

# 基于BP神经网络群的中压配电网电压降落估算

白牧可, 唐巍, 张璐, 丛鹏伟

(中国农业大学信息与电气工程学院, 北京 100083)

**摘要:** 对影响农村中压电网电压降落的因素进行了分析, 利用神经网络具有自学习、联想记忆功能以及逼近任意非线性映射的能力, 提出了基于BP神经网络群的中压电网电压降落估算方法。为解决由于样本多、分类空间复杂而易导致网络不容易收敛的问题, 采用分层的BP网络群结构, 将样本分类, 由各BP子网进行单类样本训练, 完成对样本的并行训练及测试。该方法依据电压降落影响因素及实际电网结构参数, 确定神经网络输入输出特征量; 按照线路负荷分布类型将样本分类, 减小了BP网络训练复杂度; 根据样本误差和误差变化调整学习率和冲量因子, 提高了BP网络学习效率。实际算例结果验证了所提出方法的有效性和可行性。

**关键词:** 电压降落; 农村中压电网; 神经网络群; BP算法改进; 估算方法

## Estimation of voltage drop of middle voltage distribution network based on BP neural network group

BAI Mu-ke, TANG Wei, ZHANG Lu, CONG Peng-wei

(College of Information and Electrical Engineering, China Agriculture University, Beijing 100083, China)

**Abstract:** The paper analyzes the factors influencing the voltage drop of the rural middle-voltage power network. Considering the self-learning ability, associative memory and approximating nonlinear mapping of neural network, a new method to estimate voltage drop of middle voltage distribution network is proposed based on BP neural network group. As the large number of sample data of voltage estimation and the complexity of classification are easy to lead to difficult network convergence, the BP network group structure is proposed. According to the specific requirements, samples are classified and input to each BP subnet to complete the single training as well as parallel training and tests. According to impact factors of the voltage drop and the actual parameters of distribution network, the neural network input and output characteristics are identified. The samples are classified according to the load distribution type, thus the complexity of BP network training is reduced and the training efficiency is improved. The simulation results of actual examples show that the proposed method is effective and feasible for estimation of voltage drop.

**Key words:** voltage drop; rural middle-voltage power network; neural network group; improved algorithm of BP; estimation method

中图分类号: TM76 文献标识码: A 文章编号: 1674-3415(2014)02-0132-07

## 0 引言

近年来, 随着“新农村建设”、“城镇化建设”步伐的加快以及“家电下乡”政策的实施, 农村经济呈多元化发展, 农村电力负荷快速增长, 部分农村地区在用电高峰时段出现电压偏低问题, 已很难满足农村地区生产生活用电需要; 由于农村外务农民较多, 春节期间大量农民返乡, 春节用电剧增, 使电压偏低现象呈现季节性特点; 同时, 乡村居住点不断延伸, 农村负荷中心不断偏移, 农村山区线路供电半径偏长, 进一步加剧了低电压现象。2009

年, 农村低电压问题投诉达到了10.9万次; 国家电网管辖范围内, 低电压已经给23.12%的行政村、6.69%的农村居民户、8.38%的农村供电人口带来了诸多不便。低电压问题已经严重影响广大农村地区的优质可靠供电, 亟待解决。为了解决低电压问题需对低电压现象做出判断并采取相应措施, 快速做出低电压估算, 并采取相应措施将电压控制在标准范围之内<sup>[1-2]</sup>。

当电网结构、参数及运行数据已知, 通过潮流计算<sup>[3-4]</sup>可以获得电压降落的准确结果。但农村电网量测有限, 配变未装量测装置, 只知线路首端数据, 无法进行潮流计算获得准确的电压降落。在此情况下, 通过估算获得满足计算需求的电压降落是可行

基金项目: 国家电网公司科技项目 (ND71-11-007)

方法。目前介绍配电网线损估算的文章<sup>[5-6]</sup>较多, 但对电压降落估算的研究较少, 文献[7]基于电压损失系数表提出了在各种典型负荷分布情况下对馈线低电压问题的快速判断法, 但未考虑到中压分支线的电压降落, 由于实际线路中存在许多大分支线路, 其造成的电压降落是不容忽视的; 文献[8]基于架空线路和电缆线路的电压损耗分析构造了混合馈线最大电压损耗的非线性估算模型, 并运用 Gauss-Raphson 方法给出了估算模型中参数的求解方法, 但未考虑配变造成的电压降落以及负荷分布对电压降落的影响。

