

基于TCN-FEDformer的碳排放权交易价格预测

王情缘

长沙理工大学数学与统计学院, 湖南 长沙

收稿日期: 2026年8月2日; 录用日期: 2026年8月26日; 发布日期: 2026年9月3日

摘要

碳排放权交易价格的准确预测对于完善碳市场运行机制、引导企业减排决策至关重要。本文提出了一种TCN-FEDformer碳排放权交易价格预测模型。该模型将时序卷积网络(Temporal Convolutional Networks, TCN)与频率增强分解Transformer (Frequency Enhanced Decomposed Transformer, FEDformer)进行并行建模, 并引入多层感知机(Multi-Layer Perceptron, MLP)对两路特征进行融合, 从而实现对碳排放权交易价格的有效预测。基于湖北和广东碳排放权交易市场的实际数据, 对构建的模型进行了系统的实证分析。实验结果表明, TCN-FEDformer模型在预测精度和稳定性方面均优于传统时序预测模型与Transformer架构的相关模型, Diebold-Mariano (DM)检验结果也进一步验证了该模型预测性能的提升在统计意义上显著。

关键词

碳排放权交易价格, 时间序列预测, 混合模型

Carbon Emission Allowance Trading Price Forecasting Based on TCN-FEDformer Model

Qingyuan Wang

School of Mathematics and Statistics, Changsha University of Science and Technology, Changsha Hunan

Received: August 2, 2026; accepted: August 26, 2026; published: September 3, 2026

Abstract

Accurate forecasting of carbon emission allowance trading prices is of critical importance for improving the operational efficiency of carbon markets and guiding corporate emission reduction decisions. This study proposes a TCN-FEDformer carbon emission allowance trading price prediction model. The model performs parallel modeling using Temporal Convolutional Networks (TCN) and the Frequency Enhanced Decomposed Transformer (FEDformer), and introduces a multilayer

perceptron (MLP) to fuse the features from the two branches, thereby enabling effective prediction of carbon emission trading prices. Based on actual data from the Hubei and Guangdong carbon emission allowance trading markets, a systematic empirical analysis is conducted to evaluate the performance of the proposed model. The results demonstrate that the TCN-FEDformer model outperforms traditional time-series forecasting models and Transformer-based models in terms of both predictive accuracy and stability. Furthermore, the Diebold-Mariano (DM) test confirms that the improvement in forecasting performance is statistically significant.

Keywords

Carbon Emission Allowance Trading Price, Time Series Forecasting, Hybrid Model

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

全球能源需求日益增长,不可再生资源供需逐渐失衡,将成为人类社会发展的主要威胁。燃烧化石能源不仅会产生大量二氧化碳,还会造成空气污染,导致全球生态环境迅速恶化[1]。碳排放权交易市场被认为是解决这些问题的重要解决方案,它通过在金融市场交易碳排放权,引导和鼓励大型能源企业使用可再生能源[2]。近年来,中国作为世界上最大的碳排放国,它的排放量已经超过了世界排放量的四分之一。2021年7月16日,中国的全国碳排放权交易市场正式启动[3]。截至2022年底,中国碳市场覆盖重点排污单位2162家,碳排放量46亿吨,成为全球最大碳市场[4]。碳排放权交易价格能够直接或间接影响和促进高排放企业排放结构转变,引导社会投资绿色低碳领域。因此,建立一个有效、准确的碳排放权交易价格预测模型具有重要意义,这将有助于恢复世界生态平衡,促进更健康的生活和稳定气候。

针对碳排放权交易价格序列非线性强、波动频繁以及多尺度特征并存等问题,本文提出了一种新的TCN-FEDformer碳排放权交易价格预测模型,该模型通过构建一种并行特征提取与融合的预测框架来实现准确预测。时序卷积网络(Temporal Convolutional Networks, TCN)利用因果卷积和扩张卷积结构高效提取价格序列中的局部动态和短期依赖关系;频域增强分解Transformer(Frequency Enhanced Decomposed Transformer, FEDformer)基于傅里叶变换的频域增强机制,在降低计算复杂度的同时有效捕捉碳价格序列中的长期周期性和低频结构特征。通过多层感知机(Multi-Layer Perceptron, MLP)将两路互补特征在高维空间中进行融合,实现了对碳排放权交易价格多尺度特征的联合建模,提升了对非平稳价格序列的建模能力和预测精度。

本文的主要贡献可概括为以下三点:首先,提出了一种新的TCN-FEDformer预测模型,将TCN与FEDformer进行并行建模,并引入MLP对两路特征进行融合,为碳排放权交易价格预测提供了一种有效的建模思路;其次,基于湖北和广东碳排放权交易市场的数据,对所构建的模型进行了系统的对比实验分析,结果表明该模型在预测精度和稳定性方面均优于其他对比模型;最后,通过DM检验进一步验证了所提模型预测优势的统计显著性,表明TCN-FEDformer在碳排放权交易价格预测任务中具有更强的稳健性和实际应用价值。

