

DOI: 10.7667/PSPC171567

# 基于神经网络的状态估计方法研究

赵巍岳, 靳松, 吕天成

(华北电力大学电子与通信工程系, 河北 保定 071001)

**摘要:** 智能电网建设的快速推进, 导致状态估计算法所处理的数据量急剧增加。串行状态估计算法求解速度慢, 无法满足电力系统实时分析的要求; 而并行状态估计方法需要大规模计算集群的支持, 会占据大量的硬件资源并产生高能耗。为解决上述问题, 提出一种基于神经网络的状态估计方法。该方法以离线方式搭建并训练神经网络。在状态估计的实际计算中, 以神经网络的前向计算代替传统算法中的迭代最小二乘拟合, 从而大幅减少状态估计算法的执行时间。由于神经网络的前向计算所需时间很短, 即使处理大规模电网, 提出的方法仍可在单机平台上运行, 从而避免使用大规模计算集群所需的能耗。同时, 神经网络自身的高容错性还能有效地修正量测数据中的误差。实验结果表明, 与串行方法相比, 所提方法计算速度提升了约 205 倍。

**关键词:** 状态估计; 智能电网; 神经网络; 权重初始化

## Research on state estimation based on artificial neural networks

ZHAO Weiyue, JIN Song, LÜ Tiancheng

(Department of Electronics and Communication Engineering, North China Electric Power University, Baoding 071001, China)

**Abstract:** With the rapid progress in smart grid, data required to be processed by the state estimation algorithm increases sharply. However, the existing serial algorithms suffered from lower computing speed and cannot meet the requirement of real-time analysis; while deployment of the parallel algorithms needs large scale computing cluster which occupies huge amount of hardware resources and resulting in high energy cost. To overcome above mentioned problems, this paper proposes a Neural Network (NN) based state estimation algorithm. The proposed algorithm constructs and trains the neural network in an offline manner. While solving the actual estimation problem, the iterative least square fitting in traditional state estimation schemes is replaced with forward calculation of the trained neural network. This can reduce execution time of the overall state estimation algorithm significantly. Because the time consumed by forward calculation of the neural networks is very short, the proposed algorithm can still run on a single machine even confronting with large scale power grid, so as to avoid the energy consumption required for computing cluster. Moreover, the neural network has high robustness and can effectively correct the gross error in the measured data. The performance comparison demonstrates that the calculation speed of the proposed scheme is improved by 205 times compared with the serial algorithm.

This work is supported by Natural Science Foundation of Hebei Province (No. F2017502043).

**Key words:** state estimation; smart grid; artificial neural network; weight initialization

## 0 引言

状态估计是电力系统信息管理系统的重要组成部分<sup>[1]</sup>, 它利用量测系统的冗余度来提高数据精度, 为电网其他分析提供数据<sup>[2]</sup>。在智能电网迅速发展的背景下, 电力系统所需要处理的数据呈指数级增长<sup>[3]</sup>, 因而对状态估计计算速度的要求也越来越高。

目前状态估计算法主要有串行和并行算法两类。串行算法, 例如基于加权最小二乘法(Weighted Least Square, WLS)的状态估计算法<sup>[4-6]</sup>、基于卡尔曼的状态估计算法<sup>[7]</sup>或是基于离散傅立叶变换的状态估计算法<sup>[8]</sup>, 受限于单机系统的计算能力<sup>[9-10]</sup>, 无法满足大规模智能电网实时分析的要求。并行算法中, 以专用并行机为计算平台的算法<sup>[11-13]</sup>, 其计算能力受硬件水平限制; 以集群为计算平台的并行状态估计算法<sup>[14]</sup>, 通过增加计算节点实现更快的速度。然

基金项目: 河北省自然科学基金项目资助 (F2017502043)

而,大规模集群维护成本很高,并且带来的能耗问题不容忽视<sup>[15-16]</sup>。因此面向大规模网络的状态估计算法,除了要有较高的精度和较快的计算速度之外,应将能耗问题纳入考虑范围。

由于电网量测系统存在误差且有一定冗余度,满足状态方程的完美解是不存在的。与传统算法通过拟合算法迭代求解的方式不同,神经网络通过其很强的函数逼近能力<sup>[17-18]</sup>,将迭代过程转化为一遍神经网络前向计算,从而大大加快计算速度。目前已有神经网络与状态估计结合的智能算法<sup>[19-23]</sup>,但工作尚有不足:1)部分神经网络设计基于特定系统<sup>[19-20]</sup>;2)神经网络结构和参数以实验的方式确定,不利于对新系统进行估计。文献[21-22]中通过减少输入数据数量,缩小了神经网络规模。但文献[21]中仅使用部分负荷功率量测量作为输入,神经网络泛化能力欠佳;文献[22]中使用特征降维方法(Principal Component Analysis, PCA)选取了部分量测量作为输入,但其没有考虑由于没有量测装置的节点,且其主要成分出现偶发误差时将会给计算结果带来较大误差。

