

基于 EMD-IPSO-LSTM 模型的短期电力负荷预测

赵一鸣 吉月辉 刘俊杰 陈嘉齐

(天津理工大学电气工程与自动化学院 天津 300384)

摘要:准确地预测短期负荷为发电厂电力调度提供依据,提高电力系统的经济性。由于负荷数据的非线性非平稳性,提出一种经验模态分解-改进粒子群算法-长短期记忆(EMD-IPSO-LSTM)的预测模型。首先,利用 EMD 处理非线性的负荷序列,将序列分解为多个本征模态函数(IMF)以及残差(Res),引入非线性递减分配方法和正弦函数分别改进粒子群算法(PSO)的惯性权重和学习因子,可以更有效地寻找 LSTM 参数的最优解。其次,利用 IPSO 优化 LSTM 的第 1 层神经元个数、损失率、以及批量大小等参数,将所有 IMF 和 Res 分为高、中、低频三组分量,并代入优化后的 LSTM 网络进行预测,叠加获取最终的预测结果。最后,以 GEFCOM2014 预测竞赛电力负荷数据集进行仿真实验,并且对 LSTM、IPSO-LSTM、EMD-PSO-LSTM 这 3 种模型作比较,结果表明所提的预测模型具有较高的预测精度。

关键词:短期负荷预测;经验模态分解;改进的粒子群算法;长短时神经网络

中图分类号: TN2 **文献标识码:** A **国家标准学科分类代码:** 520.604

Short term power load forecasting based on EMD-IPSO-LSTM model

Zhao Yiming Ji Yuehui Liu Junjie Chen Jiaqi

(School of Electrical Engineering and Automation, Tianjin University of Technology, Tianjin 300384, China)

Abstract: Accurate prediction of short-term load provides basis for power dispatching of power plants and improves the economy of power systems. Due to the non-linear and non-stationary nature of load data, this paper proposes a prediction model based on empirical mode decomposition — improved particle swarm optimization — long short-term memory (EMD-IPSO-LSTM). First, the EMD is used to deal with the nonlinear load sequence, and the sequence is decomposed into multiple intrinsic mode functions (IMF) and residuals (Res). The nonlinear decreasing assignment method and sine function are introduced to improve the inertia weight and learning factor of particle swarm optimization (PSO) respectively, so that the optimal solution of LSTM parameters can be found more effectively. Secondly, the IPSO is used to optimize the parameters such as the number of neurons in the first layer of LSTM, the loss rate, and the batch size. All IMF and res are divided into three groups: high, medium, and low frequency components, and are substituted into the optimized LSTM network for prediction. The final prediction result is obtained by superposition. Finally, a simulation experiment is carried out with the GEFCOM2014 power load forecasting competition data set, and compared with LSTM, IPSO-LSTM and EMD-PSO-LSTM. The results show that the proposed forecasting model has higher forecasting accuracy.

Keywords: short term load forecasting; EMD; IPSO; LSTM

0 引言

电力负荷预测是以历史数据为关键组成部分对未来负荷数据进行预测^[1]。负荷预测中最常见的按时间跨度分为短期负荷预测、中期负荷预测和长期负荷预测 3 种。

短期负荷预测是指日负荷预测和周负荷预测,中期负荷预测是指月至年的负荷预测,长期负荷预测是指未来 1 年以上时间段内的负荷预测。中期负荷预测可为设备维修计划提供便利。一年以上长期负荷预测可以成为电力系统发展规划的前提。短期如日负荷预测对电力系统安全运

