

DOI: 10.7667/PSPC180365

基于 EMD-SLSTM 的家庭短期负荷预测

刘建华, 李锦程, 杨龙月, 闫耀双, 刘艳梅, 张屹修

(中国矿业大学电气与动力工程学院, 江苏 徐州 221008)

摘要: 针对非平稳的家庭短期负荷数据, 直接套用预测模型难以挖掘出更深层次的时序特征。提出一种经验模式分解(Empirical Mode Decomposition, EMD)和堆栈式长短期记忆(Stack Long Short-term Memory, SLSTM)的组合算法应用于家庭短期负荷预测。首先分析了 SLSTM 和 EMD 原理, 提出 EMD-SLSTM 组合预测模型。将负荷数据通过 EMD 算法进行分解, 然后将分解后的分量数据分别转化为三维数据样本。通过设计 SLSTM 网络架构及其参数, 对归一化的分量数据和原始数据分别进行预测建模及其重构。为显示算法预测性能, 实验对比了支持向量回归、人工神经网络、深度神经网络、梯度提升回归等模型在两种情景下的性能, 采用 MAPE 和 RMSE 性能度量进行验证。实验结果表明 EMD-SLSTM 更能有效地表达出家庭短期负荷的时序关系, 具有更高的预测精度。

关键词: 家庭短期负荷预测; 深度学习; 堆栈式长短期记忆网络; 经验模式分解; 时间序列

Short-term household load forecasting based on EMD-SLSTM

LIU Jianhua, LI Jincheng, YANG Longyue, YAN Yaoshuang, LIU Yanmei, ZHANG Yixiu

(School of Electrical and Power Engineering, China University of Mining and Technology, Xuzhou 221008, China)

Abstract: For non-stationary short-term household load data, it is difficult to mine deeper temporal characteristics by directly applying the prediction model. A combination of Empirical Mode Decomposition (EMD) and Stack Long Short-Term Memory (SLSTM) algorithm is proposed for short-term household load forecasting. Firstly, the principle of EMD and SLSTM is analyzed and the EMD-SLSTM combined prediction model is proposed. Then, the load data is decomposed by the EMD algorithm and the decomposed component data is respectively converted into three-dimensional data. By designing the network architecture of SLSTM and its parameters, the normalized component data and original data are separately predicted and reconstructed. In order to show the performance of the algorithm, the performance of the support vector regression, artificial neural network, deep neural network, gradient boosting regression is compared and verified by MAPE and RMSE performance metrics in two scenarios. The results show that EMD-SLSTM can more effectively express the time series relationship of short-term household load and has higher prediction accuracy.

This work is supported by Youth Science Foundation (No. 51607179).

Key words: short-term household load forecasting; deep learning; stack long short-term memory network; empirical mode decomposition; time series

0 引言

目前分布式间歇性新能源并网依然面临着严峻的形势^[1], 为提高新能源消纳效率, 从成本和灵活性考量, 提高终端用户能源服务无疑比提升底层硬件技术水平更具优势^[2]。在电力零售市场, 各种终端用户服务, 如客户负荷管理, 需要短期负荷预测来吸引更多的客户^[3-5]。这些特征暗示着消费者的作

用将比以往更为重要, 因此, 预测的范围从宏观角度转移到微观角度^[6], 家庭负荷预测变得越来越重要。

关于负荷预测的研究方法有很多^[7], 从经典的时间序列分析到最近的机器学习方法, 包括自动回归移动平均模型 ARIMA^[8]、支持向量回归(Support Vector Regression, SVR)^[9]、随机森林^[10]、梯度提升回归(Gradient Boosting Regression, GBR)^[11]、极限学习机^[12]等。负荷预测的另一个重要分支是使用人工神经网络^[13-14] (Artificial Neural Network, ANN)模型

基金项目: 青年科学基金项目资助(51607179)

进行预测。近年来随着相关负荷数据的增加和大规模并行计算能力的提升, 利用大数据进行负荷预测成为研究的热点^[15-16]。在海量数据和并行计算性能大幅增长的背景下, 深度学习(Deep Learning, DL)在语音识别、图像分类等部分领域逼近甚至超越人类^[17]。文献[18]将 DL 应用于短期风电预测, 取得了更高的精度。文献[19]利用 EMD 分解负荷数据, 在更具平稳性的分量负荷数据中获得了更高的精度。

ANN 不具备在时间轴上的传播计算能力, 循环神经网络(Recurrent Neural Network, RNN)的输出值 O_t 会受之前输入值 $[I_t, I_{t-1}, I_{t-2}, \dots, I_{t-n}]$ 的影响, 在许多负荷预测问题中, 预测的负荷序列具有长时间的依赖性, 其长度可能随时间而变化或隐藏未知。与其他线性预测模型相比, RNN 可以学习任意复杂的函数以及变量之间隐藏的非线性交互, 在具有时序特征的负荷预测中有着明显优势。RNN 虽然解决了时间依赖的问题, 但在反向传播的链式求导计算中, 会带来梯度消失或爆炸的问题^[20]。长短期记忆(Long Short-term Memory, LSTM)网络^[20]由 5 个不同的非线性组件组成, 以一种特定的方式相互作用。LSTM 的内部状态只通过线性相互作用而改变, 这使得信息可以在整个时间轴内平滑地进行反向传播, 从而提高了时序信息的存储容量。