本文基于神经网络提出了一种高效状态估计方法。该方法采用神经网络前向计算<sup>[24]</sup>代替最小二乘迭代计算,能够串行快速完成大网络各子区域的估计算法。其核心在于建立以智能电网子区域为计算单位的神经网络。首先,本文提出了一种根据量测配置确定神经网络结构的方式;第二,为区分伪量测量、合理利用量测系统冗余信息,提出了一种神经网络权重初始化的方式;最后,确定了训练神经网络的方式,完成神经网络训练。实际状态估计方法的运行阶段,根据已划分的子区域从已离线训练完成的权重集中选取权重,进行前向计算完成状态估计的计算。实验结果表明,本文提出的方法能够有效地修正量测数据中的正常误差以及粗差。在处理系统中的偶发错误时,比文献中传统算法精度提高了82%以上,比文献中智能算法精度提高了56%以上。计算速度方面,与单机传统算法相比速度提升了约205倍。

## 1 状态估计算法

电网状态估计算法是根据具有一定冗余度的量测系统、配电网的拓扑结构参数,求解出一组相对准确的可以描述电网完整运行方式状态量的算法。量测系统由实时遥测量、遥信量和节点负荷量测量构成。通常,状态估计可以通过式(1)做出表述。

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

式中:  $x$  为  $n$  维的状态向量;  $z$  为  $m$  维的量测向量;

$h(x)$  为量测函数;  $e$  为量测误差向量。

由于量测系统存在量测误差,且量测系统具有一定的冗余度,即  $m > n$ , 方程(1)中不可能找到一组状态值  $x_0$  使残差矢量  $r(x_0)$  各分量均为 0, 残差计算方法见式(2)。

$$r(x_0) = z - h(x_0) \quad (2)$$

一般通过建立目标函数如式(3),期望得到使加权残差平方和最小的状态向量  $x_0$ 。

$$J(x) = [z - h(x)]^T R^{-1} [z - h(x)] \quad (3)$$

式中,  $R$  是以量测量标准差  $\sigma_i^2$  为对角元的  $m \times m$  阶量测误差方阵。

传统状态估计算法,采用加权最小二乘法对(3)式进行求解,为求得一组能使量测方程的计算值与实际值的误差最小的状态向量。以基于支路电流法的状态估计为例,求导后迭代状态向量的表达式如式(4)所示。

$$\begin{cases} \hat{I}_r^{(k)} = (H_r^T R_r^{(k)T} H_r)^{-1} H_r^T R_r^{(k)-1} z_r^{(k)} \\ \hat{I}_x^{(k)} = (H_x^T R_x^{(k)T} H_x)^{-1} H_x^T R_x^{(k)-1} z_x^{(k)} \end{cases} \quad (4)$$

式中:表示在第  $k$  次迭代所进行的计算,  $H_r$  和  $H_x$  为雅克比矩阵;  $I_r$  和  $I_x$  为支路电流值(状态向量);  $R_r^{(k)}$  和  $R_x^{(k)}$  为第  $k$  次迭代中节点权重值的方阵;  $z_r^{(k)}$  和  $z_x^{(k)}$  是经过等效量测变换得到的等效量测量;  $(H^T R^T H)$  称为信息阵,当两次迭代结果之差小于某一值时认为寻找到了最优解。

## 2 基于神经网络的状态估计方法

### 2.1 神经网络算法

神经网络以神经元为计算单位,各层神经元之间通过权重值相连。合理地建立并训练神经网络,可以完成对于任意函数的拟合。

神经网络基本计算单元神经元如图1所示。该神经元以  $x_1$ 、 $x_2$ 、 $x_3$  及截距+1为输入值,四条输入路径对应权重值分别为  $w_1$ 、 $w_2$ 、 $w_3$  和  $w_4$ , 其中  $w_4$  作为偏置。

