

DOI: 10.11830/ISSN.1000-5013.202008003



# 注意力机制下的 EMD-GRU 短期 电力负荷预测

方娜<sup>1,2</sup>, 余俊杰<sup>1,2</sup>, 李俊晓<sup>1,2</sup>, 陈浩<sup>1,2</sup>

(1. 湖北工业大学 太阳能高效利用及储能运行控制湖北省重点实验室, 湖北 武汉 430068;  
2. 湖北工业大学 湖北省电网智能控制与装备工程技术研究中心, 湖北 武汉 430068)

**摘要:** 为进一步提高短期电力负荷预测精度,构建一种基于注意力机制的经验模态分解(EMD)和门控循环单元(GRU)混合模型,对时间序列的短期负荷进行预测. 首先,对负荷序列进行 EMD,将数据重构成多个分量;再通过 GRU 提取各分量中时序数据的潜藏特征;经注意力机制突出关键特征后,分别对各分量进行预测;最后,将各分量的预测结果叠加,得到最终预测值. 仿真结果表明:相对于 BP 网络模型、支持向量机(SVR)模型、GRU 网络模型和 EMD-GRU 模型,基于 EMD-GRU-Attention 的混合预测模型能取得更高的预测精度,有效地提高短期电力负荷预测精度.

**关键词:** 短期负荷预测; 经验模态分解; 门控循环单元; 注意力机制

**中图分类号:** TP 183      **文献标志码:** A      **文章编号:** 1000-5013(2021)06-0817-08

## Short-Term Power Load Forecasting Under EMD-GRU Attention Mechanism

FANG Na<sup>1,2</sup>, YU Junjie<sup>1,2</sup>, LI Junxiao<sup>1,2</sup>, CHEN Hao<sup>1,2</sup>

(1. Hubei Key Laboratory for High-Efficiency Utilization and Storage Operation Control of Energy Storage System,  
Hubei University of Technology, Wuhan 430068, China;  
2. Hubei Power Grid Intelligent Control and Equipment Engineering Technology Research Center,  
Hubei University of Technology, Wuhan 430068, China)

**Abstract:** In order to further improve the accuracy of short-term power load forecasting, a mixed model of empirical mode decomposition (EMD) and gated recurrent unit (GRU) based on attention mechanism is constructed to forecast short-term load of time series. Firstly, EMD is performed on the load sequence, reconstitute data into multiple components. Then, GRU is used to extract the underlying characteristics of time series data in each component. After the key features are highlighted by combining the attention mechanism, each component is predicted respectively. Finally, the forecast results of each component are superimposed to obtain the final predictive value. The simulation results show that the EMD-GRU-Attention mixed prediction model has higher forecast accuracy compared with BP network mode, support vector machine (SVR) mode, GRU network mode and EMD-GRU mode, and it can effectively improve the accuracy of short-term power load forecasting.

**收稿日期:** 2020-08-06

**通信作者:** 方娜(1979-),女,讲师,博士,主要从事电网运行监测、电力负荷的研究. E-mail:fangna@hbut.edu.cn.

**基金项目:** 国家自然科学基金青年科学基金资助项目(51809097);湖北省教育厅科学技术研究计划指导性项目(B2018044);太阳能高效利用湖北省协同创新中心开放基金资助项目(HBSKFQN2016007);湖北工业大学博士科研启动基金项目(BSQD14029)

**Keywords:** short-term load forecasting; empirical mode decomposition; gated recurrent unit; mechanism of attention

电力负荷预测在电力系统的调度运行中起着重要作用,根据预测时间可分为长期、中期和短期预测.准确的短期负荷预测不仅能帮助系统安全可靠地运行,还能减少资源浪费,提高经济效益<sup>[1]</sup>.

