

基于 EWT-GRU-RR 的配电网短期电力负荷预测模型

白星振¹, 赵康¹, 葛磊蛟², 王慧³, 李晶⁴, 李华⁵, 牛峰⁶

- (1. 山东科技大学 电气与自动化工程学院, 山东 青岛 266590; 2. 天津大学 智能电网教育部重点实验室, 天津 300072;
3. 中国能源建设集团 天津电力设计院有限公司, 天津 300400; 4. 山东科技大学 电子信息工程学院, 山东 青岛 266590;
5. 国网辽宁省电力有限公司 经济技术研究院, 辽宁 沈阳 110015;
6. 河北工业大学 省部共建电工装备可靠性与智能化国家重点实验室, 天津 300130)

摘要:随着间歇分布式电源的大规模并入, 电力负荷的波动性和非线性特征日益明显, 现有单一预测模型较难实现精准预测。本研究提出一种经验小波变换(EWT)、门控循环单元(GRU)和岭回归(RR)相结合的短期电力负荷预测模型 EWT-GRU-RR。首先, 应用灰色关联度选取与负荷高相关性的气象耦合因素, 作为相似日的分类指标; 然后, 采用皮尔逊系数法对类别内的负荷进行最佳相似日选取以减小计算规模; 接着, 采用 EWT 将相似日负荷数据分解得到不同频率的负荷模态序列; 最后, 采用 GRU 与 RR 分别对不同频率模态序列进行多步预测, 并将预测分量叠加得到最终负荷预测结果。实验结果表明, 本研究所提模型的预测误差较单一预测模型 GRU 减少了 77% 以上, 较支持向量机回归(SVR)减少了 75% 以上, 较先采用经验模态分解(EMD)进行分解再采用径向基函数神经网络(RBF)和 RR 组合预测模型 EMD-RBF-RR 减少了 75% 以上, 较先采用 EMD 进行分解再采用 GRU 和 RR 组合预测模型 EMD-GRU-RR 减少了 76% 以上, 有效提高了负荷预测精度。

关键词:配电网; 经验小波变换; 门控循环单元; 岭回归; 短期电力负荷; 预测模型

中图分类号: TM715

文献标志码: A

Short-term power load forecasting model based on EWT-GRU-RR

BAI Xingzhen¹, ZHAO Kang¹, GE Leijiao², WANG Hui³, LI Jing⁴, LI Hua⁵, NIU Feng⁶

- (1. College of Electrical Engineering and Automation, Shandong University of Science and Technology, Qingdao 266590, China;
2. Key Laboratory of Smart Grid of Ministry of Education, Tianjin University, Tianjin 300072, China;
3. Tianjin Electric Power Design Institute Co. Ltd, China Electric Power Energy Group, Tianjin 300400, China;
4. College of Electronic and Information Engineering, Shandong University of Science and Technology, Qingdao 266590, China;
5. Economic and Technological Research Institute, State Grid Liaoning Electric Power Co. Ltd, Shenyang 110015, China;
6. State Key Laboratory of Reliability and Intelligence of Electrical Equipment, Hebei University of Technology, Tianjin 300130, China)

Abstract: With the large-scale integration of intermittent distributed power generation, the fluctuation and nonlinear characteristics of power load are becoming obvious, and it is difficult for the existing single prediction model to achieve accurate prediction. This paper proposed a short-term power load forecasting model based on the combination of empirical wavelet transform (EWT), gated recurrent unit (GRU) and ridge regression (RR). Firstly, the meteorological coupling factors highly correlated with load were selected by using grey correlation degree and were used as the classification index of similar days. To reduce the calculation scale, the best similar

收稿日期: 2022-10-04

基金项目: 国家自然科学基金项目(51807134); 省部共建电工装备可靠性与智能化国家重点实验室(河北工业大学)开放基金项目(EERI_KF20200014)

作者简介: 白星振(1977—), 男, 山东临朐人, 副教授, 博士, 主要从事电网状态估计方面研究. E-mail: xzbai@sdust.edu.cn
李晶(1978—), 女, 浙江东阳人, 讲师, 博士, 主要从事状态检测、估计等方面研究, 本文通信作者.
E-mail: peilianglj@163.com

days for the loads within the category were selected by using the Pearson correlation coefficient method. Then, similar daily load data were decomposed by using EWT to obtain the load modal sequences of different frequencies. Finally, the multi-step predictions on modal sequences of different frequencies were performed respectively by using GRU and RR and the final load prediction result was obtained by superimposing the prediction components. The experimental results show that the forecasting error of the proposed model is reduced by more than 77% compared with single forecasting model GRU, more than 75% compared with support vector regression (SVR), more than 75% compared with the combined prediction model EMD-RBF-RR, in which the empirical mode decomposition (EMD) was first used to decompose and then the radial basis function (RBF) and RR were used to predict respectively, and more than 76% compared with the combined forecasting model EMD-GRU-RR, in which EMD was used to decompose and then GRU and RR were used to predict respectively. The proposed model improves the accuracy of load forecasting effectively.

