

# 基于 PSR-LSTM 的机组负荷短期预测研究

王欣然<sup>1</sup>, 冯磊华<sup>1</sup>, 杨 锋<sup>2</sup>, 候孟超<sup>1</sup>

(1. 长沙理工大学 能源与动力工程学院, 湖南长沙 410114; 2. 湖南江河机电自动化设备股份有限公司, 湖南长沙 410013)

**摘要:**为了提高机组负荷短期预测精度,针对其非线性、时序性特点,以某 660 MW 机组为研究对象,提出一种基于相空间重构(PSR)和长短期记忆网络(LSTM)的负荷预测模型 PSR-LSTM。利用归一化函数(mapminmax)将原始机组负荷数据归一化处理后,选用 C-C 法与小数据量法证明历史负荷数据具有混沌特性并进行负荷时序重构;将重构后的每一维特征向量作为时间步输入建立的 LSTM 模型训练进行短期预测。研究表明:PSR-LSTM 预测模型在 12 h 与在 5 min 内的平均绝对百分比误差分别为 1.38% 和 0.39%,均方根误差分别为 6.38 和 1.83;相较于标准 LSTM 模型以及传统自回归滑动平均模型(ARMA),PSR-LSTM 模型误差较低并具有更高的预测精度。

**关键词:**混沌性分析;相空间重构;长短期记忆;PSR-LSTM;负荷预测

中图分类号:TM621 文献标识码:A DOI:10.16146/j.cnki.rndlgec.2021.05.011

[引用本文格式] 王欣然, 冯磊华, 杨 锋, 等. 基于 PSR-LSTM 的机组负荷短期预测研究[J]. 热能动力工程, 2021, 36(5): 66 - 72. WANG Xin-ran, FENG Lei-hua, YANG Feng, et al. Study on short-term load forecasting of units based on PSR-LSTM [J]. Journal of Engineering for Thermal Energy and Power, 2021, 36(5): 66 - 72.

## Study on Short-term Load Forecasting of Units based on PSR-LSTM

WANG Xin-ran<sup>1</sup>, FENG Lei-hua<sup>1</sup>, YANG Feng<sup>2</sup>, HOU Meng-chao<sup>1</sup>

(1. School of Energy and Power Engineering, Changsha University of Science and Technology, Changsha,

China, Post Code:410114; 2. Hunan Jianghe Electromechanical Automation Equipment

Co. Ltd., Changsha, China, Post Code:410013)

**Abstract:** In order to improve the accuracy of short-term load forecasting, a PSR-LSTM load forecasting model based on phase space reconstruction (PSR) and long-term memory network (LSTM) is proposed for a 660 MW unit. After normalizing the original unit load data with the normalized function (mapminmax), C-C method and small data method are used to prove the chaotic characteristics of historical load data, and load time series reconstruction is carried out; each dimension feature vector after reconstruction is used as time step input to establish LSTM model for short-term prediction. The results show that: the average absolute percentage error of PSR-LSTM prediction model in 12 h and 5 min is 1.38% and 0.39%, and the root mean square error is 6.38 and 1.83, respectively. Compared with the standard LSTM model and the traditional auto-regressive moving average model (ARMA), the model error is lower and the prediction accuracy is higher.

**Key words:** chaos analysis, phase space reconstruction, long short-term memory, PSR-LSTM, load forecasting

## 引言

随着电力系统的快速发展,越来越多电力工作者致力于研究火电机组负荷预测问题。研究人员从电力系统<sup>[1]</sup>本身出发,在分析大量历史数据<sup>[2]</sup>的基础上,结合新一代人工智能技术<sup>[3]</sup>与关联规则挖掘方法<sup>[4]</sup>探究其变化规律并进行预测。电网根据预测结果,基于机组实况为电厂安排各项调度计划曲线<sup>[5]</sup>,进行负荷经济分配<sup>[6]</sup>合理化等。但在实际情况中,随着电网中可再生能源装机容量的扩大,并网机组形式更加复杂多变,这使得机组负荷预测变得更为重要。而电网给出的计划曲线仅能作为参考,两者存在着较大的偏差<sup>[7]</sup>。由于短期内我国的能源结构仍然会以火电机组为主,因此研究应从机组实际出发,将单台机组的实际负荷预测值与电网调度结合向电厂下发计划曲线。