本文的其他部分如下:第二节是相关文献综述,第三节介绍了研究方法,第四节是实证结果和分析,第五节给出结论。

2. 文献综述

近年来,许多数据驱动的预测模型被开发出来,以准确预测碳排放权交易价格。早期研究多采用传统计量经济学方法对碳排放权交易价格进行建模与预测,这些方法虽然在金融时间序列分析中得到了广泛的应用,但计量经济模型对非线性长期时间序列的预测能力往往不稳定,难以有效应对碳排放权交易价格中普遍存在的非线性特征和结构突变问题。随着机器学习模型的发展,一部分学者开始采用支持向量回归(Support Vector Regression, SVR)、随机森林(Random Forest, RF)、随机向量函数链(Random Vector Function Link, RVFL)等模型对碳排放权交易价格进行预测[5][6]。

此外,深度学习方法作为机器学习方法中的新兴方法开始蓬勃发展,为碳排放权交易价格预测提供了新思路。卷积神经网络(Convolutional Neural Networks, CNN)和循环神经网络(Recurrent Neural Network, RNN)都是基础的深度学习模型[7][8]。CNN能够有效捕捉大规模时间序列数据的局部时间相关特征,而RNN通过循环结构保留历史信息,更适合碳价等长期序列预测,但其训练速度较慢,且大多与其他优化算法结合使用[9]。此外,长短期记忆网络(Long Short-term Memory Networks, LSTM)通过引入门控机制有效缓解了长序列训练中的梯度消失问题,在碳排放权交易价格预测中通常表现出更高的预测性能[10]。而后,基于注意力机制的Transformer模型逐渐被引入碳价格预测领域[11][12]。Transformer及其改进模型能够通过自注意力机制或频域分解策略有效建模长期依赖关系,在长序列预测中展现出卓越的性能[13]。

单一人工智能模型在处理非平稳性时间序列数据时仍存在局限性,因此越来越多的研究开始关注混合预测模型,通过融合不同模型的优势,更全面地挖掘动态特征和演化规律[14][15]。目前主要的分解方法有经验模态分解(Empirical Mode Decomposition, EMD)、变分模态分解(Variational Mode Decomposition, VMD)以及多元经验模态分解(Multivariate Empirical Mode Decomposition, MEMD)等[2][16][17]。闫梦[18]等以广东碳排放权交易价格为研究对象,采用EMD将原始序列分解为多个子序列,并分别利用BP神经网络与LSTM模型对低频与高频分量进行建模预测,最后通过集成所有分量的预测结果得到最终结果;袁文燕等[19]则借助MEMD对原始复杂序列进行模态分解,有效缓解了数据混叠问题,显著提升了模型的预测精度。

上述研究为改善碳排放权交易价格的预测性能提供了丰富的理论依据,但仍然存在一些不足。因此,本文构建了TCN-FEDformer碳排放权交易价格预测模型。该模型通过并行提取局部动态特征和长期周期特征,并对两路特征进行融合,从而提升模型对碳排放权交易价格预测精度和稳定性。

3. 方法

3.1. 时序卷积网络

TCN是一种基于卷积神经网络的序列建模方法,它通过因果卷积和扩张卷积来提取历史序列中的有效信息,保证序列的因果性,同时扩大了模型的感受野。由于TCN能够有效提取序列的局部波动特征与短期依赖,因此本文采用TCN对碳排放权交易价格进行特征提取。

因果卷积通过约束卷积核的感受野,使模型的每个时刻的输出只依赖于当前时刻和之前的历史信息,不会引入来自未来时刻的数据,避免了数据泄露。如图1所示,隐藏层层数越多,可捕获的历史信息就越多。然而,层数的增加会导致模型复杂性上升和效率降低。为此,引入扩张卷积来降低计算成本。

扩张卷积通过在卷积核元素之间插入间隔,有效扩大了卷积核的感受野。图2展示了一个具有三个卷积核的扩张因果卷积的原理示意图。该模型采用三层卷积结构,扩张系数分别为1、2、4,最后一层输出 y_t 的感受野为15;而采用卷积核大小为3的标准因果卷积则需要七层才能达到相同的感受野大小。

对于一维序列的输入序列 $x \in R^n$ 和过滤器 $f: \{0, 1, \dots, k-1\} \rightarrow R$,元素 t 和扩张卷积运算 F 之间存在以下关系:

$$F(t) = (x \times d \cdot f)(t) = \sum_{i=0}^{k-1} f(i) \cdot x_{t-d \cdot i} \quad (1)$$

其中， $\times$ 表示卷积运算； d 为扩张系数； i 为滤波器尺寸； $t-d \cdot i$ 为历史方向。




Figure 1. Schematic diagram of causal convolution

图 1. 因果卷积示意图




Figure 2. Schematic diagram of dilated causal convolution with three convolution kernels

