

DOI: 10.19783/j.cnki.pspc.231284

## 一种时频尺度下的多元短期电力负荷组合预测方法

李楠<sup>1,2</sup>, 姜涛<sup>2</sup>, 隋想<sup>3</sup>, 胡禹先<sup>4</sup>

(1. 现代电力系统仿真控制与绿色电能新技术教育部重点实验室(东北电力大学), 吉林 吉林 132012;

2. 东北电力大学电气工程学院, 吉林 吉林 132012; 3. 南京南瑞继保电气有限公司, 江苏 南京 210000;

4. 国家电网吉林省电力有限公司白城供电公司, 吉林 白城 137000)

**摘要:** 随机因素的增加导致电力负荷数据成分日渐复杂, 使短期负荷预测的难度逐渐增大。针对该问题, 提出一种时频尺度下的时间卷积网络与多元线性回归相融合的组合预测模型。利用自适应噪声完备集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)在时频域上将负荷数据分解为若干个频率特征不同的本征模态分量, 在模糊熵准则下聚类为随机项和趋势项。采用皮尔逊系数从诸多影响因素中筛选出与电力负荷高度相关的特征, 鉴于小时间尺度分析更易于挖掘局部细节特征, 分别构建了随机项与趋势项的细颗粒度特征集。利用具有强非线性处理能力的时间卷积网络(temporal convolutional network, TCN)去预测随机项, 利用结构简单及线性拟合效果好的多元线性回归(multiple linear regression, MLR)去预测趋势项, 将二者的预测结果进行叠加重构后获得最终预测值。在新加坡和比利时两组数据集上的实验结果证明: 所提模型具有较高的预测精度、较好的泛化性能及鲁棒性。

**关键词:** 短期电力负荷预测; 时频尺度; 分解算法; 模糊熵; 模型融合

### A multi-component short-term power load combination forecasting method on a time-frequency scale

LI Nan<sup>1,2</sup>, JIANG Tao<sup>2</sup>, SUI Xiang<sup>3</sup>, HU Yuxian<sup>4</sup>

(1. Key Laboratory of Modern Power System Simulation and Control & Renewable Energy Technology, Ministry of

Education (Northeast Electric Power University), Jilin 132012, China; 2. School of Electrical Engineering, Northeast

Electric Power University, Jilin 132012, China; 3. Nanjing Nari-Relays Electric Co., Ltd., Nanjing 210000, China;

4. Baicheng Power Supply Company, State Grid Jilin Electric Power Co., Ltd., Baicheng 137000, China)

**Abstract:** The increase of stochastic factors leads to increasing complexity of power load data components. This makes short-term load forecasting progressively more difficult. Thus a combined forecasting model fusing a temporal convolutional network with multiple linear regression on the time-frequency scale is proposed. The complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) is used to decompose the load data into multiple intrinsic mode functions with different frequency features in the time-frequency domain, and the intrinsic mode functions are clustered into random and trend terms under the fuzzy entropy criterion. The Pearson correlation coefficient is used to pick out features that are highly relevant to the power load from many influential factors. The analysis of a small time scale makes it easier to determine local detailed features, and the fine granularity feature set of the random and trend terms are constructed respectively. The temporal convolutional network (TCN) with strong nonlinear processing ability is used to predict the random term, and the multiple linear regression (MLR) with simple structure and good linear fitting effect is used to predict the trend term. The final predicted value is obtained by superposing and reconstructing both predicted results. Experimental results on two datasets including for Singapore and Belgium prove that the proposed model has high prediction accuracy, good generalizability and robustness.

This work is supported by the National Natural Science Foundation of China (No. 61973072).

**Key words:** short-term power load forecasting; time-frequency scale; decomposition algorithm; fuzzy entropy; model fusion

基金项目: 国家自然科学基金项目资助(61973072)

## 0 引言

准确的电力负荷预测是保证电网安全及经济平稳运行的必要条件<sup>[1-2]</sup>。近年来,随着大量主动性负荷和分布式新型能源的接入,以及社会突发事件<sup>[3-4]</sup>的频繁发生,这些不确定性因素导致电力负荷数据中的高频动态分量明显增加,对电力负荷预测精度产生了影响,增加了短期电力负荷预测的难度<sup>[5-6]</sup>。

自 20 世纪 70 年代,专家系统模拟人类专家的知识 and 经验解决特定区域的问题,实现了人工智能的理论研究走向实际应用、从一般推理策略探讨转向运用专门知识解决实际工程问题的重大突破。在电力负荷预测问题上,采用诸如支持向量机(support vector machine, SVM)、随机森林(random forest, RF)和神经网络等人工智能算法对电力大数据进行信息挖掘,实现负荷预测的方法日益成熟。文献[7]考虑建筑物的制冷负荷受建筑物本身及气象因素的多重影响,建立了基于最优参数配置的支持向量机负荷预测模型。文献[8]通过网络爬虫获取天气信息,并结合实际用户负荷数据,采用随机森林算法对用户负荷进行短期预测。文献[9]提出一种基于随机分布式嵌入框架的反向传播(back propagation, BP)预测模型,适用于训练数据较少的超短期电力负荷预测。文献[10]采用长短期记忆网络(long short-term memory, LSTM)进行负荷预测,同时引入随机搜索的方法进行网络参数寻优来增强模型的泛化能力。虽然人工智能算法应用于电力负荷预测取得了一定的成效,但单一的预测模型在面对成分较复杂的电力负荷数据时,会对其中的某一类或某几类特征的信息挖掘较充分,而对其他类特征的信息敏感度不足,训练所得的预测模型具有倾向性,预测精度难以进一步提升。解决该问题的思路之一是采用不同的预测模型从不同的角度挖掘数据特征,不同预测模型间实现互补,构建组合预测模型全面提升电力负荷的预测精度。

综合现有的研究成果,组合预测模型可分为权重分配预测<sup>[11-12]</sup>和数据分解预测<sup>[13-14]</sup>两类。权重分配预测的思想是对组合模型中各子模型得到的预测值进行权重的分配,重构获得最终预测结果。然而,权重的分配原则仅仅是根据某一组实际预测的误差进行权重计算,故在此单一样本上的预测精度较高,而无法保证在其余样本上的预测精度,进而导致此类组合预测模型的拓展性较差。在解决不确定因素对短期电力负荷精度的影响时,国内外学者普遍采用基于数据分解的组合预测方法,即采用分解算法对负荷数据进行分解,对分解后的不同分量或分量的组合进行预测,分解方法常采用诸如小波变换<sup>[15]</sup>

及经验模态分解等时频分析方法。小波变换在分解非平稳序列时,选取不同的小波基函数和分解层数会产生不同的效果,这使得该方法具有一定的先验性,增加了预测难度。而经验模态分解(empirical mode decomposition, EMD)是一种自适应分解方法,其依据序列自身的时间特征对数据进行分解,不需要人为设定参数<sup>[16]</sup>,但在分解的过程中由于局部极值在很短的时间间隔内发生多次跳变会产生模态混叠问题。文献[17]采用集合经验模态分解(ensemble empirical mode decomposition, EEMD)与过零率将原始负荷数据分为高频和低频两部分,分别利用门控循环单元(gated recurrent unit, GRU)和多元线性回归(multiple linear regression, MLR)进行预测。虽然 EEMD 通过引入噪声有效改善了 EMD 中存在的模态混叠问题,但引入的噪声会使计算复杂度增加,且可能残留。文献[18]通过互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD)将负荷分解为若干个分量,并采用模糊熵对各分量进行熵值计算,将低频成分中熵值接近的分量进行重组,再利用经过算术优化算法的最小二乘支持向量机进行预测。CEEMD 中引入的互补白噪声解决了 EEMD 中的噪声残留问题,并在采用模糊熵进行熵值重组的过程提高了模型的运算效率。但 CEEMD 是自适应分解过程,针对不同的负荷数据集进行分解所得到的分量个数是不固定的,这种不确定性会同时体现在组合预测模型中各子模型数量的不确定,导致该组合预测模型工程在线应用时不具备普适性。

