

DOI:10.12158/j.2096-3203.2020.05.019

## 基于BP神经网络的输电线路雷击故障预测

吴琛<sup>1</sup>, 苏明昕<sup>2</sup>, 谢云云<sup>3</sup>, 郝琛<sup>4,5</sup>, 刘旭斐<sup>1</sup>, 苏波<sup>2</sup>

(1. 云南电网有限责任公司电力调度控制中心, 云南 昆明 650011; 2. 国网宁夏电力有限公司电力调度控制中心, 宁夏 银川 750001; 3. 南京理工大学自动化学院, 江苏 南京 210094; 4. 南瑞集团(国网电力科学研究院)有限公司, 江苏 南京 211106; 5. 智能电网保护和运行控制国家重点实验室, 江苏 南京 211106)

**摘要:**雷击是导致输电线路故障的主要原因,需要对输电线路雷击故障进行预警以减少其造成的损失。传统雷区预报方法在预报准确性与雷区识别精度之间存在矛盾,难以进一步提高雷击故障预测的准确性。考虑到电力系统在运行中积累了大量雷电和雷击故障的历史数据,文中建立了基于反向传播(BP)神经网络的输电线路雷击故障预测方法。首先在历史雷击故障统计分析的基础上,筛选出输入特征;然后分别应用粒子群(PSO)算法和LM算法确定网络初始权值并进行网络训练;最后基于实际雷电数据和电网雷击故障数据对文中模型进行验证,仿真结果表明文中方法能够预测80%的雷击故障,可为实际电网的雷击故障防御提供参考。

**关键词:**雷击;输电线路故障;故障预测;反向传播(BP)神经网络;历史数据

中图分类号:TM711

文献标志码:A

文章编号:2096-3203(2020)05-0133-07

### 0 引言

雷击是导致输电线路故障的主要原因。2011—2013年,国家电网66 kV及以上电压等级输电线路累计发生雷击跳闸事故1 708次,占总跳闸次数的42.57%<sup>[1]</sup>。中国某省级电网2005—2014年输电线路故障中,雷击故障占46.78%<sup>[2]</sup>。雷击引起的输电线路故障会造成输电线路停运,影响供电可靠性,严重时可能引发大范围停电事故,如2009年的巴西大停电<sup>[3]</sup>。因此,超前预测雷击故障的发生,可为电网提前采取运行措施赢得时间,也是减少雷击故障引起的停电损失的重要防御手段<sup>[4]</sup>。

现有的雷击预警方法主要通过直接或间接的雷电监测设备,监测和预报雷电发生区域,并评估雷电发生区域内输电线路故障概率。文献[5—6]利用大气电场仪测量得到大气静电场数据,预报雷击发生区域。但单个大气电场仪仅能覆盖监测10~20 km内的局部地区,因此该方法目前主要是其他雷电预报方法的补充。多普勒天气雷达能够利用云层中雷达回波特征识别不同的天气特征,被广泛应用于天气预报<sup>[7—11]</sup>。但目前基于多普勒天气雷达的方法还未形成公认的代表雷电发生区域的雷达回波特征。文献[12—14]基于雷电定位系统的监测数据,外推预报未来时段雷击发生区域,并基

于动态雷击跳闸率评估方法计算雷击故障概率。但现有研究中雷电区域主要通过圆形<sup>[13]</sup>或多个圆形组成不规则形状<sup>[12]</sup>描述,在雷电区域中存在大量不会发生雷电的区域,雷击故障概率评估结果的准确性较低。然而,若采用更为精细的不规则形状识别雷区,又将降低雷区预测的准确性,因而难以基于现有雷区识别与预测方法进一步提高雷击故障预测精度。

电力系统在运行过程中积累了大量的雷电数据和历史故障数据,但这些数据在现有研究中未能得到充分利用。随着数据挖掘技术的发展,通过数据挖掘方法发掘雷电信息与故障信息之间的关联性,从而对雷击故障进行预测已成为可能。反向传播(back propagation, BP)神经网络结构简单,具有很强的非线性拟合能力,已经在电力系统中得到广泛应用,如线损计算<sup>[15—16]</sup>、短期电力负荷预测<sup>[17]</sup>等。查阅文献可知,现有国内外研究中尚未发现基于数据挖掘方法的输电线路雷击故障研究成果。

基于此,文中提出基于BP神经网络的输电线路雷击故障预测模型。提取了雷电特征参数,形成神经网络训练和测试的样本集,建立基于粒子群(particle swarm optimization, PSO)算法和LM(Levenberg-Marquardt, LM)算法的PSO-LM-BP网络模型,采用历史落雷信息和输电线路故障信息校验文中方法的有效性。

### 1 输电线路雷击故障预测模型

首先基于雷电监测和故障数据,生成雷击故障

收稿日期:2020-04-07;修回日期:2020-05-15

基金项目:国家自然科学基金资助项目(51507080, 616732-13)

