

分类号 _____
UDC _____

密级 公开
编号 10741

兰州财经大学

LANZHOU UNIVERSITY OF FINANCE AND ECONOMICS

硕士学位论文

(专业学位)

论文题目：基于多尺度分解的原油价格预测研究

研究生姓名：胡羽琪

指导教师姓名、职称：郭精军、教授

学科、专业名称：统计学、应用统计

研究方向：大数据分析及应用

提交日期：2024年6月5日

独创性声明

本人声明所呈交的论文是我个人在导师指导下进行的研究工作及取得的研究成果。尽我所知，除了文中特别加以标注和致谢的地方外，论文中不包含其他人已经发表或撰写过的研究成果。与我一同工作的同志对本研究所做的任何贡献均已在论文中作了明确的说明并表示了谢意。

学位论文作者签名： 胡羽璞 签字日期： 2024.6.3

导师签名： 郭咏梅 签字日期： 2024.6.3

导师(校外)签名： _____ 签字日期： _____

关于论文使用授权的说明

本人完全了解学校关于保留、使用学位论文的各项规定， 同意（选择“同意” / “不同意”）以下事项：

1. 学校有权保留本论文的复印件和磁盘，允许论文被查阅和借阅，可以采用影印、缩印或扫描等复制手段保存、汇编学位论文；

2. 学校有权将本人的学位论文提交至清华大学“中国学术期刊（光盘版）电子杂志社”用于出版和编入CNKI《中国知识资源总库》或其他同类数据库，传播本学位论文的全部或部分内容。

学位论文作者签名： 胡羽璞 签字日期： 2024.6.3

导师签名： 郭咏梅 签字日期： 2024.6.3

导师(校外)签名： _____ 签字日期： _____

Prediction of Crude Oil Prices using Multi-scale Decomposition

Candidate: Yuqi Hu

Supervisor: Jingjun Guo

摘要

原油是当今社会工业发展和日常生活中的重要能源资源，对全球经济和世界金融市场有着举足轻重的作用，国际原油价格的波动也受到多种因素的影响，准确预测国际原油价格波动已成为如今的研究热点。

本文基于对多模态分解和混合深度神经网络模型的研究，提出了一种多尺度分解-集成框架下的原油价格预测模型。具体而言，首先使用经验模态分解模型（EMD）分解原油价格序列，并通过多模态分量特征重构出三类序列（低频分量、高频分量和趋势分量），其次通过基于随机森林构建的递归特征选择法（RF-RFE）分别对三类序列选择最优特征子集，然后使用双向长短期记忆神经网络（BiLSTM）与卷积神经网络（CNN）融合的混合模型（BiLSTM-CNN）拟合三类序列变化趋势，最后集成获得原油价格序列预测结果。

为了验证模型的性能，采用世界原油市场上的三大基准价格之一的美国西德克萨斯的中质原油（WTI）每日现货价格验证模型性能，通过从评价指标（MAE、RMSE、MAPE 和 R^2 Score）和预测曲线两个角度，与四类对比模型（LSTM、LSTM-CNN、LSTM-DNN、BiLSTM-CNN）比较结果显示，所提出的模型能够有效提升预测精度。

为了拓展模型的泛用性，提升模型对突发事件冲击下的原油价格预测精度，使用特征迁移学习对模型再训练，使用突发公共卫生安全事件——新冠疫情对原油价格影响为例，验证了迁移模型的拟合精度和有效性；为了拓展模型的应用范围，将模型对原油价格序列的预测结果作为特征加入不同预测任务，以原油期货价格和新能源市场指数预测为例，验证了合理性和预测精度提升。

本文提出一种集成框架下的混合深度学习国际原油价格预测模型，通过融合 EMD 分解集成框架和混合神经网络模型，提高国际油价预测模型精度；同时，提出迁移学习提高模型处理突发事件泛用性和时效性，旨在降低预测成本，为国内市场提供预测参考。

关键词：经验模态分解模型、长短期记忆神经网络、迁移学习、原油价格预测

Abstract

Crude oil is an important energy resource in industrial development and daily life in today's society. It plays a crucial role in the global economy and financial markets, and the fluctuation of international crude oil prices is also influenced by various factors. Accurately predicting international crude oil price fluctuations has become a research hotspot today.

This thesis proposes a crude oil price prediction model based on the study of multimodal decomposition and mixed deep neural network models under a multi-scale decomposition integration framework. Specifically, the empirical mode decomposition (EMD) model is first used to decompose the crude oil price series, and three types of sequences (low-frequency, high-frequency, and trend components) are reconstructed through multimodal component features. Then, the recursive feature selection method based on random forest construction (RF-RFE) is used to select the optimal feature subsets for each of the three types of sequences. Then, a hybrid model (BiLSTM-CNN) fused with bidirectional long short-term memory neural network (BiLSTM) and convolutional neural network (CNN) is used to fit the changing trends of the three types of sequences. Finally, the prediction results of the crude oil price series are integrated and obtained.

To verify the performance of the model, the daily spot price of WTI crude oil from West Texas, one of the three benchmark prices in the world

crude oil market, was used to verify the performance of the model. From the perspectives of evaluation indicators (MAE, RMSE, MAPE, and R^2 Score) and prediction curves, the proposed model was compared with four types of comparative models (LSTM, LSTM-CNN, LSTM-DNN, BiLSTM-CNN), and the results showed that it can effectively improve prediction accuracy.

In order to expand the universality of the model and improve the prediction accuracy of the model for crude oil prices under the impact of emergencies, the model was retrained using feature transfer learning, and the impact of public health and security emergencies - COVID-19 epidemic on crude oil prices was used as an example to verify the fitting accuracy and effectiveness of the migration model; In order to expand the application scope of the model, the prediction results of the crude oil price series were added as features to different prediction tasks. Taking crude oil futures prices and new energy market index prediction as examples, the rationality and prediction accuracy were verified.

This thesis proposes a hybrid deep learning international crude oil price prediction model under an integrated framework, which improves the accuracy of the international oil price prediction model by integrating the EMD decomposition integration framework and the hybrid neural network model; At the same time, transfer learning is proposed to improve the universality and timeliness of the model in handling unexpected events,

aiming to reduce prediction costs and provide prediction references for the domestic market.

Keywords: Empirical mode decomposition model; Long short term memory neural network; Transfer learning; Crude oil price prediction

目 录

摘 要	I
Abstract	II
1 引 言	1
1.1 研究背景	1
1.2 研究意义	4
1.3 研究现状	4
1.3.1 国际原油价格影响因素相关研究	4
1.3.2 国际原油价格预测方法相关研究	7
1.3.3 文献述评	10
1.4 研究内容及方法	10
1.4.1 研究内容	11
1.4.2 研究方法	11
1.5 研究创新点	12
1.6 技术路线图	13
1.7 结构安排	14
2 国际原油价格波动影响因素分析	15
2.1 供应需求关系	15
2.1.1 原油供给与需求	15
2.1.2 原油库存	18
2.2 经济金融因素	19
2.2.1 宏观经济因素	19
2.2.2 金融市场因素	20
2.3 经济政策不确定性因素	22
2.4 地缘政治因素	23
2.5 国际原油价格波动影响因素筛选	25
3 国际原油价格预测模型	28

3.1 基础模型理论.....	28
3.1.1 基于随机森林的递归特征选择法.....	28
3.1.2 迁移学习.....	30
3.1.3 双向长短期记忆神经网络.....	30
3.1.4 卷积神经网络.....	32
3.1.5 混合深度学习模型.....	34
3.1.6 经验模态分解模型.....	35
3.2 EBC 模型设计.....	36
3.2.1 EBC 模型结构.....	36
3.2.2 EBC 模型预测流程.....	37
4 国际原油价格预测模型实证.....	38
4.1 国际原价格预测实验设计.....	38
4.1.1 国际原油价格预测实验思路设计.....	38
4.1.2 国际原油价格预测模型评价指标.....	38
4.2 国际原油价格预测实验过程.....	40
4.2.1 数据预处理.....	40
4.2.2 EMD 分解重构.....	40
4.2.3 基于不同分量的特征选择.....	43
4.2.4 基于不同分量的 BiLSTM-CNN 训练.....	45
4.2.5 分量集成重构.....	47
4.3 国际原油价格预测结果分析.....	47
4.4 构建基于特征迁移的国际油价模型.....	49
4.5 WTI 原油现货价格预测值的应用.....	51
4.5.1 WTI 原油期货价格预测.....	51
4.5.2 新能源市场指数预测.....	53
5 研究总结与展望.....	55
5.1 总结.....	55
5.2 展望.....	55
参考文献.....	57

硕士期间研究成果	61
致 谢	62

1 引言

原油为一次性能源，自 18 世纪以来随着大量开采，渐渐取代煤炭成为工业发展以及日常生活中的能源，在世界各国的经济发展中起着举足轻重的作用，如何精确预测原油价格变动趋势也成为了近几年的研究重点。同时国际原油价格的波动也受到多种因素的影响，金融因素、政治因素和供需因素等均会对国际原油价格的变动产生极其重要的影响，同时原油与国际经济也呈现出相互制约相互促进的现象，因原油与多种因素之间复杂的因果关系，预测原油价格的变动趋势成为了研究难点。

1.1 研究背景

原油市场是全球经济和金融市场中的重要组成部分，其价格的波动会对全球经济产生重大影响。作为“工业血液”，石油资源在国民经济和社会生活中有着举足轻重的地位。自 1852 年依格纳茨·卢卡西维茨发现能从石油中更简便地提取煤油后，现代社会开始尝试开采石油资源。1859 年美国人艾德温·德雷克利用蒸汽动力采用机械化技术手段开采石油揭开了现代石油产业发展的序幕，他也成为世界石油工业的开创者。自此，石油开始全面广泛地作为照明原料用于人类生活，开启了现代石油工业发展序幕。随着时间的推移，石油工业开始退出照明原料市场，就在石油工业发展受到威胁时，第二次工业革命的另一项重要成就，内燃机的发明和创新却成就了石油成为人类社会经济发展和社会生活中不可或缺的基础性能源地位。同时，内燃机也借助石油高效轻便的动力能源优势成为稳定的动力输出单元被广泛使用。由此，石油开始全面地渗透社会生活、经济生产和军事等各个领域，成为“世界能源之王”，为人类社会带来巨大财富和繁荣发展，石油工业也成为世界经济发展的重要内容。两次世界大战的爆发更是凸显出石油重要的战略价值，在具备普通商品的基本属性外，石油确定了作为国家战略实力因素之一的重要地位，与国家政治、军事和外交战略紧密相连，成为各国在全球范围内利益博弈和竞相争夺的焦点。

原油被称为“工业血液”，原油价格的变动和世界经济发展息息相关，每当国际原油价格上升十分之一，整个世界的 GDP 就会下降 0.3%。原油价格的下跌

能够从一定程度上促进非 OPEC 国家的经济发展 (Lee et al., 1995), 原油价格的上升能延缓非 OPEC 国家的经济发展速度。Ito 等人 (2012) 自回归模型对伊朗的国内宏观经济状况与国际油价的变化作了详细的分析, 结果发现由于伊朗是主要产油国, 当国际油价下降的时候, 伊朗国内的失业率也在上升, 并且国内 GDP 出现下跌。吴力波等 (2008) 协整模型, 对当今世界上中国、美国等超级大国的国内宏观经济状况和国际油价的变动之间的关系进行了深入的探讨, 结果发现, 国际原油价格的变动对这些国家国内的实体经济的发展有着不小的冲击作用。李治国等 (2013) 自回归模型对我国国内的宏观经济的发展与国际原油价格变动之间的关联展开了深入细致的研究, 结论表明, 原油价格的波动对我国的通货膨胀程度有着密切的影响, 国际原油价格的上升抬升了国内物价水平, 我国的原油进口量明显下降, 更多依赖于国内原油生产。

原油价格的变动不仅仅影响着各国经济, 世界各国的经济发展对原油也有着强烈的反作用。OPEC 国家和非 OPEC 国家之间的政治、经济往往会对国际原油价格的变动产生深远的影响, 从而影响世界各国的经济发展。世界第二大经济体和世界第一大工业国, 对原油的需求不言而喻, 我国已成为世界各国中原油对外依存度最大的国家。国际原油价格的变动在很大程度上影响着我国工业发展的成本, 同时油价的变动加大了我国政府的财政支出, 也使得人们日常出行成本变大, 抑制了我国 GDP 的发展速度, 并且由于各行业的成本变大导致我国物价出现了不同程度地上涨, 影射到我国社会发展的方方面面, 因此对于国际原油价格的变动因素分析及原油价格的预测显得至关重要, 对我国社会经济发展有着重要意义。

然而, 由于原油能源行业发展的特殊性, 原油价格的波动往往受到多种因素的制约, 金融因素、政治因素和供需因素等均会对国际原油价格的变动产生极其重要的影响, 甚至一些突发的极端情况也同样会对原油价格产生深远影响, 如 2004 年的伊拉克战争, 伊拉克作为全球主要原油输出国, 战争爆发导致之后的几年中国际原油价格急剧提升, 从 2004 年以前的每桶 40 美元左右的原油价格提升到每桶 150 美元的价格, 涨幅接近四倍。但在 2008 年经过由美国引发的全球性金融危机后, 全球经济发展停滞并陷入困境, 之前由伊拉克战争造成的高昂油价开始一路走低, 直到油价下跌至伊拉克战争之前的状态。在之后的几

年中，随着中东地区战争的不断爆发以及各大国在石油市场的竞争，油价不停的处于涨跌状态。2015 年左右，美国国内加大了页岩气的开采力度，作为石油的替代品，页岩气储量的增多使得国际原油价格得到了进一步的下降并于 2016 年左右降至每桶 30 美元的水准。由于原油属于一次性能源，OPEC 国家和非 OPEC 产油国为了自身长久的利益于 2017 年达成协议，决定减少石油的产量以此达成稳定油价和维护自身利益的目的，在减产协议达成后，国际原油价格由于供应量减少导致原油价格获得上升直至稳定在 70 美元左右。根据 Bernabe 等人（2004）研究可知地缘政治冲突和自然灾害均会对原油价格波动产生影响，因此为了建立准确的价格预测模型，必须正确确定预测目标即原油价格波动的影响因素和影响价格变动的经济结构。周怡洁（2022）使用时变参数向量自回归动态溢出指数模型将国际油价、中美股市和地缘政治风险纳入同一框架进行评估，结果发现地缘政治风险作为整个系统的信息发出者，中美股市和国际油价有着时变且非对称的溢出效应，尤其在全球宏观经济下行时期，溢出效应加强，地缘政治风险对中美股市和国际油价的冲击进一步提升。

美国作为全球石油在能源消费和能源供应方面最重要的参与者之一，是世界第二大原油进口国和第四大原油出口国，美原油（WTI）和布伦特原油均属于全球原油定价的基准之一，而 WTI 又因其良好的流动性和高度透明度报价成为了全球商品期货成交的龙头，自 2005 年以来美国的能源出口总额一直在增加，并在 2019 年达到峰值，使美国成为能源净出口国。因此美国经济影响着全球油价动态，美国经济的变化、消息和冲击都会立即影响全球油价动态，大多数情况下，这类变动由宏观经济和金融因素共同驱动，反映在原油市场的供给需求程度，从而影响投资行为。Zhang 等人（2021）提出投资者主要关注美联储利率、工业生产或失业率等宏观经济因素的变化以调整投资行为，同时这些投资行为也将作为驱动指标决定着 WTI 原油期货未来合约的数量和价格。另一方面由于美国经济、原油精炼成本和石油生产水平等因素决定了原油供应水平，从而决定了 WTI 价格动态，并且全球事件、战争和自然灾害等均会对油价动态产生重要影响。

1.2 研究意义

原油作为当今社会最重要的能源原料之一，对全球经济发展和国民生活影响深远。随着我国经济持续快速发展和城市化进程的推进，石油的需求持续保持稳定增长态势，国内原油生产能力无法满足经济社会发展对油气资源的需求，我国成为了世界第二大石油消费国，准确地判断预测原油价格未来走势，识别影响国际原油价格因素，建立国际原油价格预测模型是至关重要的。

从实际意义来看，原油价格与世界经济发展相互制约相互促进的作用。国内社会生活的方方面面均与原油价格存在着密不可分的联系，如何准确预测原油价格并有效解释原油价格影响因素显得极为重要。原油价格预测存在着巨大的困难。因原油行业的特殊性，原油价格波动受到多种因素影响，表现为预测存在着非线性、不确定性和动态性等多种特性，这使得预测变得困难。原油价格预测的不准确将会导致诸多经济社会问题。预测结果的不确定性会对相关投资者的收益和经济体系的稳定发展造成严重的不确定性，对经济发展将产生长远的不良影响。

从理论意义来看，本文从国际原油价格影响因子出发，从供应需求关系、经济金融因素、经济政策不确定性因素和地缘政治因素四个方面建立了原油价格特征集，对原油市场的波动和解构提出了数据支持。同时本文构建了混合深度学习模型与分解集成预测框架融合的国际原油价格预测模型，有效提升了原油价格预测的准确性。

1.3 研究现状

原油价格预测问题的研究方向可大致分为两类，分别为对国际原油价格影响因素和对预测模型的研究，本文将从以上两个方向着手对现有国际原油价格研究进行总结论述，并以此为依据为后文的研究方法和研究内容提供支持。

1.3.1 国际原油价格影响因素相关研究

石油是工业生产的重要原料，也是不可再生的化石燃料原料，国际石油市场已从石油输出国等组织主导的垄断定价逐步过渡到市场化，自 20 世纪 70 年

代第一次石油危机以来，原油价格一直保持着波动趋势，而且这种波动的频率和剧烈程度随着时间和经济的发展逐渐增加。原油资源不仅具有生产投入的商品性质，也产生了金融特性（Ding et al., 2017），传统的油价定价因素仅由供需决定，但供需关系已不足以解释 2008 年后金融危机时代原油市场的价格行为。下文将从原油商品属性的供需关系、金融因素和非金融因素三个方面着手，对现有国际原油价格波动影响因素研究进行总结论述。

（1）国际原油价格的供需关系影响研究

在石油市场中原油作为一种不可再生能源原料产品，石油资源的供应和工业化发展对原油资源的需求直接决定着原油的定价（Dees et al., 2007）。近年来全球的石油需求非常高，由原油和其他碳氢化合物液体制成的商品满足了世界总能源消耗的三分之一需求，这种高需求势必导致油价的波动（KIM et al., 2018），例如短期原油的供给跟不上需求的激增（Baumeister et al., 2013），2007-2008 年期间原油价格上涨也证明了这一点，由于短期产能不足无法满足原油市场的需求，导致油价弹性下降。可以说市场驱动依旧是国际原油价格波动的核心因素，供需关系在全球石油市场发挥着主导作用（Ansari, 2017）。

此外，间接导致的原油供需关系同样也会导致原油价格波动。例如标准普尔 500 指数不仅可用以反映美国经济的增长，还与诸多其他经济关系密切（Hu et al., 2010），同时经过研究发现标准普尔 500 指数对国际原油价格具有积极影响（Bhar et al., 2011），美国经济的增长可以推动世界经济繁荣，导致全球对原油需求增长，进而推高全球油价。无独有偶，亚洲的两个新兴国家中国和印度分别在原油进口国中排名第一和第三，当两国产生经济波动时，国际原油价格也同样会产生波动。

（2）国际原油价格的金融因素影响研究

石油市场经常对未来市场供应需求的预期变化做出提前反应，原油的供应和价格变化也会对世界宏观经济产生重大影响，随着国际原油市场逐步市场化，对原油价格波动的研究从传统的可耗竭资源理论转向了市场行为。石油安全不仅被视为“生产-供应”的供应安全，而且被是视为“市场融资”的价格安全。油价变化对实体经济的影响蔓延到金融市场，导致股市出现更大的冲击（Doko et al., 2018），石油金融化已经成为解释国际原油价格波动和定价行为的重要研

究论题。

世界宏观经济繁荣将促进石油市场的消费，导致石油市场短期的供给稳定，相反宏观经济的衰退则会抑制石油市场的消费，全球经济增长是国际原油价格波动的重要影响因素之一（Huang et al., 2017; Wang et al., 2017），自 20 世纪 80 年代中期以来，宏观经济冲击一直是油价波动的主要原因。

随着越来越多的投资者加入原油市场，原油市场的风险缓释和投资行为标准化逐渐提高（Silve'rio et al., 2012），自 1991 年以来，美国商品期货交易委员会（CFTC）授予金融公司购买无限量原油期货的同等权利，投资资金的增加导致原油价格上涨（Kilian et al., 2014），Coleman 等人（2012）认为除了供应需求和地缘政治因素之外，投资者对油价提高产生了推动作用，Juvenal 等人（2015）认为全球需求冲击是油价波动的主要原因，而投资行为是第二大驱动因素，Alquist 等人（2013）的研究则发现原油市场 2007-2008 年期间的投资交易行为对原油价格产生了适量影响，但起决定性作用的是亚洲新兴经济体经济的快速发展。