本文提出一种 EMD-SLSTM 组合的短期负荷预测算法, 利用 EMD 算法将非平稳负荷分解成更具平稳的分量负荷, 设计了 3+1 层 SLSTM 网络及其参数, 分别对分量负荷和原始负荷数据进行预测建模及其重构, 最后采用实际生活中的家庭负荷数据进行实验仿真, 实验结果表明 EMD 分解算法能够极大地提高模型的预测性能, 在两种情景下, 通过与 SVR、ANN、GBR 等模型进行对比, SLSTM 网络具有更高的泛化性能。

1 堆栈式长短期记忆网络

1.1 长短期记忆网络

LSTM 通过 3 个门来保护和控制存储单元中的信息, 这些信息由激活函数的点乘 \odot 来实现, 通过梯度下降训练一系列参数来控制每个门的状态。

LSTM 中的每一个门都有一个特定且独特的功能。遗忘门 f 从先前的状态 h_{t-1} 中决定丢弃哪些信息。输入 x_t 和 h_{t-1} 经过更新门 u 运算后, 与修正过的遗忘门 f 一块决定更新状态 h_t 应该用候选状态 \tilde{h}_t 多少权重。为了生成输出 y_t , 首先使用非线性的 g_2 函数过滤它的当前状态, 然后与输出门 o 运算后一

块输出 y_t , 其中返回部分状态 y_t 作为下次输入 y_{t-1} 。每一个门都依赖于当前的外部输入 x_t 和之前的输出 y_{t-1} 。图 1 详细描绘了 LSTM 的结构原理, LSTM 的更新状态方程如式(1)所示。

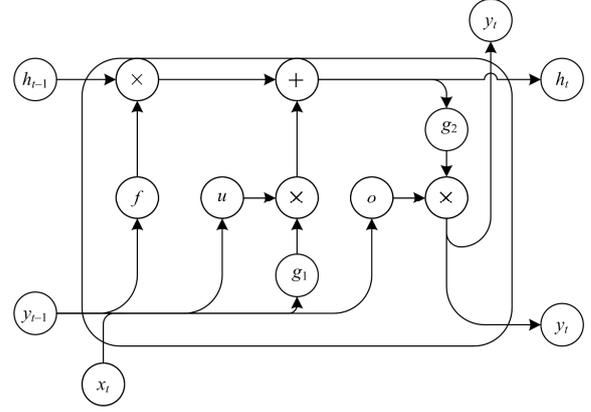


图 1 LSTM 结构图

Fig. 1 Structure of LSTM

$$\left\{ \begin{array}{l} \text{forget gate: } f_t = \sigma(W_f x_t + R_f y_{t-1} + b_f) \\ \text{candidate state: } \tilde{h}_t = g_1(W_h x_t + R_h y_{t-1} + b_h) \\ \text{update state: } u_t = \sigma(W_u x_t + R_u y_{t-1} + b_u) \\ \text{cell state: } h_t = u_t \odot \tilde{h}_t + f_t \odot h_{t-1} \\ \text{output gate: } o_t = \sigma(W_o x_t + R_o y_{t-1} + b_o) \\ \text{output: } y_t = o_t \odot g_2(h_t) \end{array} \right. \quad (1)$$

式中: x_t 为 t 时刻的输入向量; W_f 、 W_h 、 W_u 和 W_o 是与输入单元相关的权重矩阵; R_f 、 R_h 、 R_u 和 R_o 为隐藏层连接的权重矩阵; 而 b_f 、 b_h 、 b_u 和 b_o 为偏置向量; 激活函数 σ 为 sigmoid 或者 tanh; g_1 和 g_2 为非线性激活函数; \odot 为点乘。

1.2 堆栈式长短期记忆网络训练方法

SLSTM 的架构如图 2 所示。由 n 个 LSTM 层 +1 个全连接层组成, 为降低模型维度, 第 n 层 LSTM 输出一维向量。

1) 向前计算

SLSTM 向前计算跟 ANN 类似, 式(2)表示 SLSTM 的向前计算。

$$Y_t = Vf(UX_t + Wf(UX_{t-1} + Wf(UX_{t-2} + \dots))) \quad (2)$$

式中: U 为输入 X 的权重矩阵; W 为上一次的 h_{t-1} 作为这一次的输入的权重矩阵; f 为激活函数; V 为输出层的权重矩阵。

2) 反向传播

SLSTM 采用通过时间反向传播(Back Propagation Through Time, BPTT)算法^[21], 将

SLSTM 展开后使用误差反向传播(Back Propagation, BP)算法对网络进行训练。计算实际输出与真实值之间的误差,按最小误差的方法调整权值矩阵,求出权值梯度并进行迭代更新。