目前,短期电力负荷预测模型主要有统计模型和基于人工智能模型两大类.统计模型中,指数平滑法<sup>[2]</sup>难以鉴别出数据之间的转折点,在预测带有季节性的数据时,效果不好.自回归移动平均值(auto regressive moving average, ARMA)<sup>[3-4]</sup>在本质上只能捕捉线性关系,不能捕捉非线性关系.这些统计方法虽简单且速度快,但均无法很好地拟合非线性时序数据,存在局限性.在人工智能的模型中,人工神经网络(artificial neural network, ANN)<sup>[5-6]</sup>可逼近任意非线性函数,但不能挖掘出数据间的相关性,也需人为选择时间特征.长短期记忆网络(long short-term memory, LSTM)<sup>[7-11]</sup>能更精确地学习时间序列间的长期依赖性关系,解决需要人工提取时序特征和梯度消失的问题,但其收敛速度较慢.门控循环单元(gated recurrent unit, GRU)<sup>[12-13]</sup>减少运算单元,改进 LSTM,具有更快的收敛速度,并保持与 LSTM 接近的准确率. GRU 能同时兼顾负荷序列的非线性和时序性,但预测效果会因负荷序列中非平稳部分明显下降.经验模态分解(empirical modal decomposition, EMD)<sup>[14-16]</sup>降低原始电力负荷序列的非平稳性,将非平稳的负荷序列重构成一定数量、不同尺度和相对平稳的信号,当输入的时间序列较长时, GRU 在处理数据间结构的信息时不易建模,同时,也会出现丢失序列信息的问题,影响模型预测的准确率.注意力(Attention)机制<sup>[17-19]</sup>是一种资源分配机制,对输入负荷序列给予不同的权重,放大负荷序列中的重要特征,突出更加关键的特征,使其不受序列长短的影响,当模型输入负荷序列较长时,序列间相互依赖的关系也能更好地被学习分析.

为了提高负荷预测精度,本文构建一种基于注意力机制的 EMD-GRU 混合预测模型,简称 EMD-GRU-Attention 混合预测模型.

# 1 模型原理

## 1.1 EMD 数据重构

经验模态分解不用事先设立任何基函数,可直接根据数据自身的时间尺度分解信号.理论上,这种方法可分解任何类型的信号,且在分析非线性及非平稳数据时有显著的优势,十分适合处理非线性、非平稳信号.当原始信号被 EMD 之后,得到内涵模态分量( $C_i$ )和残余分量( $R_n$ ),这些分量可表征数据各时间尺度的特征,即

$$X(t)=\sum_{i=1}^n C_i+R_n. \tag{1}$$

式(1)中: $X(t)$ 为原始时间负荷序列.

过零率( $\rho$ )是分量在时间尺度内的过零次数( $n_0$ )与负荷序列长度( $l$ )的比值,计算公式为

$$\rho=\frac{n_0}{l}. \tag{2}$$

因数据量大,为较好地区分高、低频分量,定义  $\rho$  超过 0.1 为高频分量,  $\rho$  低于 0.1 为低频分量.

## 1.2 GRU 网络模型

GRU 网络模型是一种改进的循环神经网络(RNN),能捕获时间序列长短期之间的依赖关系,且成功解决 RNN 存在的梯度消失问题,内部结构简单,减少训练参数的同时,保证预测精度. GRU 基本单元,如图 1 所示.

GRU 单元更新门的输出结果为

$$z_t=\sigma(w_z\times[h_{t-1},x_t]), \tag{3}$$

$$r_t=\sigma(w_r\times[h_{t-1},x_t]), \tag{4}$$

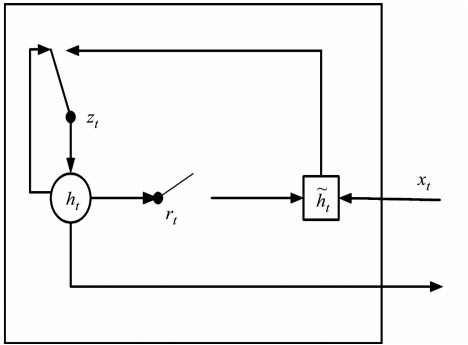


图 1 GRU 基本单元  
Fig. 1 Basic unit of GRU

$$\tilde{h}_t = \tanh(w_t \times [r_t \cdot h_{t-1}, x_t]), \tag{5}$$

$$h_t = (1 - z_t) \times h_{t-1} + z_t \times \tilde{h}_t. \tag{6}$$

式(3)~(6)中: $\sigma$ 为激活的 Sigmoid 函数; Tanh 为激活的双曲正切函数; $z_t$ 和 $r_t$ 分别为更新门和重置门; $x_t$ 为输入; $h_{t-1}$ 为上一个 GRU 单元的输出; $\tilde{h}_t$ 为收集 $h_{t-1}$ 和 $x_t$ 中所蕴含的信息; $h_t$ 为 GRU 单元最终输出.

