

DOI:10.12158/j.2096-3203.2020.01.025

## 基于PSR和DBN的超短期母线净负荷预测

石天<sup>1</sup>, 梅飞<sup>2</sup>, 陆继翔<sup>3</sup>, 陆进军<sup>3</sup>, 郑建勇<sup>1</sup>, 张宸宇<sup>4</sup>

(1. 东南大学电气工程学院, 江苏 南京 210096; 2. 河海大学能源与电气学院, 江苏 南京 210098; 3. 南瑞集团有限公司智能电网保护和运行控制国家重点实验室, 江苏 南京 211106; 4. 国网江苏省电力有限公司电力科学研究院, 江苏 南京 211103)

**摘要:**随着电网优化调度的精细化、智能化和计及电力系统安全性与经济性的电网高级应用的广泛采用及分布式能源的大量接入, 母线负荷预测的精度要求不断提高而负荷的不确定性和非线性特征进一步增强。针对上述问题, 文中提出一种基于相空间重构(PSR)和深度信念网络(DBN)的超短期母线负荷预测模型, 首先采用C-C法对净负荷时间序列进行PSR, 然后利用DBN对重构后的数据进行拟合并得出负荷的预测值。文中利用某市变电站实测负荷数据检验了该超短期母线负荷预测模型的有效性, 证明该模型在分布式电源渗透率较高且母线负荷波动较大的情况下仍然有较高的预测精度。

**关键词:**负荷预测; 母线净负荷预测; 深度信念网络; 相空间重构; 深度学习

**中图分类号:** TM910.6

**文献标志码:** A

**文章编号:** 2096-3203(2020)01-0178-06

### 0 引言

电力系统负荷预测可分为长期预测、中期预测、短期预测和超短期预测<sup>[1]</sup>。对传统短期和超短期负荷预测国内外学者已经有了系统的研究。预测方法主要可以分为两类<sup>[2]</sup>: 一类为统计学预测模型, 如采用线性外推<sup>[3]</sup>、曲线外推<sup>[4]</sup>、差分整合移动平均自回归模型(autoregressive integrated moving average model, ARIMA)<sup>[5-6]</sup>和广义自回归条件异方差模型(generalized autoregressive conditional heteroskedasticity, GARCH)<sup>[7]</sup>等; 另一类为智能预测模型, 如灰色关联度<sup>[8]</sup>、支持向量回归(support vector regression, SVR)<sup>[9]</sup>、人工神经网络(artificial neural network, ANN)<sup>[10-11]</sup>和长短期记忆网络(long short-term memory, LSTM)<sup>[12]</sup>。这些方法一般针对系统进行预测, 针对母线负荷的预测研究相对较少。

由于母线负荷的基数较小, 负荷不确定性明显, 通过负荷配比分配系统预测值的方法不能取得令人满意的效果。对此, 文献[13]采用ARIMA对历史母线数据进行拟合并采用SVR修正残差。文献[14]提出了基于聚类和ANN的母线负荷预测模型, 且取得了较好效果。

随着新能源的大量接入, 为了电力系统的实时安全分析和经济调度的可靠运行, 需要更加细致的超短期预测。文献[15]通过K均值算法对光伏发电数据聚类, 在聚类得到的各类数据上分别训练

SVR, 较于传统SVR模型明显提升了精度。文献[16]建立了改进Kohonen天气聚类模型, 将聚类历史数据与预测日气象数据作为回归神经网络的输入, 有效提高了光伏发电功率的预测精度。但上述模型集中在分布式能源发电的预测, 且天气、电价等因素对超短期预测的影响通常较小, 套用此类预测模型会增大算法复杂程度且较难显著提高模型的预测精度。