除了原油市场投资行为的兴起，金融市场的波动对油价也产生了重大影响，Miao 等人（2017）研究现实金融因素的影响大于供应需求因素和投资行为，同时由于国际原油市场主要以美元进行结算，美元汇率也对原油价格的波动产生了影响（Zhang et al., 2018），例如 2014 年油价暴跌的主要原因是欧元兑换美元汇率的下跌（Tokic et al., 2015），在美元周期性强弱势态的演变过程中，美元指数的强劲时期通常是国际经济相对疲软时期，美元指数与原油价格呈现负相关的增长态势。

（3）国际原油价格的非金融因素影响研究

石油供应国与消费国之间的资源分配不均衡使石油成为了政治敏感商品，除了金融因素的影响之外，原油产油区政治因素的变化往往会对油价波动产生重大影响。地缘政治因素往往直接或间接对原油价格产生影响（Li et al., 2022），例如 1973 年第四次中东战争爆发后，OPEC 国家实行减产、提价、禁运和国有化措施，使得原油价格上涨至近 4 倍，造成了世界局势的巨大动荡；2023 年巴勒斯坦伊斯兰抵抗运动袭击以色列，引发了新一轮国际原油价格上涨，但仅持续一天时间后回落，充分显示了原油市场是一个受多种复杂因素影响的敏感市

场。研究显示 OPEC 国家的政治风险往往会对油价产生显著的正向影响，其影响程度仅次于原油需求因素（Chen et al., 2016），而石油生产国与其邻国之间产生的政治紧张局势可能会导致原油价格大幅上涨（Wang et al., 2017）。但由于政治风险因素难以量化，这一直是原油价格波动研究的难点。

原油价格的波动与各国经济政策的不确定性也产生的较大的相互影响作用，经济政策的不确定性也反映了原油需求的波动，原油生产国受到政策影响，也会调整原油产量，从而影响国际原油价格，这一影响同时也会导致投资行为和投资情感倾向的波动（Yin et al., 2015），进而对原油市场产生深远影响。

国际原油价格也受到自然因素影响，如主要石油生产国突然的重大自然灾害会导致原油价格的短期波动，如 2013 年土耳其地震导致主要出口原油码头——杰伊汉码头关闭，使得原油价格短期上涨约 0.6%；2005 年“卡特里娜”飓风使得石油生产每日减产达 150 万桶，造成原油价格短期的剧烈波动。同时，可再生能源产量的变动也导致了原油市场的波动，当油价低迷时，稳定的可再生能源的投资可在一定程度上影响宏观经济市场，并对油价波动产生影响（SHAH et al., 2018）。

1.3.2 国际原油价格预测方法相关研究

根据现有的研究文献来看，张跃军等人（2021）提出对国际原油价格的预测一般分为传统计量模型和机器学习模型等，下文将分别从计量经济学模型、机器学习模型着手，论述对原油价格预测模型研究现状和本文改进思路。

（1）基于计量经济学模型的原油价格预测研究

传统计量模型是将经济学模型和统计理论知识相结合的经济模型，可用于预测国际原油价格的一般有自回归差分移动平均模型（ARIMA）（Mohammadi et al., 2010）、广义自回归条件异方差模型（GARCH）（Hou et al., 2012）和 VAR（Plakandaras et al., 2012）等。

Lanza 等人（2005）运用误差修正模型和协整模型对国际原油价格的变动及其因素进行了分析并对国际原油价格进行了预测。Baumeister 等（2012）分别使用 VAR 模型和 ARMA 模型对国际原油价格进行预测分析，结论发现，VAR 模型对国际原油价格的预测相比于 ARMA 模型效果更加优越。张跃军等（2007）

使用 GARCH 模型对我国大庆油田原油价格进行分析预测取得了较好的效果。Mohammadi 等（2010）将 ARIMA 模型和 GARCH 模型组合为 ARIMA-GARCH 模型对国际原油价格的走势进行预测。魏蓉蓉等（2011）使用自回归移动平均模型对 WTI 的价格进行预测。虽然计量经济学模型在原油价格预测问题已经积累了长久的使用经验，但依旧无法很好的捕捉非平稳和随机数据精确的内在特征,尤其针对影响因子复杂且具有突发不可控性因素的原油价格预测问题，如徐进和王雪莲（2022）提出的油价变动的主要驱动力包括了原油市场金融化特征，这使得传统计量经济学模型难以精确拟合非线性不确定性的预测信息。

（2）基于机器学习的原油价格预测研究

机器学习模型是目前更为主流的预测国家原油价格的方法，机器学习模型主要通过将大量数据大量特征代入模型进行训练，通过训练好的模型对预测样本进行预测。使用机器学习方法预测原油价格的学者普遍认为，高级集成下的混合深度学习模型工具优于传统计量经济学统计工具。这是由于国际原油价格强烈的时变性以及受到诸多因素的影响，单纯的对国际原油价格单序列进行计量分析会出现较大的偏差。机器学习模型则不同，机器学习模型将与国际原油价格变动的相关因素作为特征代入模型进行训练，在大量数据的支持下，机器学习模型将大量特征中的有效特征进行识别训练，最终训练后的模型可以实现对国际原油价格的精确预测效果，机器学习模型在训练时可深度多层次捕捉有效特征信息，具有降噪、非线性拟合和自适应等多种优点。机器学习方法常使用的原油价格预测模型主要有支持向量机（SVM）、极端学习机（ELM）（Plakandaras et al., 2019）和随机森林（RF）等，例如 Yu 等（2017）使用最小二乘支持向量机回归模型对国际原油价格进行预测并取得了比其他计量模型更好的预测效果；Khashman 等（2011）使用支持向量机模型对 WTI 原油价格进行了预测取得了精确的预测表现；楚新元等人（2021）使用 K 近邻回归算法（KNN）预测 WTI 原油价格。此外随着机器学习技术的发展，神经网络模型也逐渐应用于原油价格预测，例如潘少伟等（2021）使用 LSTM 模型对 WTI 国际原油价格进行预测取得了较好的效果，Chiroma 等（2015）使用遗传算法寻优优化下的神经网络模型进行国际原油价格预测。

（3）基于深度学习与分解集成框架的原油价格预测研究

然而随着研究的深入，基础的深度学习模型已很难满足更高精确度的原油价格预测需求，一方面针对时序回归拟合问题构建的结构较为简单的深度学习模型难以挖掘长时间步长下的时序关联特征，另一方面由于原油行业的特殊性，为时序回归问题特化的神经网络显然不适合处理因果关系复杂的原油价格影响因素，因此原油价格预测模型的研究主要分为以下两个方向。

一类研究引入混合深度模型的思想，使用集成结构优化基模型的链接方式，有效提高复杂回归问题的拟合精度，通过深度学习模型特有的分层挖掘结构，将善于处理底层低级特征且压缩损失信息少的模型作为底层基模型，将善于处理高层特征的复杂回归模型作为高层基模型以实现标记特征到预测目标值的迁移过程，例如，牛东晓等人（2023）使用长短期记忆网络-门控循环单元组合预测模型处理原油价格预测问题，Lu 等人（2020）将 LSTM 与卷积层结合构建预测模型，林宇等人（2023）基于数据分解、强化学习集成策略和误差修正技术构建的原油价格预测模型。

另一类研究则引入“分而治之”的思想，使用时频域的小波分析处理方法，对原油价格波动曲线分解后的模态分量分别进行子特征集降维和回归预测，以提高模型对特征集信息的挖掘能力。Li 等（2018）采用集成经验模态分解方法将国际原油价格序列分解成若干波段序列分别进行预测，崔金鑫等人（2020）使用 CEEMD 算法对原油价格序列进行分解，然后通过 PSO-ELM 模型对原油价格的走势作出预测。Wu 等人（2019）使用 EEMD 方法将原油价格序列分解为不同的分量，然后使用神经网络模型对不同分量进行预测，最后经过集成后的结果明显好于未经集成的模型，唐振鹏等人（2021）提出混合多步预测模型预测原油价格，相较于单步预测有效提高预测精度，赵兴等人（2022）分解预测集成与计量经济模型融合，提出了 CEEMDAN-ARIMA-GARCH 模型的原油价格预测模型，Guo 等人（2022）通过 VMD 分解原油价格时序数据集，有效提高 LSTM 模型在不同频段对预测目标的指标信息挖掘能力。

上述研究是从方法论的角度进行简述的，而另一研究研究角度主要集中于原油价格复杂的影响因子，Demirer 等人（2020）、Bonato 等人（2020）和 Gkillas 等人（2020）使用 HAR-RV 工具研究了石油市场波动与金融压力、油价冲击和投资者幸福感之间的相互关系等，研究涵盖了从原油市场到黄金市场的

时变溢出效应，原油波动性与农业投资波动性之间的关系，以及比特币、黄金和原油市场之间的相互联系。Akay 和 Uyar (2016)、Dai (2020) 研究了发达市场和新兴市场的股票市场、金融工具、可再生能源资源和油价动态之间的相互联系。Ben Jabeur 等人 (2021) 通过使用绿色能源 (GER)、全球环境指数 (ESG) 和股票市场等变量预测原油价格，张耀杰等人 (2022) 提出应基于多源数据进一步提高机器学习模型的原油价格预测能力和可解释性。本文的研究模型将会综合考虑前人的预测因子研究思路，以提高模型预测复杂维度，提升模型抗风险和降噪能力。

1.3.3 文献述评

从国际原油价格波动的影响因素来看，油价波动的驱动因素在各个时期均有不同，但供应需求等原油商品因素仍然是原油定价的决定性因素；除此之外随着原油市场逐渐过渡到市场行为，原油产生了金融属性，金融因素被认为是 21 世纪以来油价变化的主要驱动力；非金融因素也是导致原油价格波动的重要影响因素之一，包括有政治因素、地理因素、自然因素和经济政策不确定性因素等等，但由于非金融因素多数无法量化，是原油价格预测研究中一直以来的难点。

从国际原油价格预测模型来看，现有的研究显示机器学习模型可以比传统计量经济学模型更好地捕捉非线性信息特征，同时一条研究路线认为结构复杂的深度神经网络学习模型可以更好地多层挖掘时序关联特征，另一条研究路线认为油价波动包含历史信息 and 隐藏信息波动，使用小波分析的频率分解模型可有效提高在多频模态上的预测精度，然而以往大多数研究往往只采用单个研究路线，因此基于现有研究的局限性，本文使用混合深度学习模型在多模态分解向量下进行原油价格预测研究，以提高模型的预测精度和抗风险抗噪声能力。

1.4 研究内容及方法

基于上述研究背景和现有的研究成果，本文根据影响原油现货价格影响因子构建模型特征集，并根据前人工作的考察，采取针对原油价格的非线性、不确定性和动态性等多种特性构建模型，并提出混合深度学习模型下的多尺度分

解的混合深度学习模型（EMD-BiLSTM-CNN，EBC），以提高对原油价格预测的精确度和时效性。

1.4.1 研究内容

考虑到原油价格预测问题的特殊性和模型复杂度等，本文的研究内容主要为以下四个方面：

（1）影响因子方面，根据前人的研究构建适用于 EBC 模型的特征原集，为了弥补深度学习模型可解释性不足，引入 GRA 对特征原集进行分析，量化判断各影响因子之间的相关度。

（2）预测模型方面，提出一种基于经验模态分解模型和深度学习模型混合集成的原油价格预测模型（EBC）。该深度学习混合模型为 BiLSTM 和 CNN 的混合模型（BiLSTM-CNN）。

（3）特征选择方面，基于 EBC 预测模型与原油价格影响特征原集提出特征子集。由于 EMD 模型分解的 IMF 分量个数的不确定性和各分量的预测情况不同，需要针对不同的分量重构预测子集。

（4）预测结果应用方面，本文提出了特征迁移思想在原油价格预测任务中的应用，同时本文也选取了 WTI 原油期货价格和与原油能源息息相关的新能源市场指数作为例证，验证 WTI 原油现货价格预测值的实际应用价值。

1.4.2 研究方法

本文主要使用了混合深度学习模型、经验模态分解模型、基于随机森林的递归特征消除法和灰色关联度分析法等。

（1）混合深度学习模型（Hybrid Deep Learning Model）

本文提出了一种由基础神经网络模型混合构建的深度学习模型，提高模型多角度挖掘特征信息能力，以提高模型的预测精度和泛用性。本文使用了双向长短期记忆神经网络（Bidirectional Long Short-Term Memory, BiLSTM）和卷积神经网络（Convolutional Neural Network, CNN）构建混合深度学习神经网络（BiLSTM-CNN）。

（2）经验模态分解模型（Empirical Mode Decomposition Model, EMD）

由于原油价格预测问题具有影响因素复杂、非线性、不确定性和动态性等多种特点，结构简单的时序预测模型难以处理多模态特征因子，因此本文引入分解集成框架的经验模态分解模型，通过对原油价格序列进行模态分解和重组，分别对重组后的分量构建预测模型，提高针对不同分量的特征信息挖掘能力，以提升模型的预测精度。

（3）基于随机森林的递归特征消除法（Recursive Feature Elimination Method - Random Forest, RFE-RF）

由于针对不同的分量需要构建不同的预测模型，为了提高预测模型的时效性并降低模型复杂度，通过特征的重要性筛选特征子集至关重要，本文的特征选择方法为基于随机森林的递归特征消除法。RFE的基本思想为通过不断剔除权重最小的一部分特征来评估模型的拟合能力，直到筛选得出最优特征子集。随机森林模型是一类包含有多个决策树的回归模型，其树状的模型结构使得RF具备较好的特征权重解释能力和较快的模型训练能力，同时RF具有较强的抗噪声性能，是非常适用于特征选择的模型。

（4）灰色关联度分析法（Grey Relation Analysis, GRA）

GRA基于灰色系统理论提出，通过关联系数计算系统中各因素之间的数值关系，常用于衡量特征集中某个因素受其他因素影响相对强弱。其基本思想为根据序列曲线集合形状的相似程度来判断其联系是否紧密，根据两个因素之间的发展趋势相似相异程度，为因素的相关性提供了量化度量。本文使用GRA判断特征原集的各影响因子的相关性，通过对因素的重要性进行排序，以提高EBC模型的可解释能力。

1.5 研究创新点

针对原油价格预测问题的特殊性、时效性和影响因子复杂等特性，本文基于现有的原油价格预测模型的研究基础上，提出的创新点主要为以下两点：

（1）提出集成框架下的混合深度学习国际原油价格预测模型。考虑到EMD频率分解模型的迭代分解不能将IMF分量个数作为定值，使用T检验重构IMF分量为高低频和趋势分量，分别对三个分量进行子特征集筛选以提高模型的拟合精度，并训练通过K折交叉验证分别训练三个BiLSTM-CNN混合深度学

习神经网络，降低过拟合风险的同时，提高预测精度；

(2) 提出原油价格预测任务的特征迁移学习方法。将突发事件加入的特征集作为新的映射空间，已训练好的模型为初始点，进行相似任务的训练，增加突发事件的样本容量的同时，有效提高了模型的时效性和泛用性。

1.6 技术路线图

本文的技术路线图如下图 1.1 所示，将从分析问题、解决问题和总结展望三个方向出发，对原油价格预测问题进行研究。

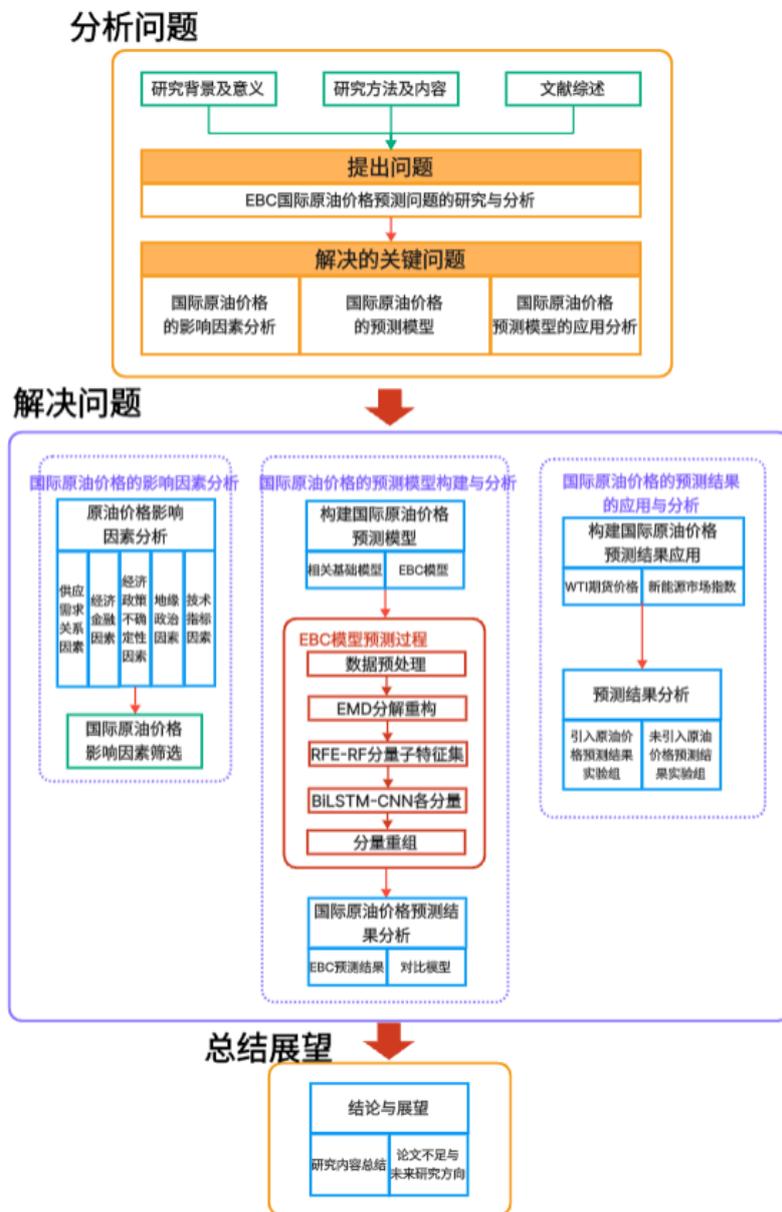


图 1.1 技术路线图

论文第一章主要阐述研究背景研究意义和研究内容，根据前人的研究成果，提成本文的研究思路，论文第二章和第三章主要提出了原油预测问题的特征集和预测模型，论文第四章进行实证分析，通过实际研究和对比模型说明本文提出的预测模型优越性，第六章则对第五章的预测结果进行应用分析，第七章对本文的研究内容进行总结并展望未来的研究方向。

1.7 结构安排

本文通过对国际原油价格波动影响因素分析，分别从供应需求关系、经济金融因素、经济政策不确定性因素和地缘政治因素四个方面构建特征集，使用混合深度学习模型（BiLSTM-CNN），与分解集成框架下的 EMD 模型构建预测模型（EBC），通过 WTI 原油价格进行实证与对比模型进行对比分析，并将 WTI 原油价格预测结果作为影响因子引入原油期货价格和新能源市场指数预测任务，有效提高了预测精度，论文的主体包括以下五个部分。

（1）第一部分为引言，围绕本文的研究背景及研究意义展开论述，从国际原油价格波动的影响因素和预测方法两个角度着手，提出本文的研究论点，并以此为依据提出本文的研究内容、研究方法和创新点；

（2）第二部分为国际原油价格波动影响因素分析。包括有供应需求关系、经济金融因素、经济政策不确定性因素和地缘政治因素四个方面。使用 GRA 模型分析各特征因素之间的相关性，提高模型的可解释性；

（3）第三部分为国际原油价格预测模型。主要介绍了国际原油价格预测模型的结构、预测流程和构建的基础模型理论，包括有迁移学习思想、RF、BiLSTM、CNN、BiLSTM-CNN、EMD 等；

（4）第四部分为国际原油价格实证。详细介绍了 EBC 模型的数据清洗、特征降维、模型训练、模型预测和预测结果分析，为了验证 EBC 模型的优越性，本文选取了四个对比模型；并引入特征迁移学习思想和 WTI 原油现货价格预测的应用，将原油现货价格作为影响因子引入模型，分别对原油期货价格和新能源市场指数预测问题进行分析；

（5）第五部分为总结与展望。对本文的研究内容和结果做了简要概括，并对原油现货价格和 EBC 模型的后续工作进行展望。

2 国际原油价格波动影响因素分析

本文的预测的目标值为 WTI 原油现货价格，WTI 原油是美国西德克萨斯的中质原油，是世界原油市场上的三大基准价格之一，美国以纽约商业交易所（NYMEX）上市的 WTI 原油合约为定价基准。本文选取 2000 年 1 月 1 日至 2023 年 12 月 31 日数据共 6138 条，来源于知名石油网站美国能源信息署（<https://www.eia.gov/>）。