1.3 Attention 机制

Attention 机制对特征向量分配不同的权重,对重要特征给予足够的关注,忽略无关信息,从而来突出关键特征.在 GRU 对输入数据分别进行特征提取和时序分析后,与之进行结合. Attention 机制示意图,如图 2 所示.

计算公式为

$$C = \text{Tanh}(h_t), \tag{7}$$

$$\partial = \text{Soft}_{\max}(w^T \cdot C), \tag{8}$$

$$\alpha = h_t \cdot \partial^T. \tag{9}$$

式(7)~(9)中: $w^T$ 为权重矩阵; $\alpha$ 为注意力层的输出.

最后,结果由全连接层映射,得到预测结果.




图 2 Attention 机制示意图  
Fig. 2 Schematic diagram of attention mechanism

2 EMD-GRU-Attention 混合预测模型

EMD-GRU-Attention 混合预测模型结构,如图 3 所示.图 3 中:Dense 为全连接层.

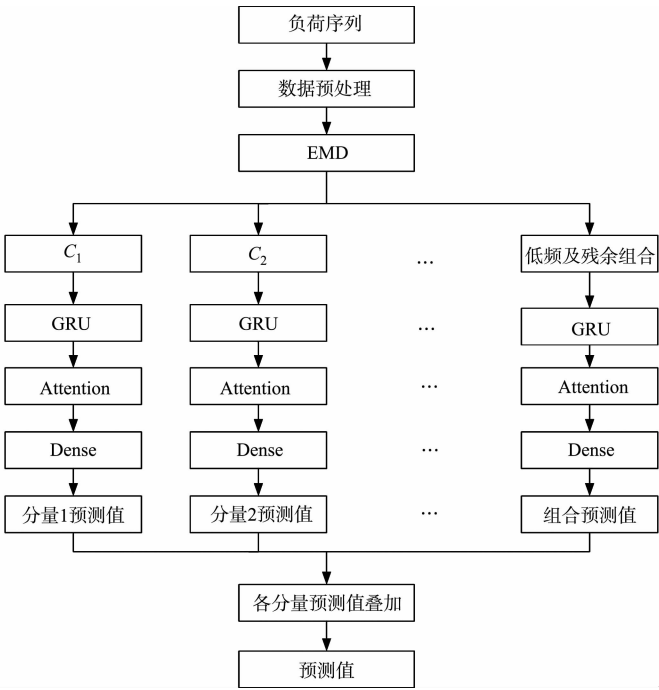


图 3 EMD-GRU-Attention 混合预测模型结构

Fig. 3 Structure of EMD-GRU-Attention in mixed prediction model

负荷序列中异常值与缺失值均以均值替代及补充,归一化处理后,利用 EMD 将数据重构成多个分量,并将尽量多的低频内涵模态分量和残余分量叠加组合,以降低模型的时间复杂度.对各高、低频内涵模态分量及残余分量组合分量以同样方式选取训练集和测试集,再分别将各分量的训练集输入 GRU 神经网络中.同时,引入 Attention 机制,经全连接层线性拟合后,输出各分量及组合分量的预测值.采用的损失函数为均方误差函数,用 Adam 优化算法对模型参数进行优化,批次为 512,训练轮数为 220,进而对模型整体进行训练确定.

运用测试集通过确定后的模型得到各分量及组合分量的预测值,将各时刻对应分量预测值叠加,得出最终各时刻的预测值,最后,用误差指标评估模型. 基于 TensorFlow-GPU 框架下设计网络结构,调用 Keras 中的函数式模型,根据上述具体参数编写代码,进行仿真.

3 算例分析与验证

3.1 数据集及数据预处理

数据集为丹麦西部 2016 年(2016 年 1 月 1 日至 2016 年 12 月 31 日)的负荷数据,来自著名开源代码库 GitHub 中 Gmomo 的开源项目,采样频率为  $1 \text{ 点} \cdot \text{h}^{-1}$ ,共 8 784 条. 对负荷序列进行 EMD,选取各分量前 90%的数据进行训练,各分量后 10%的数据进行测试,在训练集中取前  $n$  个点对应  $n+1$  的点,即  $[x_1, x_2, x_3, \cdots, x_n]$  对应  $x_{n+1}$ ,  $[x_2, x_3, x_4, \cdots, x_{n+1}]$  对应  $x_{n+2}$ ,依次对训练集进行分割,测试集也做同样处理.