针对分布式电源大量接入引起的净负荷不确定性增强和母线负荷预测精度的要求提高, 文中提出一种基于相空间重构(phase space reconstruction, PSR)和深度信念网络(deep belief network, DBN)的超短期母线负荷预测模型: 首先对母线负荷历史数据进行PSR, 将历史数据投影到相空间中的动点轨迹, 再利用DBN拟合动点轨迹, 并给出轨迹的预测, 最终得到负荷的预测值。为了检验提出的基于PSR和DBN超短期母线负荷预测模型的有效性, 文中应用某市变电站实测负荷数据, 验证模型在实际情况下的预测有效性和预测效果。

### 1 PSR

PSR是由Takens提出的一种用于分析时间序列的方法。其基本思想是把时间序列看作是由一个确定的非线性动力系统产生的分量, 通过该分量的变化规律可以重构出动力系统的等价高维相空间。其中, 重构的关键是确定最优的嵌入维数 $m_{opt}$ 和延时 $t_{opt}$ 。

文中采用C-C方法<sup>[17]</sup>同时求取最优嵌入维数

收稿日期: 2019-07-07; 修回日期: 2019-08-21

基金项目: 国家重点研发计划资助项目(2018YFB0905000)

$m_{\text{opt}}$  和延时  $t_{\text{opt}}$ , 设有一组时间序列为  $x = \{x_1, x_2, \dots, x_N\}$ , 嵌入维数为  $m$ , 延时为  $t$ , 则时间序列  $x$  经过 PSR 后的集合可表示为:

$$\begin{bmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \\ \vdots \\ \mathbf{X}_M \end{bmatrix} = \begin{bmatrix} x_1 & x_{1+t} & \cdots & x_{1+(m-1)t} \\ x_2 & x_{2+t} & \cdots & x_{2+(m-1)t} \\ \vdots & \vdots & & \vdots \\ x_M & x_{M+t} & \cdots & x_N \end{bmatrix} \quad (1)$$

式中:  $M = N - (m - 1)t$ 。

在式(1)的基础上, 定义关联积分。

$$C(m, N, r_k, t) = \frac{2}{M(M-1)} \times \sum_{1 \leq i < j \leq M} \theta(r_k - \|\mathbf{X}_i - \mathbf{X}_j\|) \quad (2)$$

其中:

$$\theta(x) = \begin{cases} 0 & x < 0 \\ 1 & x \geq 0 \end{cases} \quad (3)$$

根据 BDS (Brock-Dechert-Scheinkman) 统计结论<sup>[18-19]</sup>, 当  $N > 3000$  时可得  $m$  和  $r_k$  的取值范围,  $m \in \{2, 3, 4, 5\}$ ,  $r_k = k \times 0.5\sigma$ , 其中  $\sigma$  为时间序列的标准差,  $k \in \{1, 2, 3, 4\}$ 。

定义检验统计量  $S$  和  $\Delta S$  并采用分块平均策略, 表达式为:

$$\begin{cases} S(m, N, r_k, t) = \\ \frac{1}{t} \sum_{i=1}^M C_i \left( m, \frac{N}{t}, r_k, t \right) - C_i^m \left( m, \frac{N}{t}, r_k, t \right) \\ \Delta S(m, N, t) = \\ \max[S(m, N, r_k, t)] - \min[S(m, N, r_k, t)] \end{cases} \quad (4)$$

计算  $S$  和  $\Delta S$  的平均值  $\bar{S}$  和  $\overline{\Delta S}$ :

$$\begin{cases} \bar{S}(t) = \frac{1}{4 \times 4} \sum_{m=2}^5 \sum_{k=1}^4 S(m, N, r_k, t) \\ \overline{\Delta S}(t) = \frac{1}{4} \sum_{m=2}^5 \Delta S(m, N, t) \end{cases} \quad (5)$$

