

DOI: 10.13382/j.jemi.B2002906

基于 S 变换和 PSO-GRNN 的柔性 直流输电线路故障测距方法*

徐耀松¹ 唐 维¹ 徐才宝¹ 徐 胜²

(1. 辽宁工程技术大学 电气与控制工程学院 葫芦岛 125105;

2. 国网辽宁省电力有限公司葫芦岛供电公司 葫芦岛 125105)

摘要:针对现有柔性直流输电线路接地故障的神经网络故障测距算法中,训练样本过多、训练时间较长、且未对鲁棒性提出有效验证的问题,提出一种基于 S 变换和粒子群(PSO)算法优化广义神经网络(GRNN)的线路故障测距算法。从故障行波能量谱的角度出发,采用 S 变换提取故障暂态电压信号能量谱,然后对表征各频率区间的能量进行求和,以实现能量特征样本的准确提取;再将归一化处理后的能量样本输入神经网络进行训练,并采用 PSO 算法对 GRNN 的光滑因子进行优化,以提高网络收敛速度和训练精度。最后,通过电磁暂态仿真证明该方法定位精度高,不易受过渡电阻影响,在输入样本存在测量误差以及外界噪声干扰的情况下,最大误差仍低于 1.5%,具有一定的工程运用价值。

关键词: 暂态能量和; S 变换; 粒子群算法; 广义神经网络; 故障测距

中图分类号: TM93 **文献标识码:** A **国家标准学科分类代码:** 470.40

Fault location method for VSC-HVDC line based on ST and PSO-GRNN

Xu Yaosong¹ Tang Wei¹ Xu Caibao¹ Xu Sheng²

(1. Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China;

2. Huludao Power Supply Company, State Grid Liaoning Electric Power Company, Huludao 125105, China)

Abstract: Aiming at the existing neural network fault location algorithms for ground faults on VSC-HVDC lines, there are too many training samples, long training time, and no effective verification of robustness is proposed. A method based on ST and PSO optimizes the line fault location algorithm of GRNN. From the perspective of the fault traveling wave energy spectrum, the ST is used to extract the fault transient voltage signal energy spectrum, and the energy representing each frequency interval is summed to achieve accurate extraction of the energy characteristic samples; and then normalized the subsequent energy samples and input to the neural network for training, and the PSO algorithm is used to optimize the smoothing factor of the GRNN to improve the network convergence speed and training accuracy. Finally, the electromagnetic transient simulation proves that the method has high positioning accuracy and is not easily affected by the transition resistance. In the case of input samples with measurement errors and external noise interference, the maximum error is still less than 1.5%, which has certain engineering application value.

Keywords: transient energy sum; S-transform; particle swarm optimization; generalized neural network; fault location

0 引言

柔性直流输电技术因其输出谐波少、不存在换相失败、可单独控制有功和无功功率、无需无功补偿等优点^[1],现被国家大力推广。电压源换流器型高压直流

输电(voltage source converter-high voltage direct current transmission, VSC-HVDC)作为新一代直流输电技术,其传输容量和电压等级也得到了大幅度提升。然而直流输电线路在进行远距离跨地域输电时,极易受到极端气候和复杂地形的影响,因而线路单极接地故障频发且难以搜寻。当发生单极接地故障,不仅会造成系统

的停运,严重时还会引发系统的瘫痪。因此,精确的故障测距技术对直流输电系统的稳定运行具有重大现实意义^[2]。

目前,国内外学者已对柔性直流输电线路故障定位展开了大量研究^[3],对直流输电系统测距方法而言,以行波法和故障分析法的运用较为常见。行波法可以分为单端和双端两种测距法,单端法的原理是利用行波在故障点和线路物理边界折反射时间差来计算故障距离^[4],此方法定位精度高,但受过渡电阻影响大、波头识别困难、对采样频率要求高。双端测距法则是利用线路两端的行波波头到达时刻进行测距^[5],此方法可有效消除过渡电阻影响,但对同步性要求较高,需投入时钟同步设备。采用故障分析法进行测距时,过渡电阻对测距精度影响较大^[6],通过建立输电线路拓扑结构模型,列写复数方程组进行定位的方法^[7]计算量大且容易出现伪根。对此,有学者提出采用神经网络的方法^[8],通过将双端故障信号的高频分量串联连接以形成特征波形,然后输入到卷积神经网络(CNN)中进行学习,能有效解决双端通信不同步以及高阻接地问题,但卷积神经网络自身存在着结构冗余、所需训练样本较多、训练时间过长的问题,因此较难运用于实际。

为解决上述神经网络测距方法的不足,本文提出了一种基于S变换和粒子群(PSO)算法优化广义神经网络(GRNN)的柔性直流输电线路故障测距新方法。首先,分析了双端柔性直流输电系统固有频率与故障距离之间的数学关系,从故障行波能量主要集中在固有频率附近的角度出发,利用S变换提取故障行波不同频率区间暂态能量和作为故障信号初始特征向量;然后,将归一化的各区间能量样本放入GRNN神经网络中建立故障测距回归模型;最后,采用PSO算法对GRNN网络中光滑因子 σ 进行优化,充分提高GRNN网络的收敛速度和稳定性。通过在PSCAD/EMTDC仿真平台上搭建VSC双端柔性直流输电系统模型,仿真结果表明,该方法定位精度高、算法收敛速度快,鲁棒性好、且对过渡电阻有一定的耐受能力。

