

Research on Carbon Price Prediction Method Based on Decomposition-Prediction-Aggregation and Genetic Algorithm (GA) Optimization

Jinglei Li

Inner Mongolia University of Technology, Hohhot, Inner Mongolia, 010000, China

Abstract

In the context of carbon neutrality, accurate carbon price forecasting is crucial for data centers. The nonlinear and non-stationary nature of carbon price series limits the accuracy of single models. The existing “decomposition-aggregation” paradigm employs variational mode decomposition (VMD) technology, where the subjective setting of parameters (K, α) affects prediction accuracy. To address this, we propose the VMD-GA-BiLSTM model. The core innovation lies in introducing a genetic algorithm that minimizes the average approximate entropy of intrinsic mode components as the fitness function, adaptively optimizing the VMD parameters K and α to enhance predictability. Subsequently, bidirectional long short-term memory networks (BiLSTM) are utilized to independently predict each component and aggregate them. Empirical analysis using EU carbon market data demonstrates that the proposed model outperforms benchmarks including autoregressive integrated moving average (ARIMA), BiLSTM, and unoptimized VMD-BiLSTM in both root mean square error (RMSE) and mean absolute error. This study provides a rigorous framework for high-volatility series prediction and delivers reliable price signals for low-carbon data center scheduling.

Keywords

carbon price forecasting; data center; decomposition-prediction-aggregation; variational mode decomposition (VMD); genetic algorithm (GA); approximate entropy (ApEn); bidirectional long short-term memory network (BiLSTM)

基于“分解 – 预测 – 聚合”及 GA 优化的碳价格预测方法研究

李晶磊

内蒙古工业大学，中国 · 内蒙古 呼和浩特 010000

摘要

“碳中和”背景下，碳价格精准预测对数据中心至关重要。碳价序列非线性非平稳，单一模型精度受限。现有“分解-聚合”范式中变分模态分解技术（VMD）参数()设定主观，影响精度。为此，本文提出VMD-GA-BiLSTM模型。核心创新在于：引入遗传算法，以最小化本征模态分量的平均近似熵为适应度函数，自适应寻优VMD最佳参数，以提升序列可预测性。随后利用双向长短期记忆网络进行独立预测各分量并聚合。选取欧盟碳市场数据实证表明，所提模型在均方根误差、平均绝对误差上均优于自回归积分滑动平均模型、双向长短期记忆网络（BiLSTM）及未优化VMD-BiLSTM等基准。本研究为高波动序列预测提供了严谨范式，为数据中心低碳调度提供了可靠的价格信号。

关键词

碳价格预测；数据中心；分解-预测-聚合；变分模态分解(VMD)；遗传算法(GA)；近似熵(ApEn)；双向长短期记忆网络(BiLSTM)

1 引言

1.1 研究背景与意义

随着全球气候变化问题日益严峻，构建可持续发展路

【基金项目】“内蒙古自治区直属高校基本科研业务费“基于人工智能的数据中心碳中和关键技术研究”项目支持。

【作者简介】李晶磊（1995-），女，蒙古族，硕士，讲师，从事人工智能、数据分析研究。

径已成为国际社会的普遍共识。碳排放权交易体系（ETS）作为一种核心的政策工具，其重要性与日俱增。截至2025年，全球运行的碳市场已覆盖约19%的温室气体排放量，其核心信号——碳价格，正日益深刻地影响着资本流向与产业决策。在此背景下，中国提出的“双碳”目标不仅是一项庄严承诺，更是一场广泛而深刻的经济社会系统性变革。作为实现该目标的关键抓手，全国碳市场的稳步发展与未来从能源“双控”向碳排放“双控”的转变，将进一步凸显碳价格在资源配置中的决定性作用^[1]。

与此同时,数字经济的飞速发展带来了数据中心产业的爆炸式增长,其巨大的能源消耗与碳排放问题随之而来。据国际能源署预测,在人工智能等高算力需求的驱动下,全球数据中心的电力消耗到 2030 年将可能翻倍^[2]。这种能源需求的爆炸式增长,与全球及各国日趋严格的碳减排目标形成了尖锐的矛盾。因此,碳价格已从一个外部环境因素,转变为影响其核心运营决策与长期战略规划的内生成本变量。精准的碳价格预测是企业实施低碳经济调度的前提,它能指导企业优化能源采购、管理碳配额、对冲市场风险,并为绿色技术投资提供可靠的决策依据^[3]。然而,现有研究常采用过于简化的线性函数模拟碳价,与真实市场动态相去甚远,无法为企业提供有效的运营指导。因此,开发能够精确捕捉碳价格复杂动态的高保真度预测模型,不仅具有重要的理论价值,更对支持关键产业的绿色转型具有紧迫的现实意义。