Key words: power distribution network; empirical wavelet transform; gated recurrent unit; ridge regression; short-term power load; forecasting model

精确的短期电力负荷预测是合理分配电网资源和优化电力基础设施的重要基础^[1]。实现电力负荷的精准预测,有利于电力企业根据负荷短时变化情况及时灵活调整电价和用电策略,获得良好的经济效益。同时,实现电力负荷的精准预测对于电力系统区域能源优化调度和节能经济运行具有重要意义^[2-3]。

短期电力负荷存在一定的周期特性,但随着电力市场的发展和间歇分布式能源并网水平的提高,电力负荷的规律性被逐渐削弱,出现较强的随机性和非周期成分,增加了短期负荷预测的难度。多年来,国内外学者针对如何提升短期负荷预测精度开展研究。文献[4]采用 Nadam 优化算法优化深度信念网络,提升了预测精度,但仍无法实现波动性较强的特殊类型负荷的预测;文献[5]引入实时电价这一影响因素,利用加权灰色关联投影算法选取历史负荷数据集,减小了模型的预测误差;文献[6]提出一种数据驱动与误差驱动融合的短期负荷预测方法,但没有考虑多变量间的复杂协同作用,缺乏一定的普适性。上述文献本质上是采用单一预测模型进行负荷预测,此类预测方法会因为负荷随机性过强导致模型的泛化性能不佳^[7],因此,组合预测方法应运而生。文献[8]采用变分模态分解技术将原始负荷序列分解为具有不同特征频率的子序列,并对每个子序列建立预测模型,提高了预测精度;文献[9]采用集合经验模态分解(ensemble empirical mode decomposition, EEMD)将电力负荷变化趋势加以区分,并针对不同趋势选用神经网络和多元线性回归组合预测,对随机性较强的局部特征实现了准确预测,但是随着分解模态数量的增多出现了预测误差累积、模型复杂度提高等问题。

为提高短期电力负荷预测的精度,本研究提出一种经验小波变换(empirical wavelet transform, EWT)、门控循环单元(gated recurrent unit, GRU)和岭回归(ridge regression, RR)相结合的短期负荷预测模型 EWT-GRU-RR。EWT 可以对负荷序列实现有效分解,GRU 和 RR 针对分解得到的子序列频率大小可以实现自适应预测,本研究充分利用上述特点。首先,基于灰色关联度选取与负荷高相关性的气象耦合因素作为相似日分类指标,并采用皮尔逊系数法对类别内的负荷进行最佳相似日选取;接着,采用 EWT 对相似日负荷数据进行分解得到不同频率的负荷模态序列;最后,采用 GRU 与 RR 分别对不同频率模态序列进行多步预测,再将结果叠加还原,得到最终预测结果。

1 负荷的分解与预测

短期电力负荷对季节、温度、天气十分敏感,很难用一种预测算法实现精准模拟^[10]。本研究采用 EWT 将电力负荷分解成周期、平稳成分和受外界因素影响的非周期、随机成分,使预测过程更具有针对性。在电力负荷预测模型的选择上,利用 GRU 对随机性强的分量具有出色的记忆能力和 RR 可以解决预测过程中出现的负荷数据多重共线性问题的特点,将两个预测模型相结合实现各模态分量的精准预测。

1.1 负荷分解模型

EWT 是一种以小波变换为理论框架的自适应信号分解方法,采用合适正交小波滤波器自适应划分信

号的傅里叶谱,然后提取其中不同调幅、调频模态进行处理,以获得瞬时频率和幅值,具体过程如下^[11]。

1) 对由若干天负荷数据组成的负荷序列 $f(t)$ 进行傅里叶变换,并将其在 $[0, \pi]$ 内的傅里叶频谱划分为 N 个连续段落 $\mathbf{A}_n = [\omega_{n-1}, \omega_n]$, 其中 ω_n 为分割段落之间的边界, $n=1, 2, \dots, N$ 。

2) 以 ω_n 为中心,定义宽度为 $T_n = 2\tau_n$ 的过渡区域,那么经验小波即为在每个 \mathbf{A}_n 上的带通滤波器。本研究按照文献[11]方式构造其经验小波函数 $\hat{\varphi}(\omega)$ 和经验尺度函数 $\hat{\phi}_n(\omega)$:

$$\hat{\varphi}(\omega) = \begin{cases} \sin\left(\frac{\pi}{2}\beta\left(\frac{1}{2\gamma\omega_n}(|\omega| - (1-\gamma)\omega_{n+1})\right)\right), & (1-\gamma)\omega_n \leq |\omega| < (1+\gamma)\omega_n; \\ 1, & (1+\gamma)\omega_n \leq |\omega| < (1-\gamma)\omega_{n+1}; \\ \cos\left(\frac{\pi}{2}\beta\left(\frac{1}{2\gamma\omega_{n+1}}(|\omega| - (1-\gamma)\omega_{n+1})\right)\right), & (1-\gamma)\omega_{n+1} \leq |\omega| \leq (1+\gamma)\omega_{n+1}; \\ 0, & \text{其他。} \end{cases} \quad (1)$$

$$\hat{\phi}_n(\omega) = \begin{cases} 1, & |\omega| \leq (1-\gamma)\omega_n; \\ \cos\left(\frac{\pi}{2}\beta\left(\frac{1}{2\gamma\omega_n}(|\omega| - (1-\gamma)\omega_n)\right)\right), & (1-\gamma)\omega_n \leq |\omega| \leq (1+\gamma)\omega_n; \\ 0, & \text{其他。} \end{cases} \quad (2)$$

$$\beta(x) = \begin{cases} 0, & x < 0; \\ x^4(35 - 84x + 70x^2 - 20x^3), & 0 \leq x \leq 1; \\ 1, & x > 1. \end{cases} \quad (3)$$

$$\gamma < \min_n \left(\frac{\omega_{n+1} - \omega_n}{\omega_{n+1} + \omega_n} \right). \quad (4)$$