神经元输出值(即神经元激活)计算方式见式(5)。

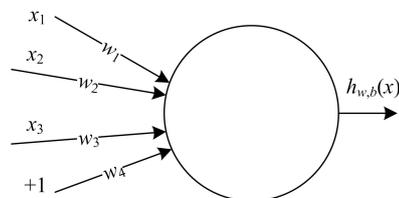


图1 一个神经元

Fig. 1 A neuron

$$h_{w,b}(x) = f(W^T x) = f\left(\sum_{i=1}^3 w_i x_i + w_4\right) \quad (5)$$

实际使用神经网络进行计算时, 只需要一组已经训练好的权重值, 输入数据并逐层、逐神经元完成所有神经元的激活, 最终在输出层得到计算结果, 这个过程被称为神经网络前向计算。

## 2.2 方法结构

本文算法面向已分解为多个子区域的智能电网, 其子区域规模大小对于本文状态估计算法实际应用时的计算速度影响不大。目前智能电网分区解耦的方法有很多<sup>[11,25]</sup>, 电网所使用具体分区方法不在本文讨论范围之内。

如图2所示, 本文提出的基于神经网络的状态估计方法分为两部分: 1) 离线训练部分, 根据子区域建立神经网络, 使用历史量测数据及状态向量对神经网络训练, 得到以子区域为估计单位的神经网络权重集; 2) 状态估计部分, 根据子区域信息从权重集中读取神经网络权重值, 量测数据预处理之后通过前向计算得到状态向量, 完成状态估计算法。

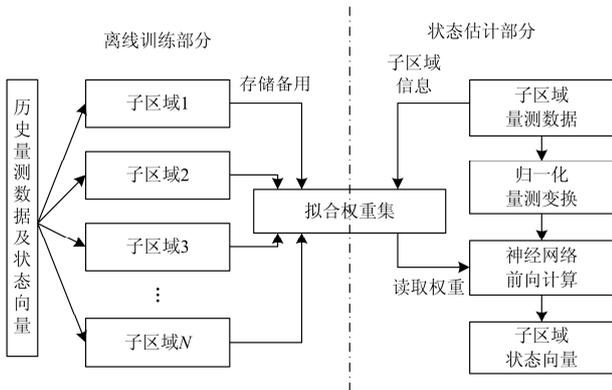


图2 方法结构图  
Fig. 2 Method structure

## 2.3 神经网络结构与建立

对于电网某子区域(节点数为  $n$ )，设该区域内共有  $a$  个量测点、 $b$  个非量测点(为满足系统可观测性)，共计  $m$  个量测数据。则神经网络建立规则如下：

(1) 输入层神经元数目为  $m$ ，输出层神经元数目为  $n$ 。

(2) 隐含层神经元数量确定: 由式(4)可知在第  $k$  次迭代过程中, 对量测量  $z_r^{(k)}$  和  $z_x^{(k)}$  进行如式(6)一次运算。

$$f^{(k)} = (H^T R^{(k)T} H)^{-1} H^T R^{(k)-1} \quad (6)$$

式中: 雅克比矩阵  $H$  为常矩阵;  $R^{(k)}$  为权重矩阵;  $f^{(k)}$  为  $m \times n$  维矩阵。本文将隐含层神经元数目设置

为  $m$ ，使输出层与隐含层之间权重阵同样为  $m \times n$  维。

(3) 隐含层层数确定: 通过实验分析隐含层数量为 2，隐含层数量不同时估计误差如表 1。

表 1 不同隐含层情况下的估计结果

Table 1 Estimation results in different hidden layers

	1 个隐含层	2 个隐含层	3 个隐含层
平均估计误差	1.179%	0.285%	0.544%

建立完成的神经网络如图 3 所示。

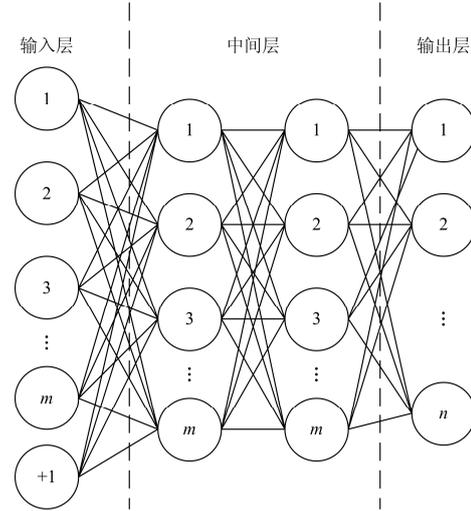


图3 神经网络结构图

Fig. 3 Structure of neural network

## 2.4 神经网络权重初始化

传统的神经网络权重初始化采用服从高斯分布的随机初始化方法。但这种方法可能使神经网络训练的难度增加, 原因主要有两方面: 第一, 随机初始化不能区分正常量测量和伪量测量, 将增加伪量测量对估计精度的影响; 第二, 根据网络拓扑结构以及信息阵结构, 相邻的量测数据之间关系的紧密程度要高于不相邻量测点, 随机初始化不能体现量测数据之间相关性的强弱。下面结合算例, 具体说明本文中权重初始化的方法。