样本和正常样本;然后构建基于 BP 神经网络的雷击故障预测模型;同时,为了加快 BP 神经网络的训练速度和增强收敛效果,建立基于 PSO 的初始权值优化方法和基于 LM 方法的 BP 神经网络训练方法。

### 1.1 生成样本

我国现已建成覆盖大部分国土面积的雷电定位与监测系统,能够实时精确地定位落雷点,获得落雷点的经纬度,以及落雷的雷电流强度<sup>[18-19]</sup>。在电网公司的信息管理系统中,记录了输电线路每条杆塔的经纬度信息和历史雷击故障信息。因此,基于雷电系统测得数据,结合杆塔经纬度信息和历史雷击故障信息,可以统计每个时间步长内不同宽度线路走廊内的落雷数量、雷电强度、雷击引起的故障情况,从而形成雷击故障预测的历史数据样本。

通过我国东部某省份雷电定位系统监测到的部分落雷信息,针对发生雷击故障的所有线路,统计在历史雷击故障发生前一个时间段中不同宽度输电走廊内的平均落雷数量,如图 1(a)所示。针对部分未发生雷击故障的输电线路,统计前一时段中不同宽度输电走廊内平均落雷数量,如图 1(b)所示。可以看出,随着输电走廊宽度的增加,输电走廊内落雷数量不断增加;随着时间步长的增加,输电走廊内落雷数量同样增加。但对于雷击故障情况,时间步长大于 15 min 时,落雷数量增长较少。对于雷击故障和非故障情况,雷击故障发生前的平均落雷数量是非故障时平均落雷数量的 3~4 倍。由此可见,在输电线路雷击故障发生前,雷电活动强度增大。

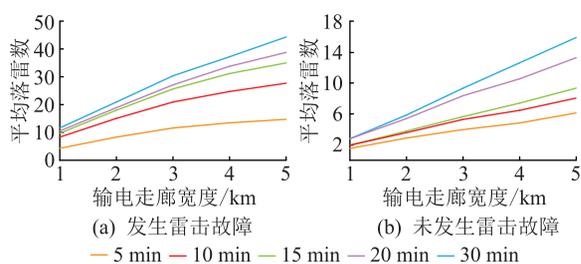


图 1 输电线路故障前一时间段不同宽度输电线路走廊内平均落雷数量

Fig.1 Average lightning number in different transmission corridor width during the time interval before transmission line fault

根据上述分析,当时间步长大于 15 min 时,落雷数量的增长数量较少,因此文中将雷暴发生过程以 15 min 为步长划分为离散的时间段,分别统计每个时间段内的落雷信息。包括各线路走廊内的落雷个数  $X_1$ ,距离各线路最近的落雷点与线路间的距离  $X_2$ ,各线路走廊内的平均雷电流强度  $X_3$ 和距离各

线路最近的落雷的雷电流强度  $X_4$ 。将统计得到的一个时间步长内的落雷信息与下一个时间步长内的雷击故障信息作为一个样本,每个雷击跳闸事故都可以生成一个故障样本。且雷暴发生过程中,大部分时间内大部分输电线路都是正常运行,正常样本远多于故障样本。故如果采用所有数据进行训练,将使 BP 神经网络的输出倾向于正常类而无法识别故障类样本。因此采用随机采样<sup>[20]</sup>生成正常样本,使正常样本与故障样本数量保持平衡,取其中 80%的正常样本和故障样本作为训练样本,剩余样本为测试样本。

### 1.2 BP 神经网络模型

单隐层 BP 神经网络由输入层、隐层和输出层构成。输入层共  $p$  个神经元,其中  $p-1$  个神经元分别对应样本的  $p-1$  维输入特征,另外一个神经元是为隐层激活函数的阈值设计的,其值置为  $-1$ ,则输入样本为  $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{i(p-1)}, -1]^T$ 。隐层神经元共  $q$  个,其中  $q-1$  个神经元与输入层以权值连接,第  $j$  个输入层神经元与第  $k$  个隐层神经元间的权值为  $w_{jk}$ ,另外一个神经元同样是为输出层激活函数设置的,其值始终为  $-1$ ,则第  $k$  个隐层神经元的净输入  $T_k$  为:

$$T_k = \sum_{j=1}^p w_{jk} x_{ij} \quad k = 1, 2, \dots, q - 1 \quad (1)$$

隐层激活函数采用 sigmoid 函数,则第  $k$  个神经元的输出为:

$$m_k = \frac{1}{1 + e^{-T_k}} \quad k = 1, 2, \dots, q - 1 \quad (2)$$

由于雷击故障预警是一个二分类问题,因此输出层只需设置一个神经元,该神经元与隐层神经元以权值  $w_k$  连接,激活函数同样采用 sigmoid 函数。网络输出  $T$  和个体  $i$  的神经网络输出  $y_i$  为:

$$T = - \sum_{k=1}^q w_k m_k \quad (3)$$

$$y_i = \frac{1}{1 + e^{-T}} \quad (4)$$

### 1.3 PSO 算法优化初始权值

传统 BP 神经网络的训练采用梯度下降法调整各层间的连接权值和阈值,其收敛速度较慢,容易收敛于极值附近而得不到理想结果。PSO 算法根据鸟群的觅食行为提出,算法易于实现,所需调整参数少,是一种全局搜索算法,当应用于 BP 神经网络的权值优化时,能够改善训练时易陷入局部极值的缺陷,兼顾全局和局部寻优<sup>[21]</sup>。因此,文中采用 PSO 方法优化初始权值。

