

# 基于 MIC-EEMD-改进 Informer 的含高比例清洁 能源与储能的电力市场短期电价多步预测

许越<sup>1</sup>, 李强<sup>2</sup>, 崔晖<sup>1</sup>

(1. 电力调度自动化技术研究与系统评价北京市重点实验室(中国电力科学研究院有限公司),  
北京市 海淀区 100192;

2. 电网安全全国重点实验室(中国电力科学研究院有限公司), 北京市 海淀区 100192)

## Short-term Multi-step Price Prediction for the Electricity Market With a High Proportion of Clean Energy and Energy Storage Based on MIC-EEMD-improved Informer

XU Yue<sup>1</sup>, LI Qiang<sup>2</sup>, CUI Hui<sup>1</sup>

(1. Key Laboratory of Research and System Evaluation of Power Dispatching Automation Technology  
(China Electric Power Research Institute), Haidian District, Beijing 100192, China;

2. National Key Laboratory of Power Grid Safety (China Electric Power Research Institute), Haidian District, Beijing 100192, China)

**ABSTRACT:** The emergence of the electricity spot market underscores the critical role of short-term electricity price forecasting for decision-makers in various market sectors. The increasing integration of clean energy and energy storage presents substantial challenges for short-term price predictions. This paper introduces a multi-step short-term electricity price forecasting model using the Maximum Information Coefficient (MIC), Ensemble Empirical Mode Decomposition (EEMD), and an enhanced Informer approach. Initially, MIC is applied to identify factors highly correlated with electricity prices, serving as the model's primary input sequences. These original sequences undergo EEMD decomposition, resulting in multiple Intrinsic Mode Functions (IMF) and a residual component. These components are then input separately into the improved Informer model to generate multi-step forecasts for the upcoming day, up to the 24th hour. The forecasted results undergo subsequent filtering. The filtered sequence forecast results are combined to produce the final prediction. Validation with data from the Spanish electricity market confirms that this model significantly improves the accuracy of short-term multi-step electricity price forecasting.

**KEY WORDS:** high proportion of clean energy; short-term multi-step electricity price prediction; maximum information coefficient; ensemble empirical mode decomposition; enhanced

Informer

**摘要:** 随着电力现货市场的开展, 短期电价预测对于各市场主体的决策有着重要意义, 而高比例清洁能源与储能的不断接入给短期电价预测带来很大挑战。提出一种基于最大信息系数法(maximum information coefficient, MIC)、集成经验模态分解(ensemble empirical mode decomposition, EEMD)和改进 Informer 的短期电价多步预测模型。首先, 采用 MIC 分析出与电价相关性较高的几类因素作为模型原始输入序列; 然后, 将上述原始序列进行 EEMD 分解后得到多条本征模函数(intrinsic mode function, IMF)和一个残余项后输入改进 Informer 分别得到翌日 24 点多步预测结果, 再对预测结果进行滤波; 最后, 将滤波后序列的预测结果叠加得到最终的预测值。以西班牙电力市场数据进行验证, 实验结果证明该模型可以有效提高电力市场短期电价多步预测精度。

**关键词:** 高比例清洁能源; 短期电价多步预测; 最大信息系数; 集成经验模态分解; 改进 Informer

**DOI:** 10.13335/j.1000-3673.pst.2023.1671

## 0 引言

在电力市场<sup>[1]</sup>中, 电价作为经济杠杆有着举足轻重的地位, 电价的演化过程综合反应了市场中各类因素的变化趋势。因此, 电价预测自电力市场发展以来便一直是一个亟待研究和解决的重要课题。随着电力现货市场<sup>[2]</sup>的不断开展, 短期电价预测<sup>[3]</sup>更是重中之重。

自 1997 年国内外开始对电价预测方法研究以来, 主要分为三大类预测方法。第一类为仿真方法, 学者们通过仿真建立系统的准确模型并对模型进

基金项目: 中国电力科学研究院有限公司研究开发项目“电力现货市场通用出清与数据支撑关键技术”(52420022000R)。

Project Supported by Research and Development Project of China Electric Power Research Institute “Key Technologies of General Clearing and Data Support in Power Spot Market” (52420022000R).

行求解以进行电价预测，主要有 GE Power Systems Energy Consulting 开发的市场评估和投资组合策略算法<sup>[4]</sup>和 LCG Consulting 开发的 UPLAN<sup>[5]</sup>软件，但仿真方法需要系统详细运行数据且计算成本高，实用性较低；第二类是统计学方法，主要有差分自回归移动平均<sup>[6]</sup>(auto regressive integrated moving average, ARIMA)模型和广义自回归条件异方差(generalized auto regressive conditiona heteroskedastic, GARCH)模型<sup>[7]</sup>等，这一类方法由于忽略了影响电价的因素如负荷等，因此预测精度一般；第三类为人工智能领域的机器学习方法，其中细分为两类：一类是传统机器学习算法如支持向量机回归<sup>[8]</sup>(support vector regression, SVR)、随机森林<sup>[9]</sup>(random forest, RF)等。另一类是近些年来被广泛采用的深度学习算法，主要指的是深度神经网络。反向传播神经网络<sup>[10]</sup>(back propagation neural network, BPNN)是最早期用于短期电价预测的深度神经网络，其将影响电价的多因素作为模型的输入一定程度上提升了预测精度，如文献[11]考虑了市场力取得了不错的效果。但 BP 神经网络忽略了电价及其影响因素这些输入的时序相关性。

循环神经网络<sup>[12]</sup>(recurrent neural network, RNN)在电价预测时考虑了输入时序相关性，弊端是 RNN 的循环结构会使得当输入序列较长时出现梯度爆炸或梯度消失现象。为解决 RNN 的上述问题，一些 RNN 的变体如长短时记忆网络(long short term memory, LSTM)和门控循环单元(gated recurrent unit, GRU)通过引入门机制来控制信息的流动和遗忘。但 RNN 及其变体对输入序列是平等对待的，不能很好的关注输入序列中的关键信息，文献[13]和文献[14]分别在 LSTM 和 GRU 中引入注意力机制(attention, ATT)，通过计算注意力权重来关注输入序列中的重要部分，从而更有效的处理长序列数据。

电力现货市场中需要对短期电价进行多步预测。文献[15]利用全连接层建立的多输出预测模型虽解决了过去多步预测中常存在的建模时间长和累积误差的问题，但没有考虑输出电价序列之间的时序相关性，而基于编码器-解码器架构的 Transformer 模型<sup>[16]</sup>由于在编码器和解码器的输入端都加入位置编码，可以很好的解决这一问题，但 Transformer 模型较为复杂，自注意力机制需使用大量的计算资源与内存空间。Informer 模型<sup>[17]</sup>在 Transformer 架构的基础上进行了稀疏化、蒸馏、生成式解码等操作，在提升计算精度的同时降低模型

