

分类号 C8/405
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: 多分解技术组合下基于二次筛选的碳价格预测

研究生姓名: 王建平

指导教师姓名、职称: 孙景云、教授

学科、专业名称: 统计学、应用统计

研究方向: 大数据分析

提交日期: 2024年6月3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： 王建华 签字日期： 2024.6.3

导师签名： 孙景云 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： 王建华 签字日期： 2024.6.3

导师签名： 孙景云 签字日期： 2024.6.3

导师(校外)签名： _____ 签字日期： _____

Carbon price prediction based on secondary screening under the combination of multiple decomposition techniques

Candidate : Wang Jianping

Supervisor: Sun Jingyun

摘 要

随着全球气候变化问题日益严重,碳排放权交易作为一种有效的碳减排手段在全球范围内得到广泛实施。中国作为世界上最大的碳排放权交易市场之一,其碳价格走势对于国内外的碳减排和经济发展具有重要影响。实现碳排放权交易价格的准确预测,能够帮助政府在“双碳”目标计划下进行宏观政策调控,能够帮助企业制定更精准的生产计划,所以建立预测精度较高的碳价格预测模型具有重要的现实意义。本文在现有中国碳价格预测领域研究成果的基础上,以北京、湖北、深圳三个碳交易所碳价格预测为例,主要研究内容如下:

(1) 本文提出一种同步多分解方法的预测框架,通过与单一分解方法的预测结果做对比验证同步多分解思路的可行性。首先将历史碳价格序列同时做 EMD 分解、OVMD 分解和 SSA 分解,计算每个分解子序列的 LZ 复杂度值并根据肘部法则进行聚类重构,再利用 Ada-Elman 模型对重构序列进行预测,最后 BP 做非线性集成。

(2) 本文提出一种基于多数据信息的多元分解碳价格预测模型。首先根据现有的中国碳价格影响因素研究文献筛选有关影响因素,与历史碳价格共同输入做多元经验模态分解 (MEMD),得到分解子序列相同的数据集,计算每个子序列的多尺度散步熵值 (MDE) 重构为高频、低频,针对不同频率做 Lasso 筛选重要的影响因素进入预测模型,通过对比验证该模型的优越性。

(3) 本文提出了一种加入百度搜索信息且融合多元分解、多分解方法的预测模型。百度作为中国受众群体最大的搜索引擎,其搜索指数能够相当程度上反应碳价格的受关注程度。首先通过碳价格的相关影响词选择百度搜索指数,与查阅文献选择的其他市场的影响因素做 GBDT 模型进行重要性排序;其次,被挑选的因素和历史碳价格共同输入多元经验模态分解和多元变分模态分解 (MEMD/MVMD) 中进行分解,将分解序列重构为高频、低频、趋势项;接着引入 Pearson 相关系数、主成分分析 (PCA)、格兰杰因果检验 (Granger Causality) 对序列进一步做过滤筛选;最终过滤得到的序列输入卷积神经网络-双向长短时记忆神经网络预测模型 (CNN-BiLSTM) 进行预测。通过与其他模型进行对比验证该模型的优越性。

根据本文所作工作可以得出结论：（1）基于市场影响因素和百度搜索指数的碳价格预测是可靠有效的；（2）同步多分解方法能够提高碳价格预测模型的预测效果；（3）当基于分解重构框架的碳价格预测模型加入了外生因素输入时，需要对外生因素序列做二次筛选，否则会影响模型预测效果。

关键词：同步多分解 百度搜索指数 多元分解 碳价格预测

Abstract

With the increasingly serious problem of global climate change, carbon emission trading as an effective means of carbon emission reduction has been widely implemented in the world. As one of the largest carbon emission trading markets in the world, China's carbon price trend has an important impact on carbon emission reduction and economic development both domestically and internationally. Accurate prediction of carbon emission trading price can help the government to carry out macro-policy regulation under the "dual carbon" target plan and help enterprises to make more accurate production plans. Therefore, it is of great practical significance to establish a carbon price prediction model with higher prediction accuracy. Based on the existing research results in the field of carbon price prediction in China, this paper takes the carbon price prediction of Beijing, Hubei and Shenzhen carbon exchanges as examples. The main research contents are as follows:

(1) This paper proposes a prediction framework of synchronous multi-decomposition method, and verifies the feasibility of synchronous multi-decomposition method by comparing with the prediction results of a single decomposition method. Firstly, the historical carbon price sequence was decomposed by EMD, OVMD and SSA simultaneously, and the LZ complexity value of each decomposition subsequence was calculated, and cluster reconstruction was carried out according to the elbow rule. The reconstructed sequence was predicted by Ada-Elman model, and nonlinear integration was performed by BP.

(2) This paper proposes a carbon price prediction model based on multiple data information. Firstly, relevant influencing factors were screened according to the existing research literature on influencing factors of China's carbon price, and the data set with the same decomposition

subsequence was obtained by input of multiple empirical mode decomposition (MEMD) together with the historical carbon price. The multi-scale walking entropy (MDE) of each subsequence was calculated and reconstructed into high frequency and low frequency. The important influencing factors were selected by Lasso for different frequencies into the prediction model, and the superiority of the model was verified by comparison.

(3) This paper proposes a prediction model that combines multiple decomposition and multiple decomposition methods with Baidu search information. As the largest search engine in China, Baidu's search index can reflect the attention of carbon price to a considerable extent. First of all, the paper selects the Baidu search index with the relevant influential words of carbon price, and makes a GBDT model to rank the importance of the influencing factors of other markets selected by the literature review. Secondly, the selected factors and historical carbon prices are input into multiple empirical mode decomposition and multiple variational mode decomposition (MEMD/MVMD) for decomposition, and the decomposition sequence is reconstructed into high frequency, low frequency and trend terms. Then Pearson correlation coefficient, principal component analysis (PCA) and Granger Causality were introduced to further filter the sequences. Finally, the filtered sequences were input into the convolutional neural network (CNN-BiLSTM) for prediction. The superiority of this model is verified by comparing with other models.

According to the work done in this paper, it can be concluded that: (1) the carbon price prediction based on market influence factors and Baidu search index is reliable and effective; (2) Synchronous multi-decomposition method can improve the prediction effect of carbon price prediction model; (3) When exogenous factor input is added to the carbon

price prediction model based on decomposition and reconstruction framework, secondary screening of exogenous factor sequence is required, otherwise the prediction effect of the model will be affected.

Keywords: Synchronous multi-decomposition; Baidu search index; Multivariate decomposition; Carbon price prediction

目 录

1 引言	1
1.1 研究背景及意义.....	1
1.2 文献综述.....	3
1.2.1 基于历史碳价格的预测.....	3
1.2.2 基于其他市场影响因素的预测.....	4
1.2.3 基于网络搜索指数与文本分析的预测.....	5
1.2.4 文献述评.....	6
1.3 研究内容与创新点.....	7
1.3.1 研究内容.....	7
1.3.2 创新点.....	8
1.4 研究结构安排.....	8
2 研究方法	11
2.1 分解方法.....	11
2.1.1 经验模态分解(EMD).....	11
2.1.2 变分模态分解(VMD).....	12
2.1.3 奇异谱分解(SSA).....	12
2.1.4 多元经验模态分解(MEMD).....	13
2.1.5 多元变分模态分解(MVMD).....	14
2.2 因素筛选模型.....	16
2.2.1 梯度提升迭代决策树模型(GBDT-CART).....	16
2.2.2 Lasso 回归.....	17
2.3 多尺度散布熵(MDE).....	18
2.4 预测模型.....	18
2.4.1 艾尔曼神经网络模型(Elman).....	18
2.4.2 自适应提升算法优化的艾尔曼模型(Adaboost-Elman).....	19
2.4.3 遗传算法优化的艾尔曼模型(GA-Elman).....	21

2.4.4	极限学习机模型(ELM)	22
2.4.5	卷积神经网络(CNN)	22
2.4.6	双向长短时记忆神经网络模型(BiLSTM)	23
2.5	评价指标	25
3	基于同步多分解集成预测方法下的碳价格预测	26
3.1	预测框架	26
3.2	数据预处理	27
3.3	建立预测模型	28
3.3.1	多通道分解重构	28
3.3.2	Adaboost-Elman 预测	29
3.4	预测模型评价	30
3.5	本章小结	32
4	多元模态分解下考虑市场因素的碳价格预测	33
4.1	预测框架	33
4.2	数据预处理	34
4.2.1	碳价格影响因素的选取	35
4.2.2	MEMD 分解	35
4.2.3	分解序列重构	37
4.2.4	Lasso 筛选影响因素	38
4.3	建立预测模型	40
4.4	预测模型评价	40
4.5	本章小结	44
5	同步多分解技术组合下基于二次筛选数据的碳价格预测	45
5.1	预测框架	45
5.2	数据预处理	46
5.2.1	影响因素的筛选	46
5.2.2	MEMD\MVMD 分解重构	48

5.3 PCA-Pearson-Granger Causality 过滤	49
5.3.1 Pearson 检验	49
5.3.2 PCA 检验	49
5.3.3 Granger Causality 检验	49
5.3.4 过滤结果	54
5.4 CNN-BiLSTM 预测	57
5.5 模型对比	60
5.6 本章小结	62
6 总结	63
6.1 结论	63
6.2 展望	64
参考文献	65
附 录	70
攻读硕士学位期间承担的科研任务及主要成果	76
致 谢	77

1 引言

1.1 研究背景及意义

当工业革命开启了人类生产生活的新篇章，温室气体也在大气中急剧上升，随之而来愈演愈烈的温室效应，也严重影响着全球的平均气温的上涨。气温的升高带来冰川的融化，造成水平面的上涨，进一步吞噬着陆地的面积，如果任由温室效应继续加剧，许多海岛和沿海国家即将成为人类记录在历史中的会议。温室效应同时还影响着以冰川为家园的动物、植物们，冰川的融化会造成物种的灭绝，对生态系统造成不可挽回的伤害。

自工业化时代以来，以二氧化碳为主的温室气体排放量激增，它们如同无形的枷锁，锁住了大地的热量，让温室效应愈发严重。根据数据显示，2019年全球二氧化碳排放量高达364.4亿吨，占据了温室气体总量的74%，成为导致温室效应的头号元凶。全球地表平均气温也随之攀升，与1750年相比已升高了2.82℃。政府间气候变化专门委员会更是明确指出，自前工业时代以来，温室气体的浓度持续上升，这一趋势无疑是导致气候变化的罪魁祸首。

虽然近年来全球碳排放量的增速有所减缓，但碳排放的总量依然处于高位，未来的气候变化形势依然严峻。极端天气事件的频发、海平面的不断上升、农作物生长环境的恶化……这些都是气候变化给人类生存环境带来的沉重打击。因此，控制碳排放、减缓全球气候变暖，已经成为全人类共同面对的重要课题。

面对温室效应带来的严峻挑战，人类开始觉醒，并付诸行动。2016年，《巴黎协定》应运而生，它要求各国在本世纪中叶前实现碳排放净增量为零的目标，以期将全球气温上升幅度控制在工业革命前的2℃以内。欧盟、美国、澳大利亚等国家和地区纷纷建立碳排放权交易市场，通过配额分配、交易机制等手段来降低碳排放。虽然各国的碳市场在配额分配、排放监测、交易规则等方面存在差异，但它们在推动全球碳减排方面都发挥了积极作用。

准确预测碳排放权交易价格具有多重意义，它不仅关乎碳市场的健康发展，也影响着企业的决策和整体经济发展。

中国作为世界上最大的发展中国家和最大的煤炭消耗国家，尽早实现碳达峰目标对全球实现温室效应调控的目标来说至关重要。预测碳排放权交易价格有助

于市场参与者更好地理解市场趋势和供需关系。通过预测价格，政策制定者可以更有效地调整市场政策，优化配额分配，以实现减排目标。此外，准确的价格预测也有助于增强市场的透明度和公信力，吸引更多的投资者参与，促进碳市场的健康发展。中国政府通过建立碳排放权交易市场，以市场化手段激励企业减少碳排放，将排放温室气体的权利进行标价，企业通过购买排放温室气体的权利来排放自己各种生产活动导致的温室气体，这个排放温室气体的权利的价格就是碳价格。当企业进入碳价格交易体系中，就要衡量购买碳排放权价格、超额碳排放价格、以及超额碳排放给企业带来的收益等，所以如果能够准确的预测碳排放权的交易价格，有利于企业更精准地对生产活动进行规划和安排。

对于企业而言，准确预测碳排放权交易价格是其制定生产计划和投资策略的重要依据。企业可以根据预测价格来权衡减排成本和购买排放权的成本，从而制定出更合理的减排策略。这有助于企业降低生产成本，提高经济效益，同时也符合企业的社会责任和环保要求。企业在国家“双碳”目标追求的大环境下，需要解决如何平衡企业所必需的生产活动和降低生产活动所带来的温室气体排放量的问题。生产计划的调整、生产设备的升级等都是控制温室气体排放的必经之路，在达到生产活动和温室气体排放之间的最佳平衡期间，企业也希望能够实现自身利益的最大化，实现碳排放权交易价格的准确预测，能够帮助企业制定更精准的生产计划，保证企业在靠近“双碳”目标过程中的利益，降低市场不稳定的风险。

此外，准确预测碳排放权交易价格也有助于推动绿色产业的发展。随着碳市场的不断完善和碳排放权交易价格的上升，那些低碳、环保的企业和产品将更具市场竞争力。这将激励更多的企业投身于绿色产业，推动产业结构的优化和升级。

准确预测碳排放权交易价格对于碳市场的健康发展、企业的决策、绿色产业的发展以及全球气候治理和可持续发展都具有重要意义。通过碳市场的价格机制，可以有效地引导社会资金投向低碳领域，推动全球向低碳经济转型。这对于减缓全球气候变暖、保护地球生态环境、实现人类社会的可持续发展具有深远影响。

1.2 文献综述

1.2.1 基于历史碳价格的预测

基于单一碳价数据的时间序列预测模型,是碳价预测领域早期就流行起来的方法,只使用碳价数据,利用各种统计模型和机器学习模型进行预测,例如 ARIMA、SVR、LSSVR、SVM、BP、GM 模型等,到目前为止也是碳价预测领域的主流预测思想。

高杨等(2014)建立了 EMD 分解和 PSO 优化 SVM 的误差修正预测模型对国际碳市场价格进行预测,发现误差修正后的预测结果滞后性和拐点误差大的问题得到了改善,而且经过分解后的预测模型能够达到更高的预测精度;张晨等(2016)通过极点对称模态分解方法对碳价格进行分解,重构为高中低频序列后再针对不同频率的序列采用不同的预测方法进行预测,发现这种多频率组合预测方法的预测精度要高于单一预测模型的预测精度;杨星等(2018)通过构建 Db3-GA-RBF 预测模型对欧盟碳市场价格进行预测探究,验证了该模型在碳价格预测领域的优越性;Zhang 等(2022)构建了 TCN-Seq2Seq 预测模型对碳市场价格进行预测,发现该模型的鲁棒性优于传统统计模型和一般深度学习模型;Yun(2022)针对碳金融市场价格的非对称性和极端价格情况,提出了 NAGARCHSK-GRU 模型进行预测,该模型的预测精度明显优于一般机器学习模型,验证了考虑极端价格因素对预测有益;Ozan 等(2023)构建 CEEMDAN-VMD-BPNN-GA 进行碳价格预测,其中使用置换熵 PE 对分解后的碳价序列进行重构,该模型表现出了良好的预测性能;Zhang(2023)提出了一种新颖的数据驱动混合模型,该模型综合了奇异谱分析、随机森林和长短期记忆神经网络对碳价格进行预测;高长征等(2022)通过 CEEMDAN 将湖北碳价数据进行分解,再利用 Transformers 模型对每一个分解的子序列进行预测再集成作为最终预测结果。

E(2021)构建了 ESMD-KICA-LSSVR 模型对 EUA 价格进行预测,与 ARIMA、TRG、ESMD-ARIMA、ESMD-LSSVR 等其他基准模型相比之下,该模型的预测性能较为突出;Niu(2022)提出了一种纠错策略和分而治之策略的预测框架,在用 VMD 分解方法对碳价序列进行分解后,利用 MOGOA-ORELM 模型对各序列进行预测,再对其误差序列进行预测进行进一步修正,实验结果证明该模型的

预测性能要显著优于基准模型；Li(2022)提出了一种基于海鸥优化算法(SVMD)、基于波动的离散熵(FDE)、极限学习机(ELM)和基于 JAYA 算法(JAYA-KELM)优化的核极限学习机(KELM)的变分模分解碳价格组合预测模型，命名为 SVMD-FDE-ELM-JAYA-KELM，并采用湖北、广东、北京三个城市的碳价格进行预测验证，证实了该预测模型的优越性；Liu(2022)提出了一种基于混合区间多尺度分解法的组合预测模型，并将其应用于区间碳价的预测，提出了区间离散小波变换(IDWT)、区间经验模态分解(IEMD)和区间变分模态分解(IVMD)3种区间多尺度分解方法，将区间碳价分解为区间趋势和区间残差，并采用五种不同的预测模型进行预测，最后 LSTM 对预测结果进行集成，结论是该模型是对区间碳价格进行预测的有力工具；姚奕等(2017)通过 EMD-SVM 模型对湖北碳市场进行预测，对分解后重构得到的高中低频序列分别进行了影响因素的分析，但未在预测中加入影响因素数据。

1.2.2 基于其他市场影响因素的预测

常用于预测模型进行辅助预测的外生因素有两大类，也就是现有指标和自拟指标。现有指标里包括国内外能源指标、国内外气候指标、国内外经济指标与宏观政策等；自拟指标里最常用的就是百度指数和谷歌指数等，通常通过文本数据构建指标辅助预测。

有部分学者通过筛选市场性影响因素输入预测模型，毕文杰(2022)等 Airbnb 北京市房价作为研究对象，首先采用 OLS 模型对六类变量做房价解释性的筛选，再利用四种基础机器学习方法对北京房源价格进行预测；严茂林(2023)等利用城市化率、城镇居民家庭人均可支配收入、城镇食用植物油零售价格指数、消费习惯等因素构建灰色预测模型，对人均食用植物油消费量进行预测；吉兴全(2022)等针对多因素融合影响的电价序列与其影响因素间隐含的非线性关系，提出了一种基于 ATT-CNN-LSTM 的短期电价预测方法；方毅(2022)等通过引入 20 个涵盖了价值、技术、动量、情绪反转等指标和 8 个机器学习算法对沪深两市股票收益率进行预测；王满等(2022)基于 LSTM 模型、LASSO 降维和 GARCH-MIDAS 模型，研究了高维情形下利用低频宏观经济变量预测高频股价的问题；王润周等(2022)以北京丰台区批发市场的白条猪肉价格进行实证分析，提出一种分解-

重构-提取-关联-输出的农产品价格预测模型(CT-BiSeq2seq)，加入多维数据提供模型预测精度。

崔焕影等（2018）对碳价格的预测分成了短期预测和长期预测两方面，在短期预测部分使用单一碳价格，验证了数据先分解后预测的顺序能够提高预测精度，在长期预测部分加入了宏观经济因素与碳价格共同进行预测，验证了相同预测模型下，加入影响因素的预测精度更优；魏宇等（2022）在碳价格预测模型中考虑了经济形势、金融市场、国际碳市场、化石能源价格、大气环境共五个方面的影响因素加入到 DMS-DMA 预测模型中进行预测，发现化石能源价格对我国碳价格的影响在减小；Li（2022）同时针对广东和湖北交易所的碳价格进行的预测，将 MLSTM、MLP、RNN、SVR 等模型进行了预测对比，验证了 MLSTM 模型在加入影响因素后的碳价格预测模型中的优越性；Yang（2022）提出了 MEEMD-LSTM 的预测模型，可以将影响因素和碳价格序列共同进行分解进行预测，该方法具有较好的鲁棒性和自适应性，相较于基准模型有更优的预测效果。

1.2.3 基于网络搜索指数与文本分析的预测

随着互联网技术的发展，越来越多的学者发现可以将网民网络搜索专注度转化为搜索指数指标提出进行利用。刘金培等（2023）通过构建百度指数获得碳价格的非结构性数据，在经过主成分分析降为与碳价格历史数据进行 EMD、VMD、WT 分解，经过 ARIMA、Holt、ANN 模型进行预测最终集成得到预测结果，发现利用了多源信息的预测要优于单一碳价格数据预测；Pan（2023）在碳价格预测模型中加入了考虑投资者关注的新闻文本数据进行预测，并验证了该模型相较于单一碳价格模型的优越性；Huang（2020）同时考虑了现有因素的结构性和百度指数的非结构性数据，首先通过灰色关联度方法找到适合的现有因素指标，然后对百度指数进行因子分析，再对碳价数据进行 MOEMD 分解，将重构后的序列和影响因素序列一起进行预测，最终验证了 MOEMD-CKA-ELM 模型的预测性能较为优秀；王文胜等（2022）基于网络搜索数据对商品零售价格指数(RPI)变动影响的分析，构建河北省地区日度网络搜索指数进行预测；李欢等（2022）基于网络搜索数据构建了 PCA-ARDL-BP 组合模型对房价指数进行预测。