针对上述问题,本文在引入细颗粒度概念的基础上,基于自适应噪声完备集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)算法提出了一种时间卷积网络(temporal convolutional network, TCN)与多元线性回归相结合的短期电力负荷组合预测方法。所提方法利用皮尔逊系数(Pearson correlation coefficient, PCCs)对天气因素(如:温度、湿度、风速、气压)进行筛选,挖掘与电力负荷相关性较强的特征。采用 CEEMDAN 方法将原始数据分解为若干个单一频率的本征模态函数(intrinsic mode function, IMF)分量及残差(residual, Res),在模糊熵(fuzzy entropy, FE)准则下对分解出来的 IMF 分量和 Res 进行熵值计算,将各分量聚类为随机项和趋势项。在此基础上进行细颗粒度数据集的构建,连同天气因素中筛选出的强相关特征共同作为预测模型的输入。利用 TCN 与 MLR 分别对随机项与趋势项进行组合预测,提升电力负荷预测的整体精度。

## 1 负荷数据预处理及特征集的构建

### 1.1 负荷数据预处理

为了准确学习电力负荷数据中不同类别特征的规律, 本小节通过 CEEMDAN 结合模糊熵对电力负荷数据进行预处理。CEEMDAN 可将负荷数据分解为多个 IMF 分量和 Res 分量, 模糊熵用于评估各分量的复杂程度。

#### 1.1.1 CEEMDAN

相较于小波时频分析方法, EMD 作为一种基于时间序列的自适应信号分解方法, 无需预先设置任何基函数, 依据信号自身的时频特征将复杂信号分解为本征模态分量与残差项之和的形式, 其缺点是各模态分量间易存在模态混叠现象。EEMD 通过在信号分解前对原始序列多次添加高斯白噪声, 改善 EMD 中存在的模态混叠问题, 但结果会产生残余辅助噪声和重构误差。为了进一步减小经验模态分解算法中模态混叠的影响, 文献[19]在 EEMD 的基础上提出了 CEEMDAN。在 CEEMDAN 分解过程中, 是对各阶 IMF 分量进行整体平均后, 对其残差项添加噪声再进行重复分解操作, 有效地解决了白噪声从高频向低频传递的问题, 并且通过增加分解次数减小了重构误差。

CEEMDAN 算法描述如下。

定义计算算子  $E_j(\cdot)$ , 表示将待分解的信号经过 EMD 处理后得到的第  $j$  个模态分量。令  $\omega^i$  表示第  $i$  次添加的均值为 0、方差为 1 的白噪声,  $\varepsilon_i (i=0, 1, \dots, n-1)$  为白噪声的自适应系数。

1) 在待分解的信号  $S(t)$  添加  $n$  次高斯白噪声, 构造出待分解的时间序列  $S^i(t)$ , 其中  $i=1, 2, \dots, n$ 。

$$S^i(t) = S(t) + \varepsilon_i \omega^i(t) \quad (1)$$

2) 对  $S^i(t) (i=1, 2, \dots, n)$  进行  $n$  次 EMD 处理, 得到第一个模态分量  $f_{\text{IMF}_1^i(t)}$ , 对其求平均得到第一个模态分量均值  $f_{\text{IMF}_1(t)}$  和第一个残余分量  $r_1(t)$ 。

$$f_{\text{IMF}_1(t)} = \frac{1}{n} \sum_{i=1}^n f_{\text{IMF}_1^i(t)} \quad (2)$$

$$r_1(t) = S(t) - f_{\text{IMF}_1(t)} \quad (3)$$

3) 将第一个残余分量添加特定白噪声后继续进行 EMD 处理, 得到第二个模态分量均值  $f_{\text{IMF}_2(t)}$  和第二个残余分量  $r_2(t)$ 。

$$f_{\text{IMF}_2(t)} = \frac{1}{n} \sum_{i=1}^n E_1(r_1(t) + \varepsilon_1 E_1(\omega^1(t))) \quad (4)$$

$$r_2(t) = r_1(t) - f_{\text{IMF}_2(t)} \quad (5)$$

4) 与 3) 类似, 向第  $j$  个残余分量中添加白噪声, 再进行 EMD 处理。

$$f_{\text{IMF}_{j+1}(t)} = \frac{1}{n} \sum_{i=1}^n E_1(r_j(t) + \varepsilon_j E_j(\omega^j(t))) \quad (6)$$

$$r_{j+1}(t) = r_j(t) - f_{\text{IMF}_{j+1}(t)} \quad (7)$$

5) 重复上述过程, 直至残余分量不超过两个极值点且不能继续分解时, CEEMDAN 分解过程结束。原始信号  $S(t)$  被分解为  $n$  个模态分量  $f_{\text{IMF}_i(t)}$  和一个残差  $r(t)$ 。

$$S(t) = \sum_{i=1}^n f_{\text{IMF}_i(t)} + r(t) \quad (8)$$

#### 1.1.2 模糊熵

样本熵是依据概率分布评估信号复杂程度, 计算的熵值越大, 信息的不确定性就越大, 该信号的复杂程度就越高。模糊熵是在样本熵的基础上通过引入模糊隶属度函数对其进行改进。

FE 的基本流程如下所述。

1) 对于由  $N$  个数据组成的时间序列  $U = \{u(1), u(2), \dots, u(N)\}$ , 依次构造  $N - m + 1$  个  $m$  维向量  $U_{(k)}$ 。

$$U_{(k)} = [u(k), u(k+1), \dots, u(k+m-1)] - u_0(k) \quad (9)$$

$$u_0(k) = \frac{1}{m} \sum_{l=0}^{m-1} u(k+l) \quad (10)$$

式中:  $m$  为相空间维数;  $k=1, 2, \dots, N - m + 1$ ;  $u_0(k)$  为  $m$  个连续  $u(k)$  的均值。

2) 计算任意两个  $m$  维向量  $U_{(k)}$  和  $U_{(l)}$  之间的最大绝对距离  $d_{kl}^m$ 。

$$d_{kl}^m = d[U_{(k)}, U_{(l)}] = \max_{p=1, 2, \dots, m} (|u(k+p-1) - u_0(k)| - |u(l+p-1) - u_0(l)|) \quad (11)$$

3) 引入模糊隶属函数  $A_{kl}^m$ 。

$$A_{kl}^m = \exp \left[ -\ln(2) \cdot \left( \frac{d_{kl}^m}{r} \right)^2 \right] \quad (12)$$

式中,  $r$  为相似容限度, 一般取所分析时间序列的标准差的 0.15 倍。

4) 当  $k$  值给定、 $l$  取值不同时, 二者模糊隶属函数的均值按式(13)求取。

$$C_k^m(r) = \frac{1}{N - m} \sum_{l=1, l \neq k}^{N - m + 1} A_{kl}^m \quad (13)$$

5) 定义  $m$  维下的关系维度函数  $\phi^m(r)$ 。

$$\phi^m(r) = \frac{1}{N - m + 1} \sum_{k=1}^{N - m + 1} C_k^m(r) \quad (14)$$

6) 当  $N$  为有限值时, 原时间序列的模糊熵为

$$F_E(m, r, N) = \ln \phi^m(r) - \ln \phi^{m+1}(r) \quad (15)$$

模糊熵用指数函数模糊化相似度量公式，指数函数的连续性使模糊熵值随参数的变化而连续平滑变化，改善了样本熵对相关参数取值较为敏感的问题，其鲁棒性更好<sup>[20]</sup>。

## 1.2 特征集构建

### 1.2.1 相关性分析

短期电力负荷受多种因素的影响，使其在具备周期性的同时呈现出较强的随机性。随机因素可划分为内在随机因素和外在随机因素，其中外在随机因素包括天气因素、重大节假日、经济因素等<sup>[21-22]</sup>，而内在随机因素则是由系统内部非线性因素的影响导致的。电力负荷的随机性加大了负荷预测的难度。在众多外部影响因素中，天气因素的影响较为明显。为了探究出天气因素中与电力负荷相关性强的特征，本文利用皮尔逊相关系数对特征进行筛选，其定义如式(16)所示。

$$\rho(\mathbf{F}, \mathbf{P}) = \frac{\sum_{s=1}^M (F_s - \bar{F})(p_s - \bar{p})}{\sqrt{\sum_{s=1}^M (F_s - \bar{F})^2} \sqrt{\sum_{s=1}^M (p_s - \bar{p})^2}} \quad (16)$$