本文对影响农村电网电压降落的因素进行了分析, 综合考虑多方面影响因素, 根据变电站提供的运行数据以及电网结构参数及神经网络具有自学习能力、联想存储功能、高速寻找优化解的能力, 提出基于神经网络群的电压降落估算方法, 为农村中压电网电压降落估算提供了有效方法。

## 1 农村中压电网近似电压降落

中压电网电压降落包括中压线路电压降落和配电变压器电压降落。由于配电变压器位于中压电网的末端, 故由线路首端节点至任一配电变压器副方节点的电压降落为两节点之间各段线路电压降落之和加上该配电变压器电压降落。对于图 1 所示中压电网, 线路首端 A 点到最远端 G 点的电压降落。包括线路电压降落 ( $U_A-U_F$ ) 和配电变压器电压降落 ( $U_F-U_G$ )。

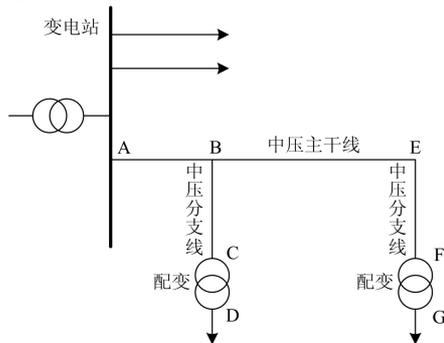


图 1 中压配电网结构

Fig. 1 Medium voltage distribution network structure

### 1.1 架空线路电压降落理论推导

由于农村地区中低压线路以架空线路为主, 故本文主要以架空线路为模型进行分析。中压架空线路的电压等级不高, 其对地电容和电晕损耗可忽略<sup>[9]</sup>。因此, 架空线路通常用一个串联阻抗电路来等值, 如图 2 所示。

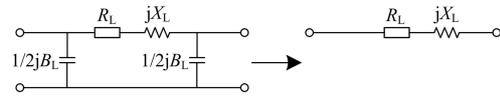


图 2 电力线路等值电路

Fig. 2 Equivalent circuit for a 10 kV overhead line

架空线电压降落包含纵分量和横分量, 由架空线电压降落理论推导可知, 横分量可忽略不计, 架空线电压降落可由其纵分量近似表示。

假设负荷集中分布于馈线末端, 线路阻抗为  $R+jX$ , 末端负荷功率为  $S=P+jQ$ , 则架空线路电压降落为

$$\Delta U = \frac{PR+QX}{U_N} = \frac{PL(R_0 + \tan \varphi X_0)}{U_N} = \frac{M(R_0 + \tan \varphi X_0)}{U_N} \quad (1)$$

式中:  $P$  为线路末端负荷功率;  $L$  为线路长度;  $PL$  为负荷矩  $M$ ;  $R_0$  和  $X_0$  为架空线路单位长度电阻、电抗, 一般情况下认为  $R_0$  和  $X_0$  与线路型号有关;  $\varphi$  为功率因数角;  $U_N$  为额定电压。

### 1.2 配电变压器电压降落理论推导

中压配电变压器的等值电路如图 3 所示。  $R_T$ 、 $X_T$  为变压器的电阻和电抗;  $G_T$ 、 $B_T$  为变压器的电导和电纳。当变压器运行电压与其额定电压接近时, 激磁支路可用其对应的功率损耗表示。

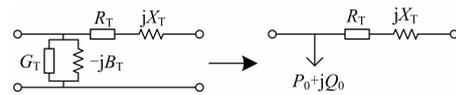


图 3 配电变压器等值电路

Fig. 3 Equivalent circuit for distribution transformer

设变压器副方电压为  $\dot{U}_{T2} < 0^\circ$ , 原方电压为  $\dot{U}_{T1}$ , 负荷端功率为  $S=P+jQ$ , 则配变电压降落为

$$\Delta U_T = U_{T1} - U_{T2} = \frac{PR_T + QX_T}{U_{T2}} = \frac{P(R_T + \tan \varphi X_T)}{U_{T2}} \quad (2)$$