对于不同的延时  $t$ ,  $\bar{S}(t)$  和  $\overline{\Delta S}(t)$  可以求出对应的值。其中,  $\bar{S}(t)$  的第一个零点或  $\overline{\Delta S}(t)$  的第一个极小值点的  $t$  值四舍五入取整即为最优延时  $t_{\text{opt}}$ 。定义检验统计量:

$$S_{\text{cor}}(t) = \overline{\Delta S}(t) + |\bar{S}(t)| \quad (6)$$

$S_{\text{cor}}(t)$  的全局最小点即为最优的嵌入窗  $t_{\omega}$ , 由于:

$$t_{\omega} = (m_{\text{opt}} - 1)t_{\text{opt}} \quad (7)$$

所以可以由式(5)确定的最优的延时  $t_{\text{opt}}$  和式(6)确定的最优的嵌入窗  $t_{\omega}$  代入式(7)并四舍五入取整求得最优的嵌入维数  $m_{\text{opt}}$ 。

## 2 DBN

DBN 是 Geoffrey Hinton<sup>[20]</sup> 提出的深度学习模型。DBN 由多个受限玻尔兹曼机 (restricted boltzmann machine, RBM) 堆叠而成。相较于神经网络, DBN 由于采用了预训练技术结合反向传播 (back propagation, BP) 算法求解网络参数, 因此不容易陷入局部最优解, 有更高的收敛精度, 并且当模型层数和层中神经元素数较大时也有较快的收敛速度, 更加适合多维非线性时间序列的拟合问题。

### 2.1 RBM

RBM 由一个可见层  $V$  和一个隐层  $H$  构成, 如图 1 所示, 可见层由  $n$  个神经元组成, 隐层由  $m$  个神经元组成, 层与层之间的神经元通过权重  $\omega$  相连。




图 1 RBM 结构

Fig.1 RBM structure diagram

RBM 的网络参数由可见层偏置  $b$ 、权重矩阵  $\omega$  和隐层偏置  $c$  构成, 训练通常采用对比散度 (contrastive divergence, CD) 算法来近似逼近似然函数的梯度<sup>[21]</sup>, RBM 训练的具体步骤如下。

步骤 1: 将训练集中的样本输入作为可见层神经元状态量  $v_1$  通过网络结构求出隐层神经元状态量  $h_1$  的激活概率并据此随机采样得到  $h_1$  的取值;

步骤 2: 将步骤 1 中求得的  $h_1$  通过网络结构求出  $v_2$  的激活概率, 并据此随机采样得到重构后的  $v_2$ ;

步骤 3: 将步骤 2 中求得的  $v_2$  通过网络结构求出  $h_2$  的激活概率  $P(h_2 = 1 | v_2)$ ;

步骤 4: 更新网络参数, 网络参数的迭代式如下。

$$\begin{cases} \omega^{(k+1)} = \omega^{(k)} + \varepsilon (h_1 v_1^T - P(h_2 = 1 | v_2) v_2^T) \\ b^{(k+1)} = b^{(k)} + \varepsilon (v_1 - v_2) \\ c^{(k+1)} = c^{(k)} + \varepsilon (h_1 - P(h_2 = 1 | v_2)) \end{cases} \quad (8)$$

式中:  $\varepsilon$  为学习率, 文中取为 0.8;  $k$  为迭代次数。

### 2.2 基于 BP 算法的 DBN

DBN 由多个 RBM 堆叠而成, 其中前一个 RBM 的隐层作为下一个 RBM 的可见层, 预训练时逐层采用 CD 算法确定网络参数, 此过程属于无监督学习, 之后将预训练得到的网络参数赋值给神经网络作为网络参数的训练初值, 并利用训练集中的样本标签结合 BP 算法对网络参数进行微调, 此过程属于监督学习, DBN 的结构如图 2 所示。




图2 DBN 结构

Fig.2 Structure diagram of DBN

### 3 基于 PSR-DBN 的超短期母线净负荷预测模型

传统的负荷波动主要是由用户的用电波动引起的。虽然用户的用电存在不确定性,但总体上有一定规律,且波动范围不大。对于超短期预测而言,采用线性外推,时间序列预测等方法通常可以达到较高精度。随着分布式能源如光伏电站的大量接入,净负荷的表达式可写为:

$$p_t = p'_t + p''_t \quad (9)$$

式中:  $p_t$  为实际的净负荷;  $p'_t$  为用户的用电负荷;  $p''_t$  为光伏等新能源电站的发电量的相反数。由于新能源电站的发电量和用电负荷一样具有不确定性,与传统发出功率可知的电源不同,因此光伏发电量可以看作是负荷。于是负荷的不确定性增大,且波动范围扩大。如还采用传统的预测方式将产生较大误差,无法准确预测负荷。