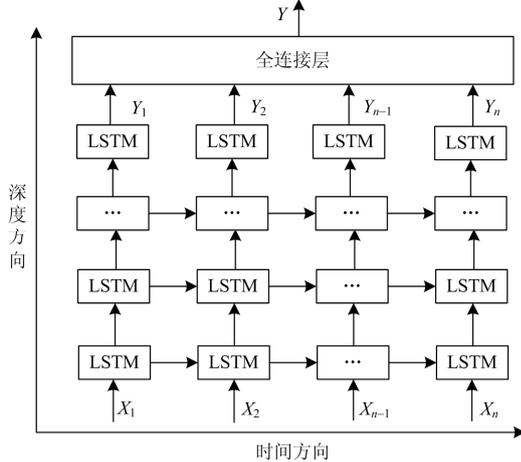


图 2 SLSTM 架构

Fig. 2 Architecture of SLSTM

2 EMD-SLSTM 组合预测模型

2.1 EMD 原理

EMD^[19]方法能够将非平稳非线性数据转为平稳线性数据,这对负荷预测模型充分挖掘其隐藏的时序关系具有极大的辅助作用,EMD 步骤如下。

首先由时序数据 $x(t)$ 的局部极大极小值确定其上包络线 $U_s(t)$ 和下包络线 $V_s(t)$, 求出均值包络线 m_1 , 如式(3)。然后用 $x(t)$ 减去 m_1 得到 c_1 , c_1 为第一个固有模态函数(Inherent Modal Function, IMF), 如式(4)所示。残差 $r_1(t)$ 为 $x(t)$ 和 m_1 的差值, 见式(5)。最后将残差 $r_1(t)$ 重复上述步骤, 得到符合条件的一系列 IMF 分量 c_i 和一个残差 r_n , 见式(6)。

$$m_1 = \frac{U_s(t) + V_s(t)}{2} \quad (3)$$

$$c_1 = x(t) - m_1(t) \quad (4)$$

$$r_1(t) = x(t) - c_1(t) \quad (5)$$

$$x(t) = \sum_{i=1}^n c_i + r_n \quad (6)$$

2.2 EMD-SLSTM 组合算法

通过 EMD 算法将短期负荷分解为若干个 IMF 分量和一个残差分量 R, 然后分别将分量负荷数据转化为三维输入矩阵, 利用 SLSTM 网络分别对分量数据进行建模预测, 最后将各个分量预测结果进行重构, 得出短期负荷预测结果, EMD-SLSTM 组合预测流程如图 3 所示。

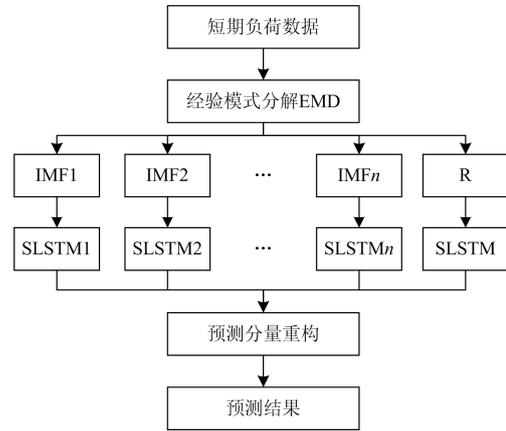


图 3 EMD-SLSTM 组合预测流程图

Fig. 3 Flowchart of EMD-SLSTM of combined forecasting

3 家庭短期负荷预测模型设计

本文所有数据分析的软硬件平台如表 1 所示。

表 1 软硬件实验平台

Table 1 Platform of hardware and software

工具	版本	工具	参数
Python 发行版	Anaconda5.1	内存 RAM	4.00 GB
深度学习框架	Keras2.0	处理器 CPU	i5-5200U
操作系统	Windows 10	CPU 频率	2.20 GHz

3.1 实验数据预处理

实验负荷数据集来源于 UCI 数据库(individual household electric power consumption)。负荷数据集的采集频率是每隔 1 min 记录一次, 数据采集的时间为 47 个月, 共计 2 075 259 个, 其中缺失值记为 ‘?’ , 约占 1.25%。

1) 数据转换

对原数据进行重采样处理, 频率为每小时采集一次, 采集数量为 $n(n=34\ 587)$ 个, 具体步骤如下: 先将数据集按小时分辨率取整, 接着将负荷列向量转化为二维矩阵, 每行表示一小时采集的 $m(m=60)$ 个数据, 如式(7)所示; 然后依次对每行 60 个负荷数据求和, 得到每小时的负荷数据值, 如式(8)所示。

