

# 基于深度信念网络伪量测建模的配电网状态估计

孙国强<sup>1</sup>, 钱 婧<sup>1</sup>, 陈 亮<sup>2</sup>, 卫志农<sup>1</sup>, 臧海祥<sup>1</sup>, 王晗雯<sup>1</sup>, 黄 强<sup>2</sup>

(1. 河海大学 能源与电气学院, 江苏 南京 210098; 2. 国网江苏省电力公司电力科学研究院, 江苏 南京 211103)

**摘要:**针对配电网实时量测不足需要增加伪量测以提高量测冗余度的情况, 提出基于深度信念网络(DBN)伪量测建模的配电网状态估计方法。利用多种类型负荷的历史数据及对应温度、日期类型对DBN进行训练, 训练完成后输入测试数据得到精度较高的伪量测; 基于改进的等效电流量测变换法进行配电网状态估计, 以线性约束的形式处理虚拟量测。仿真结果验证了所提方法的有效性。

**关键词:**配电网; 状态估计; 深度信念网络; 伪量测; 虚拟量测

中图分类号: TM 761

文献标识码: A

DOI: 10.16081/j.issn.1006-6047.2018.12.014

## 0 引言

近年来, 分布式间歇性能源的接入给配电网运行与控制带来了极大挑战。为支撑配电网经济运行、故障定位及恢复、需求侧管理等一系列高级应用, 亟需研究状态估计技术实时感知配电网的运行状态<sup>[1-3]</sup>。

与输电网相比, 配电网量测配置难以保证可观性, 因此需要增加伪量测以提高配电网的量测冗余度, 保证状态估计的可解性。与实时量测相比, 伪量测误差较大, 导致状态估计结果精度下降, 因此有必要研究获得高精度伪量测的方法。文献[4]提出了2种伪量测建模方法: 基于相关性以及基于负荷概率密度函数伪量测建模。文献[5]基于典型负荷曲线以及智能电表采集的用户负荷数据, 利用线性规划法确定无监测的用户负荷曲线。文献[6-8]利用超短期负荷预测实时跟踪网络负荷的变化, 以获得负荷节点的伪量测功率, 一定程度增强了系统的可观性, 但该超短期负荷预测结果的精确度较低, 可能使状态估计结果偏离真实状态。文献[9-10]利用人工神经网络 ANN (Artificial Neural Network) 进行伪量测建模, 提高了配电网状态估计的计算精度, 虽然 ANN 可以模拟人的大脑结构进行非线性映射, 但当神经网络的层数增加时, 其预测性能降低。近年来, 深度学习理论作为研究热点<sup>[11]</sup>, 具有很强的学习能力, 擅长处理高维、非线性、大规模数据回归与分类问题, 因此其在基于负荷预测的伪量测建模领域具有潜在应用前景。深度信念网络 DBN (Deep Belief Network) 是应用于深度学习训练的非卷积模型之一, 通过逐层训练受限玻尔兹曼机 RBM (Restricted Boltzmann Machine) 获得网络参数。DBN 的

引入使得深度学习模型的优化得以简化, 推进了深度学习的大规模应用。

除了伪量测, 配电系统还有大量的虚拟量测, 即零注入节点的功率量测。虚拟量测值为 0, 不需要通过量测设备获取, 对于提高状态估计精度至关重要。传统处理虚拟量测的方法有大权重法<sup>[12-13]</sup>和拉格朗日乘法<sup>[14-15]</sup>。由于配电线路  $R/X$  比值较大, 大权重法的计算过程中信息矩阵病态的可能性大幅增加。拉格朗日乘法处理零注入约束能够严格保证零注入节点功率为 0, 但计算效率偏低。文献[16]将零注入约束转化为模型的线性约束, 使得状态估计求解过程更加简便。

针对配电网实时量测数据难以满足状态估计需求的问题, 本文首先提出基于 DBN 的伪量测建模方法, 将多种类型负荷数据输入 DBN 进行训练得到伪量测模型, 再利用高斯混合模型<sup>[17]</sup> GMM (Gaussian Mixture Model) 计算相应的权重。同时为避免虚拟量测与伪量测权重相差过大引起数值稳定性问题, 以线性约束的形式处理虚拟量测, 并采用改进等效电流量测变换法<sup>[18]</sup>进行线性状态估计。仿真结果表明, 本文方法通过基于 DBN 的伪量测建模有效提高了状态估计精度, 同时线性约束确保了零注入节点的功率严格为 0, 又能避免大权重法易导致的信息矩阵病态问题, 具有良好的实用价值。

## 1 配电系统状态估计基本原理

当系统网络结构、参数、量测数据给定时, 量测量和系统状态变量之间的非线性关系可表示为:

$$z = h(x) + v \quad (1)$$

其中,  $z$  为量测量向量;  $x$  为状态变量向量;  $v$  为量测误差向量;  $h(x)$  为描述量测量  $z$  和状态量  $x$  之间关系的非线性量测函数。

基本加权最小二乘法的目标准则为量测函数的计算值和所对应量测值之差的加权平方和最小, 其目标函数为:

收稿日期: 2018-03-27; 修回日期: 2018-09-14

基金项目: 国家自然科学基金资助项目(51277052); 国家电网公司科学技术项目(521001160038)

Project supported by the National Natural Science Foundation of China(51277052) and the Science and Technology Program of State Grid Corporation of China(521001160038)

$$\min J(\mathbf{x}) = [\mathbf{z} - \mathbf{h}(\mathbf{x})]^T \mathbf{W} [\mathbf{z} - \mathbf{h}(\mathbf{x})] \quad (2)$$