鉴于分布式能源接入后负荷为非线性时间序列且存在较大波动,直接预测有较大困难,而采用复杂短期预测的模型又可能不满足实时性要求。文中先采用 PSR 将负荷时间序列投影到高维相空间中的一个随时间变化且短期具有规律性的动点的轨迹,再利用 DBN 的非线性拟合能力和较快的收敛速度,对相空间中的点的轨迹进行拟合并预测之后的轨迹,从而实现计及分布式能源的负荷超短期预测。

#### 3.1 PSR-DBN 预测模型的流程

对于一系列母线负荷历史数据时间序列  $p = \{p_1, p_2, \dots, p_N\}$ , PSR-DBN 预测模型的预测流程如下。

步骤 1: 对负荷时间序列进行极差归一化便于

训练 DBN, 并保存数据的最大、最小值用于之后对负荷的预测值进行反归一化, 恢复实际值。

步骤 2: 采用 C-C 方法处理负荷时间序列求出时间序列的最优的嵌入维数  $m$  和最优延时  $t$ 。

步骤 3: 根据步骤 2 中求出的嵌入维数  $m$  和延时  $t$  对负荷时间序列进行重构, 重构后的负荷时间序列相空间矩阵为:

$$\begin{bmatrix} p_1 \\ p_2 \\ \vdots \\ p_M \end{bmatrix} = \begin{bmatrix} p_1 & p_{1+t} & \cdots & p_{1+(m-1)t} \\ p_2 & p_{2+t} & \cdots & p_{2+(m-1)t} \\ \vdots & \vdots & \cdots & \vdots \\ p_M & p_{M+t} & \cdots & p_N \end{bmatrix} \quad (10)$$

步骤 4: 构建 DBN, 采用步骤 3 中重构的负荷时间序列相空间矩阵作为训练集对 DBN 进行训练, 最后利用训练完成的 DBN 预测未来时刻的负荷值。

步骤 5: 利用步骤 1 中保存的最大、最小值对步骤 4 中 DBN 返回的负荷预测值进行反归一化处理, 得到实际的负荷预测值。

上述步骤对应的流程如图 3 所示。

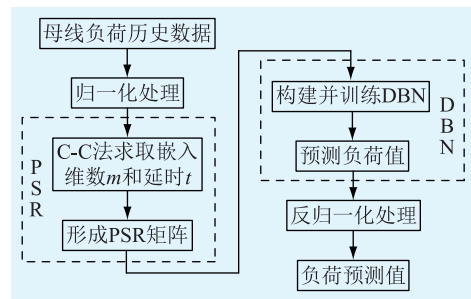


图3 PSR-DBN 预测模型流程

Fig.3 Flow chart of PSR-DBN forecasting model

#### 3.2 预测模型的网络结构

对于预测模型网络的输入层, 由于原始负荷数据经过 PSR 后输入 DBN, 所以网络的输入层神经元个数可直接设置为嵌入维数  $m$  个, 即每次输入式 (10) 中的一行元素; 对于网络的输出层, 当网络输入为式 (10) 中的一行元素时, 相当于输入了相空间中动点在某一时刻的位置向量, 此时需要输出下一时刻动点位置向量的预测值。