复杂度。同时，为了让 Informer 模型能更好的提取电价周期性、季节性并受节假日影响的特征，需对模型作进一步改进。

电价序列具有强烈的波动性，是典型的非平稳数据。须通过分解算法来对原始输入序列进行分解以提升预测精度。经验模态分解(empirical mode decomposition, EMD)<sup>[18]</sup>虽避免了小波包分解(wavelet packet decomposition, WPD)<sup>[19]</sup>需要预先设定基函数的弊端，但对于电价这一类噪声较多的信号分解容易产生过拟合以及模态混叠等问题，会对电价预测的精度产生一定的影响。EEMD<sup>[20]</sup>作为 EMD 的改进和扩展，可以有效解决这一问题。为取得更好的预测效果，还需对 EEMD 分解后的子序列进行进一步的筛选。

电力市场中的短期电价受历史电价、负荷等多种因素影响，需要考虑多个输入特征来预测短期电价。但众多的输入变量既会给数据带来过多噪声也会增加模型的时间与存储复杂度。因此须对影响电价的因素作相关性分析。常用的相关性分析的办法主要有皮尔逊相关系数法、斯皮尔曼相关系数法、K-最邻近距离等。与上述方法相比，基于互信息理论的最大信息系数法<sup>[21]</sup>(maximum information coefficient, MIC)在衡量两个变量之间的相关性时具有更广的适用范围、更低的计算复杂度以及更高的鲁棒性。

综上所述，本文首次提出了一种基于 MIC-EEMD-改进 Informer 的短期电价多步预测模型。首先用 MIC 筛选出与短期电价相关性较大的特征，其中创新性的将储能列入分析范围；其次采用 EEMD 对筛选出来的原始序列组合进行分解组成子序列组合并剔除预测效果不好的子序列；同时对原始 Informer 模型进行改进，增加了全局时间戳以更好捕捉电价的时序特征。特别地，Informer 本身还具有多标签输出的特点，在进行电价预测的同时可同步进行负荷预测。最后，采用西班牙电力市场数据进行算例分析表明本文采用的预测方法有效提升了预测精度。

## 1 电价模型输入特征选择

### 1.1 最大信息系数 MIC

MIC 常在机器学习中用作特征选择，具有非参数性、自适应性、尺度不变性和一致性的优势。对于电价预测来说，电价可能受多种因素影响，不同地区电价变化特点与影响因素也会有区别。因此对于具体的数据集，需要在输入模型前对可能的影响

因素作 MIC 相关性分析,以筛选出对电价影响较大的序列,提升模型的预测效果。

## 1.2 电价相关性分析

本文使用的数据集来源于西班牙电力市场 2018 年 1 月 1 日—2018 年 12 月 31 日共 365 天实际运行数据,颗粒度为 1h。主要包含电价、负荷、煤炭发电、石油发电、天然气发电、水电、核电、风光发电、气候、储能等一系列数据。为了简化输入,需要根据发电特点将多种发电进行合并。

在完全竞争的电力市场中,发电侧基于成本报价,因此发电成本很大程度影响了电力现货市场的出清电价。发电成本主要由容量成本和电量成本组成,其中容量成本主要包含发电厂投资等固定成本而电量成本主要指的是燃料成本。传统火电如煤、石油、天然气发电受燃料成本变动影响较大,而核电、水电、风光这一类清洁能源主要成本来源于固定的投资成本,变动较小。基于上述考虑,本文将发电侧划分为两类:一类是火电(煤、石油、天然气),另一类是清洁能源发电(水电、核电、风、光),对每一日 24 点电价分别与负荷、火电、清洁能源、储能、气候计算 MIC 值,计算结果分别如图 1 和图 2 所示。

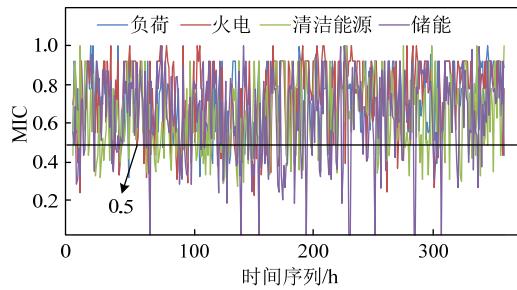


图 1 电价与负荷、火电、清洁能源、储能的 MIC

Fig. 1 Maximum information coefficients of electricity price with load, thermal power, clean energy, and energy storage

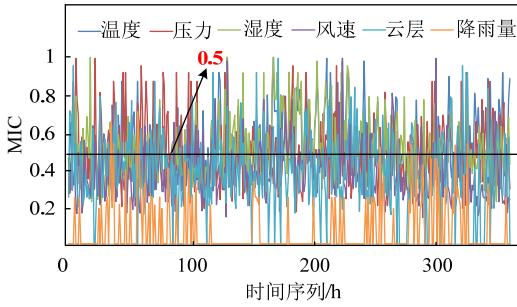


图 2 电价与气候的 MIC

Fig. 2 Maximum information coefficients of electricity price with climate

通过图 1 和图 2 对比可知,在选取的 365 天里,绝大多数天里电价与负荷、火电、清洁能源发电、储能的 MIC>0.6,即具有强相关性;而在绝大多数天里

电价与气候的 MIC<0.6,具有弱相关性。同时发现,相较于气候数据中的其他量,温度与电价的相关性显得较高,在 365 天里有 112 天其 MIC>0.6,探究其本质是因为温度与负荷具有强相关性,经实验分析,在 365 天中温度与负荷有 202 天的 MIC 值大于 0.6,因此,在将负荷作为电价预测输入变量时既考虑了负荷本身对电价的影响,也考虑了一部分温度对电价的影响。

综上所述,选择负荷、火电、清洁能源发电、储能作为电价预测模型的一部分特征输入,而由于电价的周期性变化特点使得电价历史数据本身也可以作为电价预测模型的特征输入。

## 2 集合经验模态分解

### 2.1 原理介绍

EEMD 通过对原始信号引入随机信号,并多次进行 EMD 分解,来减少噪声的影响,从而提高分解的稳定可靠性。EEMD 步骤如附录 A 所示。

### 2.2 模型输入的 EEMD 分解

受电力市场各方面不确定因素的影响,电价序列正是典型的非线性、非平稳的数据,因此在输入预测模型之前对其进行平稳化处理、自适应的提取出几个具有周期性的 IMF 分量很有必要。

本文将电价、负荷、火力发电、清洁能源发电、储能原始序列分别进行 EEMD 分解,形成  $K$  条 EEMD 序列组合输入后续模块。电价对应的 EEMD 序列如图 3 所示。