其中,  $\mathbf{W}$  为量测权重矩阵。利用牛顿法迭代求解式(2), 迭代方程组形式为:

$$\Delta \mathbf{x}^l = \mathbf{G}^{-1}(\mathbf{x}^l) \mathbf{H}^T(\mathbf{x}^l) \mathbf{R}^{-1} [\mathbf{z} - \mathbf{h}(\mathbf{x}^l)] \quad (3)$$

$$\mathbf{x}^{l+1} = \mathbf{x}^l + \Delta \mathbf{x}^l \quad (4)$$

其中,  $l$  为迭代次数;  $\mathbf{R}$  为量测误差协方差矩阵;  $\mathbf{H}(\mathbf{x}) = \frac{\partial \mathbf{h}(\mathbf{x})}{\partial \mathbf{x}}$  为量测函数的雅可比矩阵;  $\mathbf{G}(\mathbf{x}) = \mathbf{H}^T(\mathbf{x}) \mathbf{R}^{-1} \mathbf{H}(\mathbf{x})$  为增益矩阵。

## 2 DBN 基本原理

DBN 是深度学习的生成模型之一, 由多层 RBM 堆叠而成。RBM 作为一种有效的特征处理方法, 能够求解电力系统高维、复杂、非线性问题<sup>[19]</sup>。本文采用 DBN 对节点的伪量测功率进行建模以获得精度较高的伪量测。

### 2.1 RBM

RBM 是由可见层和隐含层构成的对称、无自反馈的随机神经网络模型, 层内神经元无连接, 层间神经元通过权重全连接, 其典型拓扑结构如图 1 所示。图中  $\mathbf{s}$  为可见层, 表示观测数据;  $\mathbf{g}$  为隐含层, 相当于特征提取器;  $\mathbf{W}$  为两层之间的连接权重。网络中神经元只有激活、未激活 2 种状态, 通常用二进制数 1 和 0 表示。

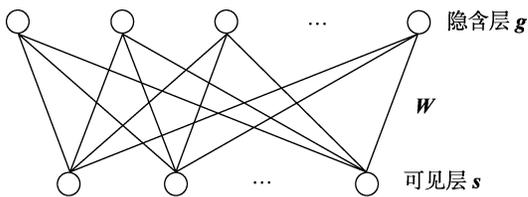


图 1 RBM 典型拓扑结构

Fig.1 Typical topological structure of RBM

RBM 是一种基于统计力学提出的能量模型, 令  $n, m$  分别为可见层及隐含层神经元的个数,  $s_i, g_j$  分别为可见层第  $i$  个神经元的状态以及隐含层第  $j$  个神经元的状态, 状态  $(\mathbf{s}, \mathbf{g})$  确定的 RBM 系统所具有的能量可表示为:

$$E(\mathbf{s}, \mathbf{g} | \boldsymbol{\theta}) = - \sum_{i=1}^n a_i s_i - \sum_{j=1}^m b_j g_j - \sum_{i=1}^n \sum_{j=1}^m s_i W_{ij} g_j \quad (5)$$

其中,  $\boldsymbol{\theta} = \{a_i, b_j, W_{ij}\}$  为 RBM 的参数, 数值可通过训练得到。当参数确定时, 可以得到给定状态的联合分布概率:

$$P(\mathbf{s}, \mathbf{g} | \boldsymbol{\theta}) = \frac{1}{Z(\boldsymbol{\theta})} \sum_{\mathbf{s}, \mathbf{g}} e^{-E(\mathbf{s}, \mathbf{g} | \boldsymbol{\theta})} \quad (6)$$

$$Z(\boldsymbol{\theta}) = \sum_{\mathbf{s}, \mathbf{g}} e^{-E(\mathbf{s}, \mathbf{g} | \boldsymbol{\theta})}$$

其中,  $Z(\boldsymbol{\theta})$  为归一化因子。由于隐含层各神经元的

激活状态是相互独立的, 当可见层各神经元的状态给定时, 隐含层第  $j$  个神经元的激活概率为:

$$P(g_j=1 | \mathbf{s}, \boldsymbol{\theta}) = \sigma \left( b_j + \sum_i s_i W_{ij} \right) \quad (7)$$

同理, 当隐含层各神经元的状态给定时, 可见层第  $i$  个神经元的激活概率为:

$$P(s_i=1 | \mathbf{g}, \boldsymbol{\theta}) = \sigma \left( a_i + \sum_j W_{ij} g_j \right) \quad (8)$$

其中,  $\sigma(y) = \frac{1}{1 + \exp(-y)}$  为 sigmoid 激活函数。

### 2.2 DBN

DBN 是由 Hinton 等人提出的一种高效学习的深度网络, 用于处理高维、大规模数据问题。DBN 的发展应用开启了当前深度学习研究的浪潮。RBM 不同层数对伪量测建模精度具有直接影响, 经过多次实验比较, 本文建立 2 层 RBM 网络结构的 DBN 模型, 其结构如附录中图 A1 所示。

在伪量测建模时首先对 DBN 进行训练, 目的是确定连接权重与神经元偏置。训练过程包括预训练和反向微调两部分。预训练过程首先输入负荷历史值、气象信息、日期类型等数据, 采用无监督贪心算法训练第一个 RBM, 完成后将该 RBM 隐含层输出作为后一个 RBM 的输入并对其进行训练。反向微调过程采用误差反向传播 BP (Back Propagation) 算法对参数进行微调, 该反向微调过程与 BP 神经网络的训练原理相同, 因此 DBN 最后一层为单层 BP 神经网络。

## 3 基于 DBN 伪量测建模的改进等效电流量测变换法状态估计

本文算法分为 2 个部分: 采用 DBN 对节点的伪量测功率进行建模, 利用高斯混合模型计算相应的伪量测权重; 同时, 由于配电网含有虚拟量测, 提出采用线性约束处理虚拟量测的方法, 建立改进的等效电流量测变换法状态估计模型。