1 双端柔性直流输电线路系统结构

为分析双端柔性直流输电系统中输电线路发生故障时的电磁暂态特性,本文搭建了双端柔性直流输电系统模型,如图1所示。VSC-HVDC系统额定电压为 ± 200 kV,正负极各并联电容1 000 μF ,换流站VSC1容量500 MW,换流站VSC2容量400 MW,输电线路采用电缆连接,全长219 km,电缆各参数设置参考文献[9]进行设置,具体参数如表1所示。




图1 双端柔性直流输电系统模型

Fig. 1 Model of a two-terminal VSC-HVDC transmission system

表1 直流电缆线参数

Table 1 Parameters of the DC cable

电缆线各参数	数值
单位等效电阻 $R/(\Omega \cdot \text{km}^{-1})$	1.55×10^{-2}
单位等效电感 $L/(\text{H} \cdot \text{km}^{-1})$	3.32×10^{-4}
单位等效电容 $C/(\text{F} \cdot \text{km}^{-1})$	1.86×10^{-8}

GE1和GE2为系统交流侧;换流变采用Y/Y₀联结方式;换流站1采用定无功、定电压的控制方式,换流站2采用定有功、无功的控制方式;换流站采用六个桥臂的VSC拓扑结构;换流站采用基于dq变换的直接电流解耦控制策略;直流线路两侧均安装直流电抗器以限制故障电流,用L表示。线路故障隔离装置直流断路器用M、N表示。当线路发生短路故障时,输电线路两端并联电容的放电,导致暂态电压产生了明显突变^[10],其故障信号包含了多种频率分量,通过对其分析可以有效地进行故障测距研究。

2 输电线路行波能量在故障测距中的运用

2.1 输电线路行波固有频率分析

当直流输电线路发生故障时,由于换流站并联的电容器以及直流侧的限流电抗器在线路两端构成实体物理边界^[11],故障行波会在故障点和测量端之间多次反射,从而产生了行波的固有频率,故障行波频谱反映了行波能量的幅值特性,其中最低次频率幅值最大,频谱能量最高,为主频率成分^[12],表达式为:

$$\omega_0 = \frac{2\pi}{T} \quad (1)$$

式中: ω_0 为固有主频率; T 为频谱震荡周期。

2.2 直流输电线路行波谱能量与故障测距的关系

当直流输电线路发生故障时, M 端和 N 端为线路采样装置点,对 $M-M'$ 和 $N-N'$ 之间的输电线路采用二端口网络进行等效^[13],故障等效电路如图2所示。图2中 u_M, u_N 为测量端电压; Z_C 为线路波电抗; Z_M, Z_N 分别为 M 端和 N 端系统等值电抗; u_f 为前行电压波, u_r 为反向电压波; $u_1(t), u_2(t)$ 为系统等效电压。

由故障等效电路可得 u_M, u_N 电压分别为:




图2 输电系统故障等效电路

Fig. 2 Transmission system fault equivalent circuit

$$u_M(t) = \frac{Z_M}{Z_M + Z_C} 2u_s(t) + \frac{Z_C}{Z_M + Z_C} u_1(t) \quad (2)$$

$$u_N(t) = \frac{Z_N}{Z_N + Z_C} 2u_r(t) + \frac{Z_C}{Z_N + Z_C} u_2(t) \quad (3)$$

对式(2)、(3)进行 Laplace 变换可得:

$$u_s(s) = \frac{p(s)}{1 - \beta_1(s)\beta_2(s)p^2(s)} \left[\beta_2(s)p(s) \frac{Z_C}{Z_M(s) + Z_C} \cdot u_1(s) + \frac{Z_C}{Z_N(s) + Z_C} u_2(s) \right] \quad (4)$$

$$u_r(s) = \frac{p(s)}{1 - \beta_1(s)\beta_2(s)p^2(s)} \left[\beta_1(s)p(s) \frac{Z_C}{Z_N(s) + Z_C} \cdot u_2(s) + \frac{Z_C}{Z_M(s) + Z_C} u_1(s) \right] \quad (5)$$

联立可得特征根方程为:

$$1 - \beta_1(s)\beta_2(s)p^2(s) = 0 \quad (6)$$

$$\beta_1(s) = \frac{Z_M(s) - Z_C}{Z_M(s) + Z_C} \quad (7)$$

$$\beta_2(s) = \frac{Z_N(s) - Z_C}{Z_N(s) + Z_C} \quad (8)$$

$$p(s) = e^{-sT} \quad (9)$$

$$1 - \beta_1\beta_2 e^{-2(\sigma + j\omega_0)T} = 0 \quad (10)$$

式中: σ 和 ω_0 分别为 s 的实部和虚部; T 代表主频率周期。

再将 $e^{j\theta} = \cos\theta + j\sin\theta$ ($\theta = 2k\pi; k = 0, \pm 1, \pm 2, \dots$)代入上式可求得:

$$e^{j2k\pi} = \beta_1\beta_2 e^{-2(\sigma + j\omega_0)T}, k = 0, \pm 1, \pm 2, \dots \quad (11)$$