### 2.4.1 相邻量测量和不相邻量测量

IEEE33 节点系统量测配置如图 4 所示, 其中线路功率量测 13 对(方框表示), 节点负荷功率量测 32 对(箭头表示)。选取各节点的负荷电流值作为状态量。以节点 5 负荷功率量测值  $WL_5$  为例说明(图中圆圈标注)。

设与  $WL_5$  相邻的支路功率量测量为  $W_5$ 、 $W_6$  和  $W_{25}$ , 根据功率量测变换将功率量测转换为等效电流量测。公式如式(7)所示。

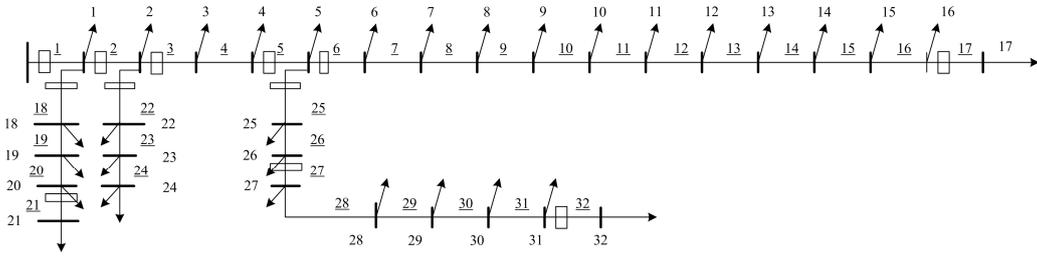


图4 IEEE33 节点系统

Fig. 4 IEEE33 power system

$$z_r + z_x = \left( \frac{P + jQ}{\dot{U}} \right)^* \quad (7)$$

式中:  $PQ$  为功率量测量  $W$  的实虚部;  $U$  为节点电压。

量测量  $WL_5$ 、 $W_5$ 、 $W_6$  和  $W_{25}$  等效变换为等效支路电流  $Z_5$ 、 $Z_6$ 、 $Z_{25}$  和等效节点负荷电流  $ZL_5$ 。在节点 5 处, 由基尔霍夫电流定律(KCL)有

$$\dot{ZL}_5 = \dot{Z}_5 - \dot{Z}_6 - \dot{Z}_{25} \quad (8)$$

估计负荷电流  $IL_5$  时, 对估计精度影响最大的值为  $ZL_5$ ; 其次为  $Z_5$ 、 $Z_6$ 、 $Z_{25}$ , 称式(8)中  $Z_5$ 、 $Z_6$ 、 $Z_{25}$  与负荷电流  $IL_5$  相邻, 表示为集合 A; 其余节点量测量对  $IL_5$  的估计精度影响较小, 称为不与负荷电流  $IL_5$  相邻, 用集合 B 表示。

#### 2.4.2 神经网络权重初始化

设相邻系数用于表示量测值与估计值的相邻关系  $k_1$ 、 $k_2$ 、 $k_3$ 。 $k_1$  表示量测值与估计值重合,  $k_2$  表示量测值与估计值的关系属于集合 A,  $k_3$  量测值与估计值的关系属于集合 B。根据相邻系数, 神经网络各层权重值初始化如式(9)所示。

$$\begin{cases} w_{ii} = \frac{1}{\sigma_i^2} \cdot k_1 \\ w_{ij} = \text{Probability}\left(-\frac{1}{\sigma_i^2} \cdot k_2, \frac{1}{\sigma_i^2} \cdot k_2\right), j \in A \\ w_{ij} = \text{Probability}\left(-\frac{1}{\sigma_i^2} \cdot k_3, \frac{1}{\sigma_i^2} \cdot k_3\right), j \in B \end{cases} \quad (9)$$

式中:  $\text{Probability}(a, b)$  表示取  $a$ 、 $b$  之间的随机值;  $w_{ij}$  表示第  $i$  个神经元与下一层第  $j$  个神经元之间的权重值;  $\sigma_i^2$  为量测标准差。本文中相邻系数规定为  $1 \geq |k_1| > |k_2| > |k_3|$ 。

### 2.5 神经网络权重训练方法

#### 2.5.1 神经网络权重训练公式

本文使用反向迭代训练神经网络权重, 训练时采取全样本集批次学习方式(full batch learning)。设训练样本集为  $C$ , 样本总数为  $N_T$ 。在对样本  $C_T$  训练时, 各层  $\delta$  值分别为  $\delta_i^T$ 、 $\delta_h^T$  和  $\delta_o^T$ , 对于网络中