3) 计算其相关系数 $W_f^\varepsilon(n, t)$ 和近似相关系数 $W_f^\varepsilon(0, t)$, 相关系数由经验小波函数与信号内积产生, 近似相关系数由尺度函数与信号内积产生。

$$W_f^\varepsilon(n, t) = \langle f, \varphi_n \rangle = \int f(\tau) \overline{\varphi_n(\tau - t)} d\tau. \quad (5)$$

$$W_f^\varepsilon(0, t) = \langle f, \varphi_1 \rangle = \int f(\tau) \overline{\varphi_1(\tau - t)} d\tau, \quad (6)$$

4) 将原始负荷序列 $f(t)$ 重构, 得到:

$$f(t) = W_f^\varepsilon(0, t) \phi_1(t) + \sum_{n=1}^N W_f^\varepsilon(n, t) \phi_n(t) = F^{-1} \left(\hat{W}_f^\varepsilon(0, \omega) \hat{\varphi}_1(\omega) + \sum_{n=1}^N \hat{W}_f^\varepsilon(n, \omega) \hat{\varphi}_n(\omega) \right). \quad (7)$$

式中: $F^{-1}(\cdot)$ 分别为傅里叶逆变换; $\hat{\varphi}_n$ 和 $\hat{\varphi}_1(\omega)$ 分别为经验小波函数和经验尺度函数的傅里叶变换形式; $\hat{W}_f^\varepsilon(0, \omega)$ 和 $\hat{W}_f^\varepsilon(n, \omega)$ 分别为 $W_f^\varepsilon(0, t)$ 和 $W_f^\varepsilon(n, t)$ 的傅里叶变换形式。

5) 求解 $f(t)$ 各模态分量。这种自适应划分输入负荷信号并得到特征差异明显的模态分量的方式, 可实现对负荷特征的有效提取。

$$f_0(t) = W_f^\varepsilon(0, t) \phi_1(t), \quad (8)$$

$$f_k(t) = W_f^\varepsilon(k, t) \phi_k(t). \quad (9)$$

式中: 模态分量 $f_0(t)$ 代表整体变化趋势的 IMF 分量, 较为平稳, 本研究将其定义为负荷分量 F_0 ; $f_k(t)$ 代表特征差异明显的 IMF 分量, 本研究将其定义为负荷分量 F_k , $k=1, 2, \dots, N$ 。

1.2 负荷预测模型

1.2.1 门控循环单元

循环神经网络(recurrent neural network, RNN)通过引入循环单元结构,使其在未构造时序特征的情况下实现动态记忆输入序列的时序特性,但当输入序列足够长时, RNN 的梯度可能会在反向传播期间逐渐减小,导致网络权重无法更新而停止学习^[12]。为解决上述问题,文献[13]提出 GRU。在使用 EWT 得到各负荷分量后,本研究使用 GRU 预测负荷分量中非周期、无规律波动的高频分量,保证精度的同时进一步节省

运算时间。GRU 单元结构参考文献[14],这里不再赘述。

1.2.2 岭回归

为提高负荷预测的精确性,分别对 EWT 分解产生的负荷序列采用滑动窗口多步长处理,各分量均可得到高度相关自变量负荷矩阵 $\mathbf{X}_k = [f_k(t-1), f_k(t+1), f_k(t-2), f_k(t+2)]$, 因变量负荷矩阵为 $\mathbf{Y}_k = [y_1, y_2, \dots, y_n]^T$, 其中 k 为 F_k 对应模态数。若继续采用传统预测模型,则会因输入自变量特征过多陷入过拟合,导致预测精度降低。为此,文献[14]通过引入正则化项解决自变量之间多重共线性的问题,传统回归公式为:

$$\mathbf{Y}_k = \sum_{i=1}^q \mathbf{X}_k \boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad (10)$$

式中, $\boldsymbol{\beta} = [\beta_1, \beta_2, \dots, \beta_q]^T$ 为相关参数向量,通过最小二乘法可得其解为 $\hat{\boldsymbol{\beta}} = (\mathbf{X}_k^T \mathbf{X}_k)^{-1} \mathbf{X}_k^T \mathbf{Y}_k$ 。

若继续采用传统回归公式,矩阵 $\mathbf{X}_k^T \mathbf{X}_k$ 奇异且其部分特征根接近 0,导致预测值与实际值之间的误差 $\hat{\beta}_{\text{MSE}}$ 变大,使得所求解不再稳定。

$$\hat{\beta}_{\text{MSE}} = E(\|\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}\|^2) = \sigma^2 \sum_{i=1}^q \frac{1}{\lambda_i} \quad (11)$$

式中, $E(\)$ 代表 $\|\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}\|^2$ 的期望值。

因此,岭回归通过引入范数解决了负荷数据集多重共线性问题。该方法可求解式(10) $\hat{\boldsymbol{\beta}} = (\mathbf{X}_k^T \mathbf{X}_k + \lambda \mathbf{I})^{-1} \mathbf{X}_k^T \mathbf{Y}_k$, 其中 \mathbf{I} 为单位矩阵。此时,矩阵 $\mathbf{X}_k^T \mathbf{X}_k + \lambda \mathbf{I}$ 特征根远离 0,误差 $\hat{\beta}_{\text{MSE}}$ 进一步减小,回归预测值更加稳定准确。

2 预测流程和评判指标

基于上述理论分析,本研究提出一种经验小波变换、门控循环单元与岭回归的组合预测方法 EWT-GRU-RR(以下简称 EGR),该方法可明显提高预测精度,方法流程如下。

