

基于EMD-GRU的短期电力负荷预测方法

卢武, 郑人杰, 赵文彬, 唐佳圆

(上海电力大学 电气工程学院, 上海 200090)

摘要: 高效精准的短期负荷预测对电力系统安全稳定运行至关重要。提出一种基于经验模态分解(EMD)和门控循环单元(GRU)的组合预测模型。首先选取日期因素、气象因素和历史负荷因素构建输入特征集;再利用EMD算法将随机性强的历史负荷数据分解为有限个特征互异的固有模态函数分量和趋势分量,并和日期因素、气象因素一起作为GRU网络的输入;采用2层GRU循环网络增加网络深度,提升模型学习能力,对各分量数据分别预测并叠加重构输出预测值。以我国某地负荷数据为实际算例,实验结果表明,采用该方法预测误差仅为6.11%,相较于GRU网络模型和BP神经网络模型,预测精度得到巨大提升;相较于EMD-LSTM网络模型,在预测精度相差0.04%的情况下,预测时长缩短25.99%,训练效率得到显著提升。

关键词: 短期负荷预测; 时间序列; 经验模态分解; 门控循环单元

中图分类号: TM28 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqed23228

Short-term Power Load Forecasting Method Based on EMD-GRU

LU Wu, ZHENG Renjie, ZHAO Wenbin, TANG Jiayuan

(College of Electric Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: Efficient and accurate short-term load forecasting is essential to the safe and stable operation of the power system. A combined prediction model based on empirical mode decomposition (EMD) and gated recurrent unit (GRU) was proposed. First, the date factors, meteorological factors and historical load factor were selected to construct the input feature set; then the EMD algorithm was used to decompose the strong random history load data into a limited number of inherent modal function components and trend components with different features, together with date factors and meteorological factors as the input of the GRU. Double-layer GRU recurrent network design was adopted to increase the depth of the network to enhance the model learning ability, and each component data was separately predicted and superimposed to reconstruct the output prediction value. Taking the load data of a certain place in China as an actual calculation example, the experimental results illustrate that the prediction error of this method is only 6.11%, which is greatly improved compared with the GRU network model and the BP neural network model. Compared with the EMD-LSTM network model, when the prediction accuracy differs by 0.04%, the prediction time is shortened by 25.99%, and the training efficiency is significantly improved.

Key words: short-term load forecasting; time series; empirical mode decomposition(EMD); gated recurrent unit(GRU)

电力系统安全运行要求发电量与用电量维持动态平衡,但电网自身无法大规模储备能量,负荷又具有随机波动性强、影响因素多的特点。精准的负荷预测有利于电网工作人员掌握负荷变化规律,制定合理的电力生产、电网检修计划,达到电力系统安全稳定、经济高效的运行目的。

目前,负荷预测的方法主要可分为统计预测法和机器学习法。统计预测法^[1]结合历史负荷数据与现有资料,线性研究未来负荷的发展趋势,主要包括多元线性回归法^[2]、卡尔曼滤波^[3]和灰色预测模型^[4]等,此类模型操作简易、计算用时短,但对时间序列平稳要求高,难以反映非线性因素

基金项目: 国家自然科学基金资助项目(51707113)

作者简介: 卢武(1991—),男,博士,讲师,Email:wuluee@shiep.edu.cn

通讯作者: 赵文彬(1977—),男,博士,高级工程师,Email:wenbinmax@163.com

的影响。机器学习法包括支持向量机^[5]、人工神经网络算法等,这些算法解决了统计预测法非线性能力处理弱的问题,但支持向量机面对大规模数据时计算时间长、训练效率低。人工神经网络通过模拟人脑传递信息的过程,具有很强的并行分布处理能力,能够学习自变量与应变量间的非线性关系,文献[6]采用反向传播神经网络(back propagation neural network, BPNN)结合工业、农业、轻工业总产值及人口数的影响,建立上海某镇负荷预测模型;文献[7]引入小波作为隐含层的传递函数构建小波神经网络,解决了传统模型预测时间慢的问题。但研究者发现人工神经网络(artificial neural network, ANN)不具备学习时间序列相关性的能力,需要人为提取时序特征,人为干预会破坏负荷连续性,降低预测精度。短期负荷预测是研究随机非线性时间序列发展趋势的问题,统计预测法和机器学习法的局限性导致模型拟合精度较差,预测精度有限。