1.2 碳价格预测研究现状与本文贡献

碳价格作为一种典型的金融时间序列,受政策、经济、能源等多重因素影响,表现出高度的非线性、非平稳性与多尺度波动等复杂特性^[4]。现有预测方法大致可分为三类。第一类是传统的计量经济模型,如自回归积分滑动平均模型(ARIMA)和广义自回归条件异方差模型(GARCH),它们擅长捕捉线性规律,但在非线性特征日益显著的碳市场中精度受限。第二类是单一机器学习与深度学习模型,如向量回归(SVR)、长短期记忆网络(LSTM)等^[5],虽具备强大的非线性拟合能力,但在处理充满噪声的原始序列时,性能易受干扰。

为克服上述局限,基于“分解-预测-聚合”范式的混合模型应运而生。范式通过经验模态分解(EMD)、集合经验模态分解(EEMD)以及变分模态分解(VMD)等技术将原始序列分解为多个更平稳的子序列,再分别预测并聚合,显著提升了预测精度^[6]。然而,现有基于 VMD 的研究普遍存在一个关键缺陷:其核心参数“模态数量 K 和惩罚因子”多依赖主观经验设定,缺乏客观依据,导致分解效果不稳定,直接影响最终预测精度,损害了研究的科学性与可复现性^[7]。

为解决上述研究空白,本文提出了一种基于“分解-优化-预测-聚合”精细化范式的 VMD-GA-BiLSTM 混合预测模型。本研究的核心贡献在于将分解过程转变为数据驱动的、可优化的。首先,引入遗传算法(GA)自动搜索 VMD 的最佳参数组合,以替代主观的人工试错^[8]。其次,创造性地构建以最小化所有模态分量的平均近似熵(ApEn)目标的适应度函数。ApEn 是衡量时间序列复杂性的稳健指标,其值越小,序列规律性越强,可预测性越高。该设计旨在引导 GA 寻找一种能使分解后各子序列“最简单”、“最规律”的分解方式,为后续预测创造理想输入。最后,采用双向长短期记忆网络(BiLSTM)对各分量进行预测,以同时捕捉序列的历史与未来上下文信息,进一步提升预测精度^[9]。

2 相关理论与方法

2.1 变分模态分解

变分模态分解是一种新兴的、非递归的自适应信号处理技术,其目的在于将一个实值输入信号分解为一系列离散的、具有特定稀疏特性的模态分量 u_k (亦称为本征模态函数,IMF)。每个 u_k 模态被假定为紧凑地围绕一个中心频率 ω_k 的调幅-调频信号。VMD 通过构建并求解一个约束变分问题,寻找一组使总带宽最小的模态分量,同时确保它们的和能精确重构原始信号^[10]。相较于 EMD 等方法,VMD 具有更坚实的数学基础,能有效抑制模态混叠问题,获得物理意义更明确的分量^[11]。然而,VMD 的性能高度依赖于预设的模态数 K 和惩罚因子 α ,这两个参数的不当选择会严重影响分解效果,是其应用中的核心挑战^[12]。

2.2 近似熵

近似熵是一种用于量化时间序列规律性与复杂度的非线性动力学指标^[13]。它通过衡量序列中新模式产生的概率来评估其可预测性。ApEn 值越小,表明序列规律性越强,随机性越弱,可预测性越高。该算法对数据长度不敏感且抗噪能力强,尤其适用于分析金融时间序列。在本研究中,ApEn 被用作评价 VMD 分解效果的关键指标,其核心逻辑是:有效的分解应将复杂序列转化为一组复杂度更低的子序列。

2.3 遗传算法

遗传算法是一种模拟生物进化过程的全局概率性搜索算法^[14]。它通过选择、交叉和变异等操作,在解空间中迭代搜索,逐步收敛至最优解。GA 不依赖梯度信息,鲁棒性强,特别适用于解决 VMD 参数寻优这类复杂的非线性优化问题。在本研究中,遗传算法的适用性体现在其能够在一个预设的二维参数空间(由 K 和 α 构成)中,以一个明确的适应度函数为引导,高效地搜索 VMD 的最优参数组合^[15]。