更有学者通过挖掘文本信息内容进行非结构性转化，加入到预测研究中。

梁荣等（2018）采用基于程度副词语义标定的结构化方法对负荷元胞的非结构化属性进行结构化处理，利用多源信息融合和深度置信神经网络的配电系统空间负荷预测；梅梅等（2019）针对中文微博数据非结构化特点，从相关维、状态维、主题维、情绪维四个维度提出了一套标准的微博情绪挖掘方法，应用该方法体系对旅游市场进行实证分析；张奕韬等（2020）结合已有经济领域分类标准、词语之间的语义关系和词语对主题的代表性，提出了改进了文档-主题与主题-词语的分配过程的 PSPHDP 主题模型；Zhang（2022）采用了词嵌入算法对在线新闻数据和谷歌趋势进行识别，结合自身碳价序列，利用 LSTM 模型进行预测；王娜（2023）采用了百度搜索指数、资讯指数、能源指标、气候指标、经济指标等不同的因素对国内 8 个试点进行预测，并构建了动态多元网络 DMNP 进行验证，数据只做降维并未进行分解。

1.2.4 文献述评

通过近十年碳价预测国内外相关文献的梳理，我们大致可以对碳价预测的研究现状做以下总结：

目前在碳价预测领域主要分为只使用单一碳价数据进行预测和使用影响因素、百度指数等外生因素辅助预测的两大方向。在单一碳价数据预测领域，由于碳价格的非线性、非平稳性和动态不确定性，“分解-集成”预测思想是为主流。学者们的研究重点放在改进对碳价数据的分解方法和后续预测方法上，讨论如何让碳价数据在分解时既能够降低复杂度，但是同时又不丢弃有用的信息，在后续的预测上，针对不同频率的序列选用何种预测方法能够达到最优的预测效果；在多源数据预测碳价领域，从刚开始的国内金融市场、经济指标、能源价格、气候因素等方面的考虑，再到线上舆论的新闻标题、谷歌趋势、资讯指数等，通过加入对碳价序列有影响的因素序列，以期提升碳价序列的预测效果。但能源价格、国际金融指标等也存在非线性、非平稳的情况，这个时候就需要在对碳价序列进行分解的同时也对影响因素序列进行一定程度的分解，但一般情况下使用分解方法对每一个因素序列单独进行分解会导致分解子序列数量不同、分解子序列频率难以统一重构等问题，如果将影响因素与碳价序列进行共同分解，则能够解决这一问题，这也是预测领域的新思路。

通过对已有文献的学习,对本文研究工作的启示有:以分解集成预测框架为主体,加入碳价影响因素作为辅助,探究多源数据同步分解方法,多通道减少预测偏差,开展新的碳价预测思路研究。

1.3 研究内容与创新点

1.3.1 研究内容

碳价格的准确预测对政府宏观调控碳排放交易系统、企业协整生产计划等具有重要意义。本文针对中国碳价格的准确预测展开研究,主要内容包括三部分:

(1) 基于历史碳价同步多分解的碳价格预测

该章节在数据源方面只使用北京、湖北、深圳三个交易所的历史碳价格数据,在数据分解部分同步使用了 EMD、OVMD、SSA 三种分解方法,在计算各个分解序列的 Lempel-Ziv 值后,根据肘部法则确定聚类个数后,利用 Adaboost-Elman 模型对重构序列进行预测,最终预测结果由 BP 非线性集成得到。预测效果由 MAE、RMSE、SMAPE 进行评估。

(2) 基于融合因素的多元经验模态分解的碳价格预测

该章节在数据源方面加入了外生因素辅助碳价格进行预测,通过对现有加入外生因素的碳价格预测文献的大量查阅,选取了来自国际碳价格、国际金融市场、能源市场和气候环境四个场景中共 15 个影响因素,这些影响因素与历史碳价格共同进行 MEMD 分解,得到分解子序列个数相同的分解序列。计算各个子序列的 MDE 值并重构为高频、低频序列,在碳价格和影响因素的高频、低频数据集中,利用 Lasso 回归筛选相关序列、剔除无关序列,提高模型效率和预测精度。最后将筛选得到的影响因素输入到预测模型中进行预测,针对高频、低频序列进行预测时使用不同的预测模型进行预测,其中包括 BP、ELM、Elman、KELM 等基模型和 GA 优化各基模型的优化模型,预测结果由 MAE、RMSE、SMAPE 进行评估。

(3) 基于融合多数据信息的多分解框架的碳价格预测

该章节在数据源方面加入了碳排放相关的百度搜索指数 7 个,并通过大量查阅已有的研究碳价格影响因素的文献,在国际碳价格、国内外金融市场、国内外

能源市场、经济指标、气候环境五大场景里选择因素 21 个，共 28 个外生因素。首先利用 GBDT 模型对不同碳价格的影响因素进行重要性排序，剔除重要性小于 1% 的因素。将 GBDT 筛选得到的因素与历史碳价格序列共同做 MEMD 和 MVMD 分解，计算各个子序列的 MDE 值并重构为高频、低频和趋势项。其次引入过滤筛选，包括 Pearson、PCA、Granger Causality 三个环节，通过筛选的序列可以进入 CNN-BiLSTM 模型进行预测，最终结果采用线性回归模型进行集成，预测效果由 MAE、RMSE、SMAPE 进行评估。

1.3.2 创新点

本文的创新之处在于以下几点：

(1) 在单一历史碳价格数据源的碳价格预测领域，采用多种不同分解原理的分解方法同步进行分解，避免了单一分解方法固有缺点带来的分解不彻底或信息丢失的问题，并使用 K 均值聚类法遵循肘部原则确定聚类个数，并不以高频低频等主观确定聚类个数。

(2) 将影响因素与碳价格同步进行 MEMD 分解，多元经验模态分解具有自适应性、能够提取不同频率成分和处理非平稳信号的优点，利用 MDE 多尺度散布熵衡量子序列的复杂程度，多尺度散布熵在处理具有多尺度特征的时间序列时表现出色，能够有效地提取不同尺度上的模式。

(3) 将百度搜索指数引入碳价格预测中辅助预测，结合多尺度分解和多通道分解的优点进行分解，引入 Pearson-PCA-Granger Causality 过滤方法筛选有关因素序列，保证了筛选的可靠性。

1.4 研究结构安排

本文论文框架如图 1.1 所示，共由六章内容组成，分别为：

第一章为引言，主要包括本文的研究背景、研究意义、国内外文献综述，以及本文的主要内容以及论文框架。本文主要从基于单一历史碳价格的国内外碳价格预测、基于多信息的碳价格预测和基于网络搜索信息的碳价格预测三个方面对国内外相关文献进行归纳。并从中发现现有研究的不足之处，提出本文的研究思路。

第二章为研究方法理论。主要介绍了本文研究主要用到的梯度提升决策树、多元经验变分模态分解分解、奇异谱分解、LZ 复杂度、多尺度散布熵、极限学习机、艾尔曼神经网络、自适应 boosting 优化算法、遗传优化算法、Lasso 筛选、卷积神经网络和长短时记忆神经网络等研究方法。

第三章为基于同步多分解集成预测方法下的碳价格预测。针对单一的历史碳价格数据,本章采用 EMD\OVMD\SSA 同步进行分解,计算 MDE 值后进行重构,输入 Adaboost-Elman 模型进行预测,预测结果作非线性集成。并做单一分解方法下的碳价预测作为对比模型。

第四章为多元模态分解下考虑市场因素的碳价格预测。本章将国际碳价格、国际金融市场、能源市场和气候环境的因素加入预测,做 MEMD 分解和 MDE 熵值计算,重构后用 Lasso 方法对因素序列进行筛选,得到最终的预测结果。

第五章为同步多分解技术组合下基于二次筛选多数据信息的碳价格预测。本章第三章和第四章实证结果的基础上进行进一步的讨论。在数据源方面增加了百度搜索指数和部分来自五大场景的影响因素,利用 GBDT 模型进行因素筛选。在分解方法上增加了 MVMD 分解通道,并重构为高频、低频、趋势项,引入 Pearson-PCA-Granger Causality 过滤对因素序列进一步进行筛选,最终利用 CNN-BiLSTM 模型进行预测。并做单分解模型效果对比。

第六章为结论与展望。本章对前文的工作进行总结,并针对不同的预测方法给出结论,进一步针对现有工作未能顾及到的问题作出展望。

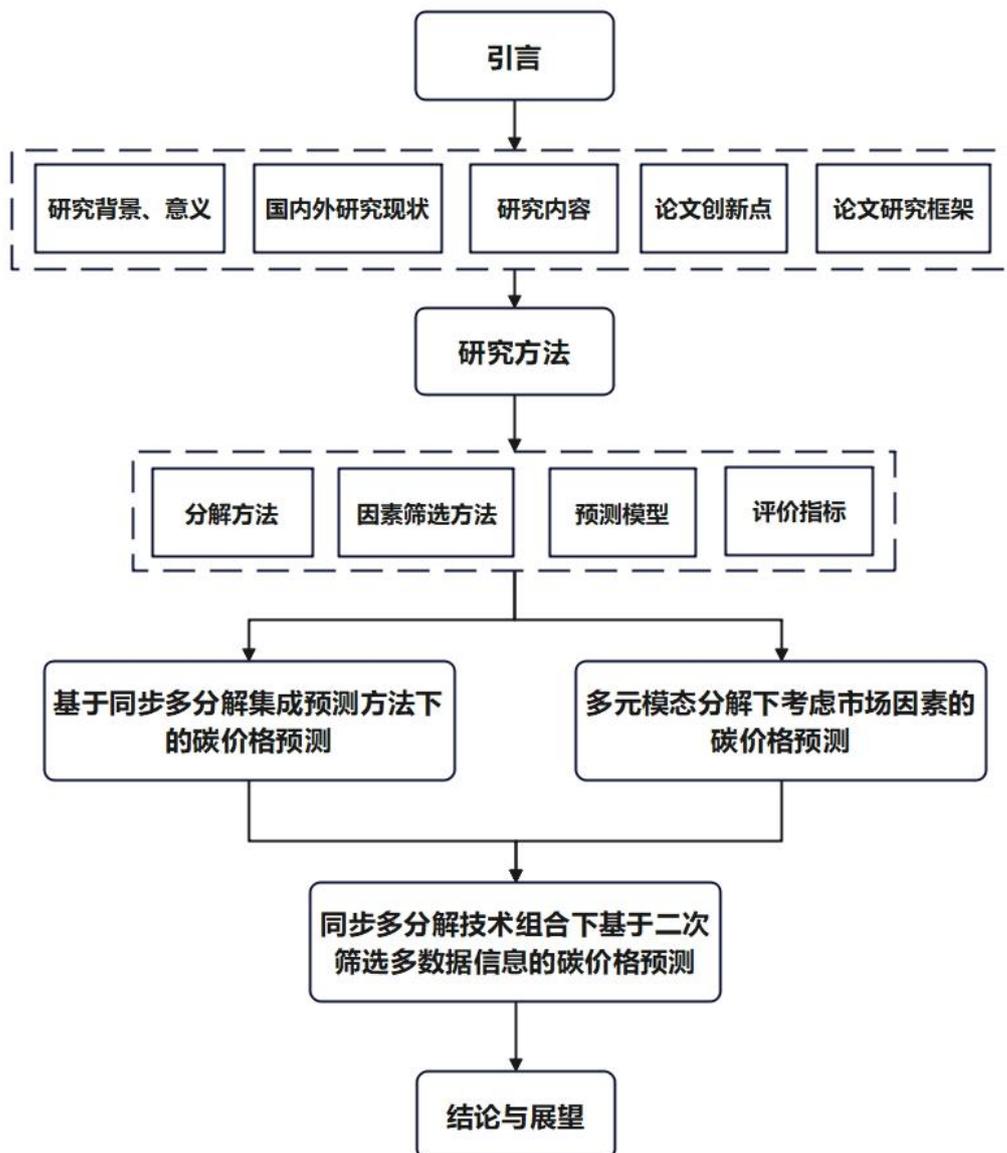


图 1.1 论文框架

2 研究方法

2.1 分解方法

2.1.1 经验模态分解(EMD)

经验模态分解(EMD)^[7]是一种针对非线性、非平稳性时间序列的信号处理方法。原始信号经过 EMD 处理, 会被分解成若干个基于信号局部特征时间尺度的本征模态函数(IMF)。同时, EMD 分解后的信号会逐渐平稳化, 消除了基函数无自适应性的问题。EMD 基本流程如下:

步骤一: 设原始序列为 $s(t)$, 采用三次样条差值法计算 $s(t)$ 中局部极大值点和极小值点, 得到原始序列的上、下包络线 $I_{\min}(t)$ 和 $I_{\max}(t)$;

步骤二: 计算上下包络线的平均包络线

$$m(t) = \frac{I_{\min}(t) + I_{\max}(t)}{2} \quad (2.1)$$

步骤三: 计算新序列

$$h_1(t) = s(t) - m(t) \quad (2.2)$$

步骤四: 重复步骤三, 对 $h_1(t)$ 筛选, 直至分解出的信号平稳;

步骤五: 最终, 将 $s(t)$ 分解为 k 个 IMF 和残余分量 $r_t(k)$

$$\begin{cases} r_2(t) = r_1(t) - h_2(t) \\ r_3(t) = r_2(t) - h_3(t) \\ \vdots \\ r_k(t) = r_{k-1}(t) - h_k(t) \end{cases} \quad (2.3)$$

步骤六: 原始信号重构为:

$$s(t) = \sum_{i=1}^k r_k(t) + h_i(t) \quad (2.4)$$

2.1.2 变分模态分解(VMD)

VMD (Variational mode decomposition) [1]是一种自适应的、完全非递归的模态变化信号处理方法。当原始载荷数据具有复杂的非线性关系时,将其作为输入数据直接预测非常困难。VMD 可以将原始负荷数据分解成多个简单序列,降低了预测难度,提高了预测精度。恰当的分解阶数能够得到足够解释原始序列的分解子序列,同时不会增加过多无用的数据负担。Li 等 (2022) 提出将方差贡献率应用于 K 值的选择,提出了以方差贡献率为优化的一种变分模态分解方法 OVMD。

随着分解阶数 K 的不断增大,后续分解得到的高频成份往往具有较低的方差贡献率。所以当发现分解得到的某个子序列方差贡献率趋于平缓时,以上一个子序列的作为最终分解个数。具体步骤如下:

步骤一: 将 $K=2$ 设置为初始分解阶数,进行 VMD 分解,得到分解的分量为 $\{m_k(t)\}(k=1,2,\dots,K)$;

步骤二: 当分解阶数 $K = F(m_k(t)^2) - F(m_k(t))^2$ 时,计算每个分量的方差 D_k , 其中 $F(m_k(t)^2)$ 为第 K 个分量的均方, $F(m_k(t))^2$ 为第 K 个分量的均方的平方;

步骤三: 计算每个分解序列的方差贡献率;

步骤四: 确定最后一个分量的方差贡献率是否趋于稳定, 如果不稳定, 取 $K=K+1$,返回步骤一。如果趋于稳定, 则 $K-1$ 为最终分解个数。

2.1.3 奇异谱分解(SSA)

奇异谱分析(SSA) (2002) 是基于时间序列数据的特定矩阵的奇异值分解 (SVD), 用于从复杂的时间序列中提取和分离出不同的成分, 如长期趋势、周期性波动和噪声等。SSA 方法原理如下:

步骤一: 构造轨迹矩阵。设数据长度为 N 的原始时间序列 $x_i = \{x_1, x_2, \dots, x_N\}$ 。首先需要选择 $L < N/2$ 的窗口长度 L, 将原始时间序列进行滞后排列得到轨迹矩阵, 令 $K = N - L + 1$, 则轨迹矩阵 X 为 $L \times K$ 的 Hankle 矩阵

$$X = \begin{bmatrix} x_1 & x_2 & \cdots & x_K \\ x_2 & x_3 & \cdots & x_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & \cdots & x_N \end{bmatrix} \quad (2.5)$$

步骤二：奇异值分解（SVD）。将 X 表示为 L 个分量矩阵之和的形式，即为

$$X = X_1 + X_2 + \dots + X_L = \sum_{i=1}^L \sqrt{\lambda_i} u_i v_i^T \quad (2.6)$$

轨迹矩阵 $X_i (i=1, 2, \dots, L)$ 的秩为 1，奇异谱 $\sqrt{\lambda_1} \geq \sqrt{\lambda_2} \geq \dots \geq \sqrt{\lambda_L}$ 。 u_i 为轨迹矩阵 X_i 的左奇异向量， v_i 为轨迹矩阵 X_i 的右奇异向量。不同的奇异值对应不同解释程度的序列，主要信息的序列有较高的奇异值，只表达波动干扰的序列奇异值较低。

步骤三：重构分组。假设 w 组选取了 $p \leq L$ 个主元，加入左右奇异谱进行重构为

$$X_w = X_1 + X_2 + \dots + X_p = \sum_{i=1}^p \sqrt{\lambda_i} u_i v_i^T \quad (2.7)$$

对 \hat{X}_w 进行对角平均化，然后将 \hat{X} 处理为标准 Hankle 矩阵，然后根据下式，即可重构得到 w 分量序列。

$$\left\{ \begin{array}{ll} \frac{1}{i} \sum_{m=1}^i x_{m, i-m+1} & 1 \leq i < L^* \\ \frac{1}{L^*} \sum_{m=1}^{L^*} x_{m, i-m+1} & L^* \leq i \leq K^* \\ \frac{1}{N-i+1} \sum_{m=i-K^*+1}^{N-K^*+1} x_{m, i-m+1} & K^* < i \leq N \end{array} \right. \quad (2.8)$$

2.1.4 多元经验模态分解(MEMD)

MEMD (2013) 是 EMD 的多元扩展，能够克服传统方法中固有模态不匹配问题。经过 MEMD 分解得到的 IMF 可有效反映输入信号的时频特性，准确描述各个频率成分的多层次特性。MEMD 的具体步骤如下：

步骤 1: 采用 Hammersley 序列采样法在 $n - 1$ 维球面上进行点集采样, 获得的 K 组方向向量;

步骤 2: 计算输入信号 $(v(t))_{t=1}^T$ 在 K 组方向向量 x^{θ_k} 上的投影集 $(p^{\theta_k}(t))_{k=1}^K$, 其中 $(v(t))_{t=1}^T = \{v_1(t), v_2(t), \dots, v_n(t)\}$ 表示包含 n 个通道的多元信号, $x^{\theta_k} = \{x_1^k, x_2^k, \dots, x_n^k\}$ 对应 $n - 1$ 球面上沿着方向角 $\theta_k = \{\theta_{k1}, \theta_{k2}, \dots, \theta_{kn-1}\}$ 的一组方向向量;

步骤 3: 求投影集 $\{p^{\theta_k}(t)\}_{k=1}^K$ 所有极大值对应的时间点 $\{t_i^{\theta_k}\}$;

步骤 4: 对 $\{t_i^{\theta_k}, v(t_i^{\theta_k})\}$ 进行插值获得多元包络曲线 $\{e^{\theta_k(t)}\}_{k=1}^K$;

步骤 5: 计算整组方向向量包络曲线的均值 $m(t)$:

$$m(t) = \frac{1}{K} \sum_{k=1}^K e^{\theta_k(t)} \quad (2.9)$$

步骤 6: 按照 $d(t) = v(t) - m(t)$ 获得 $d(t)$, 若 $d(t)$ 满足迭代终止条件, 则认为其是当前 IMF, 否则转至步骤 2。

采用 MEMD 对输入信号 $v(t)$ 进行分解, 获得 M 个不同层次的 IMF, 如公式 (2) 所示:

$$v(t) = \sum_{m=1}^M \bar{c}_m(t) + \bar{r}(t) \quad (2.10)$$

式中: $\bar{c}_m(t)$ 表示第 m 个 IMF; $\bar{r}(t)$ 为分解残差。

多元经验模态分解在处理非平稳和非线性数据上具有明显优势, 因为它能够自适应地提取出数据的内在模态, 而不需要依赖于预先设定的基函数或模型。为此, 文中采用 MEMD 对碳价格序列和影响因素序列进行分解, 获得多层次的 IMF。

2.1.5 多元变分模态分解(MVMD)

作为变分模态分解的多元拓展, MVMD (2019) 继承了 VMD 的许多优秀特性, 同时充分利用了多通道数据之间的关联性, 具有频率对齐特性。

变分模态分解是一种数据分解的变分方法,通过求解凸优化问题,自适应地获得信号的主模态该方法在服从模态完全重构输入信号的约束条件下,提出了一个使模态集体带宽最小的优化问题。MVMD的主要目标是从包含 C 个数据通道的输入数据 $x(t)$ 中提取预定义的 K 个多元调制振荡函数 $u_k(t)$ 即 $x(t) = [x_1(t), x_2(t), \dots, x_C(t)]$. 且有

$$x(t) = \sum_{k=1}^K u_k(t) \quad (2.11)$$

其中 $u_k(t) = [u_1(t), u_2(t), \dots, u_C(t)]$ 。

多元变分问题,即在每个模态都是一个中心频率的有限带宽前提下,寻找 K 个模态函数,使所有模态的估计带宽之和最小,其约束条件为所有模态的和是原始输入信号。

MVMD 的约束优化问题如下:

$$\begin{cases} \min \left\{ \sum_k \sum_c \left\| \partial_t [u_{+,c}^{k,c}(t) e^{-j\omega_k t}] \right\|_{\frac{2}{2}} \right\} \\ s.t. \sum_k \|u_{k,c}(t) = x_c(t)\|, c = 1, 2, \dots, C \end{cases} \quad (2.12)$$