1) 数据预处理。剔除数据集中缺失负荷或气象数据的负荷日,以保证数据的有效性^[15]。

2) 相似日分类依据的确定。结合灰色关联度分析,观察与日负荷变化趋势最为一致的气象因素,并将其作为分类依据进行分类。采用综合气象因素既省略了不同类型气象因素与负荷相对重要性的比较过程,又能实现对负荷变化的有效跟踪,进而保障了预测的精确性。本研究融合各日特征气象因素得到气象耦合指标人体舒适度,以此表征负荷变化情况并进行最佳相似日的选取^[16]。人体舒适度指数为:

$$D = 1.8 \times \bar{T} + 0.55 \times (1 - \bar{U}) - 3.2 \times \sqrt{\bar{V}} + 32 \quad (12)$$

式中: \bar{T} 为日平均气温,℃; \bar{U} 为日平均相对湿度,%; \bar{V} 为日平均风速,m/s。

3) 相似日的选取。根据预测日所在类别,结合皮尔逊系数法在对应类别中筛选出与预测日负荷强相关的最佳相似日。采用灰色关联度与皮尔逊相似度两种相似度指标,从不同角度筛选相似日以保证输入负荷数据含有较多的特征信息,减少数据冗余。

4) 负荷序列的分解与预测。采用 EWT 对输入负荷序列进行分解,得到数据平滑、周期性较强的模态分量和频率高、随机性较强的模态分量,根据不同分量采用不同的负荷预测方式。一方面,该方法充分利用了 GRU 非线性映射能力,能够较好地还原随机性强的低频模态分量;另一方面,采用岭回归可以在预测低频模态分量的同时,尽可能地降低 EWT 分解和预测中耗费的时间与资源,提升预测速度与效率。

5) 将各模态预测结果叠加重构,得到最终负荷预测值。

采用平均绝对百分误差(mean absolute percentage error, MAPE)和均方根误差(root mean square error, RMSE)评估模型的预测性能优劣,评估指标计算式分别为:

$$M_{\text{APE}} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \times 100\% \quad (13)$$

$$R_{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (14)$$

式中: M_{APE} 为平均绝对百分误差, R_{MSE} 为均方根误差, n 为预测点的个数, y_i, \hat{y}_i 分别为负荷真实值 $\mathbf{Y} = [y_1, y_2, \dots, y_n]^T$ 和负荷预测值 $\mathbf{Y}' = [y'_1, y'_2, \dots, y'_n]^T$ 中对应 i 时刻负荷。

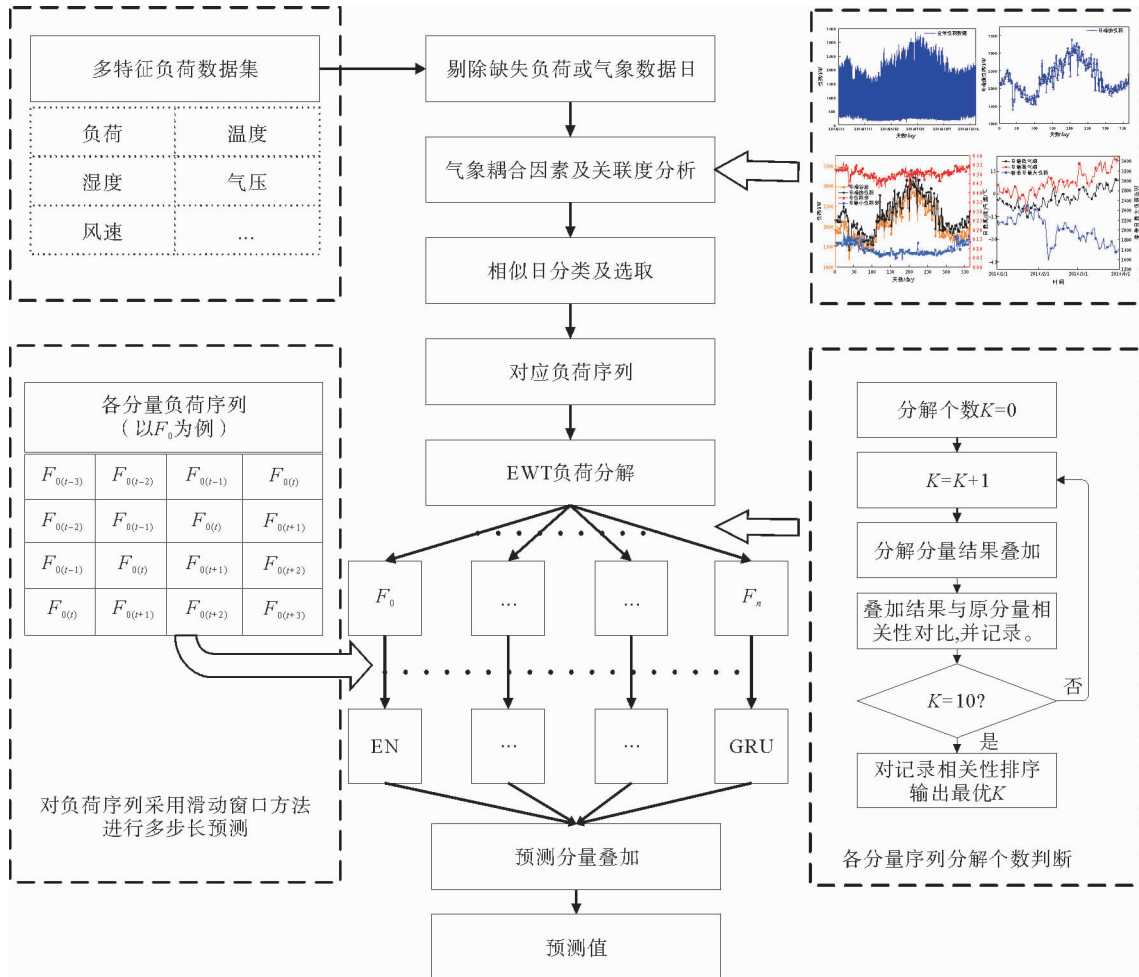


图 1 模型整体预测过程

Fig. 1 Overall forecasting process of the model

3 仿真分析

以天津市 2016 年某区域 15 min 粒度电力负荷数据为例,对提出的短期电力负荷预测方法进行验证。涉及的仿真模型均在 Python 下搭建,参数设置为:岭回归采用 Sklearn 库中的 ElasticNetCV 模块,并设置 $l1_ratio=0$;为保证 L2 岭回归范数, $\alpha=1e5$;GRU 根据数据集规模选择 $optimizer='adam'$, $loss='mean_squared_error'$, $batch_size=4$, $epochs=400$;SVR、RBF 采用 GridSearchCV 寻得最优参数,各算例参数如表 1、表 2 所示。

