函数下 MDM 检验结果  
Table 8 MDM test results under three loss functions

模型	MSE	MAE	MAPE
序列 1 WTI			
SVR	-9.5466***	-36.2691***	-45.0591***
ELM	-3.0191***	-10.9645***	-12.9418***
MLP	-19.8438***	-20.6543***	-25.1442***
LSTM	-2.0129**	-6.2607***	-7.2165***
ELMAN	-9.2494***	-15.3490***	-25.7296***
VMD-SVR	-24.9753***	-24.6028***	-28.5610***
VMD-ELM	-9.4642***	-31.2994***	-36.3925***
VMD-MLP	-41.0746***	-61.7939***	-59.4082***
VMD-LSTM	-21.6308***	-27.8065***	-38.9597***
VMD-ELMAN	-71.8211***	-79.1478***	-93.8705***
序列 2 国内原油			
SVR	-13.3046***	-15.7306***	-15.6318***
ELM	-10.3837***	-10.8837***	-10.5506***
MLP	-4.1143***	-1.0806	-0.4873
LSTM	-14.9329***	-17.0657***	-17.8916***
ELMAN	-5.8603***	-3.1270***	-2.4990**
VMD-SVR	-13.8954***	-13.3976***	-12.9495***
VMD-ELM	-8.1959***	-7.0348***	-5.2681***
VMD-MLP	-6.5833***	-5.9020***	-4.8226***
VMD-LSTM	-11.0691***	-13.5565***	-12.9341***
VMD-ELMAN	-5.4000***	-4.4904***	-1.8379***

说明:\*, \*\*, \*\*\* 分别表示在 10%, 5%, 1% 显著性水平下显著; 训练集与测试集比例为 6 : 4。

线性回归参数结果如表 9 所示。从表中可知, WTI 和国内原油期货价格的斜率  $a$  分别为 0.966 3 和 0.982 1, 几乎趋近于 1; 截距  $b$  分别为 2.998 0 和 -0.508 7, 几乎趋近于 0;  $R^2$  值分

别为 0.995 7 和 0.999 4, 几乎接近 1, 表明本文采用的 VMD-LSTM-ELMAN 模型适用于原油期货价格序列的预测, 并且较对比模型具有明显的优势。

表 9 不同模型的线性回归结果  
Table 9 Linear regression results of the different models

模型	WTI			国内原油		
	$R^2$	$a$	$b$	$R^2$	$a$	$b$
SVR	0.9900	0.9146	9.1208	0.9837	0.9734	-2.3736
ELM	0.9879	0.9220	5.4450	0.9820	0.9111	39.9940
MLP	0.8475	0.5741	23.1710	0.9865	1.0070	-3.4069
LSTM	0.9907	0.9436	4.5043	0.9870	1.0651	-37.4180
ELMAN	0.9880	1.1185	-5.2256	0.9845	0.9642	13.2130
VMD-SVR	0.9978	0.8173	11.3130	0.9958	0.8100	75.4230
VMD-ELM	0.9906	0.9084	6.9015	0.9901	1.0692	-28.1220
VMD-MLP	0.8720	1.1029	-13.5640	0.9948	0.9011	35.4520
VMD-LSTM	0.9957	0.9660	3.2136	0.9994	0.9820	-0.5782
VMD-ELMAN	0.9906	1.0035	5.2365	0.9968	0.9031	38.0800
MODEL A	0.9957	0.9663	2.9980	0.9994	0.9821	-0.5087

说明: MODEL A 表示本文提出的 VMD-LSTM-ELMAN 模型; 训练集与测试集比例为 6 : 4。

除此之外,鉴于 Brent 原油作为全球原油市场中最主要的基准之一,本文采用相同样本区间的 Brent 原油价格作为替代指标,以代替先前使用的 WTI 原油价格,从而进一步验证本文提出的 VMD-LSTM-ELMAN 模型在不同原油市场环境下的泛化能力。