将 $d = T \cdot v$ 和上述各式特征根方程联立求解,可得当所测线路终端存在电容、电感,以及故障点处存在过渡电阻时,故障距离与线路主频率之间的关系为:

$$d = \begin{cases} \frac{(\varphi + 2k\pi) \cdot v}{2\omega_0}, \text{Re}[\beta_1\beta_2] > 0 \\ \frac{(\varphi + 2k\pi - \pi) \cdot v}{2\omega_0}, \text{Re}[\beta_1\beta_2] < 0 \end{cases} \quad (12)$$

式中: d 表示所测故障距离; v 为故障线路中行波传播速度; φ 表示过渡电阻和线路边界引起的偏移角; ω_0 表示固有主频率。

由式(12)可得故障距离和故障线路固有频率存在实际的联系,因此可以通过提取故障线路固有主频率的方法进行测距。在实际测量过程中,行波存在各种折射和反射的情况,部分分量对系统的固有主频率的干扰十分严重,导致固有主频率难以提取。有研究表明,故障信号行波频谱能量主要集中在主频率附近^[14],能很好的体现固有主频率的特性,且易于提取,故可采用提取行波频谱能量的方法进行故障测距。

3 S变换能量谱故障特征提取

3.1 S变换能量谱故障特征提取

S变换是从短时傅里叶变换(STFT)和连续小波变换继承和发展而来,能准确提取信号在不同频率下的幅值、相位信息。S变换的高斯窗口的高度和宽度随频率而变化,相比STFT而言,具有更高的分辨率以及更好的时频特性。信号 $y(t)$ 的S变换可以定义如下:

$$S(\tau, f) = \int_{-\infty}^{\infty} y(t) \omega(\tau - t, f) e^{-j2\pi ft} dt \quad (13)$$

$$\omega(t - \tau, f) = \frac{|f|}{\sqrt{2\pi}} \exp \left| -\frac{f^2 (\tau - t)^2}{2} \right| \quad (14)$$

式中: τ 表示时移参数; f 为频率; j 为函数虚部单位; $\omega(t - \tau, f)$ 为高斯窗函数。

现设连续信号 $y(t)$ 的离散时间序列函数为 $y[\alpha T]$ ($\alpha = 0, 1, 2, \dots, N-1$),函数 $y[\alpha T]$ 的离散傅里叶变换为 $Y[n/NT]$,其S变换离散表示形式如下:

$$\begin{cases} S\left[\alpha T, \frac{n}{NT}\right] = \sum_{m=0}^{N-1} Y\left[\frac{m+n}{NT}\right] e^{-\frac{2\pi^2 m^2}{n^2} + j\frac{2\pi mk}{N}}, n \neq 0 \\ S[\alpha T, 0] = \frac{1}{N} \sum_{m=0}^{N-1} y\left[\frac{m}{NT}\right], n = 0 \end{cases} \quad (15)$$

式中: N 为采样点数; T 为采样时间间隔。

对离散时间序列函数 $y[\alpha T]$ 进行S变换后,得到了一个复时频S矩阵。矩阵的行代表离散频率,列代表采样时间。其中,S矩阵第 n 行所代表的频率关系式为:

$$f_n = \frac{n}{N} f_s \quad (16)$$

式中: f_s 为系统采样频率。

由于S变换可以精确提取信号 $y_i(t)$ 在不同频率下的幅值信息,现可求得在频率 f_n 下某一采样点的暂态能量表达式为:

$$E_{in} = \sum_{\alpha T} \left[S_i\left(\alpha T, \frac{n}{NT}\right) \right]^2 \quad (17)$$

而单一频率下单一采样点的暂态能量容易受到干扰信号的影响,为提高S变换能量谱分析的准确性,现对频率 f_n 下各采样点的暂态能量求和,可得此频率下的总能量为:

$$W_n = \sum_i \sum_{\alpha T} \left[S_i \left(\alpha T, \frac{n}{NT} \right) \right]^2 \quad (18)$$

3.2 S 变换能量谱

本文选取采样频率 f_s 为 20 kHz, 以过渡电阻 20 Ω 、距线路首端 M 点 200 km 处, 于 1.2 s 发生正极接地故障为例, 先对故障暂态电压进行采样, 由于双极 HVDC 传输线出现接地故障时, 正负极电压信号会出现重耦合现象^[15], 因此需引入 Karenbauer 变换矩阵对其进行解耦, 运算如下:

$$\begin{bmatrix} u_0(t) \\ u_1(t) \end{bmatrix} = S^{-1} \begin{bmatrix} u_+(t) \\ u_-(t) \end{bmatrix} = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} u_+(t) \\ u_-(t) \end{bmatrix} \quad (19)$$

