

# 基于 D-S 证据理论的母线负荷预测

刘亚南<sup>1</sup>, 卫志农<sup>2</sup>, 季 聪<sup>1</sup>, 唐一铭<sup>1</sup>, 都 晨<sup>1</sup>

(1.江苏方天电力技术有限公司,江苏南京 211102;

2.河海大学可再生能源发电技术教育部工程研究中心,江苏南京 210098)

**摘要:**基于 D-S 证据理论,提出一种母线负荷预测新方法。该方法对 BP 神经网络、改进的 BP 神经网络和支持向量机(SVM)的母线负荷预测模型分别建立权重提取和权重融合模型,并运用 D-S 证据理论对 3 种预测模型的权重进行融合。通过对预测数据进行分析,提取证据理论样本,并将可信度函数的融合结果作为母线负荷预测模型的权重,最终得到待预测日的母线负荷预测结果。仿真结果表明,与单一的母线负荷预测模型相比,经 D-S 证据理论融合的母线负荷预测模型更有效,也具有更高的预测精度。

**关键词:**BP 神经网络;支持向量机网络;D-S 证据理论;母线负荷预测

中图分类号:TM715

文献标志码:A

文章编号:1009-0665(2014)05-0021-04

随着现代计算机科学、自动化、通信技术的高速发展,变电站的调度自动化系统日趋完善。母线负荷预测能更好地实现分散式的负荷管理,对电网动态状态估计、安全稳定分析等方面具有十分重要的理论和现实意义。

母线负荷<sup>[1]</sup>可以定义为由变电站的主变压器供给一个相对较小的供电区域的负荷总和,通常一个地区的母线负荷类型比较单一。它包括有功和无功负荷,通常所指的母线负荷一般是有功负荷,同时具有稳定性不强、有坏数据、母线间的差异较大等特点。Kassaei<sup>[2]</sup>等人提出一种基于模糊和神经网络的混合模型对母线进行预测,即在负荷受天气影响较大的地区,将母线负荷分解为与天气无关的基本负荷和受天气变化影响的天气敏感负荷 2 个负荷分量。用 BP 神经网络模型预测相对稳定的基本负荷分量,而用 3 个模糊逻辑子系统建立的模型预测天气敏感负荷分量,提高了预测精度。文献[3]先采用 K 均值聚类方法对电网中众多母线进行特性聚类,形成几大类聚类中心,然后采用多层神经网络方法进行母线负荷预测。文献[4]先采用最小二乘支持向量机进行短期母线负荷预测,然后由历史预测误差组成误差序列,将历史预测误差看作一个马尔可夫过程的时间序列,采用马尔可夫链方法对未来的预测误差进行估计,并采用预测误差估计结果对上一步的预测结果进行修正,预测精度得到显著提高。文献[5]将支持向量机与相关向量机在负荷预测中进行比较,仿真结果表明相关向量机不仅提高了预测精度,并且在稀疏性与计算时间等方面的表现更加优异。文献[6]提出基于粒子群算法(PSO)优化的 BP 神经网络母线负荷预测,通过 PSO 优化 BP 权值和阀值,提高预测精度,改善母线负荷

预测的泛化性。文献[7]采用神经网络进行短期负荷预测,同时将证据理论应用于负荷预测模型的融合,提取了多种预测模型的优点,从整体上提高了预测精度,但是它对权值的计算比较复杂,采用绝对误差也不能够充分反映预测数据的准确性。文献[8]采用 3 种 BP 网络进行负荷预测,通过 Dempster 合成法则进行融合得到最终结果,但是 BP 网络也具有一定的缺陷。

鉴于上述分析,文中将根据母线负荷数据的构成和特点,提出基于证据理论的母线负荷预测模型,分别对 BP 神经网络、改进的 BP 神经网络和支持向量机母线负荷预测模型建立权重提取和权重融合模型,并运用证据理论对 3 种预测模型的权重进行融合,最终对母线负荷进行预测。