行、节约发电成本、提升用电质量、优化电力调度等方面有重要意义^[2]。

传统的预测模型主要利用历史负荷数据的时序性,方法较为简单。趋势扩展方法通常根据梯度定律推断其未来趋势和状态。类似地,回归分析的方法是把负荷及影响因素分别作为自变量和因变量,寻找二者关系和回归方程,从而预测将来的负荷值^[3]。时间序列方法是最常用的预测方法之一,常用的时间序列预测方法有自回归综合移动平均(autoregressive integrated moving average model, ARIMA)模型^[4]、季节性自回归综合滑动平均(seasonal autoregressive integrated moving average, SARIMA)模型^[5]、具有外部输入的自回归综合运动平均(autoregressive integrated moving average model, ARIMAX)模式^[6]等。但传统方法一般都把历史和预测数据看成简单的数学关系,无法较好地处理非平稳、非线性的数据。

随着机器学习的不断快速发展,机器学习的方法被广泛的应用于图像处理中,在电力负荷预测方面也取得了一定的成就。文献[7]采用模糊C均值方法来进行特征提取,然后用组合核函数作为支持向量机(support vector machine, SVM)模型的核函数,最后用烟花算法在此基础上进行了优化,提高了模型预测性能。文献[8]采用自适应网格法的多目标粒子群优化算法(multiple objective particle swarm optimization, MOPSO)优化BP神经网络,达到了较好的预测结果。文献[9]采用粒子群算法(particle swarm optimization, PSO)算法优化SVM参数,寻找SVM的最优参数组合,构建模型进行训练与预测,在一定程度上保证了短期负荷预测的精度。文献[10]采用改进的深度稀疏自编码器(improved deep learning sparse auto encoder, IDSAE)和果蝇优化算法(fruit fly optimization algorithm, FOA)优化极限学习机(extreme learning machine, ELM),减小了预测误差。文献[11]提出一种混沌鲸鱼算法优化的ELM预测模型,优化ELM的初始权值和偏置,减小输出误差。上述机器学习的方法虽然在处理非线性数据时取得了一定的效果,但是这些方法本身的特征提取能力较弱,并且预测随机性较大的数据时精度较低。

近年来,深度学习在负荷预测的比重越来越大。深度学习神经网络具有更加复杂的结构模型,更强的学习能力以及泛化能力等。文献[12]使用比循环神经网络(recursive neural network, RNN)更具有更多优点的长短期记忆网络(long short-term memory, LSTM)网络进行电力负荷预测,克服了RNN的梯度爆炸等问题,提高了预测的准确性。文献[13]将卷积神经网络(convolutional neural networks, CNN)与LSTM进行结合,提出了二者结合的混合预测模型,利用CNN对历史负荷等数据进行特征提取,再利用LSTM对其进行预测,得到了比单一模型更好的预测结果,但文献中并未充分的考虑LSTM本身超参数对预测精度的影响,神经元个数等参数对精度影响较

大,手动调节容易错过最优的超参数组合。文献[14]提出了一种基于经验模态分解(empirical mode decomposition, EMD)和LSTM网络结合的预测模型,充分发挥各算法优势提高了预测精度。文献[15]采用贝叶斯准则(Bayesian information criterion, BIC)进行特征提取,引入加权皮尔逊距离的密度峰值方法识别负荷曲线,结合LSTM进行负荷预测。文献[16]采用EMD-CNN-LSTM混合模型进行短期电力负荷预测,首先将负荷数据进行EMD平稳化处理,分解后的分量重构并叠加,利用CNN进行特征提取,最后输入到LSTM网络进行预测,得到了精度较高的结果。文献[17]采用PSO对LSTM的超参数进行优化,不断训练寻找合适的超参数,提高了模型精度与稳定性但未考虑PSO中惯性权重与学习因子对寻优过程的影响。但上述文献均需要人为手动调节神经网络参数。

为了解决上述问题,本文提出一种改进的PSO算法(improved particle swarm optimization, IPSO)与EMD算法以及LSTM相结合的预测模型,实现了神经网络超参数的自动寻优和模型预测精度的提高。首先用EMD对原始数据进行分解,以便于更好的特征提取,然后通过改PSO的惯性权重 w 以及学习因子 c_1, c_2 后的算法来对LSTM网络的神经元个数、损失率、批大小等参数进行优化,最后将数据带入优化后的网络进行负荷预测并对结果加以验证。