### 3.1 伪量测建模

本文伪量测为负荷节点的有功功率和无功功率。负荷类型包括工业负荷、居民负荷、商业负荷及其他负荷, 基本覆盖了母线负荷的基本特性, 具有广泛适用性。

采用 DBN 对节点的伪量测功率进行建模时, 输出变量为待预测日负荷  $L_{(d,t)}$ , 输入变量为对输出负荷具有较大影响的历史负荷、温度、日期类型。详细的输入变量如表 1 所示。其中, 下标  $(d, t)$  表示第  $d$  天第  $t$  时刻,  $L_{(d-1, t-1)}$  为对应前一天前一时刻的负荷值 (采样间隔为 15 min);  $T_{(d,t)}$  为第  $d$  天第  $t$  时刻的温度;  $D_{\text{type}}$  为日期类型, 分别以数字 1—7 代表星期一至星期日。

表1 伪量测建模的输入变量

Table 1 Input variables of pseudo measurement modeling

历史负荷	温度	日期类型
$L_{(d,t-1)}, L_{(d,t-2)}, L_{(d,t-3)}, L_{(d,t-4)},$ $L_{(d,t-5)}, L_{(d,t-6)}, L_{(d-1,t)}, L_{(d-7,t)}, L_{(d-1,t-1)}$	$T_{(d,t)}, T_{(d,t-1)}$	$D_{type}$

将 DBN 训练得到的一年的负荷节点注入功率误差输入 GMM, 通过边缘密度函数分析可以得到相应时刻的伪量测误差, 从而求取伪量测权重。

### 3.2 基于等效电流量测变换分离虚拟量测

通过等效电流量测变换可将非线性状态估计转换为线性状态估计, 便于分离虚拟量测并采用线性约束形式对其进行处理。本文对 DBN 进行训练得到伪量测模型后, 将实时量测、伪量测、虚拟量测输入改进等效电流量测变换法配电网状态估计器中。实时量测包括部分支路有功功率量测、无功功率量测以及电流幅值量测; 虚拟量测为零注入节点的功率量测。

状态估计器中状态变量的形式通常有直角坐标下节点电压<sup>[16]</sup>、极坐标下节点电压<sup>[3]</sup>和极坐标下的支路电流<sup>[20]</sup>3种。本文采用节点电压的直角坐标形式作为状态变量, 并且将节点注入有功功率量测  $P_i^{\text{meas}}$ 、无功功率量测  $Q_i^{\text{meas}}$  转换成节点注入电流量测实部  $I_i^{\text{real}}$ 、虚部  $I_i^{\text{imag}}$ , 将支路有功功率量测  $P_{ij}^{\text{meas}}$ 、无功功率量测  $Q_{ij}^{\text{meas}}$  以及支路电流幅值量测  $I_{ij}^{\text{meas}}$  转换成支路电流量测实部  $I_{ij}^{\text{real}}$ 、虚部  $I_{ij}^{\text{imag}}$ <sup>[21]</sup>, 以获取等效量测与电压之间的线性关系, 从而分离出虚拟量测。

节点注入功率量测等效变换公式为:

$$I_i^{\text{eq}} = I_i^{\text{real}} + jI_i^{\text{imag}} = \frac{P_i^{\text{meas}} + jQ_i^{\text{meas}}}{v_i^l \angle \theta_i^l} \quad (9)$$

其中,  $v_i^l, \theta_i^l$  分别为第  $l$  次迭代时节点电压的幅值和相角。

同理可得支路功率量测等效变换公式为:

$$I_{ij}^{\text{eq}} = I_{ij}^{\text{real}} + jI_{ij}^{\text{imag}} = \frac{P_{ij}^{\text{meas}} + jQ_{ij}^{\text{meas}}}{v_i^l \angle \theta_i^l} \quad (10)$$

支路电流幅值量测等效变换公式为:

$$I_{ij}^{\text{eq}} = I_{ij}^{\text{meas}} \frac{I_{ij}^l}{|I_{ij}^l|} \quad (11)$$

其中,  $I_{ij}^l$  为第  $l$  次迭代时的支路电流复相量。

将各类量测变换为等效电流量测后, 等效电流量测的权重较变换前发生改变, 可以根据间接量测的误差传递规律求解等效变换后量测的权重<sup>[26]</sup>。等效电流量测实部方差  $\sigma_r^2$  以及虚部方差  $\sigma_i^2$  分别为:

$$\sigma_r^2 = [e_i^2 / (e_i^2 + f_i^2)^2] \sigma_p^2 + [f_i^2 / (e_i^2 + f_i^2)^2] \sigma_q^2 \quad (12)$$

$$\sigma_i^2 = [f_i^2 / (e_i^2 + f_i^2)^2] \sigma_p^2 + [e_i^2 / (e_i^2 + f_i^2)^2] \sigma_q^2 \quad (13)$$