实际上, 若模型的输入是式 (10) PSR 矩阵中的  $p_i (1 \leq i \leq M)$ , 则下一时刻的位置向量  $p_{i+1}$  中只有  $p_{i+1+(m-1)t}$  是未知的, 因此输出层只需输出  $i+1+(m-1)t$  时刻负荷的预测值  $\hat{p}_{i+1+(m-1)t}$ 。若  $i+1$  大于  $M$ , 则需对式 (10) 的 PSR 矩阵向下增广, 增加  $p_{i+1}$  作为新的一行, 再将  $p_{i+1}$  作为模型的输入, 求取  $p_{i+2+(m-1)t}$  的预测值; 之后再对矩阵增广并求取  $p_{i+3+(m-1)t}$  的预测值, 依此类推直到预测结束。增广矩阵中  $p_{i+1}$  的表达式为:

$$p_{i+1} = [p_{i+1} \quad p_{i+1+t} \quad \cdots \quad p_{i+1+(m-1)t}] \quad (11)$$

式中： $p_{i+1+(m-1)t}$  的取值由预测范围决定，若为单步预测则  $p_{i+1+(m-1)t}$  取  $i+1+(m-1)t$  时刻测得负荷的真实值，若为多步预测且预测步数为  $k$ ，则取  $p_{i+1+(m-1)t} = \hat{p}_{i+1+(m-1)t}$ ，直至预测到第  $k$  步再利用测得对应时刻的负荷真实值替换增广矩阵中所有的预测值。由此文中 PSR-DBN 模型的网络结构如图 4 所示。




图4 网络结构

Fig.4 Network structure

## 4 算例分析

### 4.1 母线负荷数据

为验证建立模型的有效性，文中采用某市 220 kV 变电站母线 2017 年 5 月 1 日至 18 日的负荷数据，母线下级接有分布式光伏电站且安装容量约为 50 MW，负荷数据的采样时间间隔为 5 min。在此期间变电站无检修或故障停运情况，且历史数据可靠性高，利用  $3\sigma$  准则检测未出现异常数据。

文中选取 1—14 日的数据作为训练集进行 PSR-DBN 预测模型建模，选取 15—18 日的数据作为预测检验样本，并在 Matlab R2018a 的环境下对文中模型进行验证。

### 4.2 预测评价标准

为了更加直观、精确地评价模型预测效果的好坏和预测的精度，文中采用平均绝对百分误差 (mean absolute percentage error, MAPE) 和均方根误差 (root mean square error, RMSE) 作为评价指标，其中：

$$e_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{p_i - \hat{p}_i}{p_i} \right| \times 100\% \quad (12)$$



$$e_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - \hat{p}_i)^2} \quad (13)$$

式中： $n$  为预测样本的个数； $p_i$  为  $i$  时刻净负荷的实际值； $\hat{p}_i$  为  $i$  时刻净负荷的预测值。

$e_{\text{MAPE}}$  和  $e_{\text{RMSE}}$  的值越小代表模型的预测精度越高，但这 2 个指标是相对值，需要在相同的数据下进行比较才有意义。

### 4.3 PSR 重构结果

基于 PSR 理论分析，文中采用 C-C 法对 1—14 日的母线负荷数据进行 PSR，对应的统计量  $\overline{\Delta S}(t)$  和  $S_{\text{cor}}(t)$  的曲线如图 5 所示，可以看出  $\overline{\Delta S}(t)$  的第一个极小值点为  $t = 18$ ，而  $S_{\text{cor}}(t)$  没有明显的最小值点无法得出最优的嵌入窗  $t_{\omega}$ 。但由 BDS 统计结论，当  $N > 3000$  时， $m \in \{2, 3, 4, 5\}$ ，因此  $m$  最大值只能取 5，又根据式 (7) 可得最终的最优嵌入维数  $m_{\text{opt}} = 5$ ，最优延时  $t_{\text{opt}} = 18$ 。

(a)  $\overline{\Delta S}(t)$  曲线(b)  $S_{\text{cor}}(t)$  曲线图5  $\overline{\Delta S}(t)$  和  $S_{\text{cor}}(t)$  的曲线Fig.5 Curves of  $\overline{\Delta S}(t)$  and  $S_{\text{cor}}(t)$ 