图 2. 具有三个卷积核的扩张因果卷积原理图




Figure 3. Architecture diagram of the temporal convolutional network

图 3. 时序卷积网络结构图

如图 3 所示，TCN 的网络结构由多个残差块堆叠而成。每个残差块主要包含两个部分：一部分用于非线性映射的主网络结构，另一部分为残差映射路径。主网络结构由两层的扩张因果卷积层、权重归一

化层、修正线性单元(Rectified Linear Unit, ReLU)函数和正则化层组成。残差映射路径通过一维卷积运算对输入特征进行线性变换,使其与主网络输出在维度上保持一致。输入序列同时遵循主网络路径和残差映射路径,最终将两部分的输出相加形成残差连接。残差块的计算过程可以表示为

$$O = \text{Activation}(x + F(x)) \quad (2)$$

其中, O 为输出层; $F(x)$ 为当前层的特征映射; $\text{Activation}(\cdot)$ 为激活函数。

3.2. FEDformer

FEDformer 是一种用于长时间序列预测任务的深度学习模型,它通过引入频域建模机制,有效缓解了长序列建模过程中计算复杂度高、难以捕捉时间序列长期依赖性的问题。因此,本文采用 FEDformer 再一次对碳排放权交易价格进行特征提取。FEDformer 主要由多个堆叠的编码器和解码器组成,并在注意力机制中引入了频率增强分解模块,其整体结构如图 4 所示。




Figure 4. Overall architecture of FEDformer

图 4. FEDformer 的整体结构图

编码器采用多层堆叠结构: $\chi_{en}^l = \text{Encoder}(\chi_{en}^{l-1})$, $l \in \{1, \dots, N\}$ 表示第 l 层编码层的输出, $\chi_{en}^0 \in \mathbb{R}^{I \times D}$ 为嵌入的历史序列。编码器的数学表达式如下:

$$\begin{aligned} S_{en}^{l,1} &= \text{MODEcomp}(\text{FEB}(\chi_{en}^{l-1}) + \chi_{en}^{l-1}) \\ S_{en}^{l,2} &= \text{MODEcomp}(\text{FeedForward}(S_{en}^{l,1}) + S_{en}^{l,1}) \\ \chi_{en}^l &= S_{en}^{l,2} \end{aligned} \quad (3)$$

其中, $S_{en}^{l,i}$, $i \in \{1, 2\}$ 为第 l 层第 i 次分解后的季节分量。对于 FEB 模块,它有两个不同的版本(FEB-f 和 FEB-w),分别通过离散傅立叶变换(Discrete Fourier Transform, DFT)和离散小波变换(Discrete Wavelet

Transform, DWT)机制实现, 可以无缝地取代自注意块。

解码器也采用多层堆叠结构: $\chi_{de}^l, T_{de}^l = \text{Decoder}(\chi_{de}^{l-1}, T_{de}^{l-1}), l \in \{1, \dots, M\}$ 表示第 l 层解码器的输出。解码器的数学表达式如下:

$$\begin{aligned} S_{de}^{l,1}, T_{de}^{l,1} &= \text{MOEDecom}(\text{FEB}(\chi_{de}^{l-1}) + \chi_{de}^{l-1}) \\ S_{de}^{l,2}, T_{de}^{l,2} &= \text{MOEDecom}(\text{FEA}(S_{de}^{l,1}, \chi_{en}^N) + S_{de}^{l,1}) \\ S_{de}^{l,3}, T_{de}^{l,3} &= \text{MOEDecom}(\text{FeedForward}(S_{de}^{l,2}) + S_{de}^{l,2}) \\ \chi_{en}^l &= S_{de}^{l,3} \\ T_{de}^l &= T_{de}^{l-1} + W_{l,1}T_{de}^{l,1} + W_{l,2}T_{de}^{l,2} + W_{l,3}T_{de}^{l,3} \end{aligned} \quad (4)$$

其中, $S_{de}^{l,i}, T_{de}^{l,i}, i \in \{1, 2, 3\}$ 为第 l 层第 i 次分解后的季节分量和趋势分量; $W_{l,i}, i \in \{1, 2, 3\}$ 表示第 i 次提取的趋势分量 $T_{de}^{l,i}$ 的投影。与 FEB 模块类似, FEA 模块也有两个不同的版本(FEA-f 和 FEA-w), 分别通过 DFT 和 DWT 投影实现注意力设计, 可以替代交叉注意力块。

模型的最终预测是两个精炼后的分解分量通过加权求和得到: $W_s \cdot \chi_{de}^M + T_{de}^M$, 其中 W_s 将经过深度变换的季节分量 χ_{en}^M 映射到目标预测维度。