在进行这一调整后,本文使用与 WTI 原油相同的方法论和参数设置,以确保结果具有可

比性。测试集中的 MDM 检验结果如表 10 所示。对于 Brent 原油期货价格,30 种检验中有 27 种检验的结果在 1%显著性水平下拒绝原假设,进一步凸显了 VMD-LSTM-ELMAN 模型在预测原油价格方面的显著优势,不仅增强了 VMD-LSTM-ELMAN 模型在不同原油市场条件下的可信度,也为未来在其他原油市场的应用奠定了基础。

表 10 三种损失函数下 MDM 检验结果(Brent 原油)  
Table 10 MDM test results under three loss functions (Brent crude oil)

模型	MSE	MAE	MAPE
SVR	-23.7806***	-53.2575***	-32.3831***
ELM	-9.1217***	-21.7375***	-16.6403***
MLP	-9.0921***	-19.4193***	-15.2183***
LSTM	-5.7815***	-14.3739***	-10.5855***
ELMAN	-11.0951***	-23.0404***	-18.6159***
VMD-SVR	-19.5069***	-29.0288***	-21.9111***
VMD-ELM	-11.3513***	-21.2777***	-13.4464***
VMD-MLP	-17.2798***	-21.2695***	-20.0055***
VMD-LSTM	-1.1600	-0.3212	-0.6987
VMD-ELMAN	-11.3513***	-21.2777***	-13.4464***

说明:\*,\*\*,\*\*\* 分别表示在 10%,5%,1%显著性水平下显著。

综上所述,本研究在稳健性检验环节中对数据集进行了多样化的调整,包括改变数据划分比例和使用不同的数据集。实证研究结果一致表明,本文采用的 VMD-LSTM-ELMAN 模型表现均优于其他对比模型,不仅凸显了该模型在处理多变数据时的适应能力,也证实了其在面对不同市场情况和数据特性时的出色稳健性。

### 3 结论及对策建议

原油期货价格的波动会影响人们的生活,甚至阻碍国民经济的发展,因此提升原油期货价格预测的准确性在全球金融市场中具有举足轻重的作用。本研究的主要贡献是结合数据分解方法和人工智能预测模型,建立一种新型原油期货价格混合预测模型,以实现更准确的原油期货价格预测。本文主要从以下三方面集中对 WTI 原油期货价格和国内原油期货价格进行实证分析:(1)相较于其他单一模型和使用相同预测技术的分解集成模型,VMD-LSTM-ELMAN 模型对于 WTI 原油价格和国内原油价格预测的 MSE,MAE 和 MAPE 值分别为(1.513 6,6.841 2),(1.513 6,

2.000 1)和(0.023 2,0.004 4),WTI 和国内原油期货价格预测值的  $R^2$  值分别达到了 0.997 9 和 0.994 9。上述损失函数的值在所有模型中最小,且  $R^2$  值最接近于 1,凸显出 VMD-LSTM-ELMAN 方法的良好性能。(2)进一步地采用线性回归分析来验证模型的适用性。分析结果显示,WTI 原油和国内原油数据集的斜率  $a$  和截距  $b$  分别为(0.980 3,0.016 2)和(0.938 9,25.550 0),趋近于 1 和 0,表明本文采用的模型适用于原油期货价格序列的预测。(3)本文还引入 MDM 检验以比较 VMD-LSTM-ELMAN 模型与其他模型在预测能力方面的差异。检验结果表明,在大多数情况下,两类原油市场期货价格的损失函数在 1%显著性水平下拒绝原假设,证明了 VMD-LSTM-ELMAN 模型比其他模型具有更强的预测能力。最后,本文通过稳健性检验再次验证了 VMD-LSTM-ELMAN 模型在不同训练集长度下和不同原油市场的预测优越性。

