

基于误差修正的电力传感器失调节点定位

失调节点的定位直接影响无线传感器网络在智能电网应用的范围,为了获得理想的电力传感器失调节点定位结果,提出一种基于误差修正的电力传感器失调节点定位方法。首先分析当前电力传感器失调节点定位的研究现状,并指出了当前电力传感器失调节点定位方法存在的问题;然后采用经典DV-Hop算法对失调传感器节点进行初步定位,并采用极限学习机对定位误差进行修正;最后利用Matlab 2014工具箱对电力传感器失调节点定位性能进行测试。结果表明,该方法的电力传感器失调节点定位准确性要优于传统方法,同时加快了电力传感器失调节点定位速度。

菅有为 冯迎春 任庆帅 陈仁刚/国网山东省电力集团公司检修公司

0 引言

随着计算机技术、信息技术以及通信技术的飞速发展和成熟,无线传感器网络随之产生,作为当前一项重要的网络核心技术在许多领域具有广泛的应用前景,如智能电网、环境监测等。在智能电网的实际应用中,无线传感器网络中的节点由于受自身技术、环境的影响,不可避免地会使一些节点失去作用,即节点失调现象,使整个网络生存时间以及信息采集准确性受到影响。为此,如何对电力传感器失调节点进行准确定位十分关键,这也成为当前智能电网管理研究中的热点问题。

为了提高电力传感器失调节点定位的准确性,同时提高智能电网的实际应用价值,国内外研究人员进行了一些探索,构建了一种行之有效的电力传感器失调节点定位算法。当前电力传感器失调节点定位算法有三角法、DV-Hop算法和粒子群优化算法等,各种算法均具有自己的优点,同时亦存在一定的不

足,为此有学者在此基础上进行了一系列的改进,如针对粒子群优化算法易陷入局部极值的缺陷,引入了遗传算法对粒子的最优位置进行交叉和变异操作,在一定程度上提高了电力传感器失调节点定位准确度;文献[1]利用神经网络的自适应拟合能力,引入神经网络对电力传感器失调节点进行定位,但是神经网络要求节点数据相当多,因此定位结果不稳定,且可靠性差,实际应用范围受到一定的限制。文献[2]提出一种基于关联挖掘的电力传感器失调节点定位方法,在DV-Hop算法的基础上引入关联挖掘算法,定位准确度得到了一定程度的改善。

为了获得理想的电力传感器失调节点定位结果,提出一种基于误差修正的电力传感器失调节点定位方法。首先采用经典DV-Hop算法对失调传感器节点进行初步定位,然后采用极限学习机对定位误差进行修正,最后利用Matlab 2014工具箱对电力传感器失调节点定位性能进行测试和分析。

1 误差修正的电力传感器失调节点定位

1.1 DV-Hop算法

在所有传感器节点定位算法中,DV-Hop算法相对更加简单,而且易实现,因此受到了人们的青睐,其工作步骤具体如下:

1) 在传感器节点工作过程中,锚节点的位置信息已经事先知道,锚节点和



菅有为/工程师

关键词/Keywords

传感器节点·
误差修正·
非线性建模·
节点定位·
极限学习机·

待定位传感器节点之间的距离可以通过最小跳数估计得到, 这样每个锚节点在网络不断发出数据包{(ID,(x,y),Hop)}, 待定位传感器节点收到锚节点数据时, 就会记录下锚节点之间的最小跳数, 并转发给其他传感器节点。

2) 根据待定位传感器节点与所有锚节点之间的跳数, 计算它们的平均每跳距离, 具体如下

$$\text{Hopsize}_i = \frac{\sum_{j \neq i} \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}}{\sum_{j \neq i} \text{Hop}_i} \quad (1)$$