1 基于EMD-IPSO-LSTM组合模型的短期电力负荷预测

1.1 EMD

经验模态分解是Huang等^[18]于1998年提出的一种信号处理方法。EMD根据数据本身的时间尺度特征分解信号,不预设任何基函数,该方法在处理非平稳和非线性数据方面具有很大的优势^[19]。原始信号来自数据的特征,通过EMD分解为固有模式函数(intrinsic mode function, IMF)。因此,经验模态分解可以有效地分解奇异值,避免陷入局部最优,提高模型的性能和鲁棒性。

1.2 PSO算法

PSO算法根据组的适应度移动个体寻找最佳区域,每个粒子在搜索空间中移动以寻找最有利的飞行路径^[20],已广泛用于神经网络训练和结构优化设计^[21]。

在求解优化问题时,粒子群算法通过跟踪个体最优粒子和群体最优粒子来更新粒子的速度和位置。可以描述如下:在 D 维搜索空间中,有 m 个粒子形成一个组。在第 t 次迭代中,第 i 个粒子的位置和速度以及搜索到的最优位置分别为 $X_{i,j}(t)$ 、 $V_{i,j}(t)$ 和 $P_{i,j}$ 。第 e 粒子通过监督个体的最佳适应值 P_{best} 和组的当前最佳适应值 g_{best} 来更新其位置和速度。正由于这两个极值的作用,粒子便不断地更新速度及位置,逐渐的寻找最优位置。其中,速度更新和位置更新如下:

$$V_{i,j}(t+1) = \omega V_{i,j}(t) + c_1 r_1 [P_{i,j} - X_{i,j}(t)] + c_2 r_2 [P_{i,j} - X_{i,j}(t)] \quad (1)$$

$$X_{i,j}(t+1) = X_{i,j}(t) + V_{i,j}(t+1) \quad (2)$$

式中： c_1, c_2 为正的学习因子，范围为 $0 \sim 2$ ； r_1, r_2 为 $0 \sim 1$ 之间均匀分布的随机数； ω 为惯性权重。

1.3 LSTM 网络

LSTM 是由 Hochreiter 等^[22]于 1997 年提出 RNN 的变体改进，是用于预测时间序列的专家模型，有效地处理长期时间依赖问题。与 RNN 相比，LSTM 结构中添加了输入门、遗忘门和输出门，有效地处理消失梯度问题^[23]。LSTM 模型架构如图 1 所示。

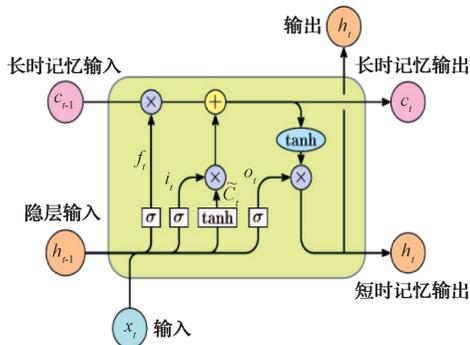


图 1 LSTM 模型的架构

其中， f_t 为遗忘门，输入门控制上一刻记忆单元 c_{t-1} 需要遗忘的信息； x_t 为时间步长为 t 的当前输入； i_t 为输入门，控制当前时刻候选状态 c_t 需要存储的信息； o_t 为输出门，控制当前时刻记忆单元 c_t 输出给外部状态 h_t 的信息。

2 EMD-IPSO-LSTM 短期电力负荷预测模型构建

2.1 IPSO 算法

虽然 PSO 在解决复杂优化问题方面有着显著的效果，但在处理优化问题时缺乏有效的参数控制，容易陷入局部最优，导致误差大，搜索精度低。本文改进了 PSO 算法的惯性权重和学习因子，找到了二者最佳的参数组合，并使用 IPSO 优化 LSTM 模型的参数，以减少人为选择参数的主观影响。