3.1 气象耦合及相似日分类

合适的历史相似日的选取可明显提升负荷预测效果,短期电力负荷预测方法越来越多地考虑到多变量、多尺度的影响因素。采用综合气象因素既省略了不同类型气象因素与负荷相对重要性的比较过程,又能实现对负荷变化的有效跟踪,保障负荷预测的精确性。本研究融合各日特征气象因素得到气象指标,并以此表征负荷变化情况,进行最佳相似日选取。其中,各气象指标与日负荷相关性如表 3 所示。

表 1 EWT 分量下 SVR 参数设置

Table 1 SVR parameters settings of each component EWT

EWT 分量	F_0	F_1	F_2	F_3	F_4
EWT-SVR	$C=10,$ $\text{gamma}=0.1,$ Kernel='sigmoid'	$C=1.0,$ $\text{gamma}=1.0,$ Kernel='rbf'	$C=1.0,$ $\text{gamma}=1.0,$ Kernel='rbf'	$C=1.0,$ $\text{gamma}=1.0,$ kernel='rbf'	$C=10,$ $\text{gamma}=0.1$ Kernel='rbf'

表 2 EMD 分量下 RBF 参数设置

Table 2 RBF parameters settings of each component of EMD

EMD 分量	I_{MF0}	I_{MF1}	I_{MF2}	I_{MF3}	I_{MF4}	I_{MF5}	I_{MF6}	R_{es}
EMD-RNF-RR	$\text{gamma}=0.2,$ num_nerous=32	$\text{gamma}=0.01,$ num_nerous=10	$\text{gamma}=0.01,$ num_nerous=10	$\text{gamma}=0.01,$ num_nerous=19	$\text{gamma}=0.01,$ num_nerous=13	岭回归 参数	岭回归 参数	$\text{gamma}=0.2,$ num_nerous=12

灰色关联法是一种通过研究数据关联性大小反映各因素对目标值重要程度的研究方法。人体舒适度指数是从气象角度对人体的舒适感进行评价的指标。由表 3 可以看出,在气象指标与日负荷的相关性上,结合多种气象因素所得的气象指标较单一气象因素有了明显的提高。本研究相似日分类指标为人体舒适度,结合文献[17]制定表 4 所示分类指标。其中,预测日为随机选取 96 点日负荷。输入过多的变量不仅增加计算复杂度,而且变量间的交叉相关影响会导致预测精度降低。因此,本研究根据预测日选取对应类别内皮尔逊相关系数最高的 4 天作为训练集。

表 3 气象指标及其相关性对比

Table 3 Comparison of meteorological indicators and their correlations

气象指标	相关系数
日平均气温 \bar{T}	0.913
日最高气温 T_{max}	0.926
日最低气温 T_{min}	0.876
日平均相对湿度 \bar{U}	0.879
日平均风速 \bar{V}	0.803
人体舒适度指数 D	0.943

表 4 人体舒适度分类及类别占比

Table 4 Classification and category proportion of human body comfort

人体舒适度指数 D	人体感觉描述	类别占比/%
≤ 50	较冷或较为凉爽	0.8
$50 < D \leq 75$	舒适,最可接受	4.9
$75 < D \leq 90$	热,可适当降温	13.1
$90 < D \leq 104$	闷热,希望注意防暑降温	29.5
$D > 104$	酷热,希望注意防暑降温,以防中暑	51.3

3.2 分解的模态分量对比分析

为进一步验证 EWT 分解的有效性,分别采用 EWT、EMD 方法对分类优选后的训练集负荷进行分解,如图 2、图 3 所示。

由图 2 可知,EWT 的模态分量由低频向高频过渡。其中,低频模态分量、负荷占比较大,高频模态分量、负荷占比较小,而且分量表现出一定的周期性,使得预测结果更加稳定。从图 3 可以看出,EMD 的各模态分量由高频向低频过渡,多模态个数导致其高频分量占比较大,高频分量预测误差的累计同时也会进一步影响到负荷预测的精度。对比图 2 和图 3 可知,EWT 分解得到的模态分量个数与 EMD 相比大幅减少。EMD 分解的模态分量通过多次迭代产生,迭代过程缺少必要的停止条件。因此,采用 EWT 可有效减少后续组合预测的运算量,从而提高效率。

基于上述对比分析,为保证负荷序列的有效分解和后续负荷预测精度,本研究选用 EWT 方法对负荷序列进行处理。

3.3 预测效果对比分析

3.3.1 单一模型间的对比分析

为了验证所提出模型的精确性,将 EWT-GRU、EWT-SVR 以及单一预测模型 GRU、SVR 与本研究提出的 EGR 模型进行对比,结果如图 4 和表 5 所示,预测绝对误差对比如图 5 所示。其中,单一预测模型采用的数据集为未经 EWT 分解的滑动窗口多步长处理负荷数据集。