### 4.4 预测结果

为了验证文中方法的预测效果，分别采用 ARIMA 模型和 DBN 模型利用 1—14 日历史数据进行训练，然后对 15—18 日的负荷进行预测，预测范围为 1 h，并计算对应模型的  $e_{\text{MAPE}}$  和  $e_{\text{RMSE}}$  值。其中 ARIMA 模型采用单位根检验法判断序列平稳性确定差分阶数  $d$ ，采用赤池信息准则 (Akaike information criterion, AIC) 优化确定其中的自回归 (auto regressive, AR) 模型阶数  $p$  和滑动平均 (moving average, MA) 模型阶数  $q$ 。优化后 ARIMA 的差分阶数  $d=2$ ， $p=22$ ， $q=19$ ，15—18 日不同模型对应的负荷预测值和实测负荷值的曲线如图 6 所示。

根据图 6 中实测值曲线可以看出，由于光伏电站的有功输出有较大波动，母线负荷曲线由一般的马鞍型产生了严重的畸变，呈现出不规则的波动，若此时还利用短期负荷预测则会产生较大误差，且浪费大量已知信息。图 6 中，ARIMA 模型的预测曲线明显偏离了实测值，在实测值剧烈波动时其曲线的变化趋势明显滞后于实测曲线；而 DBN 模型虽然大致趋势和实测值相同，但具体时刻的数值和实测值却有较大差距且预测效果不够稳定，在 15—16 日母线负荷波动较大时明显偏离实测曲线，而在 17—




图6 15—18日提前1h的负荷预测曲线

Fig.6 Load forecasting curve one hour ahead of 15—18 days

18日却有较好的预测效果。为了更加直观地看出各模型的预测效果好坏,文中计算了各模型的  $e_{MAPE}$  和  $e_{RMSE}$ ,如表1所示。

表1 各模型预测的效果

Table 1 Prediction effect of each model

算法	$e_{MAPE}/\%$	$e_{RMSE}$
PSR-DBN	0.989 2	3.231 6
DBN	1.132 2	3.468 4
ARIMA	1.592 9	4.865 7

由表1可知,文中 PSR-DBN 模型在全部3种模型中有最小的  $e_{MAPE}$  和  $e_{RMSE}$ ;可以看出传统时间序列方法例如 ARIMA 模型,在母线净负荷出现较大波动且不确定性增大时预测效果较差,相较于 DBN 和 PSR-DBN 等智能预测模型有较大差距,因此在分布式电站大量接入时,采用智能预测模型能有效提高母线负荷预测精度;加入 PSR 环节重构原始数据后的 PSR-DBN 模型预测结果的  $e_{MAPE}$  和  $e_{RMSE}$  较 DBN 模型也有明显提高,由于 PSR 的加入使原先在一维时间序列中无法获取的规律在高维相空间中得以显现,因此使 DBN 的预测效果进一步提高。综上所述,文中方法在分布式能源渗透率较高且净负荷有较大波动的母线超短期预测中有较高的预测精度和较理想的预测效果。

## 5 结语

文中针对母线负荷预测中,负荷的时间序列特性和分布式能源大量接入带来的波动性问题,提出了基于 PSR 和 DBN 的超短期母线净负荷预测模型。PSR-DBN 模型首先利用 PSR 将时间序列投影成相空间中的动点,再利用 DBN 网络出色的非线性拟合能力对轨迹进行拟合,从而实现负荷预测。

利用实际母线负荷数据验证得到:文中 PSR-DBN 预测模型在分布式电源渗透率较高且母线净负荷波动较大的情况下依旧能保持相对较高的预

测精度。且文中模型的预测精度相较于传统时间序列中的 ARIMA 模型有较大提高,加入 PSR 环节后预测精度相较于一般的神经网络模型(例如 DBN)进一步提高。因此,在分布式电源大量接入导致的母线净负荷非线性和不确定性增强的情况下,文中 PSR-DBN 模型能显著改善母线超短期净负荷预测精度。

本文得到智能电网保护和运行控制国家重点实验室项目(20195021212)资助,谨此致谢!