2.4 双向长短期记忆网络

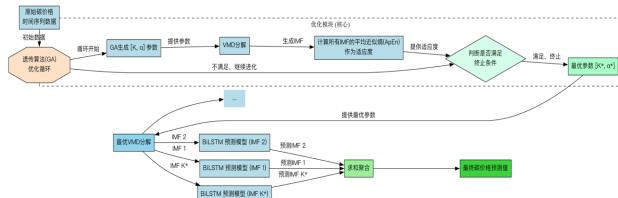
长短期记忆网络是一种特殊的循环神经网络,通过引入输入门、遗忘门和输出门等门控机制,有效解决了处理长序列时的梯度消失问题^[16]。但 LSTM 在处理序列数据时是单向的,即在时间点 t 的预测仅能利用过去($t-1$ 及之前)的信息。为了克服这一局限性,而 BiLSTM 则由一个前向 LSTM 层和一个后向 LSTM 层构成^[17]。这种结构使得模型在任一时间点都能同时利用过去和未来的上下文信息,从而构建更全面的特征表示,有望实现比单向 LSTM 更高的预测精度^[18]。

3 基于 GA-VMD-BiLSTM 的预测模型构建

3.1 模型总体框架

模型框架包含四个核心模块:GA 优化、VMD 分解、BiLSTM 预测与聚合重构。首先,原始碳价格序列被送入 GA 优化模块,其任务是为 VMD 寻找最优参数组合 $[K, \alpha]$ 。GA 在其内部迭代中,不断生成候选参数对,调用 VMD 进

行分解，并依据一个预设的适应度函数评估分解效果，直至找到最优解。随后，利用这组最优参数，通过 VMD 模块对原始序列进行最终分解，得到 K^* 个 IMF 分量。接着，为每个 IMF 分量构建独立的 BiLSTM 网络进行并行预测。最后，聚合模块将所有分量的预测结果求和，并经反归一化处理，重构为最终的碳价格预测值。模型总体框架如下图表 1 所示。



图表 1 模型总体框架流程图

3.2 GA 优化 VMD 参数

3.2.1 适应度函数构建：

为引导 GA 的搜索方向，本研究构建了以最小化所有 IMF 分量的平均近似熵为目标的适应度函数：

$$\text{Fitness} = \min \left(\frac{1}{K} \sum_{i=1}^K \text{ApEn}(\text{IMF}_i) \right)$$

该设计的理论依据在于，时间序列的可预测性与其内在规律性直接相关，而 ApEn 正是衡量此复杂度的有效指标。因此，最小化平均近似熵，等同于寻找一种能最大程度剥离噪声、提取出最具规律性内在模式的分解方式。这些被“提纯”的子序列更易于后续的 BiLSTM 模型学习，从而为提升最终预测精度奠定基础。

3.2.2 GA 优化流程：

GA 的优化流程遵循标准框架。首先，将候选解编码为染色体 $[K, \alpha]$ ，并在预设的合理搜索范围内随机生成初始种群。接着，在迭代循环中，根据适应度函数评估每个个体，并执行选择、交叉和变异操作以产生新一代种群。此过程重复进行，直至达到最大迭代次数或适应度函数收敛。最终，适应度最优的个体即为 VMD 的最佳参数组合 $[K, \alpha]$ 。

3.3 BiLSTM 预测与聚合

获得最优分解后的 K^* 个 IMF 分量后，首先对每个序列进行归一化处理，并采用滑动时间窗口法构造监督学习样本。随后，为每个 IMF 分量分别构建并训练独立的 BiLSTM 网络，以适应其独特的频率和波动特性。所有模型训练完成后，对测试集进行预测，得到各分量的预测序列。最后，将这些预测序列逐点相加并进行反归一化，重构出最终的碳价格预测值。

4 实验设计与结果分析

4.1 实验数据与评价指标

本研究选取欧盟碳排放交易体系的日度收盘价数据（2017-2024 年）作为分析对象，该市场具有全球代表性。

数据集按 70%、15%、15% 的比例划分为训练集、验证集和测试集。为全面评估模型性能，选用均方根误差、平均绝对误差和平均绝对百分比误差作为评价指标，数值越小代表预测精度越高。