近年来深度学习算法发展迅速,为预测领域研究提供了新思路。文献[8]提出深度神经网络(deep neural network, DNN)具有更多隐藏层,模型可靠性、预测精度提升,但是面对多类型实值输入数据时处理能力有待提升;循环神经网络(recurrent neural network, RNN)能够降低人为提取时间序列特征时对负荷连续性的破坏,更好地适应数据非线性特征,但是会随着时间序列增加出现梯度消失的情况;文献[9]提出长短期记忆神经网络(long short-term memory, LSTM)能够有效降低负荷输入维度,增强时序建模能力,但存在训练用时过长的的问题;门控循环单元(gated recurrent unit, GRU)是一种基于LSTM的变体^[10],具有更灵活简单的结构,在保障精确度的同时能够大幅缩短预测时长,GRU网络通过引入更新门的设计,解决了RNN网络预测中长期时间序列时梯度消失的问题,因此在电力系统短期负荷预测得到广泛应用。

针对电力系统负荷随机波动性强、趋势不显著的特点,本文提出一种基于经验模态分解(empirical mode decomposition, EMD)的门控循环单元神经网络负荷预测方法,记作EMD-GRU混合神经网络。该方法首先利用EMD算法将原本随机、非线性的短期负荷数据分解为有限个固有模态函数和趋势分量,分解后的序列特征互异,再利用GRU网络对相互影响降低的分量分别预测,

最后通过叠加重构分量得到预测结果,完成短期负荷预测。文中以我国某地区历史负荷数据作为算例进行预测,结果表明相较于其他预测方法具备更高精度和效率。

1 负荷输入特征集的构建

电力负荷与社会生活作息、气象条件密切相关,充分考虑敏感因素构建输入特征集,将最大程度提升负荷预测精度,文中采用下式表示负荷:

$$P(t) = P_d(t) + P_w(t) + P_h(t) \quad (1)$$

式中: $P(t)$ 为实际负荷值; $P_d(t)$ 为日期因素引起的负荷变化; $P_w(t)$ 为气象因素引起的负荷变化; $P_h(t)$ 为依据历史负荷数据完成的负荷预测值。

由此,构建以下输入特征集:

1)日期因素。根据生活作息方式可将日期分为工作日、公休日和节假日,不同日期因素对工业用电影响明显。基于此,构建的日期因素包括周日期和工作类型日期。

2)气象因素。电力负荷中用电设备种类繁多,空调、地暖等受气象因素影响大的设备比重逐年增加。基于此,构建气象因素时包括最高温度、日最低温度、日平均温度、相对湿度以及日降雨量。

3)历史负荷因素。模型可以根据一定时间段的历史负荷数据,学习其近期变化规律和特征,预测未来短期内的负荷值。

因此,文中构建包括日期因素、气象因素和历史负荷因素在内共8维特征向量作为输入,具体如表1所示。

表1 输入特征集

Tab.1 Input feature set

影响因素	具体特征项	特征构成描述
日期因素	周日期	1~7分别代表周一~周日
	工作类型日期	1~3分别代表工作日、公休日和节假日
气象因素	最高温度	当日最高温度/℃
	最低温度	当日最低温度/℃
	平均温度	当日平均温度/℃
	相对湿度	当日相对湿度/RH%
历史负荷因素	降雨量	当日降雨量/mm
	历史负荷	历史负荷数据/MW

2 EMD-GRU 学习模型

2.1 经验模态分解

经验模态分解^[11-13]是一种具备自适应能力的信号分析方法,被广泛应用于数据处理与数据挖

掘领域,尤其适用于非线性非平稳时间序列的研究。EMD算法可以将原始信号序列分解为若干不同频率和趋势的固有模态函数(intrinsic mode function, IMF)和一个趋势分量 r_k ,分解所得的IMF是一系列具备相对固定波动周期、能够反映原始信号特征的独立分量,具体满足以下条件:1)极值点数量和过零点数量相差不超过1;2)任意时间节点,信号局部最大值和局部最小值所定义的上下包络线均值为0。