若已知配电变压器的型号、负荷及负荷功率因数, 则可得到  $\Delta U_T$ 。

## 2 中压配电网电压降落影响因素分析

### 2.1 架空线路电压降落影响因素分析

(1) 功率、线路长度、负荷矩

由式(1)可知, 线路电压降落与功率、线路长度成正比, 亦即是线路电压降落与负荷矩成正比。

(2) 导线型号、负荷功率因数

由式(1)可得,  $A=R_0+\tan\varphi X_0$ ,  $R_0$  与  $X_0$  取值均取决于线路型号, 架空线电阻计算公式为  $R_0=\rho/S$ , 其中  $\rho$  为导线材料的电阻率( $\Omega\cdot\text{mm}^2/\text{km}$ ),  $S$  为导线

的额定截面积 (mm<sup>2</sup>)。架空线电抗一般都在 0.4 Ω/km 左右, 故取  $X_0$  为 0.4 Ω/km。

当负荷功率因数范围为 0.8~0.98 时,  $\tan\varphi$  的取值范围为 0.75~0.2, 又由于  $X_0$  取值为 0.4, 因此可知, 负荷功率因数对  $A$  影响较小, 进而得出负荷功率因数对线路电压降落影响较小。同时亦可得到,  $A$  的取值主要取决于导线型号, 故导线型号对线路电压降落有较大影响。

(3) 负荷分布

由文献[7]可知, 负荷分布对电压降落有重要影响, 引入分布系数  $F$ , 可得电压降落公式为

$$\Delta U = \frac{FPL(R_0 + \tan\varphi X_0)}{U_N} = \frac{FMA}{U_N} \quad (3)$$

限于篇幅, 此处不做推导, 负荷分布对电压降落影响如表 1 所示。

表 1 分布系数表

Table 1 Distribution coefficient of load	
负荷分布情况	分布系数 $F$
末端集中	1
均匀分布	1/2
均增分布	2/3
均减分布	1/3
先均增后均减分布	$(n+1)/3$
先均减后均增分布	$(2-n)/3$

注:  $n$  表示渐增分布与渐减分布的分界位置系数,  $n$  取值范围为 [0, 1]。

由上述讨论可知, 架空线路电压降主要的影响因素有功率、线路长度、负荷矩以及导线型号。

2.2 配电变压器电压降落影响因素分析

(1) 负荷功率

由式(2)可知, 电压降落与负荷功率成正比。

(2) 配变型号、负荷功率因数

$R_T$  与  $X_T$  取值均取决于配变型号, 且一般情况下  $X_T$  大于  $2R_T$ , 最多时  $X_T$  可大于  $5R_T$ 。

当负荷功率因数范围为 0.8~0.98 时,  $\tan\varphi$  的取值范围为 0.75~0.2。令  $A_T=R_T+\tan\varphi X_T$ , 由于  $X_T$  比  $R_T$  大许多, 故负荷功率因数对  $A_T$  影响较大, 同时, 配变型号亦对  $A_T$  有较大影响。

由上述讨论可知, 配变电压降主要的影响因素有负荷功率、配变型号以及负荷功率因数。

3 BP 网络在中压配电网电压降落估算中的应用

3.1 BP 网络群结构

BP 神经网络在许多文献中都有过详细介绍<sup>[10-12]</sup>,

本文不做详细叙述。

针对电压估算样本数据比较多, 分类空间复杂, 容易导致网络不容易收敛的情况, 因此本文提出 BP 网络群结构, 如图 4 所示, 网络群减少了每个子网络的输入数量, 从而加快了网络的收敛速度。

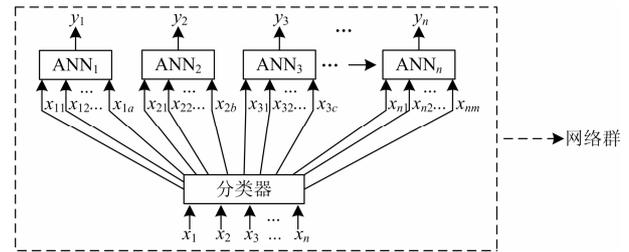


图 4 BP 网络群结构

Fig. 4 BP network group structure

BP 神经网络群结构由一个样本分类器和若干 BP 子网组成。样本分类器能够减少各 BP 子网的训练样本和拟合复杂度, 提高训练速度和学习精度。由于负荷分布对电压降落有较大的影响, 故本文在神经网络前加入分类器, 根据负荷分布的不同, 将样本  $x_1, x_2, \dots, x_n$  分类, 其中用 1~5 来分别表示负荷的均匀分布、均增分布、均减分布、先均增后均减分布及先均减后均增分布, 以便对样本进行分类。样本分类后输入各 BP 子网, 由各 BP 子网完成训练。图 4 中,  $ANN_1, \dots, ANN_n$  为网络群的 BP 子网。 $x_{ij}$  为第  $i$  个 BP 子网  $ANN_i$  的输入 (其中,  $i=1, 2, \dots, n$ ),  $y_i$  为  $ANN_i$  的网络输出。