式中： $\mathbf{P}$ 为电力负荷序列； $p_s$ 为第 $s$ 个电力负荷值， $\bar{p}$ 为其均值； $\mathbf{F}$ 为相关特征； $F_s$ 为第 $s$ 个相关特征值， $\bar{F}$ 为其均值； $M$ 为电力负荷数据的长度。

以新加坡2020年1月1日至3月31日的电力负荷数据与对应的包括温度、湿度、风速和气压在内的天气数据为例，不同的天气特征与电力负荷之间的相关性大小如图1所示。其中，相较于风速、气压而言，温度和湿度的相关性系数0.6213与0.5859更大，与负荷的相关性更强，故本文考虑将二者共同作为预测模型的天气特征输入。

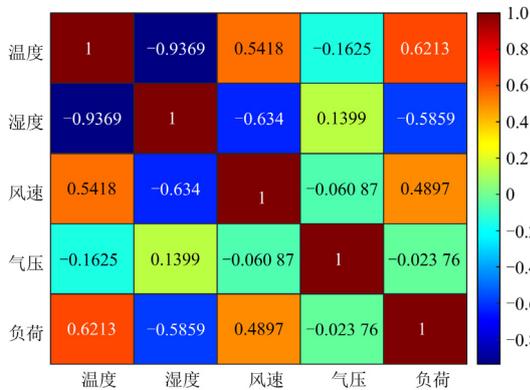


图1 电力负荷与天气因素之间的关系

Fig. 1 Relationship between electric load and weather factors

### 1.2.2 粗、细颗粒度

众所周知，在不同的时间尺度上获得的信息存在差异性，不同时间尺度上现象及信息是相互作用的。这种相互作用总的原则是：大时间尺度的现象是小时间尺度现象变化的背景，而小时间尺度上的现象可以影响大时间尺度上现象的变化。因此，为提高负荷预测精度，根据负荷数据序列在时间上的抽样频率不同体现尺度的变化，本文将历史数据划分成大时间尺度下的粗颗粒度和小时间尺度下的细颗粒度。颗粒度采用单位时间内(每小时)取样值的数量 $\lambda$ 表示。

$$\lambda = \frac{60}{\Delta T} \quad (17)$$

式中， $\Delta T$ 为电力负荷数据采样时间间隔，单位为min。

以比利时2020年全年的电力负荷数据为例，分别对粗、细颗粒度这两种数据集下的负荷预测进行讨论分析。为体现算法的公平性，采用本文提出的预测方法与文献[23]所提算法 LSTM-MLR 对不同颗粒度下的数据集进行预测，结果如图2所示。根据横向对比分析可知，随着细颗粒度 $\lambda$ 的增加，模型对数据的局部细节特征捕捉得越充分，两种模型的预测结果均有所提升。

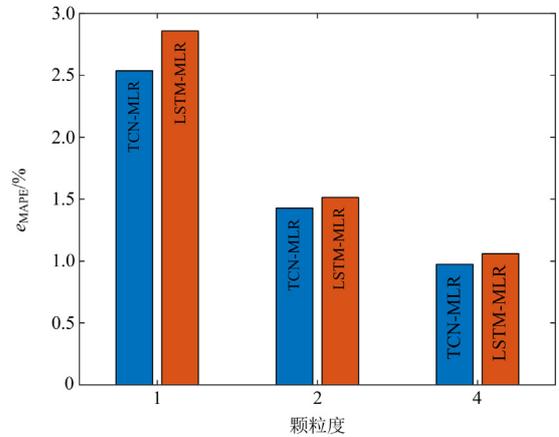


图2 不同颗粒度下的预测误差对比图

Fig. 2 Prediction error comparison of different granularities

为探究在选取不同颗粒度时，其对具有不同随机性的数据集进行预测的影响效果，本小节以2020年新加坡及比利时的电力数据为例，采用本文所提方法分别在颗粒度因子 $\lambda$ 为1和2的粗颗粒度和细颗粒度特征集下分析，结果如图3所示。

大时间尺度下的粗颗粒度反映数据的全局概貌特征，小时间尺度下的细颗粒度反映数据的局部细节特征。在组合预测模型中，波动性大、随机性强的随机项的预测结果在最终预测结果中占据主导地

位。因此, 更好地捕捉数据的局部特征是提升预测精度的关键。在新加坡和比利时两组数据集中, 新加坡的数据变化较为平稳, 而比利时的数据起伏性更大、不确定性更强, 导致随机因素作用在新加坡数据集上的效果没有比利时数据集上的强烈。从图 3 可知, 新加坡粗、细颗粒度之间预测结果的差距要比比利时粗、细颗粒度之间预测结果的差距小得多, 说明对于随机性更强的数据进行细颗粒度分析, 其预测精度的提升空间更大。

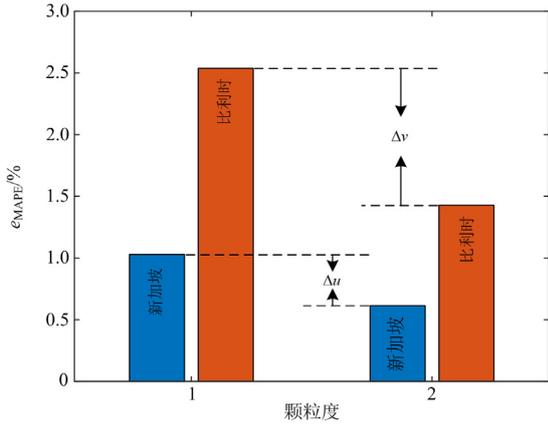


图 3 不同数据集下的预测误差对比图

Fig. 3 Prediction error comparison of different datasets

## 2 组合预测模型原理

为解决单一预测模型难以精准地处理电力负荷数据中的各类特征, 进一步提升预测精度, 本文提出一种基于 CEEMDAN 分解的 TCN-MLR 组合预测模型, 实现短期电力负荷预测。

### 2.1 多元线性回归

多元线性回归作为一种传统的回归分析方法, 用于估计两个或多个自变量与一个因变量之间的关系。与传统的神经网络相比, 其结构简单, 训练过程速度的优势明显<sup>[24]</sup>。并且, 针对时间序列中趋势明显、变化平稳的成分, 多元线性回归的预测精度更高。在多元线性回归中, 自变量与因变量之间的关系可由回归方程式表示, 每个自变量的回归系数反映对应自变量的重要程度, 如式(18)所示。

$$y = b_0 + b_1x_1 + b_2x_2 + \dots + b_\delta x_\delta + \dots + b_\eta x_\eta + \sigma \quad (18)$$

式中:  $y$  表示因变量;  $x_\delta$  表示第  $\delta$  个自变量;  $b_0$  表示常数项;  $b_\delta$  表示第  $\delta$  个自变量的回归系数;  $\eta$  表示自变量的数量;  $\sigma$  表示预测误差。

将其应用于电力负荷预测中, 式(18)可改写成矩阵表达式为

$$\mathbf{P} = \mathbf{X} \times \mathbf{B} + \boldsymbol{\mu} \quad (19)$$

$$\begin{bmatrix} p_1 \\ p_2 \\ \vdots \\ p_M \end{bmatrix} = \begin{bmatrix} 1 & x_{11} & \dots & x_{1M} \\ 1 & x_{21} & \dots & x_{2M} \\ \vdots & \vdots & & \vdots \\ 1 & x_{M1} & \dots & x_{MM} \end{bmatrix} \times \begin{bmatrix} b_0 \\ b_1 \\ \vdots \\ b_M \end{bmatrix} + \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_M \end{bmatrix} \quad (20)$$

式中:  $\mathbf{X}$  为 MLR 的输入特征, 本文中即为温度、湿度及历史负荷;  $x_{sr}$  表示第  $r$  个特征对应的第  $s$  个特征值;  $\mathbf{B}$  为回归系数向量;  $b_0$  表示常数项;  $b_s$  表示第  $s$  个回归系数,  $s=1,2,\dots,M$ ;  $\boldsymbol{\mu}$  为随机扰动向量;  $\mu_s$  表示第  $s$  个扰动值。

采用最小二乘法对回归参数进行估计, 求出回归函数, 即为预测模型。参数估计的表达式为

$$\hat{\mathbf{B}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{P} \quad (21)$$