根据神经网络结构,将初始种群设置为数个

$pq+q$ 维行向量,每个粒子包含网络所有权值信息,使用网络的均方误差  $s$  表征粒子的适应度值:

$$s = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (5)$$

式中: $n$  为样本数; $y'_i$  为个体  $i$  实际输出。在每一次迭代中通过追踪个体  $i$  历史最佳位置  $P_{i,k}$  和群体历史最佳位置  $P_{g,k}$  来更新粒子的速度和位置,以获得种群中最优适应度即最小均方误差对应的粒子,速度和位置的更新公式分别为:

$$V_{i,k+1} = wV_{i,k} + c_1r_1(P_{i,k} - X_{i,k}) + c_2r_2(P_{g,k} - X_{i,k}) \quad (6)$$

$$x_{i,k+1} = X_{i,k} + V_{i,k+1} \quad (7)$$

式中: $V_{i,k}$  为第  $i$  个粒子第  $k$  次迭代中的移动速度; $c_1, c_2$  为加速度因子,取非负常数; $r_1, r_2$  为  $0 \sim 1$  间的随机数; $X_{i,k}$  为第  $i$  个粒子第  $k$  次迭代中的位置; $w$  为非负可变惯性权重,随着迭代次数的增加线性减小。

$$w = w_{\max} - \frac{w_{\max} - w_{\min}}{k_{\max}}k \quad (8)$$

式中: $w_{\max}, w_{\min}$  分别为最大和最小惯性权重,可取  $0.9$  和  $0.4$ ;  $k_{\max}$  为最大迭代次数。迭代初期  $w$  较大有利于发挥其全局搜索能力,  $w$  较小则侧重于局部搜索。

#### 1.4 LM 算法训练 BP 神经网络

LM 算法是高斯牛顿法的一种改进形式,由于采用了近似的二阶导数信息,所以收敛速度十分迅速,稳定性好,且结合了梯度下降法的优势,在迭代初期的几步下降较快<sup>[22]</sup>。因此,文中采用 LM 方法训练 BP 神经网络,从而加快其收敛速度和精度。

假设网络的误差指标函数  $S$  为:

$$S = \frac{1}{2} \sum_{i=1}^N s_i^2 \quad (9)$$

式中: $N$  为输出层神经元个数; $s_i$  为第  $i$  个神经元误差。则有:

$$\nabla E = \mathbf{J}^T(x) \mathbf{s}(x) \quad (10)$$

式中: $\nabla E$  为梯度; $\mathbf{J}(x)$  为雅可比矩阵,其展开式为:

$$\mathbf{J}(x) = \begin{bmatrix} \frac{\partial s_1(x)}{\partial x_1} & \frac{\partial s_1(x)}{\partial x_2} & \cdots & \frac{\partial s_1(x)}{\partial x_N} \\ \frac{\partial s_2(x)}{\partial x_1} & \frac{\partial s_2(x)}{\partial x_2} & \cdots & \frac{\partial s_2(x)}{\partial x_N} \\ \vdots & \vdots & \cdots & \vdots \\ \frac{\partial s_N(x)}{\partial x_1} & \frac{\partial s_N(x)}{\partial x_2} & \cdots & \frac{\partial s_N(x)}{\partial x_N} \end{bmatrix} \quad (11)$$

则 LM 算法的权值修正公式为:

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [\mathbf{J}^T(x)\mathbf{J}(x) + \mu\mathbf{I}]^{-1}\mathbf{J}(x)\mathbf{s}(x) \quad (12)$$

式中: $\mathbf{x}_k$  为第  $k$  次迭代中神经网络的权值所组成的向量; $\mathbf{I}$  为单位矩阵; $\mu$  为比例系数,当  $\mu$  为  $0$  时,LM 算法为梯度下降法,当  $\mu$  无穷大时,为高斯牛顿法,因此通过合理调节  $\mu$  的取值可充分发挥两者的优势<sup>[23]</sup>。基于 PSO-LM-BP 神经网络的训练过程为:

(1) 设置 PSO 算法的各项参数,如粒子种群个数,加速度因子  $c_1$  和  $c_2$ ,最大迭代次数  $k_{\max}$ ,随机初始化各粒子表示网络的权值;

(2) 计算各粒子的适应度值即对应的均方误差,记录各粒子自身历史最佳位置  $P_{i,k}$  和群体历史最佳位置  $P_{g,k}$ ;