1) 改进惯性权重

惯性权重 ω 主要用于控制迁移速度对当前粒子速度的影响。一般的惯性权重分配策略是线性递减分配，权重 ω 随着迭代次数线性减小。虽然该策略可以在一定程度上提高 PSO 算法的性能，但随着迭代次数的线性减少，PSO 的局部搜索能力将变差。因此，采用非线性减量分配方法，如下式所示：

$$\omega = \omega_{\max} - (\omega_{\max} - \omega_{\min}) \cdot \sqrt{\frac{i}{item_max}} \quad (3)$$

式中： ω_{\max} 和 ω_{\min} 分别为最大惯性权重和最小惯性权重。此时， ω_{\max} 取 0.9， ω_{\min} 取 0.1， i 是当前迭代次数，

$item_max$ 是最大迭代次数，取 10。

2) 改进学习因子

学习因子 c_1 和 c_2 主要用于调整移动到个体最优位置和全局最优位置的粒子的步长。在实际应用中，随着迭代过程的推进，通常需要 c_1 的值从大变小，以加快早期迭代的搜索速度，提高全局搜索能力。并且 c_2 的值需要从小变大以便于在迭代的后期进行局部细化搜索并同时提高精度。然而，一般的 PSO 通常设置 $c_1 = c_2 = 1$ ，不能满足实际应用的要求。因此，引入正弦函数来寻找学习因子的最佳数值组合，如下式所示：

$$\begin{cases} c_1 = 2\sqrt{1 - \sin\left(\frac{\pi}{2} \cdot \frac{i}{item_max}\right)} \\ c_2 = 2\sqrt{\sin\left(\frac{\pi}{2} \cdot \frac{i}{item_max}\right)} \end{cases} \quad (4)$$

2.2 EMD-IPSO-LSTM 短期电力负荷预测模型

为了提高负荷预测的精度，充分发挥单个模型的优势，EMD、IPSO 和 LSTM 应用到负荷预测当中去，将三者组合起来。首先，针对负荷数据非线性、随机性强等特点，利用 EMD 对负荷数据集进行分解，分解为 11 个 IMF 和一个残差量 (Res)，将这 12 个量分为高、中、低频分量 3 组；利用 IPSO 优化 LSTM 的隐藏层神经元个数，dropout 比率以及 batch_size 批量大小，将 3 组分量分别输入到优化好的 LSTM 网络进行预测，将 3 组预测结果进行叠加，即得到了最终的结果。将预测结果与真实值进行对比，选取决定系数 (coefficient of determination, R^2)、平均绝对误差 (mean absolute error, MAE)、均方误差 (mean-square error, MSE) 和均方根误差 (root mean square error, RMSE) 4 个指标进行对比。该过程分为如下 4 步。

1) EMD 数据分解

负荷预测数据集有非线性、随机性强等特点，直接预测一般不会得到更好的效果。用 EMD 把数据进行分解为不同的 IMF 和 Res，可以降低非线性等缺点，如果直接将各个分量分别代入神经网络去预测，会使数据的特征学习不充分，因此将分解的 IMF 和 Res 分解为高中低频 3 组分量，以便更好的进行特征提取阶段从而达到较好的预测结果。

2) 改进的 PSO 优化 LSTM 网络

(1) 初始化 PSO 参数和 LSTM 网络的参数，这些参数包括学习因子、惯性权重、种群规模、粒子速度和位置的限制范围、搜索维度等。

(2) 确定适应度函数，本文使用的适应度函数为：

$$fit_i = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - x_i}{x_i} \right| \quad (5)$$