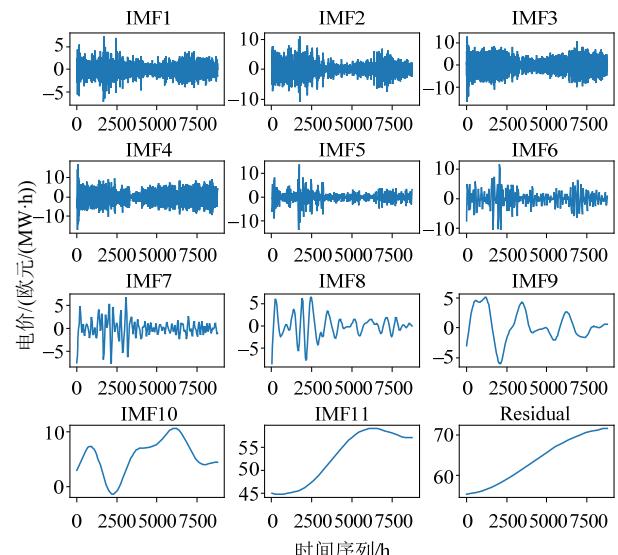


图 3 短期电价的 EEMD 序列

Fig. 3 EEMD Sequence of Short-Term Electricity Prices

由图 3 可知,根据 EEMD 本身的分解规则,电价原始序列被分为 11 个 IMF 分量和 1 个残余项。即  $K$  值取 12,但这 11 个 IMF 分量并不都能很好的

提取出电价的周期性特征, 需要对其进行一定的滤波处理, 仅筛选出周期性趋势较好的几个 IMF 分量, 而丢弃剩余的 IMF 分量。筛选的原则是分别将 11 个 IMF 组合输入电价预测主模型, 根据预测效果来观察哪些 IMF 分量很好的提取到了电价变化特征, 再加上残余项形成最终的  $K$  条序列。

### 3 改进的 Informer 模型

#### 3.1 模型整体架构

自然语言处理领域盛行的 transformer 模型由于基于编码器-解码器架构, 可以很好的处理序列到序列的预测问题, 而电价预测问题也属于这一类问题。但传统 transformer 存在架构结构复杂、自注意力机制计算量大、多个自注意力块冗余、逐步输出速度慢的问题, Informer 利用稀疏化机制、蒸馏机制以及生成式解码器大大提高了预测的速度与精度, 更加符合电力市场中电价预测的要求。同时, 为使得 Informer 模型更适合电价这一领域的预测, 本文增加全局时间戳对 Informer 加以改进, 改进后得 Informer 可以很好捕捉电价在天、周、季节等周期的变化趋势。

改进的 Informer 模型总体架构如图 4 所示。

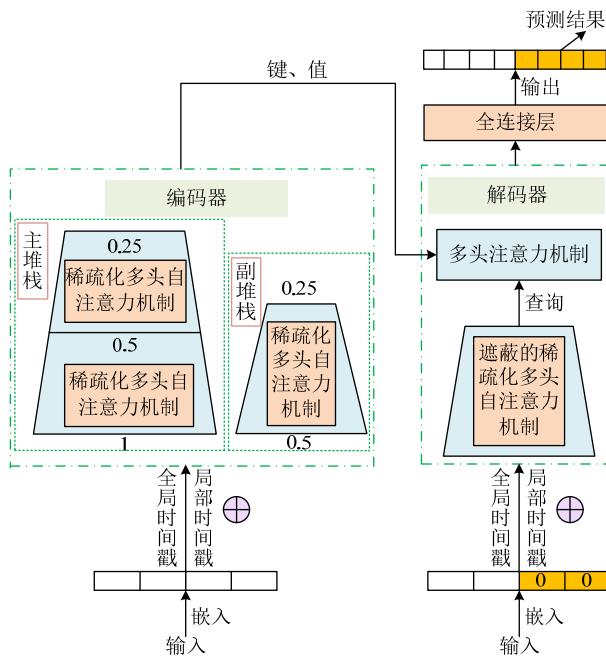


Fig. 4 Overall architecture of improved Informer

#### 3.2 改进的时间戳

RNN 及其一系列变形均通过自身循环结构捕捉时间序列模式, 而基于 Transformer 架构的 Informer 模型必须借助时间戳作为位置信息编码。

##### 3.2.1 局部时间戳

在原始的 Informer 架构中, 每次输入为一个局

部的时间窗口, 通过固定位置嵌入(embedding)保存局部上下文信息, 即为局部时间戳  $P_E$  如附录 B 所示。

##### 3.2.2 全局时间戳

由于电价具有季节性、周期性等特征, 同时电价受节假日及重大事件的影响, 参考负荷分类预测思想, 本文对 Informer 时间戳加以改进, 共分为以下 3 类, 共 4 条时间戳:

1) 为了识别一天内电价波动时间特征, 定义时-日时间戳  $P^1$  并将其标准化后范围限制在 -0.5~0.5。

$$P^1 = \frac{h}{23} - 0.5 \quad (1)$$

式中  $h$  为一天中的小时编号, 取值为 0~23。

2) 为了识别周内与周末的电价时间特征, 定义日-周时间戳  $P^2$  并将其标准化后范围限制在 -0.5~0.5。

$$P^2 = \frac{d}{6} - 0.5 \quad (2)$$

式中  $d$  为一周中的日编号, 取值为 0~6。

3) 为了识别电价季节性变化趋势, 定义日-年、月-年时间戳  $P^3$ 、 $P^4$ , 并将它们标准化后数值限制在 -0.5~0.5。

$$P^3 = \frac{D-1}{364} - 0.5 \quad (3)$$

$$P^4 = \frac{m-1}{11} - 0.5 \quad (4)$$

式中:  $D$  为一年中的日编号, 取值为 1—365;  $m$  为一年中的月编号, 取值为 1—12。

##### 3.2.3 最终输入

为了保证最终的维度一致, 用一维卷积将原始输入  $\mathbf{x}_i^t$  也映射到  $d_{\text{model}}$  维变成  $\mathbf{u}_i^t$ , 再将其与局部时间戳和全局时间戳相加后得到最终输入:

$$\mathbf{x}_{\text{feed}[i]}^t = \alpha \mathbf{u}_i^t + \mathbf{P}_{E[L_x \times (t-1)+i]} + \sum_{m=1}^4 \mathbf{p}_{[L_x \times (t-1)+i]}^m \quad (5)$$

式中:  $i \in \{1, \dots, L_x\}$ ;  $t$  表示输入时间序列序号;  $\alpha$  为平衡因子, 当输入已标准化时值为 1;  $m$  表示各个全局时间戳编号。

#### 3.3 稀疏化多头自注意力机制

##### 3.3.1 多头自注意力机制

多头自注意力机制可以通过不同注意力头很好的捕捉到序列内各种范围的依赖关系(如长距离依赖), 同时多头自注意力机制也可以并行计算, 加快模型训练速度。其中, 每个注意力头  $\mathbf{h}_i$  ( $i=1, \dots, h$ ) 的计算方法如下:

$$\mathbf{h}_i = f(\mathbf{W}_i^Q \mathbf{X}, \mathbf{W}_i^K \mathbf{X}, \mathbf{W}_i^V \mathbf{X}) = f(\mathbf{Q}_i, \mathbf{K}_i, \mathbf{V}_i) \quad (6)$$