2) 缺失值处理

由于数据集的缺失值存在连续超过一小时的现象, 无法按缺失值附近的均值或者插值进行处理, 所以对每列的缺失值按该列的均值填充, 如式(9)所示。

$$\begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_{n \times m} \end{bmatrix} \rightarrow \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix} \rightarrow \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix} \quad (7)$$

$$[X_1, X_2, \dots, X_n] = \sum_{i=1}^m x_{ni} \quad (8)$$

$$x_m = \frac{\sum_{i=1}^n x_{im}}{n} \quad (9)$$

式中: x 为每分钟的负荷; X 为每小时的负荷数据。

3.2 EMD 负荷分解

EMD 将预处理后的 34 587 个样本数据分解成 23 个 IMF 分量和 1 个残差分量 R , 组成(34 587,24) 维向量数据, 相比原负荷, 分解后的 IMF 分量依次变得更平稳, 实验仿真见图 4(R 计入 IMF 分量中)。

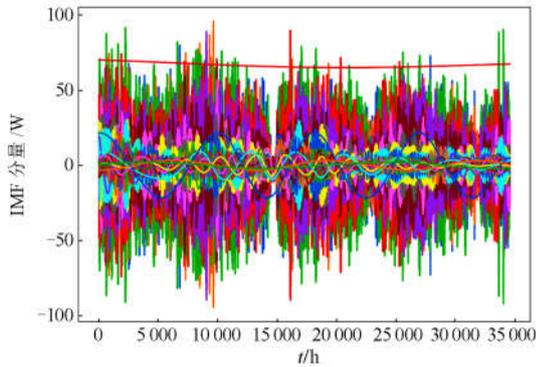


图 4 家庭短期负荷 EMD 分解曲线图

Fig. 4 Short-term load of EMD decomposition curve

由于部分分量负荷数据波动幅度依然很大, 将分量数据按 min-max 标准化进行归一化处理, 见式 (10)。数据归一化既可减少训练时间也可以防止网络的激活函数处于过饱和状态。

$$X'_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (10)$$

式中, X'_i 、 X_i 、 X_{\max} 、 X_{\min} 依次为归一化值、样本值、最大值、最小值。

3.3 网络架构及其参数设计

原家庭负荷数据和各分量数据划分如表 2 所示。时间步长 timestep 选为 12, 网络采用小批量 (mini-batch) 输入, 每次输入样本数量为 mini-batch=128。网络训练采用 20 次 epochs 迭代训练计算, lose 函数采用均方误差 MSE。

表 2 训练与测试数据集

Table 2 Dataset of training and test

数据集	数据数量	timestep	变量维度	mini-batch
训练(原)	80%	12	1	128
测试(原)	20%	12	1	128
训练(P_i)	80%	12	1	128
测试(P_i)	20%	12	1	128
训练(P_r)	80%	12	1	128
测试(P_r)	20%	12	1	128

实验采用的 SLSTM 网络架构及其参数如图 5 所示。网络架构采用 3+1 结构(3 层 LSTM 和 1 层全连接层), 多层架构能够对数据进行更深层次的表达。cell 为每层神经元的个数, 输入输出表示网络数据的向量维数。以第一层输入为例, (none,12,1) 分别表示(样本数, 时间步长, 变量维数)。

LSTM层 (激活函数=tanh, cell=128)	输入	(none,12,1)
	输出	(none,12,128)
LSTM层 (激活函数=tanh, cell=64)	输入	(none,12,128)
	输出	(none,12,64)
LSTM层 (激活函数=tanh, cell=64)	输入	(none,12,64)
	输出	(none,64)
全连接层 (激活函数=linear, cell=1)	输入	(none,64)
	输出	(none,1)

图 5 SLSTM 网络架构及其参数

Fig. 5 Architecture and parameters of SLSTM

3.4 预测分量重构

将各个预测的 IMF(P_i)和残差分量数据 P_r 进行叠加重构, 如式(11)所示, P 为重构的预测数据, 最终将 P 与真实负荷值进行对比。

$$P = \sum_{i=1}^n P_i + P_r \quad (11)$$

4 算例分析

实验采用的性能度量为 RMSE、MAPE 和 MAE, 其定义如式(12)—式(14)。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - p_i)^2} \quad (12)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - p_i}{y_i} \right| \times 100\% \quad (13)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - p_i| \quad (14)$$

式中, N 、 y_i 、 p_i 分别表示样本个数、实际值和预测值。

实验使用统计机器学习 SVR(径项基核函数)、集成学习梯度提升回归 GBR(决策树 $n=50$)、人工神经网络 ANN、深度神经网络 DNN(5 层网络)和 SLSTM 进行对比。

图 6、图 7 分别为 24 个分量预测的 MAE 和 RMSE(详细数据见表 3), 其中前 23 个为 IMF 分量, 最后 1 个为残差分量 R , 由于分量样本含有 0 值,

用 *MAE* 取代 *MAPE*。从图 6、图 7 可看出 SLSTM 的 *MAE* 和 *RSME* 在多个预测分量中位于最低，总体误差曲线位于最下方。但是有几个 IMF 分量，

ANN 和 DNN 性能表现更好，这可能与 SLSTM 网络固定 *timestep* 为 12 有关，尽管简化了建模过程和工作量，但也造成了 SLSTM 的超参数未能达到最优。