式中: u_0, u_1 分别代表解耦后的零模电压和线模电压; u_+, u_- 分别代表正负极初始电压信号; S 代表解耦矩阵。

由于线模分量比零模分量更稳定, 故选取线模分量进行分析, 通过仿真得到故障线模电压如图 3 所示。




图 3 故障行波线模电压

Fig. 3 Fault line mode voltage waveform

取故障后 5 ms 内故障行波线模分量进行 S 变换分析, 系统线路发生故障后能量频谱如图 4 所示。




图 4 各频率点的能量分布

Fig. 4 Energy distribution at each frequency point

3.3 S 变换能量谱故障特征提取

利用 S 变换有效地将线路故障中不易确定的特征点转化为能量谱中易于观察的特征点。故障行波在主固有频率附近能量集中, 在能量谱中找到能量相对集中的频率点即为主固有频率。由于不同的线路参数会影响固有

频率的数值^[16], 为避免对固有频率的选取造成误判, 现采用能表征故障信号高频和低频区域的“二分法”对各频率区域进行划分, 用多频带区域能量和来表征能量分布特点。此法通过对采样率的输出不断减半, 可将原始信号分为如下 7 个不同的频带区间: d0 区域 (5 kHz, 10 kHz)、d1 区域 (2.5 kHz, 5 kHz)、d2 区域 (1.25 kHz, 2.5 kHz)、d3 区域 (0.625 kHz, 1.25 kHz)、d4 区域 (312.5 Hz, 625 Hz)、d5 区域 (156.25 Hz, 312.5 Hz)、d6 区域 (78.125 Hz, 156.25 Hz), 以及表征低频区的 d7 区域 (0 Hz, 78.125 Hz)。由于雷击对高频区 (d0, d1, d2) 存在能量干扰, 为提高测距普适性, 本文选取 d3~d7 区域分别进行能量求和, 记为 M_h , 即:

$$M_h = \sum_{a \leq n \leq b} W_n \quad h = 3, 4, \dots, 7 \quad (20)$$

式中: h 代表所取频率区域; a 和 b 分别代表各频率区间的下限和上限。

通过式 (20) 可求得各区域能量分布如图 5 所示。




图 5 各频率区间的能量分布

Fig. 5 Energy distribution at each frequency interval

由图 5 可知, 各频率区域的能量和有着明显的差异, 此方法不仅可以有效避免固有频率选取误差, 同时还包含了大量的故障位置信息。现以过渡电阻 10 Ω 、距首端 M 点 100、150、200 km 处分别发生接地故障为例, 利用 S 变换对解耦后的线模电压进行分析, 得到 d3~d7 频率区域能量分布如图 6(a)~(c) 所示。同理, 在距首端 M 点 180 km 处发生接地故障, 以过渡电阻 5、20、50 Ω 为例, 可得到各区域能量分布如图 6(d)~(f) 所示。

由图 6 可知, 在不同的故障距离、不同的过渡电阻下, 每个频率区域的态能量分布规律各不相同。考虑到不同的故障距离和过渡电阻会影响固有频率, 进而影响到各区域的能量值, 所以可以将能量作为故障特征量用于测距。采用 GRNN 算法来拟合电压能量谱和故障距离之间的关系。

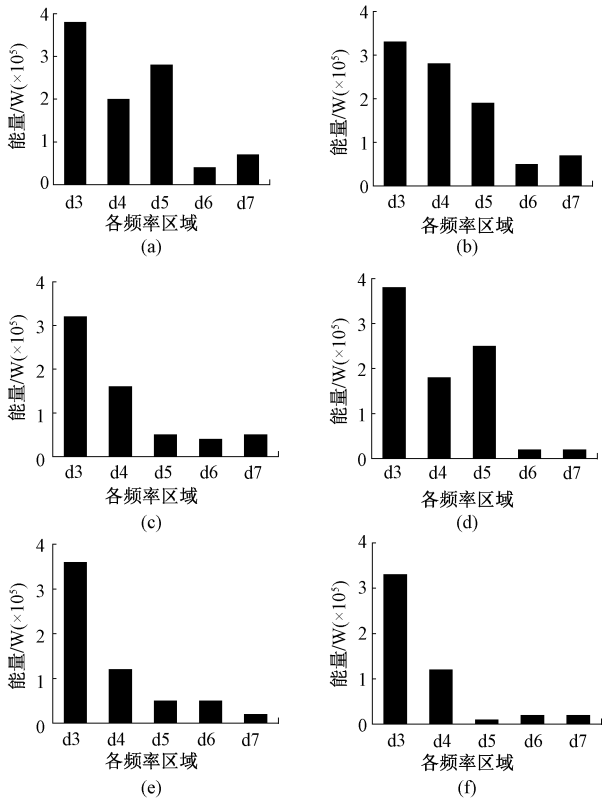


图6 不同故障条件下各频率区间的能量分布
Fig.6 Energy distribution of each frequency interval under different fault conditions