任一权重值  $w_{pq}$  的更新公式如式(10)所示。

$$\begin{cases} \Delta w_{pq} = \frac{1}{N_T} \sum_{T=1}^{N_T} \delta_q^T \cdot x_p \\ w_{pq}(t+1) = \left(1 - \frac{\lambda}{N_T}\right) w_{pq}(t) + \eta \Delta w_{pq}(t) + \alpha \Delta w_{pq}(t-1) \end{cases} \quad (10)$$

式中:  $\Delta w_{pq}$  表示权值的变化量;  $\lambda$  为正则化衰减因子, 以增强网络泛化能力;  $\eta$  为学习率, 在训练过程中逐步减小;  $\alpha$  为动量系数, 用于防止学习陷入局部最小值。

#### 2.5.2 训练集设计与训练流程

本文算法中以等效的支路电流量测和节点负荷电流量测作为输入数据, 输出数据为由节点负荷电流组成的状态向量。

以子区域为计算单位的神经网络有两个训练集和一个目标集。训练集 A: 支路电流和节点负荷电流真值; 训练集 B: 在训练集 A 中均匀加入等数量的量测向量; 目标集 Target: 节点负荷电流真值。

训练主要分为两步: 1) 使用训练集 A 训练, 学习量测量与状态值之间正确的关系; 2) 使用训练集 B 训练, 学习在含有误差时量测量与状态量的关系。

## 3 实验结果及分析

### 3.1 算例生成及测试平台

#### 3.1.1 电网运行状态模拟及历史数据运行生成

本文使用 IEEE33 节点算例和 IEEE69 节点算例模拟网络分解后的子区域。使用常规潮流模拟电力系统运行变化<sup>[2]</sup>, 在高峰负荷和低谷负荷之间截取了 21 种不同的网络负荷状态。通过潮流计算获得各子区域的历史数据; 以节点负荷电流值作为历史状态向量, 用于算法验证的标准以及神经网络训练的目标值。在 21 种网络状态中选取 11 种状态用于训练, 其余 10 种状态用于验证。

受网络通信和设备量测精度等因素影响, 量测值与数据真值相比会存在一定误差。本文根据文献[26]中的方法对网络历史数据施加了服从正态分布

的随机误差模拟量测值；对部分量测数据施加了 50%左右的误差，来模拟带有粗差的伪量测量。

### 3.1.2 测试平台

本文方法的实现基于 Python 语言编写，以 PC 机为计算平台，处理器为 Intel(R) Core(TM) i7-4790 CPU@3.60GHz，8 GB 内存。

## 3.2 神经网络训练结果及分析

### 3.2.1 验证集估计结果

对验证集数据进行状态估计计算并与状态向量真实值比较得到误差值。首先将各数据误差取绝对值后计算平均误差，之后将估计误差与输入误差进行显著性分析。验证集估计效果图如图 5、图 6 所示。

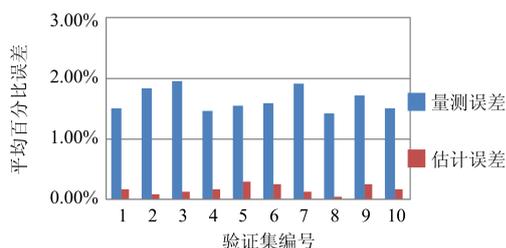


图 5 IEEE33 节点系统估计结果

Fig. 5 IEEE33 system estimation result

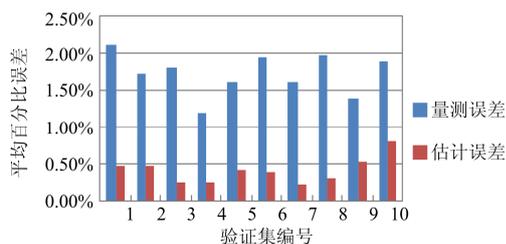


图 6 IEEE69 节点系统估计结果

Fig. 6 IEEE69 system estimation result

从图 5、图 6 中可以发现，验证集量测数据在未经训练的情况下，估计结果精度得到了很大的提升，体现了神经网络良好的泛化能力。分别对各验证集的估计误差和量测误差进行显著性分析，各验证集分析结果  $F$  值(组间均方和组内均方的比值)的实际值均大于查表值 10 倍以上， $p$  值(概率值)均小于  $10^{-4}$ 。通过均值比较和显著性比较说明，估计误差和量测误差相比有了非常显著的下降。