3.3. 提出的模型框架




Figure 5. Overall flow diagram of TCN-FEDformer
图 5. TCN-FEDformer 的整体流程图

本文融合 TCN 与 FEDformer 的优势，将模型输出的两类特征向量进行拼接后，输入 MLP 网络中进行非线性映射。通过多层全连接结构，MLP 能够有效学习不同特征之间的关联关系，从而实现对两类信息的深度融合。最终，融合后的特征通过输出层映射得到碳排放权交易价格的预测结果。模型的整体流程如图 5 所示。

4. 实证分析

4.1. 数据描述与预处理

本文选取我国区域碳排放权交易市场中具有代表性的湖北碳排放权交易价格(Hubei Carbon Emission Allowance, HBEA)和广州碳排放权交易价格(Guangdong Carbon Emission Allowance, GDEA)作为研究对象。两地碳市场开启时间较早，交易机制相对成熟，能够充分反映我国碳排放权交易价格的演化特征。数据来自 WIND 数据库(<https://www.wind.com.cn/>)，时间跨度为 2014 年 7 月 1 日至 2025 年 5 月 30 日，数据频率为日度交易价格，数据趋势如图 6 所示。




Figure 6. Trend of the carbon emission trading price dataset
图 6. 碳排放权价格数据集趋势图

预处理方面，原始数据中仅包含交易日记录，非交易日无报价，因此本文直接保留实际交易数据，不对缺失日期进行填充或插补，以避免人为构造信息对原始价格特征造成干扰。为消除量纲影响并加速模型收敛，采用 Z-Score 标准化对价格序列进行归一化处理，均值和标准差分别由训练集计算得到，确保不引入未来信息。数据集按 6:2:2 的比例划分为训练集、验证集和测试集。模型采用输入长度为 `seq_len = 10`、预测长度 `pred_len = 1` 的配置，即用过去 10 个交易日预测未来 1 个交易日。选择该设置主要基于两方面考虑：一方面，碳价序列具有显著的短期记忆特征，10 个交易日(约两周)的历史窗口足以捕捉其局部动态和自相关性；另一方面，单步预测能够直接服务于市场参与者的次日交易决策，具备明确的应用价值。

Table 1. Descriptive statistics of the carbon emission trading price series
表 1. 碳排放权交易价格序列描述性统计结果

	HBEA	GDEA
总数	2584	2435

续表

均值	30.9100	37.3456
中位数	28.9250	28.3600
最大值	61.4800	95.2600
最小值	10.3800	8.1000
标准差	11.2164	23.4506
偏度	0.1359	0.7229
峰度	1.8291	2.1409
L-B (15)	37410.4927***	35963.2861***
J-B	155.5688***	286.7983***
ADF	0.6286	0.7282

注：***表示在 1% 的显著性水平下拒绝原假设。

表 1 展示了两个碳排放权交易价格数据集的描述性统计结果。可以看出，HBEA 和 GDEA 在整体水平和波动特征上存在一定差异。从均值和中位数来看，GDEA 的平均价格高于 HBEA，而两者中位数较为接近。从极值和波动性特征来看，GDEA 的最大值和标准差都明显高于 HBEA，说明广东碳排放权交易价格在样本期内波动幅度更大，市场价格不稳定性更强。偏度和峰度结果表明，两地碳价序列均呈现正偏分布特征，且尾部更薄。Ljung-Box 检验结果在 15 阶滞后下均显著，表明碳排放权交易价格序列存在明显的自相关性。Jarque-Bera 检验结果同样拒绝正态性假设，而 ADF 单位根检验结果 P 值均大于 0.05，表明两组碳价序列均为非平稳序列。

4.2. 评估指标

为了客观评价所提出的模型在碳排放权交易价格预测中的性能，本文选取了 5 种评价指标，计算公式如下：

$$R^2 = 1 - \frac{\sum_{t=1}^N (y_t - \hat{y}_t)^2}{\sum_{t=1}^N (y_t - \bar{y})^2} \quad (5)$$

$$\text{MSE} = \frac{1}{N} \sum_{t=1}^N (\hat{y}_t - y_t)^2 \quad (6)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{t=1}^N (\hat{y}_t - y_t)^2} \quad (7)$$

$$\text{MAE} = \frac{1}{N} \sum_{t=1}^N |y_t - \hat{y}_t| \quad (8)$$

$$\text{MAPE} = \frac{100\%}{N} \sum_{t=1}^N \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (9)$$

其中， $\bar{y}$ 和 $\hat{y}_t$ 分别表示真实碳排放权交易价格 y_t 的均值和预测值。

4.3. 参数配置

本文依据模型结构对 TCN-FEDformer 的关键参数进行设置。对于 TCN，网络由 2 层一维卷积层构成，卷积核尺寸设置为 3，隐藏层维度为 512。TCN 利用扩张因果卷积对时间序列进行建模，以捕捉碳排放权交易价格的短期动态变化特征。对于 FEDformer，编码器和解码器的层数分别为 2 和 1，隐藏维度设