BP 神经子网络结构图如图 5 所示, 包含输入层、隐层及输出层三层结构。输入层神经元与中压电网电压降落的影响因素对应, 包含架空线路电压降落影响因素和配电变压器电压降落影响因素; 输出层神经元与电压降落相对应。

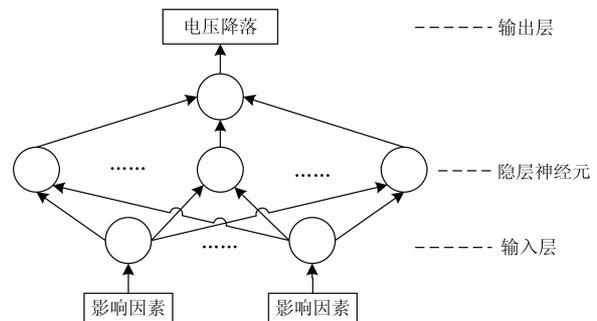


图 5 BP 神经子网络结构图

Fig. 5 BP sub-network structure

对于每一个 BP 子网, 完成相应样本子集的训

练, 若 BP 子网单独训练, 则总训练时间为各 BP 子网训练时间之和; 若 BP 子网并行训练, 考虑到各子网样本数量相近, 则各子网的训练时间相差较少, 故总训练时间约为单个 BP 子网的训练时间, 因此 BP 网络群可采用并行运行, 从而大大缩减训练时间。

### 3.2 BP 网络算法改进

由于 BP 算法<sup>[13-15]</sup>存在着缺点: 第一, 有很多局部极小点。第二, 存在平坦区, 在平坦区内误差变化很小, 多发生在神经元输出接近于 0 或 1 的情况下; 平坦区的位置范围各不相同, 有时误差曲面上会出现一些阶梯。第三, 在某些初始值条件下, 算法会陷入局部极小而不收敛。本文对 BP 网络算法进行改进。

由三层或是  $N$  层 BP 网络组成的多维空间中, 总体误差函数  $E$  将具有一个及其复杂形状的曲面, 即 BP 网络误差曲面。由于常规的 BP 算法存在着上述的缺点, 根据对 BP 网络误差曲面的分析, 提出动态误差函数 BP 算法, 它根据样本误差的大小, 时刻调整该样本误差在样本总体误差中所占的比重, 并时刻调整该样本的学习率和冲量因子。

引入加权因子  $\alpha_p$  修正样本总体误差函数为

$$E = \sum_{p=1}^m \alpha_p E_p = \frac{1}{2} \sum_{p=1}^m \alpha_p \sum_{j=1}^{l_m} (d_j^p - Y_i^p)^2 \quad (4)$$

$$\eta_p = \eta \alpha_p, \quad \beta_p = \beta \alpha_p \quad (5)$$

则可以得到  $t$  时刻权值修正量为

$$\Delta w_{ij}^{k,k+1}(t) = \sum_{p=1}^m \eta_p \left( -\frac{\partial E}{\partial w_{ij}^{k,k+1}} \right)(t) + \beta_p \Delta w_{ij}^{k,k+1}(t-1) \quad (6)$$

式中: 设总样本数为  $nt$ ;  $E_p$  为第  $p$  个样本误差函数;  $\eta_p$  和  $\beta_p$  分别为第  $p$  个样本的学习率和调整因子。

在学习过程中, 根据  $E_p$  的大小不断调整  $\alpha_p$ ,  $E_p$  越大,  $\alpha_p$  越大, 对样本  $p$  的重视程度越大;  $E_p$  越小,  $\alpha_p$  越小, 对样本  $p$  的重视程度越小。由式

(6) 知,  $\alpha_p$  的动态调整, 反映到权值修正上, 相当于动态调整  $\eta_p$  和  $\beta_p$ , 即  $\eta_p = \eta \alpha_p$ ,  $\beta_p = \beta \alpha_p$ 。