本文选取 MLR 作为趋势项预测模型的主要原因如下:

1) 从数据层面来看, 对电力负荷数据进行预处理后获得的趋势项, 基本上整体或分段呈现出单调准线性的关系;

2) 从特征选择层面来看, 影响电力负荷的因素是多样的, 由多个特征变量的最优组合共同估计负荷值, 比单一的特征变量预测更有效, 更符合工程实际;

3) 从模型层面来看, 在众多的回归模型中, MLR 超参数相对较少, 采用线性函数作为激活函数, 却无需复杂的迭代过程及参数调整, 更适用于对平滑的低频分量进行预测。

### 2.2 时间卷积网络

时间卷积网络是在卷积神经网络的基础上, 融合膨胀因果卷积和残差块的神经网络模型, 使其可以从大样本时间序列中提取特征并实现预测<sup>[25]</sup>。在时间序列建模时, 使用因果卷积的目的是学习  $t$  时刻之前的输入数据 ( $h_0, h_1, \dots, h_t$ ) 来预测下一时刻的输出。但是标准的因果卷积在面对大样本时间序列时, 往往需要通过堆叠多层网络或者使用很大的卷积核来扩大神经网络中的感受野。基于此, TCN 使用膨胀因果卷积, 在不显著增加计算成本的同时提升感受野。膨胀因果卷积的公式如式(22)所示。

$$G(\mathbf{O}, \mathbf{H}) = (\mathbf{O} * \mathbf{H})_{h_t} = \sum_{w=1}^K o_w x_{t-(K-w)d} \quad (22)$$

式中:  $\mathbf{H} = \{h_0, h_1, \dots, h_t\}$  为输入的时间序列;  $\mathbf{O} = \{o_0, o_1, \dots, o_K\}$  表示卷积核, 其大小为  $K$ ,  $o_k$  表示卷积核的个数;  $d$  为膨胀因子。

膨胀因果卷积的结构如图 4 所示, 其中  $K=1 \times 3$ ,  $d=2^{\xi-1}$ ,  $\xi$  为隐藏层的层数。当  $d=1$  时, 膨胀因果卷积即为标准的因果卷积。与标准因果卷

积相比, 膨胀因果卷积可以在相同网络层数下, 使输出序列  $\{g_0, g_1, \dots, g_t\}$  尽可能多地关联到输入序列  $\{h_0, h_1, \dots, h_t\}$ 。

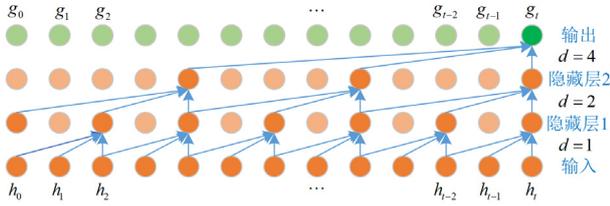


图 4 膨胀因果卷积结构图

Fig. 4 Structure of dilated causal convolution

为了加强网络的稳定性, 解决深层网络训练时可能出现的梯度消失、梯度爆炸等一系列问题, TCN 采用残差块的结构<sup>[26]</sup>, 即输入数据跳过中间的卷积操作, 经过  $1 \times 1$  的卷积处理后直接与经过中间卷积操作的数据相加的结果作为输出, 更好地适应复杂的输入输出关系。如图 5 所示, TCN 模型的基本单元由膨胀因果卷积、权重归一化、激活函数、随机失活和残差连接封装构成。

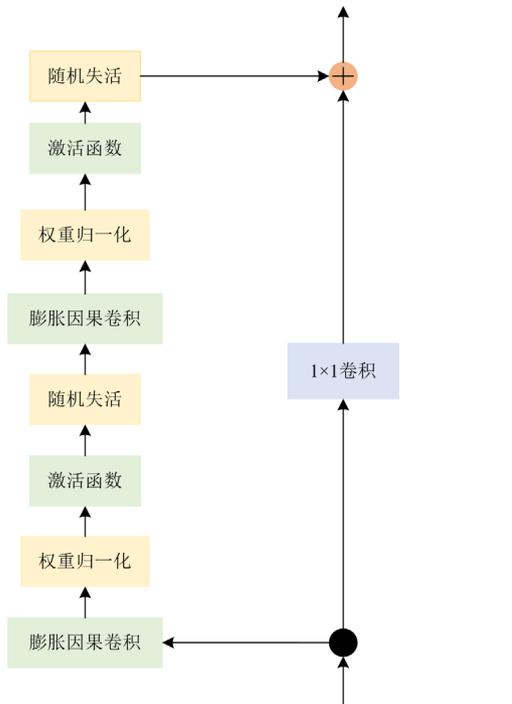


图 5 TCN 网络的基础单元

Fig. 5 Basic unit of TCN network

本文将 TCN 作为随机项的预测模型, 主要基于以下几点考虑:

1) TCN 的多尺度信息提取能力强, 通过膨胀卷积技术增大卷积核的感受野, 可以有效地捕捉时序数据中的局部依赖关系, 对电力负荷数据中的随机

项的特征信息提取更完备、更充分;

2) TCN 的并行处理能力较强, 非常适用于本文所提细颗粒度的大规模时序负荷数据样本预测, 在时间成本上与 MLR 模型更匹配, 提升了组合预测模型的运算效率;

3) TCN 具有稳定的梯度传播特性, 很难遇到梯度消失或梯度爆炸问题, 模型的稳定性及泛化能力更好。

### 2.3 基于 CEEMDAN 的 TCN-MLR 组合预测模型

本文所提的组合预测方法由数据预处理、特征集构建、模型预测及性能评估 4 个部分组成。鉴于异常值对 MLR 模型的预测精度影响较大, 在进行负荷数据分解前, 需对数据进行清洗, 包括异常值剔除及缺失值补充。为了应对外界因素的影响, 提高预测精度, 选取结合 CEEMDAN 与 FE 评估的数据预处理手段将原始数据划分为随机项分量与趋势项分量。鉴于天气因素对电力负荷的作用显著, 以及电力负荷的时间尺度变化可以通过改变数据自身的采样频率获知, 将天气数据和电力负荷数据进行相关性分析得到的强相关特征, 与在随机项分量及趋势项分量下构建的细颗粒度共同作为预测模型的输入特征。结合 MLR 线性拟合能力强与 TCN 能够深度挖掘负荷变化规律的优势, 分别对趋势项和随机项进行预测, 进而将预测值叠加重构结束模型预测过程。最后, 通过性能评估中的误差分析来验证本文所提方法的有效性。图 6 为本文提出的负荷预测方法流程图。

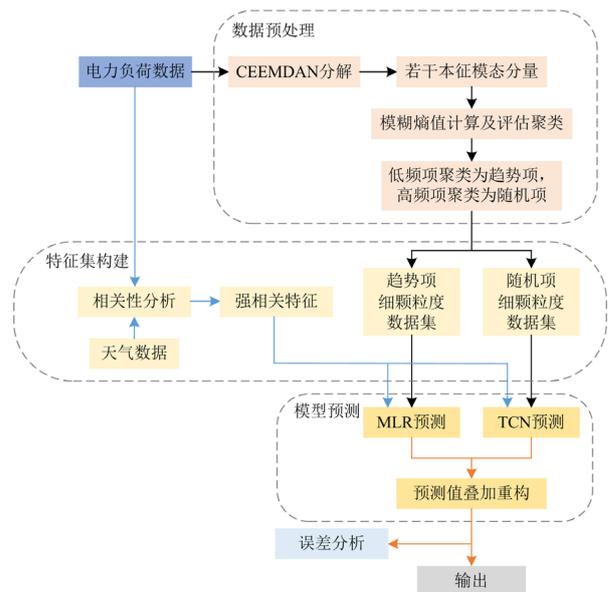


图 6 负荷预测方法的流程图

Fig. 6 Flow chart of the load forecasting method

## 2.4 评价指标

为了评估本文所提算法和对比算法的预测准确性, 本文采用平均绝对误差 ( $e_{MAE}$ )、平均绝对百分比误差 ( $e_{MAPE}$ ) 以及均方根误差 ( $e_{RMSE}$ ) 为评价指标。各评价指标的计算公式为

$$e_{MAE} = \frac{1}{Q} \sum_{q=1}^Q |P_q^{\text{pred}} - P_q^{\text{real}}| \quad (23)$$

$$e_{MAPE} = \frac{100\%}{Q} \sum_{q=1}^Q \left| \frac{P_q^{\text{pred}} - P_q^{\text{real}}}{P_q^{\text{real}}} \right| \quad (24)$$

$$e_{RMSE} = \sqrt{\frac{1}{Q} \sum_{q=1}^Q (P_q^{\text{pred}} - P_q^{\text{real}})^2} \quad (25)$$