为便于模型训练,对所选负荷数据进行归一化处理,即

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}.$$
 (10)

式(10)中: $x'$ 为原始值; $x_{\max}$ 为极大值; $x_{\min}$ 为极小值.

3.2 误差评估指标

预测结果误差评估指标采用平均绝对百分误差( $E_{\text{MAP}}$ )和均方根误差( $E_{\text{RMS}}$ ),即

$$E_{\text{MAP}} = \sum_{i=0}^n \frac{|y_p - y_r|}{|y_i|} / n \times 100\%,$$
 (11)

$$E_{\text{RMS}} = \sqrt{(\sum_{i=1}^n |y_p - y_r|)^2 / n}.$$
 (12)

式(11),(12)中: $y_p$ 为预测值; $y_r$ 为实际值; $n$ 为样本数量.

3.3 EMD 重构

EMD 分解结果,如图 4 所示. 由图 4 可知:内涵模态分量反映负荷数据在不同影响因素和不同尺度下的分布规律,且逐渐由非平稳到平稳;残差分量( $R$ )反映负荷序列长期的变化规律,且整体变化趋势较为一致.

如果对各分量进行预测,可以较大降低预测模型的拟合难度,但同时模型时间复杂度也极大增加. 因此,为降低模型的时间复杂度,将部分低频内涵模态分量与残余分量叠加组合,对确定后的模型进行预测. 分量  $C_1, C_2$  的过零率分别为 45.6%,16.9%,是高频内涵模态分量;分量  $C_3 \sim C_{10}$  的过零率分别为 45.6%,16.9%,8.37%,3.33%,1.53%,0.71%,0.39%,0.20%,0.02%,0,均为低频内涵模态分量.

将低频内涵模态分量根据  $\rho$  从小到大依次进行叠加,再与残余分量组合后进行预测,对没有用到的内涵模态分量分别单独进行预测,将预测结果叠加. 不同组合分量的  $E_{\text{MAP}}$  和训练时间( $t$ ),如表 1 所示.

表 1 不同组合分量的  $E_{\text{MAP}}$  和训练时间

Tab. 1  $E_{\text{MAP}}$  values and training time of different combination components

$n$	训练轮数	批次	$E_{\text{MAP}}/\%$	$E_{\text{RMS}}/\text{MW} \cdot \text{h}$	$t/\text{s}$
1	512	220	1.40	46.3	2 665
2	512	220	1.39	46.1	2 276
3	512	220	1.44	47.3	1 987
4	512	220	1.43	46.8	1 714
5	512	220	1.48	48.3	1 465
6	512	220	1.47	47.8	1 220
7	512	220	1.41	46.6	1 017
8	512	220	1.43	47.1	751

表 1 中: $n$ 为低频内涵模态分量个数. 由表 1 可知:8 个低频内涵模态分量与残余分量叠加得到的组合分量与剩余内涵模态分量用 EMD-GRU-Attention 混合预测模型进行预测时,得到的  $E_{\text{MAP}}, E_{\text{RMS}}$  和训练时间分别为 1.41%,46.6 MW · h 和 1 017 s,在很短的时间内得到了较高的预测精度. 因此,将 7 个