设  $E_p$  的最大值、最小值为  $E_{p\max}$  和  $E_{p\min}$ , 其算术中心为  $C_e$ ,  $C_e = \frac{E_{p\max} + E_{p\min}}{2}$ , 其覆盖宽度为

$$D_e, \quad D_e = E_{p\max} - E_{p\min}。$$

$$\eta_p = \eta_{p0} + \Delta \eta_p$$

$$\Delta \eta_p = C_\eta \cdot \text{int} \left[ \frac{E_p - C_e}{D_e / 2K_\eta} \right]$$

其中:  $C_\eta$  为正常数; int 为四舍五入取整运算。若

将  $E_p$  以  $C_e$  为中心分成  $2K_\eta$  类, 则  $\text{int} \left[ \frac{E_p - C_e}{D_e / 2K_\eta} \right]$  为

$E_p$  所属类别。若  $E_p \geq C_e$ , 则  $\Delta \eta_p \geq 0$ ; 若  $E_p \leq C_e$ , 则  $\Delta \eta_p \leq 0$ ;  $E_p$  越大,  $\eta_p$  越大。

若  $F_p = E_p(t) - E_p(t-1)$ , 设  $F_p$  的最大值、最小值为  $F_{p\max}$  和  $F_{p\min}$ , 其算术中心为  $C_f$ ,

$$C_f = \frac{F_{p\max} + F_{p\min}}{2}, \quad \text{其覆盖宽度为 } D_f,$$

$$D_f = F_{p\max} - F_{p\min}。$$

若  $F_p = E_p(t) - E_p(t-1)$ , 设  $F_p$  的最大值、最小值为  $F_{p\max}$  和  $F_{p\min}$ , 其算术中心为  $C_f$ ,

$$C_f = \frac{F_{p\max} + F_{p\min}}{2}, \quad \text{其覆盖宽度为 } D_f,$$

$$D_f = F_{p\max} - F_{p\min}。$$

$$\beta_p = \beta_{p0} + \Delta \beta_p$$

$$\Delta \beta_p = C_\beta \cdot \text{int} \left[ \frac{F_p - C_f}{D_f / 2K_\beta} \right]$$

其中:  $C_\beta$  为正常数; int 为四舍五入取整运算。若

将  $F_p$  以  $C_f$  为中心分成  $2K_\beta$  类, 则  $\text{int} \left[ \frac{F_p - C_f}{D_f / 2K_\beta} \right]$  为

$F_p$  所属类别。若  $F_p \geq C_f$ , 则  $\Delta \beta_p \geq 0$ ; 若  $F_p \leq C_f$ , 则  $\Delta \beta_p \leq 0$ ;  $F_p$  越大,  $\beta_p$  越大。

### 3.3 样本特征量选取

结合能够得到的运行数据以及实际农村中压电网结构参数, 确定 BP 网络输入 13 个特征量: 线路总功率, 型号为 LGJ-240、LGJ-185、LGJ-150、LGJ-120、LGJ-95、LGJ-70、LGJ-50、LGJ-35 的 8 种架空线各自的长度, S7、S9、S11 三个系列配变各自的总容量以及负荷分布类型。BP 网络输出特征量是中压电网电压降落。通过 BP 子网络训练形成中压电网电压降落与 13 个特征量的非线性映射关系。

样本输入输出特征量没有统一的量纲, 因此要对初始数据进行量化和归一化的处理, 使输入限制在  $(-1, 1)$  之间。

### 3.4 神经网络赋初值及网络参数确定

由于系统是非线性的, 初始值对于学习是否达

到局部最小、是否能够收敛以及收敛时间的长短的关系很大。如果初始权值太大，使得加权后的输入落在了 S 性激活函数的饱和区，使得网络在训练调节中几乎停顿。因此一般取初始权值在 (-1, 1) 之间的随机数。实践证明：三层 BP 神经网络能够模拟任意输入和输出之间的非线性映射关系。因此本文也采用只有一个隐层的拓扑网络结构。对于如何选择 BP 网络隐含层的数目，目前还没有准确的理论和方法，根据本文输入输出特征量及样本数量，

经测试隐含层神经元数目取 15~20 个为佳。

## 4 仿真算例

### 4.1 样本形成

本文采用某省农村中压电网数据为样本数据，随机抽取 80 条中压线路的负荷峰、平、谷三种时段和 7 个随机时段的运行状态作为样本，其中训练样本为 700 个，测试样本为 100 个。部分典型样本表 2。