2.1 供应需求关系

2.1.1 原油供给与需求

原油是一种不可再生资源，作为占据世界主导地位的大宗产品，随着原油定价逐渐市场化，石油资源的供应和市场对原油资源的需求决定着原油的定价，随着近年世界工业化的加速发展，原油资源的需求逐年增加，OPEC 国家的原油产量与世界原油需求量的关系往往影响着短期原油价格波动，全球原油资源分布不均衡更加重了这一影响，使得油价波动暴露在长期的不确定风险中，原油长期作为一种稀缺资源，全球供给和需求的小幅变化都将引起油价的波动。供给小于需求时，原油价格波动产生上涨趋势；供给大于需求时，原油价格波动则产生下降趋势，其中供给因素对油价呈反向作用，需求则对油价呈正向作用。

（1）原油供给因素

原油供给因素本文从原油产量、原油运输、替代商品方面三个方面选取描述指标。

原油产量方面，本文选取了美国原油及石油产品供应量、OPEC 原油产量、非 OPEC 原油产量、美国原油产量和世界原油产量作为指标，数据来源于美国能源信息署（<https://www.eia.gov/>），下图 2.1 为以上特征与油价波动趋势变化的对比图。OPEC 原油产量约占世界原油产量 35%，截止到 2020 年底，OPEC 已探明原油储量约占全球 70%，从下图可以看出世界原油产量与 OPEC 原油产量曲线波动相似，可见世界上大部分原油资源分布在 OPEC 国家。在 20 世纪中后期出现的两次石油危机和海湾战争，也造成了 OPEC 国家原油产量减产，2020

年沙特和俄罗斯的减产政策也造成了油价新一轮波动。

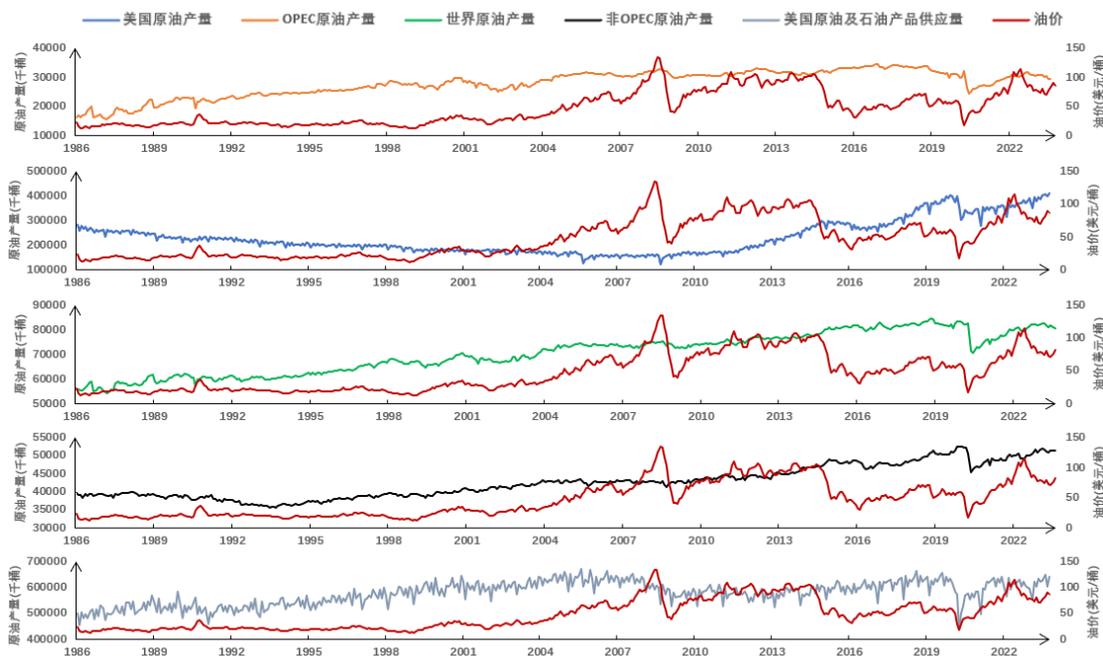


图 2.1 1986~2023 年原油产量指标与油价波动折线图

原油运输方面，原油运输成本是影响油价波动的重要原因之一，因原油分配地理位置的不均衡，原油从生产地到消费地的运费直接影响着油价，当原油运输成本增加时，油价上涨速度加快，运输过程中出现的损耗也会导致原油供应量的下降，导致油价上涨。本文使用美国东海岸原油运输净收入作为原油运输指标，数据来源于美国能源信息署 (<https://www.eia.gov/>)，下图 2.2 为油价和运输指标波动的对比图，研究表明原油运输净收入相比油价波动曲线具有滞后性，但仍与原油价格波动高度相关。



图 2.2 1986~2023 年原油运输指标与油价波动折线图

替代商品价格方面，煤炭和天然气是原油的替代能源，当原油价格上涨或

原油供应量短缺时，能源消费者将倾向于选择替代能源，使得替代能源市场短期价格呈现上涨态势，油价则呈下降趋势，反之替代能源价格上涨时能源消费者将倾向于选择石油产品，使得油价短期上涨，替代能源价格短期下降，达成市场的平衡。同时煤炭和天然气是原油生产过程中重要的成本组成部分，油价的波动受到生产成本的影响，煤炭和天然气价格上涨将导致原油开采成本上涨，进而影响原油定价。因此本文将从煤炭和天然气价格特征分别选取指标，用以描述原油替代商品市场影响油价，具体如下，其波动趋势与油价对比如下图 2.3 所示。

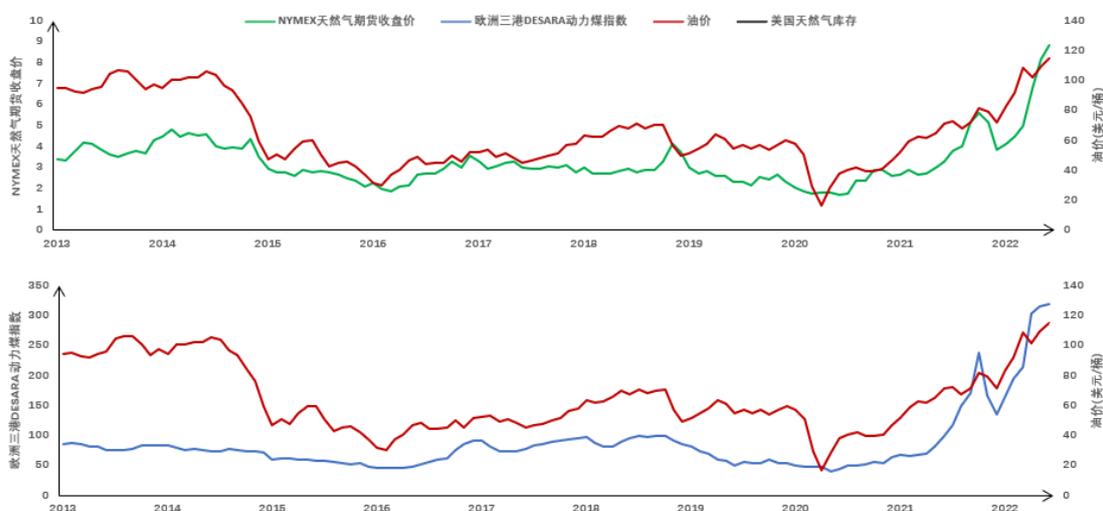


图 2.3 2013~2023 年原油替代商品因素与原油价格波动折线图

欧洲三港 DESARA 动力煤指数。欧洲三港 DESARA 动力煤指数是一种反映欧洲地区动力煤价格变动的指数，由欧洲三个主要港口的动力煤价格加权平均计算得到，常用于描述欧洲地区动力煤市场的供需状况和价格走势，是全球动力煤市场的重要参考指标之一。指数上涨表示欧洲地区动力煤需求下降供应增加，价格短期内上涨，反之指数下降表示欧洲地区动力煤需求上涨供应下降，价格短期内下降。该数据取自数据来源于 Wind 数据库。

NYMEX 天然气期货收盘价。纽约商业交易所（NYMEX）天然气期货以美国天然气市场为交易对象，是全球天然气市场的重要交易品种之一，其价格走势受到天然气供需关系和其他能源市场等多种因素的影响，同时其价格波动趋势也反映了市场对未来天然气价格的预期。该数据取自数据来源于 Wind 数据库。

美国天然气库存量。美国天然气库存对天然气价格波动有直接影响，当天

然气库存增加时天然气价格将产生下降趋势，反之当天然气库存下降时天然气价格产生上涨趋势，天然气库存的变化将在一定程度上反映未来天然气价格变动趋势。该数据取自美国能源信息署 (<https://www.eia.gov/>)，其波动趋势与油价对比如下图 2.4 所示。

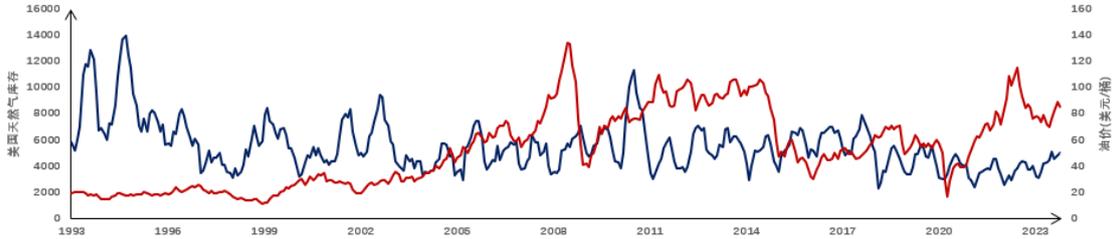


图 2.4 1993~2023 年原油替代商品因素与原油价格波动折线图

(2) 原油需求因素

原油需求因素本文选取了 OECD 石油消费量、非 OECD 石油消费量、中国石油消费量、美国石油消费量和世界原油消费量作为特征，数据来源于美国能源信息署 (<https://www.eia.gov/>)，下图 2.5 为上述特征与油价波动趋势的对比图，可以看出随着世界经济的发展，原油市场的需求量几乎持稳定持续增长态势，全球持续的经济增长，导致原油需求稳步增加，从而影响原油价格。

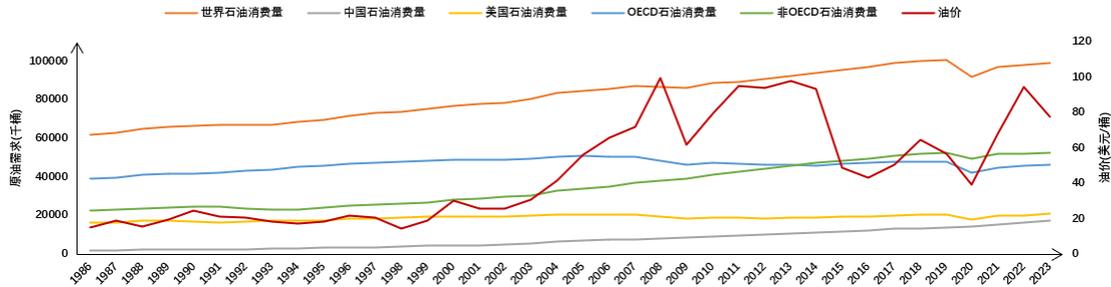


图 2.5 1986~2023 年原油需求因素与油价波动折线图

2.1.2 原油库存

原油库存的变化会影响市场供需关系和投资者对原油市场的预期，从而 y 影响油价。原油库存增加时表明原油市场原油供应链过剩，一方面投资者会产生油价下降的预期，从而减少对原油的投资和需要，另一方面，石油公司会倾向于增加商业库存，从而刺激现货价格上涨，降低现货价格，与石油期货价形

成合理价差；原油库存减少时，表明市场对原油需求旺盛，也表明了当期原油供应不足，投资者会产生油价上涨的预期，从而增加对原油的投资和需求，同时石油公司倾向于减少商业库存，通过增加当期供应等措施降低现货价格，以减小期货和现货价差。此外，原油库存的变化也会对全球工业发展和投资行为产生影响，原油库存增加一方面对工业经济发展呈现正向作用，同时也会抑制投资行为；相反如果原油库存减少，会有效促进原油市场的投资。

原油库存因素本文选取了世界原油库存、OECD 原油库存、非 OECD 原油库存、OPEC 原油库存、非 OPEC 原油库存和美国原油库存作为特征，数据来源于美国能源信息署 (<https://www.eia.gov/>)，下图 2.6 为上述特征与油价波动折线图。可以看出世界原油库存、非 OECD 原油库存和 OPEC 原油库存的变化趋势较为相近，整体呈现增长趋势，且与油价的波动趋势大体呈现负相关。

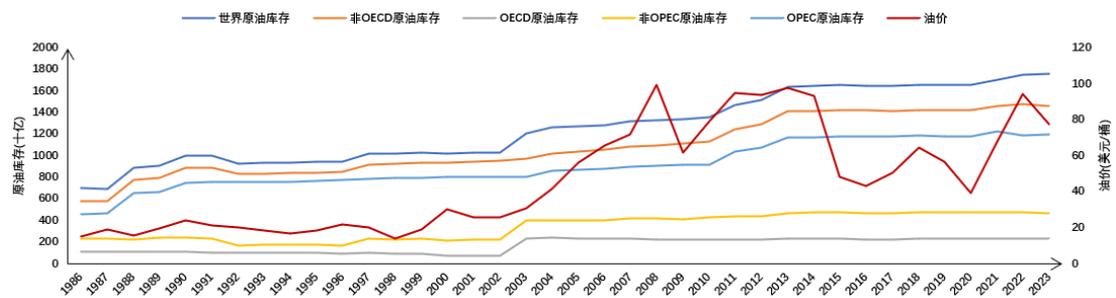


图 2.6 1986~2023 年原油库存因素与油价波动折线图

2.2 经济金融因素

2.2.1 宏观经济因素

经济繁荣将促进石油的消费，全球经济增长是影响原油价格的重要因素之一，稳定且持续增长的经济环境对原油的需求产生了正向促进作用，使得原油价格呈上涨趋势，当全球经济产生波动时，将会导致原油供需关系的不平衡，加剧原油价格的波动。

本文选取美国失业率、美国通膨率、美国原油工业生产指数和美国工业生产指数作为宏观经济因素的指标，数据来源于 Wind 数据库。上述指标的波动趋势与原油价格的对比图如下图 2.7 所示，可以看出美国原油工业生产指数和通膨

率与油价的波动趋势高度一致，工业生产指数则与油价波动的整体趋势相同，失业率指标则与油价波动呈现负相关作用。

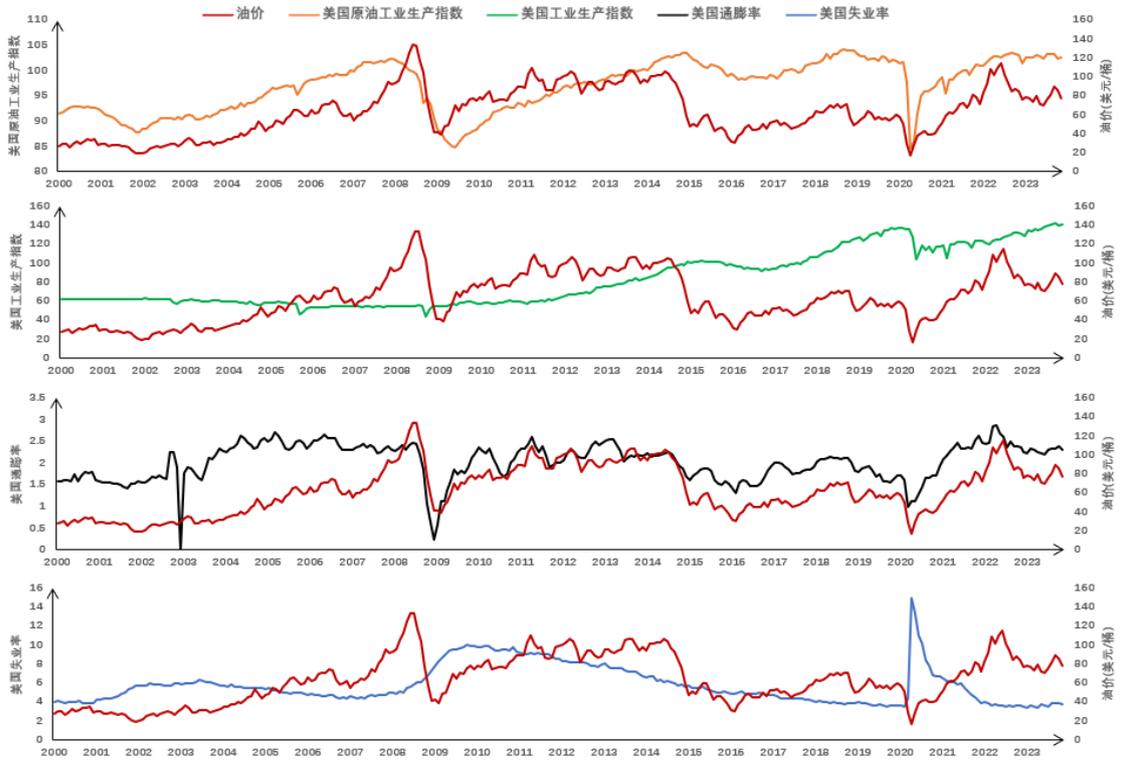


图 2.7 2000~2024 年宏观经济因素与原油价格波动折线图

2.2.2 金融市场因素

金融市场的发展对油价同样具有重大影响，经济繁荣带来的流动性增加会显著促进油价、全球原油产量和原油需求增长。本文从世界主要经济体发展情况、美元汇率和投资者预期三个方面分别选取指标描述金融市场对油价波动的影响。

全球主要经济体高速发展推动工业化和国际贸易活动的增加，从而提高了对原油的需求量，以促进油价提升，本文使用道琼斯工业指数、上证指数和标准普尔 500 指数作为描述世界主要经济体发展情况的特征指标。道琼斯工业指数 (Dow Jones Industrial Average, DJIA)，是反映美国股市行情变化的股票价格平均指数，被广泛应用于衡量美国股市的表现，是全球金融市场中被广泛关注的股票指数之一；上证指数全称为上海证券综合指数，是中国股市的主要参考标准之一，被广泛应用于衡量中国 A 股市场的整体表现；标准普尔 500 指数

(S&P 500 Index) 是记录美国 500 家上市公司的股票指数，被普遍认为是一种理想的股票指数期货合约的标的，与 DJIA 相比标普 500 指数包含的公司更多，能够更加广泛地反映市场变化，以上数据均取自 <https://stooq.com>，上述指标的波动趋势与油价的对比如下图 2.8 所示。

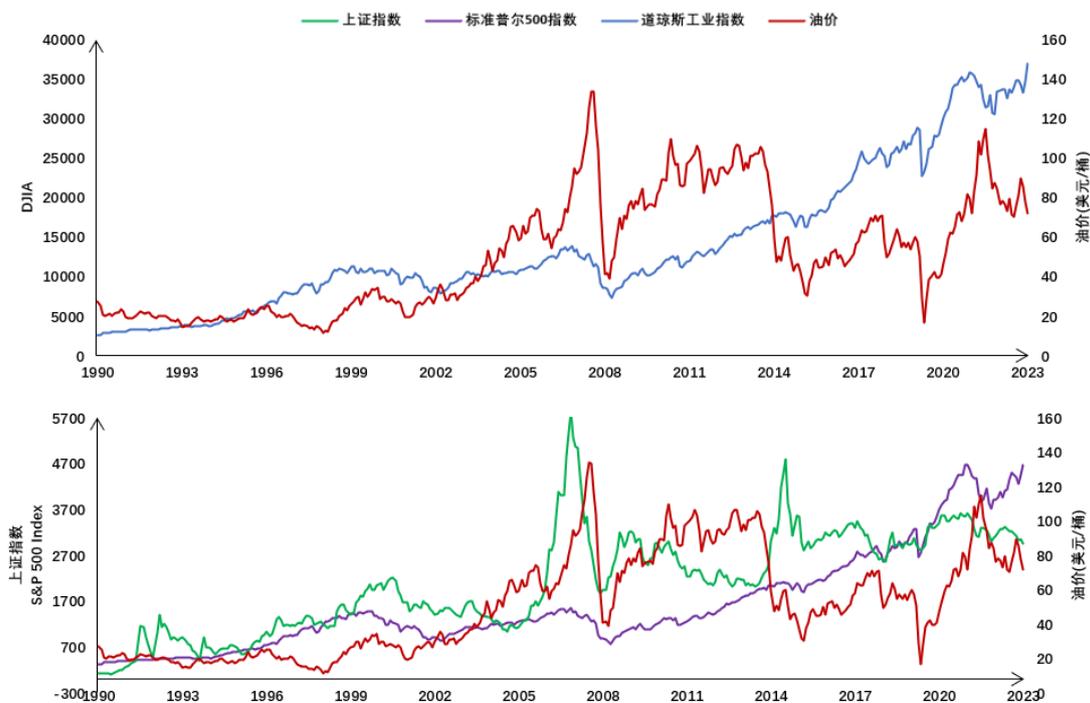


图 2.8 1990~2023 年美元指数与油价波动折线图

由于国际原油交易通常以美元计价，当美元汇率升值时，原油价格相对其他货币贬值，导致原油需求下降，从而抑制油价；相反当美元汇率贬值时，原油价格相对其他货币甚升值，可能导致原油需求增加，从而促进油价上涨。本文使用美元指数作为美元汇率特征指标，数据取自 <https://stooq.com>，美元指数变化趋势与油价波动对比图如下图 2.9 所示，油价的历史变化趋势与美元指数呈显著负相关。