其中,  $e_i, f_i$  分别为节点电压的实部和虚部;  $\sigma_p^2, \sigma_q^2$  分别为有功功率量测和无功功率量测的方差。

由于本文的状态变量为节点电压相量的实部和虚部, 经过等效电流量测变换之后, 等效量测  $\mathbf{Z}$  与直角坐标下的电压  $\mathbf{V}$  存在以下线性关系:

$$\mathbf{Z} = \mathbf{H}\mathbf{V} \quad (14)$$

等效量测  $\mathbf{Z}$  中含有虚拟量测  $\mathbf{Z}_0$  和非虚拟量测  $\mathbf{Z}_n$  两部分, 基于上式可分离出虚拟量测并以线性约束形式进行处理。将节点电压  $\mathbf{V}$  分为零注入节点电压  $\mathbf{X}_0$  和非零注入节点电压  $\mathbf{X}_n$ 。则式(14)可以写为:

$$\mathbf{Z} = \begin{bmatrix} \mathbf{Z}_0 \\ \mathbf{Z}_n \end{bmatrix} = \begin{bmatrix} \mathbf{H}_0 \\ \mathbf{H}_n \end{bmatrix} \begin{bmatrix} \mathbf{X}_0 \\ \mathbf{X}_n \end{bmatrix} = \begin{bmatrix} \mathbf{H}_{00} & \mathbf{H}_{0n} \\ \mathbf{H}_{n0} & \mathbf{H}_{nn} \end{bmatrix} \begin{bmatrix} \mathbf{X}_0 \\ \mathbf{X}_n \end{bmatrix} \quad (15)$$

分离出上式中的虚拟量测部分, 可得虚拟量测的线性约束形式以及剩余非虚拟量测表达式分别为:

$$\mathbf{Z}_0 = \mathbf{H}_{00}\mathbf{X}_0 + \mathbf{H}_{0n}\mathbf{X}_n \quad (16)$$

$$\mathbf{Z}_n = \mathbf{H}_{n0}\mathbf{X}_0 + \mathbf{H}_{nn}\mathbf{X}_n \quad (17)$$

虚拟量测值  $\mathbf{Z}_0 = 0$ , 求解式(16)可得零注入节点电压  $\mathbf{X}_0$ :

$$\mathbf{X}_0 = -\mathbf{H}_{00}^{-1}\mathbf{H}_{0n}\mathbf{X}_n \quad (18)$$

将式(18)代入式(17)中, 可得非零注入节点电压  $\mathbf{X}_n$  与非虚拟量测  $\mathbf{Z}_n$  的关系:

$$\mathbf{Z}_n = (-\mathbf{H}_{n0}\mathbf{H}_{00}^{-1}\mathbf{H}_{0n} + \mathbf{H}_{nn})\mathbf{X}_n = \mathbf{A}\mathbf{X}_n \quad (19)$$

显然矩阵  $\mathbf{A}$  为常数矩阵。

根据式(18)和式(19), 求解节点电压  $\mathbf{X}_0, \mathbf{X}_n$  是含等式约束的加权最小二乘法优化问题, 其模型为:

$$\begin{cases} \min \mathbf{J}(\mathbf{x}) = (\mathbf{Z}_n - \mathbf{A}\mathbf{X}_n)^T \mathbf{W}(\mathbf{Z}_n - \mathbf{A}\mathbf{X}_n) \\ \text{s.t. } \mathbf{X}_0 = -\mathbf{H}_{00}^{-1}\mathbf{H}_{0n}\mathbf{X}_n \end{cases} \quad (20)$$

利用牛顿法迭代求解上式, 迭代方程组形式为:

$$\Delta \mathbf{X}_n^l = (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{W} [\mathbf{Z}_n^{\text{meas}}(\mathbf{X}^l) - \mathbf{Z}_n(\mathbf{X}^l)]$$

$$\mathbf{X}_n^{l+1} = \mathbf{X}_n^l + \Delta \mathbf{X}_n^l$$

$$\mathbf{X}_0^{l+1} = -\mathbf{H}_{00}^{-1}\mathbf{H}_{0n}\mathbf{X}_n^{l+1} \quad (21)$$

其中,  $\mathbf{W}$  为非虚拟量测量权重;  $\mathbf{Z}_n^{\text{meas}}(\mathbf{X}^l)$  为第  $l$  次迭代时的等效电流量测;  $\mathbf{Z}_n(\mathbf{X}^l)$  为第  $l$  次迭代时等效电流量测与节点电压之间的线性量测函数。由于  $\mathbf{Z}_n(\mathbf{X}^l) = \mathbf{A}\mathbf{X}_n^l$ , 则每次迭代非零注入节点电压  $\mathbf{X}_n$  修正公式可推导为:

$$\Delta \mathbf{X}_n^l = (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{W} [\mathbf{Z}_n^{\text{meas}}(\mathbf{X}^l) - \mathbf{A}\mathbf{X}_n^l] \quad (22)$$

$$\Delta \mathbf{X}_n^l = (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{W} \mathbf{Z}_n^{\text{meas}}(\mathbf{X}^l) - \mathbf{X}_n^l \quad (23)$$

$$\mathbf{X}_n^l + \Delta \mathbf{X}_n^l = (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{W} \mathbf{Z}_n^{\text{meas}}(\mathbf{X}^l) \quad (24)$$

$$\mathbf{X}_n^{l+1} = (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{W} \mathbf{Z}_n^{\text{meas}}(\mathbf{X}^l) \quad (25)$$

由上式可知, 每次迭代不必重新求解线性量测函数  $\mathbf{Z}_n(\mathbf{X}^l)$  的值, 计算简便, 效率更高。式(18)中求解零注入节点电压不需要赋予虚拟量测权重, 避免了信息矩阵病态问题的出现。

## 4 算例仿真

本文以 IEEE 13 节点系统及我国某实际地级市 35 节点配电网(记为 C35)为测试算例,其网络接线图分别如附录中图 A2、图 A3 所示。将本文算法与基于 BP 神经网络伪量测建模状态估计算法及考虑零注入约束的传统大权重法进行比较,验证本文所提算法的有效性。实时量测数据是由潮流真值与服从高斯分布的随机噪声叠加而成,虚拟量测为零注入节点的功率量测。本文算法由 MATLAB R2014a 编程实现,CPU 主频为 3.2 GHz, RAM 为 4 GB。