(3) 根据式(6)和式(7)更新粒子的位置;

(4) 重新计算新粒子的适应度值,更新  $P_{i,k}$  和  $P_{g,k}$ ,  $k=k+1$ ,当迭代次数达到  $k_{\max}$  时,转步骤(5),否则转步骤(3);

(5) 将群体最佳适应度粒子对应的权值作为 BP 神经网络的初始权值,初始化 LM 算法的各参数,如目标误差  $s$ ,比例系数  $\mu$ ,调节因子  $\beta$ ,最大迭代次数  $t_{\max}$ ;

(6) 计算当前误差  $s_t$ ,若  $s_t < s$  或  $t > t_{\max}$ ,则结束训练,否则转步骤(7);

(7) 形成雅可比矩阵,根据式(12)调整权值,计算调整后的误差值  $s_{t+1}$ ,若  $s_t > s_{t+1}$ ,则调整有效,  $\mu = \mu/\beta$ ,  $t = t+1$ ;否则调整无效,使  $\mu = \mu\beta$ 。

#### 1.5 基于 PSO-LM-BP 神经网络的雷击故障预测

基于 BP 神经网络的雷击故障预测方法如图 2 所示,具体步骤为:

(1) 读入雷电定位系统中雷电历史数据、输电线路和杆塔经纬度数据以及雷击故障历史数据。

(2) 针对每个雷暴,以  $15 \text{ min}$  为时间步长,将雷暴过程划分为离散的时间段;统计每个时间段  $t_k$  中不同宽度输电走廊内的落雷特征信息,作为输入数据;将  $t_{k+1}$  时间段中的历史故障数据作为输出数据,与输入数据一起组成一个样本;对发生故障的情况,该样本为故障样本,对未发生故障的情况,该样本为正常样本。将部分样本作为训练样本优化神经网络的参数,部分样本作为测试样本验证文中方法的有效性。

(3) 采用 BP 神经网络,将线路走廊宽度从  $1 \text{ km}$  到  $5 \text{ km}$  每隔  $0.5 \text{ km}$  进行取值,在每个取值下提取对应的落雷信息特征。除去  $1$  个样本后,利用其余  $N_s - 1$  样本对该样本进行预测,得到预测误差  $s_i$ 。对每个训练样本都如此操作,从而获得  $N_s$  个样本的误差序列  $s_1, s_2, \dots, s_{N_s}$ ,并计算其均方差值  $s_m$ :

$$s_m = \sqrt{\frac{1}{N_s} \sum_{i=1}^{N_s} s_i^2} \quad (13)$$

将均方差最小的输电走廊宽度所对应的样本作为神经网络的训练样本。

(4) 采用最佳走廊宽度对应的训练样本,重新训练神经网络。

(5) 采用测试样本对训练完成的神经网络进行测试,对于预测样本  $x_0$ ,得到预测输出  $y_0$ ,当  $y_0$  大于阈值时,将样本归为故障类;当  $y_0$  小于阈值时,则将样本归为正常样本类。调整阈值的大小,获得使预测效果最佳的阈值。

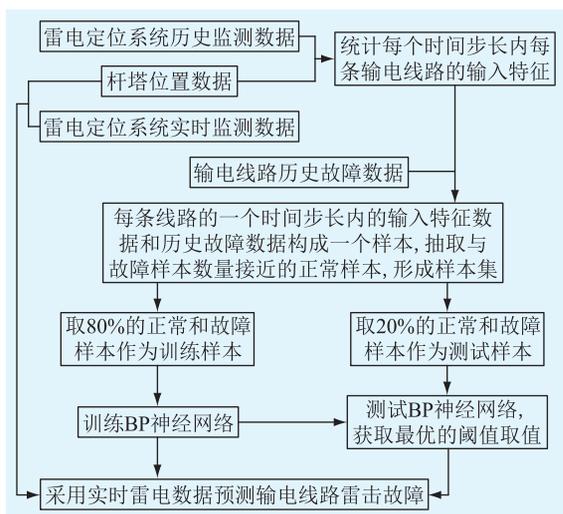


图2 基于BP神经网络的线路雷击故障预测

Fig.2 The lightning fault prediction based on BP neural network

通过上述步骤可以得到训练完成的神经网络,将实时监测到的某一条线路一个时间步长的落雷数据作为其输入数据,则可获得该线路的雷击故障预测结果,实现对一条输电线路雷击故障的预测。

## 2 雷击故障预测算例分析

### 2.1 仿真场景

文中所采用的信息为我国东部某省份 2011—2015 年雷电定位系统监测到的部分落雷信息,该省份 97 条 220 kV 交流线路的杆塔的经纬度信息,以及 129 个雷击跳闸信息。首先将每次雷暴过程以 15 min 为间隔划分为时间段,统计每个时间段中的落雷特征信息,采用单边选择算法<sup>[24]</sup>和合成少数类过采样算法<sup>[25]</sup>生成 2 000 个正常样本和 2 000 个故障样本。将 1 600 个正常样本和 1 600 个故障样本用作训练,剩下的 400 个正常样本和 400 个故障样本作为测试样本。部分故障样本见表 1。