置为 512, 前馈网络维度为 256, 注意力头数设为 8。频域建模中, 频率模式数选取为 64, 模式选择策略采用随机选择。两路模型的训练都采用批量大小为 32、学习率为 0.0001 的 Adam 优化策略, 损失函数为 MSE。

本文选取多种具有代表性的时间序列预测模型作为对比实验对象, 包括 CNN、TCN、LSTM 和门控循环单元(Gated Recurrent Unit, GRU)等时域建模模型; 同时, 选取 Informer、Autoformer 和 FEDformer 作为代表性的长时间序列预测模型。为确保对比的公平性, 本文对所有参与对比的基准模型统一在验证集上进行了参数调优。调优范围覆盖各模型的核心超参数, 每个模型选取验证集上表现最佳的参数组合用于测试。所有模型均在相同的实验环境下完成训练与测试, 以保证性能差异仅来源于模型架构本身。

4.4. 对比实验结果分析

为进一步验证模型性能, 本节将 TCN-FEDformer 模型与 4.3 节介绍的 8 个基准模型在两大碳排放权交易价格数据集上进行对比分析。图 7 展示了不同模型在 HBEA 和 GDEA 数据集的样本外测试期的预测曲线对比结果, 其中黑色曲线为真实碳价。表 2 给出了各模型在两个数据集上的误差评价指标的计算结果。通过对图形结果与误差指标的综合分析, 可以较为全面地评估各模型在碳排放权交易价格预测任务中的表现差异, 总结为以下三个方面:

第一, 传统时域模型 CNN、TCN、LSTM 和 GRU 在碳排放权交易价格预测中具备一定有效性, 但在剧烈波动阶段和长期变化刻画方面存在不足, 并且不同模型之间存在明显差异。例如, 在 HBEA 数据集中, TCN 的预测误差指标(MSE = 1.2512, RMSE = 1.1186, MAE = 0.8565, MAPE = 2.0795%)整体优于 CNN (MSE = 2.0389, RMSE = 1.4279, MAE = 1.1443, MAPE = 2.8117%), 各项指标分别下降了 38.66%、21.67%、25.15%和 26.05%, 表明基于扩张因果卷积的 TCN 在建模碳价格序列局部动态方面具有明显优势。与 RNN 模型相比, TCN 在部分指标上同样表现更优。例如, 在 HBEA 数据集中, TCN 的 MAE 和 MAPE 均低于 LSTM 和 GRU, 说明卷积结构在捕捉碳价短期波动方面优于门控结构。然而, 在价格快速变化阶段, 传统时域模型存在过度平滑的问题。从图 8 可以看出, 在 HBEA 数据集中, 四个模型的预测结果在局部峰值和谷值附近反应迟缓, TCN 虽然在 GDEA 数据集中有所改善, 但在整体上难以保持长期稳定。这表明, 只依赖时域信息建模难以全面捕捉碳排放权交易价格的特征。

第二, Transformer 架构模型在碳排放权交易价格预测中的表现存在显著分化, 其中 FEDformer 优于传统时域模型, Autoformer 与时域模型相当, Transformer 和 Informer 则表现最差。以 HBEA 数据集为例, FEDformer 的预测误差指标(MSE = 0.9867, RMSE = 0.9933, MAE = 0.6872, MAPE = 1.6442%)仅次于 TCN-FEDformer, 表明引入频域增强分解后, 模型在预测精度上显著提升。相比之下, Autoformer 在两个数据集上的预测性能与时域模型基本处于同一水平。例如, 在 GDEA 数据集中, Autoformer 的 RMSE 和 MAE 分别为 1.9049 和 1.3867, 与 CNN 和 TCN 的误差水平较为接近。从图 7 可以进一步看出 Transformer 和 Informer 的预测轨迹在 HBEA 与 GDEA 数据集中均明显偏离真实价格走势表现出较为明显的欠拟合现象。这表明, 频域增强机制在提升碳排放权交易价格预测精度方面发挥了关键作用。

第三, TCN-FEDformer 模型在两个碳排放权交易市场中均取得最优预测表现, 验证了两路特征融合建模的有效性与必要性。以 HBEA 数据集为例, TCN-FEDformer 的预测误差(MSE = 0.8721, RMSE = 0.9338, MAE = 0.6202, MAPE = 1.4800%)相较于次优模型 FEDformer (MSE = 0.9867, RMSE = 0.9933, MAE = 0.6872, MAPE = 1.6442%)进一步下降了 11.62%、5.97%、9.73%和 9.97%, 在 GDEA 数据集中, TCN-FEDformer 同样取得最高的 R^2 值和最低的误差水平, 充分说明该模型在不同市场条件下均具有较强的稳定性和泛化能力。从图 7 的预测曲线对比结果可以更加直观地观察到 TCN-FEDformer 的优势, TCN-FEDformer 的预测轨迹最紧贴真实价格序列, 这表明 TCN-FEDformer 通过将 TCN 的局部动态特征提取