### 4.1 伪量测模型测试

本文通过 DBN 对工业负荷、居民负荷、商业负荷及其他负荷的有功功率及无功功率进行建模。DBN 训练过程即是对负荷变化趋势的学习,几类负荷的有功功率变化曲线如附录中图 A4 所示。为验证 DBN 伪量测建模的有效性,将其输出结果与基于 BP 神经网络伪量测建模的输出结果进行比较。

为便于对建模结果进行定量分析,本文采用平均相对误差作为衡量 2 种不同伪量测建模方法精确度的指标:

$$e_p = \frac{1}{N} \sum_i \left| \frac{\hat{P}_i - P_i}{P_i} \right| \quad (26)$$

$$e_q = \frac{1}{N} \sum_i \left| \frac{\hat{Q}_i - Q_i}{Q_i} \right| \quad (27)$$

其中,  $\hat{P}_i$ 、 $\hat{Q}_i$  分别为 2 种神经网络有功、无功输出值;  $P_i$ 、 $Q_i$  为负荷真值;  $N$  为 2 种神经网络输出样本总数。

假设 IEEE 13 节点系统中节点 2、5、8、11 的负荷类型分别为工业负荷、居民负荷、商业负荷以及其他负荷。这 4 个节点 a 相负荷通过 DBN 以及 BP 神经网络建模,输出结果的平均相对误差如图 2 所示。

根据图 2 可知, DBN 对各个节点负荷建模输出结果的平均相对误差均低于 BP 神经网络,因此 DBN 的预测精确度较 BP 神经网络有明显的改善。

对配电网进行状态估计的周期一般为 15 min, 而 DBN 对各个节点负荷建模平均运行时间为 68 s, 在目前的普通台式计算机基础上不同负荷的训练可在服务器上并行运算,因此各类负荷在状态估计周期内有足够的时间训练,满足工程应用需求。且短期内若无负荷的不正常剧烈波动, DBN 网络无需重复训练,所以 DBN 的时间性完全能满足配电网状态估计的需求。

### 4.2 基于 2 种神经网络伪量测建模状态估计测试

本文在伪量测模型的基础上进行配电网三相状态估计。节点三相电压相角初值  $\delta_{ABC} = [0, -2/3\pi, 2/3\pi]$ , 三相电压幅值初值  $v_{ABC} = [1, 1, 1]$  p.u., 三相电压实部和虚部初值可由坐标变换得到。伪量测由本文 DBN、BP 神经网络这 2 种伪量测模型建立,其

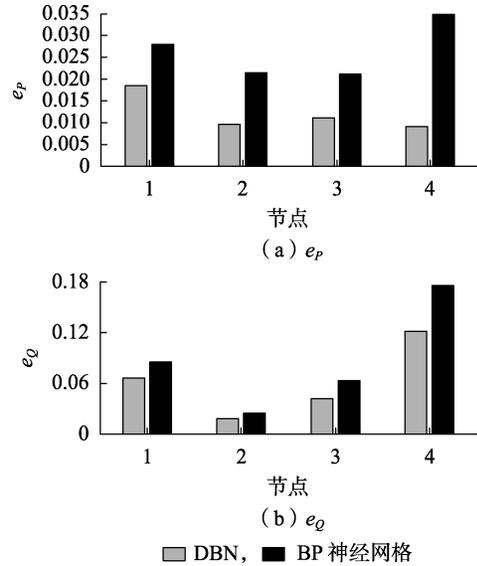


图 2 DBN 与 BP 神经网络伪量测建模结果对比

Fig.2 Results comparison of pseudo measurement modeling between DBN and BP neural networks

标准差通过高斯混合分布拟合的误差分布确定。实时量测中支路功率量测标准差为真值的 5%, 支路电流幅值量测标准差为真值的 3%。考虑到实际配电网中电压幅值量测很少, 本文的实时量测中无电压幅值量测, 虚拟量测标准差为 0.1%。

将基于 DBN 伪量测建模状态估计结果与基于 BP 神经网络伪量测建模状态估计结果相比较以验证本文模型的可行性及优越性。

本文采用平均绝对误差和最大绝对误差作为衡量基于 2 种伪量测建模状态估计精度的指标:

$$e_v = \frac{1}{M} \sum_i |\hat{V}_i - V_i| \quad (28)$$

$$e_\delta = \frac{1}{M} \sum_i |\hat{\delta}_i - \delta_i| \quad (29)$$

$$|\Delta V|_{\max} = \max \{ |\hat{V}_i - V_i| \} \quad i = 1, 2, \dots, M \quad (30)$$

$$|\Delta \delta|_{\max} = \max \{ |\hat{\delta}_i - \delta_i| \} \quad i = 1, 2, \dots, M \quad (31)$$

其中,  $M$  为节点个数;  $\hat{V}_i$ 、 $\hat{\delta}_i$  分别为节点  $i$  电压幅值以及相角的估计值;  $V_i$ 、 $\delta_i$  分别为节点  $i$  电压幅值以及相角的真值;  $e_v$ 、 $e_\delta$  分别为电压幅值和相角的平均绝对误差;  $|\Delta V|_{\max}$ 、 $|\Delta \delta|_{\max}$  分别为电压幅值和相角的最大绝对误差。基于 2 种神经网络伪量测建模的状态估计结果如表 2 所示, 表中  $e_v$ 、 $|\Delta V|_{\max}$  为标幺值。

表 2 基于 2 种神经网络伪量测建模的状态估计结果

Table 2 State estimation results based on pseudo measurement modeling using two neural networks

算例	伪量测模型	$e_v$	$e_\delta / (^\circ)$	$ \Delta V _{\max}$	$ \Delta \delta _{\max} / (^\circ)$
IEEE 13	DBN	0.010 77	0.059 65	0.015 83	0.149 3
	BP	0.019 75	0.097 52	0.027 18	0.204 2
C35	DBN	0.007 36	0.021 80	0.007 82	0.043 0
	BP	0.014 63	0.052 12	0.015 13	0.080 5