式中, (x_i, y_i) 和 (x_j, y_j) 为锚节点 i 、 j 的位置。

3) 通过步骤2) 可以得到待定位传感器节点 $D(x, y)$ 与所有锚节点 (x_1, y_1) , (x_2, y_2) , $\dots$, (x_n, y_n) 之间的距离分别为 $d_1, d_2, \dots, d_n$, 则有

$$\begin{cases} \sqrt{(x - x_1)^2 + (y - y_1)^2} = d_1 \\ \sqrt{(x - x_2)^2 + (y - y_2)^2} = d_2 \\ \vdots \\ \sqrt{(x - x_n)^2 + (y - y_n)^2} = d_n \end{cases} \quad (2)$$

在定位过程中, 难免会产生一些随机误差 ε , 则可以建立如下线性方程组

$$\mathbf{AX} + \varepsilon = \mathbf{b} \quad (3)$$

$$\text{式中, } \mathbf{A} = \begin{pmatrix} 2(x_1 - x_n) & 2(y_1 - y_n) \\ 2(x_2 - x_n) & 2(y_2 - y_n) \\ \vdots & \vdots \\ 2(x_{n-1} - x_n) & 2(y_{n-1} - y_n) \end{pmatrix};$$

$$\mathbf{b} = \begin{pmatrix} x_1^2 - x_n^2 + y_1^2 - y_n^2 - d_1^2 + d_n^2 \\ x_2^2 - x_n^2 + y_2^2 - y_n^2 - d_2^2 + d_n^2 \\ \vdots \\ x_{n-1}^2 - x_n^2 + y_{n-1}^2 - y_n^2 - d_{n-1}^2 + d_n^2 \end{pmatrix}; \quad \mathbf{X} = \begin{pmatrix} x \\ y \end{pmatrix}。$$

采用LS算法对式(3)进行求解, 可以得到^[3]

$$\mathbf{X} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{b} \quad (4)$$

1.2 极限学习机

对于数据: $\mathbf{N}_N = \{(x_i, t_i)\}_{i=1}^N$, $x_i \in \mathbb{R}$, $t_i \in \mathbb{R}$, 极限学习机根据结构风险最小化原理, 泛化能力好, 这样极限学习机可以将一个回归问题转化为^[4]

$$\min \left(\frac{1}{2} \beta_N^T \beta_N + \frac{\gamma}{2} \varepsilon^T \varepsilon \right)$$

$$\text{s. t.} \quad (5)$$

$$t_j = \sum_{i=1}^L \beta_i g(a_i x_j + b_i) - \varepsilon_j$$

式中, $g()$ 为激活函数; L 为隐含层神经元数量; $a_i = [a_{i1}, a_{i2}, \dots, a_{in}]$ 和 $\beta_N = [\beta_1, \beta_2, \dots, \beta_L]^T$ 分别为隐含层的输入和输出权值。

为了对式(5)进行求解, 引入拉格朗日乘子, 建立如下函数

$$L(w, \varepsilon, \beta_N) = \frac{1}{2} \beta_N^T \beta_N + \frac{\gamma}{2} \varepsilon^T \varepsilon - w(H_N \beta_N - T_N - \varepsilon) \quad (6)$$

式中, $w = [w_1, w_2, \dots, w_N]$ 为权值, 且有 $\mathbf{H}_N =$

$$\begin{pmatrix} G(a_1 x_1 + b_1) & \dots & G(a_L x_1 + b_L) \\ \mathbf{M} & \dots & \mathbf{M} \\ G(a_1 x_N + b_1) & \dots & G(a_L x_N + b_L) \end{pmatrix}, \quad \mathbf{T}_N = [t_1, t_2, \dots, t_N]^T。$$

对式(5)中的各变量求偏导, 可得 β_N 的解 $\tilde{\beta}_N$ 为

$$\tilde{\beta}_N = \left(\mathbf{H}_N^T \mathbf{T}_N + \frac{1}{\gamma} \right) - \mathbf{H}_N^T \mathbf{T}_N \quad (7)$$

式中, $I \in \mathbb{R}^{L \times L}$; $\tilde{\beta}_N = [\tilde{\beta}_1, \tilde{\beta}_2, \dots, \tilde{\beta}_L]^T$ 。