式中： n 为需要预测的预测值的总个数； y_i 为样本的预测值； x_i 为实际值。

(3) 计算每一次迭代过程中粒子的位置和适应度函数值。

(4) 获取粒子个体最优位置 P_{best} 和群体最优位置 g_{best} 。

(5) 更新粒子的速度和位置。

(6) 看是否满足结束条件(即是否达到最大迭代条件),满足则进行下一步,不满足则返回步骤(3)继续进行优化。

(7) 将优化后的最优结果输出并保存。

3) 负荷预测

将分解的 IMF 和 Res 分组后的 3 组高中低频分量分别带入到利用改进的 PSO 优化好的 LSTM 网络中进行预测,将 3 组预测结果进行叠加,得到最终预测结果。

4) 预测结果评价

选取 R^2 、MAE、MSE 和 RMSE 4 种评价指标进行结果评估。其中,MAE、MSE 和 RMSE 三者的值越小代表精度越高, R^2 越接近 1 越好。各个误差指标的公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (x_i - \bar{y})^2} \quad (6)$$

$$MAE = \sum_{i=1}^n \frac{|y_i - x_i|}{n} \quad (7)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2 \quad (8)$$

$$RMSE = \sqrt{\sum_{i=1}^n (y_i - x_i)^2} \quad (9)$$

式中: y_i 代表预测值; x_i 代表的实际值。

整个过程的算法流程如图 2 所示。

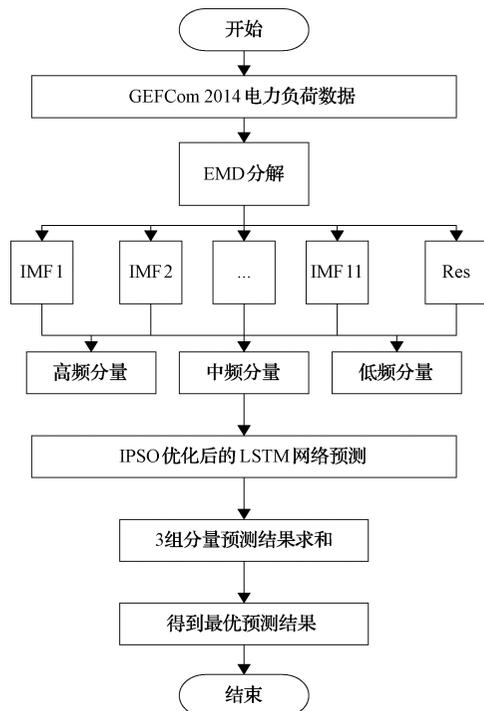


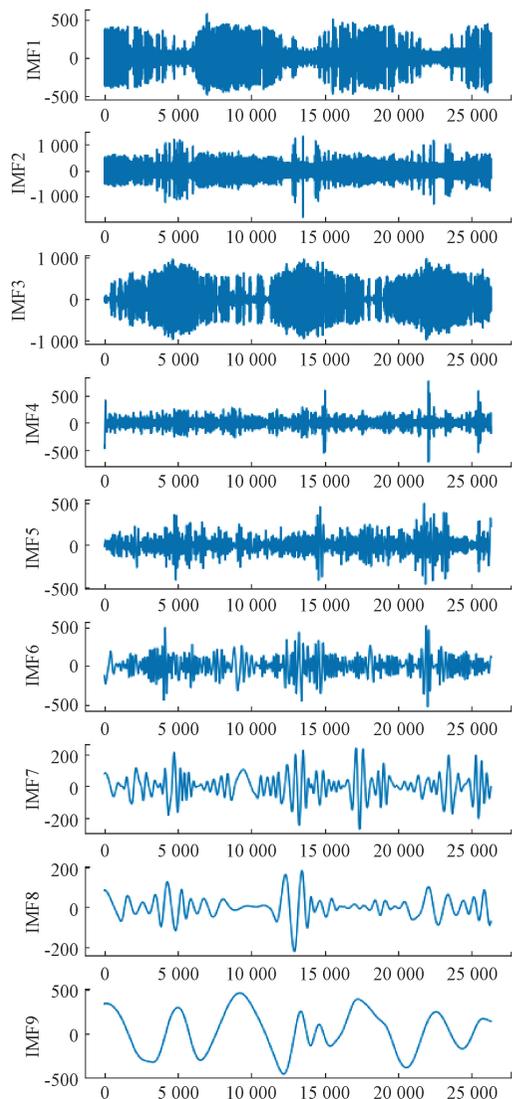
图 2 EMD-IPSO-LSTM 日负荷预测模型流程

3 算例分析

数据集取自 GEFCom2014 预测竞赛,由 2012 年~2014 年间 3 年的每小时电力负荷和温度值组成。本文实验使用的计算机环境配置 Windows10 系统, Intel Core I5-1135,CPU 频率为 2.4 GHz。编程语言为 python,其版本为 3.7,框架采用 tensorflow2.4,集成开发环境为 VS Code。