由表 2 可知,基于 DBN 伪量测建模的配电网状态估计电压幅值和电压相角的平均绝对误差、最大绝对误差均小于基于 BP 神经网络伪量测建模的配电网状态估计。可见,与基于 BP 神经网络伪量测建模相比,基于 DBN 伪量测建模状态估计结果更加精确。

#### 4.3 虚拟量测处理测试

处理零注入约束时,传统大权重法不能严格保证零注入节点功率为 0 且可能出现信息矩阵病态问题。为了验证本文以线性约束形式处理虚拟量测能够避免以上问题的出现,在伪量测模型基础上分别用改进等效电流量测变换法(记为算法 1)和传统大权重法(记为算法 2)进行状态估计。2 种方法的伪量测均由 DBN 建模得到。量测配置与 4.2 节相同。得到的迭代次数、计算时间,以及虚拟量测节点功率绝对值之和  $\sum_i |P_i|$ 、 $\sum_i |Q_i|$  如表 3 所示,表中  $\sum_i |P_i|$ 、 $\sum_i |Q_i|$  为标么值。

表 3 2 种算法状态估计结果

Table 3 State estimation results of two algorithms

算例	算法	迭代次数	计算时间/s	$\sum_i  P_i $	$\sum_i  Q_i $
IEEE 13	1	4	0.059	$7.753 \times 10^{-12}$	$6.523 \times 10^{-12}$
	2	7	0.133	$1.512 \times 10^{-4}$	$2.487 \times 10^{-4}$
C35	1	5	0.069	$1.480 \times 10^{-14}$	$1.699 \times 10^{-14}$
	2	6	0.212	$4.146 \times 10^{-3}$	$1.103 \times 10^{-3}$

由表 3 可知,本文算法迭代次数较大权重法更少,且因为雅可比矩阵为常数,计算速度得以提升;零注入节点注入功率绝对值之和远小于大权重法,保证了零注入约束严格满足。

传统大权重法中,虚拟量测权重与伪量测权重相差过大可能引起数值稳定性问题,对于 C35 节点系统,2 种方法信息矩阵条件数的对数值随迭代次数变化曲线如图 3 所示。

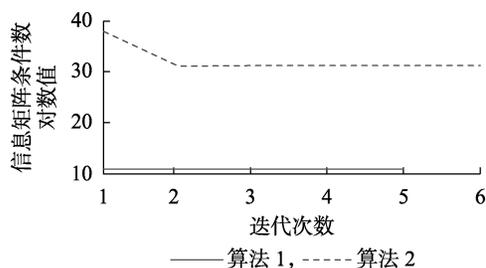


图 3 信息矩阵条件数对数值随迭代变化曲线

Fig.3 Logarithm of gain matrix condition number vs. iteration number

由图 3 可知,本文方法信息矩阵条件数远小于传统大权重法,数值稳定性问题得以改善。

## 5 结论

本文提出了基于 DBN 伪量测建模的配电网状

态估计算法,并采用线性约束形式处理虚拟量测。DBN 伪量测建模充分考虑了影响负荷的因素,利用与当前时刻负荷相关性较大的数据作为输入,与 BP 神经网络相比能够获取更精确的伪量测。另一方面通过等效电流量测变换分离虚拟量测并进行线性状态估计,严格保证了零注入节点功率为 0,改善了数值稳定性问题,同时提高了计算速度,具备工程应用价值。

附录见本刊网络版(<http://www.epae.cn>)。

## 参考文献:

- [1] 徐臣,余贻鑫. 提高配电网状态估计精度的量测配置优化方法[J]. 电力自动化设备,2009,29(7):17-21.  
XU Chen, YU Yixin. Evaluation and optimization of meter placement to enhance distribution state estimation[J]. Electric Power Automation Equipment, 2009, 29(7): 17-21.
- [2] 陈醒,卫志农,沈海平,等. 基于双解耦的配电网三相不平衡快速潮流算法[J]. 电力自动化设备,2017,37(10):63-70.  
CHEN Xing, WEI Zhihong, SHEN Haiping, et al. Three-phase unbalanced fast power flow calculation algorithm based on double decoupling for distribution network[J]. Electric Power Automation Equipment, 2017, 37(10): 63-70.
- [3] 周佳伟,卫志农,孙国强,等. 基于复数域标么化的配电网三相不对称快速分解状态估计算法[J]. 电力自动化设备,2017,37(3):13-18.  
ZHOU Jiawei, WEI Zhihong, SUN Guoqiang, et al. Grounding wire detection based on three-phase symmetrical voltage injection method for distribution network[J]. Electric Power Automation Equipment, 2017, 37(3): 13-18.
- [4] MANITSAS E, SINGH R, PAL B, et al. Modelling of pseudo-measurements for distribution system state estimation[C]//Smart Grids for Distribution. Frankfurt, Germany: IET-CIRED, 2008: 1-4.
- [5] GERBEC D, GUBINA F, TOROS Z. Actual load profiles of consumers without real time metering[C]//Power Engineering Society General Meeting. San Francisco, CA, USA: IEEE, 2005: 2578-2582.
- [6] 卫志农,谢铁明,孙国强,等. 基于超短期负荷预测和混合量测的线性动态状态估计[J]. 中国电机工程学报,2010,30(1):47-51.  
WEI Zhihong, XIE Tieming, SUN Guoqiang, et al. Linear dynamic state estimation based on mixed measurements[J]. Proceedings of the CSEE, 2010, 30(1): 47-51.
- [7] 张平,潘学萍,薛文超. 基于小波分解模糊灰色聚类 and BP 神经网络的短期负荷预测[J]. 电力自动化设备,2012,32(11):121-125.  
ZHANG Ping, PAN Xueping, XUE Wenchao. Multilevel cascading solution for distributed busbar protection[J]. Electric Power Automation Equipment, 2012, 32(11): 121-125.
- [8] TIM S, ANGIÓN A, PONCI F, et al. Impact of pseudo-measurements from new load profiles on state estimation in distribution grids[C]//Instrumentation and Measurement Technology Conference. Montevideo, Uruguay: IEEE, 2014: 625-630.
- [9] SINHA A K, MONDAL J K. Dynamic state estimator using ANN based bus load prediction[J]. IEEE Transactions on Power Systems, 1999, 14(4): 1219-1225.
- [10] 黄蔓云,孙国强,卫志农,等. 基于脉冲神经网络伪量测建模的配电网三相状态估计[J]. 电力系统自动化,2016,40(16):