式中,  $\mathbf{W}_i^Q$ 、 $\mathbf{W}_i^K$ 、 $\mathbf{W}_i^V$  分别为注意力头  $i$  的查询、键、值对应的线性变换矩阵;  $\mathbf{X}$  为原始输入序列;  $\mathbf{Q}_i$ 、 $\mathbf{K}_i$ 、 $\mathbf{V}_i$  分别为经线性变换后得到的查询、键、值矩阵。 $f$  采用缩放点积注意力, 在无关向量长度的情况下计算向量的相关性。

多头注意力再经过一个线性变换矩阵拼接得

$$\mathbf{W}_0 \begin{bmatrix} \mathbf{h}_1 \\ \vdots \\ \mathbf{h}_h \end{bmatrix} \quad (7)$$

直观的计算过程如图 5 所示, 为了简化介绍过程, 选取两个注意力头的情况进行分析。

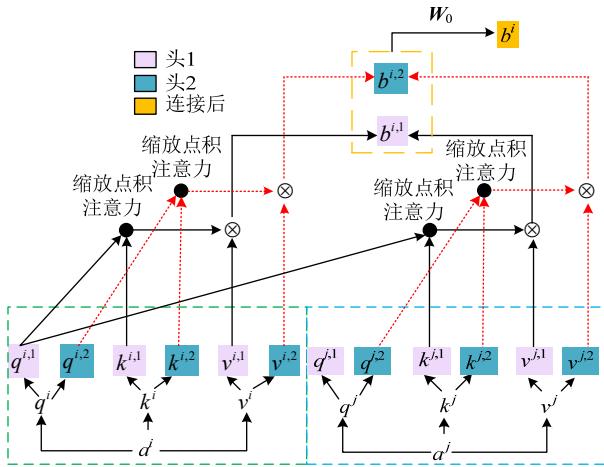


图 5 多头自注意力机制

Fig. 5 Multi-head self-attention mechanism

Informer 解决了 Transformer 在算多头注意力时每个头优化策略相同的弊端, 原理是在 Informer 的不同头中, 虽然每一个查询  $\mathbf{q}$  选取的随机  $j$  个键  $\mathbf{k}$  相同, 但每一层 self-attention 需要事先对  $\mathbf{q}$ 、 $\mathbf{k}$ 、 $\mathbf{v}$  进行线性变换, 使得每个  $\mathbf{q}$  和  $\mathbf{k}$  对应的具体向量不同从而导致  $\mathbf{q}$  的  $\overline{M}(\mathbf{q}_i, \mathbf{K})$  分数不同, 因此选取的前  $M$  个  $\mathbf{q}$  也不同, 相当于采取了不同的优化策略, 可以更好地捕捉序列在不同层面的特征。

### 3.3.2 稀疏自注意力机制

有文献发现在对自注意力机制进行定性评估的时候, 注意力得分  $Attention(\mathbf{Q}, \mathbf{K}, \mathbf{V})$  呈长尾分布, 因此对注意力得分具有主要贡献的是少部分点积对。将第  $i$  个查询  $\mathbf{q}$  与所有键  $\mathbf{k}$  的缩放点积注意力定义为概率  $p(\mathbf{k}_j|\mathbf{q}_i)$ , 若某个查询  $\mathbf{q}$  对应的概率与均匀分布差距较大, 则更有可能出现较大的点积对, 这部分是长尾头部的点积对, 故该查询  $\mathbf{q}$  不该被舍弃; 若某个查询  $\mathbf{q}$  与所有键  $\mathbf{k}$  的缩放点积注意力近似呈均匀分布  $q(\mathbf{k}_j|\mathbf{q}_i)$ , 则该查询  $\mathbf{q}$  没有什么意义, 应该被舍弃。用 KL 散度来衡量  $p$  与  $q$  的相似性, 如附录 C 所示。

为了进一步加速计算, 将每一个查询  $\mathbf{q}$  与随机  $j$  个键  $\mathbf{k}$  的注意力值当做总体概率分布, 并直接将这  $j$  个注意力值中最大的与均匀分布作差来衡量其与均匀分布的差异:

$$\overline{M}(\mathbf{q}_i, \mathbf{K}) = \max_j \left\{ \frac{\mathbf{q}_i \mathbf{k}_j^\top}{\sqrt{d}} \right\} - \frac{1}{L_x} \sum_{j=1}^{L_k} \frac{\mathbf{q}_i \mathbf{k}_j^\top}{\sqrt{d}} \quad (8)$$

根据  $\overline{M}(\mathbf{q}_i, \mathbf{K})$  选出前  $M$  个查询  $\mathbf{q}$ , 对于其他被舍弃的  $\mathbf{q}$  的位置, 直接用所有  $\mathbf{v}$  之和的均值代替。每一次迭代之后更新这  $M$  个  $\mathbf{q}$ 。

### 3.4 蒸馏机制

在图 4 编码器的主堆栈中, 包含多个注意力块, 会存在大量的冗余特征影响模型速度并占用大量的内存。Informer 通过蒸馏操作对每次经过注意力块的数据进行下采样, 因此每经过一个注意力块数据长度减少为原来的一半, 主堆栈共包含, 3 个注意力块(最后一个注意力块后不接下采样), 因此最终数据长度变为之前的四分之一。下采样过程为

$$\mathbf{X}_{j+1}^t = MaxPool(ELU(Conv1d([\mathbf{X}_j^t]_{AB}))) \quad (9)$$

式中:  $[\cdot]_{AB}$  表示注意力块, 其中包含了稀疏化多头自注意力机制;  $Conv1d(\cdot)$  表示一维卷积(使用  $3 \times 3$  卷积核, 填充为 2);  $ELU$  是激活函数;  $MaxPool$  是最大池化层。

为了增强模型的鲁棒性, Informer 还设计了堆栈副本, 副本的输入数据长度减半, 为了保证最终输出长度与主堆栈同为蒸馏前的四分之一, 减少一次蒸馏过程, 最终将主副堆栈输出拼接得到最终编码器的隐藏表示。

### 3.5 生成式解码器

在用传统的 Transformer 架构进行预测时, 编码器将输入时间序列生成一系列最终的隐藏表示, 将其与开始标记(start token)一并输入解码器后逐步生成要预测的目标时间序列, 但逐步生成的过程不仅浪费大量时间, 还会因为误差的不断累积使得模型精度下降。Informer 模型采用生成式解码器如图 4 中所示, 其输入为

$$\mathbf{X}_{de}^t = Concat(\mathbf{X}_{token}^t, \mathbf{X}_0^t) \quad (10)$$

式中:  $\mathbf{X}_{token}^t$  为目标序列之前部分已知序列;  $\mathbf{X}_0^t$  为要一次性输出的目标序列, 初始值设为 0;  $Concat$  表示将两个向量进行拼接。