## 参考文献:

- [1] 康重庆,夏清,张伯明. 电力系统负荷预测研究综述与发展方向的探讨[J]. 电力系统自动化,2004(17):1-11.  
KANG Chongqing, XIA Qing, ZHANG Boming. Review of power system load forecasting and its development[J]. Automation of Electric Power Systems, 2004(17):1-11.
- [2] HONG T, FAN S. Probabilistic electric load forecasting: A tutorial review[J]. International Journal of Forecasting, 2016, 32(3):914-938.
- [3] 徐进东,丁晓群,邓勇. 基于相似日的线性外推短期负荷预测[J]. 继电器,2005(7):37-39,65.  
XU Jindong, DING Xiaoqun, DENG Yong. Short-term load forecast using linear extrapolation based on similar historical day data[J]. Relay, 2005(7):37-39,65.
- [4] 丁恰,卢建刚,钱玉妹,等. 一种实用的超短期负荷预测曲线外推方法[J]. 电力系统自动化,2004(16):83-85.  
DING Qia, LU Jiangan, QIAN Yumei, et al. A practical method for ultra-short term load forecasting[J]. Automation of Electric Power Systems, 2004(16):83-85.
- [5] FARD A K, AKBARI-ZADEH M R. A hybrid method based on wavelet, ANN and ARIMA model for short-term load forecasting[J]. Journal of Experimental & Theoretical Artificial Intelligence, 2014, 26(2):167-182.
- [6] 郭建鹏,余颖铃,温步瀛. 基于 EEMD-ARIMA 模型的地区月负荷量预测[J]. 电力工程技术,2018,37(6):28-32,74.  
GUO Jianpeng, SHE Yingling, WEN Buying. Regional monthly load forecast based on EEMD-ARIMA model[J]. Electric Power Engineering Technology, 2018, 37(6):28-32,74.
- [7] 陈昊. 基于非高斯分布 GARCH 模型的负荷预测[J]. 电力自动化设备,2008(7):65-68.  
CHEN Hao. Load forecast based on GARCH model with non-Gaussian distribution[J]. Electric Power Automation Equipment, 2008(7):65-68.
- [8] 陈轶玮,高强,王林梅,等. 基于信息再修正的负荷协调预测方法研究[J]. 电力工程技术,2019,38(2):93-98.  
CHEN Yiwei, GAO Qiang, WANG Linmei, et al. Load coordination forecasting method based on information re-modification[J]. Electric Power Engineering Technology, 2019, 38(2):93-98.
- [9] JIANG H, ZHANG Y, MULJADI E, et al. A short-term and high-resolution distribution system load forecasting approach using