1) 从图 4(a)和图 5 不难看出,与 EWT-GRU、GRU、SVR、EGR 相比,EWT-SVR 负荷预测曲线与真实负荷曲线的拟合程度较差,其绝对误差在 0:00—8:00(0—32 时刻)不稳定,即 SVR 并不能通过 EWT 将所有负荷模态分量准确预测,最终的预测结果存在模态分量的误差累计。因此,针对不同模态预测,选用合适的模型可提高预测的可靠性。

2) 结合图 4(b)可知,相较于 GRU 直接预测,先采用 EWT 分解然后再分步预测的 EWT-GRU 模型拟合程度更高;结合表 5 中两模型的预测误差可以发现,与 GRU 相比,EWT-GRU 的 RMSE 值减小 3.686 kW,EWT-GRU 的 MAPE 值相较于 GRU 减小 75.7%。因此,采用 EWT 可以进一步提高预测的精确性。

3) 结合图 5 分析,各模型在 7:00—9:00(28—36 时刻)内的绝对误差相对较大,反应电力负荷存在较强的波动性。其中,GRU 与 SVR 分别达到 65%和 75%,这说明在该时刻采用单一模型难以表征负荷波动趋势,以致出现较大误差。而反观 EGR 和 EWT-GRU 误差均稳定在 10%以内,体现出组合模型的优势。分析图 4(b)和表 5 可知,对低频分量采用岭回归的预测模型 EGR 要比对低频分量采用 GRU 的预测模型 EWT-GRU 预测效果好,预测曲线也更加拟合实际负荷曲线;与 EWT-GRU 相比,EGR 的 MAPE 值和 RMSE 值分别减小 0.197%和 2.239 kW。但在实际应用过程中,低频分量采用神经网络会对模型增加不必要的负担,EGR 较高的预测精准度和较快的预测速度更加符合电力系统的经济运行与实际负荷预测应用。

3.3.2 组合模型间的对比分析

为进一步验证所提预测模型 EGR 的精确性,本研究采用经验模态分解法(empirical mode decomposition,EMD)同 EWT 进行多模型对比。按照文献[9]所述方式区分模态分解出的高频与低频分量,将过零率




图 2 EWT 负荷分量图

Fig. 2 Diagram of load component with EWT




图 3 EMD 负荷分量图

Fig. 3 Diagram of load component with EMD

不大于 0.02 的设置 of 低频分量,各分量过零率如图 6 所示。其中,将 EMD 分量中的 I_{MF4} 、 I_{MF5} 、 I_{MF6} ,EWT 分量中的 F_0 、 F_1 定义为低频分量,其余分量定义为高频分量。多模型预测负荷曲线结果如图 7 所示,多模型预测绝对误差对比如图 8 所示,多模型预测误差及运行时间如表 6 所示。