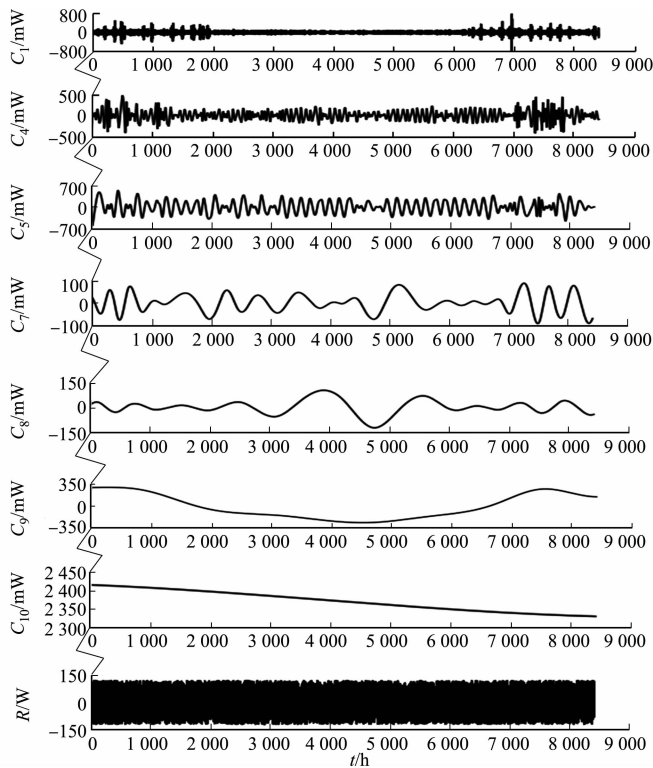


图 4 EMD 分解结果

Fig. 4 Decomposition results of EMD

低频内涵模态分量和残余分量设定为组合分量,对其余 2 个高频内涵模态分量与 1 个低频内涵模态分量分别进行预测.

3.4 GRU 网络模型参数

通过原始负荷数据对引入 Attention 机制的 GRU 结构进行调优,固定神经元数量、训练轮数和批次,调整 GRU 层数,根据  $E_{\text{MAP}}$ ,  $E_{\text{RMS}}$  的大小判断预测精度. GRU 层数调整结果,如表 2 所示.由表 2 可知:当 GRU 层数为 2 时,能在短的时间内取得更好的预测精度;当 GRU 层数为 1 层时,由于不能很好分析负荷序列及提取特征,效果较差;当 GRU 层数为 3 时,虽精度相差不大,但训练时间过长;当 GRU 层数为 4 时,则出现了过拟合,训练时间也太长.因此,GRU 层数设定为 2,GRU 神经元数量设置为  $2^n$ . 上述模型将第 1 层神经元数设为 64,返回全部时间步的隐藏状态;为减少数据流,降低冗余特征的干扰,第 2 层设置为 32,返回全部时间步的隐藏状态,输入 Attention 机制中,通过计算,分配不同权重,经 Dense 拟合后,得到更高的精度.

表 2 GRU 层数调整结果

Tab. 2 Adjustment results of different layers of GRU

GRU 层数	神经元数量	训练轮数	批次大小	$E_{\text{MAP}}/\%$	$E_{\text{RMS}}/\text{MW} \cdot \text{h}$	$t/\text{s}$
1	64	512	220	1.81	65.1	103
2	64	512	220	1.74	63.4	224
3	64	512	220	1.76	64.6	685
4	64	512	220	1.98	67.3	1 046

3.5 仿真结果对比

分别利用 BP 网络模型,支持向量机(SVR)模型,GRU 网络模型,EMD-GRU 模型和 EMD-GRU-Attention 混合预测模型进行仿真实验,对各模型参数进行调优,以相同训练集训练.确定各个模型参数后,以相同测试集预测 2016 年中 1 d(12 月 31 日)及 31 d(12 月 1 日至 12 月 31 日)的电力负荷,计算  $E_{\text{MAP}}$ ,  $E_{\text{RMS}}$ .不同模型仿真结果对比,如表 3 所示.由表 3 可知:EMD-GRU-Attention 混合预测模型在 1 和 31 d 的  $E_{\text{MAP}}$ ,  $E_{\text{RMS}}$  均低于其他 4 种模型;在 31 d 里 EMD-GRU 模型的  $E_{\text{MAP}}$ ,  $E_{\text{RMS}}$  分别为 1.75% 和 60.1 MW · h,而 EMD-GRU-Attention 混合预测模型的  $E_{\text{MAP}}$ ,  $E_{\text{RMS}}$  分别为 1.41% 和 46.6 MW · h,这

表明 EMD-GRU-Attention 混合预测模型具有更高的预测精度.