表 3 分量预测的 *MAE* 和 *RSME*
Table 3 *MAE* and *RSME* of component prediction

IMF 分量	<i>MAE</i>					<i>RSME</i>				
	SVR	GBR	ANN	DNN	SLSTM	SVR	GBR	ANN	DNN	SLSTM
1	2.22	1.06	0.94	0.73	0.58	3.98	3.09	2.51	1.45	1.39
2	1.95	0.95	0.56	0.64	0.22	3.72	2.34	1.26	1.36	0.37
3	1.83	1.10	0.61	0.93	0.35	3.27	2.55	1.54	2.28	0.76
4	1.79	1.35	0.90	0.93	1.04	3.50	3.46	2.92	2.67	3.08
5	1.44	0.51	0.21	0.52	0.54	2.75	1.22	0.45	0.97	1.10
6	2.05	1.35	0.94	0.98	1.04	4.46	3.46	2.47	2.87	3.40
7	1.55	0.85	0.90	0.93	1.13	3.12	2.27	2.52	2.51	3.49
8	1.81	0.98	0.68	0.79	0.53	3.49	2.42	1.76	2.03	1.25
9	2.19	1.38	0.95	0.99	0.69	4.30	3.54	2.92	3.34	1.92
10	2.02	1.28	0.78	0.94	0.96	3.86	3.19	2.14	2.57	2.50
11	2.89	1.74	1.50	1.37	1.21	6.66	4.71	4.54	3.95	3.76
12	1.80	0.86	0.53	0.66	0.74	3.81	2.66	1.50	1.62	1.78
13	2.46	1.99	1.56	1.34	1.26	5.18	6.15	5.33	4.50	4.83
14	1.77	0.54	0.90	0.66	0.67	3.26	1.87	2.60	1.59	1.92
15	3.61	2.90	2.58	2.19	2.42	8.95	9.38	8.37	7.16	8.22
16	2.72	1.13	0.80	1.10	0.99	5.79	3.38	2.45	3.32	3.05
17	2.64	2.20	0.77	1.00	1.04	5.27	6.80	2.55	2.47	2.95
18	1.71	0.77	0.47	0.49	0.49	3.06	2.07	1.22	0.95	1.15
19	2.24	1.43	0.54	0.60	0.32	4.80	3.78	1.62	1.31	0.75
20	1.64	0.77	0.67	0.88	0.87	3.02	1.83	1.75	2.07	2.35
21	1.81	0.66	0.25	0.46	0.34	3.46	1.40	0.75	0.87	0.71
22	2.11	1.32	1.13	0.88	0.88	5.04	4.77	4.10	3.08	3.60
23	2.08	1.79	1.48	1.09	1.02	4.35	4.39	4.09	2.97	2.86
24(R)	1.33	0.77	0.50	0.66	0.38	2.40	1.90	1.13	1.95	0.86

将 24 个分量预测数据进行重构，记为 EMD 组合预测，并跟直接预测的数据进行性能比较。直接预测和 EMD 组合预测两种情景的实验测试结果如表 4 所示，选取两天 48 h 的仿真见图 8 和图 9。从表 4 可明显看出，EMD 组合预测的性能要明显优于直接预测，各个模型有着 50% 以上的性能提升，其中 SVR 的 *MAPE* 和 SLSTM 的 *RSME* 降低了一半以上。SLSTM 网络在两种情景中的预测性能都是最高的，这得益于其复杂的记忆网络模型，但在未用 GPU 硬件加速的情况下，训练时间要远远超出其他模型。在图 9 中，EMD-SLSTM 模型在负荷急剧上升的情形中，预测效果良好，最接近真实值，但负荷在平谷小幅波动情形中，和其他组合模型一样，预测趋势较差，造成了较大的相对误差，这可能与过多的预测分量所形成的累计误差有关。而在图 8

的平谷小幅波动中，预测趋势较好，尤其是 SLSTM 预测效果要明显优于其他模型，使得 SLSTM 的 *MAPE* 也要小于其他模型。

表 4 测试性能对比
Table 4 Comparison of training and test performance

模型	单个分量 训练时间/s	直接预测		EMD 组合预测	
		<i>MAPE</i>	<i>RMSE</i>	<i>MAPE</i>	<i>RMSE</i>
SVR	39	64.58	30.63	31.10	20.60
GBR	2.3	45.57	29.15	31.29	18.15
ANN	22	46.91	29.73	29.71	15.99
DNN	30	49.39	29.44	26.91	16.15
SLSTM	760	39.64	29.65	25.73	14.54