能力与 FEDformer 的长期周期建模优势进行融合，实现了最优的预测性能。



Figure 7. Curve of predicted carbon emission trading prices
图 7. 碳排放权交易价格预测值曲线图

Table 2. Calculation results of error metrics for the comparative experimental models
表 2. 对比实验模型的误差指标计算结果

HBEA						GDEA					
	R ²	MSE	RMSE	MAE	MAPE		R ²	MSE	RMSE	MAE	MAPE
CNN	0.7895	2.0389	1.4279	1.1443	2.8117%	CNN	0.9884	3.0061	1.7338	1.2363	2.3868%
TCN	0.8708	1.2512	1.1186	0.8565	2.0795%	TCN	0.9881	3.0847	1.7563	1.2529	2.4473%
LSTM	0.8669	1.2898	1.1357	0.8717	2.0920%	LSTM	0.9681	8.2749	2.8766	2.3413	4.2899%
GRU	0.8541	1.4132	1.1888	0.8489	2.0526%	GRU	0.9824	4.5744	2.1388	1.7214	3.2938%
Transformer	0.6317	3.5680	1.8889	1.4366	3.2735%	Transformer	0.4105	152.8480	12.3632	8.8969	13.0371%
Informer	0.0332	9.3650	3.0602	2.4453	5.5296%	Informer	0.4603	139.9314	11.8293	8.7388	13.0714%
Autoformer	0.8839	1.1244	1.0604	0.7504	1.7951%	Autoformer	0.9860	3.6288	1.9049	1.3867	2.6628%
FEDformer	0.8981	0.9867	0.9933	0.6872	1.6442%	FEDformer	0.9889	2.8867	1.6990	1.2120	2.3569%
TCN-FED	0.9100	0.8721	0.9338	0.6202	1.4800%	TCN-FED	0.9898	2.6543	1.6292	1.1346	2.1826%

4.5. 模型行为定性分析

为了更深入地理解 TCN-FEDformer 模型在典型市场环境下的预测行为及其内部学习机制，本节进一步开展定性分析。具体而言，选取碳排放权交易价格波动最为剧烈的特定时间段进行预测轨迹的对比，

并通过对 FEDformer 模块的频域分解结果进行可视化, 揭示模型所捕捉到的数据内在规律。

4.5.1. 典型波动区间的预测行为对比

本文选取 2024 年 11 月 1 日至 2025 年 1 月 27 日作为典型分析区间, 该区间完整覆盖了碳价从震荡上行到急速下跌再到低位盘整的三个完整市场周期阶段, 能够全面检验模型在不同市场状态下的预测表现。该区间内碳价运行区间约为每吨 35 至 50 元, 经历了超过 20% 的深度回调, 波动剧烈, 是检验预测模型稳健性的理想场景, 结果如图 8 所示。

从两个子图的预测轨迹对比来看, TCN-FEDformer (蓝色) 在 HBEA 和 GDEA 两个市场中均与真实价格 (黑色) 贴合最为紧密, 尤其在 12 月中下旬的急跌阶段能够迅速响应趋势转折, 未出现系统性高估低估。LSTM 和 GRU 在平稳阶段容易高估, 预测曲线在转折处无法及时跟进真实走势。Transformer 和 Informer 的预测轨迹偏离真实值最远, 在 GDEA 市场 12 月中旬的冲高回落阶段出现严重虚高。TCN 和 FEDformer 在趋势跟踪方面表现良好, 但在局部细节刻画上有所不足, TCN 在急跌段存在轻微高估, FEDformer 在震荡期则趋于过度平滑。TCN-FEDformer 通过融合两路特征, 同时兼顾了趋势响应速度和局部波动刻画精度, 在两个市场均取得最优预测效果, 验证了所提混合架构在碳价预测中的有效性与稳健性。




Figure 8. Curve of predicted carbon emission trading prices in typical volatile periods

图 8. 碳排放权交易价格在典型波动区间预测值曲线图

4.5.2. 频域分解模式的可视化分析

为进一步揭示模型内部的学习机制, 缓解深度学习模型“黑箱”特性带来的疑虑, 本文对 TCN-FEDformer 中 FEDformer 模块的频域分解输出进行了提取与可视化。具体地, 将解码器输出的季节分量与趋势分量进行分离, 并与真实价格序列进行对比, 结果如图 9 所示。

从分解结果可以看出, TCN-FEDformer 的预测建立在清晰的经济逻辑之上。红色虚线所示的趋势分量准确刻画了碳价在测试期内的长期演化方向, HBEA 与 GDEA 两个市场均同步捕捉了从上行到加速下跌再至筑底企稳的完整过程, 反映了由供需基本面与政策预期变化驱动的低频宏观信号。绿色虚线所示的季节分量则围绕趋势呈现周期性波动, 其在价格震荡阶段振幅扩大, 在趋势主导阶段趋于收敛, 表明模型成功识别了与市场微观交易行为相联系的中频周期特征。将二者逐点相加即得到亮蓝色曲线所示的最终预测值, 趋势主导阶段预测主要跟随趋势分量, 波动加剧阶段季节分量提供短期修正。这种“趋势 + 季节”的合成逻辑, 验证了模型的可解释性与预测结果的可信度。