## 1 证据理论相关概念

### 1.1 基本定义

定义 1<sup>[9]</sup>设  $\Theta$  为识别框架,基本信任分配函数  $m$  是一个从集合  $2^{\Theta}$  到  $[0, 1]$  的映射,  $A$  表示识别框架  $\Theta$  的任一子集,记作  $A \in \Theta$ ,且满足  $m(\emptyset)=0$ ,  $\sum_{A \in \Theta} m(A)=1$ 。式中: $m(A)$  称为事件  $A$  的基本信任分配函数,表示证据对  $A$  的信任程度。

### 1.2 证据理论 Dempster 合成法则

D-S 合成规则是一个反映证据联合作用的法则。给定几个同一识别框架上基于不同证据的信任函数,如果证据不是完全冲突的,那么就可以利用 D-S 合成规则计算出一个新的信任函数。

设  $Bel_1, Bel_2$  是同一个识别框架上 2 个信度函数,  $m_1$  和  $m_2$  分别是其对应的基本可信度分配,对应焦元分别为  $A_i$  和  $B_j$ ,设  $K=\sum_{A_i \cap B_j=A} m_1(A_i)m_2(B_j)<1$ ,则 D-S 合成法则为:

$$m(A) = \begin{cases} \frac{\sum_{A_i \cap B_j = A} m_1(A_i)m_2(B_j)}{1-K} & A \neq \emptyset \\ 0 & A = \emptyset \end{cases} \quad (1)$$

## 2 证据理论融合权重的数学模型

### 2.1 权重提取的数学模型

运用 Dempster 合成法则进行权重融合之前,需要先提取权重。在利用训练数据对单一负荷预测模型进行训练后,每个模型都会产生训练误差。根据训练误差  $e_i$ ,可以确定每个模型相应的权重为  $w_i$ 。 $e_i = (\hat{y}_i - y_i)/y_i$ ,  $i=1,2,3$ ,  $\hat{y}_i$  为预测值,  $y_i$  为真实值。权重赋值与预测精度有关,预测精度高,赋予的权重就比较大;预测精度低,赋予的权重就比较小,因此权重  $w_i$  可以表示为  $e_i$  的函数<sup>[10-12]</sup>:

$$w_i = \frac{1/(|e_i| + \varepsilon)}{\sum_{i=1}^3 1/(|e_i| + \varepsilon)} \quad (2)$$

需要特别指出的是,这里引入  $\varepsilon$  的目的是为了避免出现相对误差为 0 的情况。由 3 个模型的预测值和权重得到组合预测的结果为:

$$Y = \sum_{i=1}^3 w_i y_i \quad (3)$$

其中: $\sum_{i=1}^3 w_i = 1$ 。

### 2.2 权重融合的数学模型

通过合成法则对多组权值进行融合,在母线负荷预测融合模型中,模型权重就相当于证据理论的基本信度值。对 3 种模型预测值  $y_1, y_2$  和  $y_3$ ,其对应的基本信度值为  $m(y_i) = w_i$  ( $i=1,2,3$ )。假设 1~3 日的负荷预测值所对应的信度值为  $m_j(P_i)$  ( $i=1,2,3$ ;  $j=1,2,3$ )。首先将 1 日和 2 日对应的信度函数进行融合,然后将合成信度函数与 3 日信度函数进行 2 重融合,最终得到的基本信度值记为  $m_4(y_1), m_4(y_2)$  和  $m_4(y_3)$ ,该基本信度值即为 4 日负荷预测型融合的权重。假设 4 日母线负荷预测结果为  $y_1^4, y_2^4$  和  $y_3^4$ ,则最终合成结果为:

$$y^4 = m_4(y_1)^4 * y_1^4 + m_4(y_2)^4 * y_2^4 + m_4(y_3)^4 * y_3^4 \quad (4)$$

## 3 3 种预测模型

### 3.1 BP 神经网络模型

BP 神经网络<sup>[13,14]</sup>是一种多层前馈神经网络,由输入层、隐含层和输出层组成。BP 网络权值调整采用反向传播的学习算法,它利用均方误差和梯度下降法来实现对网络连接权值的修正,使得网络实际输出与目标输出之间的均方误差达到期望误差范围之内。BP 网