式中:  $Q$  为测试集的样本数量;  $P_q^{\text{pred}}$  和  $P_q^{\text{real}}$  分别为测试集中第  $q$  个时间点上的预测负荷值和真实负荷值。

## 3 案例分析

本文所建立的算法模型均通过 Matlab 2021b 实现, 硬件平台采用 Intel i7-7700HQ 处理器, NVIDIA GTX 1050 显卡, 运行内存为 16 GB。本文 TCN 的参数设置如下: 残差块个数为 2, 卷积核个数为 29, 卷积核大小为 7, dropout 为 0.1, 学习率为 0.0046, 训练次数为 1000, 优化器为 Adam。LSTM 的参数设置如下: 隐藏层单元个数为 32, 学习率为 0.002, 训练次数为 100, 优化器为 Adam。SVR 的参数设置如下: 惩罚因子为 4.0, 径向基函数参数为 0.8。ELM

的参数设置如下: 隐藏层单元个数为 23, 激活函数为 sigmoid。

### 3.1 新加坡负荷数据预测分析

案例一选取新加坡 2020 年 1 月 1 日至 12 月 31 日的电力负荷数据, 采样时间间隔为 30 min, 共 17 568 条数据, 全年的负荷水平曲线如图 7 所示。

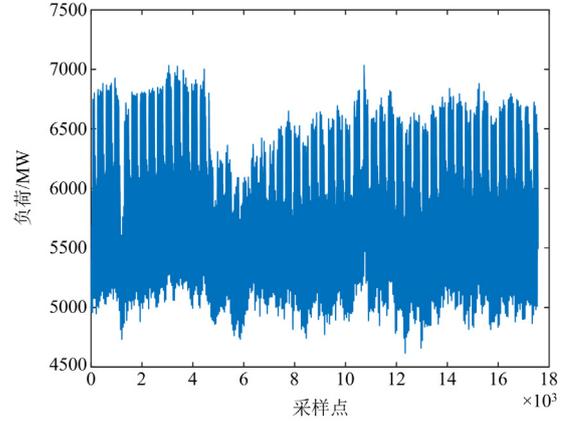


图 7 新加坡电力负荷数据

Fig. 7 Singapore electric load data

将新加坡电力负荷数据经 CEEMDAN 分解后共得到 16 个分量, 其中包括 15 个 IMF 分量 and 1 个 Res 分量。分解后的序列如图 8 所示。从图 8 中可以看出, 各分量的波动程度大体上在逐渐减小, 说明各分量的随机性在逐渐减弱, 趋势性越来越明显。

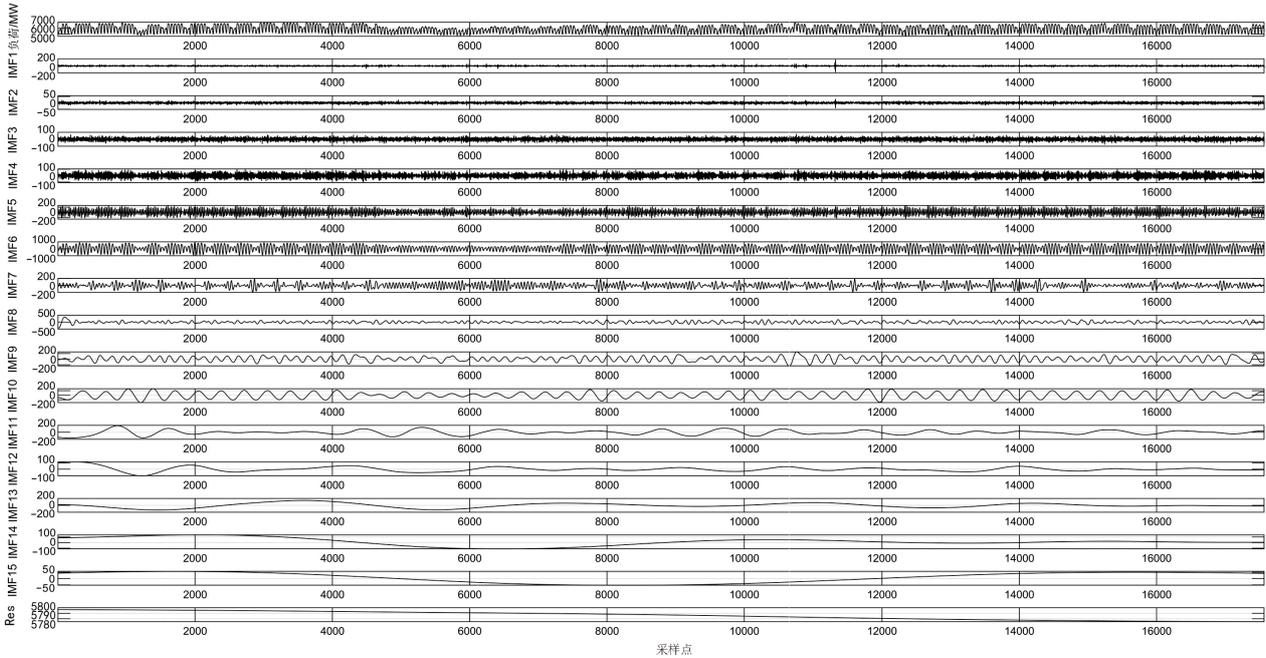


图 8 新加坡电力负荷数据的分解结果

Fig. 8 Decomposition results of Singapore electric load data

为了减少模型训练所需的时间，提高训练的效率，采用模糊熵评估分解后各子序列的复杂度，各分量的熵值求解结果如图 9 所示。根据实际经验，选取 0.01 作为阈值划分出高频项及低频项。将所有的高频项合并为随机项，将所有低频项合并为趋势项。对新加坡数据构建细颗粒度为 2 的数据集，与电力负荷强相关的温度和湿度数据共同作为特征输入。新加坡细颗粒度数据集样本总数共 8784 个，其中选取前 6148 个样本为训练集，后 2636 个样本为测试集。

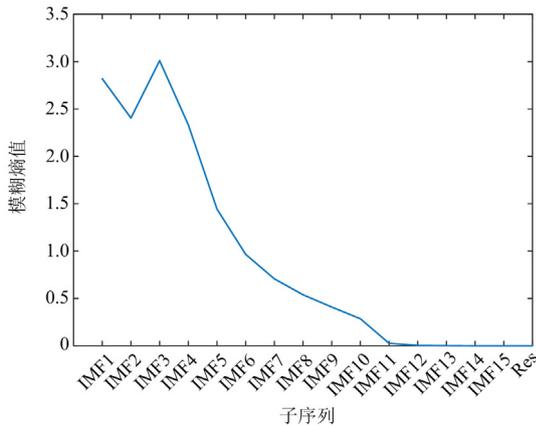


图 9 各分量的模糊熵值

Fig. 9 Fuzzy entropy of each component

为体现本文所提方法的优势，选择极限学习机 (extreme learning machine, ELM)、支持向量回归 (support vector regression, SVR)、LSTM、TCN 等单一预测模型以及 EEMD-LSTM-MLR 组合模型进行对比分析。6 种方法在测试集中某 24 个时间点上的预测结果如图 10 所示。从图 10 中可以看出，单一预测模型的效果较差，相较于真实值出现明显的偏差。