算法流程如图1所示。

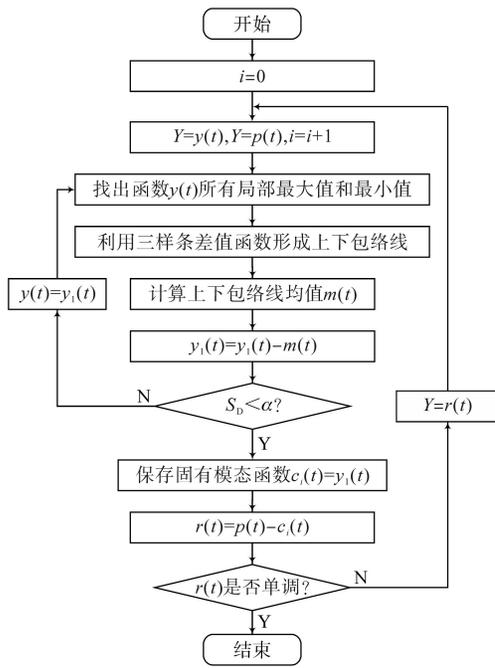


图1 EMD算法流程图

Fig.1 EMD algorithm flow chart

具体分解过程如下所示。

步骤1):计算原始信号序列 $y(t)$ 的所有局部极值点,利用三次样条插值函数形成上包络线 $m_{\max}(t)$ 和下包络线 $m_{\min}(t)$;

步骤2):计算上下包络线的均值 $m(t)$ 即

$$m(t) = [m_{\max}(t) + m_{\min}(t)]/2 \quad (2)$$

步骤3):计算原始信号序列 $y(t)$ 和上下包络线均值 $m(t)$ 的差值,得到去除低频成分的新序列 $y_1(t)$ 即

$$y_1(t) = y(t) - m(t) \quad (3)$$

步骤4):若 $S_D \geq \alpha$,则令 $y(t)=y_1(t)$ 并重复步骤1)~步骤3)直到 $S_D < \alpha$,其中:

$$S_D = \frac{\sum |y_1(t) - y(t)|^2}{\sum y(t)} < \alpha \quad (4)$$

式中: α 一般可取0.2~0.3的任意数,本文取

$\alpha=0.2$ 。

步骤5):当满足式(4)后,此时的 $y_1(t)$ 就是固有模态函数第 i 个IMF,计为 $c_i(t)$,残余分量 $r(t)$ 可由原始信号数据 $p(t)$ 减去 $c_i(t)$ 获得:

$$r(t) = p(t) - c_i(t) \quad (5)$$

重复以上步骤,可将原始信号分解为 i 个IMF分量和1个趋势分量 r_k , r_k 为单调函数代表负荷的平均趋势,最终原始信号序列 $y(t)$ 经EMD算法分解后可表示为

$$y(t) = \sum c_i(t) + r_k \quad (6)$$

2.2 GRU神经网络原理

LSTM神经网络有效解决了传统RNN网络梯度消失的问题^[4],在时间序列预测领域应用成效良好,但存在内部结构复杂、训练费时的问题,GRU^[15]网络针对以上缺点优化改良,在保留LSTM预测精度前提下,采用缩减门控神经网络结构参数的方式提升模型训练效率。作为LSTM的变体,GRU优化内部单元结构,集成遗忘门和输出门为单一的更新门,因此GRU网络只包含重置门 r_t 和更新门 z_t 。GRU结构如图2所示。

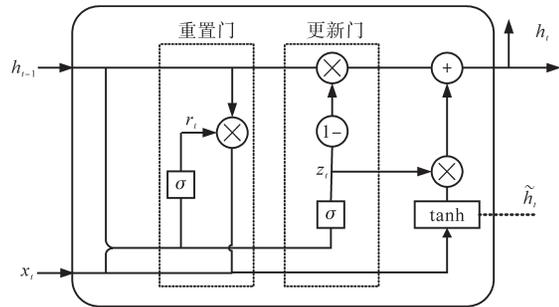


图2 GRU结构图

Fig.2 GRU structure diagram

GRU数学描述如下:

$$z_t = \sigma(W_z x_t + U_z h_{t-1}) \quad (7)$$

$$r_t = \sigma(W_r x_t + U_r h_{t-1}) \quad (8)$$

$$\tilde{h}_t = \tanh(r_t \circ U h_{t-1} + W x_t) \quad (9)$$

$$h_t = (1 - z_t) \circ \tilde{h}_t + z_t \circ h_{t-1} \quad (10)$$

式中: x_t 为 t 时刻输入变量; h_{t-1} 为上一隐藏层输出结果; \tilde{h}_t 为 x_t 和 h_{t-1} 的汇总; h_t 为本单元隐藏层输出结果; W_z, W_r, W, U_z, U_r, U 为可训练参数矩阵; $\mathbf{1}$ 为单位矩阵; \circ 为复合关系; σ 为sigmoid激活函数, σ 和 \tanh 数学描述如下所示:

$$\sigma(x) = 1/(1 + e^{-x}) \quad (11)$$

$$\tanh = (e^x - e^{-x})/(e^x + e^{-x}) \quad (12)$$

GRU模型核心模块是更新门 z_t 和重置门 r_t 。

输入变量 x_t 与上一隐藏层输出结果 h_{t-1} 的拼接矩阵经 $\sigma(x)$ 激活函数非线性变化后输入至更新门中,用于控制前一时刻信息被保留到当前状态的程度;重置门控制当前状态与先前时刻信息的结合程度,输出结果 h_t 为 $1-z_t$ 倍上一隐藏层输出结果 h_{t-1} 和 z_t 倍待定输出值 \tilde{h}_t 之和。

2.3 基于EMD-GRU的混合神经网络模型

本文提出的EMD-GRU混合神经网络模型,首先收集整理并清洗日期因素、气象因素和历史负荷因素相关数据,随后将历史负荷数据输入至EMD算法中分解,分解结果同日期因素和气象因素一起输入到GRU模型进行训练,最后得到预测结果并与测试集数据对比验证,具体过程如图3所示:

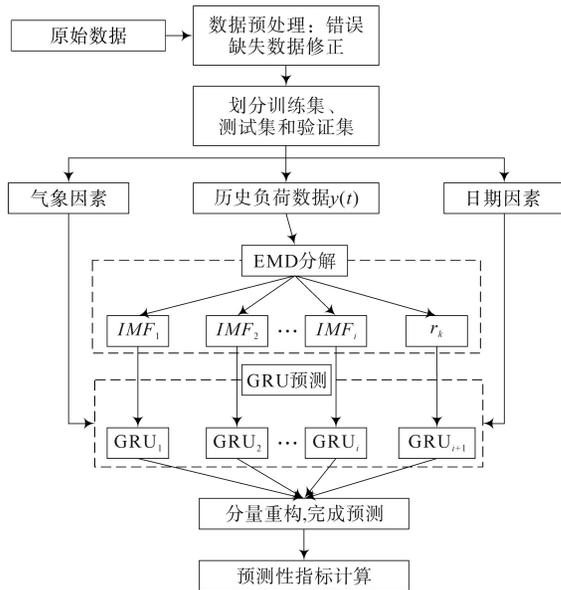


图3 EMD-GRU组合预测模型流程图
Fig.3 EMD-GRU combined prediction model flow chart
具体步骤如下:

步骤1): 数据处理。收集整理日期、气象和历史负荷数据,完成错误、缺失数据的修正,并将处理后的数据划分成训练集、验证集和测试集。

步骤2): 经验模态分解。采用EMD算法将历史负荷数据 $y(t)$ 分解为 i 个固有模态函数 $\{IMF_1, IMF_2, \dots, IMF_i\}$ 和 1 个趋势分量 $\{r_k\}$ 。考虑到分解后数据数值差异较大不利于GRU模型训练,采用min-max归一法对输入特征集数据归一化处理^[6],将数值缩放在0~1之间,计算公式如下所示:

$$x^* = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (13)$$

式中: x^* 为归一化后的数据; x 为输入数据; x_{\min}, x_{\max} 分别为输入数据中的最小值和最大值。

步骤3): GRU模型时序预测。建立基于GRU的预测模型,具体流程如图4所示,将EMD分解结果和日期因素、气象因素作为GRU网络的输入,采用2层循环网络设计提升学习能力,通过全连接层将双层GRU网络中提取的高维特征和时序信息降维,整合特征样本完成映射,起数据降维与结果输出的作用。分别对IMF分量和趋势分量进行预测,得到分量预测值后通过叠加重构获得最终的负荷预测值。