络的权值调整算法如下:

$$w(k+1) = w(k) + \alpha D(k) \quad (5)$$

式中: $w(k)$  为第  $k$  步权值; $D(k) = -\partial E / \partial w(k)$  为第  $k$  步负梯度; $E$  为  $k$  时刻的输出误差; $\alpha$  为学习率。

### 3.2 改进 BP 神经网络算法

BP 神经网络算法是一种简单的最速下降静态寻优算法,收敛缓慢。文献[8]提出多种改进的算法,取得了一定效果。文中采用动量-自适应学习率 BP 算法,从而提高学习速度并增加算法的可靠性。动量法降低了网络对于误差曲面细节的敏感性,抑制网络陷入局部极小,提高了收敛速度。动量法权值调整算法为:

$$w(k+1) = w(k) + \alpha[(1-\eta)D(k) + \eta D(k-1)] \quad (6)$$

其中: $\eta$  为动量因子, $0 \leq \eta < 1$ ,加入动量项相当于阻尼项,目的是为了改善收敛性。自适应调整学习率的权值调整算法为:

$$w(k+1) = w(k) + \alpha(k)D(k) \quad (7)$$

其中: $\alpha(k) = 2\lambda\alpha(k-1)$ ,  $\lambda = \text{sign}[D(k)D(k-1)]$ 。将上述 2 种方法结合起来,就得到动量-自适应学习率 BP 神经网络的权值修正算法:

$$w(k+1) = w(k) + \alpha(k)[(1-\eta)D(k) + \eta D(k-1)] \quad (8)$$

### 3.3 支持向量机原理

支持向量机<sup>[15,16]</sup>的基本思想是通过一个非线性映射,把输入空间的数据映射到一个高维空间,然后在此空间中作线性回归。对于回归预测问题,设训练样本  $x_i$  为输入向量, $x_i \in R^n$ ,  $y_i$  为相应目标输出数据, $y_i \in R$ ,其中  $i=1,2,\dots,n$ ,采用如下的回归函数:

$$f(x) = w\Phi(x) + b \quad (9)$$

其中: $w$  为权值向量; $b$  为偏差。这是 2 个待训练的参数,而对于非线性映射函数  $\Phi(x)$  的选取都是选择试算得到的。对  $w$  和  $b$  的训练实际是极小化下的泛函数:

$$R(c, \varepsilon) = \frac{1}{m} \sum_{i=1}^m L_\varepsilon(y_i - f(x_i), x_i) + \frac{1}{2} w^T * w \quad (10)$$

式中第一项为经验误差项,第二项为正规化项,正规化常数  $c$  用来平衡 2 项误差之间的关系,其中:

$$L(y - f(x), x) = |y - f(x)|_\varepsilon = \begin{cases} 0, & |y - f(x)| \leq \varepsilon \\ |y - f(x, w)| - \varepsilon, & \text{其他} \end{cases} \quad (11)$$

即为  $\varepsilon$  的不敏感损失函数。

具体求解时,引入核函数  $k(x, x_i)$ ,可以直接将问题转化为下面的对偶问题,并采用二次规划进行求解:

$$\max \{a_i\} \left\{ a_i^* \right\} = -\frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m (a_i - a_i^*)(a_j - a_j^*) k(x, x_j) - \varepsilon \sum_{i=1}^m (a_i + a_i^*) + \sum_{i=1}^m (a_j + a_j^*) \quad (12)$$

$$\text{s.t. } \begin{cases} \sum_{i=1}^m (a_i - a_i^*) = 0 \\ a_i, a_i^* \in [0, C] \end{cases} \quad (13)$$

由于成为一个二次规划问题,因此,原来待定的回归函数表达式可以写成:

$$f(x, a_i, a_i^*) = \sum_{i=1}^m (a_i - a_i^*) k(x, x_i) + b \quad (14)$$

核函数的选择决定了特征空间的结构。常用的有径向基(RBF)核函数等。由于对偶问题被描述成为一个凸规划问题,因此所求得的任意解均为全局最优解,克服了神经网络的局部极值问题。

## 4 基于证据理论的母线负荷预测模型

### 4.1 数据预处理

选择 SCADA 系统采集的量测数据作为原始数据源,由于传输通道等原因,采集的量测数据时常含有很多异常数据,这些数据的存在会影响预测精度。因此需要进行数据检测并剔除坏数据,文中使用横向纵向数据对比法进行预处理。