近年来,研究者已经开始重视对火电机组的负荷预测研究。马良玉<sup>[8]</sup>通过研究机组负荷在扰动下的变化量来预测负荷。刘卫亮等人<sup>[9]</sup>利用支持向量机(SVM)方法建立模型,辨识火焰辐射图像与机组负荷之间的关系并进行负荷预测。张然然等人<sup>[10]</sup>在小波变换的基础上对自回归差分滑动平均模型(ARIMA)进行改进并预测机组负荷。丁伟等人<sup>[7]</sup>提出历史匹配预测算法(HMF),利用最相似的负荷变化趋势来预测机组负荷。魏骜<sup>[11]</sup>和李冬辉等人<sup>[12]</sup>分别采取循环神经网络(RNN)及LSTM进行短期预测研究,取得了较好的预测效果,但不能直接表达多维特征具有的复杂信息。目前急需一种适合机组负荷特性、模型建立简单且预测精度较高的方法进行负荷预测。

由于机组负荷是典型的非平稳时序,利用传统时序建模的精度不高,可对火电机组负荷特性进行分析研究,找到其随时间变化的规律。因此,本文以某660 MW机组为研究对象,将机组历史负荷数据看作是时间序列进行非线性时序预测。首先对其进行混沌特性分析,采用C-C方法对时序进行PSR,将单维负荷时序映射到高维相空间,找到其自身的特点后建立多维信息,并与LSTM网络结合建立预测模型,对该模型进行研究分析并给出模型建立步

骤与预测流程,最后将预测结果与LSTM、自回归滑动平均模型(ARMA)进行比较。

## 1 某660 MW机组负荷混沌特性分析

以某电厂660 MW超超临界机组作为研究对象,该机组采用一次中间再热、三缸、四排汽凝汽式汽轮机与单炉膛、一次再热、平衡通风、露天布置、固态排渣、全钢架构、全悬吊结构的Ⅱ型直流锅炉,机组于2016年10月15日完成168 h试运行,额定主蒸汽压力为25.4 MPa,额定主蒸汽温度为571 °C,再热蒸汽温度为569 °C,最大连续蒸发量为2 101.8 t/h,负荷在50%~70%范围内波动。

### 1.1 相空间重构

相空间重构理论(PSR)由Takens等人<sup>[13]</sup>提出,应用时间序列的方法,提取原时序的一维特征信息到高维空间中,增加特征维度,使序列包含信息最大化。其关键在于确定出最优的嵌入维数m和时间延迟τ。

选取该机组2019年3月14日至4月13日的历史负荷数据,使用函数mapminmax对数据进行归一化处理,经过归一化后的数据处于统一信息范围,易于进行综合对比评价,适应后期模型的输入输出,减小误差,其形式为:

$$X_k = \frac{X_k - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

式中:X—原始数据;X<sub>min</sub>—原始数据最小值;X<sub>max</sub>—原始数据最大值;X<sub>k</sub>—归一化后的数据。

设原始机组负荷的时序为:X={x<sub>1</sub>,x<sub>2</sub>,…,x<sub>N</sub>},经过PSR后得到:

$$\begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_M \end{bmatrix} = \begin{bmatrix} x_1 & x_{1+\tau} & \cdots & x_{1+(m-1)\tau} \\ x_2 & x_{2+\tau} & \cdots & x_{2+(m-1)\tau} \\ \vdots & \vdots & & \vdots \\ x_M & x_{M+\tau} & \cdots & x_N \end{bmatrix} \quad (2)$$

式中:N—数据;M—相点数;其中M=N-(m-1)τ。

选用H.S.Kim等人<sup>[14]</sup>提出的C-C方法,利用嵌入窗口τ<sub>w</sub>=(m-1)τ,同时求取τ、m对机组负荷进行相空间重构。

对于时序X={x<sub>1</sub>,x<sub>2</sub>,…,x<sub>N</sub>},根据式(2)定义关联积分:

$$C = (m, N, r, \tau)$$

$$= \frac{2}{M(M-1)} \times \sum_{1 \leq i < j \leq M} \theta(r_k - \|X_i - X_j\|) \quad (3)$$

$$\theta(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (4)$$

式中:  $r_k$  ( $r_k > 0$ ) — 控制半径;  $\theta(x)$  — Heaviside 函数;  $C(m, N, r, \tau)$  — 相空间内任意两点间的距离小于  $r$  的概率。