求解变分问题需要引入二次惩罚因子 α 和拉格朗日乘法算子 λ , 将约束变分问题变成一个无约束的变分问题,其中 α 可以保证在存在高斯噪声的情况下进行信号重构的精度, λ 能够确保严格满足约束得到的增广拉格朗日函数为

$$\begin{aligned} L(\{u_{k,c}\}, \{\omega_k\}, \lambda_c) &= \alpha \sum_k \sum_c \left\| \partial_t [u_{+,c}^{k,c}(t) e^{-j\omega_k t}] \right\|_{\frac{2}{2}} \\ &+ \sum_c \left\| x_c(t) - \sum_k u_{k,c}(t) \right\|_{\frac{2}{2}} + \sum_c \left\langle \lambda_c, x_c(t) - \sum_k u_{k,c}(t) \right\rangle \end{aligned} \quad (2.13)$$

然后,采用交替方向乘子法来求解以上变分问题利用 ADMM,将完全优化问题划分为一系列迭代子优化问题在更新模式 $u_k(t)$ 过程中,在第 n 次迭代时考虑以下次优化问题:

$$u_{k,c}^{n+1} = \arg_{u_{k,c}} \min \left\{ \alpha \left\| \partial_t [u_+^{k,c}(t) e^{-j\omega_k t}] \right\|_2^2 + \left\| x_c(t) - \sum_i u_{i,c}(t) + \frac{\lambda_c(t)}{2} \right\|_2^2 \right\} \quad (2.14)$$

以上的最小化问题可以在频谱域内得到解决在频域内的更新表示为

$$\hat{u}_{k,c}^{n+1}(\omega) = \frac{\hat{x}_c(\omega) - \sum_{i \neq k} \hat{u}_{i,c}^{n+1}(\omega) + \frac{\hat{\lambda}_c(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (2.15)$$

为了更新中心频率 ω_k ,需要迭代求解以下次优化问题:

$$\omega_k^{n+1} = \arg_{\omega_k} \min \left\{ \sum_c \left\| \partial_t [u_+^{k,c}(t) e^{-j\omega_k t}] \right\|_2^2 \right\} \quad (2.16)$$

中心频率 ω_k^{n+1} 可以在双频域进行更新,估计新频率为相关模式功率谱的重心:

$$\omega_k^{n+1} = \frac{\sum_c \int_0^\infty \omega |\hat{u}_{k,c}(\omega)|^2 d\omega}{\sum_c \int_0^\infty |\hat{u}_{k,c}(\omega)| d\omega} \quad (2.17)$$

2.2 因素筛选模型

2.2.1 梯度提升迭代决策树模型(GBDT-CART)

本文通过 GBDT-CART 模型对碳价格的影响因素数据集进行重要性排序。给定训练集 $D = \{(x_i, y_i)\}_{i=1}^m$, 其中 $x_i \in \chi \subseteq R^d$, χ 为实例空间, $y_i \in Y \subseteq R$, 损失函数 L 。

步骤一: 初始化模型 $F_0(x)$, 估计使损失函数最小化的常数值 γ , 初始模型是只有一个根结点的树。

$$F_0(x) = \arg \min_{\gamma} \sum_{i=1}^m L(y_i, \gamma) \quad (2.18)$$

步骤二: 对样本 $i = 1, 2, \dots, m$, 计算负梯度:

$$r_{ti} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x) = F_{t-1}(x)} \quad (2.19)$$

步骤三：利用 $(x_i, r_{ti}), i = 1, 2, \dots, m$ ，拟合一棵回归树，得到第 t 棵树的叶节点区域 $R_{tj}, j = 1, 2, \dots, J$ ；

步骤四：对每个叶节点区域 $R_{tj}, j = 1, 2, \dots, J$ ，计算能使区域 R_{tj} 损失函数最小的最佳预测值 γ_{tj} ：

$$\gamma_{tj} = \underset{\gamma}{\operatorname{arg\,min}} \sum_{x_i \in R_{tj}} L(y_i, F_{t-1}(x_i) + \gamma) \quad (2.20)$$

步骤五：得到本轮迭代最佳的拟合回归树：

$$f_t(x) = \sum_{j=1}^J \gamma_{tj} I(x \in R_{tj}) \quad (2.21)$$

步骤六：更新本轮迭代的加法模型：

$$F_t(x) = F_{t-1}(x) + f_t(x) = F_{t-1}(x) + \sum_{j=1}^J \gamma_{tj} I(x \in R_{tj}) \quad (2.22)$$

步骤七：得到最终的强学习器：

$$F(x) = F_T(x) = \sum_{t=1}^T \sum_{j=1}^J \gamma_{tj} I(x \in R_{tj}) \quad (2.23)$$

2.2.2 Lasso 回归

本文利用 Lasso 回归进行指标筛选以克服指标间的多重共线性问题。Tibshirani (1996) 提出的一种压缩估计 Lasso 回归，其数学描述为

$$\operatorname{arg\,min} \left\{ \sum_{i=1}^n \left(y_i - \alpha - \sum_{j=1}^p \beta_j x_{ij} \right)^2 + \lambda \sum_{j=1}^p |\beta_j| \right\} \quad (2.24)$$

其中， x_{ij} 为解释变量， y_i 为被解释变量， $\left(y_i - \alpha - \sum_{j=1}^p \beta_j x_{ij} \right)^2$ 为残差平方和，

α 为截距项， β_j 为回归系数； $\lambda \sum_{j=1}^p |\beta_j|$ 为惩罚项，其中 λ 为惩罚参数，值越大被删

除的变量越多。

2.3 多尺度散布熵(MDE)

在衡量多序列信号复杂度的熵值群中，散布熵（Dispersion Entropy, DE）有着高计算效率和对复杂信号典型特征的高敏感性的特点，DE 表达式为：

$$DE(x, n, c, d) = - \sum_{\pi=1}^{c^n} P(\pi_{v_0 v_1 \dots v_{n-1}}) \ln(P(\pi_{v_0 v_1 \dots v_{n-1}})) \quad (2.25)$$

多尺度散布熵（Multiscale Dispersion Entropy, MDE）（2019）通过对原信号进行粗粒化处理，得到 τ 个多尺度信号，并分别计算其 DE 值得到。粗粒化过程即对长度为 N 的原始时域信号 $x_j (1 \leq j \leq N)$ ，通过下式构造 τ 个尺度信号序列：

$$y_j^{(\tau)} = \frac{1}{\tau} \sum_{i=(j-1)\tau+1}^{j\tau} x_i, 1 \leq j \leq \frac{N}{\tau} \quad (2.26)$$

其中 $\tau = 1, 2, \dots$ 为尺度因子，若 $\tau = 1$ ，则为原始时域信号；当 $\tau > 1$ 时，原始时域信号被分割为 τ 个长度为 N/τ 的粗粒化序列。

对于上述所得 τ 个粗粒序列 $y_j^{(\tau)}$ ，分别计算其散布熵值，则 MDE 表达式为：

$$MDE(x, n, c, d, \tau) = DE(y_j^\tau, n, c, d) \quad (2.27)$$

2.4 预测模型

2.4.1 艾尔曼神经网络模型(Elman)

Elman 神经网络（1996）是基于其独特的网络结构和动态信息处理能力。艾尔曼神经网络是一种典型的动态递归神经网络，它在 BP 神经网络的基础上，通过增加一个承接层（也称为上下文层或状态层）来实现对历史信息的记忆和处理。

该网络一般分为四层：输入层、隐层、承接层和输出层。输入层和隐层的连接类似于前馈网络，而隐层的输出通过承接层的延迟与存储，自联到隐层的输入。这种自联方式使得艾尔曼神经网络对历史数据具有敏感性，可以捕捉和记忆输入

数据的动态变化。

在进行预测时, 艾尔曼神经网络利用先前的输出和当前输入来共同决定当前的输出。承接层存储了隐层前一个时间步长的输出, 相当于引入了时间延迟, 使得网络可以处理时间序列数据, 并对未来的趋势进行预测。隐层的传递函数仍为某种非线性函数, 一般为 Sigmoid 函数, 输出层为线性函数, 关联层也为线性函数。

$$y(k) = g(w^3 x(k)) \quad (2.28)$$

$$x(k) = f(w^1 x_c(k) + w^2(u(k-1))) \quad (2.29)$$

$$x_c(k) = x(k-1) \quad (2.30)$$

式中, y 为 m 维输出结点向量; x 为 n 维中间层结点单元向量; u 为 r 维输入向量; x_c 为 n 维反馈状态向量; w^3 为中间层到输出层连接权值; w^2 为输入层到中间层连接权值; w^1 为承接层到中间层的连接权值; $g(*)$ 为输出神经元的传递函数, 是中间层输出的线性组合; $f(*)$ 为中间层神经元的传递函数, 常采用 S 函数。

$$E(w) = \sum_{k=1}^n (y_k(w) - \tilde{y}_k(w))^2 \quad (2.31)$$

式中, $\tilde{y}_k(w)$ 为目标输入向量。艾尔曼神经网络的内部反馈网络也增加了其处理动态信息的能力。反馈网络的动态学习特征主要由网络的反馈形式决定, 包括输入延迟、单层输出反馈、神经元自反馈等。这种反馈机制使得网络能够根据先前的状态调整自身的输出, 从而达到动态建模的目的。

2.4.2 自适应提升算法优化的艾尔曼模型(Adaboost-Elman)

AdaBoost 算法 (1996) 是一种典型的积分算法, 每次迭代后都会重新计算分类器的分类错误率。该算法的核心思想是基于相同的训练样本, 进行不同弱预测器的训练, 然后把把这些弱预测器集合起来, 构成一个更强的强预测器。为了提高迭代的分类精度, 在下一次迭代中增加前一次迭代中错误率高的训练样本的初始

权值。最后，将多个弱分类器有机结合，形成一个强分类器，实现识别准确率的整体提升。

Adaboost 是一种迭代算法，可以根据使用者的需求调整模型精度，经常被用于预测问题和分类问题。AdaBoost 算法具有串行积分学习的优点，结合弱预测量之间的相互依赖关系，按照一定的权重成为强预测量。该模型的步骤如下：

步骤一：样本选择。从分解出的每个序列中随机选择 m 组为训练样本， n 组为测试样本。初始化测试数据分布权值 $D_t(i) = 1/m$ ，根据输入和输出的维度对神经网络框架进行确定。

步骤二：弱预测器预测。训练第 t 个弱预测器时，用训练数据训练弱预测器并预测训练数据的输出，得到弱预测器预测误差 e_t ，更新训练样本权值， $g(t)$ 为误差 e_t 之和。

$$e_t = \sum_i D_t(i), i = 1, 2, \dots, m \quad (2.32)$$

且 $g(t) \neq y$ ， $g(t)$ 为预测结果， y 为期望预测结果。

步骤三：计算预测样本权重。根据 $g(t)$ 所得的预测误差 e_t 来计算样本序列的权重，其权重计算公式为：

$$a_t = \frac{1}{2} \ln \left(\frac{1 - e_t}{e_t} \right) \quad (2.33)$$

步骤四：测试样本数据权重调整。根据上式中得到的预测序列权重 a_t 来调整下一个训练样本的权重：

$$D_{t+1}(i) = \frac{D_t(i)}{B_t} * \exp[-a_t y_i g_t(x_i)] \quad (2.34)$$

B_t 是一种归一化因子，目的是使得权值之和相加为 1。

步骤五：强预测器获取。在经过训 T 次训练得到了 T 组弱预测函数 $f(g(t), a(t))$ ，组合得到最终精度更高的强预测函数 $h(x)$ ：

$$h(x) = \text{sign} \left[\sum_{t=1}^T a_t \cdot f(g_t, a_t) \right] \tag{2.35}$$

2.4.3 遗传算法优化的艾尔曼模型(GA-Elman)

GA 遗传算法（1992）是一种具有高度并行性、随机性和适应性的全局搜索算法。遗传算法的全局搜索能力通常被用来解决多目标优化、最优路径和特征选择等问题。遗传算法被广泛应用于训练连接权重、设计网络结构和寻找最优学习方法等领域。因此，本研究采用遗传算法优化 Elman 神经网络，解决神经网络算法的局部最优问题，主要用于优化 Elman 神经网络的初始权重和阈值。

GA-Elman 的主要流程为：1)确定神经网络的拓扑结构，比如神经元个数等；2)Elman 神经网络的初始化，编码初始权重和阈值；3)选择合适的适应度函数；4)在选择、交叉、变异中迭代计算，直到得到最优权重和阈值；5)误差计算。检查是否符合条件，是否继续迭代。如图 2.1 所示。

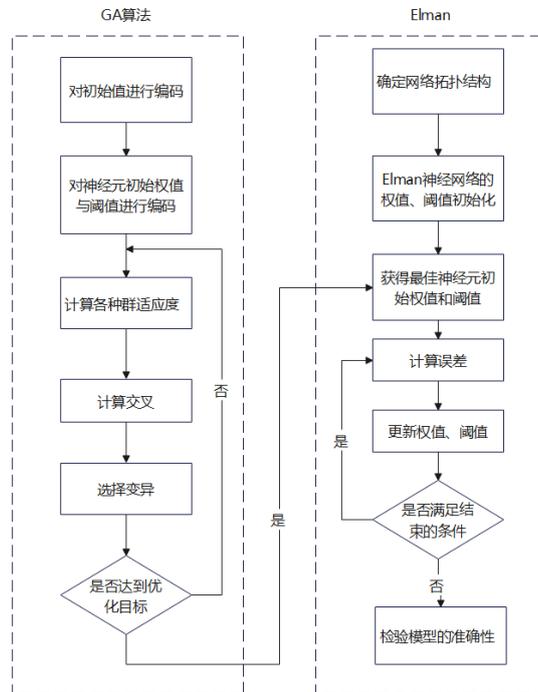


图 2.1 GA-Elman 神经网络模型流程图

2.4.4 极限学习机模型(ELM)

ELM 模型 (2006) 是一种基于单隐含层前馈神经网络的新算法。相较传统学习算法训练时间长、迭代次数多、容易陷入局部最优解等问题,ELM 具有训练速度快、泛用性广、误差小等优点。此类模型随机产生输入层与隐藏层间的连接权值和隐藏层神经元的阈值,只需设置隐藏层神经元数量,待训练完成后就可得到全局最优解。

KELM (2011) 将核函数引入 ELM 理论中,可以得到最小平方优化解,解决了 ELM 算法随机初始化问题。KELM 可以自动地处理非线性数据,因其核函数映射输入数据到 1 个更高维的空间,使得在这个新的空间中,原本非线性的问题变得线性可分,这使得 KELM 相较于 ELM 在处理复杂的碳排放系统这类非线性问题上更具优势。

KELM 的输出函数为

$$f(x) = h(x)\beta = h(x)H^T \left(HH^T + \frac{1}{R} \right)^{-1} T \quad (2.36)$$

式中: x 为神经网络的输入; β 为输出的权值; $h(x)$ 为特征映射。

引入径向基核函数:

$$\begin{cases} \Omega_{ELM} = HH^T \\ \Omega_{i,j} = h(x_i)h(x_j) = k(x_i, x_j) \end{cases} \quad (2.37)$$

$$f(x) = \begin{bmatrix} k(x, x_1) \\ \vdots \\ k(x, x_n) \end{bmatrix}^T \left(\Omega_{ELM} + \frac{1}{R} \right)^{-1} T \quad (2.38)$$

2.4.5 卷积神经网络(CNN)

CNN 卷积神经网络 (2021) 是深度学习中使用非常广泛的模型,是一个由神经元构成的深度神经网络,其基本结构包括卷积层、池化层和全连接层。CNN 的主要工作原理是提取输入数据中的重要特征,然后将这些特征传递到后续层级,

以进行更高级别的理解和决策。一维卷积不同于二维卷积，一维卷积更加适合对时间序列的预测，其只在一个维度上移动，并与二维卷积都是据的对卷积层和池化层的堆叠，使用卷积层对输入数取的特征提取，计算公式为：

$$X_j^L = f\left(\sum_{i \in M_j} X_j^{L-1} * K_j^L + b_j^L\right) \quad (2.39)$$

其中输入层为 $L-1$ 层； X_j^{L-1} 为特征矩阵，有 j 个特征；输出层为 L ； K_j^L 为输入数据； f 为 ReLU 激活函数。

再利用池化层进行数据压缩为一维向量，进一步保留卷积层所提重要特征，输出结果传到全连接层，全连接层对之前卷积层的池化层所提取到的特征进行整合，然后更新权值，实现反向传播。

2.4.6 双向长短时记忆神经网络模型(BiLSTM)

LSTM (Long Short-Term Memory) 即长短期记忆，适合于处理和预测时间序列中间隔和延迟非常长的重要事件。它的内部机制通过四个门(输入门、遗忘门、输出门和单元状态门)调节信息流，从而了解序列中哪些数据需要保留或丢弃。这种机制使得 LSTM 能够学习只保留相关信息来进行预测，并忘记不相关的数据。

2005 年，Graves (2012) 提出使用完全的后向传播方式训练 LSTM 模型，使 LSTM 的训练结果准确率更高，更能适应长时间序列内部的隐藏信息，它通过两个独立的 LSTM 层工作：一个按时间顺序处理输入，另一个按时间倒序处理输入。这样，BiLSTM 能够分别从正向和反向两个方向捕捉输入序列的特征。最终，BiLSTM 的输出由两个方向的隐藏状态拼接而成。

在 BiLSTM (2021) 中，前向 LSTM 从序列的起始位置到结束位置进行正向处理，而后向 LSTM 则从序列的结束位置到起始位置进行反向处理。这样，每个时刻的输出都融合了来自前后两个方向的上下文信息，从而提高对序列中每个时刻的预测或分类准确性。它可以应用于学习翻译语言、车流预测等前后信息关联较大的问题中。LSTM 神经网络的细胞结构主要由遗忘门 f_t 、输入门 i_t 、输出门 O_t 和细胞状态 4 个部分组成。

通过遗忘门筛选需要过滤掉的上一个 LSTM 细胞的无用信息，如公式 40 所示。

$$f_t = \sigma(U_f \times X_t + W_f \times h_{t-1} + b_f) \quad (2.40)$$

式中： f_t 为遗忘门的输出； σ 为 sigmoid 函数，将输出结果锁定在 0~1； U_f 、 W_f 为权值矩阵； X_t 为新输入的信息； h_{t-1} 是上一个 LSTM 细胞结构的输出； b_f 为偏移量。

再经过输入门]通过新输入的数据和遗忘门过滤后的数据进行下一个细胞的输入。

$$i_t = \sigma(U_i \times X_i + W_i \times h_{t-1} + b_i) \quad (2.41)$$

$$\tilde{C}_t = \tanh(U_c \times X_t + W_c \times h_{t-1} + b_c) \quad (2.42)$$

式中： i_t 为新细胞需要保存的信息； \tilde{C}_t 为原始细胞状态需要保留的信息； \tanh 为正切函数，可以将结果压缩到-1~1； U_i 、 W_i 、 U_c 、 W_c 为权值矩阵； b_i 、 b_c 为偏移量，确定了新细胞需要保留的信息，在确定原始细胞的有用信息和新细胞的保留信息后，更新细胞状态 C_t ，如公式 43 所示。

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (2.43)$$

$$O_t = \sigma(U_o \times X_t + W_o \times h_{t-1} + b_o) \quad (2.44)$$

$$h_t = O_t \times \tanh(C_t) \quad (2.45)$$

最后输出门输出目前的信息如公式 44 和公式 45 所示。式中： U_o 、 W_o 为权值矩阵； b_o 为偏移量； h_t 为当前细胞的输出。

模型的展开结构如图 2.2 所示。其中， x 为输入数据， y 为神经网络模型预测结果，数据从 2 个方向进行输入，并将结果保存到 \vec{H} 和 \vec{H} 中，经过计算，数据输出到输出层 H_i 中，计算过程如公式所示。

$$H_t = [\vec{H} \oplus \vec{H}] \quad (2.46)$$

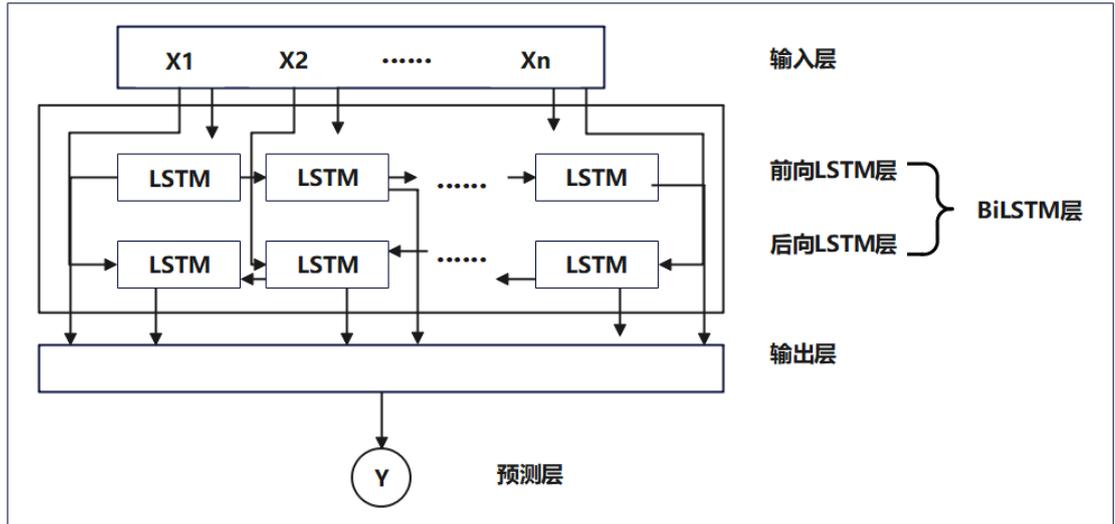


图 2.2 BiLSTM 流程图

2.5 评价指标

为了比较不同模型预测结果的准确性，本文将使用均方根误差（RMSE）、平均绝对误差（MAE）、平均平方误差（MSE）和对称平均绝对百分比误差（SMAPE）用于评估预测误差的大小。假设 y_t 为碳价格序列的实际值， \hat{y}_t 为碳价格序列的预测值， n 为预测序列的个数。则准则的算法如式所示。