- 38-43.  
HUANG Manyun, SUN Guoqiang, WEI Zhinong, et al. Three-phase state estimation in distribution system based on pseudo measurement modeling using spiking neural network[J]. Automation of Electric Power Systems, 2016, 40(16): 38-43.
- [11] 司徒友, 李刚强, 张水平. 基于小波分解和深度信念网络的短期风速预测[J]. 广东电力, 2017, 30(4): 25-30.  
SITU You, LI Gangqiang, ZHANG Shuiping. Short-term wind speed forecasting based on wavelet decomposition and deep belief network [J]. Guangdong Electric Power, 2017, 30(4): 25-30.
- [12] GARCIA A, MONTICELLI A, ABREU P. Fast decoupled state estimation and bad data processing[J]. IEEE Transactions on Power Apparatus & Systems, 1979, 98(5): 1645-1652.
- [13] HOLTEN L, GJELSVIK A, AAM S, et al. Comparison of different methods for state estimation[J]. IEEE Transactions on Power Systems, 1988, 3(4): 1798-1806.
- [14] KORRES G N. A robust algorithm for power system state estimation with quality constraints[J]. IEEE Transactions on Power Systems, 2010, 25(3): 1531-1541.
- [15] 郭焯, 吴文传, 张伯明, 等. 拉格朗日乘子法电力系统网络参数错误辨识研究[J]. 中国电机工程学报, 2013, 33(7): 86-91.  
GUO Ye, WU Wenchuan, ZHANG Boming, et al. Power system network parameter error identification by lagrange multiplier based method[J]. Proceedings of the CSEE, 2013, 33(7): 86-91.
- [16] 郭焯, 张伯明, 吴文传, 等. 直角坐标下含零注入约束的电力系统状态估计修正牛顿法[J]. 中国电机工程学报, 2012, 32(19): 96-100.  
GUO Ye, ZHANG Boming, WU Wenchuan, et al. Power system state estimation solution with zero injection constraints using modified newton method[J]. Proceedings of the CSEE, 2012, 32(19): 96-100.
- [17] MANITSAS E, SINGH R, PAL B C, et al. Distribution system state estimation using an artificial neural network approach for pseudo measurement modeling[J]. IEEE Transactions on Power Systems, 2012, 27(4): 1888-1896.
- [18] ALMEIDA M C D, OCHOA L F. An improved three-phase AMB distribution system state estimator[J]. IEEE Transactions on Power Systems, 2017, 32(2): 1463-1473.
- [19] 张春霞, 姬楠楠, 王冠伟. 受限玻尔兹曼机[J]. 工程数学学报, 2015, 32(2): 159-173.  
ZHANG Chunxia, JI Nannan, WANG Guanwei. Introduction of restricted boitzmann machines[J]. Chinese Journal of Engineering Mathematics, 2015, 32(2): 159-173.
- [20] BARAN M E, KELLEY A W. A branch-current-based state estimation method for distribution systems [J]. IEEE Transactions on Power Systems, 1995, 10(1): 483-491.
- [21] 程浩忠, 袁青山, 汪一华, 等. 基于等效电流测量变换的电力系统状态估计方法[J]. 电力系统自动化, 2000, 24(14): 25-29.  
CHENG Haozhong, YUAN Qingshan, WANG Yihua, et al. A state estimation method of power system based on equivalent current measurement transformation[J]. Automation of Electric Power Systems, 2000, 24(14): 25-29.

#### 作者简介:



孙国强

孙国强(1978—),男,江苏江阴人,副教授,博士,主要研究方向为电力系统运行分析与控制(**E-mail**: hhusunguoqiang@163.com);

钱 婧(1994—),女,江苏南通人,硕士研究生,主要研究方向为配电系统状态估计(**E-mail**: 635610253@qq.com);

卫志农(1962—),男,江苏江阴人,教授,博士研究生导师,博士,主要研究方向为电力系统运行分析与控制、输配电自动化(**E-mail**: wzn\_nj@263.net);

臧海祥(1986—),男,江苏扬州人,副教授,博士,主要研究方向为电力系统规划与运行、新能源发电技术(**E-mail**: zanghaixiang@hhu.edu.cn)。

## State estimation of distribution system based on pseudo measurement modeling using deep belief network

SUN Guoqiang<sup>1</sup>, QIAN Qiang<sup>1</sup>, CHEN Liang<sup>2</sup>, WEI Zhinong<sup>1</sup>, ZANG Haixiang<sup>1</sup>,  
WANG Hanwen<sup>1</sup>, HUANG Qiang<sup>2</sup>

(1. College of Energy and Electrical Engineering, Hohai University, Nanjing 210098, China;  
2. State Grid Jiangsu Electric Power Company Research Institute, Nanjing 211103, China)

**Abstract:** Aiming at the situation that the pseudo measurements need to be added to improve the redundancy of measurements due to the insufficient real-time measurements in distribution system, a state estimation method based on pseudo measurement modeling method using DBN (Deep Belief Network) is proposed for distribution system. After training DBN by various historical load data, corresponding temperature and date type, the test data is input to obtain pseudo measurements with high accuracy. The state estimation of distribution system is carried out based on the improved equivalent current measurement transformation method, and the virtual measurements are processed in the form of linear constraint. Simulative results verify the effectiveness of the proposed method.