解码器在进行预测任务时需要对稀疏多头自注意力机制进行遮蔽(mask)操作, 这是为了避免预测当前位置时关注未来的位置, 具体操作方法是将 mask 的点积值设置为  $-\infty$ 。

这种生成式解码的办法一定程度上与过去负荷预测实践中常用的趋势外推法相似, 可以很好利用被预测数据本身的惯性, 因此在电价预测领域也具有一定的科学性。

#### 4 MIC-EEMD-改进 Informer

针对含高比例清洁能源和储能的电力市场短期电价多步预测问题, 本文提出了基于最大信息系数 MIC 相关性分析、集合经验模态分解以及改进的 Informer 的电价多步预测模型。模型基本框架如图 6 所示。首先对电力市场中的电价、负荷、火电、清洁能源、储能、气候历史数据进行 MIC 相关性分析, 筛除气候这一与电价相关性较小的特征; 然后将剩余特征序列分别进行 EEMD 分解, 形成若干个 IMF 组合和 1 个残余项组合; 再将这些组合分别输入改进的 Informer 预测模型得到多条电价预测分序列结果后作滤波处理, 筛选出预测效果较好的前( $K-1$ )个 IMF 序列组合, 最后, 将残余项预测结果与这( $K-1$ )个 IMF 共  $K$  条预测结果叠加即得到最终的电价预测结果, 最终模型输出为翌日 24 点电价。

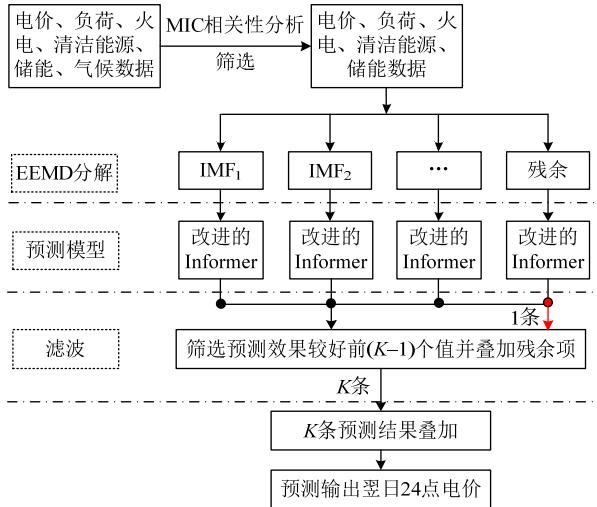


图 6 电价预测模型总框架

Fig. 6 General framework of the electricity price prediction model

#### 5 算例分析

本文仿真实验在 Python3.7 版本和 Pytorch1.9.0 运行环境下进行。

##### 5.1 数据准备与预处理

本文仿真数据取自西班牙电力市场, 由于西班牙电力市场中多种发电方式并存, 电价变化情况较为复杂, 因此更适合作为电价预测重点研究对象并将预测算法推广到其他电力市场。截止至 2018 年底, 西班牙火力发电量占比为 35.8%, 清洁能源占比 60.2%(其中核能 21.4%、风电 19.8%、水能

15.4%), 还包含部分储能。

选取西班牙电力市场 2018 年 1 月 1 日—2018 年 12 月 31 日的数据进行建模仿真, 每日取 24 个点, 每个点包含电价、负荷、火电、清洁能源发电、储能 5 项信息。选取数据集前 70% 作为训练集对模型参数进行训练, 再选取数据集 10% 作为验证集以对模型中的超参数进行调整, 最后剩余 20% 作为测试集以检验模型泛化能力及性能。

为消除不同数据间量纲的影响, 对原始数据进行最大最小归一化处理, 公式为

$$\bar{x} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (11)$$

式中:  $\bar{x}$  表示归一化后的值;  $x$  表示归一化前的值;  $x_{\max}$  和  $x_{\min}$  分别表示数据中的最大值与最小值。

##### 5.2 预测误差评价指标

为评价模型预测效果, 本文采用平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean square error, RMSE) 和平均绝对百分比误差 (mean absolute percentage error, MAPE) 这三大类常用评价指标, 具体定义式见附录 D。

##### 5.3 EEMD 效果验证及最优 EEMD 选择

原始输入序列电价、负荷、火电、清洁能源、储能能在进行 EEMD 分解后, 共形成 11 个 IMF 组合和一个残余项组合共 12 条序列。将这个 12 条序列输入改进的 Informer 模型, 12 条序列的预测情况如图 7 所示。

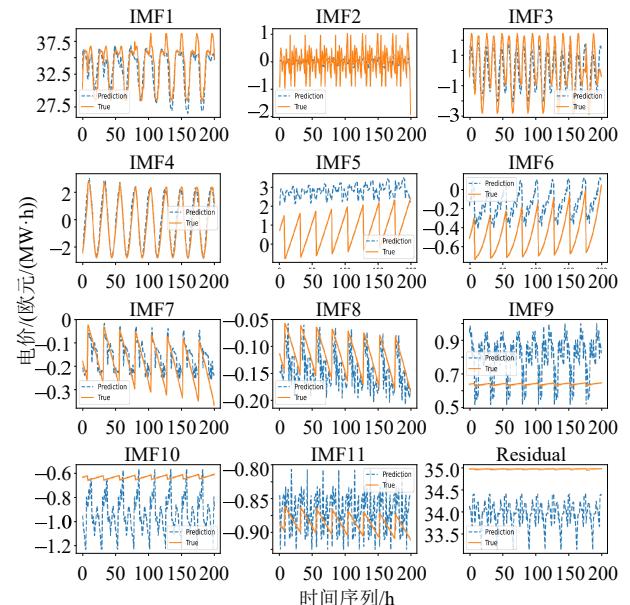


图 7 电价 EEMD 序列各预测曲线

Fig. 7 Electricity price EEMD sequence's various forecast curves

通过图 7 可以看出, 并非所有的 IMF 分量在改进 Informer 中的拟合结果都很好, 仅 IMF1、IMF3

和 IMF4 拟合结果较好，表明为了更好的适配主模型-改进 Informer 的固有特点，需对原始的 EEMD 分解作进一步优化，优化思路主要有两点：一是将表现不好的几条 IMF 预测结果简单合并；二是滤波掉这些表现不好的 IMF 预测结果，仅将剩余预测结果叠加作为最终的预测结果。