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (2.47)$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (2.48)$$

$$SMAPE = \frac{100\%}{n} \sum_{t=1}^n \left(\frac{|\hat{y}_t - y_t|}{\left(\frac{|\hat{y}_t| + |y_t|}{2} \right)} \right)^2 \quad (2.49)$$

其中，MAE 反映了预测的误差，SMAPE 反映了预测值与真实值相差的百分比程度，RMSE 反映了预测值与真实值之间的偏差。RMSE、MAE 和 SMAPE 值越小，表明预测值与实际值的偏差越小。

3 基于同步多分解集成预测方法下的碳价格预测

3.1 预测框架

根据对已有文献的探究和相关领域研究方法的学习,本章针对中国碳市场价格序列特点提出 EMD\OVMD\SSA-Adaboost-Elman 预测模型,基本框架如图 3.1 所示。本章提出的研究模型主要包含以下几个步骤:

步骤一:数据分解。将北京、深圳、湖北碳排放权交易所的碳价数据分别输入到 SSA 分解算法、EMD 分解算法、OVMD 分解算法中,得到各个分解通路分解得到的子序列;

步骤二:序列重构。将各分解方法得到的子序列分别计算其 Lempel-Ziv 复杂度,根据各子序列的 Lempel-Ziv 复杂度输入到 K 均值聚类法中,根据肘部法则选择适合的类目数量进行重构;

步骤三:模型预测。将重构后的序列输入到 Adaboost-ELMAN 模型中进行预测,得到序列的预测值,将重构序列的预测值进行线性加总;

步骤四:数据重构。将三个分解通路得到的预测值进行 BP 非线性集成,得到最终的预测值。模型的构建流程如图 3.1 所示。

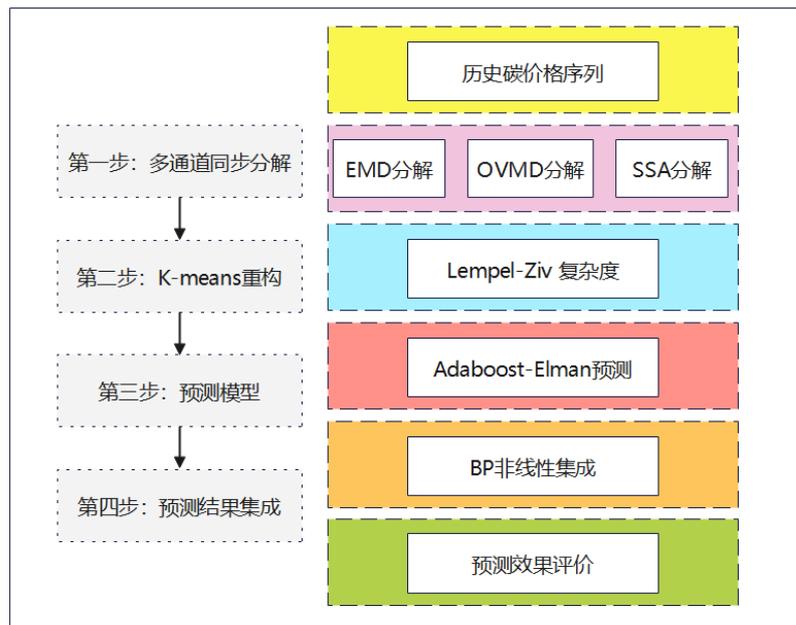


图 3.1 预测框架流程图

3.2 数据预处理

本文选取北京、深圳、湖北三个碳交易所的碳价格作为研究对象，深圳是全国首个启动碳排放权交易试点的城市，流动率多年稳居全国第一，湖北作为累计成交量和累计成交额第一的碳交易所，北京碳交易所更是作为响应首都政策第一梯队，都在不同的层面具有代表性意义。由于北京、深圳、湖北交易所的建立时间不同，所以本文在不同的碳交易所选取碳价序列的时间段不同。

本文对于深圳交易所和北京交易所采用 2013 年 12 月份到 2022 年 3 月份的月度数据，共 100 个样本数据；湖北交易所采用 2014 年 4 月份到 2022 年 3 月份的月度数据，共 96 个样本数据。数据的训练集测试集比例为 8: 2，前 80% 的数据作为训练集，后 20% 的数据作为测试集。本文三个交易所的碳价数据均来源于 wind 数据库。三个交易所原始碳价趋势如图 3.2 所示。

对北京、深圳、湖北三个碳交易所对应时间段的碳价数据进行描述性统计分析后可知，北京碳价的标准差为 16.257，深圳碳价的标准差为 17.736，湖北碳价的标准差为 8.469，说明三个碳交易所碳价格的较为离散，且北京、深圳、湖北的碳价序列在 1%、5%、10% 的水平下的检验临界值都小于 t 检验值， P 值均大于 0.05，说明三个碳交易所碳价格序列都具有非平稳性，这可能是由于宏观经济政策、国内外能源价格等因素导致的。三家碳价格序列经过非线性检验后可知，北京、深圳、湖北碳价格序列嵌入维度为 10 时的 BDS 统计量分别为 0.321322、0.318828、0.278368，且 P 值均为 0，说明三家碳交易所碳价格序列均为显著的非线性序列，这意味着先分解后预测顺序的必要性。

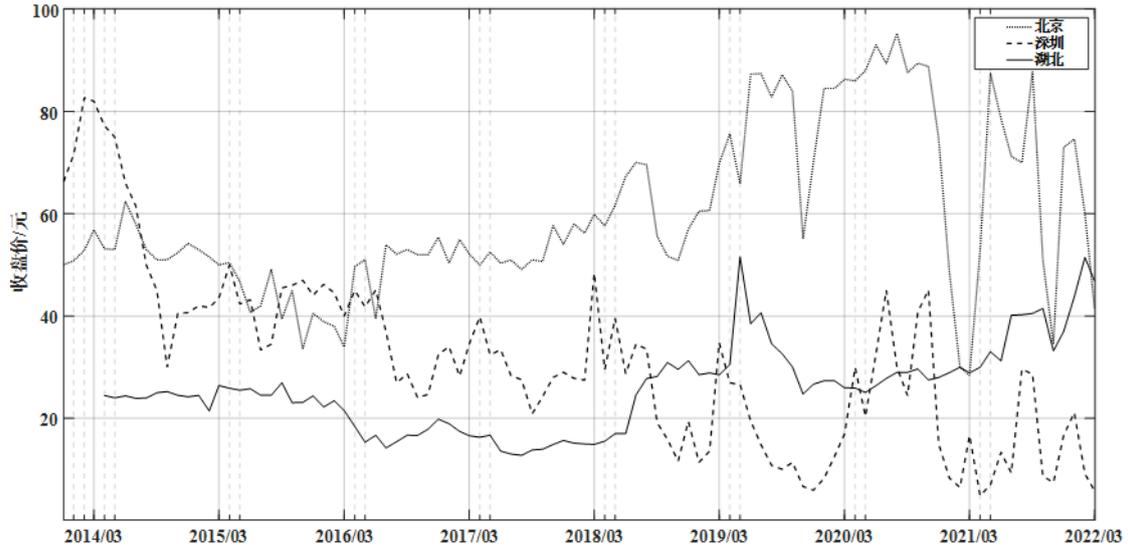


图 3.2 三个碳交易所碳价格趋势图

3.3 建立预测模型

3.3.1 多通道分解重构

首先将每一个交易所的碳价格都通过三种分解方法进行分解,由于不同的分解方法确定分解子序列个数的标准不同,所以不同的交易所在不同的分解方法下的分解子序列个数不同。其中,EMD 分解方法可以自行确定分解的个数,SSA 分解方法通过奇异值的奇异熵来判断能够包含原始序列大部分信息的分解个数,OVMD 分解方法通过计算不同分解阶数下分解序列的方差贡献率来确定分解阶数,由于经过分解得到子序列数量较多,若直接将分解得到的子序列分别进行预测,会导致较大的工作量,所以在分解之后、预测之前要进行子序列的重构。

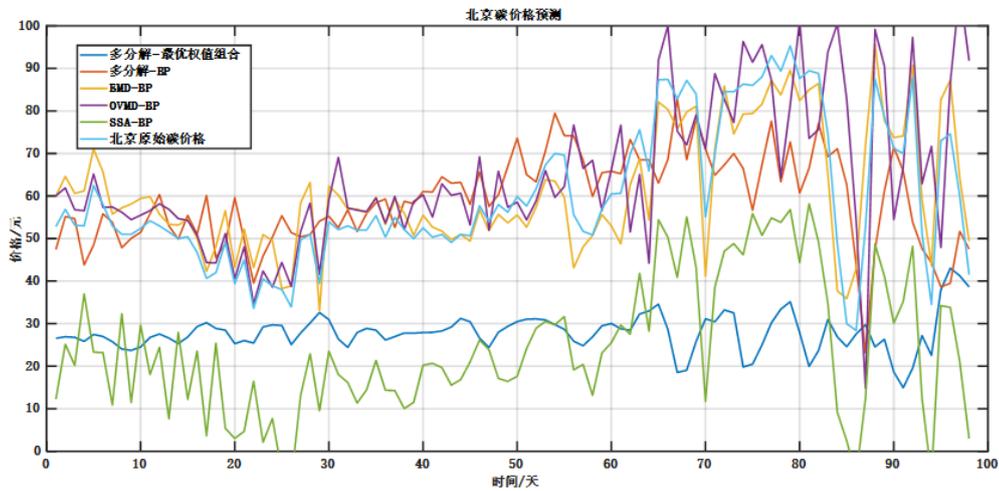
本章采用计算各子序列的 Lempel-Ziv 复杂度,将不同子序列的复杂程度进行统一标准量化,并以此为依据进行 K 均值重构。进行重构时,本章并没有提前主观规定聚类的个数,比如高低频等,而是按照肘部法则来确定合适的聚类个数,最终各个交易所的聚类个数如下表 3.1 所示。

表 3.1 不同交易所的聚类个数

交易所	EMD	OVMD	SSA
北京	3	3	4
深圳	3	3	4
湖北	3	3	4

3.3.2 Adaboost-Elman 预测

将聚类后的子序列输入到 Adaboost-ELMAN 模型中进行预测，并将预测得到的子序列输入到 BP 神经网络中进行非线性集成，最终评价指标进行评估。为了验证本研究提出的模型的有效性和优越性，同时将单一分解方法的 EMD-Ada-ELMAN、OVMD-Ada-ELMAN、SSA-Ada-ELMAN 模型拿来对比，在集成方法上，本研究采用 BP 神经网络非线性集成和赵鑫等采用的最优加权法(Owc)进行对比。北京、深圳、湖北交易所的碳价格预测结果如图 3.3 所示。



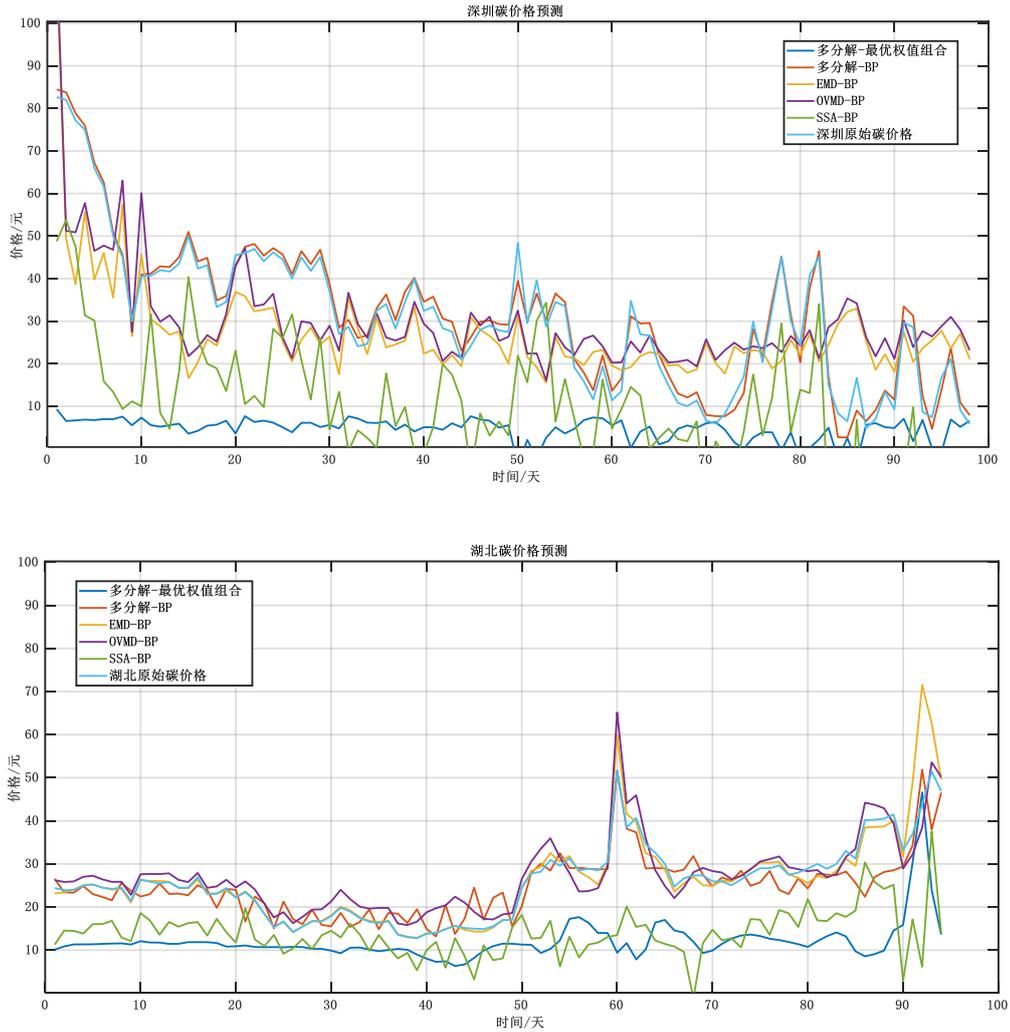


图 3.3 Adaboost-Elman 预测碳价格趋势图

3.4 预测模型评价

在不同分解方法上，单一的 EMD、OVMD、SSA 分解方法中，EMD 分解的模型和 OVMD 分解的模型在北京、深圳、湖北三个交易所的 MAE、RMSE 指标上表现较好，但是 SMAPE 表现较差；基于 SSA 分解方法的预测模型在北京、深圳、湖北三个交易所的各个指标上的表现，效果不甚理想。具体精度对比如表 3.2 所示。

表 3.2 模型预测效果对比

交易所	模型	MAE	RMSE	SMAPE
北京	多分解-Adaboost-ELMAN-bp	0.2587	0.2823	0.6417
	多分解-Adaboost-ELMAN-Owc	0.4785	0.5420	1.8429
	EMD-Adaboost-ELMAN-bp	0.3047	0.3313	1.3409
	OVMD-Adaboost-ELMAN-bp	0.3173	0.3478	1.1347
	SSA-Adaboost-ELMAN-bp	0.4048	0.4451	1.3884
湖北	多分解-Adaboost-ELMAN-bp	0.2106	0.3158	0.5107
	多分解-Adaboost-ELMAN-Owc	0.3525	0.4020	1.5085
	EMD-Adaboost-ELMAN-bp	0.2561	0.2971	1.6923
	OVMD-Adaboost-ELMAN-bp	0.2534	0.2817	1.3757
	SSA-Adaboost-ELMAN-bp	0.2982	0.3422	1.2724
深圳	多分解-Adaboost-ELMAN-bp	0.2207	0.2651	0.6808
	多分解-Adaboost-ELMAN-Owc	0.3347	0.3970	1.8938
	EMD-Adaboost-ELMAN-bp	0.2515	0.2842	1.2721
	OVMD-Adaboost-ELMAN-bp	0.2534	0.2975	1.2658
	SSA-Adaboost-ELMAN-bp	0.2915	0.3271	1.4738

在不同的非线性集成方法上,使用最优加权法进行集成的方法在评估指标上的表现较差,将预测结果集成的方法改为BP神经网络能够显著的提高预测的精度。

由表 3.2 可知,本文提出的模型在北京交易所的指标 MAE、RMSE 值分别为 0.2587、0.2823,优于提出的其他的对比模型;在湖北交易所的指标 MAE、RMSE 值分别为 0.2106、0.3158,进一步验证了本文提出的模型的有效性和优越性;在深圳交易所的指标 MAE、RMSE 值分别为 0.2207、0.2651,和其他单分解模型相比,本章提出的多通路分解模型的预测精度明显更高。在预测结果的非线性集成部分,本章用最优权值组合法和BP神经网络集成方法进行对比,可以清晰地看出,最优权值组合法集成的预测结果的精度远远低于BP非线性集成的预测结果,这说明在针对碳价格多分解的预测结果集成方面,神经网络模型的非线性集成思路对比线性集成思路有更好的集成结果。这同样也验证了本章提出的模

型在国内单一碳价格数据源的碳价格预测上的优越性。

3.5 本章小结

针对碳价格序列的非平稳性、非线性等复杂序列的特点，本章提出的 EMD\OVMD\SSA-Adaboost-ELMAN-BP 的分解集成组合预测模型，将北京、深圳、湖北三个碳交易所的周度数据作为研究对象进行实证分析。首先，将碳价格序列同步输入到 EMD、OVMD、SSA 三个分解方法中进行分解，得到多个子序列；其次，计算每个子序列的 Lempel-Ziv 复杂度并 K 均值聚类法进行聚类；然后，运用 Adaboost-ELMAN 方法进行预测；最后，利用 BP 神经网络对预测结果进行非线性集成得到最终的预测结果。

将本章的模型和拆分后的单一分解方法的预测模型进行比较，通过评价指标可知本研究提出的模型的优越性，结果表明：EMD\OVMD\SSA-Adaboost-ELMAN-BP 的分解集成组合预测模型适用于碳价格的预测，且模型融合了多种分解方法的优点，具有更强的提取信息能力，使得预测模型能够得到更好的预测效果。

但碳价格序列受很多其他因素的影响，比如国际碳排放权价格、国际汇率、天气等，只考虑碳价格本身时，不能够准确地预测碳价格，所以后续的研究中可以尝试加入其他影响因素，进一步验证模型的可行性。

4 多元模态分解下考虑市场因素的碳价格预测

4.1 预测框架

本章在碳价格序列预测模型中加入了影响碳价格波动的外生因素序列,同时为了确保降低外生影响因素序列的复杂性,减轻因素序列加入预测对模型带来的计算压力,采用了多元经验模态分解方法对碳价格序列和影响因素序列进行同步分解,得到相似频率的分解子序列,使每个子序列含有相似特征的信息。本章采用多元经验模态分解方法对碳价格原始序列与影响因素序列同步进行分解,并作组合预测得到最终预测结果。如图 4.1 所示,具体建模步骤如下。

步骤一:数据选择。选择国内碳交易所种具有代表性的北京、深圳和湖北交易所,并将各交易所的碳排放权收盘价作为碳价格时间序列。查阅碳价格影响因素研究方向的文献,并挑选影响程度较大的 15 个影响因素共同输入模型进行预测。将原始碳价格序列和 15 个影响因素时间序列共 16 个时间序列同步输入到多元经验模态分解(MEMD)中进行分解。

步骤二:熵值重构。对每个序列计算多尺度散布熵(MDE),运用 K 均值聚类法进行聚类,得到重构后的低频和高频序列。

步骤三:因素筛选。对碳价格低频序列的其余 15 个影响因素的低频序列进行 Lasso 筛选,得到最终通过筛选的影响程度较大的影响因素低频序列。同理用于高频序列。

步骤四:组合预测。分别采用多元线性回归预测、BP 神经网络回归预测、遗传算法优化 BP 神经网络回归预测(GA-BP)、ELMAN 神经网络、遗传算法优化 ELMAN 神经网络回归预测(GA-ELMAN)、核极限学习机 KELM、遗传算法优化 KELM 神经网络回归预测(GA-KELM)对低频、高频序列进行预测,将七种低频序列预测方法和六种高频序列预测方法进行组合,得到 42 种组合方式,利用 BP 神经网络进行非线性集成,得到 42 个预测结果。

步骤五:模型评估。对不同的 42 种组合预测模型结果进行非线性集成,并计算每一种模型的平均绝对值误差(MAE)、均方误差(MSE)、均方根误差(RMSE)进行比较分析。