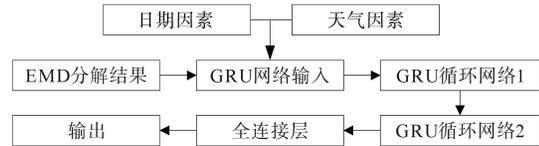


图4 GRU网络流程图

Fig.4 GRU network flow chart

步骤4): 模型预测评价。当模型训练次数满足最大迭代次数后,通过预测值和实际值的误差度量模型准确性,选用平均百分误差^[17](mean absolute percentage error, MAPE)、均方根误差^[18](root mean square error, RMSE)作为评价标准。MAPE属于绝对指标,不随负荷数量级变化而改变, RMSE属于相对指标,对数据的离散程度敏感,两者数值越小表示预测效果越好。计算公式如下所示:

$$e_{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (14)$$

$$e_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (15)$$

式中: N 为待预测负荷点个数; y_i, \hat{y}_i 分别为第 i 个负荷的实际功率值和预测功率值。

3 算例分析

本文数据集选取我国某地2014年6月1日至2014年8月30日共8 640个历史负荷数据(采样频率15 min),并同时提取日期因素、气象因素共计8维特征向量作为研究对象。训练集、测试集和验证集按8:1:1划分。

3.1 数据样本预处理

在数据样本采集过程中,受电网检修、采样设备或人为记录错误等因素影响,会造成数据缺失、采集与记录不一致的情况,在使用前需要对“坏数据”查补修正^[19-20]。针对缺失数据可以选取相邻时段和相似日数据插补,异常数据可以采用

“图示法”和“经验修正法”修正。完成缺失数据补齐与异常数据修正的典型工作日、工休日和节假日负荷数据如图5所示。

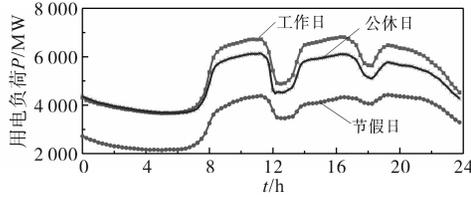


图5 经预处理的典型数据
Fig.5 Typical data preprocessed

3.2 EMD-GRU 模型参数设置

对于非线性、波动性强的时间序列,需要较多神经元才能更好的拟合序列波动细节,原则上来说GRU循环网络层数的加深就可以提升模型学习能力。在调试过程中采用控制变量法只改变网络层数,平均百分误差变化如表2所示,由表2可知GRU循环网络层数为2时平均百分误差取得最小值,当层数继续增加时,模型因过度学习出现预测误差不减反增的情况。因此GRU模型采用2层堆叠设计,神经元个数依次为256和128,初始学习率为0.001,另外采用Dropout算法防止训练时出现过拟合现象,当Dropout算法丢弃率为0.4时模型误差最小。

表2 不同GRU层数的平均百分误差

Tab.2 Mean absolute percentage error of different GRU layers

GRU层数	训练次数	$e_{MAPE}/\%$
1	75	7.28
2	75	6.11
3	75	6.49

模型训练过程采用自适应矩估计(adaptive moment estimation, Adam)优化算法^[21], Adam算法是随机梯度下降法的扩展,结合均方根传播算法和自适应梯度算法的优势,通过动量和自适应学习率提升收敛能力。在训练过程中迭代网络各神经元的权重,不断优化更新模型,使损失函数输出达到最优值,保证训练输出值接近实际值。损失函数使用均方误差(mean squared error, MSE)衡量:

$$L_{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (16)$$

3.3 EMD-GRU 预测结果

负荷时间序列经EMD算法分解得到8个IMF分量 $\{IMF_1, IMF_2, \dots, IMF_8\}$ 和1个趋势分量 $\{r_k\}$,如图6所示,其中 $IMF_1 \sim IMF_3$ 频率高,表现出强烈的随机性与波动性; $IMF_4 \sim IMF_6$ 随机性降低,呈现出

一定的周期性; IMF_7, IMF_8 和 r_k 分量趋势平缓波动小,波形逐渐接近正弦波。经EMD算法分解的IMF分量频率依次降低,规律性增强,离散型降低,趋势逐渐平稳,反映出负荷的用电特征与规律。