### 4.2 样本数据选择

从母线负荷曲线本身分析,短期负荷有着明显的周期性,表现在不同日之间的整体变化的相似性以及同类型日的相似性。因此选择 8 个影响因素作为学习机的输入变量,其中对于预测日日类型,将节假日取为整数 1,工作日取为整数 0。特征因素见表 1。

表 1 特征因素选择

序号	影响因素	表达式
1	预测日前 1 日同时刻负荷	$L(d-1, h)$
2	预测日前 2 日同时刻负荷	$L(d-2, h)$
3	预测日前 3 日同时刻负荷	$L(d-3, h)$
4	预测日前 1 日前 1 h 负荷	$L(d-1, h-1)$
5	预测日前 2 日前 1 h 负荷	$L(d-2, h-1)$
6	预测日前 1 周同时刻负荷	$L(d-7, h)$
7	预测日前 1 周前 1 h 负荷	$L(d-7, h-1)$
8	预测日日期类型	$D(d)$

### 4.3 证据理论融合样本的提取

为了确定待预测日预测模型的权重,首先对待测日前 3 日(1~3 日)的预测模型权重进行融合,然而每一天的模型权重又需要前述模型来进行权重提取。因此,为了获得融合样本,首先需要用 3 种预测模型对前 3 天的母线负荷进行预测。

## 5 算例分析

为了验证方法的有效性,以华东地区某 220 kV 变电站 2010 年 11 月 25 日至 12 月 4 日(00:00~23:00,每 1 h 为 1 点)母线负荷数据为例进行预测仿真测试。1~3 日母线负荷预测的结果如表 2、表 3 和表 4 所示。

通过对上述预测数据分析,利用阐述的数学模型对 4 日的母线负荷进行预测。首先,分别提取 1~3 日

表 2 1 日预测相对误差

时刻	BP	改进 BP	SVM	时刻	BP	改进 BP	SVM
1	0.0283	0.0333	0.1821	13	0.0892	0.0288	0.0153
2	0.0275	0.0255	0.1384	14	0.0875	0.0262	0.0147
3	0.0338	0.0252	0.1171	15	0.0923	0.0331	0.0048
4	0.0377	0.0240	0.1085	16	0.0882	0.0250	0.0209
5	0.0578	0.0346	0.0844	17	0.0758	0.0216	0.0461
6	0.0622	0.0380	0.0722	18	0.0759	0.0195	0.0082
7	0.0590	0.0248	0.0284	19	0.0732	0.0177	0.0515
8	0.0549	0.0192	0.0621	20	0.0528	0.0044	0.0862
9	0.0535	0.0168	0.0795	21	0.0366	0.0038	0.1522
10	0.0717	0.0236	0.0581	22	0.0086	0.0198	0.1822
11	0.0850	0.0276	0.0647	23	0.0385	0.0434	0.2823
12	0.0906	0.0228	0.0028	24	0.0715	0.3095	0.3095

表 3 2 日预测相对误差

时刻	BP	改进 BP	SVM	BP	BP	改进 BP	SVM
1	0.0295	0.0295	0.0907	13	0.0258	0.0258	0.0245
2	0.0353	0.0353	0.0794	14	0.0272	0.0272	0.0041
3	0.0211	0.0221	0.0668	15	0.0243	0.0243	0.0097
4	0.0326	0.0326	0.0645	16	0.0263	0.0263	0.0180
5	0.0369	0.0369	0.0528	17	0.0308	0.0308	0.0065
6	0.0263	0.0263	0.0338	18	0.0327	0.0327	0.0065
7	0.0183	0.0183	0.0654	19	0.0338	0.0338	0.0208
8	0.0229	0.0229	0.0485	20	0.0317	0.0317	0.0154
9	0.0377	0.0377	0.0477	21	0.0216	0.0216	0.0209
10	0.0440	0.0440	0.0719	22	0.0012	0.0012	0.0178
11	0.0423	0.0423	0.0362	23	0.0139	0.0139	0.0010
12	0.0321	0.0321	0.0332	24	0.0038	0.0038	0.0183