4 GRNN神经网络故障测距算法

4.1 测距样本的选取

为使能量样本充分反应线路故障信息,本文选取d3~d7频率区域各自能量和来表示初始输入矢量,即 $M = [M_3, M_4, M_5, M_6, M_7]$ 。在数据输入到神经网络进行训练之前,为了使各输入量进行网络训练时具有相同的比重,需要对能量数据进行归一化处理,将其变化区间定格在(0,1)范围内。GRNN网络模型要实现的映射关系为:

$$[M_3^*, M_4^*, M_5^*, M_6^*, M_7^*]^T \rightarrow d_0 \quad (21)$$

式中: M_h^* ($h = 3, 4, \dots, 7$) 为各频率区域归一化的能量值; d_0 为输出的故障距离。

4.2 GRNN结构模型

GRNN属于径向基网络的范畴^[17],相比RBF网络而言,GRNN具有非线性映射能力强、拟合速度快、鲁棒性高的特点,特别是只需少量的训练样本,就能取得较好的回归效果。

假设函数 y 及其变量 x 均为随机变量,其联合概率

密度为 $f(x, y)$,若已知 x 的观测值记为 X , y 相对于 x 的值记为 Y ,其期望 \hat{Y} 为:

$$\hat{Y} = E(y | X) = \frac{\int_{-\infty}^{\infty} yf(X, y) dy}{\int_{-\infty}^{\infty} f(X, y) dy} \quad (22)$$

应用parzen非参数估计,则有:

$$\hat{f}(X, Y) = \frac{\sum_{i=1}^n \exp\left[-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2} - \frac{(Y - Y_i)^T}{2\sigma^2}\right]}{n(2\pi)^{(d+1)/2}\sigma^{(d+1)}} \quad (23)$$

式中: σ 为光滑因子; d 为随机变量 x 的维数; n 为学习样本容量。

将式(22) $f(X, y)$ 替换为 $\hat{f}(X, Y)$,整理可得:

$$\hat{Y} = \frac{\sum_{i=1}^n Y_i \exp\left[-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right]}{\sum_{i=1}^n \exp\left[-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right]} \quad (24)$$

设:

$$P_i = \exp\left[-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right] \quad (25)$$

$$S_N = \sum_{i=1}^n Y_i P_i \quad (26)$$

$$S_D = \sum_{i=1}^n P_i \quad (27)$$

将式(26)、(27)代入式(24),可得:

$$\hat{Y} = \frac{S_N}{S_D} \quad (28)$$

此GRNN算法由四层组成,分别为输入层、模式层、求和层和输出层。输入层用于接受学习样本,其神经元数目等于学习样本中输入向量的维数;模式层用于处理样本信息,然后将其结果送入到求和层;求和层对模式层中的输出量分别采用式(26)和(27)进行求和;输出层通过式(28)输出最终结果。

GRNN网络各种神经元之间的连接权值由训练样本决定,光滑因子 σ 是GRNN唯一需要估计的值,因此极大的提高了网络结构设计的严谨性。为提高网络训练效率以及收敛速度,防止网络陷入局部极值点,现采用粒子群算法选择最优的 σ 值。

4.3 PSO-GRNN模型优化

粒子群算法是一种模拟鸟类相互协作寻食的智能算法,它是从随机角度出发,通过迭代寻找最优解^[18]。本文选取实际样本值与预测输出值之间的最小均方误差作为优化光滑因子的目标函数,其表达式为:

$$\text{mine} = \frac{1}{N} \sum_{i=1}^m (\hat{y}_2 - y_i)^2 \quad (29)$$

式中: e 为检测误差; m 为所使用的样本个数。

PSO 的基本模型为假定在 d 维空间中随机分布 n 个粒子, $X_i = (x_{i1}, x_{i2}, \dots, x_{id}) (i = 1, 2, \dots, N)$ 表示第 n 个粒子所处的位置, 将 X_i 代入所需优化的目标函数式(29)中计算其适应度 F_i , 从而确定出粒子在运动过程中所经过的最优点 $P_{bi} = (p_{i1}, p_{i2}, \dots, p_{id})$, 以及所有粒子到目前为止所寻找到的最优点 $P_g = (p_{g1}, p_{g2}, \dots, p_{gd})$, 粒子通过这 2 个最优点来更新自己的位置, 寻找最优解 X_{best} 的关系式如下:

$$v_{id}^{(k+1)} = \omega v_{id}^{(k)} + c_1 r_1 (p_{id}^{(k)} - x_{id}^{(k)}) + c_2 r_2 (p_{gd}^{(k)} - x_{id}^{(k)}) \quad (30)$$

$$x_{id}^{(k+1)} = x_{id}^{(k)} + v_{id}^{(k+1)} \quad (31)$$

式中: $v_{id}^{(k)}$ 表示粒子 i 第 k 次迭代式速度的 d 维分量; ω 是惯性常数; c_1, c_2 是加速常数; r_1, r_2 是均匀分布于 $(0,1)$ 区间, 且相互独立的随机数。采用 PSO 改进 GRNN 网络模型的具体步骤如下:

- 1) 选定 X_i 和 v_{id} 的数值区间, 初始化粒子个体最优点 $P_{b \cdot best}$ 和种群最优点 $P_{g \cdot best}$;
- 2) 对粒子群中各分量和 GRNN 网络输入端口实行参数转化, 然后将训练样本放入神经网络中进行训练, 并计算适应度函数 F_i ;
- 3) 根据 F_i 计算出各粒子的个体最优点 $P_{b \cdot best}$ 和种群最优点 $P_{g \cdot best}$;
- 4) 根据 P_{bi} 和 P_g 更新粒子速度与位置, 不断优化粒子群;
- 5) 如果迭代次数达到设定上限或者满足适应度函数 F_i 时, 搜寻立即结束, 输出最优解, 否则反复执行步骤 3) 和 4), 直到满足最优输出条件。

5 仿真实验

5.1 PSO-GRNN 网络收敛速度与准确性验证

本文利用 PSCAD/EMTDC 搭建如图 1 所示双端柔性直流输电系统仿真模型, 仿真采样频率为 20 kHz, 为使所选测试样本能准确体现各种故障信息, 现以距整流侧首端 5 km 处为初始采样点, 采样步长为 5 km 遍历全线, 过渡电阻选取为 $\{5 \Omega, 10 \Omega, 20 \Omega, 50 \Omega, 100 \Omega, 150 \Omega\}$ 。经整合可得 242 组数据样本。将其前 236 组数据中的初始样本 $[M_3^*, M_4^*, M_5^*, M_6^*, M_7^*]$ 输入到 PSO-GRNN 神经网络中进行训练, 最大训练次数为 500 次, 训练目标误差精度为 0.001, 训练收敛曲线如图 7 所示。PSO-GRNN 网络仅需 243 次训练即可达到所需误差要求, 其收敛速度快。

现以最后 6 组数据对训练好的 PSO-GRNN 网络模型进行精度验证, 其测试结果如表 2 所示。

由表 2 可知, 此方法能对直流输电线路故障进行定位, 耐过渡电阻能力强, 且不受故障距离影响, 故障距离最大误差在 1% 以内, 测距精度较高。




图 7 PSO-GRNN 网络收敛曲线

Fig. 7 PSO-GRNN network convergence curve

表 2 故障测距结果

Table 2 Fault location results

故障距离 /km	过渡电阻 /Ω	测距结果 /km	相对误差 /%	故障距离 /km	过渡电阻 /Ω	测距结果 /km	相对误差 /%
189	5	189.02	0.01	204	5	204.10	0.05
	10	188.88	-0.06		10	203.77	-0.11
	20	189.22	0.12		20	204.40	0.20
	50	187.20	-0.95		50	203.65	-0.17
	100	188.22	-0.41		100	204.33	0.16
	150	189.28	0.15		150	204.24	0.12
194	5	194.06	0.03	209	5	208.85	-0.07
	10	193.92	-0.04		10	209.25	0.12
	20	194.12	0.06		20	209.20	0.10
	50	193.51	-0.25		50	208.45	-0.26
	100	194.21	0.11		100	209.31	0.15
	150	193.10	-0.46		150	208.58	0.20
199	5	198.58	-0.21	214	5	214.27	0.13
	10	198.62	-0.19		10	214.32	0.15
	20	199.49	0.25		20	213.33	-0.31
	50	199.95	0.48		50	213.44	-0.26
	100	200.09	0.55		100	213.40	-0.28
	150	198.30	-0.35		150	214.64	0.30

在实际的电力系统故障检测中, 由于电力互感器自身设计参数和系统的运行工况等因素, 将会导致实际测量误差的产生, 且测量误差一般在 5% 以内。为了更好的反应实际工况, 本文采用 MATLAB 软件产生信噪比范围为 40~50 dB 的高斯白噪声信号加入到训练样本中进行训练, 再将训练好的网络用于鲁棒性检测。现以过渡电阻 50 Ω, 故障点位距首端 100 km 为例, 分别加入 45 dB 信噪比的高斯白噪声进行模拟, 每次引入不同的随机测量误差, 测量 100 次, 仿真结果如图 8 所示。

由图 8 可知, 在存在测量误差的情况下, PSO-GRNN 网络故障定位最大相对误差 < 1.5%, 仍能精确地给出




图8 加入高斯白噪声下的误差结果

Fig. 8 Relative error results under different Gaussian white noise

故障距离,充分体现了网络优良的鲁棒性,具有较高的工程实际运用价值。

5.2 不同测距方法鲁棒性对比

将模型中过渡电阻设为 20Ω , 距测量端 120 km 处发生正极接地短路, 在加入 45 dB 信噪比的高斯白噪声情况下, 与小波包结合 PSO-RBF 故障测距法^[19] (利用小波分解提取各频带能量放入神经网络训练后进行测距) 以及利用数据融合技术提升输电线路故障定位精度的新方法^[20] (利用解析法对数据融合和后的电气量进行求解测距) 进行对比, 每次引入不同的测量随机误差, 通过 20 次测量, 对比结果如图 9 所示。