基于以上结论,利用 VMD-LSTM-ELMAN 模型准确预测原油期货价格不仅有利于个体参与者和相应公司规避关联交易风险,而且有利于政

府部门对原油相关产品的贸易进行监管和宏观调控。综上所述,本文进一步为政府部门制定政策、减少环境污染以及调整世界经济格局等方面提供了思路。

### [ 参 考 文 献 ]

- 包湘海,李思敏,顾海兵,2014. 国际原油价格长期趋势预测——基于周期分析的视角[J]. 价格理论与实践, (12):59-62.
- Bao X H, Li S M, Gu H B, 2014. The Prediction of International Oil Prices Based on the cycle Perspective[J]. Price Theory & Practice, (12):59-62. (in Chinese)
- 刘岭,王聚杰,李建平,2022. 融合新闻影响力衰减的国际原油价格预测研究[J]. 系统工程理论与实践, 42(10):2710-2720.
- Liu L, Wang J J, Li J P, 2022. International crude oil price forecasting with news influence index attenuation[J]. Systems Engineering - Theory & Practice, 42(10):2710-2720. (in Chinese)
- 任泽平,2012. 能源价格波动对中国物价水平的潜在与实际影响[J]. 经济研究, 47(8):59-69.
- Ren Z P, 2012. The Potential and Actual Impact of Energy Price Increase to General Price Level in China[J]. Economic Research Journal, 47(8):59-69. (in Chinese)
- 唐小我,1992. 最优组合预测方法及其应用[J]. 数理统计与管理, (1):31-35.
- 王德运,陈奕青,耿亮,2022. 基于模态分解与误差修正策略的原油价格组合预测研究[J]. 南昌工程学院学报, 41(1):22-31.
- Wang D Y, Chen Y Q, Geng L, 2022. A novel hybrid model based on mode decomposition and error compensation strategy for crude oil price forecasting[J]. Journal of Nanchang Institute of Technology, 41(1):22-31. (in Chinese)
- 熊熊,李璇,2016. 国际原油价格预测研究[J]. 重庆理工大学学报(自然科学版), 30(1):48-53.
- Xiong X, Li X, 2016. Prediction of International Crude Oil Price[J]. Journal of Chongqing University of Technology (Natural Science), 30(1):48-53. (in Chinese)
- 徐凌,黎佳卉,李亮,2013. ARIMA 模型在国际原油价格预测中的应用[J]. 河南科学, 31(5):692-695.
- Xu L, Li J H, Li L, 2013. Application of Arima Models in Forecasting Crude Oil Prices[J]. Henan Science, 31(5):692-695. (in Chinese)
- 杨云飞,鲍玉昆,胡忠义,等,2010. 基于 EMD 和 SVMs 的原油价格预测方法[J]. 管理学报, 7(12):1884-1889.
- Yang Y F, Bao Y K, Hu Z Y, *et al.*, 2010. Crude Oil Price Prediction based on Empirical Mode Decomposition and Support Vector Machines[J]. Chinese Journal of Management, 7(12):1884-1889. (in Chinese)
- 余乐安,雷凯宇,2023. 基于模式匹配与深度学习的国际油价预测研究[J]. 中国石油大学学报(社会科学版), 39(5):51-59.
- Yu L A, Lei K Y, 2023. International Oil Price Prediction Based on Pattern Matching and Deep Learning[J]. Journal of China University of Petroleum (Edition of Social Sciences), 39(5):51-59. (in Chinese)
- 张金良,李德智,谭忠富,2019. 基于混合模型的国际原油价格预测研究[J]. 北京理工大学学报(社会科学版), 21(1):59-64.
- Zhang J L, Li D Z, Tan Z F, 2019. International Crude Oil Price Forecasting based on a Hybrid Model[J]. Journal of Beijing Institute of Technology (Social Sciences Edition), 21(1):59-64. (in Chinese)
- 张金良,谭忠富,2013. 基于混合模型的原油价格混沌预测方法[J]. 运筹与管理, 22(5):166-172.
- Zhang J L, Tan Z F, 2013. Crude Oil Price Chaotic Forecasting Method Based on Hybrid Model[J]. Operations Research and Management Science, 22(5):166-172. (in Chinese)
- 张跃军,2020. 国际油价暴跌对宏观经济的影响及对策研究[J]. 中国地质大学学报(社会科学版), 20(2):153-156.
- Zhang Y J, 2020. The Impact of International Crude Oil Price Crash on Macroeconomy and Policy Suggestions [J]. Journal of China University of Geosciences (Social Sciences Edition), 20(2):153-156. (in Chinese)
- Adhikari R, Agrawal R K, 2014. A combination of artificial neural network and random walk models for financial time series forecasting[J]. Neural Computing and Applications, 24(6):1441-1449.
- Abdoos A A, 2016. A new intelligent method based on combination of VMD and ELM for short-term wind power forecasting [J]. Neurocomputing, 203:111-120.
- An Y F, Zhai X Q, 2020. SVR-DEA model of carbon tax pricing for China's thermal power industry[J]. The Science of the Total Environment, 734:139438.
- Arjun S S, Subarna S, 2020. Analysis of look back period for stock price prediction with RNN variants: A case study on banking sector of NEPSE [J]. Procedia