图 2.9 1996~2023 年美元指数与油价波动折线图

投资者预期也是金融市场影响油价的重要指标之一，投资者的预期会影响原油市场的投资行为，如果投资者对全球经济和工业活动持乐观态度，将会促进原油市场投资行为活跃，促进油价提升；相反如果投资者持悲观态度，将会导致油价产生下降趋势。本文使用芝加哥期权交易所波动率指数（Volatility Index, VIX）恐慌指数作为投资者预期特征指标，VIX 恐慌指数由标准普尔 500 指数期权的隐含波动率计算得来，常应用于反映投资者对后市的心理预期状态。VIX 指数越低反映着投资者认为未来的市场波动趋于缓和；反之 VIX 指数越高，代表市场参与者预期后市波动程度将会更加激烈，VIX 指数较高时容易引起投资者的投资决策变化，使得投资市场对突发事件的敏感性偏高，从而导致金融市场的剧烈震荡，进而影响油价波动，下图 2.10 为 VIX 指数与油价波动趋势对比图，数据来源于 FRED 数据库（<https://fred.stlouisfed.org>），可以看出油价的剧烈波动和 VIX 指标波动往往同步出现，VIX 指标可以作为原油价格波动情况的重要影响指标。



图 2.10 1990~2023 年 VIX 恐慌指数与油价波动折线图

2.3 经济政策不确定性因素

经济政策的不确定性也会导致原油价格的波动，往往体现在货币财政政策、贸易政策和能源政策。货币真彩和财政政策会影响经济增长和通胀水平，贸易政策的不确定性会导致全球供应紊乱和贸易局势紧张，从而影响原油的供应和需求，能源政策则会对各国原油生产、进出口和新能源替代原油情况产生重大影响，同时石油公司会根据经济政策和市场情况调整产量，降低石油的供应弹性，这一举措也会对投资行为产生影响，进而影响原油价格。

本文使用 EPU (Energy Price Uncertainty) 描述经济政策不确定因素，数据取自 <http://www.policyuncertainty.com/index.html>，EPU 是指能源价格不确定性，

反映了市场对于未来能源价格波动的预期，常用于评估能源市场的风险，EPU 基于能源价格的历史波动率和隐含波动率构建。依据前人学者对原油市场和世界经济政策不确定性局势的研究，例如徐进和王雪莲（2022）提出的国际原油价格预测指标，本文选取了世界和六个石油生产消费大国（中国、美国、日本、俄罗斯、英国、加拿大）的 EPU 指标，波动情况与原油价格对比图如下图 2.11 所示，随着经济的发展近年各国 EPU 波动加剧，给原油价格波动的不确定性进一步加强。

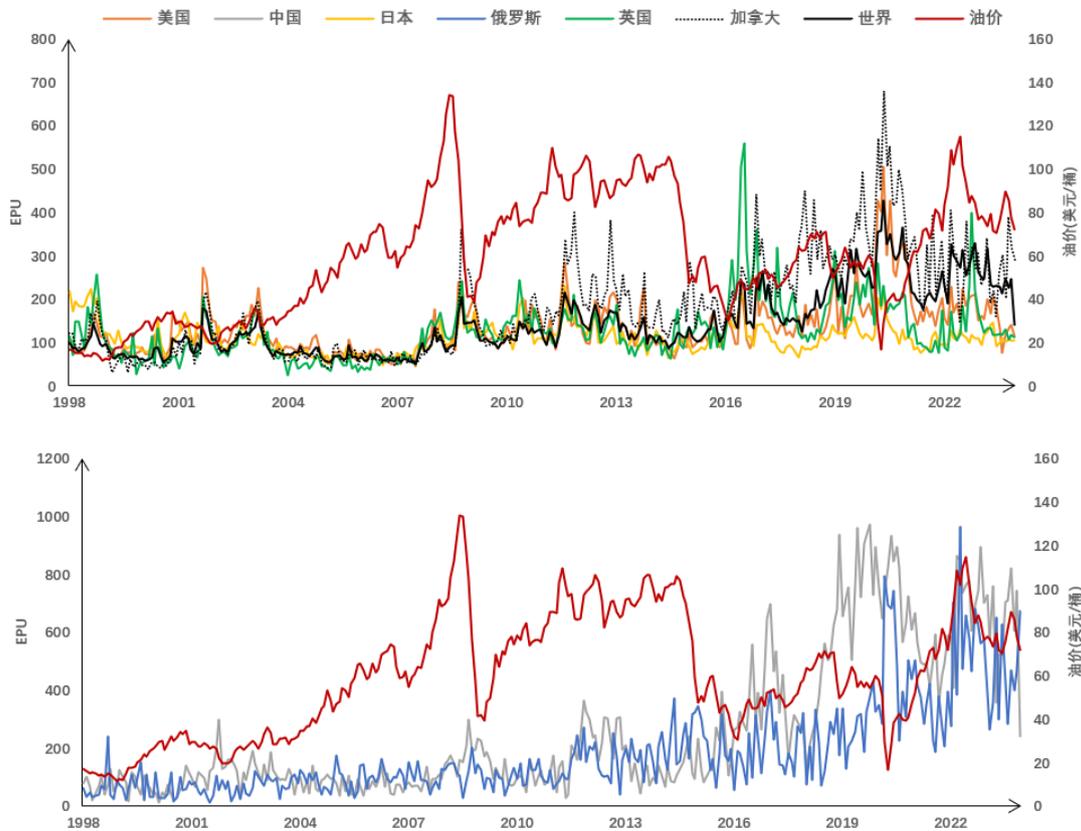


图 2.11 1998-2023 年 EPU 与原油价格波动折线图

2.4 地缘政治因素

原油资源分布的不均衡以及地理因素导致的原油运输敏感等因素使得原油成为敏感商品，产油区的政治风险造成的变化会对原油价格产生重大影响。重大地缘政治事件会导致原油产量和需求波动，从而导致油价波动的不确定性，对于原油生产消费大国的地缘政治风险更会加剧这一波动，同时由于突发地缘政治事件常常影响正常经济活动，造成投资市场低迷，产生了对金融市场因素

的影响。

本文使用 Caldara 等人（2022）构建的地缘政治风险指数（Geopolitical Risk, GPR）作为该因素的特征指标，GPR 指数根据《芝加哥论坛报》、《每日电讯报》、英国《金融时报》、《环球邮报》、《卫报》、《洛杉矶时报》、“纽约时报”、《今日美国》、《华尔街日报》和《华盛顿邮报》共十家报纸的电子档案，计算每份报纸每月与不利地缘政治事件有关文章占新闻文章总数的比例，以此为评估该地区地缘政治风险的依据，GPR 数值越大代表该地区地缘政治风险越大。本文选取了世界和六个石油生产消费大国（中国、美国、日本、俄罗斯、英国、加拿大）GPR 指数，数据取自 <https://www.matteoiacoviello.com/gpr.htm>，波动情况与油价的对比图如下图 2.12 所示，可以看出 GPR 剧烈的同时往往伴随着油价的波动。

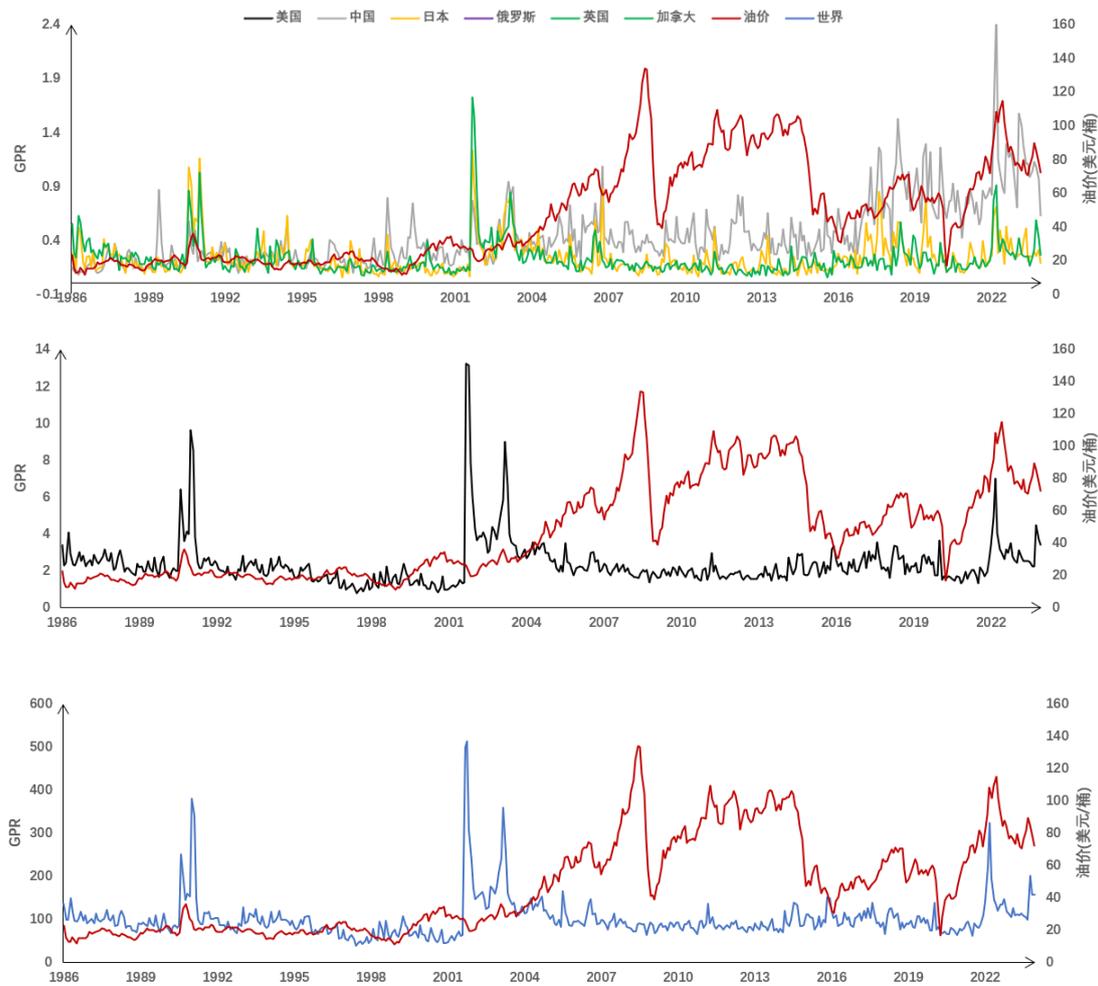


图 2.12 1986~2024 年 GPR 指数与原油波动折线图

2.5 国际原油价格波动影响因素筛选

根据供应需求关系、经济金融因素、经济政策不确定性因素和地缘政治因素四个方面的影响因素，构建国际原油价格波动特征集如下表 2.1 所示，共 43 个指标，因指标个数过多易造成模型复杂性较高，使得模型时效性下降，过拟合风险上升，因此本文使用 GRA 方法对特征集进行初步筛选，剔除重要性较低的指标。

表 2.1 国际原油价格波动指标说明

影响因素	指标分类	具体指标（括号中为指标编号 $x_1 \sim x_{43}$ ）
供需关系	原油供给	美国原油及石油产品供应量 (x_1)、OPEC 原油产量 (x_2)、非 OPEC 原油产量 (x_3)、美国原油产量 (x_4)、世界原油产量 (x_5)
	原油运输	美国原油运输净收入 (x_6)
	替代商品	欧洲三港 DESARA 动力煤指数 (x_7)、NYMEX 天然气期货收盘价 (x_8)、美国天然气库存量 (x_9)
	原油需求	OECD 石油消费量 (x_{10})、非 OECD 石油消费量 (x_{11})、中国石油消费量 (x_{12})、美国石油消费量 (x_{13})、世界原油消费量 (x_{14})
	原油库存	世界原油库存 (x_{15})、OECD 原油库存 (x_{16})、非 OECD 原油库存 (x_{17})、OPEC 原油库存 (x_{18})、非 OPEC 原油库存 (x_{19})、美国原油库存 (x_{20})
经济金融	宏观经济	美国失业率 (x_{21})、美国通膨率 (x_{22})、美国原油工业生产指数 (x_{23})、美国工业生产指数 (x_{24})、道琼斯工业指数 (x_{25})
	金融市场	上证指数 (x_{26})、标准普尔 500 指数 (x_{27})、美元指数 (x_{28})、VIX 恐慌指数 (x_{29})
经济政策不确定性		世界、中国、美国、日本、俄罗斯、英国、加拿大 EPU 指数 ($x_{30} \sim x_{36}$)
地缘政治风险		世界、中国、美国、日本、俄罗斯、英国、加拿大 GPR 指数 ($x_{37} \sim x_{43}$)

注：以上数据可从 <http://www.policyuncertainty.com/index.html>、Wind 数据库、美国能源信息署 (<https://www.eia.gov/>)、<https://www.matteoiacoviello.com//gpr.htm>、FRED 数据库 (<https://fred.stlouisfed.org>)、<https://stoq.com> 网站获取。

GRA 是一种多因素统计分析方法，核心思想为在灰色关联度系统中，当两个因子的变化趋势一致，认为二者相关性较高；反之当两个因子变化趋势不一

致，则认为二者相关性较低，依据因子之间的相关系数进行排序，获得各因子之间的影响关系量化描述，各因子的灰色关联系数和灰色加权关联度计算公式 f 分别如下式(2.1)和式(2.2)所示。

$$\xi_s(t) = \frac{\min_s \min_t |x_0(t) - x_s(t)| + \rho \max_s \max_t |x_0(t) - x_s(t)|}{|x_0(t) - x_s(t)| + \rho \max_s \max_t |x_0(t) - x_s(t)|} \quad (2.1)$$

$$r_0^s = \frac{1}{n} \sum_{t=1}^n \xi_s(t) \quad (2.2)$$

其中 ρ 为分辨系数， ρ 越接近于 0 则相关系数之间的差值越大，区分能力越强，此处 ρ 值取 0.5。式(2.1)为比较序列 $x_s(t)$ 与参考序列 $x_0(t)$ 的相关序列计算公式，式(2.2)加权平均相关序列获得相关系数。GRA 相关性分析结果的热力图如下图 2.13 所示。

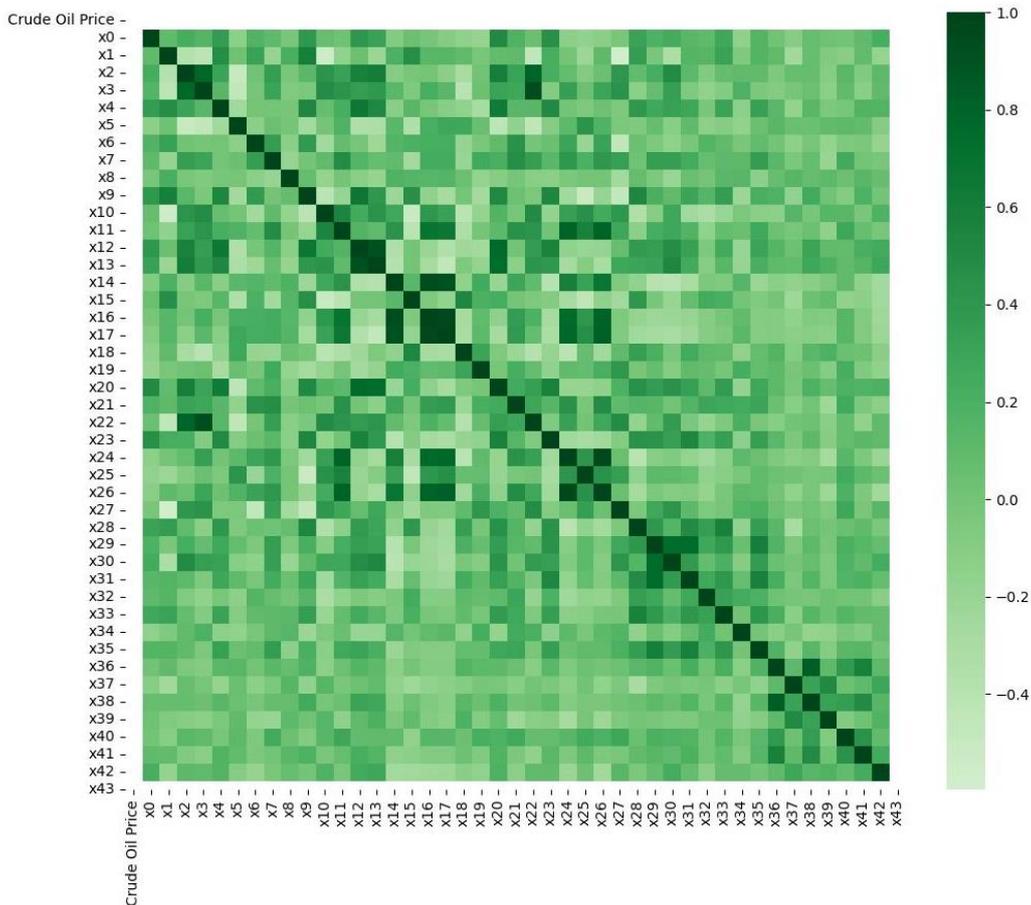


图 2.13 GRA 分析相关系数热力图

各特征指标与预测目标值 WTI 原油现货价格的相关系数如下表 2.2 所示，本文选取相关系数大于 0.8 的指标，其中因地缘政治风险较高，波动常具有不确

定性和敏感性，并对原油价格波动有着深远的影响，因此全部计入原始特征集，共计指标 25 个，具体如下表 2.3 所示。

表 2.2 国际原油价格 GRA 相关性分析结果

指标	相关系数	排序	指标	相关系数	排序	指标	相关系数	排序
x_{10}	0.9858	1	x_{33}	0.8672	16	x_{14}	0.7031	31
x_2	0.9811	2	x_{29}	0.8566	17	x_{20}	0.6995	32
x_{37}	0.9482	3	x_{42}	0.8324	18	x_{21}	0.6974	33
x_{30}	0.9222	4	x_{24}	0.8305	19	x_{41}	0.6938	34
x_{43}	0.9162	5	x_{19}	0.8144	20	x_{27}	0.6871	35
x_{35}	0.9114	6	x_{31}	0.8075	21	x_{25}	0.6812	36
x_8	0.9022	7	x_{16}	0.8048	22	x_{12}	0.6595	37
x_9	0.8998	8	x_{39}	0.7975	23	x_3	0.6442	38
x_7	0.8923	9	x_{18}	0.7957	24	x_4	0.6428	39
x_{36}	0.889	10	x_{17}	0.7877	25	x_{22}	0.6311	40
x_6	0.8799	11	x_{13}	0.7802	26	x_{11}	0.6258	41
x_{34}	0.8795	12	x_{15}	0.7695	27	x_{23}	0.6232	42
x_1	0.875	13	x_{38}	0.7491	28	x_{28}	0.6089	43
x_{32}	0.8739	14	x_5	0.7418	29			
x_{40}	0.8717	15	x_{26}	0.7137	30			

表 2.3 国际原油价格波动原始预测集

影响因素	指标分类	具体指标（括号中为指标编号 $T_1 \sim T_{25}$ ）
供需关系	原油供给	美国原油及石油产品供应量 (T_1)、OPEC 原油产量 (T_2)
	原油运输	美国原油运输净收入 (T_3)
	替代商品	欧洲三港 DESARA 动力煤指数 (T_4)、NYMEX 天然气期货收盘价 (T_5)、美国天然气库存量 (T_6)
	原油需求	OECD 石油消费量 (T_7)
	原油库存	OECD 原油库存 (T_8)、非 OPEC 原油库存 (T_9)
经济金融	宏观经济	美国工业生产指数 (T_{10})
	金融市场	VIX 恐慌指数 (T_{11})
经济政策不确定性		世界、中国、美国、日本、俄罗斯、英国、加拿大 EPU 指数 ($T_{12} \sim T_{18}$)
地缘政治风险		世界、中国、美国、日本、俄罗斯、英国、加拿大 GPR 指数 ($T_{19} \sim T_{25}$)