图9 不同测距方法测距结果对比

Fig. 9 Fault location results under different location algorithm

可见本文所提测距方法鲁棒性更高, 其原因在于 S 变换提取能量的精度远高于小波分解, 且对外界干扰有很好的降噪效果, 能更好的反映能量分布特点; 同时, 以解析法为基础的测距算法无法从原理上避免随机测量误差的影响, 而训练好的神经网络可以逼近任何期望的数学模型, 能极大的提升测距算法的鲁棒性。

6 结论

本文提出了基于 S 变换的 PSO-GRNN 神经网络

故障测距新方法, 并利用 PSCAD 以及 MATLAB 软件进行仿真实验, 结果表明, 1) 利用 S 变换对线路故障暂态电压信号进行能量谱的提取和分析, 能有效去除噪声干扰, 相较小波变换等方法而言, 具有更高的精度和可靠性; 2) 利用 GRNN 神经网络建立回归模型, 有效降低了算法对初始样本的需求量; 3) 采用粒子群算法优化 GRNN 网络参数的方法, 极大的提高了网络的收敛速度, 同时也保留了 GRNN 鲁棒性高的特点, 有效提高了测距算法的抗干扰能力; 4) 此方法与现阶段运用较为广泛的行波法相比, 采样频率要求不高, 且具有较强的耐过渡电阻能力。

参考文献

- [1] 汤广福, 贺之渊, 庞辉. 柔性直流输电技术在全球能源互联网中的应用探讨[J]. 智能电网, 2016, 4(02): 116-123.
TANG G F, HE Z Y, PANG H. Application of Flexible DC Transmission Technology in Global Energy Internet[J]. Smart Grid, 2016, 4(02): 116-123.
- [2] 吕煜, 朱思丞, 汪楠楠, 等. 基于电流突变量的直流电网区内双极短路故障定位方法[J]. 中国电机工程学报, 2019, 39(16): 4686-4694+4971.
LV W, ZHU S C, WANG N N, et al. Bipolar short-circuit fault location method in DC grid based on current sudden change[J]. Proceedings of the CSEE, 2019, 39(16): 4686-4694+4971.
- [3] 杨林, 王宾, 董新洲. 高压直流输电线路故障测距研究综述[J]. 电力系统自动化, 2018, 42(8): 185-191.
YANG L, WANG B, DONG X ZH. Overview of fault location methods in high voltage direct current transmission lines[J]. Automation of Electric Power Systems, 2018, 42(8): 185-191.
- [4] AZIZI S, AFSHARNIA, SANAYE-PASAND M. Fault location on multi-terminal DC systems using synchronized current measurements[J]. International Journal of Electrical Power & Energy Systems, 2014, 63: 779-786.
- [5] 索南加乐, 许文宣, 何世恩, 等. 基于双端电气量的串补输电线路故障测距算法[J]. 中国电机工程学报, 2013, 33(19): 157-164, 7.
SUO N J L, XU W X, HE SH E, et al. A fault location algorithm for series compensated transmission lines based on two-end information[J]. Proceedings of the CSEE, 2013, 33(19): 157-164.
- [6] 王宾, 董新洲, 薄志谦, 等. 特高压长线路单端阻抗法单相接地故障测距[J]. 电力系统自动化, 2008, 32(14): 25-29.