### 3.2.2 与现有智能算法的对比

以 IEEE33 节点系统为例，使用文献[22]中使用的 PCA 降维的方式，选取降维后包含 99%信息的数据作为输入训练神经网络。进行比较的还有使用高斯权重初始化的神经网络方法。训练时间对比见表 2，验证集估计结果见图 7。

由表 2 可知，使用本文权重初始化方法比传统方法训练精度提高了 47.1%；虽然比 PCA 降维简化后的网络训练时间长，但循环遍数少、训练精度提

高了 23.4%。

表 2 训练对比表  
Table 2 Comparison of training results

	训练循环遍数	训练时间	训练精度(MSE)
高司初始化算法	2 500	6 mm12 s	6.56E-06
本文算法	2 500	6 mm1 s	3.47E-06
PCA 降维算法	6 500	1 mm13 s	4.53E-06

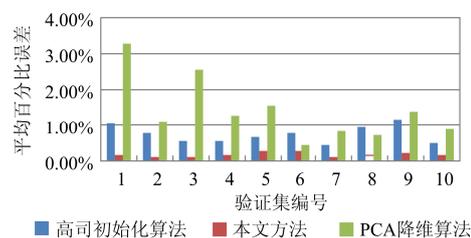


图 7 智能算法估计结果对比

Fig. 7 Estimation results comparison of the intelligent algorithms

由图 7 可知，本文方法比其余两种算法的平均估计精度要高。对误差结果进行显著性分析，各验证集分析结果的  $F$  实际值均大于查表值的 200%、 $p$  值均小于 0.01，满足差异非常显著的条件。因此本文算法估计结果优于使用了 PCA 降维方法的智能算法。

### 3.2.3 鲁棒性测试

为模拟量测系统偶发性的错误，本文在每个验证集的正常量测数据(原误差 2%左右，均为 PCA 主要成分)中随机选择一个数据，并施加 20%的误差。表 3 中记录了 WLS 算法、文献[22]算法和本文算法的估计结果。由表 3 可知，基于 WLS 算法<sup>[26]</sup>的估计误差与输入误差基本相同，本文算法估计结果比其精度提高了 82%以上；本文算法与文献[22]算法相比，更充分地利用系统中的量测信息，状态估计精度提高了 56%以上。

表 3 鲁棒性测试误差表

Table 3 Robustness testing results table

验证集编号	错误量测编号	WLS 算法	文献算法	本文算法
1	13	20.528%	5.467%	1.078%
2	5	20.791%	6.812%	1.202%
3	16	20.372%	5.462%	0.612%
4	32	19.795%	4.968%	0.103%
5	23	19.501%	5.168%	0.280%
6	15	20.844%	6.792%	0.402%
7	8	19.985%	6.489%	2.799%
8	29	20.224%	11.752%	3.262%
9	15	20.148%	7.532%	2.066%
10	6	20.916%	6.596%	0.692%

## 3.3 大规模网络算例测试与分析

### 3.3.1 算例构成

本文中使用了由 320 个 IEEE33 节点系统和 180

个 IEEE69 节点系统组成大规模网络。该网络中有 5 座 220/110/35 kV 变电站, 16 座 110/35/10 kV 变电站, 6 座 110/10 kV 变电站和 29 座 35 kV 变电站。以 220 kV 变电站为供电片区的划分依据, 将该网络划分为 5 个区域如表 4 所示。

表 4 电网区域信息表

Table 4 Power grid area information table

区域编号	变电站个数				10 kV 子区域数
	220/110/35	110/35/10	110/10	35/10	
I	1	3	1	7	106
II	1	3	2	5	102
III	1	4	1	6	105
IV	1	3	1	6	94
V	1	3	1	5	93
总计	5	16	6	29	500

### 3.3.2 大规模网络状态估计步骤

如图 8 所示, 状态估计分为如下几步:

- (1) 将量测数据按子区域划分;
- (2) 将量测数据预处理;
- (3) 根据子区域信息调用权重集;
- (4) 前向计算状态估计;
- (5) 重复前四步直到所有子区域计算完成。