将机组负荷的时序  $\{x_i\}$  分成  $t$  个不相交子序列, 采用分块平均策略定义检验统计量  $S$  和  $\Delta S$ :

$$\left\{ \begin{array}{l} S(m, N, r, t) = \frac{1}{t} \times \\ \sum_{i=1}^M \left[ C_i(m, \frac{N}{t}, r, t) - C_i^m(m, \frac{N}{t}, r, t) \right] \end{array} \right. \quad (5)$$

$$\Delta S(m, N, r, t) = \max(S(m, N, r, t)) - \min(\max(S(m, N, r, t)))$$

由 BDS 统计对  $N, m, r$  进行估计, 得到:

$$\left\{ \begin{array}{l} \bar{S}(t) = \frac{1}{16} \sum_{m=2}^5 \sum_{k=1}^4 S(m, N, r_k, t) \\ \bar{\Delta S}(t) = \frac{1}{4} \sum_{m=2}^5 \Delta S(m, N, t) \end{array} \right. \quad (6)$$

$$S_{cor}(t) = |\bar{\Delta S}(t)| + |\bar{S}(t)| \quad (7)$$

图 1 为机组负荷时序利用  $C-C$  重构后的检验统计量  $\bar{\Delta S}(t)$ ,  $S_{cor}(t)$  关于时间的延迟。由式(6)和式(7)可知,  $\bar{\Delta S}(t)$  的第一个极小值点即为时间延迟  $\tau = 5$ ,  $S_{cor}(t)$  的最小值点为嵌入窗口  $\tau_w = 16$ , 最后估算出嵌入维数  $m = 4$ , 相点数  $M = 2865$ , 即重构后的序列尺寸为  $2865 \times 4$ 。

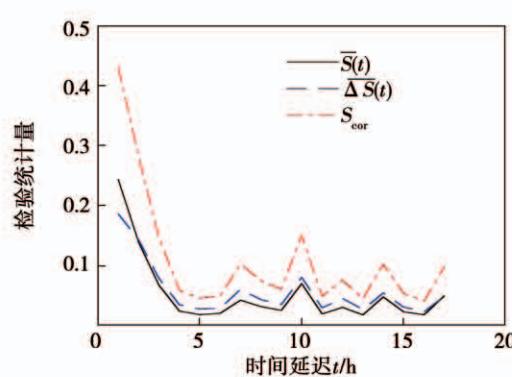


图 1  $C-C$  法相空间重构

Fig. 1 Reconstruction of  $C-C$  phase space

## 1.2 最大 Lyapunov 指数

通过 Lyapunov 指数<sup>[15]</sup> ( $\lambda > 0$ ), 可以判断机组负荷时序是否具有混沌特性。选用小数据量法求解最大 Lyapunov 指数, 与其他算法相比, 该算法计算简捷<sup>[16]</sup>、样本需求量小且求解度高<sup>[17]</sup>。

对机组负荷序列进行快速傅里叶变换 (FFT), 求出平均周期  $P$ ; 根据得到的  $m, \tau$ , 重构相空间矩阵  $\{X_j, j = 1, 2, \dots, M\}$ ; 找出相空间中每个点  $X_j$  相隔最近的点  $X_j'$ , 并进行相分离, 即:

$$d_j(0) = \min \|X_j - X_j'\|, |j - j'| > P \quad (8)$$

计算相空间中  $X_j$  最近点所对应的  $i$  个离散时间步长的距离  $d_j(i)$ :

$$d_j(i) = \min \|X_{j+i} - X_{j+i}'\| \quad (9)$$

求出所有的  $Ind_j(i)$  平均  $y(i)$ ,  $q$  为当  $d_j(i) \neq 0$  时的值, 即:

$$y(i) = \frac{1}{q \Delta t} \sum_{j=1}^q Ind_j(i) \quad (10)$$

借助最小二乘法做出回归曲线, 直线斜率就是最大 Lyapunov 指数。图 2 为求得的机组负荷序列最大 Lyapunov 指数  $\lambda = 0.02361$ , 表明重构后的 4 维机组负荷时序具有混沌特性。