SVR 在数万级别和剧烈波动的数据面前，性能要明显低于其他模型，训练时间也处于劣势，这验证了 SVR 适合小样本学习。基于决策树的集成学习

GBR 相比其他模型, 训练时间很低, 直接预测精度较高, 比较适合大量的波动数据, 但在预测更具平稳的分量数据时, 性能不及神经网络模型。值得注意的是, 在直接预测过程中, 加深网络层数的 DNN 模型在性能方面要稍低于 ANN 模型, 但在组合预测过程中, DNN 的综合性能要稍微优于 ANN; 尽管加深网络层数能够更深层次地对数据进行抽象表达, 但选用的 tanh/sigmoid 激活函数也可能带来梯度消失的问题。

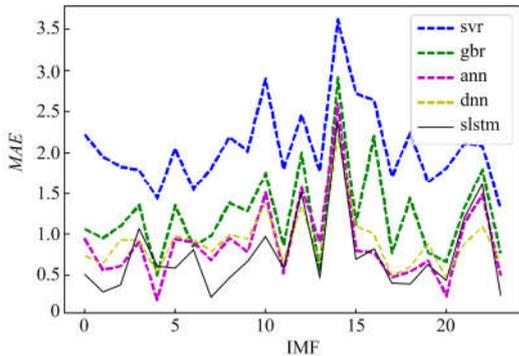


图 6 各个 IMF 分量的 MAE
Fig. 6 MAE of IMFs

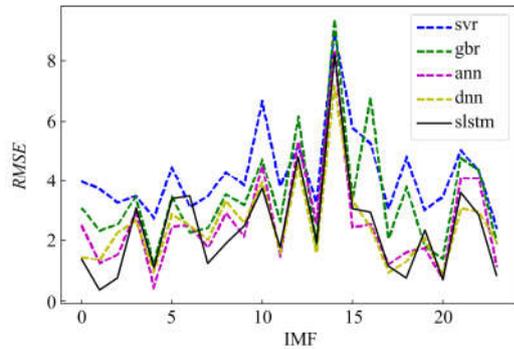


图 7 各个 IMF 分量的 RSME
Fig. 7 RSME of IMFs

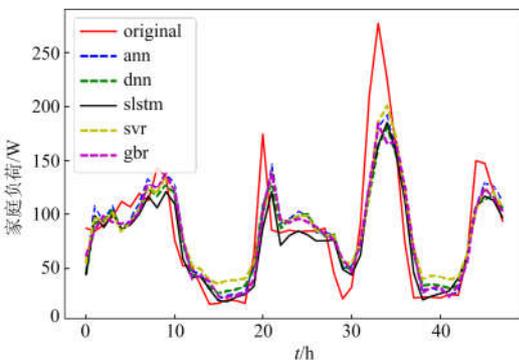


图 8 测试对比图(直接预测)
Fig. 8 Test contrast diagram (single prediction)

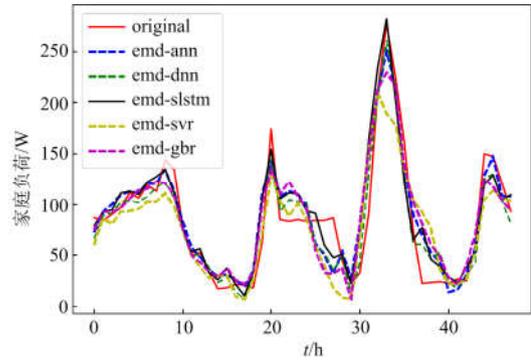


图 9 测试对比图(EMD 组合预测)

Fig. 9 Test contrast diagram (EMD combinatorial prediction)

此外, 从图 8 可以看出直接预测的效果较差, 各个模型预测明显具有滞后一个时刻的趋势, 这源于原始负荷的时序相关性较低, 相比之下, 经过 EMD 分解的分量数据具有很高的相关性, 使用时刻 t 之前 12 个时刻的时序特征, 能够较好地预测未来的走势。原始负荷时序的 Pearson 相关系数(Pearson Correlation Coefficient, PCC)^[22]见图 10, 选取第 10 个 IMF 分量的时序 PCC 见图 11, 其中时间窗口为 14 天, 在 336(14×24=336)个时刻中选择最大的 12 个时刻与当前时刻 t 之间的 PCC。

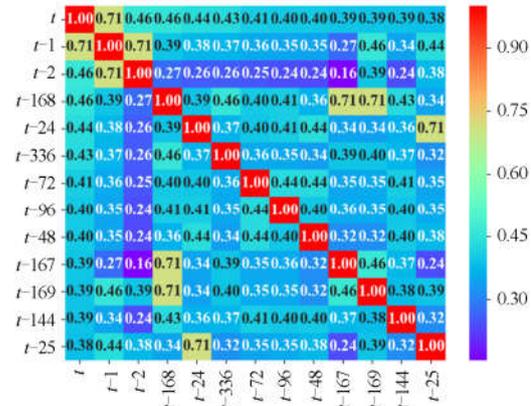


图 10 原始负荷的 Pearson 相关系数矩阵

Fig. 10 Pearson correlation coefficient of the original load

从图 10 可以看出, 负荷序列具有较弱的周期性(小周期为一天, 大周期为一周), 除了 $t-1$ 时刻的 PCC 取值为 0.5~0.8, 具有较强的相关性, 其他时刻的 PCC 取值为 0.3~0.5, 处于较弱的相关性程度, 造成了预测的滞后性和较差的性能。而在图 11 中, 时刻 t 的前 5 个时刻的 PCC 高达 0.99 以上, 具有极强的相关性, 即便是时刻 $t-12$ 的 PCC 也位于 0.9 以上, 处于强相关性程度, 所以能够预测未来趋势, 而且预测性能较好。