Figure 9. Comparison of decomposition forecasting for carbon emission trading prices

图 9. 碳排放权交易价格分解预测对比

4.6. Diebold-Mariano 检验结果分析

为进一步检验 TCN-FEDformer 模型相比较于各对比模型在预测精度上的统计显著性差异, 本文采用 Diebold-Mariano (DM) 检验对不同模型的预测误差序列进行比较。将 TCN-FEDformer 模型作为基准模型, 分别在 HBEA 与 GDEA 两个数据集上, 基于 MSE、MAE 和 MAPE 三个损失函数计算 DM 统计量, 结果如表 3 所示。

从 HBEA 数据集的检验结果可以看出, TCN-FEDformer 模型相对于其他 8 个对比模型的 DM 统计量均为负值, 并且在 1% 的水平下显著 ($p < 0.01$)。这表明在三个误差函数下, TCN-FEDformer 的预测误差都显著小于 CNN、TCN、LSTM、GRU 以及 Transformer、Informer、Autoformer、FEDformer。在 GDEA 数

据集上, DM 检验结果呈现出与 HBEA 市场一致的结论。这说明在不同的碳排放权交易市场中, TCN-FEDformer 的预测性能优势具有较强的稳健性。

Table 3. Calculation results of the DM statistics for the comparative experimental models
表 3. 对比实验模型的 DM 统计量计算结果

	HBEA				GDEA		
	MSE	MAE	MAPE		MSE	MAE	MAPE
CNN	-10.3102***	-13.5530***	-13.7987***	CNN	-3.0092***	-4.1542***	-3.9984***
TCN	-5.4476***	-8.4579***	-8.7144***	TCN	-4.9144***	-5.9072***	-5.9962***
LSTM	-6.0791***	-9.8835***	-9.8658***	LSTM	-12.6207***	-16.4702***	-16.4718***
GRU	-6.2665***	-8.9977***	-9.2198***	GRU	-7.7690***	-12.6567***	-12.0065***
Transformer	-13.6817***	-15.6397***	-15.7484***	Transformer	-14.4760***	-20.6222***	-23.8937***
Informer	-16.9367***	-21.7609***	-22.4092***	Informer	-14.8969***	-21.6876***	-26.0235***
Autoformer	-4.4312***	-6.3066***	-6.2901***	Autoformer	-5.5885***	-6.9045***	-6.5679***
FEDformer	-2.5295**	-3.8411***	-3.9402***	FEDformer	-2.3398**	-3.2267***	-3.5637***

注: **、*分别表示在 1%、5%的显著性水平下显著。

5. 总结

本文提出了一种新的 TCN-FEDformer 模型, 并以 HBEA 和 GDEA 两个典型的碳排放权交易市场数据为研究对象, 对模型的预测性能进行了系统评估与验证。通过实验分析, 我们可以得出以下结论:

第一, TCN-FEDformer 模型在预测性能上表现突出。它通过 TCN 提取碳排放权交易价格序列的局部动态特征与短期依赖关系, 同时通过 FEDformer 建模价格序列中的长期频域特征和周期性结构, 最后通过 MLP 融合两路特征, 实现对碳排放权交易价格的高精度预测和预测稳定性。

第二, 在多种主流时序预测模型的对比实验中 TCN-FEDformer 取得最优预测效果。本文选取 CNN、TCN、LSTM、GRU 等传统时域模型, 以及 Transformer、Informer、Autoformer 和 FEDformer 等基于注意力机制的模型作为对比对象。实验结果表明, TCN-FEDformer 在 HBEA 与 GDEA 数据集上的误差指标均显著低于对比模型, 且在 MSE、RMSE 和 MAPE 等关键指标上优势明显。

第三, DM 检验结果进一步验证了 TCN-FEDformer 优势的统计显著性。在 HBEA 和 GDEA 数据集上, TCN-FEDformer 相对于各对比模型在 MSE、MAE 和 MAPE 指标上的 DM 统计量均在 1%的水平上显著, 验证了模型性能提升具有统计意义上的稳健性。

综上所述, 本文提出的 TCN-FEDformer 模型在碳排放权交易价格预测中展现出更高的预测精度和稳健性。研究结论不仅为碳市场价格预测提供了一种有效的方法, 也为相关政策制定和市场风险管理提供了有价值的决策参考。

参考文献

- [1] Güney, T. (2019) Renewable Energy, Non-Renewable Energy and Sustainable Development. *International Journal of Sustainable Development & World Ecology*, **26**, 389-397. <https://doi.org/10.1080/13504509.2019.1595214>
- [2] Zhu, B., Han, D., Wang, P., Wu, Z., Zhang, T. and Wei, Y. (2017) Forecasting Carbon Price Using Empirical Mode Decomposition and Evolutionary Least Squares Support Vector Regression. *Applied Energy*, **191**, 521-530. <https://doi.org/10.1016/j.apenergy.2017.01.076>
- [3] 蒋松谕, 何贞铭, 周再文, 等. 二次分解策略的深度学习碳交易价格预测[J]. 科学技术与工程, 2024, 24(8): 7928-7939.