综上所述，为验证 EEMD 分解的有效性并选取最优 EEMD 分解，本文分别设计如下实验。

- 1) 实验 A：不对原始输入序列进行分解。
- 2) 实验 B0：对原始序列进行完全的 EEMD 分解，原始序列=IMF1+IMF2+…+IMF11+Residual。
- 3) 实验 B1：将 IMF2-IMF11 进行叠加后作为新的 IMF，原始序列=IMF1+IMF(新)+Residual。
- 4) 实验 B2：仅选取拟合较好的 IMF1、IMF3、IMF4，原始序列=IMF1+IMF3+IMF4+Residual。
- 5) 实验 B3：选取前 4 个 IMF 组合，原始序列=IMF1+IMF2+IMF3+IMF4+Residual。

选取测试集最后 400 个数据点结果如图 8 所示，评价指标分析如表 1 所示。

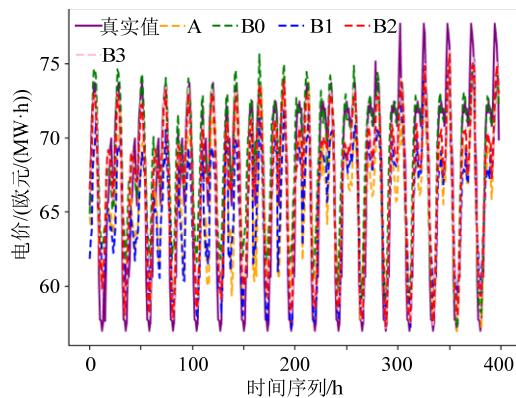


图 8 不同 EEMD 分解电价预测曲线

Fig. 8 Electricity price prediction curves under different EEMD Decomposition

表 1 不同分解模式下评价指标

Table 1 Evaluation metrics for different decomposition modes

实验	$X_{MAE}$	$X_{RMSE}$	$X_{MAPE}$
A	3.09	3.57	4.60
B0	2.12	2.87	3.36
B1	2.91	3.36	4.29
B2	1.76	2.14	2.67
B3	1.68	2.08	2.46

通过对比图 8 和表 1 可知：

- 1) 经对比实验 A 与 B0 可以发现：EEMD 分解对于提升预测效果有显著作用。
- 2) 经对比实验 B0 与 B1、B2、B3 可以发现：EEMD 完全分解后经过有效的二次滤波处理输入模型后会有更佳预测效果，而二次合并处理会使得

周期性区分不明显，让结果更差。

3) 经对比实验 B2 与 B3 可以发现：对于 EEMD 分解，一般过滤掉最后几个 IMF 分量更加科学，对后续预测结果更有利。

#### 5.4 改进的 Informer 有效性验证

为验证主模型-改进 Informer 的有效性，本文将其与过去常用的预测模型 LSTM 作对比实验，而其他的算法如 CNN-LSTM、SSA-LSTM、Attention-LSTM 等主要是在输入 LSTM 前采用了不同的预处理办法，不在本轮实验考虑范围。本文预测任务为多步预测，常用的 LSTM 的多步预测方法有如下两种。

1) LSTM1：采用滚动方式训练模型，每次输入已知 24 点电价来预测下一时间点电价。具体地，由预测时间点前 24 个时刻电价预测  $t$  时刻电价，再由前 23 个时刻+ $t$  时刻预测电价来预测  $t+1$  时刻电价，依次类推最终输出  $t, t+1, \dots, t+23$  共 24 点电价。

2) LSTM2：一次性输出未来 24 时刻电价，每次输入已知 24 点电价得到输出值后，再输入全连接层，全连接层的输出设置为 24，类似于多回归问题。

将上述两种预测方法与改进的 Informer 作对比实验，最终的预测结果如图 9 和表 2 所示。

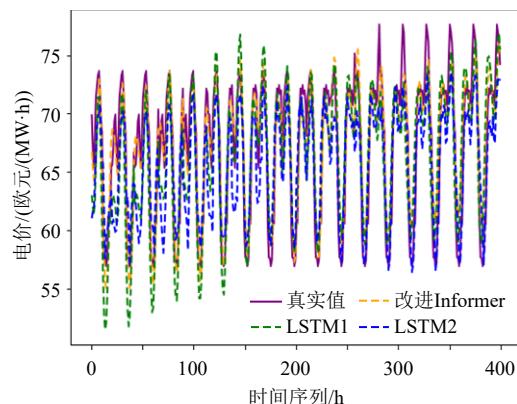


图 9 不同预测模型下电价预测曲线

Fig. 9 Electricity price prediction curves under different forecasting models

表 2 不同预测模型下评价指标

Table 2 Evaluation metrics under different forecasting models.

实验	$X_{MAE}$	$X_{RMSE}$	$X_{MAPE}$
改进 Informer	3.09	3.57	4.60
LSTM1	5.53	6.46	10.53
LSTM2	4.21	5.68	9.76

根据对比结果可知，改进的 Informer 具有最好的预测结果，LSTM2 次之，LSTM1 预测效果最差。这是由于预测底层逻辑的差距：

1) LSTM1 预测时会不断加入新的预测值导致误差累积, 如最后一步预测的输入只有第一个是真实值, 其余 23 个均是预测值。

2) LSTM2 一次性输出 24 点预测值虽然不会加入累积误差, 但由于全连接层在训练权重参数时, 没有考虑输出 24 个点之间的时序性而把他们当作独立的标签, 这会使得预测精度的下降。

3) 改进的 Informer 基于编码器-解码器的底层架构, 在编码和解码时都加入了时间戳来捕捉输入输出的时序特征, 对于由序列到序列的预测具有很好的优势。

### 5.5 国内省级电力现货市场应用前景

目前, 我国省级电力现货市场<sup>[23]</sup>建设正如火如荼的展开中。其中, 广东、山西、浙江、四川、福建、山东、甘肃、蒙西 8 个第一批试点结算试运行逐步深入, 截至目前为止已有 5 个进入长周期不间断试运行。各试点省份在电力现货价格机制方面均采取按照边际价格出清(market clearing price, MCP)而非按照报价(pay as bid, PAB)成交方式, 发电企业会趋于按照各自边际成本报价以保证交易成功, 一定程度上削弱了市场力。MCP 主要有系统边际电价(system marginal price, SMP)、分区边际电价(zonal marginal price, ZMP)、节点边际电价(locational marginal price, LMP)<sup>[23]</sup>3 种, 各省分别根据自身的源荷结构与分布、网架结构特点选取了不同的电价机制。

其中, SMP 主要用于没有网络阻塞的系统, 系统内所有成交量都按照出清点对应的价格成交, 电价不随空间变化。蒙西、四川、福建在市场初期采用系统边际电价, 但同时也会发布分时分区节点电价信息以供市场参考; ZMP 适用于电网不同区域之间可能发生输电阻塞, 而在区域内部输电阻塞发生的概率较小或情况比较轻微的情况, 甘肃由于河西能源富集、河东负荷聚集的特点在用户侧采用了 ZMP 的机制; LMP 适用于电网阻塞程度较为严重、输电能力经常受限的地区, 广东、浙江、山东、山西<sup>[24]</sup>均采用分时节点电价, 分时节点电价由系统电能价格和阻塞价格两部分构成, 系统电能价格反映系统电力供需情况, 阻塞价格反映节点所在位置的电网阻塞情况。