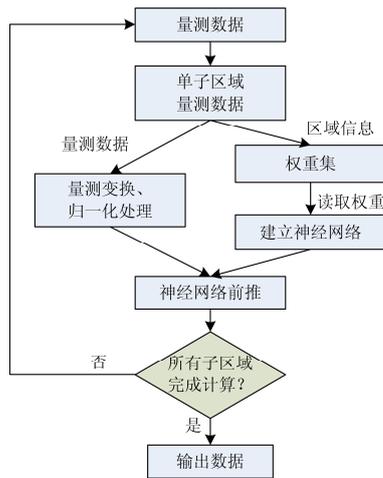


图 8 大规模网络状态估计流程图

Fig. 8 State estimation flow chart of large scale network

### 3.3.3 计算时间对比

为比较计算时间, 本文还在实验环节实现了基于文献[26]的单机状态估计算法。如表 5 所示, 本文算法相较于串行算法速度提升了约 205 倍。

表 5 计算时间对比表

Table 5 Comparison of computation time

算法名称	计算时间
传统串行算法	23 min 53 s
本文算法	7 s

## 4 结语

本文基于神经网络设计了一种面向大规模网络的高能效状态估计方法。首先, 根据网络中各子区域的量测配置, 离线建立并训练神经网络, 形成权重集; 在进行状态估计计算时, 根据子区域信息调用权重, 进行前向计算完成状态估计算法。其主要优势与创新点如下:

(1) 根据子区域量测配置建立的神经网络, 能够合理利用量测冗余信息, 增强状态估计的鲁棒性。

(2) 提出了一种新的神经网络权重初始化方法。该方法根据量测信息的相邻关系对权重赋初值, 能够合理利用正常量测量与伪量测量, 加快了神经网络训练速度, 提高了估计精度。

(3) 使用神经网络前向计算替换迭代计算, 大大加快各子区域的估计速度, 使单机情况下仍可以对大规模网络快速进行估计。

## 参考文献

- [1] 王韶, 江卓翰. 基于奇异值分解和等效电流量测变换的电力系统状态估计[J]. 电力系统保护与控制, 2012, 40(12): 111-115.  
WANG Shao, JIANG Zhuohan. Power system state estimation based on singular value decomposition and equivalent current measurement transformation[J]. Power System Protection and Control, 2012, 40(12): 111-115.
- [2] 于尔铿. 电力系统状态估计[M]. 北京: 水利电力出版社, 1985.
- [3] 孟建良, 刘德超. 一种基于 Spark 和聚类分析的辨识电力系统不良数据新方法[J]. 电力系统保护与控制, 2016, 44(3): 85-91.  
MENG Jianliang, LIU Dechao. A new method for identifying bad data of power system based on Spark and clustering analysis[J]. Power System Protection and Control, 2016, 44(3): 85-91.
- [4] 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, 82.  
HUANG Manyun, SUN Guoqiang, WEI Zhinong, et al. Three-phase state estimation in distribution systems based on pseudo measurement modeling using spiking neural network[J]. Automation of Electric Power Systems, 2016, 40(16): 38-43, 82.
- [5] 黄知超, 谢霞, 王斌. 结合模糊综合评判与决策的电力系统状态估计[J]. 电力系统保护与控制, 2015, 43(7): 65-69.  
HUANG Zhichao, XIE Xia, WANG Bin. Power system state estimation combined with fuzzy comprehensive evaluation and decision-making[J]. Power System Protection and Control, 2015, 43(7): 65-69.
- [6] 胡春潮, 何杰, 马凯. 基于信息冗余的电力系统分布式状态估计[J]. 电力系统保护与控制, 2017, 45(16): 111-115.