### 2.2 线路走廊范围的确定

采用 1.5 节中的方法,得到不同线路走廊宽度对应样本的误差均方差值如图 3 所示。可见,走廊宽度为 1.5 km 时,对应样本的误差均方差值最小。因

表 1 跳闸线路落雷信息统计

Table 1 Statistics of lightning information of fault transmission lines

线路名	$X_1$	$X_2/\text{km}$	$X_3/\text{kA}$	$X_4/\text{kA}$
JJ 线	1	0.856 3	257.50	257.5
BJ 线	17	0.130 1	51.22	52.0
WH II 线	65	0.054 9	44.04	40.8
YX I 线	2	0.690 9	49.60	56.1
YJ 线	13	0.057 6	43.17	30.6

此,在后续研究中将 1.5 km 走廊宽度对应的样本作为神经网络模型的训练样本。

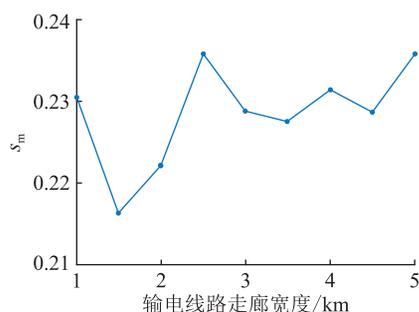


图3 不同输入的误差序列均方差值

Fig.3 Mean square of error series for different input

## 2.3 雷击故障预测结果

### 2.3.1 训练结果

每个对于训练样本,其中前 1 600 个为故障样本,其实际值  $y'_i$  为 1,后 1 600 个为正常样本,其实际值  $y'_i$  为 0,神经网络的输出值  $y_i$  与实际值差的绝对值  $\Delta y_i$  如图 4 所示。

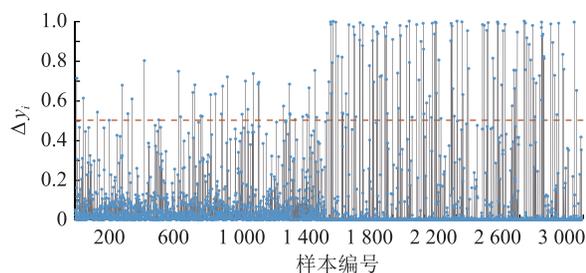


图4 PSO-LM-BP 神经网络训练样本误差分布

Fig.4 Error distribution of training samples for PSO-LM-BP neural network

选取  $\Delta y_i = 0.5$  (图 4 中红线) 作为阈值时,预测输出分类后得到的训练样本故障预测结果如表 2 所示。

表 2 PSO-LM-BP 训练样本故障预测结果

Table 2 Fault prediction result of training sample for PSO-LM-BP neural network

样本类型	分类为故障	分类为正常
故障样本	1 564	36
正常样本	114	1 486

### 2.3.2 评价指标

文中采用二分类法,将雷击故障定义为正类,正常运行为负类。当雷击故障被正确预测,称为真正类,即  $T_P$ ;当雷击故障被错误预测,称为假负类,即  $F_N$ ;当正常运行被错误预测,称为假正类,即  $F_P$ ;当正常运行被正确预测,称为真负类,即  $T_N$ 。雷击故障预测的效果可以用真正类率  $R_{TP}$  或命中率、负真正类率  $R_{FP}$  或假警率以及准确率  $R_{ACC}$  来表示:

$$R_{TP} = \frac{T_P}{T_P + F_N} \times 100\% \quad (14)$$

$$R_{FP} = \frac{F_P}{F_P + T_N} \times 100\% \quad (15)$$

$$R_{ACC} = \frac{T_N + T_P}{F_P + F_N + T_P + T_N} \times 100\% \quad (16)$$

当采用 0.5 作为阈值时,上述训练样本的  $R_{TP}$  为 97.75%,  $R_{FP}$  为 7.13%,  $R_{ACC}$  为 95.31%。

### 2.3.3 预测结果

对于 800 个预测样本(其中前 400 个为故障样本,后 400 个为正常样本),基于 PSO-LM-BP 网络的输出误差见图 5。当采用不同的阈值时,神经网络的预测效果很有很大差别。文中采用接收者操作特征(receiver operating characteristic, ROC) 曲线来表示不同阈值的预测效果,如图 6 所示。当阈值取 0 时,所有样本均被预测为故障样本,对应图中右上角的点;当阈值取 1 时,所有样本均被预测为正常样本,对应图中左下角的点;当取不同阈值使  $R_{FP}$  增加时,  $R_{TP}$  也同样在增加;  $R_{ACC}$  值随着  $R_{FP}$  的增加,先增加后减小。如果以  $R_{ACC}$  最优为目标,最佳的阈值为 0.37,此时  $R_{TP}$  为 0.94,  $R_{FP}$  为 0.11,  $R_{ACC}$  为 0.92。对于雷击故障的预测,可以接受适度的  $R_{FP}$ ,而不必以  $R_{ACC}$  最高为目标,使用者可以根据实际运行情况,选择适当的阈值。