3 国际原油价格预测模型

本文选择混合深度神经网络 BiLSTM-CNN 与模态分解模型 EMD 集成的迁移训练模型对 WTI 原油现货价格进行预测，通过 EMD 多频段多尺度地挖掘预测样本特征，有效提高原油价格预测精度，为国内原油市场投资及原油催生市场提供合理有效的发展建议。

3.1 基础模型理论

EBC 模型是由 EMD 和 BiLSTM-CNN 共同构成的集成模型，旨在多尺度挖掘预测数据的全局及局部特征，本文将从 EBC 组成元件的原理出发，分别从 EBC 模型结构和 EBC 模型预测流程的角度进行介绍。

3.1.1 基于随机森林的递归特征选择法

本文使用基于随机森林的递归特征选择法 (RFE-RF) 对分解重构后的分量进行特征选择，下文将分别从随机森林和递归特征选择法的算法原理和结构论述该方法作为特征选择算法的优点。

(1) 随机森林 (RF)

随机森林算法是基于 Bagging 思想构建的多决策树集成模型 (Ensemble Model)，其中 Bagging 是一种典型的集成思想，核心在于集成多个弱分类器的预测结果，Bagging 有放回抽样方法组成新的训练样本集，有效降低了模型过拟合风险，多个基模型拟合的预测结果有效降低预测误差，由于本文的预测目标为原油价格时序数据，因此选取 RF 算法的回归模型，具体如下：

Step1: 有放回地从训练集中取出 n 个训练样本组成训练子集；

Step2: 使用训练子集训练新的基模型，重复 m 次获得 m 个基模型；

Step3: 将 m 个基模型预测结果加权平均生成最终预测结果。

随机森林的基模型为决策树 (Decision Tree, DT)，决策树是一种树形结构的有监督机器学习算法，每一个内部节点代表一个属性的测试，每一个分支表示一种测试的输出，每一个叶节点表示一类分类结果，决策树的决策过程从根节点开始，通过节点分类待测试属性，按照决策思路分类分支，使得分支的属

性尽可能单一，将叶节点的分类结果作为一类属性参与决策结果，建立 DT 的算法具体如下。

算法 1 生成决策树

输入: 训练集 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$

输入: 特征集 $A = \{a_1, a_2, \dots, a_d\}$

输出: 以 $node$ 为根结点的一棵决策树

```

1: function DECISIONTREE( $D, A$ )
2:   if  $D$  中样本全属于同一类别  $C$  then
3:     将  $node$  标记为  $C$  类叶结点
4:   end if
5:   if  $A = \emptyset$  OR 训练集  $D$  中样本在  $A$  上取值相同 then
6:     将  $node$  标记为叶结点, 其类别标记为  $D$  中样本数最多的类
7:   end if
8:   从  $A$  中选择最优划分属性  $a_i$ 
9:   for  $a_i$  的每一个值  $a_i^v$  do
10:    为  $node$  生成一个分支; 令  $D_v$  表示  $D$  中在  $a_i$  上取值为  $a_i^v$  的样本子集
11:    if  $D_v$  为空 then
12:      将分支结点标记为叶结点, 其类别标记为  $D$  中样本最多的类
13:    else 以  $DecisionTree(D_v, A/\{a_i\})$  为分支结点
14:    end if
15:  end for
16: end function
    
```

多个决策树依据 Bagging 思想集成为随机森林，随机森林结构图如下图 3.1 所示，随机森林模型通过加权平均每棵决策树的预测结果，获得最终的预测结果。

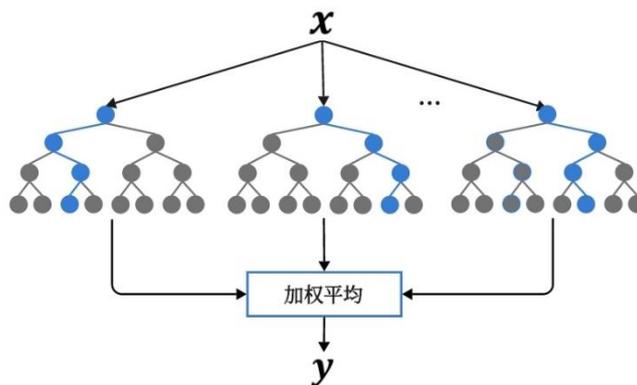


图 3.1 随机森林结构图

(2) 递归特征选择法 (RFE)

递归特征选择法是一种基于模型的特征选择法，通过反复训练模型剔除权重较低的特征来得到最优特征子集，本文选择的基础模型为随机森林。具体步

骤如下所示：

Step1: 初始化。以随机森林模型为训练的基础模型；

Step2: 特征重要性排序：通过随机森林模型输出各特征权重，本文使用 R^2 Score 作为评估模型拟合效果指标，并按照权重大小对特征进行排序；

Step3: 从特征集中剔除权重较低的特征，构建特征子集；并返回 Step2 重新训练模型获得新的子特征集；

Step4: 输出不同大小的子特征集和模型评估指标，选取模型拟合效果最佳的子特征集作为最优子特征集。

由于 RFE 可以自动选择最佳特征子集和最佳特征子集大小，降低了数据维度和模型复杂度，有效提高模型的可解释性和训练速度，同时也有效提高了模型的自适应能力和泛化性，因此 RFE 算法极为适用于原油价格预测这类特征复杂且数量较多的预测任务。

3.1.2 迁移学习

迁移学习（Transfer Learning）提出之初是为了解决训练集和预测集数据无法服从相同的分布或非同源特征空间难点，将为完成任务A的模型作为初始点，重新应用在任务B的模型开发过程中，通过模型已学习的相关任务来改进新的学习任务。由于国际原油价格波动具有易受多种突发因素影响的特点，往往单一时间段建模的油价预测模型难以处理长期的预测任务，因此本文引入了基于特征迁移学习思想，将源域与目标域的特征变换到同一特征空间，将经过历史数据训练好的模型作为初始点，处理出现突发因素影响下的油价预测任务。

3.1.3 双向长短期记忆神经网络

长短期记忆神经网络（LSTM）是一种改进的循环神经网络（RNN），解决了 RNN 由于梯度消失和梯度爆炸所导致的时间数据长距离记忆消失问题，是用预测时间序列数据的常用模型。LSTM 由三个部分组成，分别为输入层、输出层和隐藏层，其中 LSTM 的核心是位于隐藏层的 LSTM 神经元，LSTM 隐藏层网络结构如下图 3.2 所示。

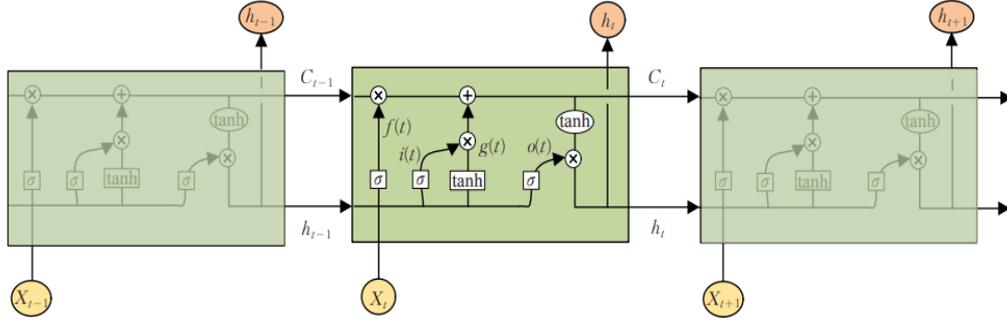


图 3.2 LSTM 结构图

LSTM 隐藏层由多个连接的单个 LSTM 神经元组成，单个 LSTM 神经元主要通过门结构控制信息流，可分为遗忘门、更新门和输出门，具体如下所示，其中， W 为更新权重， b 为偏置。

(1) 遗忘门

遗忘门决定了当前 LSTM 神经元状态 h_t 中保留多少上一时刻神经元 h_{t-1} 状态信息，表达式如下。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.1)$$

(2) 更新门

更新门决定了当前神经元状态 h_t 中保留多少当前的输入信息 x_t ，更新门的表达式如下式所示。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.2)$$

$$\hat{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3.3)$$

此时，上一时刻 $t-1$ 神经元状态的部分信息和 t 当前时刻的输入部分信息被保留到当前的神经元状态中，该更新公式如下：

$$c_t = f_t \odot c_{t-1} + i_t \odot \hat{c}_t \quad (3.4)$$

(3) 输出门

输出门决定了当前时刻 t 隐藏状态的输出值，通过激活函数将隐藏状态转换为预测值，具体公式如下所示。

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3.5)$$

$$h_t = o_t \odot \tanh(c_t) \quad (3.6)$$

$$y_t = \phi(W_y h_t + b_y) \quad (3.7)$$

在传统的递归神经网络模型和 LSTM 模型中，信息只能向前传播，导致时间 t 的状态只依赖于时间 t 之前的信息。为了使每一个时刻都包含上下文信息，使用 BiLSTM 结合了双向递归神经网络 (BiRNN) 模型和 LSTM 单元来捕获上下文信息。BiLSTM 是上述 LSTM 模型的扩展，其中两个 LSTM 应用于输入数据。如下图 3.3 所示，在第一轮中，在输入序列（即前向层）上应用 LSTM。在第二轮中，输入序列的反向形式被馈送到 LSTM 模型（即反向层）。应用两次 LSTM 可以改善学习长期依赖关系，从而提高模型的准确性。

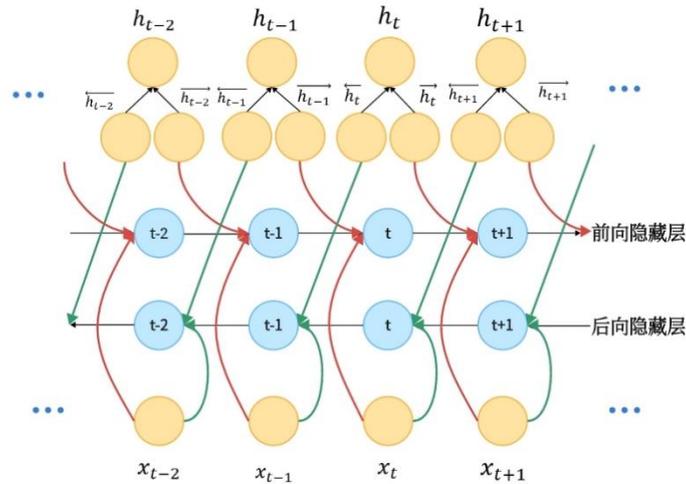


图 3.3 BiLSTM 结构图

3.1.4 卷积神经网络

卷积神经网络 (CNN) 主要用于挖掘独立同分布特征，CNN 保留了 DNN 多层感知器结构，改进了各网络层功能和形式，CNN 的网络结构可分为输入层、卷积层、池化层、全连接层和输出层，其中核心层级为卷积层、池化层和全连接层。

(1) 卷积层

卷积层是卷积神经网络最重要的一个层级，主要进行两个关键步骤：局部关联，每个神经元充当一个卷积核 (kernel)，kernel 的计算公式如下式(3.8)所示，其中 \mathbf{a} 代表经过输入层处理后的输入数据， \mathbf{b} 表示输出特征矩阵， \mathbf{w} 为卷积核参数，此处以二维数组举例；窗口滑动，即使用 kernel 对局部数据进行计算，挖

掘隐藏特征。

$$b[i, j] = \sum_{u, v} a[i + u, j + v] \cdot w[u, v] \quad (3.8)$$

(3) 池化层

池化层常设置于连续的卷积层中间，池化层常使用的方法包括有 Max pooling 和 average pooling，用于压缩向下层传递数据和参数的维数。一方面池化层保持特征不变，即向下一级传递特征信息时保留重要特征，压缩非重要特征；另一方面池化层可处理冗余数据，降低模型复杂度，提高模型处理数据速率并降低过拟合风险。

(4) 全连接层

全连接层常设置于 CNN 网络尾部，两层之间所有神经元都具有权重连接，用于进一步处理挖掘数据信息。

CNN 网络结构图如下图 3.4 所示，输入数据经过输入层、卷积层、池化层、全连接层和输出层处理为输出数据。由于 CNN 的参数共享机制，此处仅给出一个 Kernel 作为卷积层表示。ReLU 为激活层，对卷积层输出结果进行非线性映射，CNN 一般采用较多的激活函数为收敛速度快且求梯度简单的修正线性单元 (ReLU)。由结构图可以看出 CNN 与 DNN 结构非常相似，均保留了多层级的神经网络结构，可有效多层挖掘独立同分布的隐藏特征信息。

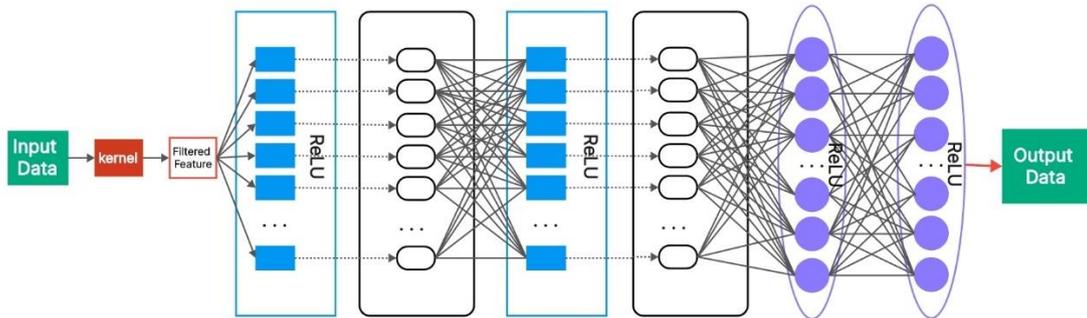


图 3.4 CNN 神经网络结构图

3.1.5 混合深度学习模型

BiLSTM-CNN 是 BiLSTM 和 CNN 组成的混合深度学习模型，结构如下图 3.5 所示，可分为四个组成部分，分别为输入部分、BiLSTM 部分、CNN 部分和输出部分。

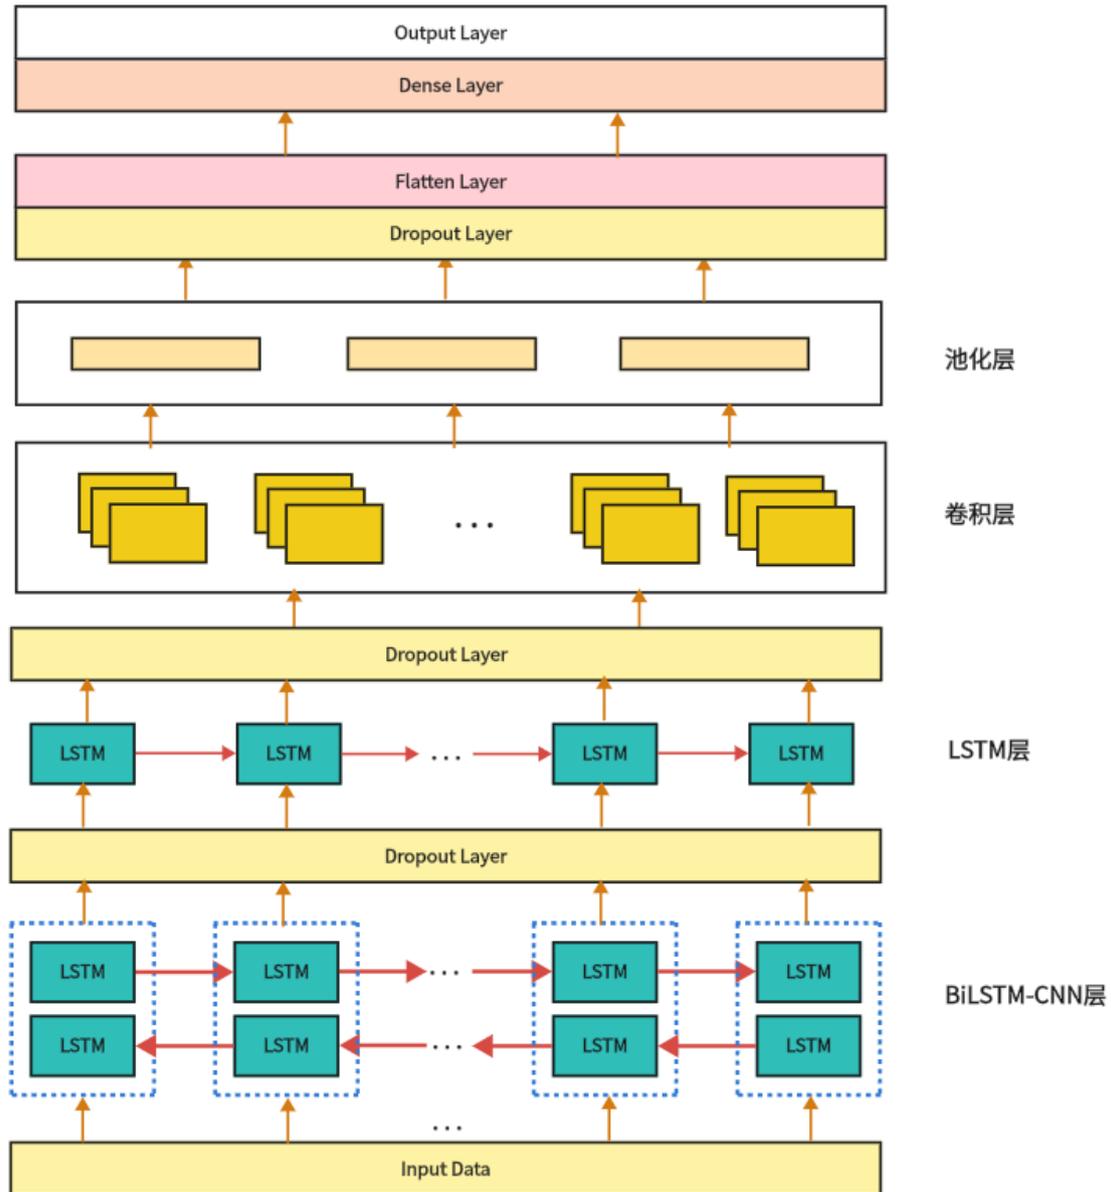


图 3.5 BiLSTM-CNN 结构图

(1) 输入部分

输入部分即输入层，接受模型输入数据并将数据处理为下一层神经网络可处理维度。由于 BiLSTM 模型具有特殊的时间步长记忆力功能，因此输入数据

预处理阶段需要做好时间步长封装。

(2) BiLSTM 部分

BiLSTM 部分包括 BiLSTM 层和 LSTM 层以及分别插入神经网络层之后的 Dropout 层，Dropout 层主要用于降低神经网络层神经元连接数量，降低模型复杂度以降低模型过拟合。

(3) CNN 部分

CNN 部分包括有卷积层、池化层、Dropout 层、拉直层和全连接层。CNN 隐含层的卷积层和池化层交替组合是实现卷积神经网络特征提取功能的核心模块，高层是全连接层对应传统多层感知器的隐含层和逻辑回归分类器，CNN 用来处理独立同分布数据，擅长对局部特征进行捕捉。

(4) 输出部分

输出部分即输出层，将经过 BiLSTM-CNN 特征提取及非线性拟合处理后的多维数据，经过参数值取 1 的全连接层映射为目标预测数值。

BiLSTM-CNN 模型在 BiLSTM 网络的隐藏层后接入 CNN 模块，将 BiLSTM 模块的输出作为 CNN 模块的输入，依次通过卷积层和池化层对输入层的数据进行局部特征的处理最终通过全连接层和激活函数的作用得出最终的预测结果。

3.1.6 经验模态分解模型

经验模态分解模型（EMD）是一种针对时域频的小波分析方法，相比于其他小波分析方法依赖对小波基的选取，EMD 的改进在于其克服了无自适应基函数的问题，模型的自主适应性显著提高，使得 EMD 适合处理高噪声、非线性和非平稳的时间序列数据，其本质是对信号的平稳化处理，理论上可以分解任何类型的时序数据。

本征模函数（IMF）是原始信号经 EMD 分解后得到的各频段的子信号分量，IMF 需要满足以下两个条件：在整个 IMF 分量数据空间中，极值点和过零点的个数必须相等或相差不能大于 1；在任意时刻由局部极大值点构成的上包络线和局部极小值点构成的下包络线均值为 0，即关于横轴对称。通过 IMF 的定义和要求，EMD 分解信号步骤可如下理解：

Step1: 基于原始信号的局部极大值点和局部极小值点分别做出上下包络线，

并求出上下包络线均值包络线；

Step2: 原始信号减去均值包络线，得到中间信号，判断中间信号是否满足 IMF 要求，若满足则认为该中间信号为原始信号分解的 IMF 分量之一，若不满足则返回 Step1，在中间信号的基础上继续构建包络线，直到残余的中间信号满足 IMF 要求，通常得到一个 IMF 分量需要经过多次迭代；