**Key words:** distribution network; state estimation; deep belief network; pseudo measurement; virtual measurement

附录:

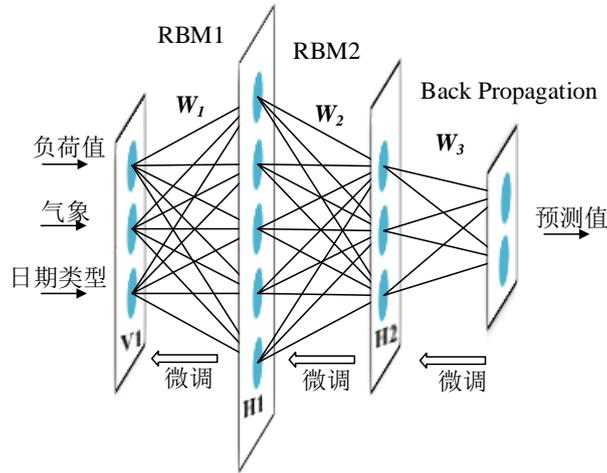


图 A1 DBN 网络结构模型

Fig.A1 Model of DBN network structure

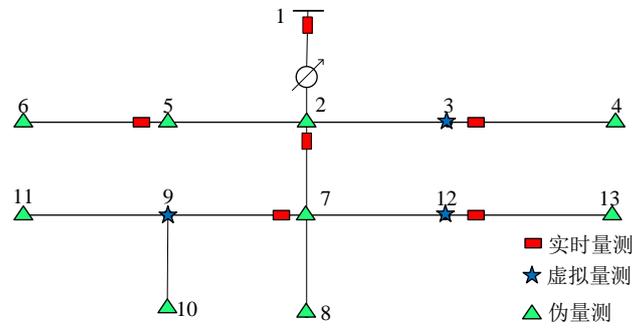


图 A2 IEEE 13 节点系统

Fig.A2 IEEE 13-bus system

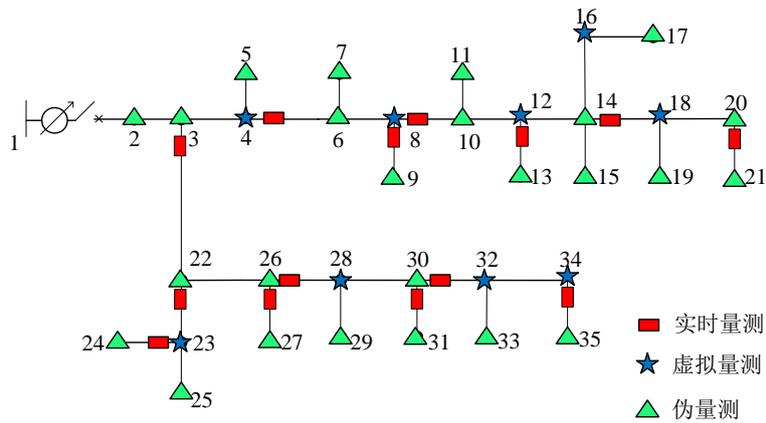


图 A3 某实际地级市 35 节点配电网

Fig.A3 A practical urban 35-bus distribution network

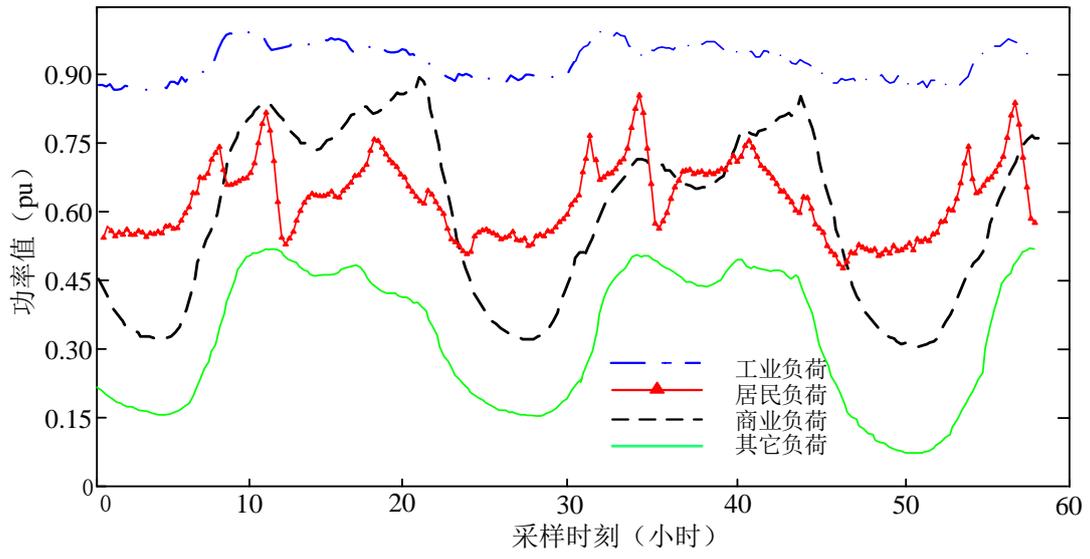


图 A4 部分采样时刻的负荷变化曲线

Fig.A4 Load variation curve at partial sampling times