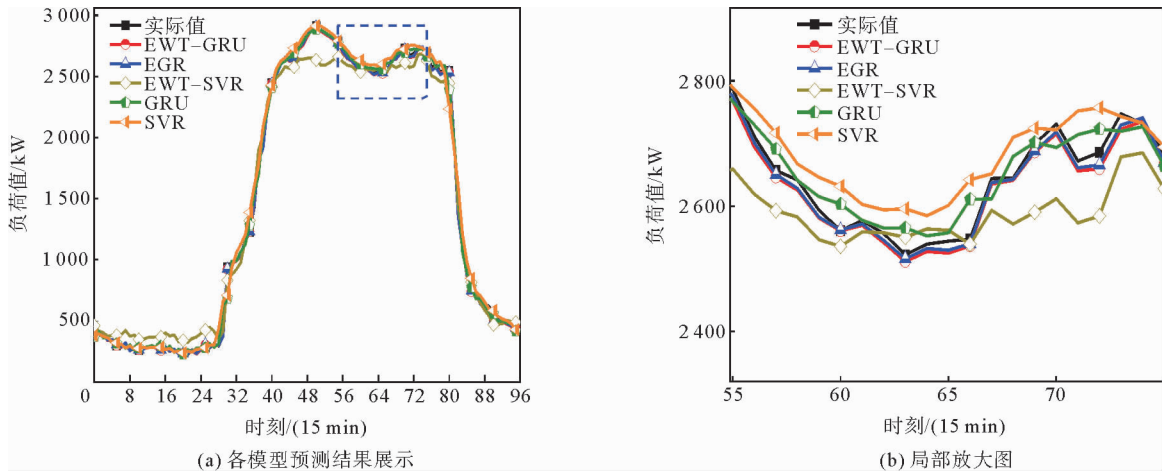


图 4 单模型预测结果

Fig. 4 Single model prediction results

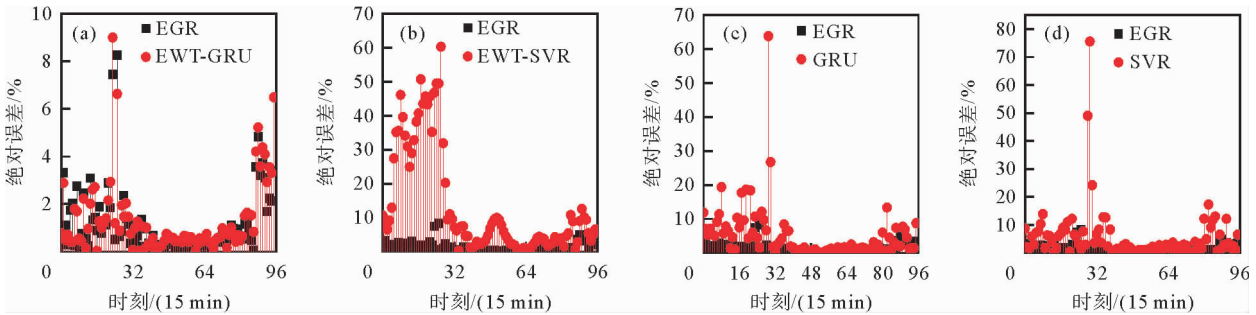


图 5 单模型绝对误差对比

Fig. 5 Single model absolute error comparison

表 5 单模型预测误差

Table 5 Forecasting error of single model

评价指标	EWT-GRU	GRU	EWT-SVR	SVR	EGR
RMSE/kW	1.321	5.007	13.461	5.598	1.124
MAPE/%	13.594	55.980	101.353	76.309	11.355

1) 由图 7(a)可知,各模型预测负荷曲线与实际负荷曲线的趋势大致吻合,但是个别时段(如图 7(a)中的(1)处)各模型的预测能力差异明显。同时,从图 7(b)可以看出,应用不同分解方法得到的负荷预测曲线趋势均不相同。其中,EMD-GRU、EMD-GRU-RR 和 EMD-RBF-RR 的预测曲线趋势相对于 EWT-GRU、EGR 表现较差。

2) 如图 8 所示,整体来看,采用 EMD 的组合预测模型整体误差偏大;局部来看,EGR 的最大绝对误差较 EMD-GRU、EMD-GRU-RR、EMD-RBF-RR 减少了 70% 以上,预测效果较优。进一步,由表 6 可知,由于 EMD 的分解个数偏多,使得运行速度变慢,EGR 较 EMD-GRU-RR 模型在运行时间上减少了 110.6 s,同时,由于低频分量采用岭回归预测模型,使得 EGR 较 EWT-GRU 减少了 73.753 s。因此采用 EWT 和岭回

归的 EGR 预测模型在保证预测精度的同时提高了运行速度,具有良好的稳定性。

3) 由表 6 可知,相较于 EMD-GRU, EWT-GRU 的 MAPE 值和 RMSE 值分别减小 72.7% 和 73.7%。因此,采用 EWT 进行负荷分解得到的预测结果更加准确。同时,从图 7(c) 可以看出,在低频模态分量中采用岭回归代替神经网络模型仍然可以取得可观的效果。




图 6 各分量过零率

Fig. 6 Zero-crossing rate of each component




图 7 多模型预测结果

Fig. 7 Prediction results of the multi-models

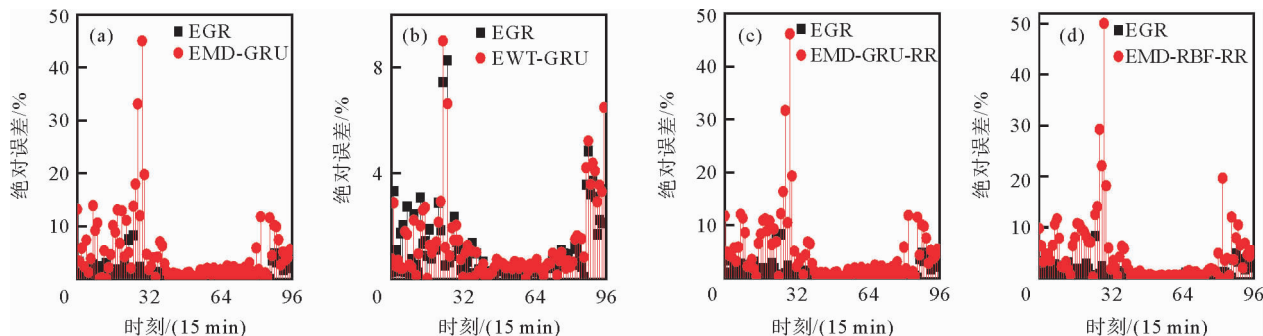


图 8 多模型绝对误差对比

Fig. 8 Comparison of absolute error of the multi-models

表 6 多模型预测误差及时间
Table 6 Forecasting error run time of multi-models

模型	MAPE/%	RMSE/kW	运行时间/s
EMD-GRU	4.839	51.746	328.272
EWT-GRU	1.321	13.594	209.855
EGR	1.124	11.355	136.102
EMD-GRU-RR	4.816	51.061	246.702
EMD-RBF-RR	4.821	52.340	306.000

4 结论

针对目前短期电力负荷预测中气象因素难以充分利用和单一负荷预测模型难以精准预测的问题,本研究提出一种组合预测模型,并通过仿真实验进行验证,得出以下结论。

1) 采用 EWT 对负荷数据进行分解,一方面减少了模态分量个数,降低了后续组合预测模型的运算规模;另一方面,对不同频率的模态分量采用不同预测模型,一定程度上减少了算法的时间复杂度。

2) 采用岭回归与神经网络 GRU 组合预测,不仅能够精准把握短期负荷周期稳定成分的变化趋势,更能实现受外界因素扰动非稳定成分的准确预测。与单一预测模型和基于 EWT 或 EMD 的组合预测模型相比,本研究所提模型在预测精度上有了明显的提高。

在今后的工作中,可进一步借鉴人工智能和深度学习领域的前沿技术,简化预测模型的操作步骤,提高运行效率。

参考文献:

[1] 徐蕙,陈平,李海涛,等. MPSR-MKSVM 电力负荷预测综合优化策略[J]. 电测与仪表,2022,59(1):77-83.
XU Hui,CHEN Ping,LI Haitao, et al. Comprehensive optimization strategy of power load forecasting based on MPSR-MKSVM[J]. Electrical Measurement & Instrumentation,2022,59(1):77-83.