Step3: 用原始信号减去 Step2 得到的 IMF 分量，残余信号认为成新的原始信号，再次经过 Step1 和 Step2 获得 IMF 分量，直到分解完成。因此通常可以将原始信号看作单一频率波和残波的和，表达式如公式(3.9)所示，*res*为残波。

$$\text{原波形} = \sum \text{IMFs} + \text{res} \tag{3.9}$$

3.2 EBC 模型设计

本文所提出的 EBC 预测模型将 EMD 经验模态分解模型与 BiLSTM-CNN 混合模型相结合，下文将从模型结构和模型预测流程分别进行介绍。

3.2.1 EBC 模型结构

EBC 模型结构如下图 3.6 所示，可以看出 EBC 是基于 EMD 分解集成框架构建的混合集成深度学习模型。EBC 主要由两个部分组成，EMD 是主框架，其作用在于将预测数据分解为 IMF 分量，根据各 IMF 分量特性重构为高频、低频和趋势分量；BiLSTM-CNN 将对 IMF 重构分量进行预测，并通过加权集成重构各分量回归结果，输出真正的预测结果。

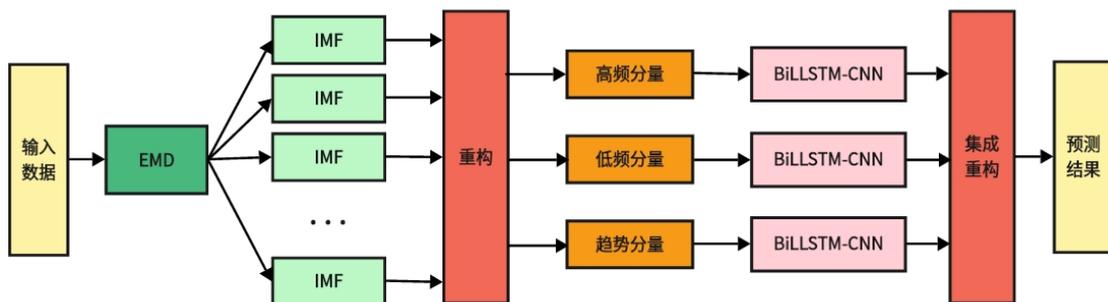


图 3.6 EBC 结构图

3.2.2 EBC 模型预测流程

本文所提出的 EBC 模型的预测流程如下图 3.7 所示，可大致分为三个部分：数据预处理、EBC 模型预测和模型评价，细分为六个小步骤。

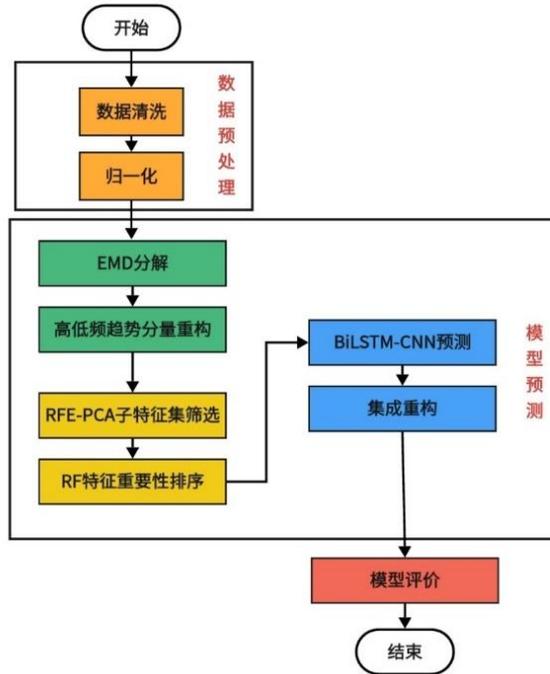


图 3.7 EBC 模型预测流程图

Step1: 数据初始化。将经过预处理后的数据和特征指标按时间顺序组合为样本集，以 7: 2: 1 的比例分为训练集、验证集和预测集；

Step2: EMD 分解重构。将训练集和验证集的传入 EMD 模型进行模态分解，分解之后的数据由 n 个 IMF 分量和特征指标组成，对高低频和趋势分量进行重构，多角度挖掘油价的历史波动信息和隐含信息波动等。

Step3: 基于不同分量的特征选择。由于不同分量与特征指标的映射目标不同，需要根据不同的映射构建不同的模型，本文使用 RFE-RF 分别对三个分量进行特征选择。

Step4: 基于不同分量的 BiLSTM-CNN 训练。将三个分量与其对应的特征子集分别传入 BiLSTM-CNN 进行训练，获得三个针对高低频和趋势分量预测目标的预测模型，并保存模型参数用以迁移学习训练。

Step5: 分量集成重构。将三个分量的预测向量加权平均获得 EBC 最终的预测结果。

4 国际原油价格预测模型实证

通过上文所构建的 EBC 模型，下文将按 EBC 集成模型处理数据的流程顺序，逐一详细分析 WTI 原油价格预测任务的过程。

4.1 国际原价格预测实验设计

4.1.1 国际原油价格预测实验思路设计

本文的研究目标是构建一个准确预测国际原油价格波动的迁移混合深度集成模型，并验证其实际应用价值，因此实验主要分为四个部分，第一部分为构建国际原油价格预测模型，第二部分为国际油价预测模型的预测结果评价分析，第三部分为基于特征迁移学习思想构建的国际油价预测模型，第四部分为 WTI 原油现货价格预测值的应用，具体如下图 4.1 所示。

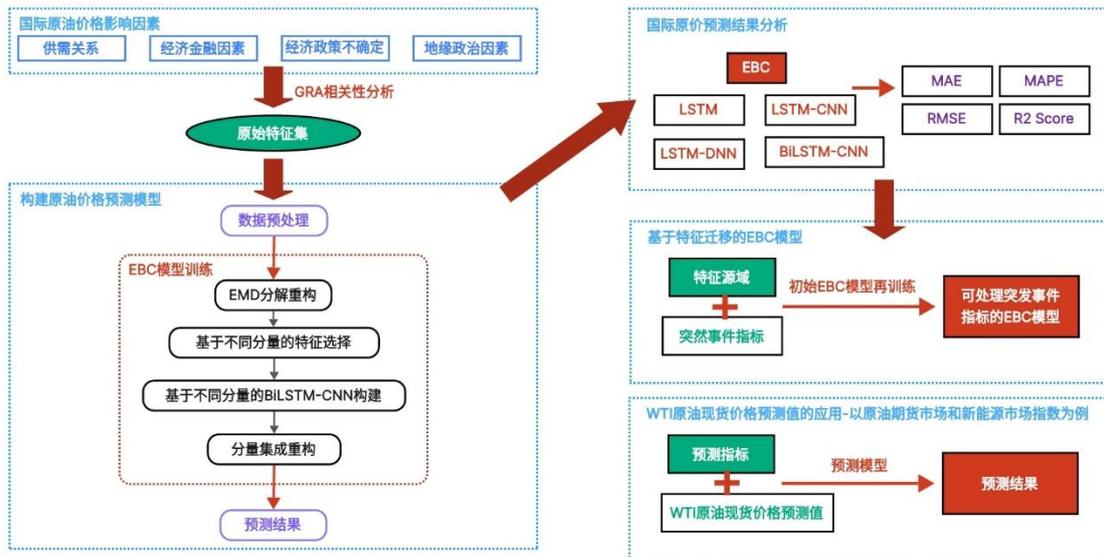


图 4.1 实验思路设计

4.1.2 国际原油价格预测模型评价指标

模型评估常常作为预测任务的最后一步，其计算的评价指标是评判模型预测能力优劣的重要判断标准。本文选用了平均绝对误差（Mean Absolute Error, MAE）、均方根误差（Root Mean Square Error, RMSE）、平均绝对百分比误差

(Mean Absolute Percentage Error, MAPE) 和决定系数 (R^2 Score) 作为模型的评价指标, 具体如下, 其中 y_i 、 \hat{y}_i 和 \bar{y}_i 分别为真实值、预测值和平均值, n 则为真实数据集的大小。

(1) 平均绝对误差

MAE 是真实值与预测值的差值绝对值的平均, 用来比较成对数值的误差, MAE 取值越小代表着模型的预测效果越好。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.1)$$

(2) 均方根误差

RMSE 则是真实值与预测值平方和均值的开方, 是度量模型预测效果的常用指标。RMSE 取值越小代表着模型的预测效果越好。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.2)$$

(3) 平均绝对百分比误差

MAPE 用于衡量真实值与预测值之间的误差百分比。MAPE 取值越接近 0 代表着模型的预测准确度越高。

$$MAPE = \left(\frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \right) \times 100\% \quad (4.3)$$

(4) 决定系数

R^2 Score 常用于评价回归模型的拟合程度。 R^2 Score 取值越接近 1 代表着模型的拟合效果越好, R^2 Score 越接近 0 代表着模型的拟合效果越差。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (4.4)$$

4.2 国际原油价格预测实验过程

4.2.1 数据预处理

数据预处理包含三个部分，第一部分是预测数据的排序、补足空值，即数据清洗过程；第二部分是对特征数据的标准化；第三部分是将样本数据切分为训练集验证集和测试集。

(1) 数据清洗

由于获取的数据来源不同，特征指标数据集与原油 WTI 价格数据集的排序方式不同，本文按照时间索引，以升序的方式重新排列数据，并找出了 117 个空值，本文使用均值插值法填补空值。

(2) 数据标准化

考虑到特征指标的标准不同，例如本文所选取的美元指数与伦敦现货黄金价格之间存在巨大的数据量级差异，因此必须对特征指标数据集进行标准化处理。本文使用了极差标准化法，该方法计算公式如下式(4.5)所示，具体计算过程为找出该指标的最大值 X_{max} 和最小值 X_{min} ，使用每一个观察值 X 减去 X_{min} ，再除以 X_{max} 与 X_{min} 的差值，经过极差标准化法处理后的特征指标数据集将在[0,1]范围内变化。

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (4.5)$$

(3) 数据切分

将处理好的特征集与预测目标值按时间顺序组合为样本集，并按 7: 2: 1 的比例分为训练集、验证集和测试集，训练集用来训练样本，寻找模型的最优超参，验证集用来测试模型的预测效果，辅助训练集寻优，测试集的作用则是观察模型的泛化能力并防止模型过拟合。

4.2.2 EMD 分解重构

(1) EMD 分解

根据本文所提出的 EBC 预测模型，输入数据首先进入 EMD 分解模块，该

模块分解结果和原始数据（WTI）如趋势图如下图 4.2 所示，原始数据信号被分为 8 个 IMF 分量，IMF 1~IMF 8 是 IMF 分量，自高频到低频的顺序依次排列，*res* 是余波分量，代表着原始信号的趋势。

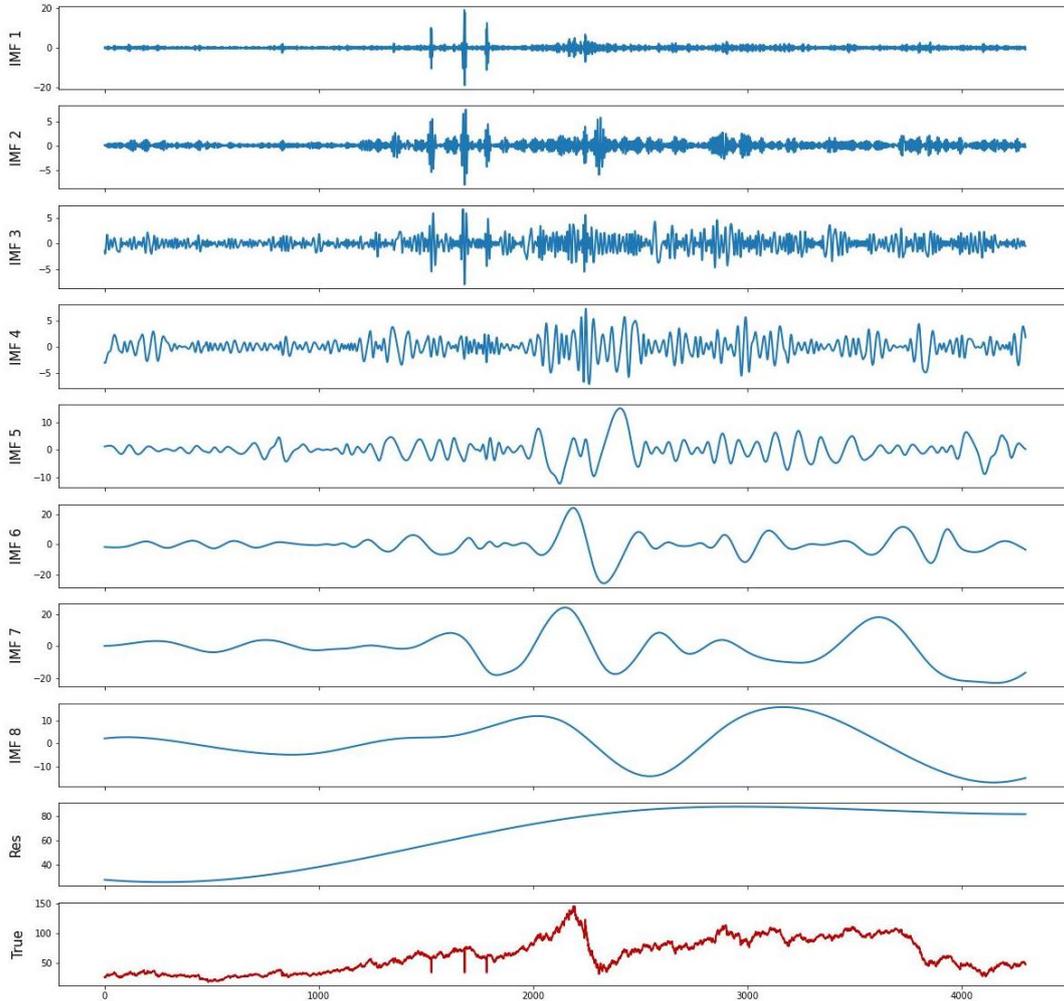


图 4.2 EMD 分解结果分量图

IMF 分量和的方差贡献比和 Spearman 相关系数在表 4.1 给出，研究表明 IMF 1~IMF 4 对原始信号的相关性较弱，但平均周期短，IMF 5~IMF 8 对原始信号的相关性较大，且平均周期逐渐增大。于是可以将 IMF 1~IMF 4 视为 WTI 原油价格的短期波动，IMF 5~IMF 8 看作 WTI 原油价的长期波动。从短期波动来看，WTI 现货价格变动具有高度随机性和非线性，因此使用传统的计量经济方法或机器学习方法预测 WTI 现货价格波动，常常不能取得很好的预测效果；从长期波动来看，长期趋势的方差贡献比占比最高，是影响 WTI 现货价格的主要因素，因此提高对 WTI 原油现货价格的全局特征提取，可以有效提高模型预测精度。

表 4.1 各分量方差贡献比

分量	方差贡献比	相关系数
IMF 1	0.3579%	0.0345
IMF 2	0.2933%	0.0411
IMF 3	0.5358%	0.0684
IMF 4	1.0784%	0.0361
IMF 5	8.1707%	0.2638
IMF 6	6.4802%	0.2641
IMF 7	36.7441%	0.6237
IMF 8	8.5679%	0.6578
<i>res</i>	31.4207%	0.5215

值得注意的是 IMF 7 和 IMF 8 反映了原始信号的局部特征，因此使用 BiLSTM-CNN 预测包括 IMF 7 和 IMF 8 的重构分量时可以适当增加 CNN 权重，以提高模型在局部特征的选择能力；其他分量为随机分量，反映着 WTI 原油现货价格波动的随机性。并且以上 IMF 分量都均匀地分布在横轴两侧，在预测非平稳数据任务中展现出稳定性，对后续 BiLSTM-CNN 的预测提供了稳定的数据样本。

(2) 高低频分量和趋势分量重构

为了更好地分析 WTI 原油价格的影响因子，分别对高频分量 (IMF_{High}) 和低频分量 (IMF_{Low}) 和趋势分量 (IMF_{Trend}) 进行重构。趋势分量为 *res* 余波，高低频分量重构的关键在于如何区别高低频分量，本文采用 T 检验进行验证，重构步骤如下所示：

Step1: 将 IMF 1 记为 $Alpha_1$ ，IMF 1 和 IMF 2 分量和记为 $Alpha_2$ ，以此类推，分别将 8 个 IMF 分量叠加为 8 个 $Alpha$ 指标；

Step2: 分别对 $Alpha$ 指标求均值，对 8 个均值进行是否显著区别于 0 的 T 检验，检验结果如下图 4.3 所示，明显发现 $Alpha_5$ 首次出现 p 值小于 0.05 的情况，即认为 $Alpha_5$ 的均值显著不为 0，因此认为 IMF 1~IMF 4 为高频分量，IMF 5~IMF 8 为低频分量；

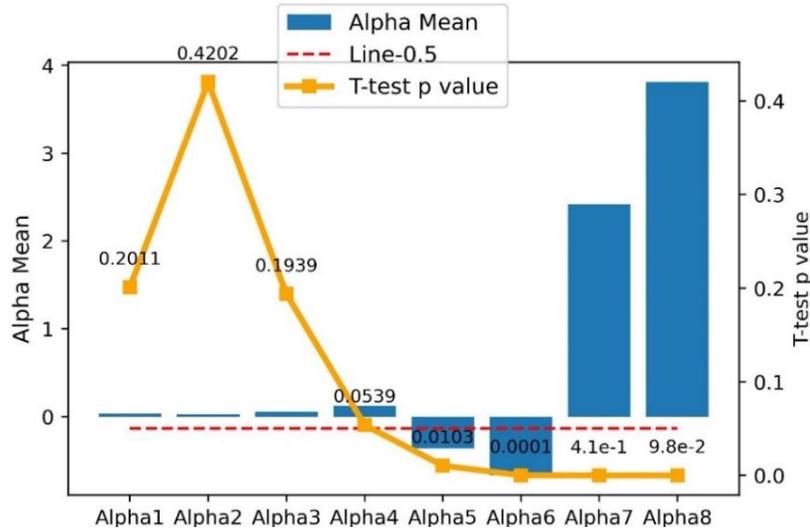


图 4.3 IMF 均值和 T 检验结果图

Step3: 分别对预测后的 IMF 高频和低频分量进行重构, 重构结果如下图 4.4 所示, 可以直观地看到高频分量在局部特征上表现良好, 低频数据表现出全局特征, 趋势向量反映出原始信号的变化趋势。

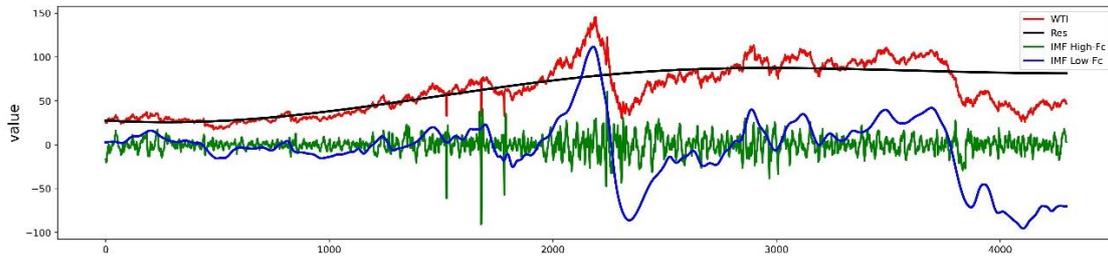


图 4.4 高低频趋势分量重构图

4.2.3 基于不同分量的特征选择

根据经验选择的特征值往往不能很好地完成预测任务, 因此需要通过各特征指标的重要性排序对最优特征子集进行选择。本文使用基于随机森林 (RF) 的递归特征选择法 (RFE) 对特征指标进行降维, 步骤如下:

Step1: 通过 5 折交叉验证训练训练 RF 模型, 计算候选特征子集的各特征权重, 并根据权重大小进行排序, 去除权重最小的特征指标, 组成新的特征子集;

Step2: 使用 R^2 Score 判断新构成的特征子集是否为最优, 若为最优子集则输出该子集为最优特征集合, 若该子集不为最优, 则返回 Step1 继续计算, 直到

获取最优子集。

图 4.5 为 RFE 算法计算不同大小特征子集的模型评价结果，表 4.2 为 RFE-RF 特征选择的结果，高频低频分量和趋势分量的最优子特征集维度分别为 12、15 和 16。可以看出随着特征集大小增加，模型的拟合效果整体呈现波动上涨并趋于平缓的趋势，一般情况下特征指标的个数越多，机器学习的表现就越好，但过度的特征描述易造成过拟合，降低模型的泛化能力，因此针对不同预测任务和不同的预测模型进行特征选择是极为重要的一步。