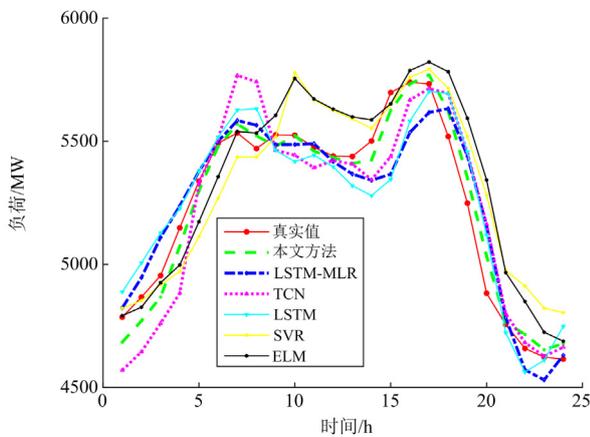


图 10 各模型的预测结果对比图

Fig. 10 Prediction result comparison chart of each model

代表 EEMD-LSTM-MLR 模型的蓝色曲线仅仅在 6 点和 11 点上与真实值曲线出现短暂相交。而本文所提方法在整体采样时间点上都能够捕捉真实曲线的变化趋势，具有很高的还原度。

表 1 为各预测方法在测试集下的  $e_{MAE}$ 、 $e_{MAPE}$  及  $e_{RMSE}$  结果。从表 1 中可知，在单一模型中，TCN 表现出较好的预测性能，其  $e_{MAE}$  和  $e_{RMSE}$  比 ELM、SVR、LSTM 分别下降 65.3371 MW、84.8041 MW、62.2370 MW 和 90.5183 MW、7.0893 MW、5.0864 MW。组合预测模型 EEMD-LSTM-MLR 的  $e_{MAE}$  和  $e_{RMSE}$  比 TCN 分别下降 1.4861 MW 和 6.6739 MW。而本文提出的基于细颗粒度下的 CEEMDAN-TCN-MLR 与 EEMD-LSTM-MLR 相比，三类指标值又分别下降 33.2106 MW、0.5794%、39.6750 MW，说明本文所提方法具有良好的预测性能，与真实负荷之间的偏离程度最小。

表 1 各预测方法在新加坡数据集下的误差对比

Table 1 Error comparison among prediction methods in

Singapore dataset			
模型	$e_{MAE}/MW$	$e_{MAPE}/\%$	$e_{RMSE}/MW$
ELM	135.7103	2.3600	177.4789
SVR	132.6102	2.2878	183.1931
LSTM	77.4625	1.3500	97.7612
TCN <sup>[26]</sup>	70.3732	1.2044	92.6748
EEMD-LSTM-MLR <sup>[24]</sup>	68.8871	1.1932	86.0009
本文方法	35.6765	0.6138	46.3259

### 3.2 比利时负荷数据预测分析

案例二选取比利时 2020 年 1 月 1 日至 12 月 31 日的电力负荷数据，采样间隔为 15 min，共 35 137 条数据，如图 11 所示。

为了对比新加坡和比利时两个数据集中随机因素的强弱，根据其统计特性绘制如图 12 所示的箱型

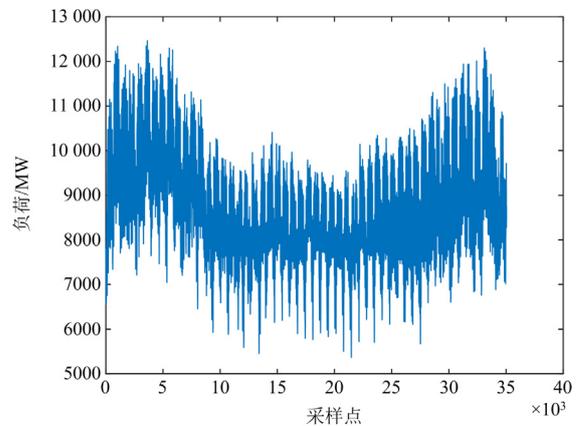


图 11 比利时电力负荷数据

Fig. 11 Belgium electric load data

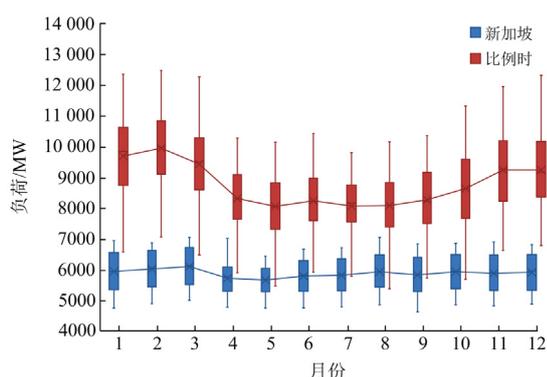


图 12 数据集统计特性箱型图

Fig. 12 Box diagram of statistical feature of dataset

图。其中，箱型图的上边缘与下边缘分别代表数据的最大值和最小值，矩形盒的两个边缘分别代表数据的上、下四分位数，盒内的线段代表数据的中位数。将每组数据集的每个月份的均值点进行连接，从连接曲线的变化趋势可以看出，新加坡数据集的波动比较平缓，相比较而言，位于上方的比利时数据集的起伏性更大。因此，比利时数据的不确定性更高，受随机因素的影响更强。

将比利时电力负荷数据经 CEEMDAN 分解后得到如图 13 所示的 16 个 IMF 分量和 1 个 Res 分量，据此实验结果可以验证自适应分解算法对于不同的数据集经分解所获得的分量个数具有不确定性。

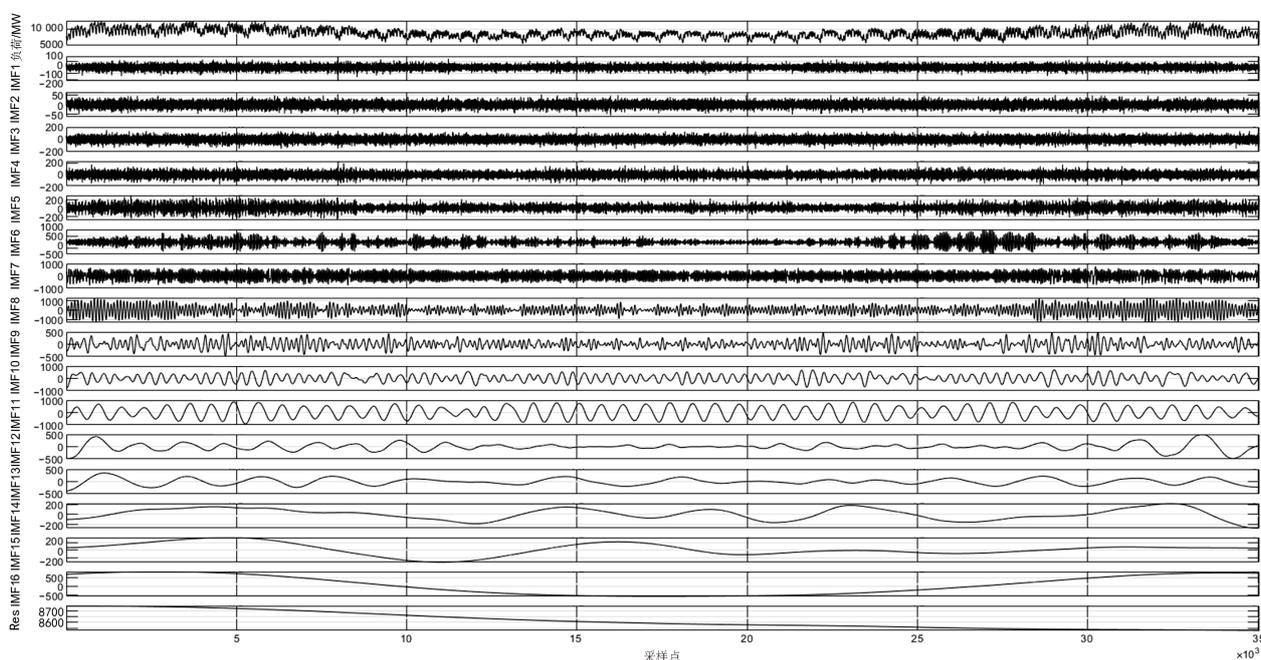


图 13 比利时电力负荷数据的分解结果

Fig. 13 Decomposition results of Belgium electric load data

将 17 个分量的模糊熵值进行计算，各分量的熵值如图 14 所示。根据模糊熵聚类原则，IMF1—IMF12 为高频项，叠加构成随机项；而 IMF13—Res 为低频项，叠加构成趋势项。由于比利时电力负荷数据的采样时间间隔为 15 min，即  $\lambda$  为 4，得到的细颗粒度样本集共 8784 条数据，取前 6148 条数据为训练集，后 2636 条数据为测试集。