[2] 郭傅傲,刘大明,张振中,等. 基于特征相关分析修正的 GPSO-LSTM 短期负荷预测[J]. 电测与仪表,2021,58(6):39-48.
GUO Fuao,LIU Daming,ZHANG Zhenzhong, et al. GPSO-LSTM short-term load forecasting based on feature correlation analysis and correction[J]. Electrical Measurement & Instrumentation,2021,58(6):39-48.

[3] 张淑清,段晓宁,张立国,等. Tsne 降维可视化分析及飞蛾火焰优化 ELM 算法在电力负荷预测中应用[J]. 中国电机工程学报,2021,41(9):3120-3130.
ZHANG Shuqing,DUAN Xiaoning,ZHANG Liguó, et al. Tsne dimension reduction visualization analysis and moth flame optimized ELM algorithm applied in power load forecasting[J]. Proceedings of the CSEE,2021,41(9):3120-3130.

[4] 杨智宇,刘俊勇,刘友波,等. 基于自适应深度信念网络的变电站负荷预测[J]. 中国电机工程学报,2019,39(14):4049-4061.
YANG Zhiyu,LIU Junyong,LIU Youbo, et al. Transformer load forecasting based on adaptive deep belief network[J]. Proceedings of the CSEE,2019,39(14):4049-4061.

[5] 赵佩,代业明. 基于实时电价和加权灰色关联投影的 SVM 电力负荷预测[J]. 电网技术,2020,44(4):1325-1332.
ZHAO Pei,DAI Yeming. Power load forecasting of SVM based on real-time price and weighted grey relational projection algorithm[J]. Power System Technology,2020,44(4):1325-1332.

[6] 郑睿程,顾洁,金之俭,等. 数据驱动与预测误差驱动融合的短期负荷预测输入变量选择方法研究[J]. 中国电机工程学报,2020,40(2):487-500.
ZHENG Ruicheng,GU Jie,JIN Zhijian, et al. Research on short-term load forecasting variable selection based on fusion of data driven method and forecast error driven method[J]. Proceedings of the CSEE,2020,40(2):487-500.

[7] 史佳琪,张建华. 基于多模型融合 Stacking 集成学习方式的负荷预测方法[J]. 中国电机工程学报,2019,39(14):4032-4042.

- SHI Jiaqi,ZHANG Jianhua. Load forecasting based on multi-model by stacking ensemble learning[J]. Proceedings of the CSEE,2019,39(14):4032-4042.
- [8] 吴松梅,蒋建东,燕跃豪,等. 基于 VMD-PSO-多核极限学习机的短期负荷预测[J]. 电力系统及其自动化学报,2022,34(5):18-25.
- WU Songmei,JIANG Jiandong,YAN Yuehao, et al. Short-term load forecasting based on VMD-PSO-multi-core extreme learning machine [J]. Proceedings of the CSU-EPSSA,2022,34(5):18-25.
- [9] 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(02):593-602.
- [10] 李滨,陆明珍. 考虑实时气象耦合作用的地区电网短期负荷预测建模[J]. 电力系统自动化,2020,44(17):60-68.
- LI Bin,LU Mingzhen. Short-term load forecasting modeling of regional power grid considering real-time meteorological coupling effect[J]. Automation of Electric Power Systems,2020,44(17):60-68.
- [11] GILLES,J. Empirical wavelet transform[J]. IEEE Transactions on Signal Processing,2013,61(16):3999-4010.
- [12] 马磊,黄伟,李克成,等. 基于 Attention-LSTM 的光伏超短期功率预测模型[J]. 电测与仪表,2021,58(2):146-152.
- MA Lei,HUANG Wei,LI Kecheng, et al. Photovoltaic ultra short-term power forecasting model based on Attention-LSTM[J]. Electrical Measurement & Instrumentation,2021,58(2):146-152.
- [13] 生西奎,付强,于洋,等. 基于深度学习 GRU 网络的配电网理论线损计算方法[J]. 电测与仪表,2021,58(3):54-59.
- SHENG Xikui,FU Qiang,YU Yang, et al. Distribution network line loss calculation method based on deep learning GRU network[J]. Electrical Measurement & Instrumentation,2021,58(3):54-59.
- [14] ZHENG J,CHEN X,YU K, et al. Short-term power load forecasting of residential community based on GRU neural network[C]//2018 International conference on power system technology (POWERCON). IEEE,2018:4862-4868.
- [15] 杜涵潇,汤旻安. 基于 CEEMD-RSVPSO-KELM 的用户侧微电网短期负荷预测[J]. 电测与仪表,2020,57(18):69-76.
- DU Hanxiao,TANG Min'an. Short-term load forecasting for user-side micro-grid based on CEEMD-RSVPSO-KELM model[J]. Electrical Measurement & Instrumentation,2020,57(18):69-76.
- [16] 吴云,雷建文,鲍丽山,等. 基于改进灰色关联分析与蝙蝠优化神经网络的短期负荷预测[J]. 电力系统自动化,2018,42(20):67-72.
- WU Yun,LEI Jianwen,BAO Lishan, et al. Short-term load forecasting based on improved grey relational analysis and neural network optimized by bat algorithm[J]. Automation of Electric Power Systems,2018,42(20):67-72.
- [17] 秦海超,王玮,周晖,等. 人体舒适度指数在短期电力负荷预测中的应用[J]. 电力系统及其自动化学报,2006,18(2):63-66.
- QIN Haichao,WANG Wei,ZHOU Hui, et al. Short-Term electric load forecast using human body amenity indicator[J]. Automation of Electric Power Systems,2006,18(2):63-66.

(责任编辑:傅 游)