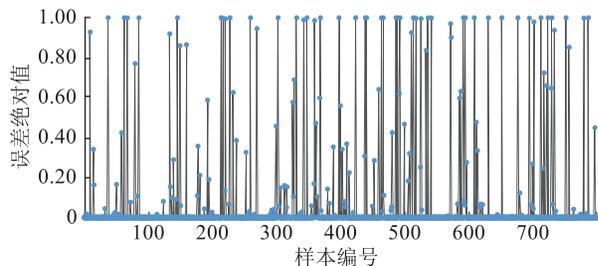


图 5 PSO-LM-BP 神经网络预测样本误差分布  
Fig.5 Error distribution of prediction samples for PSO-LM-BP neural network

### 2.3.4 结果比较

取  $R_{FP} = 0.11$ ,  $R_{TP} = 0.94$  所对应的阈值 0.37 为 BP 神经网络的阈值,将文中方法与传统的 BP 神经网络进行比较,结果如表 3 所示。由表 3 可知,基于

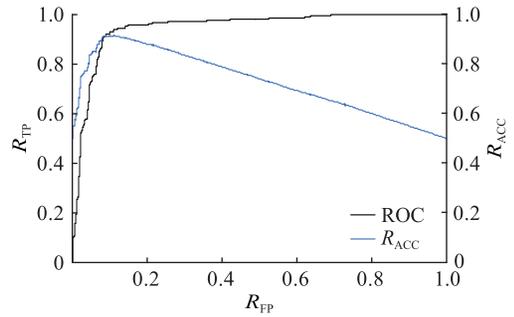


图 6 不同阈值的预测效果

Fig.6 Predictive effect of different threshold

PSO-LM-BP 神经网络的线路雷击故障预测模型对于雷击跳闸故障的预报命中率达到 94.00%,同时假警率为 11.00%。而传统的 BP 神经网络的跳闸预测命中率为 96.00%,假警率为 18.75%。综合来看,PSO-LM-BP 的准确率达到了 91.50%,高于 BP 神经网络的 88.63%。无法预报的故障样本大多发生在落雷不是很密集或线路距离落雷点较远等情况下,同时跳闸虚警的样本中线路均位于雷区,线路附近落雷数较多,处于可能发生跳闸的危险状态。对比传统的 BP 神经网络,PSO-LM-BP 有着更高的故障预报成功率,并且大大减小了迭代次数。

表 3 预测样本预警精度

Table 3 Fault prediction accuracy of prediction sample

方法	$R_{TP}/\%$	$R_{FP}/\%$	$R_{ACC}/\%$	迭代次数
PSO-LM-BP	94.00	11.00	91.50	63
BP	96.00	18.75	88.63	474

## 3 结语

针对现有的输电线路雷击故障预测方法难以进一步提高输电线路雷击故障预测准确性的问题,文中采用历史雷电信息、雷击故障信息和输电线路信息,提出了基于 BP 神经网络的雷击故障预警方法。首先将雷暴发生过程按时间步长划分为时间段,统计出各个时间段内的落雷特征信息,与历史雷击故障数据综合,构建神经网络的训练和测试样本。然后,建立了基于 BP 神经网络的雷击故障预警模型,采用 PSO 方法对神经网络的初始权值进行优化,基于 LM 方法加快神经网络的训练速度。基于实际雷击故障数据的预测结果表明,文中方法具有 91.5% 的预报正确率。相对于传统 BP 方法,文中方法具有更高的准确率及更快的迭代速度,可以为线路雷电防御提供决策依据。

文中忽略了输电线路内部影响参数,训练数据偏少,影响了雷击故障预报的效果,在未来的研究中,需要进一步考虑更多的影响因素,采用更多的

训练数据和新的数据挖掘方法,以提高雷击故障预测的准确性。

本文得到云南电网有限责任公司科技项目“在自然灾害下电网风险评估与预防控制技术研究二期工程”,国网宁夏电网有限公司科技项目“电网一体化安全管控体系平台技术支撑系统”,智能电网保护和运行控制国家重点实验室开放课题研究项目资助,谨此致谢!