- [4] Zhou, K. and Li, Y. (2017) Carbon Finance and Carbon Market in China: Progress and Challenges. *Journal of Cleaner Production*, **214**, 536-549. <https://doi.org/10.1016/j.jclepro.2018.12.298>
- [5] 王玉芳, 王楠, 张书华. 基于多源数据特征和多尺度分析的欧盟碳价格混合预测[J]. 系统科学与数学, 2025, 45(10): 3245-3266.
- [6] 周坤, 高晓辉, 李廉水. 基于 EMD-XGB-ELM 和 FSGM 二元处理的碳排放权交易价格集成预测[J]. 中国管理科学, 2024, 32(10): 325-334.
- [7] 徐登可, 汤朱远洋, 沈琳琳. 基于 CEEMDAN-CNN-LSTM 模型的上海碳排放权交易价格区间预测研究[J]. 统计科学与实践, 2024(7): 28-31+40.
- [8] Sun, W. and Li, Z. (2020) An Ensemble-Driven Long Short-Term Memory Model Based on Mode Decomposition for Carbon Price Forecasting of All Eight Carbon Trading Pilots in China. *Energy Science & Engineering*, **8**, 4094-4115. <https://doi.org/10.1002/ese3.799>
- [9] Lan, Y., Huangfu, Y., Huang, Z. and Zhang, C. (2024) Breaking through the Limitation of Carbon Price Forecasting: A Novel Hybrid Model Based on Secondary Decomposition and Nonlinear Integration. *Journal of Environmental Management*, **362**, Article 121253. <https://doi.org/10.1016/j.jenvman.2024.121253>
- [10] Shi, H., Wei, A., Xu, X., Zhu, Y., Hu, H. and Tang, S. (2024) A CNN-LSTM Based Deep Learning Model with High Accuracy and Robustness for Carbon Price Forecasting: A Case of Shenzhen's Carbon Market in China. *Journal of Environmental Management*, **352**, Article 120131. <https://doi.org/10.1016/j.jenvman.2024.120131>
- [11] Ji, M., Du, J., Du, P., Niu, T. and Wang, J. (2025) A Novel Carbon Price Forecasting Model Integrating Mixed-Frequency Modeling into the Transformer Architecture from a Multi-Factor Perspective. *Expert Systems with Applications*, **289**, Article 128300. <https://doi.org/10.1016/j.eswa.2025.128300>
- [12] Li, J. and Guo, Y. (2025) A Hybrid Model for Carbon Price Forecasting Based on SSA-NSTransformer: Considering the Role of Multi-Stage Carbon Reduction Targets. *Journal of Environmental Management*, **375**, Article 124237. <https://doi.org/10.1016/j.jenvman.2025.124237>
- [13] Zhou, T., Ma, Z., Wen, Q., et al. (2022) FEDformer: Frequency Enhanced Decomposed Transformer for Long-Term Series Forecasting. 2022 *International Conference on Machine Learning*, Baltimore, 17-23 July 2022.
- [14] 陈岩, 张苗, 高静. 基于 CEEMDAN-SE-GRU 的碳排放权交易价格预测[J]. 信息系统工程, 2024(11): 123-126.
- [15] 危冰淋, 刘春雨, 刘家鹏. 基于 Transformer-LSTM 模型的多因素碳排放权交易价格预测[J]. 价格月刊, 2024(5): 49-57.
- [16] Huang, Y., Dai, X., Wang, Q. and Zhou, D. (2021) A Hybrid Model for Carbon Price Forecasting using GARCH and Long Short-Term Memory Network. *Applied Energy*, **285**, Article 116485. <https://doi.org/10.1016/j.apenergy.2021.116485>
- [17] Xu, J., Tan, X., He, G. and Liu, Y. (2019) Disentangling the Drivers of Carbon Prices in China's ETS Pilots—An EEMD Approach. *Technological Forecasting and Social Change*, **139**, 1-9. <https://doi.org/10.1016/j.techfore.2018.11.009>
- [18] 闫梦, 王聪. 基于多尺度集成模型预测碳交易价格——以广州碳排放交易中心为例[J]. 技术经济与管理研究, 2020(5): 19-24.
- [19] 袁文燕, 杜鸿川, 李洁仪, 等. 基于多源数据特征驱动和多尺度分析的 PM2.5 混合预测研究[J]. 系统科学与数学, 2023, 43(2): 399-416.