最后, 可以得到极限学习的回归模型为

$$v = \sum_{i=1}^L \tilde{\beta}_i G(a_i u + b_i) \quad (8)$$

1.3 误差修改的失调节点定位

由于锚节点 (x_i, y_i) , $i = 1, 2, \dots, n$, 与待定位节点 (x, y) 的实际距离为 r_i , $i = 1, 2, \dots, n$, 那么 $|r_i - d_i| < \varepsilon_i$, 而且 (x, y) 满足如下条件

$$\begin{cases} d_1^2 - \varepsilon_1^2 \leq (x_1 - x)^2 + (y_1 - y)^2 \leq d_1^2 + \varepsilon_1^2 \\ d_2^2 - \varepsilon_2^2 \leq (x_2 - x)^2 + (y_2 - y)^2 \leq d_2^2 + \varepsilon_2^2 \\ \vdots \\ d_n^2 - \varepsilon_n^2 \leq (x_n - x)^2 + (y_n - y)^2 \leq d_n^2 + \varepsilon_n^2 \end{cases} \quad (9)$$

对 (x, y) 的值进行估计, 可以得到

$$f(x, y) = \sum_{i=1}^n \sqrt{(x_i - x)^2 + (y_i - y)^2 - d_i^2} \quad (10)$$

本文将极限学习机与DV-Hop算法相结合, 提出了一种基于误差修正的电力传感器失调节点定位算法, 以提高定位的准确性和可靠性, 具体工作流程如图1所示。




图1 误差修正定位算法的工作流程

2 电力传感器失调节点定位的仿真测试

2.1 实验环境

为了测试本文算法的电力传感器失调节点定位性能,利用Matlab 2014工具箱进行仿真测试,无线传感器网络的参数设置如下表所示。

表 无线传感器网络的相关设置

参数	参数值
监测范围/m × m	100 × 100
传感节点数	100
通信半径/m	5~20
锚节点数量	10~30
仿真时间/s	100

为了使本文算法的结果具有可比性,采用单一DV-Hop算法和极限学习机实现电力传感器节点定位对比实验,并采用定位误差(error)分析其优劣,error计算公式为

$$\text{error} = \frac{1}{M} \sum_{i=1}^M \sqrt{(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2} \times 100\% \quad (11)$$

2.2 结果与分析

所有算法的电力传感器失调节点定位结果的误差对比如图2所示。从图2的误差变化过程可知,本文算法的电力传感器失调节点定位误差要比单一DV-Hop算法和极限学习机少得多,而且电力传感器失调节点定位的准确性相当高,具有十分显著的定位优越性,因此可以获得更加理想的电力传感器失调节点定位结果。




图2 电力传感器失调节点定位误差对比

3 结束语

针对传统方法的电力传感器失调节点定位误差大、可靠性低的缺陷,提出了一种误差修改的电力传感器失调节点定位算法,采用具体仿真实验可以得到如下结论:

1) 由于电力传感器失调节点定位的特殊性,经典DV-Hop算法无法准确找到电力传感器失调节点位置,而且定位时间长,定位效率低。

2) 通过引入误差修改的理念,采用极限学习机对经典DV-Hop算法的定位进行修正,定位准确性得到了显著的改善,定位误差明显低于其他电力传感器失调节点定位算法,定位结果更加可靠、有说服力,在智能电网管理中具有广泛的应用前景。

参考文献

- [1] 吴健,赵德光,张志杰. 基于神经网络的传感器动态补偿算法及DSP实现[J]. 计算机测量与控制, 2011, 21(5): 1239-1242.
- [2] 吴健,张志杰,王文廉. 传感器动态误差高速并行修正方法及其FPGA实现[J]. 传感技术学报, 2012, 25(1): 67-71.
- [3] Fang Wei, Sun Jun, Xu Wenbo. A new mutated quantum-behaved particle swarm optimizer for digital IIR filter design[J]. EUROPP Journal on Advances in Signal Processing, 2009, 10(2): 1-7.
- [4] Liu N, Wang H. Ensemble based extreme learning machine[J]. IEEE Signal Processing Letters, 2010, 17(8): 754-757.

(收稿日期: 2015-08-14) EA