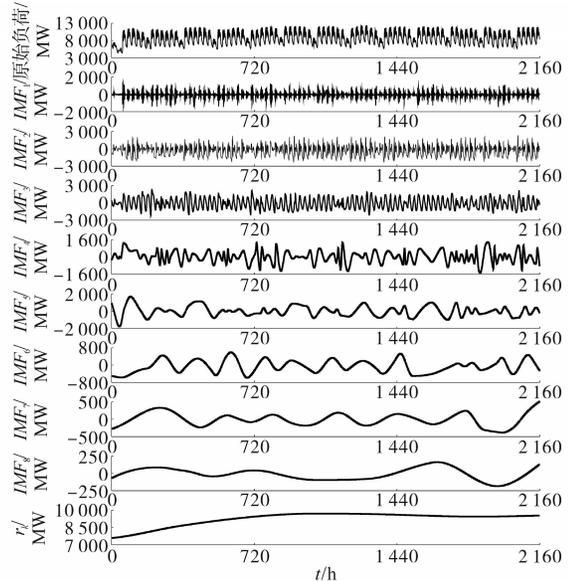


图6 原始负荷和EMD算法分解结果

Fig.6 Initial load and EMD algorithm decomposition results

GRU预测模型对8组IMF序列和1组趋势分量序列分别展开预测,将各分量预测结果叠加重构为最终负荷预测值,表3为8月29日部分负荷真实值及预测值。

表3 随机选取部分预测日真实值及预测值

Tab.3 True and predicted values of some predicted days were randomly selected

时刻	实际值/ MW	预测值/ MW	时刻	实际值/ MW	预测值/ MW
0:00	8 170.75	8 520.22	12:00	9 936.27	9 401.27
1:00	7 901.40	8 251.52	13:00	9 510.29	10 393.42
2:00	7 666.47	8 121.33	14:00	11 396.90	12 327.97
3:00	7 411.07	7 963.70	15:00	11 709.80	12 305.10
4:00	7 200.84	7 465.82	16:00	11 842.80	12 588.25
5:00	7 040.97	7 381.51	17:00	11 512.80	10 703.27
6:00	6 911.79	7 299.31	18:00	9 496.99	10 013.54
7:00	7 048.85	7 827.61	19:00	10 235.70	10 734.45
8:00	9 045.58	9 747.54	20:00	10 302.30	10 860.53
9:00	11 102.50	12 205.40	21:00	10 066.80	10 428.85
10:00	11 520.60	12 448.79	22:00	9 484.43	9 800.95
11:00	11 720.30	12 536.75	23:00	8 863.49	8 274.93

图7为预测日平均百分误差和均方根误差统计,整体来看即使是在负荷波动最为剧烈时段,EMD-GRU模型预测误差基本都能控制在10%以内,表现出稳定的预测能力,对于各时刻实际负荷都有较高的拟合度。

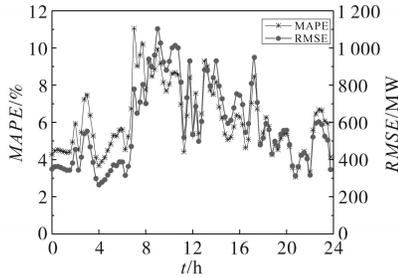


图7 预测日误差统计

Fig.7 Forecast day error statistics

3.4 预测结果分析

为体现本文算法有效性和准确性,分别采用EMD-LSTM,GRU,BP神经网络模型和本文提出的EMD-GUR模型进行预测对比。

为保证对比实验客观,对比模型参数设置最优数值,其中EMD-LSTM模型和GRU模型的层数、训练次数、损失函数等参数与EMD-GRU模型保持一致;BP神经网络设置参数如下:隐藏层神经元个数128,最大训练次数1000,损失函数MSE,激活函数ReLU,学习率0.001。

实验结果为各模型执行20次实验的均值,采用 e_{MAPE} 、 e_{RMSE} 和预测时长评估不同模型预测精度和训练效率,其中EMD-GRU和EMD-LSTM模型预测时长为预测9个分量的总用时。具体结果如表4所示。

表4 模型预测效果评估

Tab.4 Evaluation of model prediction effectiveness

模型方法	评估指标		
	$e_{MAPE}/\%$	e_{RMSE}/MW	预测时长/s
EMD-GRU模型	6.11	586.37	9×188.38
EMD-LSTM模型	6.07	593.26	9×254.52
GRU模型	8.02	753.50	1×192.38
BP模型	10.22	983.54	1×325.66

由表4可知,相比于传统GRU网络模型,文中所提的EMD-GRU神经网络模型均方根误差下降了167.13 MW,平均百分误差降低了1.91%;与BP神经网络相比均方根误差下降了397.17 MW,平均百分误差降低了4.11%;与EMD-LSTM模型相比,在预测精度几乎保持相同的情况下,EMD-GRU模型缩短了25.99%的预测时长,训练效率得到显著提升。

另外,记预测精度小于7%的结果为优质预测点^[22],各模型优质预测点统计结果如图8所示,其中EMD-GRU优质预测点共计70个,占有所有预测点的73%,比EMD-LSTM模型、GRU模型、BP模型多3个、18个、35个,单点预测质量具有明显优势。