- WANG B, DONG X ZH, BO ZH Q, et al. An impedance fault location algorithm for UHV long transmission lines with single-line-to-ground faults[J]. Automation of Electric Power Systems, 2008, 32(14): 25-29.
- [7] 王宾, 陆元园. 利用多时刻信息的 T 接线路单相接地故障单端测距方法[J]. 中国电机工程学报, 2016, 36(10): 2611-2618.
- WANG B, LU Y Y. Single terminal fault location to single-line-to-ground fault in T transmission line based on sequenced time session data [J]. Proceedings of the CSEE, 2016, 36(10): 2611-2618.
- [8] LAN S, CHEN M J, CHEN D Y. A Novel HVDC Double-terminal Non-Synchronous Fault Location Method based on Convolutional Neural Network [J]. IEEE Transactions on Power Delivery, 2019: 1-1.
- [9] 李炼炼, 蔡炜, 杨黎明, 等. 舟山柔性直流输电工程的直流电缆操作过电压计算与分析[J]. 高电压技术, 2017, 43(11): 3645-3652.
- LI L L, CAI W, YANG L M, et al. Switching over voltage calculation and analysis of DC cables for Zhoushan flexible DC transmission project [J]. High Voltage Technology, 2017, 43(11): 3645-3652.
- [10] 蔡新雷, 宋国兵, 高淑萍, 索南加乐, 李广. 利用电流固有频率的 VSC-HVDC 直流输电线路故障定位[J]. 中国电机工程学报, 2011, 31(28): 112-119.
- CAI X L, SONG G B, GAO SH P, et al. Fault location of VSC-HVDC DC transmission line using current natural frequency [J]. Proceedings of the CSEE, 2011, 31(28): 112-119.
- [11] 李斌, 何佳伟, 李晔, 欧逸哲. 基于边界特性的多端柔性直流配电系统单端量保护方案[J]. 中国电机工程学报, 2016, 36(21): 5741-5749, 6016.
- LI B, HE J W, LI W, OU Y ZH. Single-end quantity protection scheme for multi-terminal flexible DC power distribution system based on boundary characteristics [J]. Proceedings of the CSEE, 2016, 36(21): 5741-5749, 6016.
- [12] 黄忠棋. 采用行波固有频率的混合线路故障测距新方法[J]. 电力系统及其自动化学报, 2015, 27(11): 73-79.
- HUANG ZH Q. A new fault location method for hybrid transmission lines using traveling wave natural frequency [J]. Journal of Electric Power Systems and Automation, 2015, 27(11): 73-79.
- [13] HUANG S F, WANG X G. A fault location scheme based on spectrum characteristic of fault-generated high-frequency transient signals [C]. Power & Energy Society General Meeting. Calgary, AB, Canada: IEEE, 2009: 1-5.
- [14] 刘可真, 束洪春, 于继来, 等. ± 800 kV 特高压直流输电线路故障定位小波能量谱神经网络识别法[J]. 电力自动化设备, 2014, 34(4): 141-147.
- LIU K ZH, SHU H CH, YU J L, et al. Fault location wavelet energy spectrum neural network identification method for ± 800 kV HVDC transmission line [J]. Automation of Electric Power Systems, 2014, 34(4): 141-147.
- [15] ZHANG Y, TAI N L, XU B. Fault analysis and traveling-wave protection scheme for bipolar HVDC lines[J]. IEEE Transactions on Power Delivery, 2012, 27(3): 1583-1591.
- [16] 邹林勇. 利用故障行波固有频率的单端行波故障测距法[D]. 成都: 西南交通大学, 2008.
- WU L Y. A single ended fault location method using travelling wave natural frequencies [D]. Chengdu: Southeast Jiaotong Universities, 2008.
- [17] 王慧莹, 吴亮红, 梅盼盼, 张红强, 周少武. 果蝇优化广义神经网络的风电功率短期预测[J]. 电子测量与仪器学报, 2019, 33(06): 177-183.
- WANG H Y, WU L H, MEI P P, et al. Short-term wind power prediction of Drosophila optimized generalized neural network [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(6): 177-183.
- [18] 宁琦, 耿读艳, 王晨旭, 赵杰, 董嘉冀. 基于多尺度排列熵及 PSO-SVM 的输电线路故障判别[J]. 电子测量与仪器学报, 2019, 33(7): 173-180.
- NING Q, GENG D Y, WANG CH X, et al. Fault Identification of Transmission Lines Based on Multiscale Permutation Entropy and PSO-SVM [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(7): 173-180.
- [19] 徐耀松, 冯明昊, 梁小飞, 等. 小波包结合 PSO-RBF 故障测距法[J/OL]. 电力系统及其自动化学报: 1-8[2019-10-02]. <https://doi.org/10.19635/j.cnki.csu-epsa.000190>.
- XU Y S, FENG M W, LIANG X F, et al. Wavelet packet combined with PSO-RBF fault location method [J/OL]. Proceedings of the CSU-EPSC: 1-8[2019-10-02]. <https://doi.org/10.19635/j.cnki.csu-epsa.000190>.
- [20] 焦在滨, 吴润东, 王钊, 等. 利用数据融合技术提升输电线路故障定位精度的新方法[J]. 中国电机工程学报, 2017, 37(9): 2571-2579.
- JIAO Z B, WU R D, WANG ZH, et al. A novel method to improve the fault location accuracy in transmission line

based on data fusion technology[J]. Proceedings of the CSEE, 2017, 37(9): 2571-2579.

作者简介



徐耀松,2004年于辽宁工程技术大学获得硕士学位,2012年于天津大学获得博士学位,现为辽宁工程技术大学副教授,主要研究方向为智能测控系统设计。

E-mail: 38158183@qq.com

Xu Yaosong received his M. Sc. degree from Liaoning Technical University in 2004, Ph. D. degree from TianJin University in 2012. Now he is an associate professor in Liaoning Technical University. His main research interests

include intelligent measurement and control system design.



唐维,2016年于北京交通大学海滨学院获得学士学位,现为辽宁工程技术大学硕士研究生,主要研究方向为电力系统故障诊断。

E-mail: 973489251@qq.com

Tang Wei received his B. Sc. Degree from Beijing Jiaotong University Haibin College in 2016. Now he is a M. Sc. candidate in Liaoning Technical University. His main research interest includes power system fault diagnosis.