表 3 不同模型仿真结果对比

Tab. 3 Comparison of simulation results of different models

模型	1 d		31 d	
	$E_{\text{MAP}}/\%$	$E_{\text{RMS}}/\text{MW} \cdot \text{h}$	$E_{\text{MAP}}/\%$	$E_{\text{RMS}}/\text{MW} \cdot \text{h}$
BP 网络	3.94	106.8	3.47	116.1
SVR	4.16	114.4	4.05	119.8
GRU 网络	2.81	91.0	2.02	67.2
EMD-GRU	1.89	54.0	1.75	60.1
EMD-GRU-Attention 混合预测	1.35	39.3	1.41	46.6

为了验证 EMD,GRU 和 Attention 之间的组合性能,将 GRU 网络,EMD 和 Attention 递进组合,得出不同组合模型在某一天(2016 年 11 月 27 日)的预测值及评估指标( $E_{\text{MAP}}$ 和  $E_{\text{RMS}}$ ),如表 4 所示.表 4 中: $P_r$  为实测功率; $P_p$  为预测功率.由表 4 可知:GRU 网络模型,EMD-GRU 模型和 EMD-GRU-Attention 混合预测模型 24 h 内的  $E_{\text{MAP}}$  分别为 0.15%~7.94%,0.12%~6.75%,0.28%~3.32%, $E_{\text{RMS}}$  分别为 3.5~157.6 MW·h,3.0~146.8 MW·h,3.3~80.4 MW·h,随着网络模型的递进组合,其误差范围逐渐缩小,整体准确率稳步上升;3 种模型在 1 d 内的平均  $E_{\text{MAP}}$  分别为 2.13%,1.89%和 1.34%,平均  $E_{\text{RMS}}$  分别为 50.4,43.6,31.7 MW·h,这进一步表明 EMD-GRU-Attention 混合预测模型具有更高的预测性能.

表 4 不同模型负荷预测结果

Tab. 4 Load forecasting results of different models


$t/\text{h}$	$P_r/\text{MW}$	GRU 网络模型			EMD-GRU 模型			EMD-GRU-Attention 混合预测模型		
		$P_p/\text{MW}$	$E_{\text{MAP}}/\%$	$E_{\text{RMS}}/\text{MW} \cdot \text{h}$	$P_p/\text{MW}$	$E_{\text{MAP}}/\%$	$E_{\text{RMS}}/\text{MW} \cdot \text{h}$	$P_p/\text{MW}$	$E_{\text{MAP}}/\%$	$E_{\text{RMS}}/\text{MW} \cdot \text{h}$
1	2 835.1	2 926.0	3.20	90.6	2 926.2	3.21	91.1	2 843.7	0.31	8.6
2	2 731.3	2 806.3	2.72	75.0	2 688.4	1.56	42.9	2 745.3	0.51	14.0
3	2 620.6	2 686.6	2.51	66.0	2 657.5	1.41	36.9	2 701.0	3.07	80.4
4	2 595.8	2 591.0	0.18	4.8	2 683.9	3.39	88.1	2 587.8	0.31	8.0
5	2 786.8	2 750.4	1.30	36.4	2 791.7	0.17	4.9	2 727.4	2.13	59.4
6	2 952.3	3 026.3	2.50	74.0	2 920.5	1.07	31.8	3 030.3	2.64	78.0
7	2 847.6	2 863.7	0.56	16.1	2 898.6	1.79	51.0	2 886.3	1.36	38.7
8	2 659.6	2 713.4	2.02	53.6	2 693.3	1.26	20.1	2 718.2	2.20	58.6
9	2 482.3	2 522.7	1.62	40.4	2 534.8	2.11	52.5	2 475.2	0.28	7.1
10	2 338.8	2 353.7	0.63	14.9	2 297.6	1.76	41.2	2 315.7	0.99	23.1
11	2 174.1	2 117.4	2.61	56.7	2 027.3	6.75	146.8	2 143.3	1.41	30.8
12	1 888.3	1 906.1	0.94	17.8	1 966.8	4.15	78.5	1 872.6	0.82	15.7
13	1 817.4	1 834.2	0.92	16.8	1 831.8	0.79	14.4	1 850.8	1.83	33.4
14	1 805.0	1 838.9	1.88	33.9	1 797.4	0.41	7.6	1 813.4	0.46	8.4
15	1 790.4	1 836.7	2.58	46.3	1 811.5	1.18	21.1	1 838.3	2.68	47.9
16	1 804.0	1 854.5	2.80	50.5	1 834.0	1.66	30.0	1 820.2	0.89	16.2
17	1 863.9	1 970.3	5.71	106.4	1 911.2	2.54	47.3	1 853.2	0.57	10.7
18	1 984.4	2 142.0	7.94	157.6	2 023.9	1.99	39.5	2 050.3	3.32	65.9
19	2 197.3	2 200.8	0.15	3.5	2 160.5	1.67	36.8	2 180.8	0.75	16.5
20	2 374.5	2 339.4	1.47	35.1	2 325.9	2.04	48.6	2 320.9	2.25	53.6
21	2 475.1	2 420.7	2.20	54.4	2 456.0	0.77	19.1	2 440.0	1.41	35.1
22	2 530.7	2 460.1	2.78	70.6	2 484.1	1.84	46.6	2 526.0	0.18	3.3
23	2 527.6	2 482.6	1.78	45.0	2 481.9	1.81	45.7	2 540.3	0.50	12.7
24	2 480.1	2 437.0	1.74	43.1	2 483.1	0.12	3.0	2 514.1	1.37	34.0