- HU Chunchao, HE Jie, MA Kai. Power system distributed state estimation based on information redundancy of secondary system[J]. Power System Protection and Control, 2017, 45(16): 111-115.
- [7] 李江, 王义伟, 魏超, 等. 卡尔曼滤波理论在电力系统中的应用综述[J]. 电力系统保护与控制, 2014, 42(6): 135-144.
- LI Jiang, WANG Yiwei, WEI Chao, et al. A survey on the application of Kalman filtering method in power system[J]. Power System Protection and Control, 2014, 42(6): 135-144.
- [8] 周治国, 王毅, 张华良. 高频采样下基于 DFT 的配电网相量测量算法研究[J]. 电力系统保护与控制, 2017, 45(19): 101-108.
- ZHOU Zhiguo, WANG Yi, ZHANG Hualiang. Research on phasor measurement algorithm of distribution network based on DFT under high frequency sampling[J]. Power System Protection and Control, 2017, 45(19): 101-108.
- [9] BORKAR S, CHIEN A A. The future of microprocessors[J]. Communications of the ACM, 2011, 54(5): 67-77.
- [10] ESMAEILZADEH H, BLEM E, ST AMANT R, et al. Dark silicon and the end of multicore scaling[C] // 2011 38th Annual International Symposium on Computer Architecture (ISCA), June 4-8, 2011, San Jose, USA: 365-376.
- [11] KARIMIPOUR H, DINAHAHI V. Parallel domain-decomposition-based distributed state estimation for large-scale power systems[J]. IEEE Transactions on Industry Applications, 2016, 52(2): 1265-1269.
- [12] JEONG H M, LEE H S, PARK J H. Application of parallel particle swarm optimization on power system state estimation[C] // 2009 Transmission & Distribution Conference & Exposition: Asia and Pacific, October 26-30, 2009, Seoul, South Korea: 1-4.
- [13] KARIMIPOUR H, DINAHAHI V. Extended Kalman filter-based parallel dynamic state estimation[J]. IEEE Transactions on Smart Grid, 2015, 6(3): 1539-1549.
- [14] 黄伟, 庞琳, 曹彬, 等. 基于分区解耦的配电网状态估计的分布式并行计算[J]. 电力系统保护与控制, 2014, 42(15): 45-51.
- HUANG Wei, PANG Lin, CAO Bin, et al. Parallel and distributed computing for an area-decoupled state estimation method for distribution systems[J]. Power System Protection and Control, 2014, 42(15): 45-51.
- [15] 吴杰, 卢志刚, 杨斌, 等. 基于改进并行遗传算法的电网状态估计[J]. 电网技术, 2006, 30(18): 64-68.
- WU Jie, LU Zhigang, YANG Bin, et al. Dynamic state estimation for power system based on an adaptive unscented Kalman filter[J]. Power System Technology, 2006, 30(18): 64-68.
- [16] MITTAL S. Power management techniques for data centers: a survey[J]. IEEE Systems Journal, 2017, 11(2): 772-783.
- [17] MITTAL S. A survey of techniques for approximate computing[J]. ACM Computing Surveys (CSUR), 2016, 48(4): 62.
- [18] ELDRIDGE S, RAUDIES F, ZOU D, et al. Neural network-based accelerators for transcendental function approximation[C] // Proceedings of the 24th Edition of the Great Lakes Symposium on VLSI, ACM, 2014: 169-174.
- [19] ESMAEILZADEH H, SAMPSON A, CEZE L, et al. Neural acceleration for general-purpose approximate programs[C] // Proceedings of the 2012 45th Annual IEEE/ACM International Symposium on Microarchitecture. IEEE Computer Society, 2012: 449-460.
- [20] SINGH S K, SHARMA J. A Hopfield neural network based approach for state estimation of power systems embedded with FACTS devices[C] // 2006 Power India Conference, April 10-12, 2006, New Delhi, India: 7 pp.
- [21] ONWUACHUMBA A, WU Y, MUSAVI M. Reduced model for power system state estimation using artificial neural networks[C] // 2013 IEEE Green Technologies Conference, April 4-5, 2013, Denver, USA: 407-413.
- [22] ONWUACHUMBA A, MUSAVI M. New reduced model approach for power system state estimation using artificial neural networks and principal component analysis[C] // 2014 IEEE Electrical Power and Energy Conference (EPEC), Calgary, Canada: 15-20.
- [23] QIANG X, CHENG G, WANG Z. An overview of some classical growing neural networks and new developments[C] // 2010 2nd International Conference on Education Technology and Computer (ICETC), June 22-24, 2010, Shanghai, China: V3-351-V3-355.
- [24] 焦李成. 神经网络系统理论[M]. 西安: 西安电子科技大学出版社, 1990.
- [25] 马健, 唐巍, 徐升, 等. 基于多准则分区和 WLS-PDIPM 算法的有源配电网状态估计[J]. 电力系统自动化, 2016, 40(12): 28-36.
- MA Jian, TANG Wei, XU Sheng, et al. Dynamic state estimation for power system based on an adaptive unscented Kalman filter[J]. Automation of Electric Power Systems, 2016, 40(12): 28-36.
- [26] 李慧. 配电系统负荷数据处理方法的研究[D]. 北京: 中国农业大学, 2005.

收稿日期: 2017-10-24; 修回日期: 2017-12-12

作者简介:

赵巍岳(1992—), 男, 硕士研究生, 主要研究领域为电力系统仿真、大数据分析处理、智能电网状态估计; E-mail: SVA2049@163.com

靳松(1977—), 男, 通信作者, 副教授, 硕士生导师, 主要研究领域为分布式计算、电力大数据分析处理; E-mail: jinsong@ncepu.edu.cn

吕天成(1991—), 男, 硕士研究生, 主要研究领域为电力系统局部放电信号诊断、分析与处理。E-mail: ltc233@163.com

(编辑 张爱琴)