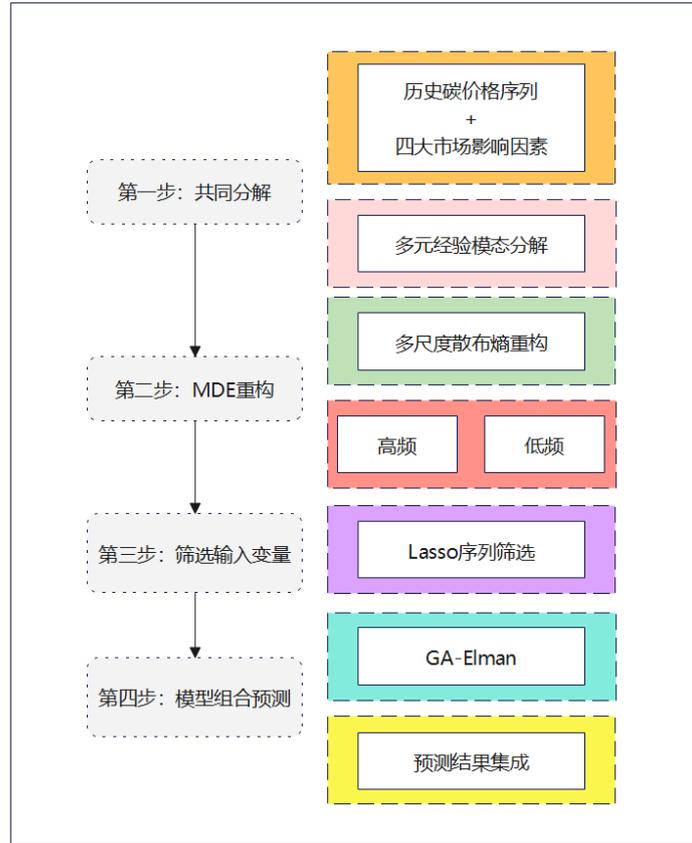


图 4.1 预测框架流程图

4.2 数据预处理

碳市场是一个复杂的非平稳、非线性的系统，会受到能源价格、经济政策等各方面因素的影响，且碳价的历史价格序列能够提供的信息是有限的，所以中把市场因素、国际能源因素等等考虑进去到碳价格的预测当中去，能够帮助学者捕捉更多的变化。在考虑如何选择影响因素方面，洪涓等（2009）从国际需求、国内供给、国内限价政策以及国际市场等方面进一步探究了影响中国碳价格的影响因素；胡登龙（2016）从市场因素、环境因素和政策因素三方面，再比较国际碳价形成机制，对国内碳价的影响因素及其形成机制进行探讨；陆敏等（2019）通过灰色关联方法，主要探究了中国能源价格对中国碳排放权价格的影响；周建国等（2016）通过挖掘国际碳价、国内外经济状况、国内外能源价格及汇率等方面的因素对中国碳价变化的影响，发现我国历史碳价的变化受我国经济状况影响较大；王小燕等（2022）通过对国际碳价、国内外经济指标、国外能源指标、国内

能源指标、气候环境和宏观政策六个方面进行探究，最终筛选出对广州碳价格产生正或负影响的涉及各个方面的影响因素。

4.2.1 碳价格影响因素的选取

本文结合已有对中国碳价影响因素研究的文献，准备从国际碳价、国内外经济指标、国内外能源指标、气候环境 4 个方面入手筛选影响因素。

首先在国际碳价上，选取欧盟排放配额（EUA）作为代表因素，在同水平的技术条件下，配额数量的增加导致市场供给的增加，进而会导致平均价格的下降，在碳排放权交易体系中，欧盟由于开始时间较早已有较为成熟的交易体系，对于中国在建立自己的碳排放权交易体系之初有重要的参考价值，故认为 EUA 的价格波动与中国碳价波动在一定程度上有所关联。其次在国内外经济指标方面主要选取欧洲斯托克 50 指数、国库券、标准普尔 500 指数、SHIBOR、沪深 300 指数进行描述，经济发展对带动生产活动有正向需求引导，二氧化碳排放量上升，进而导致碳排放权配额价格上涨。天然气、煤气、原油等能源材料的消耗可以对二氧化碳气体排放量产生正向或负向的影响，这都会进一步影响碳排放权价格，在国内外能源方面采用了 NYMEX 天然气期货收盘价、欧洲三港 DESARA 动力煤指数、布伦特原油期货指数收盘价、IPE 鹿特丹煤炭期货收盘价。在气候环境方面，温度的变化影响供暖的时长，供暖时长的延长会导致碳排放气体的增加，也是对碳排放权价格有所影响，故针对三个碳交易所地区不同采用各自区域的气温最低温度和最高温度，并利用美元汇率来说明汇率变动对碳价序列的影响。

4.2.2 MEMD 分解

通过对初步选取的碳价格影响因素的非线性检验可知，三个交易所的碳价格序列和影响因素序列全部是非平稳序列，这说明如果我们想要对碳价格序列进行准确地预测，让影响因素成功发挥提高预测精度的作用，那么首先一步的分解必不可少。分解方法能够让序列的长期趋势和短期波动项剥离，形成各具波动特征子序列，之后再采用针对性的预测方法来对长期趋势序列和短期波动序列进行预测，这能够大大提高模型的预测能力。

将北京、湖北、深圳碳价格序列和其他初步筛选的共 15 个影响因素同步输

入到 MEMD 分解算法中，得到了 7 个分解子序列各自具有其波动特征，振幅、频率、周期等各不相同。北京、湖北、深圳碳价格的分解结果如图 4.2 所示。

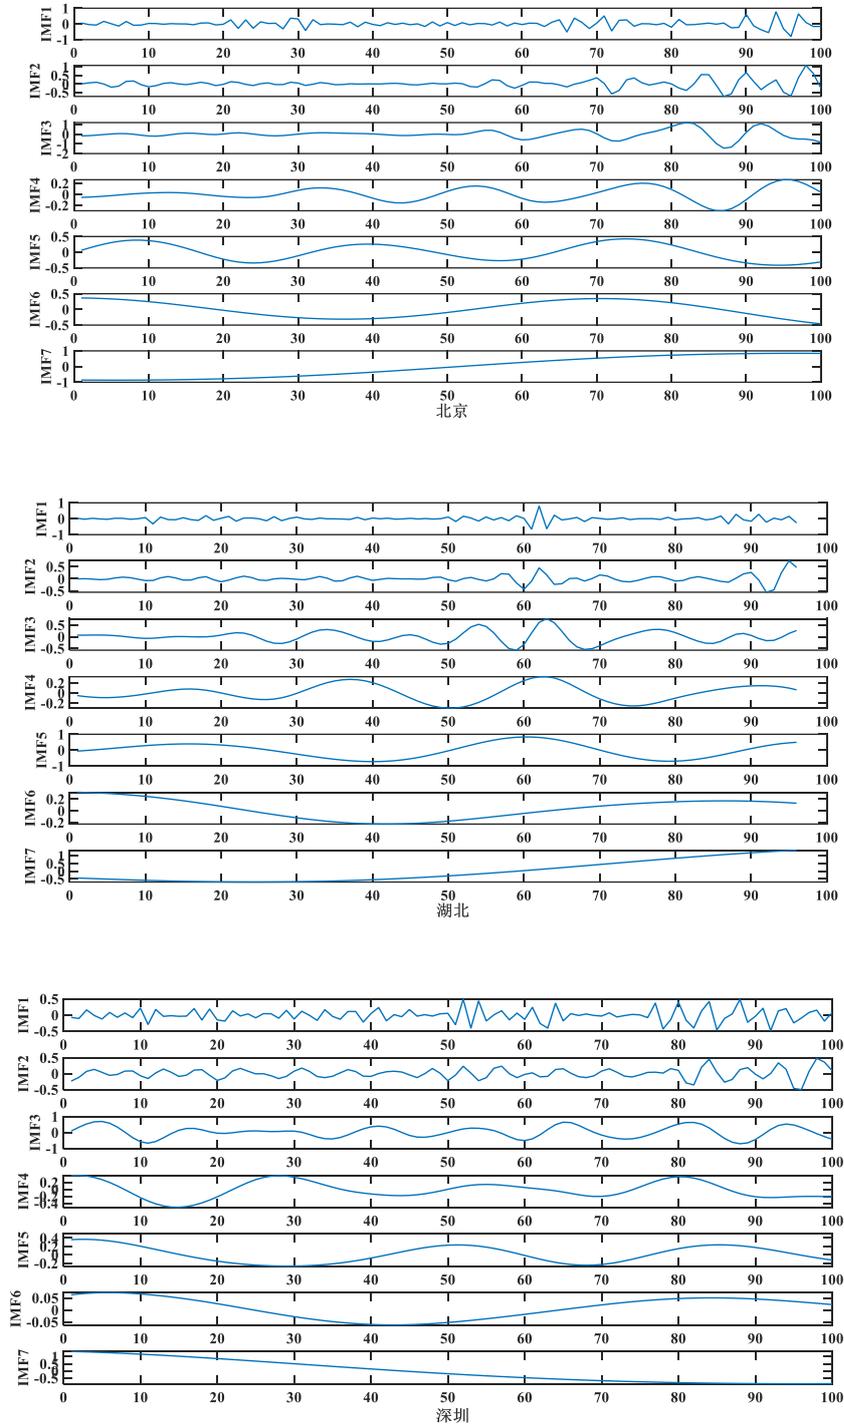


图 4.2 北京、湖北、深圳碳价格序列分解示意图

4.2.3 分解序列重构

本文意图将通过 MEMD 分解得到的各因素的子序列分为高频和低频两类，K 均值聚类能够将复杂度相似的熵值分为一类。根据不同子序列分类情况进行聚类，得到最终的高频低频序列。北京、深圳、湖北碳价格序列的重构如附表 1、图 4.3 所示。

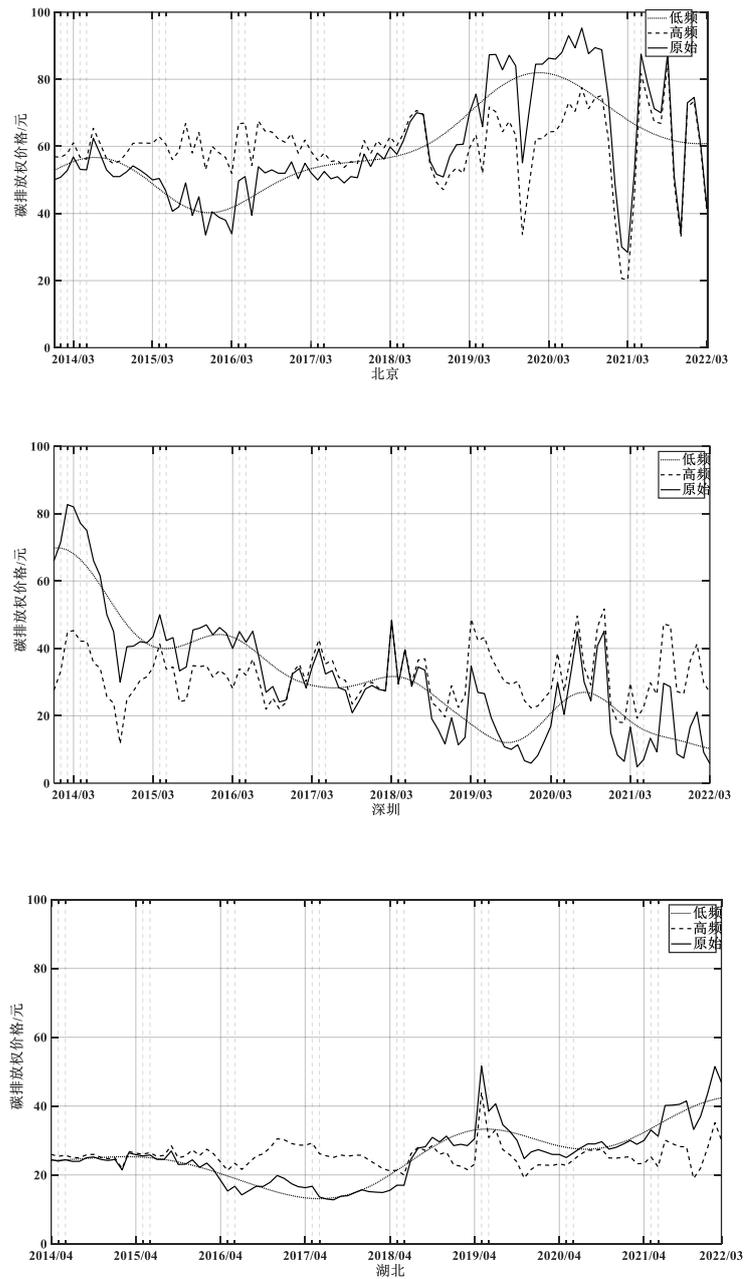


图 4.3 北京、湖北、深圳重构序列图

4.2.4 Lasso 筛选影响因素

为了探索影响高频序列和低频序列的不同影响因素都有哪些,有必要再次进行影响因素的筛选,本研究采用 Lasso 方法对高频和低频的影响因素进行筛选,直接剔除影响程度较小的因素,留下影响较大的因素,能够有效提高后续的模型预测精度。在经过 person 相关系数进一步筛选, Lasso 最终选择后三个交易所分别的影响因素,北京、深圳、湖北碳交易所的影响因素如表 4.1 所示。

表 4.1 Lasso 筛选影响因素

交易所	重构	剩余影响因素
北京	低频	国库券 NYMEX 天然气期货收盘价 商品研究局期货指数 CRB 标准普尔 500 指数 SHIBOR 沪深 300 指数 美元汇率 极端高温 投资者情绪指数
	高频	无
深圳	低频	欧洲三港 DESARA 动力煤指数 商品研究局期货指数 CRB 欧洲斯托克 50 指数 SHIBOR 沪深 300 指数 美元汇率 极端高温 投资者情绪指数
	高频	无
湖北	低频	布伦特原油期货指数收盘价 标准普尔 500 指数 欧洲斯托克 50 指数 SHIBOR 沪深 300 指数 极端高温
	高频	无

由表 4.1 中的内容可以得知, 在影响北京碳价格的低频率序列的因素中有 NYMEX 天然气期货收盘价、商品研究局期货指数 CRB、国库券、极端高温、标准普尔 500 指数、SHIBOR、沪深 300 指数、美元汇率、投资者情绪指数。

影响深圳碳价格低频率序列的影响因素有欧洲三港 DESARA 动力煤指数、商品研究局期货指数 CRB、欧洲斯托克 50 指数、SHIBOR、沪深 300 指数、美元汇率、极端高温和投资者情绪指数。

影响湖北碳价格的长期趋势的影响因素有布伦特原油期货指数收盘价、标准普尔 500 指数、欧洲斯托克 50 指数、SHIBOR、沪深 300 指数和极端高温。

从 Lasso 的筛选结果中可以看出, 北京、湖北、深圳三个碳交易所存在相同的影响因素有商品研究局期货指数 CRB、标准普尔 500 指数、欧洲斯托克 50 指数、极端高温、SHIBOR、沪深 300 指数、美元汇率、投资者情绪指数。碳排放权交易价格的波动受到多方面影响, 这些相同的影响因素都是在一定程度上反映经济形势、金融市场、政策因素、供求关系等市场的变动关系。

在能源价格方面, 影响北京碳价格的是 NYMEX 天然气期货收盘价, 影响深圳碳价格的是欧洲三港 DESARA 动力煤指数, 影响湖北碳价格的是布伦特原油期货指数收盘价, 从能源价格因素的不同中可知, 北京市企业生产活动中最依赖天然气能源, 随着环境意识的增强和清洁能源政策的推广, 北京在能源供应和消费方面正逐步减少对煤炭等传统能源的依赖, 而加大对清洁能源, 如天然气和可再生能源的使用。天然气作为一种相对清洁的替代能源, 正在更广泛地替代传统的煤炭和石油, 成为企业生产活动中的重要能源来源; 深圳作为中国经济的重要城市之一, 其经济发展和能源消费受到全球经济形势的影响。欧洲三港 DESARA 动力煤指数是国际煤炭市场的重要指标, 其价格变动受到全球经济形势、能源政策、贸易关系等多种因素的影响。国际煤炭市场价格波动可能通过影响深圳企业的生产成本和能源供应, 进而影响到深圳碳排放权交易价格, 又或许因其受国际金融市场波动的原因与深圳碳价格产生相关程度较高的波动被筛选; 布伦特原油期货指数与湖北碳排放权交易价格之间存在正相关关系。原油价格的变动往往与全球经济形势密切相关。当布伦特原油期货指数收盘价上涨时, 可能反映出全球经济形势向好, 这将促进湖北地区的经济发展, 提高企业对碳排放权的需求。同时, 良好的经济形势也可能导致能源需求增加, 从而推动碳排放权价格上涨。

4.3 建立预测模型

对于不同的波动程度的序列，本文采用不同的预测模型进行预测。对于碳价格分解序列及其影响因素的低频数据，本文采用多元线性回归、BP 神经网络、GA-BP 神经网络、ELMAN 神经网络、GA-ELMAN 神经网络、KELM 神经网络、GA-KELM 神经网络进行预测，对于碳价格分解序列及其影响因素的高频数据，本文采用 BP 神经网络、GA-BP 神经网络、ELMAN 神经网络、GA-ELMAN 神经网络、KELM 神经网络、GA-KELM 神经网络进行预测。最终将任意一种低频预测结果与任意一种高频预测结果进行 BP 神经网络的非线性集成的结果作为最终的预测结果。

北京、深圳、湖北碳价格各个模型预测结果如图 4.4 所示。

4.4 预测模型评价

针对各个碳交易所碳排放权交易价格序列分解重构得到的高频、低频率序列，不同频率的序列采用不同的预测方法，将各个预测方法下的高频率序列结果与各个预测方法下的低频率序列结果进行集成，通过误差指标来判断高频或低频率序列中，选择预测效果最优的模型，并将各个频率最优模型预测结果进行非线性集成得到该碳交易所下、碳价格序列的最优组合预测模型如表 4.2 所示。

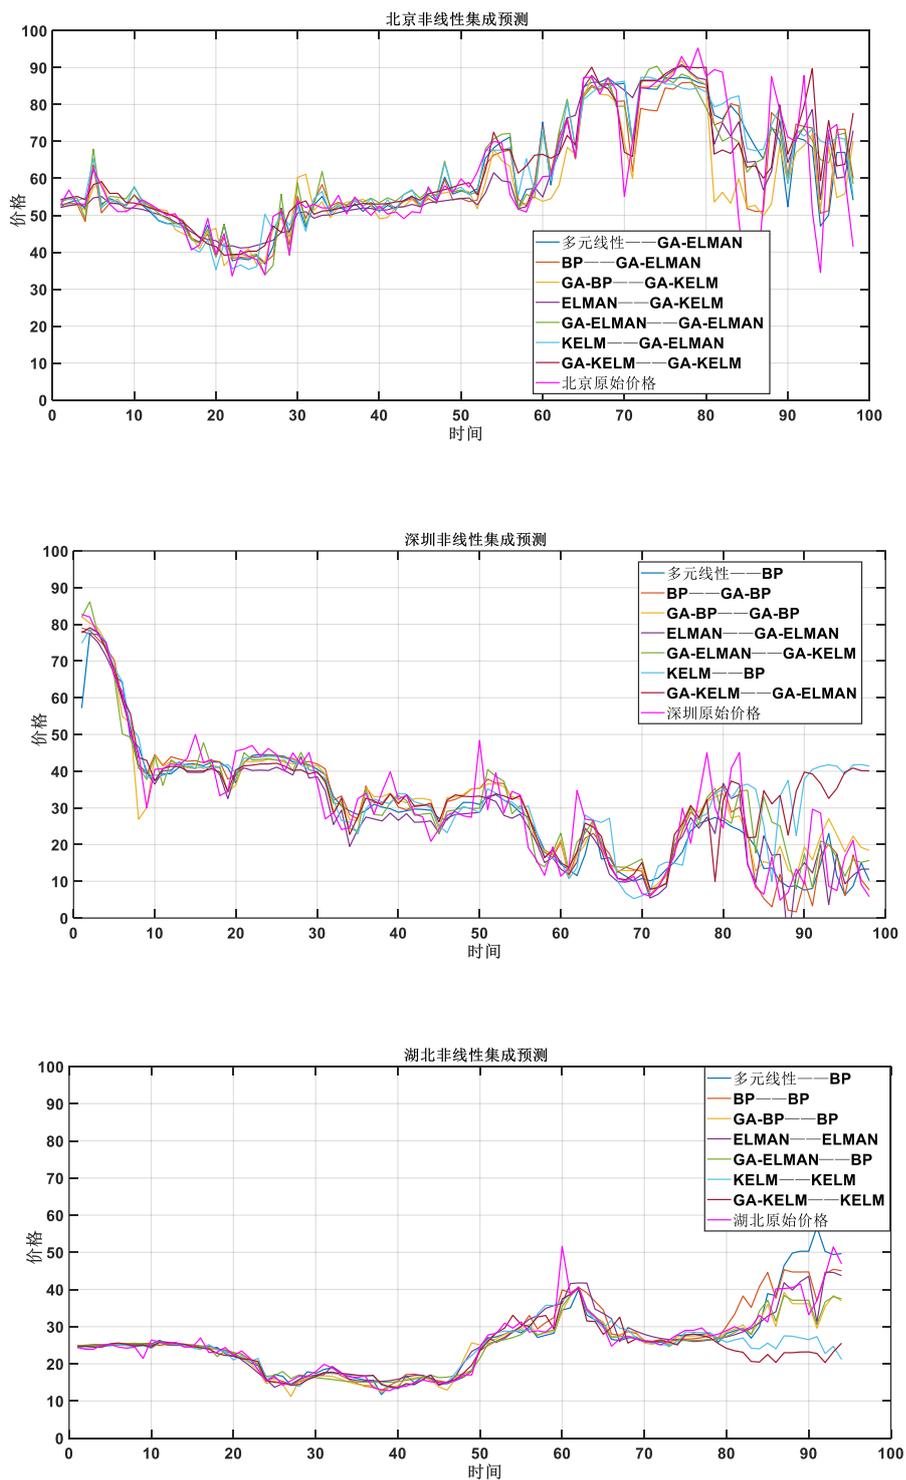


图 4.4 北京、湖北、深圳非线性集成结果

表 4.2 碳交易价格序列预测模型精度比较

交易所	低频	高频	MAE	RMSE	SMAPE
湖北	多元线性回归	BP	0.23747	0.46887	0.30715
	BP	BP	0.24357	0.3842	0.25069
	GA-BP	BP	0.24602	0.41723	0.31626
	ELMAN	ELMAN	0.25377	0.37884	0.26370
	GA-ELMAN	BP	0.2459	0.39269	0.31746
	KELM	KELM	0.37602	0.72493	0.51983
	GA-KELM	KELM	0.42404	0.80786	0.56956
北京	多元线性回归	GA-ELMAN	0.33178	0.5926	0.34183
	BP	GA-ELMAN	0.32581	0.50971	0.34217
	GA-BP	GA-KELM	0.36933	0.60628	0.36658
	ELMAN	GA-KELM	0.35612	0.60683	0.35730
	GA-ELMAN	GA-ELMAN	0.35474	0.56554	0.34792
	KELM	GA-ELMAN	0.37304	0.62711	0.38912
	GA-KELM	GA-KELM	0.36183	0.61474	0.36019
深圳	多元线性回归	BP	0.29521	0.40886	0.23706
	BP	GA-BP	0.2881	0.38599	0.23014
	GA-BP	GA-BP	0.29554	0.39811	0.2563
	ELMAN	GA-ELMAN	0.29357	0.38497	0.24914
	GA-ELMAN	GA-KELM	0.31494	0.43272	0.28573
	KELM	BP	0.43947	0.66289	0.41971
	GA-KELM	GA-ELMAN	0.39997	0.60415	0.38372