图 15 为随机选取各预测模型在测试集中某连续 24 个时间点上的预测结果。从图 15 中可以看出，由于比利时数据的随机性更强，故在 24 个时间点上的波动更剧烈且频繁。与其他模型相比，在 17 至 24 时间点之间，本文所提方法的预测值与真实值之差最小。

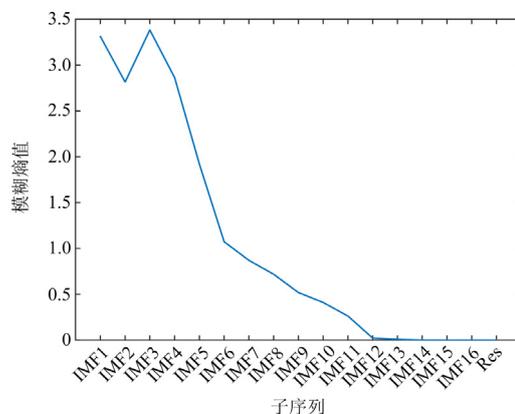


图 14 各分量的模糊熵值

Fig. 14 Fuzzy entropy of each component

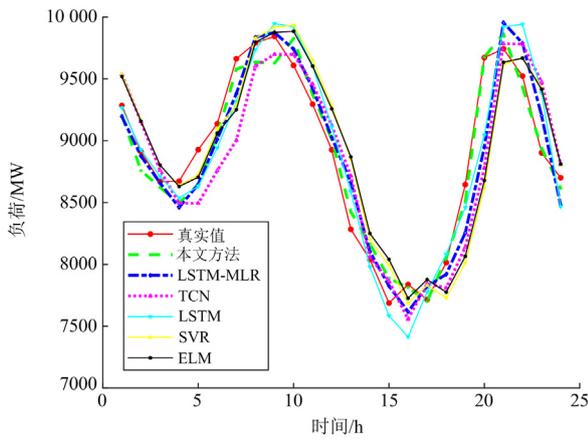


图 15 各模型的预测结果对比图

Fig. 15 Prediction result comparison chart of each model

表 2 为各预测方法在测试集下的  $e_{MAE}$ 、 $e_{MAPE}$  及  $e_{RMSE}$  结果。从表 2 中可直观地看出，基于粗颗粒度下的单一模型的预测效果较差，EEMD-LSTM-MLR 与单一模型 ELM、SVR、LSTM、TCN 相比， $e_{MAPE}$  分别下降 0.8113%、0.7531%、0.2613%、0.1769%，说明组合预测模型的预测效果要好于单一预测模型。而作为本文所提出的基于细颗粒度下 CEEMDAN-TCN-MLR 预测方法，其精度比 EEMD-LSTM-MLR 提高 1.8845%，说明该模型相较于其他组合模型，其预测精度表现更为优秀。

表 2 各预测方法在比利时数据集下的误差对比

Table 2 Error comparison among prediction methods in Belgium dataset

模型	$e_{MAE}/MW$	$e_{MAPE}/\%$	$e_{RMSE}/MW$
ELM	326.6009	3.6700	407.5782
SVR	322.7079	3.6118	409.2152
LSTM	277.1176	3.1200	341.2138
TCN <sup>[26]</sup>	269.4758	3.0356	330.5511
EEMD-LSTM-MLR <sup>[24]</sup>	253.3003	2.8587	315.6333
本文方法	85.6830	0.9742	108.7538

### 3.3 鲁棒性分析

随机选取输入特征可能导致模型对于输入数据的扰动敏感性增加，使得预测模型的可靠性降低。为准确分析输入特征的随机选取对预测模型鲁棒性产生的影响，通过改变天气特征的维度以及细颗粒度特征集中历史负荷数据的维度，分别基于新加坡数据集与波动更剧烈的比利时数据集进行多次实验，将各次实验的均值作为模型的输出，实验结果如表 3、表 4 所示。

由表 3、表 4 的实验结果可知，输入特征的随机选取会造成预测结果的浮动，对比表 1、表 2 中

本文方法的评价指标结果，在新加坡数据集与比利时数据集下的  $e_{MAPE}$  与  $e_{RMSE}$  分别产生了 0.0458%、2.4174 MW 及 0.0508%、5.3318 MW 的偏差，但由于组合模型强大的自学习能力，使其在整体上仍然具有较高的预测精度，表明本文所提方法具有较强的鲁棒性。

表 3 新加坡不同特征数据集下的预测对比结果

Table 3 Prediction comparison results under different feature datasets in Singapore

实验编号	$e_{MAPE}/\%$	$e_{RMSE}/MW$
1	0.6729	48.6621
2	0.6295	48.1901
3	0.6393	48.2472
4	0.7199	50.8521
5	0.6298	47.6588
6	0.6663	48.8496
均值	0.6596	48.7433

表 4 比利时不同特征数据集下的预测对比结果

Table 4 Prediction comparison results under different feature datasets in Belgium

实验编号	$e_{MAPE}/\%$	$e_{RMSE}/MW$
1	1.0284	116.3963
2	1.0261	116.0853
3	1.0208	113.8167
4	1.0326	112.8739
5	1.0086	113.6900
6	1.0172	112.3407
7	1.0183	112.8425
8	1.0486	114.6399
均值	1.0250	114.0856

## 4 结论

本文以提高短期负荷预测的精度为目的，从影响预测精度的两个因素——输入特征和模型本身出发，针对负荷数据的采样频率不同可以反映尺度的变化，提出细颗粒度的概念并进行细颗粒度数据集构建，利用 TCN 与 MLR 组合预测方法进行仿真分析，得到的结论如下：

1) 与 EEMD 相比，CEEMDAN 在分解时添加的是白噪声经 EMD 处理得到的残余分量，有效降低重构信号中的噪声残余。同时，采用模糊熵评估分解获得的各子序列的复杂程度，根据模糊熵评估准则将其划分为随机项和趋势项，有利于提高预测精度。

2) 针对电力负荷受多种因素影响而呈现出较强的随机性，本文应用皮尔逊相关系数进行相关性分析，以筛选出高度相关输入特征。为了进一步提

高预测精度,提出细颗粒度的概念,并在不同细颗粒度下进行分析得知, $\lambda$ 越大,数据的局部特征被挖掘得越充分,预测效果越好。

3) 针对单一预测模型难以全面捕捉到数据中的复杂关系,本文采用 TCN 与 MLR 相结合的预测模型,TCN 的非线性处理能力强,MLR 的线性拟合准确,二者结合在两个数据集的预测结果均优于其他对比模型,并且在随机选取输入特征时,组合预测模型仍获得较高精度,具有较好的鲁棒性。