表 2 部分典型样本  
Table 2 Some typical samples

样本序号	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
电压降落/kV	0.52	0.77	0.60	0.69	0.88	0.70	0.36	0.45	0.90	0.83	0.98	0.56	0.60	0.53	0.66	0.53	1.17	0.90
线路功率/kW	1545	5780	3164	3449	2890	6660	3449	2060	5274	6936	3449	4139	4624	8658	3468	4747	5202	6647
LGJ-240 长度/km	2.72	1.20	9.86	0.58	0.00	0.80	0.58	0.00	5.46	0.00	4.37	1.24	0.00	0.68	11.43	1.91	2.97	0.00
LGJ-185 长度/km	3.92	4.67	0.00	2.11	0.61	0.91	2.11	2.91	2.95	2.61	14.34	0.00	0.00	0.45	0.00	1.03	7.56	0.00
LGJ-150 长度/km	2.78	3.23	0.00	0.87	12.20	0.00	0.00	3.97	5.38	6.81	0.00	1.46	0.00	0.57	0.00	1.88	5.67	3.30
LGJ-120 长度/km	0.00	0.00	0.00	0.00	0.00	0.00	0.87	2.81	0.00	2.72	4.08	0.87	4.76	1.58	0.00	0.00	0.00	2.92
LGJ-95 长度/km	28.12	3.30	70.23	10.72	0.00	0.00	7.34	21.60	15.78	11.26	5.57	14.57	0.00	2.53	21.77	5.52	6.39	0.00
LGJ-70 长度/km	9.30	10.28	0.00	19.15	0.00	1.58	14.57	4.42	19.77	5.32	6.92	0.00	0.00	3.19	0.00	6.92	16.10	4.64
LGJ-50 长度/km	0.00	0.00	0.00	2.93	8.01	2.53	0.00	36.74	0.00	5.48	0.00	2.93	9.07	0.00	0.00	0.00	0.00	6.02
LGJ-35 长度/km	20.92	4.69	0.00	0.00	6.92	3.19	10.89	0.00	42.53	0.00	6.13	15.29	0.00	0.00	0.00	14.89	8.35	0.00
S7 配变容量/kVA	0	50	0	0	30	1140	350	263	395	185	0	0	30	935	788	0	30	483
S9 配变容量/kVA	3453	6448	6501	3095	5123	6355	2745	4440	6501	12015	2485	5790	8103	10210	5988	6501	9140	11565
S11 配变容量/kVA	315	1105	480	110	1000	980	110	430	480	2510	720	210	1600	6395	1260	480	1700	2260
负荷分布	1	1	1	2	2	2	3	3	3	3	4	4	4	4	5	5	5	5

### 4.2 样本训练

训练误差要求为  $10^{-3}$ ，设置输入层、隐含层、输出层神经元数目分别为 13、20 和 1，训练算法采用 BP 算法，激活函数采用 tansig 函数。经过训练得到相应的神经网络权值，其中包括一个 13×20 的输入层到隐含层的权值矩阵；一个 20×1 的隐含层到输出层的权值矩阵；一个 1×20 隐含层的阈值矩

阵；一个 1×1 输出层的阈值矩阵。限于篇幅，这里不予列出。

在给定训练精度为  $10^{-3}$  时，普通的 BP 网络训练迭代 4225 次收敛，而采用本文改进 BP 算法迭代 2696 次即收敛，收敛速度提高了 36.19%，如图 6 所示。