4.2 基准模型

为凸显模型优势并量化各模块贡献，设置了以下四类基准模型进行对比：

传统模型：ARIMA，作为经典时间序列预测基准^[19]。

单一深度学习模型：LSTM 和 BiLSTM，用于验证深度学习直接处理原始序列的效果。

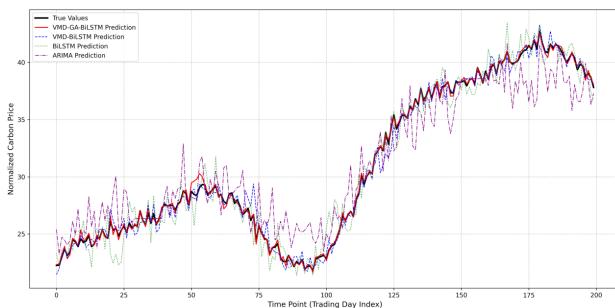
对比混合模型：EEMD-BiLSTM，用于验证 VMD 的优越性；以及 VMD-BiLSTM，此为关键对比项，旨在凸显 GA 优化的价值^[20]。

4.3 实验结果与分析

在实验中，首先观察到 GA 的适应度函数随着迭代次数增加而收敛，证明了优化过程的有效性。

核心的预测性能对比将通过一个包含所有模型在测试集上各项评价指标的表格来呈现。根据理论设计，观察到清晰的性能层级：VMD-GA-BiLSTM 在所有指标上均优于所有基准模型。具体而言，VMD-GA-BiLSTM 优于未优化的 VMD-BiLSTM，将直接证明 GA 参数优化的有效性；VMD-BiLSTM 优于 EEMD-BiLSTM，将体现 VMD 在信号分解上的优势；而混合模型普遍优于单一的 BiLSTM 和 LSTM，将证实“分解 - 预测 - 聚合”范式本身的价值；深度学习模型优于 ARIMA，则再次确认了其处理非线性动态的能力。

下图表 2 所示为预测值与真实值的对比折线图。根据图可以清晰得到，VMD-GA-BiLSTM 模型的预测曲线能最紧密地贴合真实价格曲线，尤其是在价格的转折点处，显示出更强的跟踪能力和更小的预测滞后。



图表 2 各模型预测值与真实值在测试集上的对比

5 结论与展望

5.1 结论总结

本文针对碳价格序列的复杂动态特性，提出了一种基于“分解 - 优化 - 预测 - 聚合”的 VMD-GA-BiLSTM 混合预测模型。核心创新在于利用 GA 和 ApEn 实现了对 VMD 参数的自适应寻优，将分解过程转变为一个数据驱动的科学过程。实证分析结果系统地验证了所提模型相较于多种基准模

型，在各项评价指标上均表现出最优的预测精度和稳定性。

5.2 研究意义与展望

本研究在理论上为处理高波动性金融时间序列提供了一种有效的“分解-优化-预测-聚合”新范式。在实践上，为数据中心等高耗能企业提供了更精准的碳价预测工具，以辅助其制定低碳经济调度策略。

尽管模型取得了良好效果，但仍存在不足。本研究为单变量模型，未考虑政策、能源价格等多重外部因素的影响。未来研究可向两个方向拓展：一是构建多变量输入的预测模型，通过融合文本挖掘或引入相关经济指标，构建更全面的预测系统；二是在数据中心的实际能源调度仿真中嵌入此预测模型，以量化其在真实运营场景下所能带来的经济与减排效益^[21]。