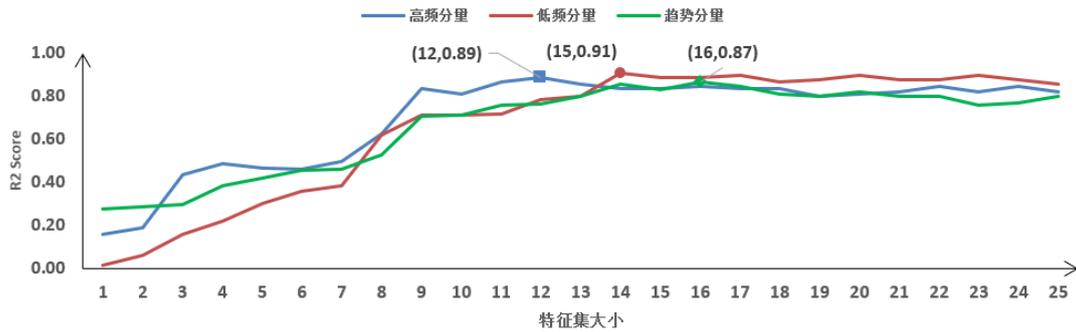


图 4.5 RFE 特征选择R² Score评价结果

表 4.2 RFE-RF 特征选择结果

分量类型	高频分量		低频分量		趋势分量	
最优特征集大小	12		15		16	
指标编码	权重	是否保留	权重	是否保留	权重	是否保留
T ₁	0.0126	Y	0.0881	Y	0.0672	Y
T ₂	0.0186	Y	0.0840	Y	0.0057	N
T ₃	0.0077	N	0.0089	N	0.0097	Y
T ₄	0.1489	Y	0.0317	Y	0.0866	Y
T ₅	0.0356	Y	0.0735	Y	0.6266	Y
T ₆	0.0079	N	0.0196	Y	0.0109	Y
T ₇	0.1293	Y	0.0103	N	0.0251	Y
T ₈	0.0466	Y	0.0120	N	0.0107	N
T ₉	0.0276	Y	0.0385	Y	0.0039	N
T ₁₀	0.0230	Y	0.0531	Y	0.0231	Y
T ₁₁	0.0113	N	0.0491	Y	0.0190	Y
T ₁₂	0.0095	N	0.0085	N	0.0192	Y
T ₁₃	0.3203	Y	0.0964	Y	0.0234	Y
T ₁₄	0.0035	N	0.0218	N	0.0054	N

续表 4.2 RFE-RF 特征选择结果

分量类型	高频分量		低频分量		趋势分量	
	12		15		16	
最优特征集大小	权重	是否保留	权重	是否保留	权重	是否保留
T_{15}	0.0048	N	0.0170	N	0.0175	Y
T_{16}	0.0033	N	0.0134	N	0.0150	Y
T_{17}	0.0063	N	0.0340	Y	0.0177	Y
T_{18}	0.1115	Y	0.0109	N	0.0119	Y
T_{19}	0.0078	N	0.0156	N	0.0122	Y
T_{20}	0.0321	Y	0.0216	Y	0.0056	N
T_{21}	0.0020	N	0.0244	Y	0.0030	N
T_{22}	0.0071	N	0.0180	Y	0.0032	N
T_{23}	0.0123	Y	0.1635	Y	0.0024	N
T_{24}	0.0046	N	0.0141	N	0.0122	Y
T_{25}	0.0058	N	0.0721	Y	0.0037	N

4.2.4 基于不同分量的 BiLSTM-CNN 训练

本文将 BiLSTM-CNN 混合模型加入 EMD 分解算法，分别在重构的分量空间 (IMF_{High} 、 IMF_{Low} 和 IMF_{Trend}) 中训练模型，即需要训练三次。需要注意的是，BiLSTM 模块具有数据记忆能力，因此数据传入预测模型之前，首先要进行时间滑窗的封装，本文选择记忆天数为 5 天，预测步长为 1 天，即在时间轴上设定大小为 5 天的时间滑窗，以滑动步长为 1 的速度在时间轴上前进，每天为一组输入数据，直至滑动到时间轴末端。

在三组训练任务中，EBC 需要寻优超参有 BiLSTM 层神经元数量 (BiLSTM Units)、LSTM 层神经元数量 (LSTM Units)、CNN 卷积核大小 (Filter) 和丢失率 (Dropout Rate)，如下表 4.3 所示。

为了验证 EBC 模型的稳定性、有效性，本文选取了四个对比模型 (LSTM、LSTM-DNN、LSTM-CNN 和 BiLSTM-CNN) 与 EBC 的预测结果进行比较分析，对比模型的超参设定如下表 4.4 所示。

表 4.3 EBC 超参取值范围

模块	神经网络层	超参及取值范围
BiLSTM	BiLSTM Layer	BiLSTM Units: [128,512]
	LSTM Layer	LSTM Units: [64,128]
	Dropout Layer	Dropout Rate: 0.2
	Conv Layer	Fliter: [64,512]
CNN	MaxPooling Layer	Pool Size: 1
	Flatten Layer	Default
	Dense Layer	Dense Units: [32,128]
OutPut	Output Layer	Dense Units: 1

表 4.4 对比模型超参

模型	神经网络层	超参及取值范围
LSTM	LSTM Layer	LSTM Units: 32
	LSTM Layer	LSTM Units: 32
	Dropout Layer	Dropout Rate: 0.1
LSTM-DNN	LSTM Layer	LSTM Units: 64
	Dropout Layer	Dropout Rate: 0.1
	Dense Layer	Dense Units: 128
LSTM-CNN	LSTM Layer	LSTM Units: 128
	LSTM Layer	LSTM Units: 64
	Dropout Layer	Dropout Rate: 0.1
	Conv Layer	Fliter: 64
	MaxPooling Layer	Pool Size: 1
BiLSTM-CNN	Dense Layer	Dense Units: 32
	BiLSTM Layer	BiLSTM Units: 64
	LSTM Layer	LSTM Units: 128
	Dropout Layer	Dropout Rate: 0.2
	Conv Layer	Filter: 64
	MaxPooling Layer	Pool Size: 1
	Dense Layer	Dense Units: 128

为了保证对比过程的公平性，部分超参不加入寻优过程，包括批大小（Batch Size）取 64，迭代次数（Epochs）取 32，激活函数（Activation）取 Relu，优化函数（Optimier）取 Adam，学习率为 0.001，并均采用随机搜索算法，最大寻优次数为 50 次，记忆天数取 5 天，预测步长都为 1 天。

4.2.5 分量集成重构

信号重构是 EMD 分解算法的重要步骤之一，本文选取加和的方式进行重构，针对本文的 WTI 现货价格数据，重构公式如公式(4.6)所示， \widehat{IMF}_{High} 为高频分量的预测值， \widehat{IMF}_{Low} 是分量的预测值， \widehat{IMF}_{Trend} 为趋势分量的预测值， \hat{y}_{WTI} 是 WTI 原油现货价格的预测值。

$$\hat{y}_{WTI} = \widehat{IMF}_{High} + \widehat{IMF}_{Low} + \widehat{IMF}_{Trend} \quad (4.6)$$

4.3 国际原油价格预测结果分析

预测任务往往需要对模型的预测能力进行评判，常用模型评价指标和选择对比模型作为评判的标准，本文选择常用的四类时序数据预测模型作为对比模型，分别为 LSTM、LSTM-DNN、LSTM-CNN 和 BiLSTM-CNN。

下图 4.6 为各模型在测试集的拟合结果，LSTM 和 LSTM-DNN 表现出了明显的滞后性，滞后天数为时间滑窗大小 5 天，可以认为这两个模型的预测结果不具有实际应用的价值；LSTM-CNN 和 BiLSTM-CNN 则相较于 LSTM 和 LSTM-DNN 拟合效果较好，但在拐点处，LSTM-CNN 拟合过于敏感，出现了浮动过早的问题，而 BiLSTM-CNN 整体拟合比 LSTM-CNN 更优，但在曲线仅有较小波动情况的拐点，出现了只能拟合波动趋势不能准确预测原油价格的问题；而对比六个预测模型，EBC 的预测曲线几乎与原始数据重合，拟合效果最好，验证了 EBC 集成模型的有效性。

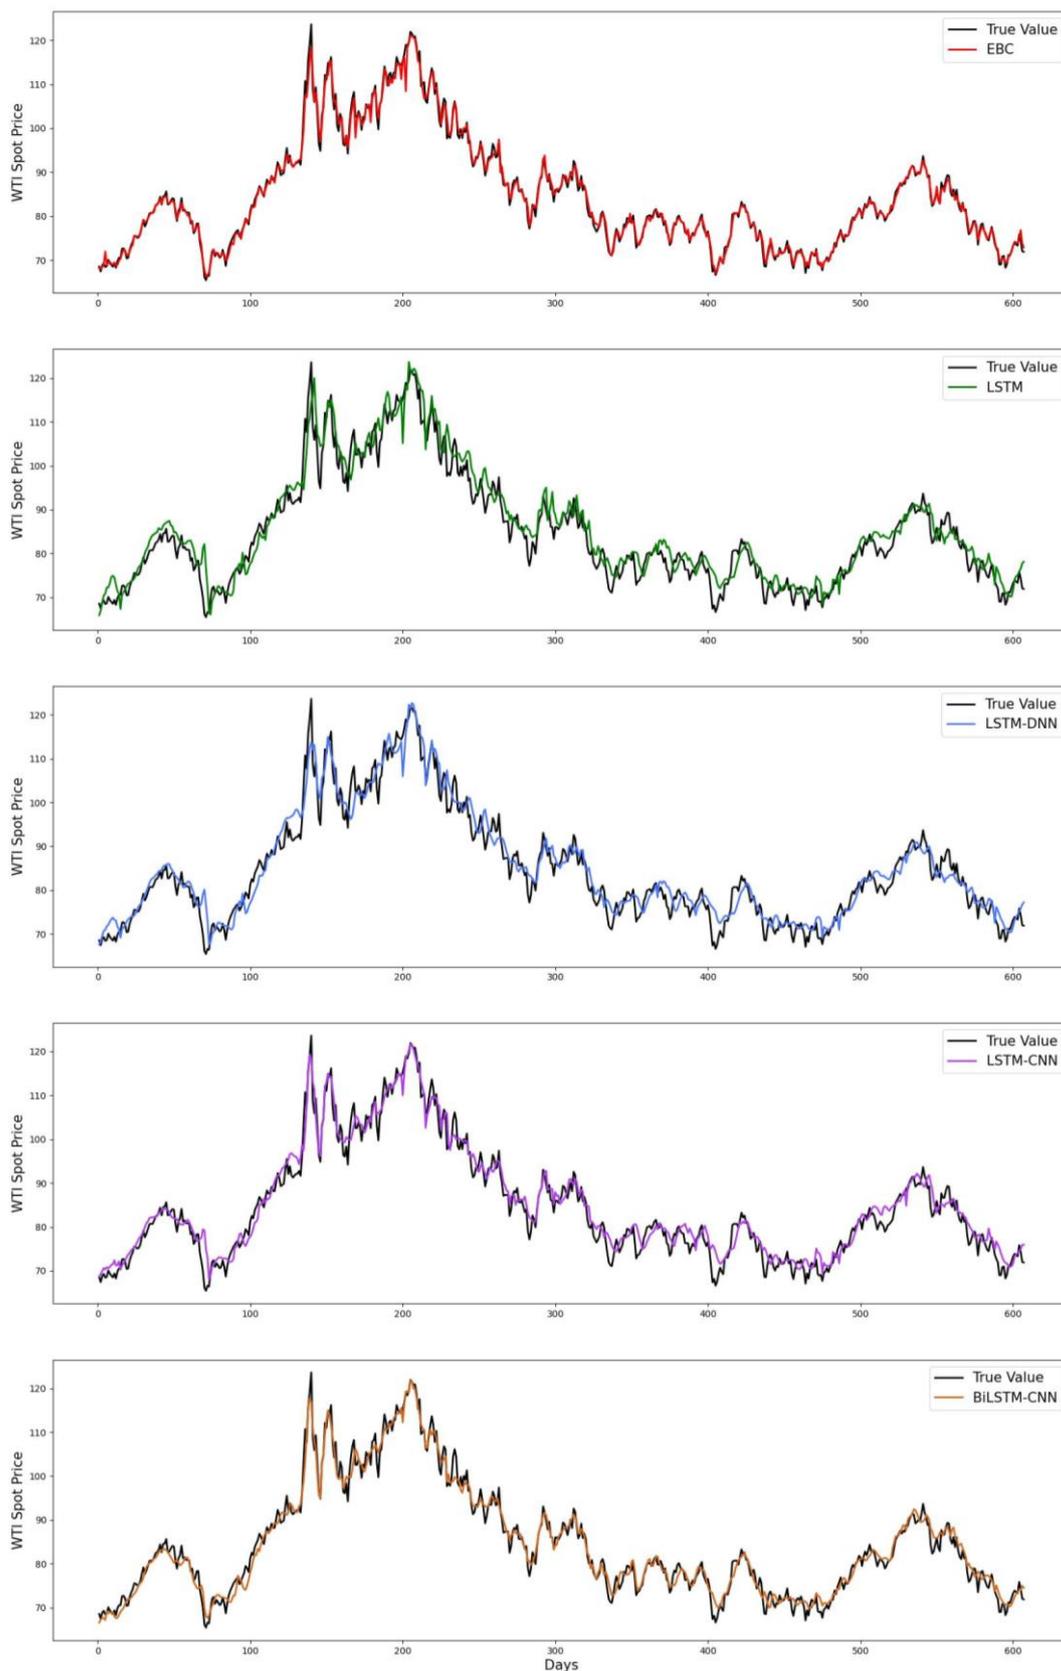


图 4.6 各模型预测结果图

通过预测结果图可以观察到各模型的预测整体情况，下表 4.5 给出了各模型

拟合结果的评价指标数值，可以看出 LSTM 和 LSTM-DNN 的评价指标表现较差，考虑到模型预测结果的滞后性，虽然在拐点的预测能力较为优秀，但对比评价指标显示整体预测效果较差，不具有实际价值；LSTM-CNN 和 BiLSTM-CNN 的 MAE 和 RMSE 表现较好，BiLSTM-CNN 的评价指标数值略小于 LSTM-CNN，BiLSTM 模块相较于 LSTM 模块增加了双向训练思想，可以更好地提取全局特征，此处预测结果也很好地证明了双向结构的优越性，这也是本文选择 BiLSTM-CNN 与 EMD 模型结合的原因。EBC 集成模型有着五个模型最小的 MAE、RMSE 和 MAPE 数值，相较于 BiLSTM-CNN，MAE 下降了约 48.8%，RMSE 下降了约 41.8%，MAPE 下降了约 51.7%，验证了在 BiLSTM-CNN 模型上融合 EMD 预测 WTI 原油现货价格的可行性。

表 4.5 各模型评价指标

模型	评价指标			
	MAE	RMSE	MAPE	R^2 Score
EBC	0.7607	1.1287	0.0086	99.2%
LSTM	2.6145	3.4873	0.0313	92.7%
LSTM-DNN	2.3841	3.1069	0.0285	94.2%
LSTM-CNN	2.0107	2.6383	0.0246	95.8%
BiLSTM-CNN	1.4844	1.9403	0.0178	97.7%

4.4 构建基于特征迁移的国际油价模型

由于原油价格波动的影响因素具有复杂性，且对突发事件敏感，不同时期构建的预测模型往往很难维持长期的高精度预测效果，本文引入迁移学习的思想，将原始特征空间视为源域，加入新的指标特征空间为目标域，通过使用训练过的模型再训练，构建从源域到目标域的映射，使模型能够胜任在不同时间段和不同的特征集下的预测任务，迁移学习可有效提高模型的自适应能力、泛化能力，降低模型训练时间，提高模型时效性，降低模型的维护成本，并降低模型训练所需数据的复杂度。

本文以 2020 年 1 月至 2021 年 12 月新冠疫情时期国际油价预测任务为例，

选取指标为世界卫生组织（World Health Organization, WHO）统计每月与新冠肺炎大流行相关的平均超额死亡人数，该指标与油价波动趋势对比如下图 4.7 所示，可以看出随着疫情死亡人数下降，国际油价逐渐回升，二者呈负相关作用。



图 4.7 疫情指标与油价波动对比图

引入疫情指标并对模型再训练，最优模型的超参值取值范围如下表 4.6 所示，其中 Batch Size、Epochs、Activation、Optimizer 和学习率不变，采用随机搜索算法，最大寻优次数为 50 次，记忆天数取 5 天，预测步长为 1 天。

表 4.6 特征迁移 EBC 模型超参取值范围

模块	神经网络层	超参及取值范围
BiLSTM	BiLSTM Layer	BiLSTM Units: [64,512]
	LSTM Layer	LSTM Units: [128,512]
	Dropout Layer	Dropout Rate: 0.1
	Conv Layer	Fliter: [64,128]
CNN	MaxPooling Layer	Pool Size: 1
	Flatten Layer	Default
	Dense Layer	Dense Units: [64,128]
OutPut	Output Layer	Dense Units: 1

预测结果如下表 4.7 所示，其中基于特征迁移的 EBC 模型编号为Model₃，使用未加入疫情指标的 EBC 模型、加入疫情指标重新训练的 EBC 模型作为对比模型，分别建立模型编号Model₁和Model₂，可以看出未加入新冠指标的模型预测效果最差，加入新冠指标重新训练的模型综合评价指标较优，但单次训练时长远超迁移学习模型，而本文提出的特征迁移的 EBC 模型R²评分达到了 98.9%，

甚至 MAE 评价指标优于 $Model_2$ ，有效验证了指标迁移 EBC 模型的实际应用价值和时效性。

表 4.7 特征迁移 EBC 模型预测结果

模型	评价指标				单次训练
	MAE	RMSE	MAPE	R^2 Score	时间
$Model_1$	3.0279	3.9351	6.0535	96.2%	3min 36s
$Model_2$	2.0681	1.9584	3.5985	99.1%	3min 56s
$Model_3$	1.9907	2.1409	3.5865	98.9%	1min 21s

4.5 WTI 原油现货价格预测值的应用

WTI 现货价格常常影响着世界的经济发展，因此有效 WTI 原油价格对国内投资者和受原油价格影响的市场有着重要意义，本文将给出两个 WTI 原油现货预测价格的应用。

4.5.1 WTI 原油期货价格预测

WTI 原油期货与现货不同在于交易机制、资金利用率、交易时间和涨幅限制，对于国内的众多投资者来说，能够较为准确地预测原油期货价格，可有效规避风险并提高资源配置利用率。

本文选取实验数据选取 2014 年 1 月 1 日至 2023 年 1 月 1 日 WTI 期货收盘价作为预测目标，共计 2066 条数据，数据来自股票网站 (<https://stooq.com/>)，以 7: 2: 1 的比例按时间顺序划分为训练集、验证集和测试集。为了公正判断 WTI 预测原油价格是否能够提高 WTI 期货价格预测精度，在 WTI 原油期货价格预测任务中设置了两个实验组，实验组 A 的预测指标为开盘价、最高价、最低价和成交额；实验组 B 的预测指标加上上文 WTI 原油现货价格预测结果。选取上文表现较优的 BiLSTM-CNN 作为预测模型，考虑到股价预测任务的时效性，使用网格搜索算法寻优，寻优结果如下表 4.8 所示，其余未寻优超参设定与上文相同以保证对比结果的可信度。

表 4.8 BiLSTM-CNN 超参数值

超参	实验组	
	实验组 A	实验组 B
BiLSTM Units	104	96
LSTM Units	128	88
Dropout Rate	0.2	0.2
Filter	56	128
Pool Size	1	1
Dense Units	64	112

下图 4.8 为实验 AB 组的预测结果，其中红色的预测曲线为实验 B 组即加入了 WIT 原油预测现货价格指标，蓝色的预测曲线为实验 A 组即不加入 WTI 原油预测现货价格指标。由于 BiLSTM-CNN 优秀的预测能力，实验 AB 组均未出现明显的滞后性，两条曲线都很好拟合出了原始数据的整体趋势，但观察拐点研究表明预测结果较为悬殊，实验 A 组的拟合曲线对于大部分极值点的预测均存在明显误差，而实验 B 组的拟合曲线几乎与原始数据曲线重合，可以认为实验 B 的拟合效果远优于实验 A 组。