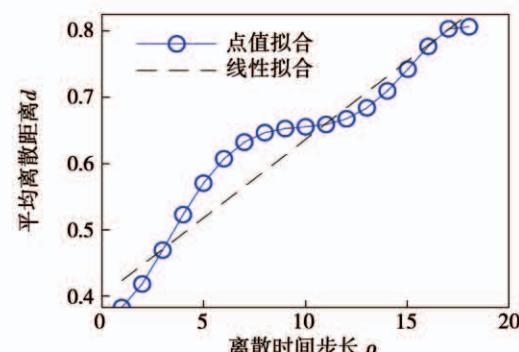


图 2 最大 Lyapunov 指数

Fig. 2 Maximal Lyapunov exponent

## 2 长短期记忆网络模型 (LSTM)

LSTM 是通过改进递归神经网络 (RNN) 得到的模型, 在神经元中增加输入门、输出门和遗忘门<sup>[18]</sup>, 对时序中的关键信息进行选择性的“记忆”与“遗忘”<sup>[19]</sup>。改良后的模型能够有效克服训练中“梯度消失”的现象, 可以记忆长期的信息。LSTM 模型的基本结构如图 3 所示。

状态记忆单元遗忘部分由输入遗忘门的  $x_t$ 、前一时刻隐藏状态输出  $h_{t-1}$  及状态记忆单元  $S_{t-1}$  决定。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (11)$$

式中:  $f_t$ —遗忘门,帮助  $LSTM$  决定从  $S_{t-1}$  中删除的信息;  $b_f$ —对应的偏差值;  $\sigma(\cdot)$ —激活函数,确定遗忘门的激活状态。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (12)$$

$$\tilde{S}_t = \tanh(W_s \cdot [h_{t-1}, x_t] + b_s) \quad (13)$$

$$S_t = f_t \times S_{t-1} + i_t \times \tilde{S}_t \quad (14)$$

式中:  $i_t$ —输入门,决定储存到新状态记忆单元  $S_{t-1}$  的新信息类别;  $\tilde{S}_t$ —添加到新状态单元  $S_t$  的值;  $b_i$  和  $b_s$ —对应的偏差值;  $f_t \times S_{t-1}$  决定  $S_{t-1}$  中遗忘的信息数量,  $i_t \times \tilde{S}_t$  决定新状态记忆单元  $S_t$  添加的信息数量。

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (15)$$

$$h_t = O_t \times \tanh(S_t) \quad (16)$$

式中:  $O_t$ —输出门,计算隐藏状态  $h_t$ ;  $W_f, W_i, W_s$  和  $W_o$ —对应门与输入  $x_t$  以及中间隐藏层输出  $h_{t-1}$  相乘的权重矩阵;  $b_o$ —对应的偏差值;  $f_t, i_t, S_t, O_t, C_t$  和  $h_t$ —遗忘门、输入门、输入节点、输出门、记忆单元状态和隐含状态的输出结果。

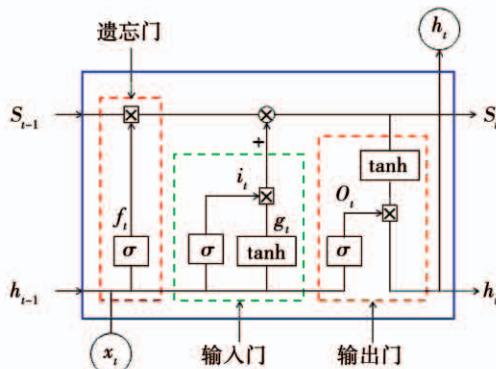


图3 LSTM基本结构

Fig. 3 Basic structure of LSTM

### 3 PSR-LSTM 预测模型

PSR-LSTM 预测模型能够兼具 PSR 多维信息表达能力与 LSTM 的时序信息表达特性。通过 PSR, 机组负荷时序投映到高维空间中, 此时形成的动点轨迹能够随时间变化且在短期内有规律。将重构后