表 4 3 日预测相对误差

时刻	BP	改进 BP	SVM	BP	BP	改进 BP	SVM
1	0.0071	0.0520	0.0369	13	0.0008	0.0031	0.1272
2	0.0165	0.0376	0.0719	14	0.0098	0.0103	0.1213
3	0.0328	0.0255	0.0688	15	0.0176	0.0095	0.1305
4	0.0635	0.0068	0.0606	16	0.0050	0.0049	0.1094
5	0.0670	0.0099	0.0946	17	0.0057	0.0007	0.1178
6	0.0623	0.0136	0.1100	18	0.0061	0.0010	0.1099
7	0.0705	0.0200	0.0940	19	0.0043	0.0079	0.1061
8	0.0607	0.0160	0.1029	20	0.0070	0.0109	0.0899
9	0.0543	0.0175	0.1068	21	0.0169	0.0141	0.0510
10	0.0391	0.0198	0.1158	22	0.0352	0.0163	0.0158
11	0.0319	0.0244	0.1297	23	0.0576	0.0133	0.0388
12	0.0088	0.0099	0.1255	24	0.0880	0.0350	0.0688

的模型权重,然后通过 Dempster 法则进行多重融合,将融合结果作为 4 日预测模型权重,文中的  $\epsilon$  选择 0.01。通过计算,可以得到 1~3 日预测模型对应的权重,如表 5 所示。

利用 D-S 证据理论和前面所述的数学模型,将表 3 中的权重当作相应的基本信度值,再通过 Dempster 合成法则进行 2 重融合,得到的融合结果为 0.1594,

表 5 1~3 日 3 种预测模型对应的权重

日期	BP 权重	改进 BP 权重	SVM 权重
1	0.2715	0.5383	0.1902
2	0.2657	0.4047	0.3295
3	0.3290	0.5351	0.1359

0.7833, 0.0572。将融合结果作为模型的权重, 对 4 日的母线负荷预测, 结果如表 6 所示。3 种单一预测模型与权值融合模型的预测误差对比如表 7 所示。

表 6 4 日母线负荷预测结果

时刻	真实值 /MW	预测值 /MW	相对误差 /%
1	49.5	49.3654	0.0027
2	47.775	46.0991	0.0351
3	46.35	44.2611	0.0451
4	45.075	42.9961	0.0461
5	44.1	41.7470	0.0534
6	43.075	40.6351	0.0566
7	42.525	39.9019	0.0617
8	41.8	39.2100	0.0620
9	41.175	38.6157	0.0622
10	40.425	37.9595	0.0610
11	39.8	37.3904	0.0605
12	39.25	36.9866	0.0577
13	38.85	36.6789	0.0559
14	38.675	36.6574	0.0522
15	38.25	36.4090	0.0481
16	38.3	36.2652	0.0531
17	38.45	36.2743	0.0566
18	38.425	36.3243	0.0547
19	38.75	36.5106	0.0578
20	38.125	36.8263	0.0341
21	38.675	37.3463	0.0344
22	39.325	38.3084	0.0259
23	40.6	39.7957	0.0198
24	42.62	41.9697	0.0154

表 7 4 种方法误差比较

预测方法	最大误差 /%	平均相对误差 /%
BP	7.96	5.69
改进 BP	6.56	5.11
SVM	13.4	5.62
D-S	6.22	4.63

从表 7 中可以看出, 单一预测模型中, 改进 BP 网络的预测精度较高, 最大误差比 BP 预测模型和 SVM 预测模型低 1.4% 和 6.84%。D-S 证据理论提取了各种模型的优点, 结果表明, 其权值融合模型预测的最大误差和平均相对误差均小于单一预测模型。

## 6 结束语

提出了一种基于证据理论的母线负荷预测方法。

借助证据理论, 通过 Dempster 合成法则对历史预测数据进行模型权重的融合, 从而对待预测日的母线负荷进行预测。首先建立了权重提取的数学模型, 通过对待测日前 3 日的母线负荷进行预测, 提取了融合样本, 从而计算这 3 日的模型权重, 并对权重进行融合, 然后将融合结果作为待测日的模型权重, 对待测日的母线负荷进行了预测。实例分析结果表明, 基于证据理论的母线负荷预测模型比单一模型更有效、精度也更高。