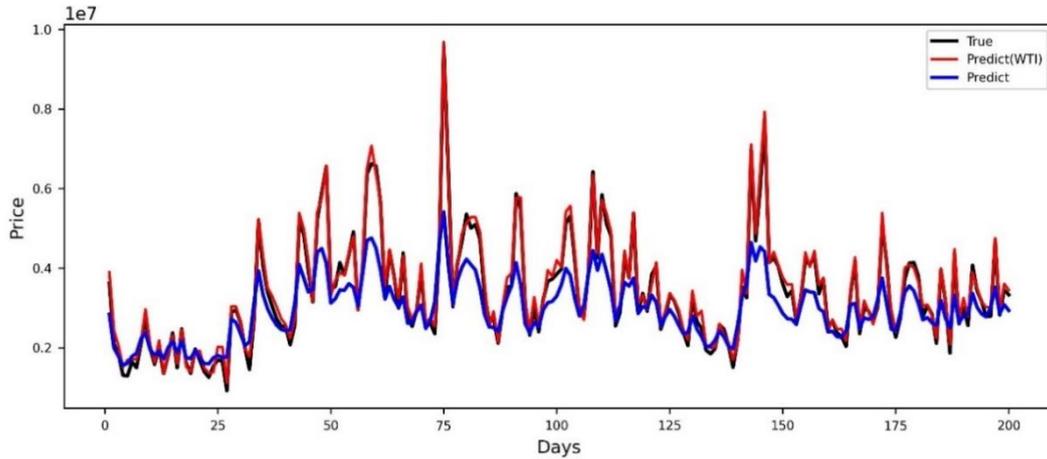


图 4.8 WTI 期货价格预测结果图

从数值的角度来看，分析预测结果如下表 4.9 所示，当预测数据量级过大时，MAE 和 RMSE 的量级也随之增大，实验 B 组相较于实验 A 组 MAE 和 RMSE 都有明显下降，观察 R^2 Score 发现，实验 B 组的拟合度较好，相比于实验 A 组上升了约 53.7%，结合上图的预测结果来看，说明了加入 WTI 现货预测价格作为

WTI 期货预测任务指标的可行性。

表 4.9 WTI 期货价格预测评价指标

实验组	评价指标		
	MAE	RMSE	R^2 Score
实验组 A	7.6135	8.6433	64.12%
实验组 B	2.4727	5.9117	96.55%

4.5.2 新能源市场指数预测

除去和原油市场紧密联系的 WTI 期货，新能源市场也受到了原油市场的影响，目前我国较为常规的新能源行业包括有风力发电、光伏发电、光热发电、核能、水力发电、生物质能、潮汐能地热能等等，因提倡绿色发展思想，新能源汽车等二级新能源市场也成为了近几年的新兴产业，本文选取新能源市场指数作为该市场发展情况的数值体现，自 2014 年 1 月 1 日至 2023 年 1 月 1 日，共 2056 条数据，以 7: 2: 1 的比例按时间顺序分割为训练集、验证集和测试集。同样采用与 WTI 期货预测任务相同的实验方法，实验 A 组的预测指标为开盘价、最高价、最低价、成交额，实验 B 组加上 WTI 原油现货价格的预测值作为指标，使用 BiLSTM-CNN 作为预测模型，超参设定如下表 4.10 所示。

表 4.10 BiLSTM-CNN 超参数值

超参	实验组	
	实验组 A	实验组 B
BiLSTM Units	72	128
LSTM Units	128	88
Dropout Rate	0.2	0.1
Filter	72	112
Pool Size	1	1
Dense Units	88	64

图 4.9 给出了实验 AB 组的预测结果，与上文的预测结果类似，虽然实验

AB 组都很好地预测了新能源市场股指的整体趋势，但实验 B 组依旧展现出了比实验 A 组更好的拟合效果，实验 B 组的预测曲线几乎与真实值曲线重叠，而实验组 A 则在 25 天至 50 天股指剧烈上升时表现出了滞后性，可以认为从预测结果图来看，加入 WTI 现货预测价格作为预测指标可以提高模型拟合度。

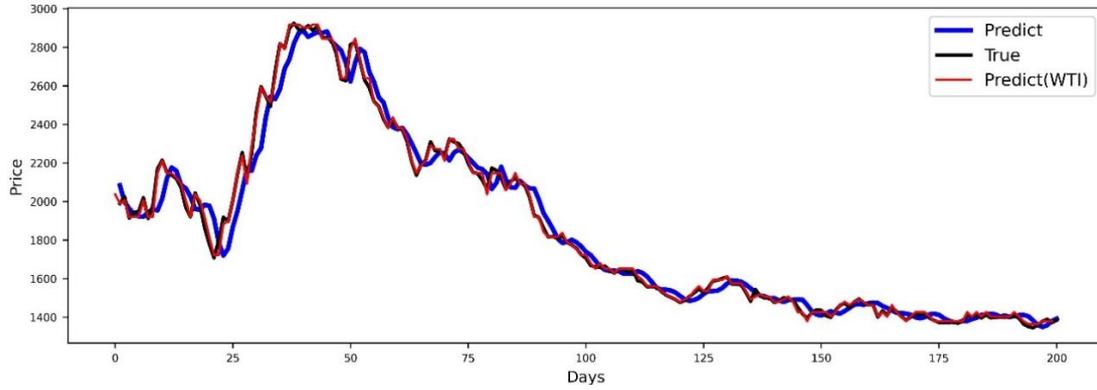


图 4.9 新能源市场股指预测结果图

从模型评价指标表 4.11 来看，当预测数据的量级减小时，MAE 和 RMSE 的量级也随之减小，实验 B 组的 MAE 和 RMSE 相较于实验 A 组下降了 41.9%和 70.2%， R^2 Score 则更为清晰的表现了实验 AB 组的拟合情况，实验 B 组相较于实验 A 组提高了 1.9%，符合上图所展现的实验 AB 组预测结果，验证了 WTI 现货预测价格作为预测因子的可行性。

表 4.11 新能源市场股指预测评价指标

实验组	评价指标		
	MAE	RMSE	R^2 Score
实验组 A	4.9143	5.3193	97.37%
实验组 B	1.2848	3.1851	98.22%

5 研究总结与展望

5.1 总结

WTI 原油对全球经济有着举足轻重的影响，为了更好地预测 WTI 原油现货价格，为国内投资者和受原油影响的市场提供合理化发展建议，本文提出了一种 EMD 模态分解算法与 BiLSTM-CNN 融合的集成模型，用以更准确地预测 WTI 原油现货价格。EBC 预测模型在多尺度多频段数据上挖掘信息，通过对 EMD 分解的 IMF 分量重构为高低频和趋势分量，使用 BiLSTM-CNN 分别进行预测，重构预测值获得最终的 WTI 现货价格预测结果，并通过特征迁移思想拓展模型的泛用性。

特征指标方面，本文使用供应需求关系、经济金融因素、经济政策不确定性因素和地缘政治因素共计 43 个指标，使用灰色相关性分析对指标进行初步筛选，构建大小为 25 的原始特征子集；模型构建方面，本文构建了基于 EMD 分解集成框架下的混合神经网络，并引入了特征迁移学习，用以处理突发事件情况下的国际油价预测任务，提高模型的泛用性和时效性，降低模型在突发事件情况下的预测成本。

模型实证方面，将 EBC 模型的预测结果通过与四个对比模型（LSTM、LSTM-CNN、LSTM-DNN、BiLSTM-CNN）和预测目标的对比，观察四个评价指标（MAE、RMSE、MAPE 和 R^2 Score）和拟合图验证了 EBC 模型在预测精度上的优越性；同时进一步引入了迁移学习，以疫情指标为例，验证了特征迁移模型的时效性和实际应用价值；在 WTI 原油现货价格预测值的应用方面，选取 WTI 期货价格和新能源市场股指作为 WTI 原油现货价格预测结果的实证，验证说明了在原油相关市场的预测任务中加入 WTI 原油现货预测价格作为特征，可以有效提高预测精度。

5.2 展望

随着原油市场的发展，油价的影响因子越来越复杂多变，同时随着技术的发展，原油预测模型可处理的模型复杂度逐渐增加，对模型预测精度的要求越

来越高，考虑到数据的可获得性、研究时间和硬件的限制，本文的局限性和未来研究可拓展的方向如下：

（1）特征指标方面

本文根据前人的研究选取了供需因素、经济金融、经济政策不确定性和地缘政治风险因素，但一方面突发事件对原油价格影响难以量化，另一方面部分指标因数据量过少难以进行模型训练，这部分指标包含的隐藏信息丢失，使得原油价格的隐藏波动趋势难以准确地被预测。未来随着数据价值的挖掘，精准客观的指标构建将会有效提高原油价格预测模型的拟合效果。

（2）预测模型方面

本文使用了分解集成框架构建混合深度学习模型，虽然 EBC 模型在实证中展现了优秀的预测能力，但由于模型为了深度多层次挖掘特征信息，造成了模型结构的冗余，使得模型对新问题的拓展性较低，本文提出的特征迁移学习虽然弥补了这方面的不足，却没有从根本上解决模型结构复杂度过高的问题。未来的研究可通过改善神经元之间的链接方式，提高单个基础模型对于多模态数据的信息挖掘能力，建立高预测精度的轻量级预测模型。

参考文献

- [1] Alquist R, Gervais O, The role of financial speculation in driving the price of crude oil[J]. *Energy*, 2013, 34(3):35–54.
- [2] Ansari D. OPEC, Saudi Arabia, and the shale revolution: Insights from equilibrium modelling and oil politics[J]. *Energy Policy*, 2017, 111: 166-178.
- [3] Baumeister C, Kilian L. Real-time forecasts of the real price of oil[J]. *Journal of business & economic statistics*, 2012, 30(2): 326-336.
- [4] Baumeister C, Peersman G. The role of time - varying price elasticities in accounting for volatility changes in the crude oil market[J]. *Journal of applied econometrics*, 2013, 28(7): 1087-1109.
- [5] Bhar R, Malliaris A G. Oil prices and the impact of the financial crisis of 2007–2009[J]. *Energy Economics*, 2011, 33(6): 1049-1054.
- [6] Caldara D, Iacoviello M. Measuring geopolitical risk[J]. *American Economic Review*, 2022, 112(4): 1194-1225.
- [7] Chen H, Liao H, Tang B-J et al, Impacts of OPEC’s political risk on the international crude oil prices: an empirical analysis based on the SVAR models[J]. *Energy Econ*, 2016, 57: 42–49.
- [8] Chiroma H, Abdulkareem S, Herawan T. Evolutionary Neural Network model for West Texas Intermediate crude oil price prediction[J]. *Applied Energy*, 2015, 142: 266-273.
- [9] Dees S, Karadeloglou P, Kaufmann R K, et al. Modelling the world oil market: Assessment of a quarterly econometric model[J]. *Energy Policy*, 2007, 35(1): 178-191.
- [10] Guo J, Zhao Z, Sun J, et al. Multi-perspective crude oil price forecasting with a new decomposition-ensemble framework[J]. *Resources Policy*, 2022, 77: 102737-102752.
- [11] Hou A, Suardi S. A nonparametric GARCH model of crude oil price return volatility[J]. *Energy Economics*, 2012, 34(2): 618-626.
- [12] Hu J. Dependence structures in Chinese and US financial markets: a time-varying conditional copula approach[J]. *Applied Financial Economics*, 2010, 20(7): 561-583.

- [13] Ito K. The impact of oil price shocks on the Iranian economy: New evidence[J]. *Economics Bulletin*, 2012, 32(1): 2246-2254.
- [14] Khashman A, Nwulu N I. Intelligent prediction of crude oil price using Support Vector Machines[C]// 2011 IEEE 9th International Symposium on Applied Machine Intelligence and Informatics (SAMI). IEEE, 2011: 165-169.
- [15] Kilian L, Lee T K. Quantifying the speculative component in the real price of oil: The role of global oil inventories[J]. *Journal of International Money and Finance*, 2014, 42: 71-87.
- [16] Kim M S. Impacts of supply and demand factors on declining oil prices[J]. *Energy*, 2018, 155: 1059-1065.
- [17] Lanza A, Manera M, Giovannini M. Modeling and forecasting cointegrated relationships among heavy oil and product prices[J]. *Energy Economics*, 2005, 27(6): 831-848.
- [18] Lee K, Ratti N R A. Oil Shocks and the Macroeconomy: The Role of Price Variability[J]. *The Energy Journal*, 1995, 16(4): 39-56.
- [19] Lu W, Li J, Li Y, et al. A CNN-LSTM-based model to forecast stock prices[J]. *Complexity*, 2020, 2020(1): 1-10.
- [20] Li T, Hu Z, Jia Y, et al. Forecasting crude oil prices using ensemble empirical mode decomposition and sparse Bayesian learning[J]. *Energies*, 2018, 11(7): 1882-1905.
- [21] Li F, Huang Z, Zhong J, et al. Do tense geopolitical factors drive crude oil prices? [J]. *Energies*, 2020, 13(16): 4277-4296.
- [22] Miao H, Ramchander S, Wang T, et al. Influential factors in crude oil price forecasting[J]. *Energy Economics*, 2017, 68: 77-88.
- [23] Mohammadi H, Su L. International evidence on crude oil price dynamics: Applications of ARIMA-GARCH models[J]. *Energy Economics*, 2010, 32(5): 1001-1008.
- [24] Plakandaras V, Gupta R, Wong W K. Point and density forecasts of oil returns: The role of geopolitical risks[J]. *Resources Policy*, 2019, 62: 580-587.
- [25] Shah I H, Hiles C, Morley B. How do oil prices, macroeconomic factors and policies affect the market for renewable energy?[J]. *Applied energy*, 2018, 215: 87-97.
- [26] Silverio R, Szklo A. The effect of the financial sector on the evolution of oil prices:

- Analysis of the contribution of the futures market to the price discovery process in the WTI spot market[J]. *Energy Economics*, 2012, 34(6): 1799-1808.
- [27] Tchatoka F D, Masson V, Parry S. Linkages between oil price shocks and stock returns revisited[J]. *Energy Economics*, 2019, 82: 42-61.
- [28] Tokic D, The 2014 oil bust: causes and consequences[J]. *Energy Policy*, 2015, 85: 162-169.
- [29] Huang S, An H, Wen S, et al. Revisiting driving factors of oil price shocks across time scales[J]. *Energy*, 2017, 139: 617-629.
- [30] Wang Q, Sun X. Crude oil price: Demand, supply, economic activity, economic policy uncertainty and wars—From the perspective of structural equation modelling (SEM)[J]. *Energy*, 2017, 133: 483-490.
- [31] Wu Y X, Wu Q B, Zhu J Q. Improved EEMD-based crude oil price forecasting using LSTM networks[J]. *Physica A: Statistical Mechanics and its Applications*, 2019, 516: 114-124.
- [32] Yin L. Does oil price respond to macroeconomic uncertainty? New evidence[J]. *Empirical Economics*, 2016, 51: 921-938.
- [33] Yu L, Xu H, Tang L. LSSVR ensemble learning with uncertain parameters for crude oil price forecasting[M]. Elsevier Science Publishers B. V. 2017.
- [34] Zhang H L, Liu C X, Zhao M Z, et al. Economics, fundamentals, technology, finance, speculation and geopolitics of crude oil prices: an econometric analysis and forecast based on data from 1990 to 2017[J]. *Petroleum Science*, 2018, 15: 432-450.
- [35] Zhang Y, Wang M, Xiong X, et al. Volatility spillovers between stock, bond, oil, and gold with portfolio implications: Evidence from China[J]. *Finance Research Letters*, 2021, 40: 101786-101796.
- [36] 楚新元, 卢爱珍, 张敬信. 基于 KNN 模型的原油价格预测研究[J]. *价格月刊*, 2021, (05): 15-22.
- [37] 崔金鑫, 邹辉文. 原油期货价格预测模型 CEEMDAN-PSO-ELM[J]. *计算机系统应用*, 2020, 29(02): 28-39.
- [38] 李治国, 郭景刚. 国际原油价格波动对我国宏观经济的传导与影响—基于 SVAR 模型的实证分析[J]. *经济经纬*, 2013, 2013(04): 54-59.

- [39] 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(01): 164-180.
- [40] 林宇, 余元圆, 张希等. 基于误差修正与深度强化学习的原油期货价格预测研究[J]. 系统工程理论与实践, 2023, 43(01): 206-221.
- [41] 牛东晓, 崔曦文. 基于混合深度学习的原油价格预测[J]. 华北电力大学学报(社会科学版), 2023, (06): 30-42.
- [42] 潘少伟, 李辉, 王亚玲, 蔡文斌. LSTM 神经网络原油价格预测[J]. 计算机技术与发展, 2021, 31(05): 180-185.
- [43] 唐振鹏, 张婷婷, 吴俊传等. 基于混合模型的原油价格多步预测研究[J]. 计量经济学报, 2021, 1(02): 346-361.
- [44] 魏蓉蓉, 叶圣伟. 国际原油期货价格波动趋势分析——基于 ARIMA 模型的实证研究[J]. 价格理论与实践, 2011, (11): 68-69.
- [45] 吴力波, 华民. 国际原油价格上涨对中国、美国和日本宏观经济的影响[J]. 国际石油经济, 2008, (01): 32-37+45+87-88.
- [46] 徐进, 王雪莲. 国际原油现货价格预测指标构建及应用研究——以 WTI 原油价格为例[J]. 价格理论与实践, 2022, (05): 118-121+206.
- [47] 许南, 廖施煜, 邓国琳. 混合型 PSO-BP 模型在原油期货价格预测中的应用[J]. 计算机工程与应用, 2011, 47(35): 234-236.
- [48] 张耀杰, 王玉东. 原油价格预测: 近 30 年研究回顾和未来展望[J]. 系统管理学报, 2022, 31(06): 1169-1189.
- [49] 张跃军, 范英, 魏一鸣. 基于 GED—GARCH 模型的中国原油价格波动特征研究[J]. 数理统计与管理, 2007, (03): 398-406.
- [50] 张跃军, 邢丽敏. 国际原油价格预测的研究动态与展望[J]. 电子科技大学学报(社科版), 2021, 23(04): 92-105.
- [51] 赵兴, 王星惠, 杨梦梦. CEEMDAN-ARIMA-GARCH 模型及其在国际原油价格预测中的应用[J]. 西安石油大学学报(社会科学版), 2022, 31(06): 1-10+55.
- [52] 周怡洁. 地缘政治风险对中美股市及国际油价溢出效应研究[J]. 河北企业, 2022, 2022(04): 41-47.

硕士期间研究成果

1、论文类：胡羽琪, 庞秋月, 王龙. “双循环”下西部地区经济增长动力何在[J]. 中国外资, 2023, (16): 93-95.

2、竞赛类:

- (1) 获得第九届全国大学生统计建模比赛研究生组省级三等奖
- (2) 获得第八届全国大学生统计建模比赛研究生组省级三等奖
- (3) 获得山东省研究生黄河流域生态与经济平衡建模大赛省级三等奖

3、项目类:

- (1) 参与“基于集成框架的欧式期权价格预测研究”(国家社会科学基金项目, 72361016)
- (2) 参与“混合高斯 Heston 资产价格模型构建及其在投资组合中的应用”(国家社会科学基金项目, 71961013)
- (3) 参与“黄河流域生态保护和高质量发展统计监测评价研究”(甘肃省科学技术厅“双一流”软科学专项, 23JRZA412)

致 谢

当我终于完成了这篇论文的时候，我怀着激动的心情，站在这曾经无数次凝视过、仰望过的书桌前，开始书写这份致谢词。对于我来说，这篇论文的结束，不仅仅是一篇学术文章的完稿，更是一段人生的历练与成长。感谢这一路走来的每一个人，正是你们，帮助我在人生的旅途中不断前行。

首先，我要感谢我的导师，从选题到完成每一步都离不开您的悉心指导。您严谨的治学态度、深厚的学术造诣和无尽的耐心让我深受启发。您不仅在学术上给予了我无私的帮助，更在人生的道路上给了我宝贵的建议。在论文的写作过程中，您无数次与我探讨、交流，每一次都让我受益匪浅。在此，我向您表示最深的敬意和感谢。

同时，我要感谢学院的每一位老师，感谢老师们的教导和辛勤付出。

我也要感谢每一位同学，我们一起度过了无数个白天和黑夜，一起攻克难题，一起分享喜悦。感谢你们在我遇到困难时给予的鼓励和支持，让我在学术的道路上不再孤单。

感谢我的家人和朋友，你们的关心、支持和理解是我前行的动力。每当我遇到困难和挫折时，你们总是我最坚实的后盾。感谢你们一直陪伴在我身边，让我在人生的道路上更加坚定。

回首这一路走来，虽然遭遇了各种挑战和困难，但正是这些磨难，使我变得更加坚韧和勇敢。这段时光，是我人生中无法忘怀的一段经历。我会将这段经历化作前进的动力，用我的努力和成绩来回报你们的支持和帮助。再次感谢所有给予我帮助、支持和关心的人，让我能走到这里。愿我们在人生的旅途中，无论面对怎样的风雨与困难，都能勇敢前行，携手共进。