每一维特征向量作为  $LSTM$  的时间步长输入网络, 根据求取的嵌入维数  $m$  确定  $LSTM$  输入层节点数, 由于已经求出嵌入维数  $m$  为 4, 所以  $LSTM$  模型的输入层节点为 4。通过多次实验发现, 适量增加  $LSTM$  隐含层数能够提高预测结果。因此最终模型包含了 4 个隐含层, 各层的节点数分别为 8、16、32 和 64。模型使用  $Adam$  优化算法, 并在各层之间采用  $Dropout$  技术避免模型出现过度拟合的情况。图 4 为模型的网络结构。

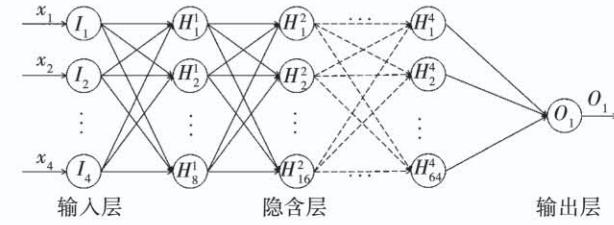


图4 PSR-LSTM预测模型网络结构

Fig. 4 Network structure of PSR-LSTM prediction model

#### 3.1 预测流程

为了加快网络模型的学习速度, 在进行重构前使用函数  $\{mapminmax\}$  对数据进行归一化处理, 并保存各参数; 利用  $C-C$  法求取最优  $m, \tau$  重构时序; 选用小数据量法求取机组负荷时间序列的最大  $Lyapunov$  指数, 判断系统的混沌特性; 确定  $LSTM$  网络层数; 将重构后的每一维时序, 都作为时间步长输入  $LSTM$  模型进行训练并预测; 利用已保存参数的最大值和最小值, 对预测出的数据进行反归一化处理。具体流程如图 5 所示。

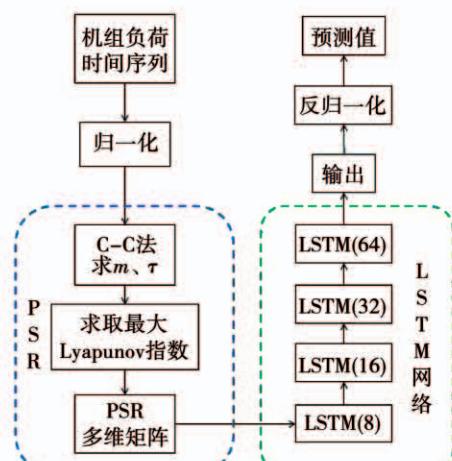


图5 PSR-LSTM预测流程

Fig. 5 PSR-LSTM prediction process

### 3.2 评价指标

为更好地显现出模型效果,采用平均绝对百分比误差(MAPE)和均方根误差(RMSE)作为评价模型预测效果的指标:

$$e_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - T_i}{Y_i} \right| \times 100\% \quad (17)$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - T_i)^2} \quad (18)$$

式中:  $n$ —预测样本数;  $Y_i$ —真实值;  $T_i$ —预测值。

## 4 案例分析

### 4.1 数据选取

为验证 PSR-LSTM 模型的有效性,采用某电厂 2019 年 3 月 14 日至 4 月 13 日无检修或无故障停运情况的机组负荷数据,历史数据可靠性高。数据采样时间间隔为 15 min,共 2 880 条,在此期间用电需求小。选取 3 月 14 日至 4 月 12 日的负荷数据作为训练集进行 PSR-LSTM 预测模型建模,预测未来 12 h 的负荷情况,每 15 min 预测一次,共计 48 个点。设置模型学习率为 0.001,批尺寸 64 个,训练数为 500,随机失活概率为 0.2。在模型中其他参数不变的情况下,通过增加 LSTM 隐含层数来测试模型深度是否合适。当模型增加到 4 层时误差不再降低,因此最终模型含有 4 个隐含层,如表 1 所示。

表 1 不同隐含层数试验结果

Tab. 1 Test results of different hidden layers

LSTM 隐含层数	学习率	训练轮数	训练批次	MAPE/%
1	0.001	500	64	3.572 8
2	0.001	500	64	2.138 7
3	0.001	500	64	2.015 3
4	0.001	500	64	1.470 1
5	0.001	500	64	1.902 5