3.1 EMD 分解

将电力负荷数据按照 EMD 方法进行分解,分解为不同频率的 IMF,共分解为 11 个 IMF 和 1 个 Res,前 4 个 IMF 分量频率较高,代表数据中的高频成分;后 3 个 IMF 和最后的 Res 频率较低可以代表数据中的低频分量。分解后的 IMF 及 Res 如图 3 所示。IMF₁~IMF₄ 为高频分量,IMF₅~IMF₈ 为中频分量,IMF₉~IMF₁₁ 以及 Res 为低频分量。



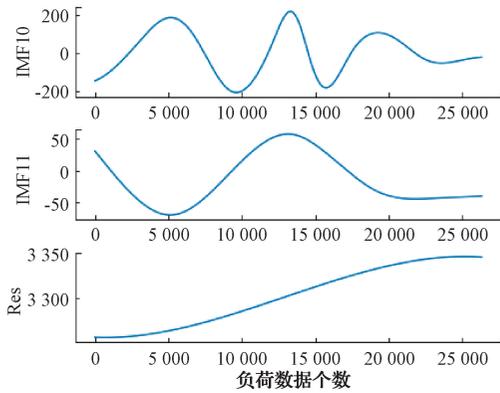


图3 负荷数据分解后的IMF和Res

3.2 改进的PSO优化

本文实验使用改进的PSO对LSTM的两个参数进行寻优,主要是LSTM神经网络第1层神经元个数和droupout比率以及batch_size批量大小,优化的参数范围以及结果如表1所示。

表1 优化参数范围及结果

优化的参数	上限值	下限值	最优值
神经元个数	259	256	257
Droupout 比率	0.19	0.03	0.034 8
Batch_size 批大小	128	64	113

当神经网络第1层神经元个数为257且droupout比率约为0.034 8,batch_size为113时为最优结果。

3.3 负荷数据预测

采用数据集中电力负荷的前80%作为训练集,后20%作为测试集。并且使用该数据集在LSTM、IPSO-LSTM、EMD-PSO-LSTM、EMD-IPSO-LSTM和真实值进行对比实验,预测结果如图4所示。

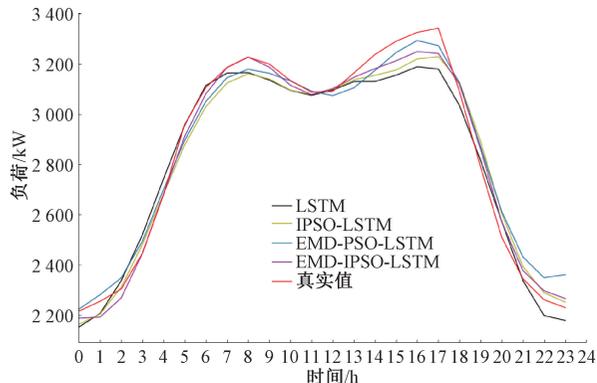


图4 4种模型负荷预测

采用4种指标评价预测精度,如表2所示。

从图4可以看出,本文提出的EMD-IPSO-LSTM算法预测效果得到提升。不同预测模型逐点的相对误差对

表2 4种预测模型比较

预测模型	R ²	MAE/kW	MSE/kW	RMSE
LSTM	0.966	55.92	4 913.51	70.10
IPSO-LSTM	0.974	55.31	4 246.80	65.16
EMD-PSO-LSTM	0.976	50.32	3 520.18	59.33
EMD-IPSO-LSTM	0.987	35.36	2 020.88	44.98