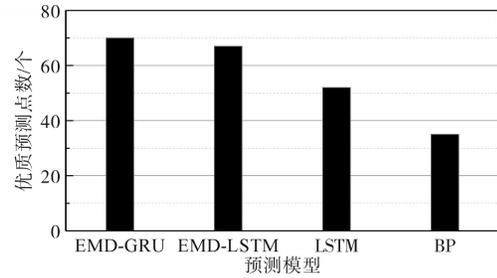


图8 各模型优质预测达标个数

Fig.8 Number of high quality prediction standards for each model

综上所述,综合整体预测精度和单点预测质量,文中采用的EMD-GRU混合神经网络模型表现良好,较其他网络模型预测性能均有提升。

4 结论

本文提出一种基于EMD-GRU的混合神经网络模型,该方法适用于非线性、波动性强的负荷序列,并在实际案例中表现出良好的预测性能。

1)充分考虑影响电网负荷波动的敏感因素,构建了包括日期因素、气象因素和历史负荷因素的输入特征集。

2)EMD算法能将波动性强的负荷分解成更为平稳的分量负荷,GRU网络模型能高效识别负荷的时序特性,EMD-GRU模型综合两种算法的优势,细致把握并充分学习负荷的细节变化,极大程度的提升模型性能。

3)通过对比实验证明,相较于EMD-LSTM、GRU和BP神经网络模型,文中所提的EMD-GRU能够在保持较高预测效率的同时,具有更高的预测精度。

参考文献

[1] 郭虹,李壮举.基于中央空调的几种负荷预测方法对比分析[J].建筑热能通风空调,2020,39(9):1-5.
Guo Hong, Li Zhuangju. Comparison and analysis of several load forecasting methods based on central air conditioning[J]. Building Energy & Environment, 2020, 39(9): 1-5.

[2] 谢毓广,刘童,陈凡,等.基于置信度理论和多元线性回归方程的电网负荷预测[J].电工技术,2018(13):42-45.
Xie Yuguang, Liu Tong, Chen Fan, et al. Network load forecasting based on confidence theory and multiple linear regression equation[J]. Electric Engineering, 2018(13): 42-45.

[3] 王科,陈丽华.基于卡尔曼滤波的节假日短期负荷预测[J].电气技术,2014(1):4-6.
Wang Ke, Chen Lihua. Short-term holiday load forecasting based on Kalman filter[J]. Electrical Engineering, 2014(1):4-6.