### 4.2 预测结果

为进一步验证 PSR-LSTM 模型的预测效果,分别采用标准的 LSTM 模型和传统时序预测模型 ARMA 进行预测对比。在 ARMA 模型中,对原始数据进行一阶差分后,利用 AIC 准则进行定阶,并进行 D. W 残差检验,最终确定自回归项  $p=4$ ,滑动平均项  $q=5$ 。训练数据同样采用 3 月 14 日至 4 月 12 日

的历史负荷数据,预测未来 12 h 的负荷。

图 6 给出了模型的预测结果,ARMA 预测误差较大且有一定的滞后性,LSTM 模型对负荷的预测趋势与真实负荷大致相同,但预测值误差较大。比较而言,PSR-LSTM 模型预测曲线与真实曲线更接近,但在负荷骤变时的预测效果一般。

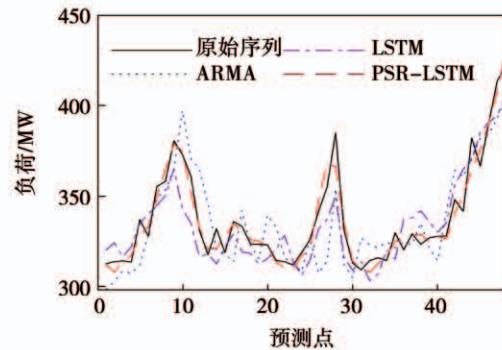
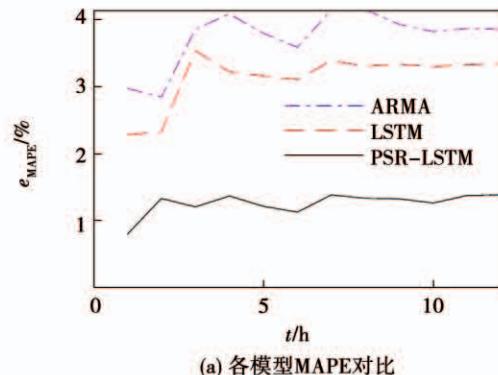


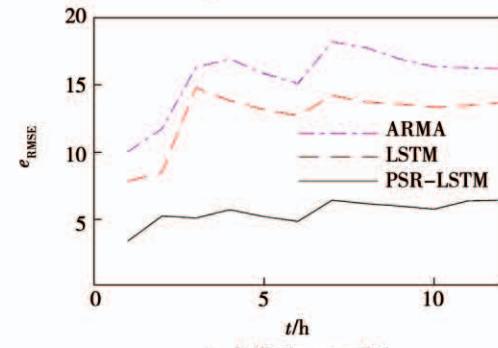
图 6 12 h 预测对比

Fig. 6 Comparison of 12 h prediction

图 7 给出了各模型 12 h 内各模型 MAPE 及 RMSE 的对比,PSR-LSTM 模型的误差在 12 h 内远小于另外两种。随着预测时间的增加,各模型的误差均有所增大,但是 PSR-LSTM 模型的性能指标始终优于其他两个模型。



(a) 各模型MAPE对比



(b) 各模型RMSE对比

图 7 12 h 预测误差对比

Fig. 7 Comparison of 12 h prediction error

为了进一步对并网机组负荷进行预测,通过缩短采样时间增加数据密度,以10 s一个点为采样时间间隔,选取4月11日22:00至13日2:00的历史数据,预测5 min内的负荷变化,预测30个点。图8为增加采样数据密度后预测5 min内的结果。结合图8与表2各模型的预测精度对比,使用PSR-LSTM模型进行预测的曲线更接近于真实曲线。

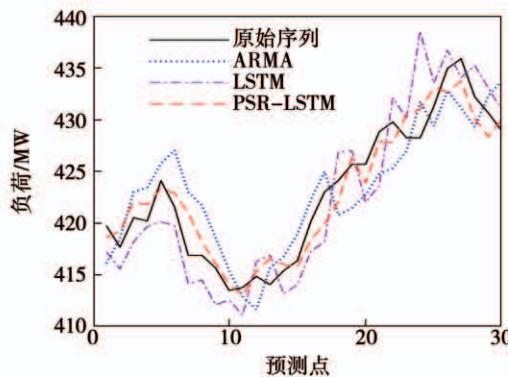


图8 5 min 预测对比

Fig. 8 Comparison of 5 min prediction

模型在12 h内预测的 $e_{MAPE}$ 最高为4.89%,最低为0.024%, $e_{RMSE}$ 最高为6.39,最低为3.34。在5 min内 $e_{MAPE}$ 最高为0.98%,最低为0.10%, $r_{RMSE}$ 最高为4.09,最低为0.44。预测取得了较好的效果,在不同预测范围内的结果均优于ARMA模型与LSTM模型,通过对比证明该模型具有更高的预测精度。