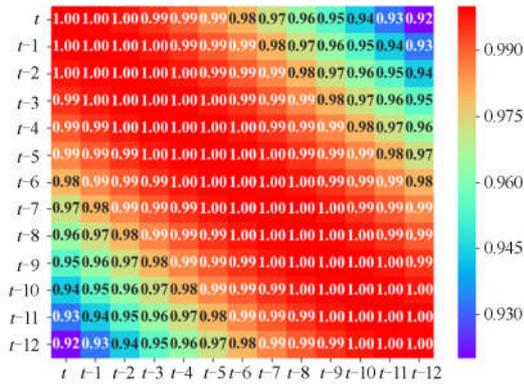


图 11 第 10 个 IMF 分量的 Pearson 相关系数矩阵
Fig. 11 Pearson correlation coefficient of the tenth IMF

5 结论与展望

1) 分析了 EMD 和 SLSTM 算法的原理,提出了 EMD-SLSTM 组合算法应用到家庭短期负荷预测。

2) 对预处理后的家庭负荷进行 EMD 分解, 实验设计了 3+1 层 SLSTM 架构及其参数, 分别对分量负荷和原始负荷两种情景进行训练和重构预测。

3) 实验结果表明 EMD 分解算法能够极大地提高模型的预测性能, 在两种情景下, 通过与 SVR、ANN、DNN、GBR 等模型进行对比, SLSTM 网络具有更高的泛化性能, 但其在训练时间上远远超出其他模型。

SLSTM 网络的复杂性让参数训练变得更加困难, 训练出更优参数可以进一步提高预测的精度。同时在平稳线性的负荷分量中, 诸多简单预测模型也有很好的泛化能力, 在负荷分量中进行不同模型的组合, 既能提高模型的精度, 又可以大幅度减少模型的训练时间。

参考文献

[1] 舒印彪, 张智刚, 郭剑波, 等. 新能源消纳关键因素分析及解决措施研究[J]. 中国电机工程学报, 2017, 37(1): 1-8.
SHU Yinbiao, ZHANG Zhigang, GUO Jianbo, et al. Study on key factors and solution of renewable energy accommodation[J]. Proceedings of the CSEE, 2017, 37(1): 1-8.

[2] KAZMERSKI L. Renewable and sustainable energy reviews[J]. Renewable & Sustainable Energy Reviews, 2013, 38: 834-847.

[3] 王守相, 孙智卿, 刘喆. 面向智能用电的家庭能量协同调度策略[J]. 电力系统自动化, 2015, 39(17): 108-113.

WANG Shouxiang, SUN Zhiqing, LIU Zhe. Household energy collaborative scheduling strategy for smart power utilization[J]. Automation of Electric Power Systems, 2015, 39(17): 108-113.

[4] 孙国强, 李逸驰, 卫志农, 等. 智能用电互动体系构架探讨[J]. 电力系统自动化, 2015, 39(17): 68-74.
SUN Guoqiang, LI Yichi, WEI Zhinong, et al. Discussion on the architecture of smart power use interaction system[J]. Automation of Electric Power Systems, 2015, 39(17): 68-74.

[5] 刘孝杰, 苏小林, 阎晓霞, 等. 面向主动响应和售电市场的主动配电系统负荷预测[J]. 电力系统及其自动化学报, 2017, 29(2): 121-128.
LIU Xiaojie, SU Xiaolin, YAN Xiaoxia, et al. Load forecasting of active distribution system for active response and selling electricity market[J]. Proceedings of the CSU-EPSS, 2017, 29(2): 121-128.

[6] RYU S, NOH J, KIM H. Deep neural network based demand side short term load forecasting[C] // 2016 IEEE International Conference on Smart Grid Communications (SmartGridComm), November 6-9, 2016, Sydney, Australia: 308-313.

[7] 廖旋焕, 胡智宏, 马莹莹, 等. 电力系统短期负荷预测方法综述[J]. 电力系统保护与控制, 2011, 39(1): 147-152.
LIAO Nihuan, HU Zhihong, MA Yingying, et al. Review of the short-term load forecasting methods of electric power system[J]. Power System Protection and Control, 2011, 39(1): 147-152.

[8] 麦鸿坤, 肖坚红, 吴熙辰, 等. 基于 R 语言的负荷预测 ARIMA 模型并行化研究[J]. 电网技术, 2015, 39(11): 3216-3220.
MAI Hongkun, XIAO Jianhong, WU Xichen, et al. Research on load forecasting ARIMA model parallelization based on R language[J]. Power System Technology, 2015, 39(11): 3216-3220.