### 参考文献:

- [1] 康重庆, 夏清, 刘梅. 电力系统负荷预测 [M]. 北京: 中国电力出版社, 2007, 3-5.
- [2] KASSAEI H R, KEYHANI A, WOUNG T, et al. A Hybrid Fuzzy Neural Network Bus Load Modeling and Predication [J]. IEEE Transactions on Power Systems, 1999, 14(2): 718-724.
- [3] SALGADO R M, BALLINI R, OHISHI T. An Aggregate Model Applied to the Short-term Bus Load Forecasting Problem [C]// IEEE Power Systems Conference and Exposition. Bucharest, IEEE, 2009: 1-8.
- [4] 李光珍, 刘文颖. 基于 LSSVM 和马尔可夫链的母线负荷短期预测 [J]. 电力系统保护与控制, 2010, 38(11): 55-60.
- [5] 段青, 赵建国, 马艳. 相关向量机与支持向量机在负荷预测中的比较 [C]// 全国电气工程博士论坛. 成都: 西南交通大学, 2008: 314-319.
- [6] 彭信淞, 贺辉, 姚建刚, 等. 用 PSO 优化 BP 神经网络的母线负荷预测方法 [J]. 电力系统及其自动化学报, 2010, 22(5): 146-151.
- [7] 吴京秋, 孙奇, 杨伟, 等. 基于 D-S 证据理论的短期负荷预测模型融合 [J]. 电力自动化设备, 2009, 29(4): 66-70.
- [8] 孙奇, 杨伟. D-S 证据理论融合改进 BP 网络的短期负荷预测研究 [J]. 继电器, 2007, 35(7): 61-65.
- [9] 杨风暴, 王肖霞. D-S 证据理论的冲突证据合成方法 [M]. 北京: 国防工业出版社, 2010, 15-20.
- [10] 刘亚南, 卫志农, 孙国强, 等. 基于 D-S 证据理论的短期风速预测模型 [J]. 电力自动化设备, 2013, 33(7): 1-6.
- [11] 李鹏, 颜艳, 郑武军, 等. 证据理论融合量子神经网络的短期负荷预测 [J]. 电力系统保护与控制, 2010, 38(16): 49-53.
- [12] 李鑫滨, 张娟, 张岩, 等. 基于 D-S 证据理论的相似日支持向量机短期负荷预测 [J]. 电网技术, 2010, 34(7): 143-147.
- [13] 蔡凯, 谭伦农, 李春林, 等. 时间序列与神经网络法相结合的短期风速预测 [J]. 电网技术, 2008, 32(8): 82-90.
- [14] 梁雪飞, 陈歆技. 小波熵和 BP 神经网络在孤岛检测与扰动辨识中的应用 [J]. 江苏电机工程, 2012, 31(3): 5-8.
- [15] 崔晓祥, 李娟. 基于支持向量机回归的电力系统负荷建模 [J]. 江苏电机工程, 2012, 31(3): 37-39.
- [16] 李云飞, 黄彦全, 蒋功连, 等. 基于 PCA-SVM 的电力系统短期负荷预测 [J]. 电力系统及其自动化学报, 2007, 19(5): 66-70.

### 作者简介:

刘亚南(1988), 男, 江苏徐州人, 硕士, 从事电力系统负荷预测研究工作;

(下转第 27 页)

10 kV 线路零序电流Ⅱ段保护整定值改为 60 A, 0.6 s, 主变低压侧后备零序电流Ⅱ段保护整定值为 90 A, 1.0 s。这样,无论在电流的防止和动作的时间上均满足运行要求。