#### 参考文献:

- [1] 梁志峰. 2011—2013 年国家电网公司输电线路故障跳闸统计分析[J]. 华东电力, 2014, 42(11): 2265-2270.  
LIANG Zhifeng. Statistical analysis of transmission line fault tripping in state grid corporation of China in 2011—2013[J]. East China Electric Power, 2014, 42(11): 2265-2270.
- [2] 陆佳政, 周特军, 吴传平, 等. 某省级电网 220 kV 及以上输电线路故障统计与分析[J]. 高电压技术, 2016, 42(1): 200-207.  
LU Jiazheng, ZHOU Tejun, WU Chuanping, et al. Fault statistics and analysis of 220 kV and above power transmission line in province-level power grid[J]. High Voltage Engineering, 2016, 42(1): 200-207.
- [3] FERRO M, YAMASAKI A S J, PIMENTEL D R M, et al. Cloud-to-ground lightning warnings based on electric field-mill measurements in BRAZIL [C]//30th International Conference on Lightning Protection (ICLP). 2010: 1-6.
- [4] 薛禹胜, 吴勇军, 谢云云, 等. 停电防御框架向自然灾害预警的拓展[J]. 电力系统自动化, 2013, 37(16): 18-26.  
XUE Yusheng, WU Yongjun, XIE Yunyun, et al. Extension of blackout defense scheme to natural disasters early-warning[J]. Automatic of Electric Power Systems, 2013, 37(16): 18-26.
- [5] 林伟芳, 孙华东, 汤涌, 等. 巴西“11·10”大停电事故分析及启示[J]. 电力系统自动化, 2010, 34(7): 1-5.  
LIN Weifang, SUN Huadong, TANG Yong, et al. Analysis and lessons of the blackout in Brazil power grid on November 10, 2009[J]. Automation of Electric Power Systems, 2010, 34(7): 1-5.
- [6] 孟青, 吕伟涛, 姚雯, 等. 地面电场资料在雷电预警技术中的应用[J]. 气象, 2005, 31(9): 30-33.  
MENG Qing, LYU Weitao, YAO Wen, et al. Application of detection data from electric field meter on ground to lightning warning technique[J]. Meteorological Monthly, 2005, 31(9): 30-33.
- [7] ZEPKA G S, PINTO O, SARAIVA A C V. Lightning forecasting in southeastern Brazil using the WRF model[J]. Atmospheric Research, 2014(135): 344-362.
- [8] VOORMANSIK T, ROSSI P J, MOISSEEV D, et al. Thunderstorm hail and lightning detection parameters based on dual-polarization doppler weather radar data[J]. Meteorological Applications, 2017, 24(3): 521-530.
- [9] SUPARTA W, WAHYU S P. Parametric studies of ANFIS family capability for thunderstorm prediction[M]. Space Science and Communication for Sustainability. Singapore: Springer, 2018: 11-21.
- [10] BALA K, DILIP K C, SANCHITA P. Soft computing and data mining techniques for thunderstorms and lightning prediction: a survey [C]//2017 International conference of Electronics, Communication and Aerospace Technology (ICECA). 2017.
- [11] UKKONEN P, AGOSTINO M, ANTTI M. Evaluation of thunderstorm predictors for finland using reanalyses and neural networks[J]. Journal of Applied Meteorology and Climatology 2017, 56(8): 2335-2352.
- [12] 谢云云, 薛禹胜, 王昊昊, 等. 电网雷击故障概率的时空在线预警[J]. 电力系统自动化, 2013, 37(17): 44-51.  
XIE Yunyun, XUE Yusheng, WANG Haohao, et al. Space-time early-warning of power grid fault probability by lightning[J]. Automaton of Electric Power Systems, 2013, 37(17): 44-51.
- [13] 赵芝, 石季英, 袁启海, 等. 输电线路的雷击跳闸概率预测计算新方法[J]. 电力系统自动化, 2015, 39(3): 51-58.  
ZHAO Zhi, SHI Jiying, YUAN Qihai, et al. A new prediction calculation method of transmission lines lightning trip probability[J]. Automaton of Electric Power Systems, 2015, 39(3): 51-58.
- [14] TAO H, GU S, WANG H, et al. Method of lightning warning based on atmospheric electric field and lightning location data [C]//2016 33rd International Conference on Lightning Protection (ICLP). 2016: 1-5.
- [15] 薛禹胜, 赖业宁. 大能源思维与大数据思维的融合: (一) 大数据与电力大数据[J]. 电力系统自动化, 2016, 40(1): 1-8.  
XUE Yusheng, LAI Yening. Integration of macro energy thinking and big data thinking: part one big data and power big data [J]. Automation of Electric Power Systems, 2016, 40(1): 1-8.
- [16] 李亚, 刘丽平, 李柏青, 等. 基于改进 K-Means 聚类神经网络台区线损率计算方法[J]. 中国电机工程学报, 2016, 36(17): 4543-4551.  
LI Ya, LIU Liping, LI Baiqing, et al. Calculation of line loss rate in transformer district based on improved K-means clustering algorithm and BP neural network[J]. Proceedings of the CSEE, 2016, 36(17): 4543-4551.
- [17] 苏学能, 刘天琪, 曹鸿谦, 等. 基于 Hadoop 架构的多重分布式 BP 神经网络的短期负荷预测方法[J]. 中国电机工程学报, 2017, 37(17): 4966-4973.  
SU Xueneng, LIU Tianqi, CAO Hongqian, et al. A multiple distributed BP neural networks approach for short-term load forecasting based on Hadoop framework[J]. Proceedings of the CSEE, 2017, 37(17): 4966-4973.
- [18] 陈家宏, 张勤, 冯万兴, 等. 中国电网雷电定位系统与雷电监测网[J]. 高电压技术, 2008, 34(3): 425-431.  
CHEN Jiahong, ZHANG Qin, FENG Wanxing, et al. Lightning location system and lightning detection network of China power grid [J]. High Voltage Engineering, 2008, 34(3): 425-431.
- [19] 曹璞磷, 束洪春, 马仪, 等. 基于雷电定位系统与行波实测数据的雷击故障关联度分析[J]. 中国电机工程学报, 2015, 35(20): 5220-5227.