比如图5所示,本文提出的EMD-IPSO-LSTM模型缩小了误差浮动区间,具有较高的平稳性。除了少数点的误差较大,但整体预测效果较好,24个点相对误差总体低于3.015%,使预测结果更加接近于真实值。由表2可知,预测精度由低到高依次为LSTM、IPSO-LSTM、EMD-PSO-LSTM、EMD-IPSO-LSTM。本文预测模型的R²值最接近1,其他3种误差MAE、MSE、RMSE最小。EMD-PSO-LSTM的R²值比IPSO-LSTM提高了0.002,MAE降低了4.99 kW,MSE降低了726.62 kW, RMSE降低了5.83 kW,EMD分解降低了数据的非线性和不稳定性,从而提高了模型精度。相比于EMD-PSO-LSTM组合模型,所提出模型R²提高了0.011,MAE降低了14.96 kW,MSE降低了1 499.3 kW, RMSE降低了14.35。综上所述,预测模型拥有较高的预测精度。

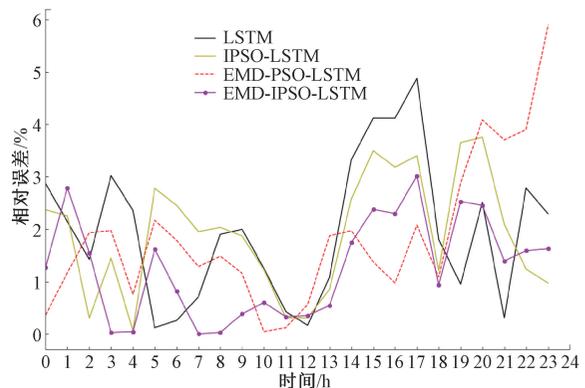


图5 4种模型逐点相对误差对比

4 结论

本文针对负荷数据的非线性,不稳定性,建立了EMD-IPSO-LSTM短期负荷预测模型,进行了负荷预测,并以GEFCom2014负荷数据集为例进行了验证。该模型可以充分发挥各部分优势:EMD分解可以降低数据的非线性和随机性;LSTM相比于CNN、MLP等模型在处理时间序列数据上具有长时记忆功能,实现简单等优势;而IPSO算法可以进一步的对其神经网络神经元个数以及droupout比率及batch_size批大小等参数进行优化,进一步提高模型精度。本文研究仅考虑了负荷序列的数据,下一步可以引入气候、经济等影响因素,进一步在此基础上提高预测精度。