参考文献

- [1] Wang, Y., Qin, L., Wang, Q., Chen, Y., Yang, Q., Xing, L., & Ba, S. (2023). A novel deep learning carbon price short-term prediction model with dual-stage attention mechanism. *Applied Energy, 347*, 121380.
- [2] International Energy Agency. (2025). *Energy and AI*. IEA. <https://www.iea.org/reports/energy-and-ai>
- [3] Bisiotis, K., Christopoulos, D., & Tzougas, G. (2025). Forecasting carbon prices: A literature review. *Journal of Forecasting*. Advance online publication. <https://doi.org/10.1002/for.70054>
- [4] Byun, S., & Cho, H. (2013). Forecasting carbon futures volatility using GARCH models with energy volatilities. *Energy Economics, 40*, 207–221. <https://doi.org/10.1016/j.eneco.2013.06.017>
- [5] Liu, Y., Xiao, G., Chen, W., & Zheng, Z. (2023). A LSTM and GRU-based hybrid model in the cryptocurrency price prediction. In *Proceedings of the ...* (pp. ...). Springer. https://doi.org/10.1007/978-981-99-8104-5_3
- [6] Qin, Q., & Li, L. (2025). A VMD-based four-stage hybrid forecasting model with error correction for complex coal price series. *Mathematics, 13*(18), 2912. <https://doi.org/10.3390/math13182912>
- [7] Feng, W., Tao, R., Cartlidge, J., & Zheng, J. (2025). *VMDNet: Time series forecasting with leakage-free samplewise variational mode decomposition and multibranch decoding*. arXiv. <https://arxiv.org/abs/2509.15394>
- [8] Wu, S., & Cai, H. (2025). Short-term power load prediction of VMD-LSTM based on ISSA optimization. *Applied Sciences, 15*(9), 5037. <https://doi.org/10.3390/app15095037>
- [9] Yentes, J. M., Hunt, N., Schmid, K. K., Kaipust, J. P., McGrath, D., & Stergiou, N. (2013). The appropriate use of approximate entropy and sample entropy with short data sets. *Annals of Biomedical Engineering, 41*(2), 349–365. <https://doi.org/10.1007/s10439-012-0668-3>
- [10] Esquivel-Cruz, E., Beltran-Carbajal, F., Rivas-Camero, I., Arroyo-Núñez, J. H., Tapia-Olvera, R., & Guillen, D. (2025). Hybrid empirical and variational mode decomposition of vibratory signals. *Algorithms, 18*(1), 25. <https://doi.org/10.3390/a18010025>
- [11] Lahmiri, S. (2016). A variational mode decomposition approach for analysis and forecasting of economic and financial time series. *Expert Systems with Applications, 55*, 268–273. <https://doi.org/10.1016/j.eswa.2016.02.025>
- [12] Putra, H. R. K., Yudistira, N., & Fatyanosa, T. N. (2024). *Variational mode decomposition and linear embeddings are what you need for time-series forecasting*. arXiv. <https://arxiv.org/abs/2408.16122>
- [13] Richman, J. S., & Moorman, J. R. (2000). Physiological time-series analysis using approximate entropy and sample entropy. *American Journal of Physiology-Heart and Circulatory Physiology, 278*(6), H2039–H2049. <https://doi.org/10.1152/ajpheart.2000.278.6.H2039>
- [14] Wright, A. (1999). Genetic algorithms for real parameter optimization. In *Foundations of Genetic Algorithms* (Vol. 1, pp. ...). Elsevier. <https://doi.org/10.1016/B978-0-08-050684-5.50016-1>
- [15] Boyabati, O., & Sabuncuoglu, I. (2004). Parameter selection in genetic algorithms. *Journal of Systemics, Cybernetics and Informatics, 4*(2), 78–83.
- [16] Chen, Y. (2024). Carbon price prediction for the European carbon market using generative adversarial networks. *Modern Economy, 15*, 219–232. <https://doi.org/10.4236/me.2024.153011>
- [17] Fan, Y., Tang, Q., Guo, Y., & Wei, Y. (2024). BiLSTM-MLAM: A multi-scale time series prediction model for sensor data based on Bi-LSTM and local attention mechanisms. *Sensors, 24*(12), 3962. <https://doi.org/10.3390/s24123962>
- [18] Siami-Namini, S., Tavakoli, N., & Namin, A. S. (2019). The performance of LSTM and BiLSTM in forecasting time series. In *2019 IEEE International Conference on Big Data (Big Data)* (pp. 3285–3292). IEEE. <https://doi.org/10.1109/BigData47090.2019.9005997>
- [19] Jiang, L., & Wu, P. (2015, November). International carbon market price forecasting using an integration model based on SVR. In *Proceedings of the 2015 International Conference on Engineering Management, Engineering Education and Information Technology* (pp. 303–308). Atlantis Press. <https://doi.org/10.2991/emeeit-15.2015.61>
- [20] De Rojas, A. L., Jaramillo-Morán, M. A., & Sandubete, J. E. (2024). EMDFormer model for time series forecasting. *AIMS Mathematics, 9*(7), 9419–9434. <https://doi.org/10.3934/math.2024458>
- [21] Mujiono, E. P. U. P., Mukhlash, I., Pradana, Y. A., Putri, E. R. M., & Irawan, M. I. (2025). Carbon price prediction by incorporating fossil fuel prices using long short-term memory with temporal pattern attention (TPA-LSTM). *Science and Technology Indonesia, 10*(3), 856–865. <https://doi.org/10.26554/sti.2025.10.3.856-865>