BP 网络模型,SVR 模型,GRU 网络模型,EMD-GRU 模型和 EMD-GRU-Attention 混合预测模型在 2016 年 11 月 28 日和 29 日的负荷预测结果对比,如图 5(a)所示.图 5(a)中: $P$  为功率.由图 5(a)可


知:BP 网络模型,SVR 模型在波峰和波谷区域出现很大幅度的偏差,而 GRU 网络模型,EMD-GRU 模型和 EMD-GRU-Attention 混合预测模型相对于这两种模型都能较好地拟合真实曲线.

GRU 网络模型和 EMD-GRU 模型的负荷预测结果对比,如图 5(b)所示. 由图 5(b)可知:从整体上看,基于 EMD-GRU 模型的预测曲线不仅在波峰波谷区域与实际变化曲线更贴近,在其他区域也与实际的变化趋势更吻合,其原因是序列的非平稳性导致 GRU 网络模型不能很好地预测出序列的变化趋势,而 EMD 重构序列改善了这一问题,使得预测精度更好.


EMD-GRU 模型与 EMD-GRU-Attention 混合预测模型的负荷预测结果对比,如图 5(c)所示. 由图 5(c)可知:在大多数波峰和波谷区域,EMD-GRU-Attention 混合预测模型的预测精度更高,这体现了 Attention 机制突出关键特



(a) 不同模型预测



(b) GRU 网络模型和 EMD-GRU 模型



(c) EMD-GRU 结合 Attention 机制预测

图 5 不同模型负荷预测结果对比

Fig. 5 Comparison of load forecasting results of different models

征的能力,使得在预测转折点时更能拟合真实曲线.

4 结论

提出一种基于 Attention 机制的 EMD-GRU 混合预测模型用于短期电力负荷预测. 先通过 EMD 将负荷数据重构;再利用 GRU 抽取各分量及组合分量中潜藏特征;引入 Attention 机制突出关键特征,对各分量及组合分量预测;最后,叠加各分量预测值得到最终预测结果. 通过算例仿真及对比,得到以下 5 个结论.

- 1) 负荷序列作为输入,经 EMD 降低序列的非平稳性及复杂度,便于模型预测.
- 2) 将 EMD 处理后的向量作为 GRU 网络模型的输入,通过 GRU 网络模型,能较好地分析负荷数据的时序性和复杂非线性关系.
- 3) 结合 Attention 机制,计算 GRU 处理后的特征向量,给予不同权值,突出关键特征,进一步提高负荷预测精度.
- 4) EMD-GRU-Attention 混合模型结合了 EMD,GRU 网络和 Attention 机制的特点,实验结果表明:该模型可明显提升短期电力负荷预测精度.
- 5) EMD-GRU-Attention 混合预测模型提高了预测精度,但模型训练时,时间复杂度也随之提高,后续可对这部分进行改进.

参考文献:

[1] KHWAJA A S,ZHANG Xiaoying,ANPALAGAN A,*et al.* Boosted neural networks for improved short-term electric load forecasting[J]. Electric Power Systems Research,2017,143:431-437. DOI:10. 1016/j. epsr. 2016. 10. 067.