由表 4.2 可以看出，最优的预测北京碳价格模型组合为 BP-GA-ELMAN，其中低频部分为 BP 神经网络预测，高频由 GA-ELMAN 神经网络预测，MAE 值为 0.32581，RMSE 值为 0.50971，SMAPE 值为 0.34217。其次效果最优的模型是 BP-KELM，低频由 BP 神经网络预测，高频由 KELM 预测，MAE 值为 0.33643，

RMSE 值 0.52813, SMAPE 值为 0.33705。由此我们能够了解到,在对北京碳价格低频序列进行预测时,简单的线性预测模型不能够很好的预测低频序列,此时机器学习模型表现更佳。在机器学习模型中,简单结构的 BP 神经网络反而相较于复杂的 ELMAN、KELM 神经网络预测效果更好。

BP-BP 模型和 BP-GA-BP 模型的效果比 BP-(GA)ELMAN 或 BP-(GA)KELM 的预测效果差一点,这说明在对波动幅度较大的高频序列时,简单结构的机器预测模型已经不能够满足预测的要求,可以使用 ELMAN 或 KELM 等模型进行预测,当然,如果加入优化算法,例如本文使用的遗传算法,能够帮助进一步提高预测的效果。

由表 4.2 我们可以看到,最优的预测深圳碳价格预测模型组合是 ELMAN-GA-ELMAN。低频序列的预测模型采用 ELMAN 神经网络,高频序列的预测模型为 GA-ELMAN,该组合预测的 MAE 值为 0.29357, RMSE 值为 0.38497, SMAPE 值为 0.24914,证明了该模型的有效性。

通过表 4.2 中的数据我们可以发现,当低频预测方法为多元线性回归、BP 神经网络、ELMAN 神经网络时,无论采用哪种高频预测方法进行预测,其总体的预测精度都处于一个较好的水平。但当我们选择 GA-ELMAN 神经网络、KELM 核极限学习机、GA-KELM 神经网络来进行低频预测时,无论选择哪一种高频预测方法,此时的预测精度都是处于较差的水平。这种对比产生的原因可能是,当面对低频序列预测时,由于序列的大部分波动在分解步骤被清晰的剥离开,且在重构阶段,具有相对复杂波动情况的序列被准确地分到高频序列,剩下频率较低子序列被分为低频序列,这时低频序列相对而言不再复杂,用简单的预测方法,例如多元线性回归预测方法,就能够很好的对低频序列进行预测。如果此时采用较为复杂的机器学习方法、深度学习方法等对低频序列进行预测,这种复杂的预测方法非常依赖参数的调整,如果参数设定偏颇,就会导致厉害的算法反而没有简单的算法效果好的结果。

由表 4.2 可知,最优的预测湖北碳价格的预测模型组合为 ELMAN-ELMAN,低频序列用 ELMAN 神经网络预测,高频序列用 ELMAN 神经网络预测,该模型的 MAE 值为 0.25377, RMSE 值为 0.37884, SMAPE 值为 0.2637,证明该模型的预测精度和拟合效果都是很好的。

通过表 4.2 的数据我们能够发现,通过对比湖北碳价格低频序列用复杂机器学习算法例如 KELM、GA-KELM 等,发现越复杂的低频预测方法越会加大预测的误差。得到分解重构后的低频序列用简单的预测方法进行预测效果会更好的结论,这一发现和深圳、北京碳价格的预测结果是相同的。

4.5 本章小结

本章主要提出了一种将影响因素和碳价格序列同步进行分解再进行预测的方法。由于碳价格的波动性,采用 MEMD 将碳价格序列和影响因素分解为多个分量,并计算各分量多尺度散布熵的大小将其分为高频、低频。通过 BP、ELMAN、KELM 和遗传算法优化的三种神经网络模型分别对高频和低频进行预测,得出预测结果。本章以湖北、深圳、北京碳交易价格为样本,主要结论和创新点如下:

(1) 使用 MEMD 分解方法对碳价格序列和影响因素序列进行分解,提取同尺度共同因子,有效地提高模型预测的精度。对比 EMD、VMD 等单序列分解方法,避免了不同因素序列分解子序列数目不同,也大大减小了工作量。

(2) 本文创新性地应用了多尺度散布熵值 MDE 衡量分解后的各子序列的复杂度,为后续的重构工作提供了便利,降低了预测的难度,提高预测的准确性。

(3) 北京、湖北、深圳每个交易所的碳价格时间序列具有不同的特征,故不同的交易所最优的预测模型不同。但共同点就是 ELMAN 神经网络在此次研究中脱颖而出,成为适用三个交易所的预测模型,证明了 ELMAN 神经网络适合进行时间序列预测。

5 同步多分解技术组合下基于二次筛选数据的碳价格预测

5.1 预测框架

本章节在上一章节的基础上,在外生因素部分加入与中国碳排放权价格有关的百度搜索指数,与国际碳市场、国内外金融市场、国内外能源市场、经济指标和气候环境等因素共同组成影响碳价格预测的外生因素部分。外生因素与历史碳价格做 GBDT-CART 筛选重要的影响因素进入到 MEMD/MVMD 的分解,重构后经过 Pearson-PCA-Granger Causality 的过滤得到最终输入预测模型 CNN-BiLSTM 的高、低、趋势序列。

具体预测模型如图 5.1 所示。

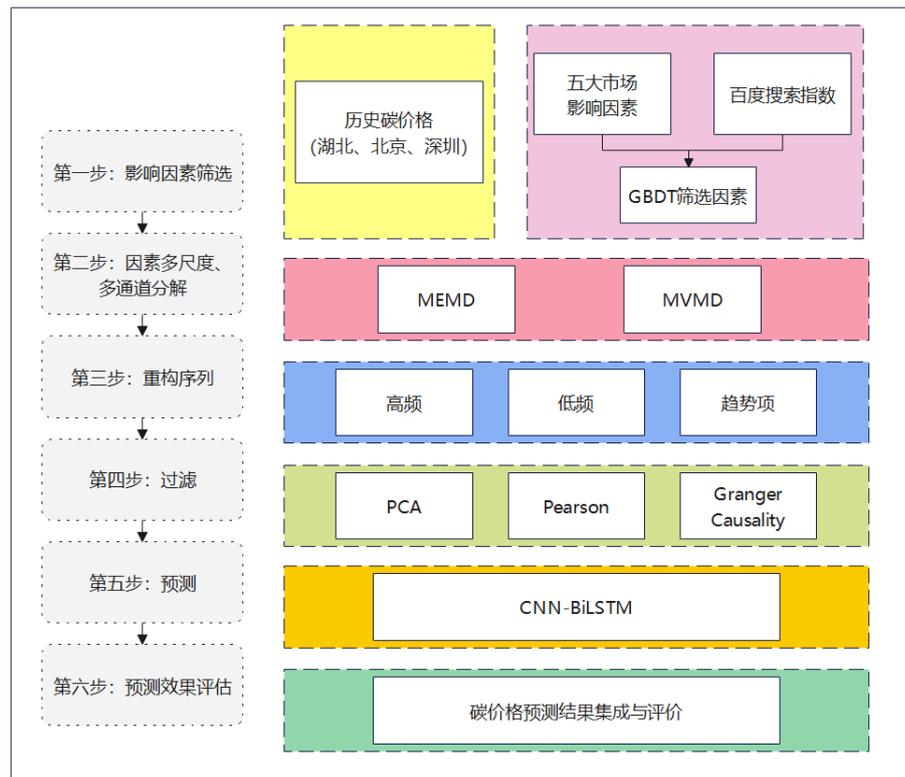


图 5.1 预测框架流程图

5.2 数据预处理

百度搜索引擎作为中国最大的搜索引擎,在中国互联网用户中拥有广泛的认知度和使用率。本文依据百度搜索指数“碳排放”关键词搜索热度和相关性,共选取碳排放相关关键词碳中和、碳排放、碳交易、低碳、碳足迹、节能减排和低碳经济共 7 个,并在国内外金融市场、国际碳市场、国内外能源市场、经济指标以及气候环境五大市场选取,在第四章采用的数据基础上,再加入欧元汇率、工业增加值累计增长、制造业采购经理指数、CSI300、商品研究局期货指数、投资者情绪指数共 21 个外生因素辅助碳价格预测,所有数据来自 Wind 数据库。其中湖北交易所的碳价格选取时间为 2014 年 4 月至 2022 年 3 月,深圳、北京碳交易所选取时间为 2013 年 12 月至 2022 年 3 月。外生因素共有 28 个,所有数据归一化,数据训练集测试集比例为 8: 2。

5.2.1 影响因素的筛选

本文采用 GBDT-CART 回归模型对 28 个外生因素的重要程度进行排序,GBDT 回归模型对北京、湖北、深圳的碳价格、外生因素的回归拟合效果 R^2 分别为 0.759、0.818、0.894,可知其排序结果有较高的可靠性。GBDT 筛选得到的影响因素如表 5.2 可知。

表 5.1 GBDT 回归模型预测评价

交易所	数据集	MSE	RMSE	MAE	R^2
北京	训练集	0	0	0	1
	测试集	0.014	0.12	0.087	0.759
湖北	训练集	0	0.001	0	1
	测试集	0.008	0.089	0.062	0.818
深圳	训练集	0	0	0	1
	测试集	0.006	0.08	0.062	0.894

表 5.2 GBDT 回归模型筛选因素

交易所	预测因子	特征重要性(%)
北京	欧盟排放配额(EUA)	34.30
	欧洲三港 DESARA 动力煤指数	22.90
	极端低温	9.10
	极端高温	6.20
	富时 100 指数	5.50
	低碳（搜索指数）	4.80
	节能减排（搜索指数）	4.80
	工业增加值累计增长	4.20
	美元/人民币	1.80
	上证综合指数	1.30
	碳足迹（搜索指数）	1.30
	低碳经济（搜索指数）	1.10
湖北	标准普尔 500 指数	34.30
	欧盟排放配额(EUA)	31.80
	IPE 鹿特丹煤炭	12.50
	欧元/人民币	3.70
	国库券	3.40
	欧洲斯托克 50 指数	3.40
	上证综合指数	3.10
	节能减排（搜索指数）	2.20
	CSI300	1.70
	工业增加值累计增长	1.00
深圳	标准普尔 500 指数	53.60
	制造业采购经理指数	8.80
	国库券	6.10
	CSI300	5.30
	上证综合指数	4.30

续表 5.2

交易所	预测因子	特征重要性(%)
	投资者情绪指数	3.80
	碳中和（搜索指数）	3.40
	欧盟排放配额(EUA)	2.90
深圳	布伦特原油期货指数收盘价	2.80
	欧元/人民币	2.70
	工业增加值累计增长指数	1.60
	碳足迹（搜索指数）	1.50

5.2.2 MEMD\MVMD 分解重构

通过 GBDT 筛选得到的因素的描述性统计、ADF 检验、非线性检验结果可知，这些影响因素序列存在非线性不平稳的情况。非线性平稳的时间序列会对预测带来不小的负担，所以在进行时间序列预测之前，对非线性平稳序列进行分解的步骤是必不可少的。将影响因素序列同历史碳价格序列一同输入 MEMD 和 MVMD 模型中进行同步分解，由于 MVMD 分解方法需要提前确定分解 K 值，故本文先利用 MEMD 方法对数据集进行分解，将 MEMD 自适应确定的分解子序列个数 K 值赋值给 MVMD 模型进行分解，经过 MEMD 分解可知北京、湖北、深圳三个交易所及其影响因素分解子序列个数都为 K=7。

计算分解得到的每个子序列的 MDE 值，通过 K 均值聚类将每个因素的子序列重构为高频、低频、趋势项三类。如附表 2、附表 3 所示。

5.3 PCA-Pearson-Granger Causality 过滤

由于本文将碳价格与影响因素共同分解后重构为高频、低频、趋势项三个序列，而经过分解后的因素序列可能包含重要程度不同的因素，一些经过分解后包含较少信息而含较高噪声扰动项的序列在输入预测模型时，反而会降低碳价格预测模型的预测精度。所以在正式输入预测模型进行预测前，本文设置了一个过滤环节，该环节包括相关系数、主成分分析和格兰杰因果检验三部分，任一因素序列只要通过三者其二，则被选择进入正式的预测模型。

5.3.1 Pearson 检验

首先针对北京、湖北、深圳碳价格及其影响因素做相关性考察（包括碳价格的滞后一期与影响因素序列之间的相关性），相关性显著（ $P>0.05$ ）且相关系数大于 0.5 则被选择，通过相关性检验的因素序列可见表 5.3；

5.3.2 PCA 检验

其次对碳价格和影响因素序列做主成分分析，根据特征根大于 1 的原则决定主成分个数，计算每个影响因素在各个主成分的因子载荷系数并计算公因子方差，选择公因子方差大于平均值的因素序列，通过主成分检验的因素序列可见表 5.4。

5.3.3 Granger Causality 检验

最后进行格兰杰因果检验，由于格兰杰因果检验结果容易受滞后期选择的影响，所以数据集在进行格兰杰因果检验前先进行向量自回归确定滞后期，若重构后的序列不能够通过 ADF 检验则先进行协整检验，不通过协整检验的序列则进行差分处理平稳后再做向量自回归确定滞后期，通过格兰杰因果检验的序列则被选择，检验结果见表 5.5。

表 5.3 Pearson 检验结果

分解方法	交易所	高频	低频	趋势项
MEMD	北京	欧洲三港 DESARA 动力煤指数	工业增加值累计增长、极端低温	欧盟排放配额(EUA)、美元/人民币、节能减排（搜索指数） 低碳经济（搜索指数）
	湖北	无	无	欧盟排放配额(EUA)、标准普尔 500 指数、欧洲斯托克 50 指数、碳中和（搜索指数）、碳排放（搜索指数）、低碳（搜索指数）
	深圳	无	无	欧盟排放配额(EUA)、标准普尔 500 指数、投资者情绪指数
MVMD	北京	无	极端高温、低碳（搜索指数）	欧盟排放配额(EUA)、极端高温、美元/人民币、碳足迹（搜索指数）、节能减排（搜索指数）、低碳经济（搜索指数）
	湖北	无	欧盟排放配额 (EUA)、国库券、IPE 鹿特丹煤炭、富时 100 指数、标准普尔 500 指数	欧盟排放配额(EUA)、SHIBOR、欧元/人民币、标准普尔 500 指数、欧洲斯托克 50 指数、投资者情绪指数、碳中和（搜索指数）、碳排放（搜索指数）、碳交易（搜索指数）、低碳（搜索指数）
	深圳	无	工业增加值累计增长	制造业采购经理指数、上证综合指数、欧盟排放配额(EUA)、CSI300、标准普尔 500 指数、投资者情绪指数、碳足迹（搜索指数）

表 5.4 PCA 检验结果

分解方法	交易所	高频	低频	趋势项
	北京	工业增加值累计增长、极端高温、极端低温、美元/人民币、欧洲三港 DESARA 动力煤指数、低碳（搜索指数）、碳足迹（搜索指数）	工业增加值累计增长、欧盟排放配额(EUA)、极端低温、欧洲三港 DESARA 动力煤指数、低碳经济（搜索指数）	上证综合指数、欧盟排放配额(EUA)、极端低温、美元/人民币、欧洲三港 DESARA 动力煤指数、低碳（搜索指数）、碳足迹（指数）、节能减排（指数）、低碳经济（指数）
MEMD	湖北	SHIBOR、欧元/人民币、布伦特原油期货指数收盘价、IPE 鹿特丹煤炭、富时 100 指数、标准普尔 500 指数、欧洲斯托克 50 指数、碳排放（搜索指数）	欧盟排放配额(EUA)、SHIBOR、欧元/人民币、富时 100 指数、标准普尔 500 指数、欧洲斯托克 50 指数、碳中和（搜索指数）、碳排放（搜索指数）	SHIBOR、布伦特原油期货指数收盘价、IPE 鹿特丹煤炭、标准普尔 500 指数、欧洲斯托克 50 指数、碳中和、碳排放（搜索指数）、低碳（搜索指数）
	深圳	工业增加值累计增长、制造业采购经理指数、CSI300、国库券、布伦特原油期货指数收盘价、标准普尔 500 指数、碳中和（搜索指数）、碳足迹（搜索指数）	上证综合指数、欧盟排放配额(EUA)、CSI300、国库券、布伦特原油期货指数收盘价、标准普尔 500 指数	制造业采购经理指数、欧盟排放配额(EUA)、CSI300、欧元/人民币、布伦特原油期货指数收盘价、标准普尔 500 指数、投资者情绪指数、碳中和（搜索指数）、碳足迹（搜索指数）

续表 5.4

分解方法	交易所	高频	低频	趋势项
	北京	工业增加值累计增长、欧盟排放配额(EUA)、美元/人民币、富时 100 指数、低碳(搜索指数)、碳足迹(搜索指数)、低碳经济(搜索指数)	极端高温、极端低温、美元/人民币、欧洲三港 DESARA 动力煤指数、低碳(搜索指数)、碳足迹(指数)、节能减排(指数)、低碳经济(指数)	工业增加值累计增长、欧盟排放配额(EUA)、极端高温、美元/人民币、欧洲三港 DESARA 动力煤指数、富时 100 指数、碳足迹(指数)、节能减排(指数)、低碳经济(指数)
MVMD	湖北	国库券、IPE 鹿特丹煤炭、富时 100 指数、标准普尔 500 指数、碳中和(搜索指数)、碳排放(搜索指数)、碳交易(搜索指数)	欧盟排放配额(EUA)、欧元/人民币、布伦特原油期货指数收盘价、IPE 鹿特丹煤炭、富时 100 指数、标准普尔 500 指数、欧洲斯托克 50 指数、碳中和(搜索指数)	欧盟排放配额(EUA)、SHIBOR、国库券、布伦特原油期货指数收盘价、富时 100 指数、标准普尔 500 指数、碳中和(搜索指数)、碳排放(搜索指数)
	深圳	无	工业增加值累计增长、上证综合指数、欧盟排放配额(EUA)、CSI300、欧元/人民币、布伦特原油期货指数收盘价、标准普尔 500 指数	工业增加值累计增长、上证综合指数、欧盟排放配额(EUA)、CSI300、布伦特原油期货指数收盘价、标准普尔 500 指数、投资者情绪指数、碳中和(指数)、碳足迹(指数)

表 5.5 Granger Causality 检验结果

分解方法	交易所	高频	低频	趋势项
	北京	工业增加值累计增长、期货结算价(连续):欧盟排放配额(EUA)、极端高温、欧洲三港 DESARA 动力煤指数、富时 100 指数、低碳 (搜索指数)、碳足迹 (搜索指数)	工业增加值累计增长、上证综合指数、欧盟排放配额(EUA)、极端低温、美元/人民币、欧洲三港 DESARA 动力煤指数、低碳 (搜索指数)、节能减排 (搜索指数)、低碳经济 (搜索指数)	工业增加值累计增长、美元/人民币、富时 100 指数、碳足迹 (搜索指数)、节能减排 (搜索指数)、低碳经济 (搜索指数)
MEMD	湖北	欧元/人民币、国库券、布伦特原油期货指数收盘价、IPE 鹿特丹煤炭、碳排放 (搜索指数)	碳排放 (搜索指数)、碳交易 (搜索指数)	欧洲斯托克 50 指数、投资者情绪指数
	深圳	工业增加值累计增长、碳中和 (搜索指数)	制造业采购经理指数、欧盟排放配额(EUA)、国库券、布伦特原油期货指数收盘价、投资者情绪指数	制造业采购经理指数、上证综合指数、CSI300、欧元/人民币、布伦特原油期货指数收盘价
MVMD	北京	工业增加值累计增长、欧盟排放配额(EUA)、极端高温、欧洲三港 DESARA 动力煤指数、富时 100 指数、碳足迹 (搜索指数)、低碳经济 (搜索指数)	工业增加值累计增长、欧盟排放配额(EUA)、极端低温、欧洲三港 DESARA 动力煤指数、富时 100 指数、低碳 (指数)、碳足迹 (指数)、节能减排 (搜索指数)	上证综合指数、欧盟排放配额 (EUA)、美元/人民币