参考文献

- [1] PANDA S K, JAGADEV A K, MOHANTY S N. Forecasting methods in electric power sector [J]. International Journal of Energy Optimization and Engineering, 2018, 7(1): 1-21.
- [2] 王晓辉, 邓威威, 齐旺. 基于超参数优化的短期电力负荷预测模型[J]. 国外电子测量技术, 2022, 41(6): 152-158.
- [3] 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.
- [4] LEE C M, KO C N. Short-term load forecasting using lifting scheme and ARIMA models[J]. Expert Systems with Applications, 2011, 38(5):5902-5911.
- [5] JETCHEVA J G, MAJIDPOUR M, CHEN W P. Neural network model ensembles for building-level electricity load forecasts[J]. Energy and Buildings, 2014, 84: 214-223.
- [6] 崔和瑞, 彭旭. 基于 ARIMAX 模型的夏季短期电力负荷预测[J]. 电力系统保护与控制, 2015, 43(4): 108-114.
- [7] 简献忠, 顾祎婷. 一种基于全过程优化支持向量机的短期电力负荷预测方法[J]. 电力科学与工程, 2018, 34(11):45-51.
- [8] 张静, 石鑫. 基于改进 MOPSO-BP 算法的短期电力负荷预测研究[J]. 电力学报, 2019, 34(6):556-563.
- [9] 王义军, 李殿文, 高超, 等. 基于改进的 PSO-SVM 的短期电力负荷预测[J]. 电测与仪表, 2015, 52(3): 22-25.
- [10] 张淑清, 要俊波, 张立国, 等. 基于改进深度稀疏自编码器及 FOA-ELM 的电力负荷预测[J]. 仪器仪表学报, 2020, 41(4): 49-57.
- [11] 吴飞, 李霆, 张航, 等. 基于 CWOA-ELM 的短期电力负荷预测研究[J]. 电子测量技术, 2020, 43(4):88-92.
- [12] CUI C, HE M, DI F, et al. Research on power load forecasting method based on LSTM model[C]. 2020 IEEE 5th Information Technology and Mechatronics Engineering Conference (ITOEC), 2020:1657-1660.
- [13] 陆继翔, 张琪培, 杨志宏, 等. 基于 CNN-LSTM 混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(8):131-137.
- [14] 王荣茂, 谢宁, 于海洋, 等. 基于 EMD-LSTM 模型的台区负荷短期预测方法[J]. 实验室研究与探索, 2022, 41(1):62-66,79.
- [15] 夏飞, 张洁, 张浩, 等. 基于 BIC 准则和加权皮尔逊距离的居民负荷模式精细识别及预测[J]. 电子测量与仪器学报, 2020, 34(11):33-42.
- [16] 徐岩, 向益锋, 马天祥. 基于 EMD-CNN-LSTM 混合模型的短期电力负荷预测[J]. 华北电力大学学报:自然科学版, 2022, 49(2):81-89.
- [17] 王晓辉, 邓威威, 齐旺. 基于 PSO-LSTM 的电力负荷预测模型[J]. 上海节能, 2022(2):164-169.
- [18] HUANG N E, ZHENG S, LONG S R. A new view of nonlinear water waves: The Hilbert spectrum[J]. Annual Review of Fluid Mechanics, 1999, 31(1): 417-457.
- [19] LAHMIRI S. Comparing variational and empirical mode decomposition in forecasting day-ahead energy prices[J]. IEEE Systems Journal, 2015, 11(3): 1907-1910.
- [20] HU Y, LI J, HONG M, et al. Short term electric load forecasting model and its verification for process industrial enterprises based on hybrid GA-PSO-BPNN algorithm: A case study of papermaking process[J]. Energy, 2019, 170: 1215-1227.
- [21] 蒋锋, 彭紫君. 基于混沌 PSO 优化 BP 神经网络的碳价预测[J]. 统计与信息论坛, 2018, 33(5):93-98.
- [22] HOCHREITER S, SCHMIDHUBER R. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [23] YUAN P, LEI Z L, ZENG Q H, et al. Load forecasting of refrigerated display cabinet based on CEEMD-IPSO-LSTM combined model [J]. Open Physics, 2021, 19(1): 360-374.

作者简介

赵一鸣, 硕士研究生, 主要研究方向为电力系统负荷预测。

E-mail: zhaoyiming_tjlg@126.com

吉月辉(通信作者), 博士, 副教授, 主要研究方向为信息物理系统、电力系统负荷预测。

E-mail: jiyuehuitju@126.com

刘俊杰, 博士, 讲师, 主要研究方向为非线性系统建模与控制、电力系统负荷预测。

陈嘉齐, 硕士研究生, 主要研究方向为电力系统负荷预测。