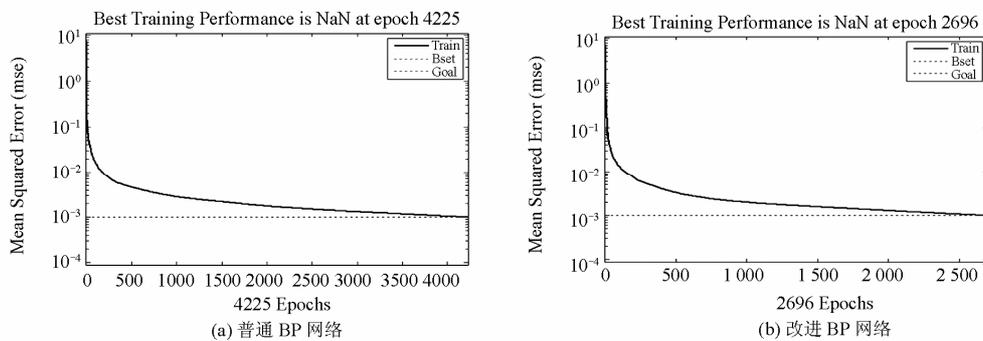


图 6 BP 网络训练收敛图

Fig. 6 BP network training convergence results

以均匀分布负荷分布的 BP 子网络为例, 经过样本训练, 结果显示训练相对误差最大值不超过 5%, 主要分布在(0%, 3%]-之间, 训练样本误差情况如表 3 所示。

表 3 训练样本相对误差

Table 3 Relative error of training samples

训练相对误差/%	<1	1~3	3~4	4~5
样本所占比例/%	43.15	45.69	8.63	2.53

### 4.3 测试结果

表 4 给出随机抽取的 24 个测试样本结果。

由表 4 可知, 利用已经训练完成的网络对其余的样本进行测试, 结果显示测试相对误差在 0.01%~4.76%的范围内, 最大值不超过 5%, 主要分布在(1%, 3%]-之间。估算效果好, 因此大部分测试样本均可以满足精度要求。测试样本误差情况如表 5 所示。

表 4 实际与预测电压降落及相对误差

Table 4 Actual and predictive voltage drop and relative error

样本 序号	实际	预测	测试 相对 误差	样本 序号	实际	预测	测试 相对 误差
	电压 降落 /kV	电压 降落 /kV			电压 降落 /kV	电压 降落 /kV	
1	0.755	0.750	0.65	13	0.585	0.600	2.54
2	1.234	1.209	1.99	14	0.493	0.494	0.30
3	0.706	0.726	2.79	15	1.122	1.134	1.07
4	1.742	1.742	0.01	16	0.951	0.957	0.69
5	0.388	0.369	4.76	17	0.718	0.724	0.92
6	0.583	0.605	3.80	18	1.735	1.681	3.10
7	1.184	1.207	1.87	19	0.861	0.839	2.61
8	0.454	0.461	1.65	20	0.690	0.677	1.92
9	0.792	0.809	2.23	21	1.280	1.219	4.73
10	1.062	1.042	1.90	22	0.627	0.612	2.41
11	0.742	0.731	1.51	23	0.717	0.732	2.06
12	0.630	0.648	2.85	24	0.951	0.962	1.13

表 5 测试样本相对误差

Table 5 Relative error of testing samples

测试相对误差/%	<1	1~3	3~4	4~5
样本所占比例/%	20.84	62.50	8.33	8.33

由表 6 可知, 与普通 BP 神经网络方法相比, 基于神经网络群的改进 BP 神经网络方法的测试精度为 97.29%, 提高了 4.12%; 平均相对误差为 1.73%, 降低了 0.72%。基于神经网络群的改进 BP 神经网络方法大大提高了测试精度。

表 6 测试精度比较

Table 6 Comparison of forecasting accuracy

方法	测试精度/%	平均相对误差/%
基于神经网络群的 改进 BP 神经网络方法	97.29	1.73
普通 BP 神经网络方法	93.17	2.45

## 5 结论

本文通过对农村中压电网电压降落的影响因素分析, 确定了 BP 神经网络的输入输出特征量, 进而提出了基于 BP 神经网络群的农村中压电网电压降落估算方法, 算例仿真结果表明本文提出的 BP 神经网络群结构以及改进算法能够有效减少样本空间的复杂度, 提高学习效率和训练精度, 能够实现农村中压电网电压降落的快速、准确估算。本文方法为中压电网电压降落估算提供了一种新的思路, 对于线损估算等其他类似问题具有一定的参考价值。