#### 参考文献:

- [1] 程路,陈乔夫.小电流接地系统单相接地选线技术综述[J].电网技术,2009,33(18):219-224.
- [2] 张志文,申建强,杨俊,等.配电网混合接地运行分析[J].电力系统及其自动化学报,2012,24(2):47-52.
- [3] 刘明岩.配电网中性点接地方方式的选择[J].电网技术,2004,28(16):86-89.
- [4] 江苏省电力公司.电力系统继电保护原理与实用技术[M].北京:中国电力出版社,2006:4-6.
- [5] 王英民.10 kV 小电阻接地系统接地变压器零序保护误动原因分析[J].华北电力技术,2009(1):24-26,29.
- [6] 窦新宇,李春明.广州 10 kV 电网中性点经小电阻接地的研究[J].继电器,2007,35(1):158-161.
- [7] 中国标准出版社第四编辑室.输变电技术常用标准汇编:电力变压器卷[M].北京:中国标准出版社,2010:40-42.
- [8] 陈刚,王清昊,黄玉霞,等.中性点间隙击穿引起的 220 kV 主变跳闸事故的分析[J].电瓷避雷器,2013(5):73-78.
- [9] 国家发展和改革委员会.DL/T 584—2007 3 kV~110 kV 电网继电保护装置运行整定规程[S].北京:中国电力出版社,2008.
- [10] 田宝江,张太升,陈军,等.不平衡零序电流对纵联零序保护的影响分析及其对策[J].电力系统自动化,2013,37(19):132-135.

#### 作者简介:

鲍有理(1966)男,安徽安庆人,高级工程师,从事电力系统继电保护专业技术管理工作;  
季东方(1974),男,江西抚州人,工程师,从事电力系统设备维护及技术支持工作。

## Study on Definite-time of Zero Sequence Over-current Protection Settings for Low Resistance Grounding System

BAO Youli<sup>1</sup>, JI Dongfang<sup>2</sup>

(1.Wuxi Power Supply Company, Wuxi 214061,China;  
2.Guodian Nanjing Automation Co.Ltd., Nanjing 210032, China)

**Abstract:** The zero sequence over-current protection would clear fault in low resistance ground system. The fault current contains the short circuit and the capacitance current. Therefore, the effects of capacitance current on zero sequence protection of 10 kV line and transformer backup zero sequence protection should be considered, especially for the value setting of definite-time of zero sequence over-current protection. The direction of capacitance current and fault current of 10kV line is investigated. The quantitative effects of single-line ground fault on line zero sequence protection and transformer backup zero sequence protection are analyzed. It provides a reference for coordinating protection settings between transformer backup definite-time of zero sequence protection and 10kV line definite-time of zero sequence protection.

**Key words:** low resistance grounding system; capacitance current; zero sequence current backup protection; setting value

(上接第 24 页)

卫志农(1962),男,江苏江阴人,教授,博士生导师,研究方向为电力系统运行分析与控制、输配电系统自动化等;

季 聰(1988),男,江苏南通人,硕士,从事电力系统运行与控制研究工作;

唐一铭(1990),男,江苏徐州人,硕士,从事电力系统运行与控制研究工作;

都 晨(1986),女,江苏南京人,硕士,从事电力系统负荷预测研究工作。

## Bus Load Forecasting Based on D-S Evidence Theory

LIU Yanan<sup>1</sup>, WEI Zhinong<sup>2</sup>, JI Cong<sup>1</sup>, TANG Yiming<sup>1</sup>, DU Chen<sup>1</sup>

(1.Jiangsu Frontier Electrical Power Technology Co.Ltd., Nanjing 211102, China;2.Research Center for Renewable Energy Generation Engineering, Ministry of Education, Hohai University, Nanjing 210098, China)

**Abstract:** In this paper, based on Dempster-Shafer (D-S) evidence theory, a new bus load forecasting approach is presented. The proposed method will firstly establish the weight extraction model and weight fusion model for BP neural networks, generalized BP neural networks and SVM bus load forecasting models, respectively. Then, by using D-S evidence theory, the weights of three forecasting models are fused. After the extraction of fusion samples of evidence theory by analyzing forecasting data, and multi-fusion result of belief function is taken as the weight of bus load forecasting model, by which the bus load in the future is forecasted. Finally, simulation results provided later show that the proposed method in this paper are more effective and has a higher forecasting accuracy than that by using only one model.

**Key words:** BP neural network; SVM; D-S evidence theory; bus load forecasting