## 参考文献

- [1] 侯慧,王晴,赵波,等.关键信息缺失下基于相空间重构及机器学习的电力负荷预测[J].电力系统保护与控制,2022,50(4):75-82.  
HOU Hui, WANG Qing, ZHAO Bo, et al. Power load forecasting without key information based on phase space reconstruction and machine learning[J]. Power System Protection and Control, 2022, 50(4): 75-82.
- [2] 杨书强,王涛,檀晓林,等.基于长短期记忆的图像化短期电力负荷预测方法[J].全球能源互联网,2023,6(3):282-288.  
YANG Shuqiang, WANG Tao, TAN Xiaolin, et al. Image based short-term power load forecasting method using long short-term memory[J]. Journal of Global Energy Interconnection, 2023, 6(3): 282-288.
- [3] RUAN Guangchun, WU Dongqi, ZHENG Xiangtian, et al. A cross-domain approach to analyzing the short-run impact of COVID-19 on the US electricity sector[J]. Joule, 2020, 4(11): 2322-2337.
- [4] 钟劲松,王少林,冉懿,等.基于互信息和 LSTM 的用户负荷短期预测[J].电力建设,2022,43(7):96-102.  
ZHONG Jingsong, WANG Shaolin, RAN Yi, et al. Short-term consumer load forecasting based on mutual information and LSTM[J]. Electric Power Construction, 2022, 43(7): 96-102.
- [5] 王凌云,林跃涵,童华敏,等.基于改进 Apriori 关联分析及 MFOLSTM 算法的短期负荷预测[J].电力系统保护与控制,2021,49(20):74-81.  
WANG Lingyun, LIN Yuehan, TONG Huamin, et al. Short-term load forecasting based on improved Apriori correlation analysis and an MFOLSTM algorithm[J]. Power System Protection and Control, 2021, 49(20): 74-81.
- [6] 刘文杰,刘禾,王英男,等.基于完整自适应噪声集成经验模态分解的 LSTM-Attention 网络短期电力负荷预测方法[J].电力建设,2022,43(2):98-108.  
LIU Wenjie, LIU He, WANG Yingnan, et al. Short-term power load forecasting method based on CEEMDAN and LSTM-attention network[J]. Electric Power Construction, 2022, 43(2): 98-108.
- [7] LI Qiong, MENG Qinglin, CAI Jiejun, et al. Applying support vector machine to predict hourly cooling load in the building[J]. Applied Energy, 2009, 86(10): 2249-2256.
- [8] 胡兆龙,胡俊建,彭浩,等.基于深度随机森林算法的短期用户负荷预测—以金华地区为例[J].电子科技大学学报,2023,52(3):430-437.  
HU Zhaolong, HU Junjian, PENG Hao, et al. Short-term user load forecasting based on deep random forest: take Jinhua city as an example[J]. Journal of University of Electronic Science and Technology of China, 2023, 52(3): 430-437.
- [9] 李国庆,刘钊,金国彬,等.基于随机分布式嵌入框架及 BP 神经网络的超短期电力负荷预测[J].电网技术,2020,44(2):437-445.  
LI Guoqing, LIU Zhao, JIN Guobin, et al. Ultra short-term power load forecasting based on randomly distributive embedded framework and BP neural network[J]. Power System Technology, 2020, 44(2): 437-445.
- [10] 张宇帆,艾芊,林琳,等.基于深度长短时记忆网络的区域级超短期负荷预测方法[J].电网技术,2019,43(6):1884-1891.  
ZHANG Yufan, AI Qian, LIN Lin, et al. A very short-term load forecasting method based on deep LSTM RNN at zone level[J]. Power System Technology, 2019, 43(6): 1884-1891.
- [11] 周洲,焦文玲,任乐梅,等.蚁群算法分配权重的燃气日负荷组合预测模型[J].哈尔滨工业大学学报,2021,53(6):177-183.  
ZHOU Zhou, JIAO Wenling, REN Lemei, et al. Combined forecasting model of gas daily load based on weight distribution of ant colony algorithm[J]. Journal of Harbin Institute of Technology, 2021, 53(6): 177-183.
- [12] 牛东晓,魏亚楠.基于 FHNN 相似日聚类自适应权重的短期电力负荷组合预测[J].电力系统自动化,2013,37(3):54-57.  
NIU Dongxiao, WEI Yanan. Short-term power load combinatorial forecast adaptively weighted by FHNN similar-day clustering[J]. Automation of Electric Power Systems, 2013, 37(3): 54-57.
- [13] 张平,潘学萍,薛文超.基于小波分解模糊灰色聚类和 BP 神经网络的短期负荷预测[J].电力自动化设备,2012,32(11):121-125,141.  
ZHANG Ping, PAN Xueping, XUE Wenchao. Short-term load forecasting based on wavelet decomposition, fuzzy gray correlation clustering and BP neural network[J]. Electric Power Automation Equipment, 2012, 32(11): 121-125, 141.
- [14] MATHEW J, BEHERA R K. EMD-Att-LSTM: a data-

- driven strategy combined with deep learning for short-term load forecasting[J]. *Journal of Modern Power Systems and Clean Energy*, 2021, 10(5): 1229-1240.
- [15] BESSEC M, FOUQUAU J. Short-run electricity load forecasting with combinations of stationary wavelet transforms[J]. *European Journal of Operational Research*, 2018, 264(1): 149-164.
- [16] 杨斌, 杨世海, 曹晓冬, 等. 基于 EMD-QRF 的用户负荷概率密度预测[J]. *电力系统保护与控制*, 2019, 47(16): 1-7.
- YANG Bin, YANG Shihai, CAO Xiaodong, et al. Short-term consumer load probability density forecasting based on EMD-QRF[J]. *Power System Protection and Control*, 2019, 47(16): 1-7.
- [17] 邓带雨, 李坚, 张真源, 等. 基于 EEMD-GRU-MLR 的短期电力负荷预测[J]. *电网技术*, 2020, 44(2): 593-602.
- DENG Daiyu, LI Jian, ZHANG Zhenyuan, et al. Short-term electric load forecasting based on EEMD-GRU-MLR[J]. *Power System Technology*, 2020, 44(2): 593-602.
- [18] 杨海柱, 田馥铭, 张鹏, 等. 基于 CEEMD-FE 和 AOA-LSSVM 的短期电力负荷预测[J]. *电力系统保护与控制*, 2022, 50(13): 126-133.
- YANG Haizhu, TIAN Fuming, ZHANG Peng, et al. Short-term load forecasting based on CEEMD-FE-AOA-LSSVM[J]. *Power System Protection and Control*, 2022, 50(13): 126-133.
- [19] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise[C]// 2011 IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP), May 22-27, 2011, Prague, Czech Republic: 4144-4147.
- [20] CHEN Weiting, WANG Zhizhong, XIE Hongbo, et al. Characterization of surface EMG signal based on fuzzy entropy[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2007, 15(2): 266-272.
- [21] 陈梓行, 金涛, 郑熙东, 等. 基于新型日期映射法和 ISGU 混合模型的短期电力负荷预测[J]. *电力系统保护与控制*, 2022, 50(15): 72-80.
- CHEN Zixing, JIN Tao, ZHENG Xidong, et al. Short-term power load forecasting based on a new date mapping method and an ISGU hybrid model[J]. *Power System Protection and Control*, 2022, 50(15): 72-80.
- [22] 庞传军, 余建明, 张波, 等. 基于梯度提升树计及非线性的电力负荷影响因素分析[J]. *电力系统保护与控制*, 2020, 48(24): 71-78.
- PANG Chuanjun, YU Jianming, ZHANG Bo, et al. Nonlinear correlation analysis of influence factors of a power load based on a gradient boosting decision tree[J]. *Power System Protection and Control*, 2020, 48(24): 71-78.
- [23] LI Jian, DENG Daiyu, ZHAO Junbo, et al. A novel hybrid short-term load forecasting method of smart grid using MLR and LSTM neural network[J]. *IEEE Transactions on Industrial Informatics*, 2020, 17(4): 2443-2452.
- [24] AMRAL N, OZVEREN C S, KING D. Short term load forecasting using multiple linear regression[C]// 2007 42nd International Universities Power Engineering Conference, September 4-6, 2007, Brighton, UK: 1192-1198.
- [25] 赵洋, 王瀚墨, 康丽, 等. 基于时间卷积网络的短期电力负荷预测[J]. *电工技术学报*, 2022, 37(5): 1242-1251.
- ZHAO Yang, WANG Hanmo, KANG Li, et al. Temporal convolution network-based short-term electrical load forecasting[J]. *Transactions of China Electrotechnical Society*, 2022, 37(5): 1242-1251.
- [26] 符杨, 任子旭, 魏书荣, 等. 基于改进 LSTM-TCN 模型的海上风电超短期功率预测[J]. *中国电机工程学报*, 2022, 42(12): 4292-4302.
- FU Yang, REN Zixu, WEI Shurong, et al. Ultra-short-term power prediction of offshore wind power based on improved LSTM-TCN model[J]. *Proceedings of the CSEE*, 2022, 42(12): 4292-4302.

收稿日期: 2023-10-03; 修回日期: 2023-11-18

作者简介:

李楠(1973—), 女, 通信作者, 博士, 副教授, 研究方向为数据挖掘在电力系统中的应用; E-mail: jllinan@163.com

姜涛(1996—), 男, 硕士研究生, 研究方向为人工智能算法在电力系统中的应用。E-mail: 15944071258@163.com

(编辑 魏小丽)