本文所采用的电价预测模型主要是一种时间序列的预测算法, 因此可以很好的捕捉电价背后蕴含的时序信息, 适用于 SMP 电价的预测; 而对于采用 ZMP 以及 LMP 电价的预测, 需要进一步捕捉电价的空间信息, 后续可结合图卷积神经网络作进

一步研究。

### 6 结论

本文针对含高比例清洁能源与储能的电力市场短期电价多步预测问题, 提出了一种基于 MIC-EEMD-改进的 Informer 的电价预测模型, 通过对西班牙电力市场的算例分析可知:

1) 通过 EEMD 分解, 将输入原始序列分解为一系列平稳的 IMF 分量和残余项, 并根据各 IMF 分量预测情况过滤掉最后几个噪音较多的 IMF 分量, 极大地提高了预测精度。

2) 改进的 Informer 基于编码器-解码器架构, 在编码器和解码器输入部分加入时间戳, 很好的捕捉了输入以及输出的时序相关性, 在处理多步预测问题方面有显著优势。

综上, 本文提出的电价预测方法适用于含高比例清洁能源与储能的短期电价多步预测问题, 并在国内电力现货市场<sup>[25]</sup>中有一定的应用前景。

附录见本刊网络版(<http://www.dwjs.com.cn/CN/1000-3673/current.shtml>)。

### 参考文献

- [1] 丁一, 谢开, 庞博, 等. 中国特色、全国统一的电力市场关键问题研究(1): 国外市场启示、比对与建议[J]. 电网技术, 2020, 44(7): 2401-2410.  
DING Yi, XIE Kai, PANG Bo, et al. Key issues of national unified electricity market with Chinese characteristics (1): enlightenment, comparison and suggestions from foreign countries[J]. Power System Technology, 2020, 44(7): 2401-2410(in Chinese).
- [2] 宋永华, 包铭磊, 丁一, 等. 新电改下我国电力现货市场建设关键要点综述及相关建议[J]. 中国电机工程学报, 2020, 40(10): 3172-3186.  
SONG Yonghua, BAO Minglei, DING Yi, et al. Review of Chinese electricity spot market key issues and its suggestions under the new round of Chinese power system reform[J]. Proceedings of the CSEE, 2020, 40(10): 3172-3186(in Chinese).
- [3] 张显, 王锡凡. 短期电价预测综述[J]. 电力系统自动化, 2006, 30(3): 92-101.  
ZHANG Xian, WANG Xifan. Review of the short-term electricity price forecasting[J]. Automation of Electric Power Systems, 2006, 30(3): 92-101(in Chinese).
- [4] BASTIAN J, ZHU Jinxiang, BANUNARAYANAN V, et al. Forecasting energy prices in a competitive market[J]. IEEE Computer Applications in Power, 1999, 12(3): 40-45.
- [5] DEB R, ALBERT R, HSUE L L, et al. How to incorporate volatility and risk in electricity price forecasting[J]. The Electricity Journal, 2000, 13(4): 65-75.
- [6] 周明, 严正, 倪以信, 等. 含误差预测校正的 ARIMA 电价预测新方法[J]. 中国电机工程学报, 2004, 24(12): 63-68.  
ZHOU Ming, YAN Zheng, NI Yixing, et al. A novel ARIMA approach on electricity price forecasting with the improvement of predicted error[J]. Proceedings of the CSEE, 2004, 24(12): 63-68(in Chinese).