续表 5.5

分解方法	交易所	高频	低频	趋势项
MVMD	湖北	上证综合指数、欧盟排放配额(EUA)、国库券、布伦特原油期货指数收盘价、IPE 鹿特丹煤炭、标准普尔 500 指数、欧洲斯托克 50 指数、碳中和 (搜索指数)、碳排放 (搜索指数)、碳交易 (搜索指数)	欧盟排放配额(EUA)、SHIBOR、国库券、布伦特原油期货指数收盘价、IPE 鹿特丹煤炭、标准普尔 500 指数、投资者情绪指数、碳中和 (搜索指数)	SHIBOR、欧元/人民币、IPE 鹿特丹煤炭
	深圳	上证综合指数、欧盟排放配额(EUA)、CSI300、国库券、布伦特原油期货指数收盘价、投资者情绪指数	CSI300、欧元/人民币、标准普尔 500 指数、碳中和 (搜索指数)	制造业采购经理指数、欧盟排放配额 (EUA)、欧元/人民币、布伦特原油期货指数收盘价、碳中和 (搜索指数)

5.3.4 过滤结果

在经过二次过滤 Pearson-PCA-Granger Causality 环节的筛选下，得到 MEMD 和 MVMD 分解方法下各碳交易所在不同频率下的相关因子序列。根据二次过滤环节的特性，将因子序列中通过 Pearson、PCA 和 Granger Causality 三个检验中任意两个检验的序列，确认为最终通过二次过滤环节的因子序列，各碳交易所最终筛选因子序列如表 5.6 和表 5.7 所示。

表 5.6 MEMD 分解下二次筛选最终因子

分解方法	交易所	高频	低频	趋势项
MEMD	北京	工业增加值累计增长指数、北京极端高温、欧洲三港 DESARA 动力煤指数、低碳（搜索指数）、碳足迹（搜索指数）	工业增加值累计增长指数、欧盟排放配额 (EUA)、北京极端低温、欧洲三港 DESARA 动力煤指数、低碳经济（搜索指数）	欧盟排放配额(EUA)、美元/人民币汇率、碳足迹（搜索指数）、节能减排（搜索指数）、低碳经济（搜索指数）
	湖北	欧元/人民币、布伦特原油期货指数收盘价、IPE 鹿特丹煤炭收盘价、碳排放（搜索指数）	碳排放（搜索指数）	标准普尔 500 指数、欧洲斯托克 50 指数、碳中和（搜索指数）、碳排放（搜索指数）、低碳（搜索指数）
	深圳	工业增加值累计增长指数、碳中和（搜索指数）	欧盟排放配额(EUA)、国库券、布伦特原油期货指数收盘价	制造业采购经理指数、欧盟排放配额(EUA)、CSI300、欧元/人民币、布伦特原油期货指数收盘价、标准普尔 500 指数、投资者情绪指数

表 5.7 MVMD 分解下二次筛选最终因子

分解方法	交易所	高频	低频	趋势项
	北京	工业增加值累计增长、欧盟排放配额(EUA)、富时 100 指数、碳足迹(搜索指数)、低碳经济(搜索指数)	北京极端高温、北京极端低温、欧洲三港 DESARA 动力煤指数、低碳(搜索指数)、碳足迹(搜索指数)、节能减排(搜索指数)	欧盟排放配额(EUA)、北京极端高温、美元/人民币汇率、碳足迹(搜索指数)、节能减排(搜索指数)、低碳经济(搜索指数)
MVMD	湖北	国库券、IPE 鹿特丹煤炭收盘价、标准普尔 500 指数、碳中和(搜索指数)、碳排放(搜索指数)、碳交易(搜索指数)	欧盟排放配额(EUA)、国库券、布伦特原油期货指数收盘价、IPE 鹿特丹煤炭收盘价、富时 100 指数、标准普尔 500 指数、碳中和(搜索指数)	欧盟排放配额(EUA)、SHIBOR、欧元/人民币、标准普尔 500 指数、碳中和(搜索指数)、碳排放(搜索指数)
	深圳	欧盟排放配额(EUA)、CSI300	工业增加值累计增长指数、CSI300、欧元/人民币、标准普尔 500 指数	制造业采购经理指数、上证综合指数、欧盟排放配额(EUA)、CSI300、布伦特原油期货指数收盘价、标准普尔 500 指数、投资者情绪指数、碳中和(搜索指数)、碳足迹(搜索指数)

从上述筛选出的因子中可知与北京碳价格影响程度较高的市场影响因素有欧盟排放配额(EUA)、工业增加值累计增长指数、欧洲三港 DESARA 动力煤指数、气温因素有北京极端高温, 百度搜索指数有碳足迹(搜索指数)、低碳经济(搜索指数)、节能减排(搜索指数); 湖北碳价格影响程度较高的市场影响因素有 IPE 鹿特丹煤炭收盘价、标准普尔 500 指数, 百度搜索指数有碳排放(搜索指数)、碳中和(搜索指数); 深圳碳价格影响程度较高的市场影响因素有欧盟排放配额(EUA)、布伦特原油期货指数收盘价、CSI300, 百度搜索指数有碳中和(搜索指数)。

5.4 CNN-BiLSTM 预测

将经过过滤环节筛选得到的因素序列同历史碳价格的滞后序列共同作为预测模型的输入 CNN-BiLSTM 模型进行预测。训练轮数为 1000, 学习率 0.001, 优化器为 Adam 算法, 单 CNN 结构, 输出通道 32, 卷积核为 (1, 3), 遗忘率为 0.2, 激活函数为 Rule, BiLSTM 隐藏层 2 层, 单元个数 64。同时做 MEMD 和 MVMD 分解序列预测结果不同集成方法的对比。

三个碳交易所的碳价格预测结果如图 5.2 所示, 预测模型精度如表 5.8 所示。

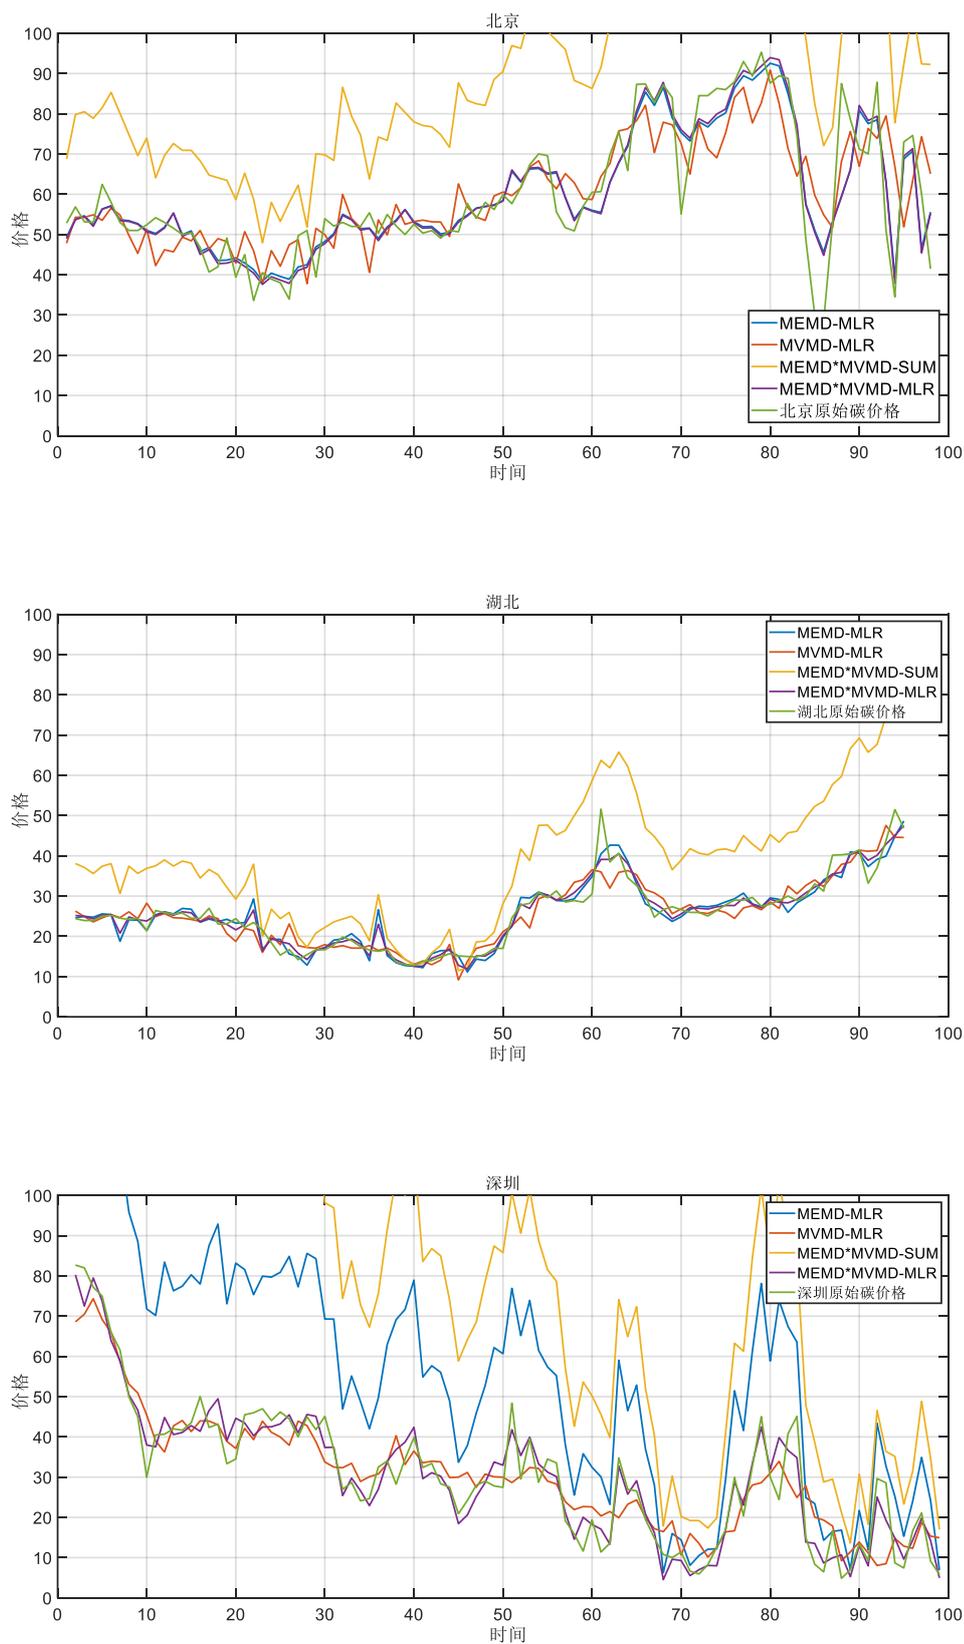


图 5.2 CNN-BiLSTM 碳价格预测结果

表 5.8 CNN-BiLSTM 预测模型精度评估

交易所	预测模型	MAE	RMSE	SMAPE
北京	MEMD-MLR	0.070996913	0.100661279	0.200028708
	MVMD-MLR	0.11243949	0.1540821	0.286361486
	MEMD\MVMD-SUM	0.474167164	0.51547715	0.711186603
	MEMD\MVMD-MLR	0.069448585	0.100153034	0.196981016
湖北	MEMD-MLR	0.049135518	0.07112998	0.289757299
	MVMD-MLR	0.061072363	0.086282581	0.296249698
	MEMD\MVMD-SUM	0.337311696	0.394050088	0.75291761
	MEMD\MVMD-MLR	0.041964634	0.063954072	0.245220938
深圳	MEMD-MLR	0.332587157	0.391481953	0.70697465
	MVMD-MLR	0.073839473	0.097376065	0.364473078
	MEMD\MVMD-SUM	0.662018205	0.76449988	1.053127876
	MEMD\MVMD-MLR	0.042556991	0.056046224	0.259281853

由表 5.8 可知，与单一分解方法的 MEMD-MLR 模型和 MVMD-MLR 模型相比，本文提出的 MEMD\MVMD-MLR 模型效果更优。本文提出的模型预测下，北京碳价格预测模型的 MAE 值为 0.0694，RMSE 值为 0.100153034，SMAPE 值为 0.196981016，相较于 MEMD-MLR 预测模型预测效果提升了一些，相较于 MVMD-MLR 预测模型预测效果提升较多，MAE 值降低了 0.05，RMSE 值降低了 0.05，SMAPE 值降低了 0.09。这验证了本文提出的基于同步多分解方法的碳价格预测模型预测性能更优。同理湖北、深圳碳价格预测，本文提出的最优模型其各个误差指标都为最优。

比较 MEMD\MVMD-BP 模型和 MEMD\MVMD-MLR 模型可知，在数据集经过较为复杂的深度学习神经网络的预测后，继续采取神经网络模型进行预测可能会导致弄巧成拙，反而降低了模型的预测效果，此时使用简单的线性回归模型即可完成预测结果集成的任务。

5.5 模型对比

通过对本文提出的三个碳价格预测模型效果进行对比,可以对三个预测模型的预测效果优劣进行对比,选取最优的预测模型为本文最终的预测模型。以 A1 表示单一历史碳价格数据源, A2 表示市场影响因素, A3 表示碳价格相关的百度搜索指数,以 M1 代表 EMD\OVMD\SSA-Adaboost-ELMAN-BP 模型, M2 代表 MEMD-Lasso-最优预测模型组合-BP 模型, M3 代表 GBDT-MEMD\MVMD-(PCA-Pearson-Granger Causality)-CNN-BiLSTM-MLR 模型,不同交易所碳价格预测精度比较如表 5.9 所示。

表 5.9 模型预测精度对比

交易所	数据源	预测模型	MAE	RMSE	SMAPE
北京	A1	M1	0.25870	0.28230	0.64170
	A1+A2	M2	0.32581	0.50971	0.34217
	A1+A2+A3	M3	0.06945	0.10015	0.19698
湖北	A1	M1	0.21060	0.31580	0.51070
	A1+A2	M2	0.23747	0.46887	0.30715
	A1+A2+A3	M3	0.04196	0.06395	0.24522
深圳	A1	M1	0.22070	0.26510	0.68080
	A1+A2	M2	0.28810	0.38599	0.23014
	A1+A2+A3	M3	0.04256	0.05605	0.25929

(1) 由模型 M1 和表 M3 对比可知,两个模型同是基于同步多分解方法的碳价格预测模型,不同之处在于数据源选取的不同。对比两个模型的预测效果可知,相较于基于单一历史碳价格的预测模型,无论是北京、湖北,还是深圳的碳价格预测,结合百度搜索指数和市场性因素作为数据源的预测模型预测效果更佳,后者的 MAE 值下降 0.2, RMSE 值下降 0.18, SMAPE 值下降 0.4,本文提出的基于百度搜索指数和市场性影响因素相结合的同步多分解方法预测模型大大提高了碳价格预测模型的预测精度。

(2) 由 M2 和 M3 对比可知,两个模型都是多源数据的碳价格预测模型,

不同之处在于后者做了同步多分解和二次筛选的模型设计。对比两个模型的预测效果可知，同样针对北京、湖北、深圳三个碳交易所碳价格预测，前者的预测效果远远不如后者的预测效果。例如针对北京碳价格预测，单分解方法的预测模型 MAE 值为 0.3258，RMSE 值为 0.5097，SMAPE 值为 0.34217，高出后者的误差指标三倍的距离。这说明引入多源数据的模型，需要对因素进行二次筛选以提高影响因素序列的筛选门槛，得到更能够在预测模型种起到积极作用的因素序列，并且加入同步多分解模型，使碳价格及其因素序列能够分解的更加充分，给后续重构序列提供更准确的度量信息。

(3) 由 M1、M2、M3 对比可知，无论是在北京碳交易所，还是湖北、深圳交易所，M3 预测模型的预测精度都是高于 M1、M2 模型的预测精度。M3 模型是在 M1、M2 模型的基础上进行改进的，汲取了 M1 模型多分解方法组合的优点、M2 模型多数据源输入的优点，对于 M1 模型的机器学习预测模型和 M2 模型的因素筛选模型、机器学习预测模型进行了进一步的升级，形成了同时具有多数据源信息输入、多分解方法组合、多元分解方法的数据预处理方法，并引进包含 PCA、Pearson、Granger Causality 检验环节的过滤环节对分解得到的因素序列中包含信息较少、对碳价格序列预测影响程度较低的序列进行筛选，通过 CNN-BiLSTM 模型对序列集合进行预测，相较于简单的机器学习模型，CNN-BiLSTM 模型能够更好的对序列内部的信息进行提取，大大地提高了模型的预测精度。而且通过北京、湖北、深圳三个交易所碳价格预测的验证，可以说明 M3 模型在碳价格预测领域的稳定性和优越性。

5.6 本章小结

本章旨在验证结合同步多分解方法和多数据信息的碳价格预测模型的可行性。首先第一步数据预处理阶段,先通过百度搜索指数需求图谱相关程度确定了与碳价格相关的百度搜索指数共七个,爬取其日度搜索量并计算每月搜索总量然后转化为百度搜索指数月度数据,其次通过大量查阅碳价格影响因素的研究文献,选取来自国际碳价格、国内外金融市场、国内外能源市场、经济指标和气候环境五大场景共 21 个影响因素,将所有影响因素同碳价格做 GBDT-CART 重要性排序,剔除因素数据集中重要性小于 1%的因素,保留其中重要性大于 1%的影响因素;第二步同步多分解,本章节采用了 MEMD 和 MVMD 两种多元分解方法对碳价格序列和影响因素做同步分解,得到相同分解阶数的子序列集,本章分解工作得到北京、湖北、深圳碳价格及其影响因素的分解阶数都为 7;第三步熵值重构。计算各个子序列的多尺度散布熵值(MDE)并做高频、低频、趋势项重构,此处因素暂不做筛选,所有序列均作重构处理;第四步为二次过滤检验。本环节引入 Pearson-PAC-Granger Causality 三部分过程的过滤模型,针对每一城市的同意频率的不同因素序列做筛选过滤,任一序列只要通过三者其二的检验,即被选择进入正式的预测模型;第五步模型预测与评估,本章节采用 CNN-BiLSTM 模型作为主模型对筛选得到的数据集进行预测,并作单一分解方法和不同集成方法的对比模型,以验证本章提出的组合预测模型的优越性。

6 总结

6.1 结论

本文以北京、湖北、深圳的碳价格预测为例，针对中国碳价格预测模型展开研究，根据各个模型碳价格预测精度对比，可以得出以下结论：

(1) 对于碳价格预测，对碳价格序列采用多分解方法的预测模型精度要优于单一分解方法下的预测模型精度。本文在第三章提出一种基于单一历史碳价格的同步多分解碳价格预测模型。该模型只使用了历史碳价格数据作为数据源，创新之处在于数据分解部分同步使用了 EMD、OVMD、SSA 三种原理不同的分解方法，保证序列分解的充分性和全面性。通过观察单一分解方法的预测模型和同步多分解预测模型进行对比可知，同步多分解方法能够有效提高碳价格预测模型的预测精度。

(2) 在碳价格预测中加入与碳价格序列相关程度较高的外生因素序列，能够提高碳价格序列的预测精度。本文在第四章提出一种基于融合多因素的多元经验模态分解的碳价格预测模型。该模型在数据源方面加入了多市场因素辅助碳价格进行预测。首先在影响因素筛选方面，本文通过对现有碳价格影响因素研究文献的大量查阅，选取了来自国际碳价格、国际金融市场、能源市场和气候环境四个场景的影响因素，然后这些影响因素与历史碳价格共同进行 MEMD 分解，本文利用 Lasso 回归模型为碳价格的高频、低频序列筛选相关因素序列、剔除无关因素序列。通过对比第三章中单一历史碳价格数据源的单一分解方法下的碳价格预测精度可知，第四章中加入外生市场因素的碳价格预测精度有所提升，所以加入相关程度较高的影响因素序列能够辅助碳价格预测。

(3) 网络搜索信息在预测领域具有使用价值，在碳价格预测中融入百度搜索信息相较于未加入的模型预测精度有所提升。本文在第五章提出一种基于融合百度搜索指数信息的多分解方法框架下的碳价格预测，该模型在数据源方面加入了目前备受关注的网络搜索指数。通过百度搜索指数需求图谱对碳价格相关关键词进行筛选，与其他市场因素一同通过 GBDT-CART 模型进行选择。该模型的分解方法采用了同步多分解和多元分解方法相结合的组合 (MEMD\MVMD) 对碳价格和一次筛选得到的影响因素做共同分解。该模型在因素重构后引入过滤筛选

模型，包括 Pearson、PCA、Granger Causality 三个环节，任一因素序列需要通过三个环节中任意两个则被认为该序列同碳价格的重构序列存在相关影响关系，有助于碳价格重构序列的预测，将其选入 CNN-BiLSTM 模型进行最终预测，通过该模型的预测效果可知，融入百度搜索指数数据的同步多分解模型的预测效果在本文提出的三个预测模型中效果最佳。

6.2 展望

针对本文现有研究存在的一些不足，提出以下几点改进建议：

(1) 本文虽然做中国碳价格预测研究，但目前研究工作只做了北京、湖北、深圳三个碳交易所碳价格序列的验证，在后续的中国碳价格预测研究中，可以改用中国其他碳交易所碳价格数据验证本文提出的碳价格预测模型的稳健性；