[2] 夏家盛,吉培荣. 负荷预测指数平滑法“厚近薄远”规律研究[J]. 电力学报,2019,34(1):23-29. DOI:10.13357/j.cnki.jep.002770.

[3] 甘中学,喻想想,许裕栗,等. 基于周期性 ARMA-SVR 模型的空调冷热负荷预测[J]. 控制工程,2020,27(2):380-385. DOI:10.14107/j.cnki.kzgc.170759.

[4] 俱鑫,刘尚科,苟瑞欣,等. 基于 ARMA 和 Kalman Filter 的需求响应基线负荷预测[J]. 电子设计工程,2020,28(18):175-180. DOI:10.14022/j.issn1674-6236.2020.18.039.

[5] MOEENI H,BONAKDARI H. Impact of normalization and input on ARMAX-ANN model performance in suspended sediment load prediction[J]. Water Resources Management,2018,32(3):1-19. DOI:10.1007/s11269-017-1842-z.

[6] 邢晓敏,何铁新,郑雪瑞,等. 基于 ANN-dropout 的配电网可靠性预测方法[J]. 南方电网技术,2019,13(2):66-73. DOI:10.13648/j.cnki.issn1674-0629.2019.02.010.

[7] 陈亮,王震,王刚. 深度学习框架下 LSTM 网络在短期电力负荷预测中的应用[J]. 电力信息与通信技术,2017,15(5):8-11. DOI:10.16543/j.2095-641x.electric.power.ict.2017.05.002.

[8] 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):1884-1892. DOI:10.13335/j.1000-3673.pst.2018.2101.

[9] RAHMAN A,SRIKUMAR V,SMITH A D. Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks[J]. Applied Energy,2018,212:372-385. DOI:10.1016/j.apenergy.2017.12.051.

[10] 李鹏,何帅,韩鹏飞. 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. DOI:10.13335/j.1000-3673.pst.2018.0433.

[11] 黄发良,连亚飞. Senti-LSTM: 一个基于递归神经网络的情感分析模型[J]. 福建师范大学学报(自然科学版),2020,36(1):12-18. DOI:10.12046/j.issn.1000-5277.2020.01.003.

[12] KANG Ke,SUN Hongbin,ZHANG Chengkang, *et al.* Short-term electrical load forecasting method based on stacked auto-encoding and GRU neural network[J]. Evolutionary Intelligence,2019,12(3):385-394. DOI:10.1007/s12065-018-00196-0.

[13] 姚程文,杨苹,刘泽健. 基于 CNN-GRU 混合神经网络的负荷预测方法[J]. 电网技术,2020,44(9):3416-3424. DOI:10.13335/j.1000-3673.pst.2019.2058.

[14] 魏骛,茅大钧,韩万里,等. 基于 EMD 和长短期记忆网络的短期电力负荷预测研究[J]. 热能动力工程,2020,35(4):203-209. DOI:10.16146/j.cnki.rndlgc.2020.04.028.

[15] 汤庆峰,刘念,张建华,等. 基于 EMD-KELM-EKF 与参数优选的用户侧微电网短期负荷预测方法[J]. 电网技术,2014,38(10):2691-2699. DOI:10.13335/j.1000-3673.pst.2014.10.012.

[16] BEDI J,TOSHNIWAL D. Empirical mode decomposition based deep learning for electricity demand forecasting[J]. IEEE Access,2018,6:49144-49156. DOI:10.1109/ACCESS.2018.2867681.

[17] 彭文,王金睿,尹山青. 电力市场中基于 Attention-LSTM 的短期负荷预测模型[J]. 电网技术,2019,43(5):745-751. DOI:10.13335/j.1000-3673.pst.2018.1554.

[18] 赵兵,王增平,纪维佳,等. 基于注意力机制的 CNN-GRU 短期电力负荷预测方法[J]. 电网技术,2019,43(12):4370-4376. DOI:10.13335/j.1000-3673.pst.2019.1524.

[19] 李昭昱,艾芊,张宇帆,等. 基于 Attention 机制的 LSTM 神经网络超短期负荷预测方法[J]. 供用电,2019,36(1):17-22. DOI:10.19421/j.cnki.1006-6357.2019.01.003.

(责任编辑: 陈志贤      英文审校: 吴逢铁)