[4] 李春涛,李啸懿,袁辉,等.基于改进灰色模型的短期负荷

- 预测[J]. 电气开关, 2017, 55(2): 11-13, 96.
- Li Chuntao, Li Xiacong, Yuan Hui, *et al.* Short-term load forecasting based on improved grey model[J]. Electric Switchgear, 2017, 55(2): 11-13, 96.
- [5] 魏立兵, 赵峰, 王思华. 基于人群搜索算法优化参数的支持向量机短期电力负荷预测[J]. 电测与仪表, 2016, 53(8): 45-49, 74.
- Wei Libing, Zhao Feng, Wang Sihua. Short-term power load forecasting of support vector machine based on parameters optimization of population search algorithm[J]. Electrical Measurement & Instrumentation, 2016, 53(8): 45-49, 74.
- [6] 周中明, 李建平, 张鑫, 等. ANN在电力系统中期负荷预测中的应用[J]. 电力系统及其自动化学报, 2003, 15(2): 36-39.
- Zhou Zhongming, Li Jianping, Zhang Xin, *et al.* The application of ANN in middle term load forecasting of power system[J]. Proceedings of the CSU-EPSA, 2003, 15(2): 36-39.
- [7] 王伟. 基于小波神经网络的电力系统负荷预测[J]. 科技创业月刊, 2017, 30(5): 138-140.
- Wang Wei. Power system load forecasting based on wavelet neural network[J]. Pioneering with Science & Technology Monthly, 2017, 30(5): 138-140.
- [8] 孔祥玉, 郑锋, 鄂志君, 等. 基于深度信念网络的短期负荷预测方法[J]. 电力系统自动化, 2018, 42(5): 133-139.
- Kong Xiangyu, Zheng Feng, E Zhijun, *et al.* Short-term load based on deep belief network [J]. Automation of Electric Power Systems, 2018, 42(5): 133-139.
- [9] 张宇航, 邱才明, 贺兴, 等. 一种基于LSTM神经网络的短期用电负荷预测方法[J]. 电力信息与通信技术, 2017, 15(9): 19-25.
- Zhang Yuhang, Qiu Caiming, He Xing, *et al.* Short-term load forecasting based on LSTM neural network[J]. Electric Power Information and Communication Technology, 2017, 15(9): 19-25.
- [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] 王飞林, 崔双喜, 杜玉婵, 等. 风光储出力波动抑制策略[J]. 电气传动, 2020, 50(9): 66-71.
- Wang Feilin, Cui Shuangxi, Du Yuchan, *et al.* Fluctuation suppression strategy of scenery storage output[J]. Electric Drive, 2020, 50(9): 66-71.
- [12] 李雨琪, 杨明, 柴娜, 等. 基于转速信号的电机轴承故障诊断方法[J]. 电气传动, 2019, 49(9): 92-96.
- Li Yuqi, Yang Ming, Chai Na, *et al.* Fault diagnosis method of motor bearing using speed signal[J]. Electric Drive, 2019, 49(9): 92-96.
- [13] Qu Zhiguo, Sun Hanrong, Zheng Min. An efficient quantum image steganography protocol based on improved EMD algorithm[J]. Quantum Information Processing, 2021, 20(2): 1-29.
- [14] 陈振宇, 刘金波, 李晨, 等. 基于LSTM与XGBoost组合模型的超短期电力负荷预测[J]. 电网技术, 2020, 44(2): 614-620.
- Chen Zhenyu, Liu Jinbo, Li Chen, *et al.* Ultra short-term power load forecasting based on combined LSTM-XGBoost model[J]. Power System Technology, 2020, 44(2): 614-620.
- [15] 张立峰, 刘旭. 基于CNN-GRU神经网络的短期负荷预测[J]. 电力科学与工程, 2020, 36(11): 53-57.
- Zhang Lifeng, Liu Xu. Short-term load forecasting based on CNN-GRU neural network[J]. Electric Power Science and Engineering, 2020, 36(11): 53-57.
- [16] 王瑞, 周晨曦, 逯静. 基于一种组合模型的短期电力负荷预测[J]. 计算机仿真, 2018, 35(12): 396-400.
- Wang Rui, Zhou Chenxi, Lu Jing. Short-term load prediction based on a combination model[J]. Computer Simulation, 2018, 35(12): 396-400.
- [17] 李鹏, 何帅, 韩鹏飞, 等. 基于长短期记忆的实时电价条件下智能电网短期负荷预测[J]. 电网技术, 2018, 42(12): 4045-4052.
- Li Peng, He Shuai, Han Pengfei, *et al.* Short-term load forecasting of smart grid based on long-short-term memory[J]. Power System Technology, 2018, 42(12): 4045-4052.
- [18] 马天男, 王超, 彭丽霖, 等. 计及需求响应和深度结构多任务学习的电力系统短期负荷预测[J]. 电测与仪表, 2019, 56(16): 50-60.
- Ma Tiannan, Wang Chao, Peng Lilin, *et al.* Short-term load forecasting of power system considering demand response and short-term load forecasting of power system considering demand response and [J]. Electrical Measurement & Instrumentation, 2019, 56(16): 50-60.
- [19] 罗凤章, 张旭, 杨欣, 等. 基于深度学习的综合能源配电系统负荷分析预测[J]. 高电压技术, 2021, 47(1): 23-32.
- Luo Fengzhang, Zhang Xu, Yang Xin, *et al.* Load analysis and prediction of integrated energy distribution system based on deep learning[J]. High Voltage Engineering, 2021, 47(1): 23-32.
- [20] 郑海雁, 王成亮. 基于用电大数据的中长期负荷预测研究[J]. 电测与仪表, 2018, 55(13): 74-77.
- Zheng Haiyan, Wang Chengliang. Research of medium-long term load forecasting based on electricity big data[J]. Electrical Measurement & Instrumentation, 2018, 55(13): 74-77.
- [21] 王增平, 赵兵, 纪维佳, 等. 基于GRU-NN模型的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(5): 53-58.
- Wang Zengping, Zhao Bing, Ji Weijia, *et al.* Short-term load forecasting method based on GRU-NN model[J]. Automation of Electric Power Systems, 2019, 43(5): 53-58.
- [22] 谢谦, 董立红, 匡向阳. 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.

收稿日期:2021-03-17

修改稿日期:2021-04-29