- Computer Science, 167:788–798.
- Bengio Y, Simard P, Frasconi P, 1994. Learning long-term dependencies with gradient descent is difficult[J]. IEEE Transactions on Neural Networks, 5(2):157–166.
- Cao J, Li Z, Li J, 2019. Financial time series forecasting model based on CEEMDAN and LSTM[J]. Physica A: Statistical Mechanics and its Applications, 519:127–139.
- Dragomiretskiy K, Zosso D, 2014. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 62(3):531–544.
- Guresen E, Kayakutlu G, Daim T U, 2011. Using artificial neural network models in stock market index prediction[J]. Expert Systems with Applications, 38(8):10389–10397.
- Huang Y M, Dai X Y, Wang Q W, *et al.*, 2021. A hybrid model for carbon price forecasting using GARCH and long short-term memory network[J]. Applied Energy, 285:116485.
- Huang Y S, Deng Y, 2021. A new crude oil price forecasting model based on variational mode decomposition [J]. Knowledge-Based Systems, 213:106669.
- Hestenes M R, 1969. Multiplier and gradient methods[J]. Journal of Optimization Theory and Applications, 4(5):303–320.
- Hochreiter S, Schmidhuber J, 1997. Long short-term memory[J]. Neural Computation, 9(8):1735–1780.
- Jammazi R, Aloui C, 2012. Crude oil price forecasting: Experimental evidence from wavelet decomposition and neural network modeling[J]. Energy Economics, 34(3):828–841.
- Kazem A, Sharifi E, Hussain F K, *et al.*, 2013. Support vector regression with chaos-based firefly algorithm for stock market price forecasting[J]. Applied Soft Computing, 13(2):947–958.
- Khashei M, Bijari M, 2014. Fuzzy artificial neural network model for incomplete financial time series forecasting [J]. Journal of Intelligent & Fuzzy Systems, 26(2):831–845.
- Kilian L, Vigfusson R J, 2011. Nonlinearities in the oil price-output relationship[J]. Macroeconomic Dynamics, 15(S3):337–363.
- Lin T, Horne B G, Giles C L, 1998. How embedded memory in recurrent neural network architectures helps learning long-term temporal dependencies[J]. Neural Network, 11(5):861–868.
- Li P H, Li Y G, Xiong Q Y, *et al.*, 2014. Application of a hybrid quantized ELMAN neural network in short-term load forecasting[J]. International Journal of Electrical Power and Energy Systems, 55:749–759.
- Li C, Tao Y, Ao W G, *et al.*, 2018. Improving forecasting accuracy of daily enterprise electricity consumption using a random forest based on ensemble empirical mode decomposition[J]. Energy, 165:1220–1227.
- Lin Y, Chen K C, Zhang X, *et al.*, 2022. Forecasting crude oil futures prices using BiLSTM-Attention-CNN model with Wavelet transform[J]. Applied Soft Computing, 130:109723.
- Li X Y, Zhang L, Wang Z P, *et al.*, 2019. Remaining useful life prediction for lithiumion batteries based on a hybrid model combining the long short-term memory and ELMAN neural networks[J]. Journal of Energy Storage, 21:510–518.
- Liu Y S, Yang C H, Huang K K, *et al.*, 2020. Non-ferrous metals price forecasting based on variational mode decomposition and LSTM network [J]. Knowledge-Based Systems, 188:105006.
- Potts T B, Yergler D B, 2016. Marcellus Shale and structural breaks in oil and gas markets: The case of Pennsylvania[J]. Energy Economics, 57:50–58.
- Rumelhart D E, Hinton G E, Williams R J, 1986. Learning representations by back-propagation errors[J]. Nature, 323(6088):533–536.
- Steve O, 2010. Modeling global and local dependence in a pair of commodity forward curves with an application to the US natural gas and heating oil markets[J]. Energy Economics, 32(2):373–388.
- Sinvaldo R M, Ramon Gomes da S, Viviana C M, *et al.*, 2020. Multi-step wind speed forecasting based on hybrid multi-stage decomposition model and long short-term memory neural network[J]. Energy Conversion and Management, 213:112869.
- Sun W, Huang C C, 2020. A novel carbon price prediction model combines the secondary decomposition algorithm and the long short-term memory network[J]. Energy, 207:118294.
- Wang D Y, Luo H Y, Grunder O, *et al.*, 2017. Multi-step ahead electricity price forecasting using a hybrid model based on two-layer decomposition technique and BP neural network optimized by firefly algorithm [J]. Applied Energy, 190:390–407.
- Wang J, 2017. Forecasting stochastic neural network based on financial empirical mode decomposition[J]. Neural