- [7] GARCIA R C, CONTRERAS J, VAN AKKEREN M, et al. A GARCH forecasting model to predict day-ahead electricity prices[J]. IEEE Transactions on Power Systems, 2005, 20(2): 867-874.
- [8] 牛东晓, 刘达, 邢棉, 等. 基于自组织映射支持向量机的日前电价预测[J]. 电网技术, 2007, 31(18): 15-18, 22.  
NIU Dongxiao, LIU Da, XING Mian, et al. Day-ahead electricity price forecasting using support vector machines based on self-organizing map[J]. Power System Technology, 2007, 31(18): 15-18, 22(in Chinese).
- [9] 魏勤, 陈仕军, 黄炜斌, 等. 利用随机森林回归的现货市场出清价格预测方法[J]. 中国电机工程学报, 2021, 41(4): 1360-1367.  
WEI Qin, CHEN Shijun, HUANG Weibin, et al. Forecasting method of clearing price in spot market by random forest regression[J]. Proceedings of the CSEE, 2021, 41(4): 1360-1367(in Chinese).
- [10] GUO J J, LUH P B. Improving market clearing price prediction by using a committee machine of neural networks[J]. IEEE Transactions on Power Systems, 2004, 19(4): 1867-1876.
- [11] 胡朝阳, 孙维真, 汪震, 等. 考虑市场力的短、中、长期电价预测[J]. 电力系统自动化, 2003, 27(22): 16-22.  
HU Zhaoyang, SUN Weizhen, WANG Zhen, et al. Short-term, medium-term and long-term forecasting of electricity price with consideration to market power[J]. Automation of Electric Power Systems, 2003, 27(22): 16-22(in Chinese).
- [12] YANG Hongming, LAI Mingyong. Chaotic characteristics of electricity price and its forecasting model[J]. Australian Journal of Electrical and Electronics Engineering, 2005, 2(2): 117-125.
- [13] 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.  
JI Xingquan, ZENG Ruomei, ZHANG Yuming, et al. CNN-LSTM short-term electricity price prediction based on an attention mechanism[J]. Power System Protection and Control, 2022, 50(17): 125-132(in Chinese).
- [14] 谢谦, 董立红, 库向阳. 基于Attention-GRU的短期电价预测[J]. 电力系统保护与控制, 2020, 48(23): 154-160.  
XIE Qian, DONG Lihong, SHE Xiangyang. Short-term electricity price forecasting based on Attention-GRU[J]. Power System Protection and Control, 2020, 48(23): 154-160(in Chinese).
- [15] 殷豪, 丁伟峰, 陈顺, 等. 基于长短时记忆网络-纵横交叉算法的含高比例新能源电力市场日前电价预测[J]. 电网技术, 2022, 46(2): 472-480.  
YIN Hao, DING Weifeng, CHEN Shun, et al. Day-ahead electricity price forecasting of electricity market with high proportion of new energy based on LSTM-CSO model[J]. Power System Technology, 2022, 46(2): 472-480(in Chinese).
- [16] VASWANI A, SHAZER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017: 6000-6010.
- [17] ZHOU Haoyi, ZHANG Shanghang, PENG Jieqi, et al. Informer: beyond efficient transformer for long sequence time-series forecasting [C]//Proceedings of the 35th AAAI Conference on Artificial Intelligence. AAAI, 2021: 11106-11115.
- [18] 勾玄, 肖先勇. 基于经验模式分解与LSTM神经网络的短期电价预测模型[J]. 西安理工大学学报, 2020, 36(1): 129-134.
- GOU Xuan, XIAO Xianyong. Short-term electricity price forecasting model based on empirical mode decomposition and LSTM neural network[J]. Journal of Xi'an University of Technology, 2020, 36(1): 129-134(in Chinese).
- CONEJO A J, PLAZAS M A, ESPINOLA R, et al. Day-ahead electricity price forecasting using the wavelet transform and ARIMA models[J]. IEEE Transactions on Power Systems, 2005, 20(2): 1035-1042.
- 张金良, 王明雪. 基于EEMD, SVM和ARMA组合模型的电价预测[J]. 电力需求侧管理, 2020, 22(3): 63-68.  
ZHANG Jinliang, WANG Mingxue. Electricity price forecasting based on EEMD, SVM and ARMA combination model[J]. Power Demand Side Management, 2020, 22(3): 63-68(in Chinese).
- 赵雅雪, 王旭, 蒋传文, 等. 基于最大信息系数相关性分析和改进多层次门控LSTM的短期电价预测方法[J]. 中国电机工程学报, 2021, 41(1): 135-146.  
ZHAO Yaxue, WANG Xu, JIANG Chuanwen, et al. A novel short-term electricity price forecasting method based on correlation analysis with the maximal information coefficient and modified multi-hierarchy gated LSTM[J]. Proceedings of the CSEE, 2021, 41(1): 135-146(in Chinese).
- XU Yue, LI Qiang, CUI Hui, et al. Physical and mathematical significance of locational marginal price[C]//Proceedings of the 2023 5th Asia Energy and Electrical Engineering Symposium. Chengdu: IEEE, 2023: 1383-1388.
- 孙大雁, 关立, 胡晨旭, 等. 省间电力现货交易机制设计与探索[J]. 电网技术, 2022, 46(2): 421-428.  
SUN Dayan, GUAN Li, HU Chenxu, et al. Design and exploration of inter-provincial power spot trading mechanism[J]. Power System Technology, 2022, 46(2): 421-428(in Chinese).
- 王小昂, 邹鹏, 任远, 等. 山西电力现货市场中长期与现货衔接问题及对策[J]. 电网技术, 2022, 46(1): 20-27.  
WANG Xiaoang, ZOU Peng, REN Yuan, et al. Problems and solutions of medium & long-term trading connected with electricity spot market in Shanxi province[J]. Power System Technology, 2022, 46(1): 20-27(in Chinese).
- 李宏仲, 吕勇荡. 数据驱动下的日前市场发电商智能决策方法[J]. 电网技术, 2023, 47(3): 1056-1065.  
LI Hongzhong, LÜ Yongdang. Data-driven intelligent decision-making method for day-ahead market power generation companies [J]. Power System Technology, 2023, 47(3): 1056-1065(in Chinese).



许越

在线出版日期: 2024-02-05。

收稿日期: 2023-09-15。

作者简介:

许越(2000), 男, 通信作者, 硕士研究生, 研究方向为电力市场, E-mail: xy15195952768@163.com;

李强(1966), 男, 教授级高级工程师, 硕士生导师, 研究方向为电力系统 EMS、DTS 和电力市场等, E-mail: liq@epri.sgcc.com.cn。

(责任编辑 王金芝)

## 附录 A

EEMD 分解步骤:

- 1) 设定实验次数  $M$ 。
- 2) 将高斯白噪声添加到原始信号  $x(t)$  得到新信号:

$$x_i(t) = x(t) + n_i(t)$$

式中:  $x_i(t)$  表示第  $i$  次实验得到的新信号;  $n_i(t)$  表示第  $i$  次实验加入的高斯白噪声;  $i=1,2,3,\dots,M$ 。

- 3) 每次实验都进行 EMD 分解, 得到各自的分解结果:

$$x_i(t) = \sum_{j=0}^J x_{IMF}^{i,j}(t) + r_n^i$$

式中:  $x_{IMF}^{i,j}(t)$  表示第  $i$  次实验新信号  $x_i(t)$  分解得到的第  $j$  个 IMF 分量;  $r_n^i$  表示第  $i$  次实验的残余项。

- 4) 重复上述 2)、3), 分别得到每次实验的 IMF 集合:

$$\sum_{j=0}^J x_{IMF}^{1,j}(t) \text{, } \sum_{j=0}^J x_{IMF}^{2,j}(t) \text{, } \dots \text{, } \sum_{j=0}^J x_{IMF}^{M,j}(t)$$

- 5) 集合平均  $M$  次实验各 IMF 分量:

$$x_{IMF}^j(t) = \frac{1}{M} \sum_{i=1}^M x_{IMF}^{i,j}(t)$$

式中  $x_{IMF}^j(t)$  EEMD 分解后的第  $j$  个 IMF 分量。

## 附录 B

局部时间戳:

$$\begin{cases} PE(pos, 2j) = \sin\left(\frac{pos}{(2j)^{\frac{d_{model}}{2}}}\right) \\ PE(pos, 2j+1) = \cos\left(\frac{pos}{(2j)^{\frac{d_{model}}{2}}}\right) \\ j \in \{1, 2, 3, \dots, \frac{d_{model}}{2}\} \end{cases}$$

式中:  $L_x$  为输入序列长度;  $d_{model}$  为输入表示的最终特征维度。

## 附录 C

KL 散度

$$KL(q \parallel p) = \ln \sum_{j=1}^{L_k} \exp\left(\frac{\mathbf{q}_i \mathbf{k}_j^T}{\sqrt{d}}\right) - \frac{1}{L_x} \ln \sum_{j=1}^{L_k} \frac{\mathbf{q}_i \mathbf{k}_j^T}{\sqrt{d}} - L \ln L_x$$

式中:  $L_x$  为输入序列长度;  $d$  为其中一个  $q$  或  $k$  的长度。

## 附录 D

三大评价指标:

$$\begin{aligned} X_{MAE} &= \frac{1}{T} \sum_{t=1}^T |\hat{p}(t) - p(t)| \\ X_{RMSE} &= \sqrt{\frac{1}{T} \sum_{t=1}^T (\hat{p}(t) - p(t))^2} \\ X_{MAPE} &= \frac{1}{T} \sum_{t=1}^T \left| \frac{\hat{p}(t) - p(t)}{p(t)} \right| \times 100\% \end{aligned}$$

式中:  $T$  为测试集样本数量;  $p(t)$  为  $t$  时刻电价真实值;  $\hat{p}(t)$  为  $t$  时刻电价预测值。