[9] 熊军华, 牛珂, 张春歌, 等. 基于小波变异果蝇优化支持向量机短期负荷预测方法研究[J]. 电力系统保护与控制, 2017, 45(13): 71-77.
XIONG Junhua, NIU Ke, ZHANG Chungu, et al. LSSVM in short-term load forecasting based on wavelet transform and mutant fruit fly optimization algorithm[J]. Power System Protection and Control, 2017, 45(13): 71-77.

[10] 吴潇雨, 和敬涵, 张沛, 等. 基于灰色投影改进随机森林算法的电力系统短期负荷预测[J]. 电力系统自动化, 2015, 39(12): 50-55.
WU Xiaoyu, HE Jinghan, ZHANG Pei, et al. Power

- system short-term load forecasting based on improved random forest with grey relation projection [J]. *Automation of Electric Power Systems*, 2015, 39(12): 50-55.
- [11] CANDANEDO L M, FELDHEIM V, DERAMAIX D. Data driven prediction models of energy use of appliances in a low-energy house[J]. *Energy & Buildings*, 2017, 140: 81-97.
- [12] LI Z, YE L, ZHAO Y, et al. Short-term wind power prediction based on extreme learning machine with error correction[J]. *Protection and Control of Modern Power Systems*, 2016, 1(1): 9-16. DOI: 10.1186/s41601-016-0016-y.
- [13] 杨杰, 霍志红, 何永生, 等. 基于小波与最小资源分配网络的超短期风电功率预测研究[J]. *电力系统保护与控制*, 2018, 46(9): 55-61.
YANG Jie, HUO Zhihong, HE Yongsheng, et al. Ultra-short-term wind power prediction based on wavelet and minimum resource allocation network[J]. *Power System Protection and Control*, 2018, 46(9): 55-61.
- [14] 杨秋霞, 刘同心, 高辰, 等. 计及光伏电站功率预测的电力系统优化分析[J]. *电力系统保护与控制*, 2018, 46(2): 117-123.
YANG Qiuxia, LIU Tongxin, GAO Chen, et al. Power system optimization analysis considering power prediction of PV power station[J]. *Power System Protection and Control*, 2018, 46(2): 117-123.
- [15] 雷正新, 韩蓓, 聂萌, 等. 配电网大数据环境下的多点负荷预测算法与应用研究[J]. *电力系统保护与控制*, 2016, 44(23): 68-78.
LEI Zhengxin, HAN Bei, NIE Meng, et al. Research and application of multi-node load forecasting algorithm under the environment of distribution network's big data[J]. *Power System Protection and Control*, 2016, 44(23): 68-78.
- [16] 王德文, 孙志伟. 电力用户侧大数据分析并行负荷预测[J]. *中国电机工程学报*, 2015, 35(3): 527-537.
WANG Dewen, SUN Zhiwei. Big data analysis and parallel load forecasting of electric power user side[J]. *Proceedings of the CSEE*, 2015, 35(3): 527-537.
- [17] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [18] 朱乔木, 李弘毅, 王子琪, 等. 基于长短期记忆网络的风电场发电功率超短期预测[J]. *电网技术*, 2017, 41(12): 3797-3802.
ZHU Qiaomu, LI Hongyi, WANG Ziqi, et al. Short-term wind power forecasting based on LSTM[J]. *Power System Technology*, 2017, 41(12): 3797-3802.
- [19] 郑连清, 郑艳秋. 基于经验模式分解与人工神经网络的短期电力负荷预测[J]. *电力系统保护与控制*, 2009, 37(23): 66-69.
ZHENG Lianqing, ZHENG Yanqiu. Short-term power load forecasting based on empirical mode decomposition and ANN[J]. *Power System Protection and Control*, 2009, 37(23): 66-69.
- [20] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [21] BENGIO Y, SIMARD P, FRASCONI P. Learning long-term dependencies with gradient descent is difficult[J]. *IEEE Transactions on Neural Networks*, 2002, 13(2): 157-166.
- [22] 唐伟斌, 李涛, 邹晶晶, 等. 基于皮尔逊相关系数的电网夏季空调负荷预测研究[J]. *电力需求侧管理*, 2017, 19(6): 7-13.
TANG Weibin, LI Tao, ZHOU Pinjing, et al. Summer load forecasting of power grid based on Pearson correlation coefficient[J]. *Power Demand Side Management*, 2017, 19(6): 7-13.

收稿日期: 2018-04-02; 修回日期: 2018-06-05

作者简介:

刘建华(1973—), 男, 博士, 副教授, 研究方向为智能变配电网安全与保护; E-mail: 13382679966@163.com

李锦程(1992—), 男, 通信作者, 硕士研究生, 研究方向为机器学习在智能配用电中的应用; E-mail: lijincheng718@foxmail.com

杨龙月(1988—), 男, 博士, 讲师, 研究方向为智能配电网与电力电子技术。E-mail: 644653327@qq.com

(编辑 许威)