表2 预测精度对比

Tab. 2 Prediction accuracy comparison

预测范围	模型名称	$e_{MAPE}/\%$			$e_{RMSE}$		
		平均	最大值	最小值	平均	最大值	最小值
12 h	ARMA	3.854	11.485	0.242	16.203	18.174	10
12 h	LSTM	3.339	9.094	0.112	13.662	14.769	7.806
12 h	PSR-LSTM	1.382	4.893	0.024	6.382	6.388	3.344
5 min	ARMA	0.8011	1.4665	0.2085	4.2743	6.1139	0.8708
5 min	LSTM	0.6527	2.4013	0.1252	3.2539	10.2839	0.5362
5 min	PSR-LSTM	0.3921	0.9808	0.1049	1.8285	4.0889	0.4359

总体来说,LSTM模型与ARMA算法均有一定的局限性。PSR-LSTM模型的预测精度更高,能够更准确地预测出未来负荷的变化,且模型建立步骤简单清晰,总体计算量较小,适用于短期机组负荷的

预测。

## 5 结 论

利用Lyapunov指数证明了机组负荷的混沌性,选用C-C法进行相空间重构,基于PSR提出并建立了660 MW机组LSTM负荷预测模型,给出模型建立步骤与预测流程,模型的建立步骤清晰,总体计算量较小,适用于短期机组负荷的预测。

(1) 通过PSR提取一维信息重构为多维特征时序,能够增加特征维度使序列包含信息最大化;LSTM网络对复杂的非线性关系拟合效果较好,且适量增加LSTM网络隐含层数能够增加模型深度,提高整体预测效果。

(2) PSR-LSTM模型兼具PSR的特征信息,多维扩展与LSTM的时序表达特性,与传统预测方法相比具有更高短期预测精度。

通过PSR-LSTM对火电机组负荷的预测,能够提前告知电网实现优化调度,并使电厂安排日、周调度计划,组合优化机组,协调水电、火电及水库调度等更合理,有效提高电厂运行效率。

由于机组负荷是复杂的非线性系统,影响因素众多,还有很多地方值得深入探讨,后续研究工作将针对不同影响因素对机组负荷的预测以及模型中各参数的调整等方面做进一步的研究,提高机组负荷预测实时性等。

## 参 考 文 献:

- [1] 张素香,赵丙镇,王风雨,等.海量数据下的电力负荷短期预测[J].中国电机工程学报,2015,35(1): 37–42.  
ZHANG Su-xiang,ZHAO Bing-zhen,WANG Feng-yu,et al.Short-term power load forecasting based on big data[J].Proceedings of the CSEE,2015,35(1): 37–42.
- [2] 孙海蓉,谢碧霞,田瑶,等.基于数据的SecRPSO-SVM短期电力负荷预测[J].系统仿真学报,2017,29(8): 1829–1836.  
SUN Hai-rong,XIE Bi-xia, TIAN Yao, et al. Forecasting of short-term power load of SecRPSO-SVM based on data-driven[J]. Journal of System Simulation,2017,29(8): 1829–1836.
- [3] KYRIAKOS K, MATTHEW P. Aswarm intelligence framework for reconstructing gene networks [J]. IEEE ACM Transactions on Computational Biology and Bioinformatics (TCBB), 2012,9 (2): 358 – 371.