- Networks,90;8—20.
- Wang J, Li X, 2018. A combined neural network model for commodity price forecasting with SSA[J]. *Soft Computing*, 22(16):5323—5333.
- Wu Y X, Wu Q B, Zhu J Q, 2019. Improved EEMD-based crude oil price forecasting using LSTM networks[J]. *Physica A: Statistical Mechanics and its Applications*, 516:114—124.
- Yu L A, Wang S Y, Lai K K, 2008. Forecasting crude oil price with an EMD-based neural network ensemble learning paradigm [J]. *Energy Economics*, 30 (5): 2623—2635.
- Yin H, Dong Z, Chen Y L, *et al.*, 2017. An effective secondary decomposition approach for wind power forecasting using extreme learning machine trained by crisscross optimization [J]. *Energy Conversion and Management*, 150(1):108—121.
- Zhu Q, Zhang F, Liu S, *et al.*, 2019. A hybrid VMD-BiGRU model for rubber futures time series forecasting [J]. *Applied Soft Computing*, 84:105739.
- Zhang L H, Wang J, Wang B, 2020. Energy market prediction with novel long short-term memory network: Case study of energy futures index volatility [J]. *Energy*, 211:118634.
- Zhang X, Yang K, Lu Q, *et al.*, 2023. Predicting carbon futures prices based on a new hybrid machine learning: Comparative study of carbon prices in different periods [J]. *Journal of Environmental Management*, 346:118962.
- Zhao Z L, Sun S L, Sun J Y, *et al.*, 2024. A novel hybrid model with two-layer multivariate decomposition for crude oil price forecasting [J]. *Energy*, 288:129740.

(责任编辑:甘娟娟)

## 期 刊 简 介

《成都理工大学学报(自然科学版)》创办于1960年,原名《成都地质学院学报》(1960~1993年)、《成都理工学院学报》(1994~2002年),2003年更名为《成都理工大学学报(自然科学版)》。现今为双月刊,国内外公开发行。

本刊刊登的主要内容有:油气地质与勘探、矿产地质与勘探、地质工程与灾害防治,兼顾地球探测与信息技术、环境科学与工程、矿物材料科学与工程,及其它地球科学的理工类学科。

收录本刊全部或部分论文的科技文摘期刊和数据库主要有:(1)中国科学引文数据库(CSCD);(2)中国科技期刊引证报告;(3)中国学术期刊综合评价数据库;(4)中文科技期刊数据库;(5)中国地质文摘;(6)中国石油文摘;(7)古生物学文摘;(8)PЖ;(9)SCOPUS;(10)JST;(11)Chemical Abstracts;(12)Petroleum Abstracts;(13)Bibliography and Index of Geology等等。