(2) 本文提出的最优碳价格预测模型网络搜索指数领域，只涉及了百度搜索指数一种搜索指数，在后续的中国碳价格预测研究中，可以进一步挖掘其他网络信息，例如谷歌搜索指数、碳价格相关的新闻文本信息等，这些因素具有更多的网络关注信息，能够进一步帮助碳价格的准确预测；

(3) 本文提出的针对多尺度数据的分解方法 MEMD 和 MVMD，在分解上仍然存在一定的缺陷，后续可以选择在这两个基础模型上改进的优化分解算法，进一步提高碳价格和因素序列分解效果；

(4) 本文采用的碳价格影响因素虽然涉及了国际碳价格、国际金融市场、国际能源市场、经济指标和气候环节五大场景的因素，但许多对碳价格波动具有影响的因素并未考虑进预测模型，例如新冠时期导致的全球经济下行、国外爆发战争等社会性因素等，可以在后续的研究中讨论一种度量指标加入预测模型。

参考文献

- [1] Dragomiretskiy K, Zosso D. Variational mode decomposition[J]. IEEE transactions on signal processing, 2013, 62(3): 531-544.
- [2] Freund Y, Schapire R E. Experiments with a new boosting algorithm[C]//icml. 1996, 96: 148-156.
- [3] Graves A, Graves A. Long short-term memory[J]. Supervised sequence labelling with recurrent neural networks, 2012: 37-45.
- [4] Holland J H. Genetic algorithms[J]. Scientific american, 1992, 267(1): 66-73.
- [5] Huang G B, Zhou H, Ding X, et al. Extreme learning machine for regression and multiclass classification[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2011, 42(2): 513-529.
- [6] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1-3): 489-501.
- [7] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences, 1998, 454(1971): 903-995.
- [8] Huang Y, Dai X, Wang Q, et al. A hybrid model for carbon price forecasting using GARCH and long short-term memory network[J]. Applied Energy, 2021, 285: 116485.
- [9] Huang Y, He Z. Carbon price forecasting with optimization prediction method based on unstructured combination[J]. Science of the Total Environment, 2020, 725: 138350.
- [10] Jia W, Zhao D, Zheng Y, et al. A novel optimized GA–Elman neural network algorithm[J]. Neural Computing and Applications, 2019, 31(2): 449-459.
- [11] Jianwei E, Ye J, He L, et al. A denoising carbon price forecasting method based on the integration of kernel independent component analysis and least squares support vector regression[J]. Neurocomputing, 2021, 434: 67-79.
- [12] Li G, Ning Z, Yang H, et al. A new carbon price prediction model[J]. Energy, 2022,

- 239: 122324.
- [13] Li G, Zheng C, Yang H. Carbon price combination prediction model based on improved variational mode decomposition[J]. *Energy Reports*, 2022, 8: 1644-1664.
- [14] Liu J, Wang P, Chen H, et al. A combination forecasting model based on hybrid interval multi-scale decomposition: Application to interval-valued carbon price forecasting[J]. *Expert Systems with Applications*, 2022, 191: 116267.
- [15] Min Y, Shuzhen Z, Wuwei L. Carbon price prediction based on multi-factor MEEMD-LSTM model[J]. *Heliyon*, 2022, 8(12).
- [16] Nadirgil O. Carbon price prediction using multiple hybrid machine learning models optimized by genetic algorithm[J]. *Journal of Environmental Management*, 2023, 342: 118061.
- [17] Niu X, Wang J, Zhang L. Carbon price forecasting system based on error correction and divide-conquer strategies[J]. *Applied Soft Computing*, 2022, 118: 107935.
- [18] Pan D, Zhang C, Zhu D, et al. Carbon price forecasting based on news text mining considering investor attention[J]. *Environmental Science and Pollution Research*, 2023, 30(11): 28704-28717.
- [19] Pham D T, Liu X. Training of Elman networks and dynamic system modelling[J]. *International Journal of Systems Science*, 1996, 27(2): 221-226.
- [20] Rukhin A L. Analysis Time Series Structure SSA and Related Techniques[J]. *Technometrics*, 2002, 44(3): 290.
- [21] Sun S, Jin F, Li H, et al. A new hybrid optimization ensemble learning approach for carbon price forecasting[J]. *Applied Mathematical Modelling*, 2021, 97: 182-205.
- [22] Sun W, Xu C. Carbon price prediction based on modified wavelet least square support vector machine[J]. *Science of the Total Environment*, 2021, 754: 142052.
- [23] Tibshirani R. Regression shrinkage and selection via the lasso[J]. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 1996, 58(1): 267-288.
- [24] Ur Rehman N, Aftab H. Multivariate variational mode decomposition[J]. *IEEE Transactions on signal processing*, 2019, 67(23): 6039-6052.
- [25] Ur Rehman N, Park C, Huang N E, et al. EMD via MEMD: multivariate noise-

- aided computation of standard EMD[J]. *Advances in adaptive data analysis*, 2013, 5(02): 1350007.
- [26] Yun P, Zhang C, Wu Y, et al. Forecasting carbon dioxide price using a time-varying high-order moment hybrid model of NAGARCHSK and gated recurrent unit network[J]. *International Journal of Environmental Research and Public Health*, 2022, 19(2): 899.
- [27] Zhang C, Lin B. Carbon prices forecasting based on the singular spectrum analysis, feature selection, and deep learning: Toward a unified view[J]. *Process Safety and Environmental Protection*, 2023, 177: 932-946.
- [28] Zhang F, Wen N. Carbon price forecasting: a novel deep learning approach[J]. *Environmental Science and Pollution Research*, 2022, 29(36): 54782-54795.
- [29] Zhang F, Xia Y. Carbon price prediction models based on online news information analytics[J]. *Finance Research Letters*, 2022, 46: 102809.
- [30] Zhou F, Huang Z, Zhang C. Carbon price forecasting based on CEEMDAN and LSTM[J]. *Applied Energy*, 2022, 311: 118601.
- [31] 白强,董洁,田园春.中国碳排放权交易价格的波动特征及其影响因素研究[J]. *统计与决策*,2022,38(05):161-165.
- [32] 毕文杰,扶春娟.基于机器学习的 Airbnb 房源价格预测及影响因素研究——以北京市为例[J].*运筹与管理*,2022,31(09):217-224.
- [33] 崔焕影,窦祥胜.基于 EMD-GA-BP 与 EMD-PSO-LSSVM 的中国碳市场价格预测[J].*运筹与管理*,2018,27(07):133-143.
- [34] 方毅,陈煜之,卫剑.人工智能与中国股票市场——基于机器学习预测的投资组合量化研究[J].*工业技术经济*,2022,41(08):83-91.
- [35] 高杨,李健.基于 EMD-PSO-SVM 误差校正模型的国际碳金融市场价格预测[J]. *中国人口·资源与环境*,2014,24(06):163-170.
- [36] 高长征,李东伟,王秀娜等.利用智能机器学习方法对区域碳排放权交易价格预测研究——基于湖北碳市场数据的分析[J].*价格理论与实践*,2022,(04):89-93+205.
- [37] 洪涓,陈静.我国碳交易市场价格影响因素分析[J].*价格理论与实*

- 践,2009(12):65-66.
- [38] 胡登龙.我国碳交易价格影响因素及价格机制研究[J].价格月刊,2016(10):21-26.
- [39] 吉兴全,曾若梅,张玉敏等.基于注意力机制的 CNN-LSTM 短期电价预测[J].电力系统保护与控制,2022,50(17):125-132.
- [40] 解小文,周新苗.中国碳金融市场价格的影响因素及风险测度研究[J].科技与经济,2022,35(01):96-100.
- [41] 李从志,郑近德,潘海洋,等.基于精细复合多尺度散布熵与支持向量机的滚动轴承故障诊断方法[J].中国机械工程,2019,30(14):1713.
- [42] 李欢,董娜,潘敏等.基于 PCA-ARDL-BP 神经网络的房价指数预测研究[J].建筑经济,2022,43(S1):759-763.
- [43] 梁荣,杨波,马润泽等.利用多源信息和深度置信神经网络的配电系统空间负荷预测[J].电力建设,2018,39(10):12-19.
- [44] 刘金培,张了丹,朱家明等.非结构性数据驱动的混合分解集成碳交易价格组合预测[J].运筹与管理,2023,32(03):149-154.
- [45] 陆敏,苍玉权.影响中国碳价的能源价格因素关联研究[J].中国环境管理,2018,10(04):88-92.
- [46] 马明娟;李强;殷文琦;宗鑫;周文瑞.碳中和目标下基于 GA-BP 神经网络的碳交易定价模型及其模拟研究[J].生态经济,2022,38(03):40-46.
- [47] 梅梅,刘颖,唐小利等.微博非结构化数据的情绪挖掘方法及在旅游预测中的应用[J].情报资料工作,2019,40(01):64-72.
- [48] 王满,张苗苗.考虑高维宏观信息的波动率与股票价格预测[J].统计与决策,2022,38(20):138-143.
- [49] 王娜.基于动态多元网络的中国碳价预测[J].统计研究,2023,40(01):49-61.
- [50] 王润周,张新生,王明虎.基于信号分解和深度学习的农产品价格预测[J].农业工程学报,2022,38(24):256-267.
- [51] 王文胜,常晓颖.基于网络搜索数据的地区 RPI 增速预测研究——模拟河北省日度网络搜索指数对地区 RPI 影响分析[J].价格理论与实践,2022(02):104-107+201.

- [52] 王小燕,周思敏,徐晓莉等.基于图结构自适应 Lasso 的碳排放权价格影响因素分析[J].统计与信息论坛,2022,37(04):73-83.
- [53] 魏宇,张佳豪,陈晓丹.基于 DMS 和 DMA 的我国碳排放权交易价格预测方法——来自湖北碳市场的经验证据[J].系统工程,2022,40(04):1-16.
- [54] 伍友龙.多元经验模态分解及在 SAR 图像目标识别中的应用[J].红外与激光工程,2021,50(4):20200236-1-20200236-7.
- [55] 严茂林,葛玮玮,张洋等.中国城镇居民人均食用植物油消费量的趋势预测与影响因素分析[J].中国油脂,2023,48(11):1-7.
- [56] 杨星,梁敬丽,蒋金良等.多标度分形特征下碳排放权价格预测算法[J].控制理论与应用,2018,35(02):224-231.
- [57] 姚奕,吕静,章成果.湖北碳市场价格形成机制及价格预测[J].统计与决策,2017,(19):166-169.
- [58] 张晨,杨仙子.基于多频组合模型的中国区域碳市场价格预测[J].系统工程理论与实践,2016,36(12):3017-3025.
- [59] 张奕韬,万常选,刘喜平等.基于 PSP_HDP 主题模型的非结构化经济指标挖掘[J].软件学报,2020,31(03):845-865.
- [60] 周建国,刘宇萍,韩博.我国碳配额价格形成及其影响因素研究——基于 VAR 模型的实证分析[J].价格理论与实践,2016(05):85-88.
- [61] 王建平.基于同步多分解集成预测方法的中国碳价格预测[J].甘肃金融,2023,(12):35-40+8.

附 录

附表 1 碳价格及影响因素分解重构结果

交易所	影响因素	高频	低频
北京	北京碳价格	1,2,3,4	5,6,7
	国库券	1,2,3,4	5,6,7
	NYMEX 天然气期货收盘价	1,2,3	4,5,6,7
	欧洲三港 DESARA 动力煤指数	1,2,3,4,5,6	7
	布伦特原油期货指数收盘价	1,2,3,4	5,6,7
	IPE 鹿特丹煤炭期货收盘价	1,2,3,4,5,6	7
	商品研究局期货指数 CRB	1,2,3,4	5,6,7
	标准普尔 500 指数	1,2,3	4,5,6,7
	欧洲斯托克 50 指数	1,2,3,4	5,6,7
	EUA	1,2,3,4	5,6,7
	SHIBOR	1,2,3,4	5,6,7
	沪深 300 指数	1,2,3,4,5,6	7
	美元汇率	1,2,3,4	5,6,7
	极端高温	1,2,3,4	5,6,7
	极端低温	1,2, 4	3,5,6,7
投资者情绪指数	1,2,3,4, 5	6,7	
湖北	湖北碳价格	1,2,3,4	5,6,7
	国库券	1,2,3	4,5,6,7
	NYMEX 天然气期货收盘价	1,2,3,4	5,6,7
	欧洲三港 DESARA 动力煤指数	1,2,3,4,5,6	7
	布伦特原油期货指数收盘价	1,2,3,4	5,6,7
	IPE 鹿特丹煤炭期货收盘价	1,2,3,4,5,6	7
	商品研究局期货指数 CRB	1,2,3,4	5,6,7
	标准普尔 500 指数	1,2,3,4	5,6,7
	欧洲斯托克 50 指数	1,2,3	4,5,6,7

续表 1

交易所	影响因素	高频	低频
湖北	EUA	1,2,3,4	5,6,7
	SHIBOR	1,2,3,4	5,6,7
	沪深 300 指数	1,2,3,4	5,6,7
	美元汇率	1,2,3,4	5,6,7
	极端高温	1,2,3,4,5	6,7
	极端低温	1,2, 4	3,5,6,7
	投资者情绪指数	1,2,3,4	5,6,7
深圳	深圳碳价格	1,2,3	4,5,6,7
	国库券	1,2,3	4,5,6,7
	NYMEX 天然气期货收盘价	1,2,3	4,5,6,7
	欧洲三港 DESARA 动力煤指数	1,2,3,4,5,6	7
	布伦特原油期货指数收盘价	1,2,3,4	5,6,7
	IPE 鹿特丹煤炭期货收盘价	1,2,3,4,5,6	7
	商品研究局期货指数 CRB	1,2,3	4,5,6,7
	标准普尔 500 指数	1,2,3,4	5,6,7
	欧洲斯托克 50 指数	1,2,3,4	5,6,7
	EUA	1,2,3	4,5,6,7
	SHIBOR	1,2,3,4	5,6,7
	沪深 300 指数	1,2,3	4,5,6,7
	美元汇率	1,2,3,4	5,6,7
	极端高温	1,2,3,4,5,6	7
	极端低温	1,2	3,4,5,6,7
投资者情绪指数	1,2,3,4	5,6,7	

附表 2 MEMD 分解下碳价格及其影响因素分解序列重构结果

MEMD	影响因素	高频	低频	趋势项
北京	北京碳价格	1,2	3	4,5,6,7
	工业增加值累计增长	1	2,3	4,5,6,7
	上证综合指数	1,2	3,4	5,6,7
	欧盟排放配额(EUA)	1,2,3	4,5	6,7
	极端高温	1	2	3,4,5,6,7
	极端低温	1,2	3,4	5,6,7
	美元/人民币	1	2,3	4,5,6,7
	欧洲三港 DESARA 动力煤指数	1,2	3,4	5,6,7
	富时 100 指数	1,2	3	4,5,6,7
	低碳（搜索指数）	1	2,3,4	5,6,7
	碳足迹（搜索指数）	1	2,3	4,5,6,7
	节能减排（搜索指数）	1,2	3,4,5	6,7
	低碳经济（搜索指数）	1,2,3	4,5	6,7
	湖北	湖北碳价	1,2	3,4
上证综合指数		1,2,3	4,5	6,7
欧盟排放配额(EUA)		1,2,3	4	5,6,7
SHIBOR		1,2	3,4,5	6,7
欧元/人民币		1,2,3	4	5,6,7
国库券		1,2	3	4,5,6,7
布伦特原油期货指数收盘价		1,2	3,4,5	6,7
期货收盘价(连续):IPE 鹿特丹煤炭		1,2	3	4,5,6,7
富时 100 指数		1,2	3,4	5,6,7
标准普尔 500 指数		1,2	3,4	5,6,7
欧洲斯托克 50 指数		1,2	3,4,5	6,7
投资者情绪指数		1	2,3,4	5,6,7

续表 2

MEMD	影响因素	高频	低频	趋势项
湖北	碳中和（搜索指数）	2,3	1,4	5,6,7
	碳排放（搜索指数）	1,2,3	4	5,6,7
	碳交易（搜索指数）	1	2,3	4,5,6,7
	低碳（搜索指数）	1,3	2,4,5	6,7
深圳	深圳碳价	1,2,3	4,5	6,7
	工业增加值累计增长	1,2	3	4,5,6,7
	制造业采购经理指数	1,2	3,4	5,6,7
	上证综合指数	1	2,3	4,5,6,7
	欧盟排放配额(EUA)	1,2,3	4,5,6	7,
	CSI300	1,2	3,4,5	6,7
	欧元/人民币	1,2,3	4	5,6,7
	国库券	1,2	3,4	5,6,7
	布伦特原油期货指数收盘价	1,2	3,4	5,6,7
	标准普尔 500 指数	1,2,3	4,5,6	7,
	投资者情绪指数	1,2	3,4	5,6,7
	碳中和（搜索指数）	2,3	1,4,5	6,7
	碳足迹（搜索指数）	1,2	3,4	5,6,7

附表3 MVMD 分解下碳价格及其影响因素分解序列重构结果

交易所	影响因素	高频	低频	趋势项
北京	北京碳价格	3,4,6	2,5,7	1
	工业增加值累计增长	2,4,6,7	3,5	1
	上证综合指数	3,5,6	2,4,7	1
	欧盟排放配额(EUA)	4	2,3,6,7	1,5
	极端高温	4,6,7	2,3,5	1
	极端低温	4,6,7	3,5	1,2
	美元/人民币	3,4,7	2,5,6	1
	欧洲三港 DESARA 动力煤指数	2,4	3,5,6,7	1
	富时 100 指数	2,3,4,6,7	5	1
	低碳（搜索指数）	4	2,5,6	1,3,7
	碳足迹（搜索指数）	2,3,4,6	5,7	1,
	节能减排（搜索指数）	4,7	2,3,5,6	1
	低碳经济（搜索指数）	2,7	3,4,5,6	1
	湖北	湖北碳价格	4,5,6,7	3
上证综合指数		5,6	3,4,7	1,2
欧盟排放配额(EUA)		4,5,6,7	3	1,2
SHIBOR		4,5,6,7	3	1,2
欧元/人民币		4,5,6,7	2,3	1
国库券		4,5,6,7	3	1,2
布伦特原油期货指数收盘价		4,5,6,7	3	1,2
期货收盘价(连续):IPE 鹿特丹煤炭		4,5,6,7	3	1,2
富时 100 指数		5,6,7	3,4	1,2
标准普尔 500 指数		4,5,6	3,7	1,2
欧洲斯托克 50 指数		5,6,7	3,4	1,2
投资者情绪指数		5,6	3,4	1,2
碳中和（搜索指数）		5,6,7	3,4	1,2

续表 3

交易所	影响因素	高频	低频	趋势项
湖北	碳排放（搜索指数）	4,6,7	2,3,5	1
	碳交易（搜索指数）	4,6,7	3,5	1,2
	低碳（搜索指数）	4,6	3,5,7	1,2
深圳	深圳碳价格	4,5	3,6,7	1,2
	工业增加值累计增长	4,6	3,5,7	1,2
	制造业采购经理指数	3,4,6,7	2,5	1
	上证综合指数	5,6	3,4,7	1,2
	欧盟排放配额(EUA)	4	3,5,6,7	1,2
	CSI300	4,5,7	3,6	1,2
	欧元/人民币	4,5,6,7	3	1,2
	国库券	4,6,7	3,5	1,2
	布伦特原油期货指数收盘价	4	3,5,6,7	1,2
	标准普尔 500 指数	5,6	3,4,7	1,2
	投资者情绪指数	6	3,4,5,7	1,2
	碳中和（搜索指数）	7	4,6	1,2,3,5
	碳足迹（搜索指数）	3,6	4,5,7	1,2

攻读硕士学位期间承担的科研任务及主要成果

- [1] 王建平.基于同步多分解集成预测方法的中国碳价格预测[J].甘肃金融,2023,(12):35-40+8.

致 谢

时间的流逝往往在人回望过去的时候发生，就像这篇论文写到致谢部分，我就恍惚间回想起这研究生的3年，才惊觉2021年已经是3年前的事情了。现在去回想3年前的自己，似乎许多事情已经模糊，但是站在3年后的我又确实认真度过了人生中绚烂多彩的这3年。感慨万千，这突如其来、打得人措手不及，但又如期而至的毕业。

感谢我亲爱的孙老师，原本有许多感谢和抱歉的话突然化在心里说不出来。我坚定且自豪地感恩您是位好导师，3年来的无数个细小的瞬间，我都在庆幸成为了您的学生。时至今日我能在我的硕士毕业论文里敲下每一个字，都有您一步一个台阶指引的影子。学生顽劣、笨拙，老师也为不让人省心的孩子一遍一遍磨着嘴皮，小树能漫不经心地茁壮生长，都是园丁在风雨无阻地修剪枝叶、浇水施肥。抱歉没能成为您“别人家的孩子”，但感谢您成为我们“别人家的老师”。

感谢我度过了7年青春时光的亲爱的大学，从成年来每个阶段的成长都有你的见证。这无疑是我产生翻天覆地变化的7年，学校里每个平凡的角落都有我难忘的回忆，校门口排队半小时才能吃上的摊摊、只买了一根香肠结果引来了一群小狗、操场上看排球比赛被当头一球、四五月里满园的花香和蓝天。从那个校区到这个校区校车只要半个小时，3块钱承载着我的七年，只是以后再来，要在校门口填访客登记表了。

感谢在这里遇到的每一个人，感恩我们之间发生的每一个故事。文学作家笔下的角色借由相逢的故事丰满人物形象，我在自己的人生中走向现在的自己。我的人生框架里每走一步都有新的着墨，成为画作是个惊喜，不是画作也没关系。

感恩不遇，感恩相遇。