## 参考文献

- [1] DL/T 5118-2000 农村电力网规划设计导则[S].
- [2] GB/T12325-2008 电能质量供电电压允许偏差[S].
- [3] 刘蔚, 宁文辉, 黄东山. 一种改进的辐射状配电网潮流计算方法[J]. 电力系统保护与控制, 2009, 37(15): 1-4.
- LIU Wei, NING Wen-hui, HUANG Dong-shan. A modified power flow calculation method for radial distribution system[J]. Power System Protection and Control, 2009, 37(15): 1-4.
- [4] XU Jing-zhou, CHEN Xiao. Forward/backward sweep method based on map structure for power flow calculation of distribution system[C] // 2010 China International Conference on Electricity Distribution. Haikou, China, 2010: 1-4.
- [5] Lasso H, Ascanio C, Guglia M. A model for calculating technical losses in the secondary energy distribution network[C] // Transmission & Distribution Conference and Exposition, Latin America, 2006: 1-6.
- [6] 袁慧梅, 郭喜庆, 于海波. 中压配电网线损计算新方法[J]. 电力系统自动化, 2002, 26(11): 50-53.
- YUAN Hui-mei, GUO Xi-qing, YU Hai-bo. New method for calculating energy losses in medium-voltage distribution systems[J]. Automation of Electric Power

- Systems, 2002, 26(11): 50-53.
- [7] 赵俊光, 王主丁, 乐欢. 中压配电网规划中馈线电气计算的估算方法[J]. 电力系统自动化, 2008, 32(16): 99-102.  
ZHAO Jun-guang, WANG Zhu-ding, YUE Huan. Estimation method for electrical calculation of feeders in middle voltage distribution network planning[J]. Automation of Electric Power Systems, 2008, 32(16): 99-102.
- [8] 周卓敏, 李湘华, 何禹清, 等. 架空和电缆混合馈线的电压损耗快速估算[J]. 电力系统保护与控制, 2010, 38(17): 169-173.  
ZHOU Zhuo-min, LI Xiang-hua, HE Yu-qing, et al. Fast estimation of voltage loss in feeders consisting of overhead line and power cable[J]. Power System Protection and Control, 2010, 38(17): 169-173.
- [9] 陈珩. 电力系统稳态分析[M]. 北京: 中国电力出版社, 2007.
- [10] 张明光, 李艳. 基于 BP 神经网络的下一交易日出清电价预测[J]. 电力系统保护与控制, 2009, 37(5): 18-21.  
ZHANG Ming-guang, LI Yan. Method for forecasting next-day market clearing prices based on BP neural network[J]. Power System Protection and Control, 2009, 37(5): 18-21.
- [11] 李勇, 王建君, 曹丽华. 基于 BP 神经网络的火电厂实时负荷优化分配[J]. 电力系统保护与控制, 2011, 39(17): 87-92.  
LI Yong, WANG Jian-jun, CAO Li-hua. Real time optimal load dispatch of power plant based on back propagation neural network[J]. Power System Protection and Control, 2011, 39(17): 87-92.
- [12] 陈昌松, 段善旭, 殷进军. 基于神经网络的光伏阵列发电预测模型的设计[J]. 电工技术学报, 2009, 24(9): 153-158.  
CHEN Chang-song, DUAN Shan-xu, YIN Jin-jun. Design of photovoltaic array power forecasting model based on neutral network[J]. Transactions of China Electrotechnical Society, 2009, 24(9): 153-158.
- [13] 祝文姬, 何怡刚. 容差模拟电路软故障诊断的神经网络方法[J]. 电工技术学报, 2009, 24(11): 184-191.  
ZHU Wen-ji, HE Yi-gang. Neural network based soft fault diagnosis of analog circuits with tolerances[J]. Transactions of China Electrotechnical Society, 2009, 24(11): 184-191.
- [14] 郭创新, 游家训, 彭明伟, 等. 基于面向元件神经网络与模糊积分融合技术的电网故障智能诊断[J]. 电工技术学报, 2010, 25(9): 183-190.  
GUO Chuang-xin, YOU Jia-xun, PENG Ming-wei, et al. A fault intelligent diagnosis approach based on element-oriented artificial neural networks and fuzzy integral fusion[J]. Transactions of China Electrotechnical Society, 2010, 25(9): 183-190.
- [15] 王成亮, 王宏华, 向昌明, 等. 发电机进相能力的 RBF 神经网络模型[J]. 电工技术学报, 2012, 27(1): 124-129.  
WANG Cheng-liang, WANG Hong-hua, XIANG Chang-ming, et al. Generator leading phase ability model based on RBF neural network[J]. Transactions of China Electrotechnical Society, 2012, 27(1): 124-129.

---

收稿日期: 2013-05-16; 修回日期: 2013-07-23

作者简介:

白牧可(1985-), 女, 博士研究生, 主要研究方向为分布式发电、配电网规划与评估研究。