- CAO Pulin, SHU Hongchun, MA Yi, et al. The correlation degree of lightning location system and measured field traveling wave data for lightning induced fault distinguishing [J]. Proceedings of the CSEE, 2015, 35(20):5220-5227.
- [20] CHAWLA N, JAPKOWIEZ N, KOLEZ A. Special issues on learning from imbalanced datasets[J]. SIGKDD Explorations, 2004, 6(1):1-6.
- [21] 马修元, 段钰锋, 刘猛, 等. 基于 PSO-BP 神经网络的水焦浆管道压降预测[J]. 中国电机工程学报, 2012, 32(5):54-60.
- MA Xiuyuan, DUAN Yufeng, LIU Meng, et al. Prediction of pressure drop of coke water slurry flowing in pipeline by PSO-BP neural network[J]. Proceedings of the CSEE, 2012, 32(5):54-60.
- [22] 项文强, 张华, 王姮, 等. 基于 LM 算法的 BP 网络在变压器故障诊断中的应用[J]. 电力系统保护与控制, 2011, 39(8):100-103.
- XIANG Wenqiang, ZHANG Hua, WANG Heng, et al. Application of BP neural network with LM algorithm in power transformer fault diagnosis[J]. Power System Protection and Control, 2011, 39(8):100-103.
- [23] 伍川辉, 蒋荣伟. 基于 PSO-LM-BP 神经网络的压力传感器温度补偿方法[J]. 仪表技术与传感器, 2018(2):129-133.
- WU Chuanhui, JIANG Rongwei. Temperature compensation method of pressure sensor based on PSO-LM-BP neural network[J]. Instrument Technique and Sensor, 2018(2):129-133.
- [24] KUBAT M, MATWIN S. Addressing the curse of imbalanced training sets: one-sided selection [C]//International Conference of Machine Learning. 1997:179-186.
- [25] CHAWLA N V, BOWYER K W, HALL L O, et al. Smote: synthetic minority over-sampling technique[J]. Journal of Artificial Intelligence Research, 2002, 16(1):321-357.

作者简介:



吴琛

吴琛(1974),女,硕士,教授级高级工程师,从事电力系统及自动化相关工作(E-mail: elfwu@21cn.com);

苏明昕(1970),男,硕士,高级工程师,从事电网调度运行相关工作;

谢云云(1985),男,博士,副教授,研究方向为电力系统防灾减灾与恢复控制。

## BP neural network based lightning fault prediction of transmission lines

WU Chen<sup>1</sup>, SU Mingxin<sup>2</sup>, XIE Yunyun<sup>3</sup>, YU Chen<sup>4,5</sup>, LIU Xufei<sup>1</sup>, SU Bo<sup>2</sup>

- (1. Power Dispatching and Control Center of Yunnan Power Grid Co., Ltd., Kunming 650011, China;
2. State Grid Ningxia Power Electric Co., Ltd. Power Dispatching and Control Center, Yinchuan 750001, China;
3. School of Automation, Nanjing University of Science and Technology, Nanjing, 210094, China;
4. NARI Group(State Grid Electric Power Research Institute) Co., Ltd., Nanjing 211106, China;
5. State Key Laboratory of Smart Grid Protection and Control, Nanjing 211106, China)

**Abstract:** Lightning fault is one of the main reasons of transmission line faults, which is necessary to be predicted to reduce the loss caused by lightning faults. The accurate detection of lightning area has conflict with the accurate lightning prediction, which makes it hard to further improve the accuracy of lightning fault prediction based on current method. With the development of data mining technology, large amount of measured lightning information, historical lightning faults information, which are deposited in the database of power system for many years, can be utilized to predict lightning faults. Therefore, a lightning prediction method for transmission lines is proposed based on BP neural network. Firstly, the input parameters of lightning faults are analyzed based on the historical lightning data. Then, a BP neural network is employed to establish the prediction model, in which PSO is employed to calculate initial weight value and LM is employed to accelerate training speed of BP neural network. Lastly, actual lightning information is adopted to verify the effectiveness of proposed method. Simulation results show that 80% of lightning faults can be predicted by proposed method which can provide a reference for power system operation.

**Keywords:** lightning; transmission line faults; faults prediction; back propagation (BP) neural network; historical data

(编辑 方晶)