- support vector regression with hybrid parameters optimization [J]. IEEE Transactions on Smart Grid, 2016; 1-1.
- [10] BENTOP M R, POMBO J A N, CALADO M R A, et al. Optimization of neural network with wavelet transform and improved data selection using bat algorithm for short-term load forecasting[J]. Neurocomputing, 2019, 358; 53-71.
- [11] PAN Y, MEI F, MIAO H, et al. An approach for hvcb mechanical fault diagnosis based on a deep belief network and a transfer learning strategy[J]. Journal of Electrical Engineering and Technology, 2019, 14(1): 407-419.
- [12] YU Ruiguo, GAO Jie, YU Mei, et al. LSTM-EFG for wind power forecasting based on sequential correlation features [J]. Future Generation Computer Systems, 2019, 93; 33-42.
- [13] 金山红, 朱想, 赫卫国, 等. 基于相空间重构 ARIMA 和 SVR 的母线净负荷预测 [J]. 电力需求侧管理, 2018, 20(2): 20-24.
- JIN Shanong, ZHU Xiang, HE Weiguo, et al. Forecasting of bus-bar net load based on PSR-ARIMA and SVR [J]. Power Demand Side Management, 2018, 20(2): 20-24.
- [14] PANAPALIDIS, IOANNIS P. Clustering based day-ahead and hour-ahead bus load forecasting models [J]. International Journal of Electrical Power & Energy Systems, 2016, 80; 171-178.
- [15] 张雨金, 杨凌帆, 葛双治, 等. 基于 Kmeans-SVM 的短期光伏发电功率预测 [J]. 电力系统保护与控制, 2018, 46(21): 118-124.
- ZHANG Yujin, YANG Lingfan, GE Shuangye, et al. Short-term photovoltaic power forecasting based on Kmeans algorithm and support vector machine [J]. Power System Protection and Control, 2018, 46(21): 118-124.
- [16] 李燕青, 杜莹莹. 基于双维度顺序填补框架与改进 Kohonen 天气聚类的光伏发电短期预测 [J]. 电力自动化设备, 2019, 39(1): 60-65.
- LI Yangqing, DU Yingying. Short-term photovoltaic power forecasting based on double-dimensional sequential imputation framework and improved Kohonen clustering [J]. Electric Power Automation Equipment, 2019, 39(1): 60-65.
- [17] KIM H S, EYKHOLT R, SAIAS J, et al. nonlinear dynamics, delay times, and embedding windows [J]. Physica D: nonlinear Phenomena, 1999, 127(1): 48-60.
- [18] 郑永康. 相空间重构与支持向量机结合的短期负荷预测研究 [D]. 成都: 西南交通大学, 2008.
- ZHENG Yongkang. Short-term load forecasting based on phase space reconstruction and support vector machine [D]. Chengdu: Southwest Jiaotong University, 2008.
- [19] BROCK W A, HSIEH D A, LE B B. Nonlinear dynamics, chaos, and instability: statistical theory and economic evidence. Cambridge: MIT Press, 1991.
- [20] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18(7): 1527-1554.
- [21] BENGIO Y. Learning deep architectures for AI [J]. Foundations and Trends © in Machine Learning, 2009, 2(1): 1-127.

作者简介:



石天

石天(1996),男,硕士在读,研究方向为电力系统负荷预测(E-mail: stx@seu.edu.cn);  
梅飞(1982),男,博士,讲师,研究方向为新能源发电技术;  
陆继翔(1973),男,博士,高级工程师,从事人工智能与电网调度工作。

## Ultra-short-term bus net load forecasting based on phase space reconstruction and deep belief network

SHI Tian<sup>1</sup>, MEI Fei<sup>2</sup>, LU Jixiang<sup>3</sup>, LU Jinjun<sup>3</sup>, ZHENG Jianyong<sup>1</sup>, ZHANG Chenyu<sup>4</sup>

(1. School of Electrical Engineering, Southeast University, Nanjing 210096, China;

2. College of Energy and Electrical Engineering, Hohai University, Nanjing 210098, China;

3. State Key Laboratory of Smart Grid Protection and Operation Control, NARI Group Co., Ltd.,

Nanjing 211106, China; 4. State Grid Jiangsu Electric Power Co., Ltd. Research Institute, Nanjing 211103, China)

**Abstract:** With the refinement and intelligentization of power grid optimization and the extensive adoption of advanced applications of power grid security and economy, and the large-scale access of distributed energy, the accuracy requirements of bus load forecasting are constantly increasing while uncertainty and nonlinear of the load are further enhanced. Aiming at the above problems, an ultra-short-term bus net load forecasting model based on phase space reconstruction and deep belief network is proposed in this paper. firstly, the phase space reconstruction of the original time series is carried out by C-C method, and then the reconstructed data is fitted by the deep belief network to obtain the predicted value of the load. In this paper, the effectiveness of the proposed ultra-short-term bus load forecasting model is tested by using the measured load data of a substation in a city. It is proved that the proposed model still has high prediction accuracy under the condition of high distributed power penetration rate and large fluctuation of bus load.

**Keywords:** load forecasting; bus net load forecasting; deep belief network; phase space reconstruction; deep learning

(编辑 方晶)