- [4] 杨越文,侯慧娟,杨 祎,等.基于贝叶斯模型的输电线路运行参数关联规则挖掘及预测方法[J].电网技术,2017,41(11):3648 – 3653.  
YANG Yue-wen, HOU Hui-juan, YANG Yi, et al. Association rule mining and prediction method for transmission line operation parameters based on Bayesian model [J]. Power System Technology, 2017, 41(11): 3648 – 3653.
- [5] 董 雷,周文萍,张 沛,等.基于动态贝叶斯网络的光伏发电短期概率预测[J].中国电机工程学报,2013,33(S1):38 – 45.  
DONG Lei, ZHOU Wen-ping, ZHANG Pei, et al. Short-term photovoltaic output forecast based on dynamic Bayesian network theory [J]. Proceedings of the CSEE, 2013, 33(S1): 38 – 45.
- [6] 王 虹.基于小波的电力系统短期负荷预测[D].北京:华北电力大学,2016.  
WANG Hong. Short-term load forecasting based on wavelet [D]. Beijing: North China Electric Power University, 2016.
- [7] 丁 伟,任少君,司风琪,等.一种基于 HMF 的火电机组短期负荷预测方法[J].热能动力工程,2020,35(1):191 – 197.  
DING Wei, REN Shao-jun, SI Feng-qi, et al. A short-term load forecasting method for thermal power units based on HMF [J]. Journal of Engineering for Thermal Energy and Power, 2020, 35 (1) : 191 – 197.
- [8] 马良玉,成 蕾.考虑回热循环的超超临界机组负荷预测神经网络模型[J].热力发电,2016,45(4): 19 – 27,34.  
MA Liang-yu, CHEN Lei. Load prediction model for ultra-supercritical turbine power unit considering regenerative cycle characteristics [J]. Thermal Power Generation, 2016, 45(4): 19 – 27, 34.
- [9] 刘卫亮,马良玉,林永君.基于炉膛火焰图像的燃煤机组负荷预测[J].动力工程学报,2011,31(8): 619 – 623.  
LIU Wei-liang, MA Liang-yu, LIN Yong-jun. Load forecasting of a coal-fired power generating unit based on furnace flame images [J]. Journal of Chinese Society of Power Engineering, 2011, 31 (8) : 619 – 623.
- [10] 张然然,刘鑫屏.火电机组超短期负荷预测[J].热力发电,2018,47(7):52 – 57.  
ZHANG Ran-ran, LIU Xin-ping. Ultra-short-term load forecasting for thermal power units [J]. Thermal Power Generation, 2018, 47 (7) : 52 – 57.
- [11] 魏 鹰,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.  
WEI Ao, MAO Da-jun, HAN Wan-li, et al. Short-term load forecasting based on EMD and long short-term memory neural networks [J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(4) : 203 – 209.
- [12] 李冬辉,尹海燕,郑博文.基于 MFOA-GRNN 模型的年电力负荷预测[J].电网技术,2018,42(2):585 – 590.  
LI Dong-hui, YIN Hai-yan, ZHENG Bo-wen. An annual load forecasting model based on generalized regression neural network with multi-swarm fruit fly optimization algorithm [J]. Power System Technology, 2018, 42(2) : 585 – 590.
- [13] TAKENS F. Detecting strange attractors in turbulence [J]. Lecture notes in Math (S0075 – 8434), 1981, 898: 361 – 381.
- [14] KIM H S, EYKHOLT R, SALAS J D. Nonlinear dynamics, delay times and embedding windows [J]. Physica D (S0167 – 2789), 1999, 127: 48 – 60.
- [15] JAN A, ANTON K, NIKOLAY E, et al. Quantifying Chaos by Various Computational Methods. Part 1: Simple Systems [J]. Entropy, 2018, 20(3) : 175.
- [16] 龚祝平.混沌时间序列的平均时间周期计算方法[J].系统工程,2010,28(12):111 – 113.  
GONG Zhu-ping. The calculating method of the average period of chaotic time series [J]. System Engineering, 2010 , 28 ( 12 ) : 111 – 113.
- [17] 戴伯望.基于相空间重构的 CC-HMM 窑内喂煤量趋势预测[D].湖南:湖南大学,2017.  
DAI Bo-wang. A phase-space-reconstruction-based CC-HMM on kiln coal feeding trend prediction [D]. Hunan: Hunan University, 2017.
- [18] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8) : 1735 – 1780.
- [19] GRAVES A, MOHAMED A, HINTTON G. Speech recognition with deep recurrent neural network [C]. IEEE International Conference on Acoustics, Speech and Signal Processing, May 26 – 31 , 2013, Vancouver, Canada.

(刘 颖 编辑)