

引用格式:梁俊卿,赵建视,吕笑琳. 基于邻里支持和神经网络的 WSN 数据融合算法研究[J]. 微电子学与计算机,2019,36(8):87-91. [LIANG J Q,ZHAO J S,LYU X L. Data aggregation of WSN based on neighborhood support and BP neural network [J]. Microelectronics & Computer,2019,36(8): 87-91.]

基于邻里支持和神经网络的 WSN 数据融合算法研究

梁俊卿,赵建视,吕笑琳

(青岛理工大学 信息与控制工程学院,山东 青岛 266033)

摘 要: 为了提高无线传感器网络(wireless sensor network, WSN)的可靠性、稳健性、减少错误及冗余信息的传输,提出了一种基于邻里支持度的动态分簇 BP(Back Propagation)神经网络数据融合算法(Neighborhood-Support-Back-Propagation Networks Data Aggregation, NBNDA). 其中动态分簇以及簇首的选择基于邻里支持度的大小以及节点的剩余能量等. 同时,为了减少 WSN 中的通信量,在簇首处使用三层神经网络进行监测数据的特征提取,然后将特征值发送至汇聚节点. 仿真实验表明,与 LEACH 协议相比,本文算法不仅能够提高 WSN 的可靠性和稳健性,又能减少数据冗余,延长网络寿命.

关键词: 无线传感器网络;数据融合;邻里支持度;BP 神经网络

中图分类号: TP393

文献标识码: A

文章编号: 1000—7180(2019)08—0087—05

Data aggregation of WSN based on neighborhood support and BP neural network

LIANG Jun-qing, ZHAO Jian-shi, LYU Xiao-lin

(School of Information and Control Engineering, Qingdao University of Technology, Qingdao 266033, China)

Abstract: To improve wireless sensor network (WSN) reliability, robustness and reduce error and redundant information transmission. A dynamic clustering BP neural network Data Aggregation algorithm based on neighborhood support is proposed. The dynamic clustering and the selection of cluster head are based on the state of the node, the neighborhood support and the residual energy of the node. At the same time, in order to reduce communications in WSN, the cluster head uses three-layer neural network for feature extraction of monitoring data, and then sends the feature value to the sink node. Simulation results show that this algorithm can not only improve the reliability and robustness of WSN, but also reduce data redundancy and extend the network life compared with the classic clustering protocol LEACH.

Key words: WSN; data aggregation; neighborhood support; BP neural network

1 引言

随着 WSN 技术的不断发展,越来越多的学者加入到 WSN 关键技术的研究. 文献[1]将神经模糊优化模型(RNFOM)应用到 WSN 的数据融合中,以提高监测数据的可靠性. 但其没有考虑到传感器能

量不足的问题. 文献[2]通过设置阈值,在用户感兴趣的事件发生时相关节点才进入正常工作状态. 从而,减少了冗余数据的传输,降低了能量消耗. 文献[3]在节点采集数据时,仅当数据异常时才进行数据的传输,降低了能量的消耗. 文献[4]将 NARX 神经网络时序预测模型和基于矢量量化的分簇路由协议

有机结合,从时间和空间相关性上消除冗余.文献[5]将经典的分簇路由和 BP 神经网络相结合,通过 BP 神经网络提取原始数据的少量特征,以减少网络通信量.文献[6]将自组织映射神经网络和经典的分簇路由协议相结合,提取同类数据的特征,减少了网络通信量.

针对以上问题及分析,本文提出了一套基于邻里支持度和神经网络的数据融合算法,简称 NBN-DA 算法.

2 基于邻里支持度的改进分簇算法

LEACH 协议主要是为了解决节约能源和减少通信能量消耗的问题而提出的一种协议.但是,其没有考虑到传感器由于处于恶劣环境,而带来的噪声干扰的问题.也没有考虑到冗余数据的转发造成的通信带宽的增加的问题.为了解决上述问题,本文提出邻里支持度 NS(Neighbourhood Support)并应用于无线传感网络.旨在减少数据冗余的同时提高了监测数据的可靠性,以降低能耗和提高检测数据的精度.

2.1 WSN 模型

为了方便讨论,本文假设在某感知区域 Area 内随机分布 s 个无线传感器.该无线传感器网络具有如下特点:

- (1)节点按一定密度部署后将被固定不变.
- (2)传感器节点初始能量相同,且不能补给.
- (3)汇聚节点部署在感知区域 Area 外且唯一.
- (4)汇聚节点能量充沛且可以持续补给.有足够大的功率向所有节点传送消息,而其余节点发射功率有限.
- (5)节点可以获取其相对位置.

其中前 4 项为 WSN 的典型设置.第 5 项十分重要,因为,节点通常需要获取其位置信息.尤其是在进行计算邻里支持度的时候,需要根据传感器位置判断其邻里节点.

2.2 邻里支持度模型定义

为了获取邻里支持度,首先需要建立邻里支持模型.在感知区域 Area 内,传感器节点 s_j 的邻里为与传感器 s_i 距离小于等于半径 r 的所有传感器节点,表示为式(1)所示.其中, r 根据具体的应用设置.

$$N_{s_j} = \{s_j \mid dis(s_j, s_i) \leq r\} \quad (1)$$

式中, $dis(s_j, s_i)$ 为传感器节点 s_j 与 s_i 之间的距离,计算公式为式(2)所示:

$$dis(s_j, s_i) = \sqrt{(s_{j_x} - s_{i_x})^2 + (s_{j_y} - s_{i_y})^2} \quad (2)$$

式中, s_{j_x}, s_{i_x} 分别为 j 传感器和 i 传感器的横坐标; s_{j_y}, s_{i_y} 分别为 j 传感器和 i 传感器的纵坐标.

对于任意的具有 k 种传感器的节点,根据硬阈值 HT、软阈值 ST 和邻里支持度阈值 th,传感器节点可以分为如下 4 种状态.

C_1 (正常).判断其检测值 data 是否大于硬阈值 HT,如果大于硬阈值 HT,转入 C_1 状态.如果小于硬阈值,保持 C_1 状态.

C_2 (可疑).判断检测值与硬阈值的差是否大于软阈值 ST,如果大于软阈值 ST,保持 C_2 状态,待异常解除后转入 C_1 状态.如果小于软阈值,转入 C_1 状态.

当传感器出现可疑状态时,该传感器自动检测其邻里支持度,邻里支持度的计算方法为式(3)所示:

$$NS = i/j \quad (3)$$

式中, i 为该节点邻里中处于 C_2 状态的节点数; j 表示该节点邻里的总数.

C_3 (异常).如果邻里支持度大于阈值 TH,则表明该节点存在异常,保持 C_3 状态,直至异常解除.

C_4 (误报).如果邻里支持度小于支持度阈值 TH,则表明该节点不存在异常状态.

2.3 基于邻里支持度的动态分簇算法

无线传感器网络中的经典分簇路由都是提前规划好簇的结构,他们只是仅仅考虑到能量,相对位置等因素.很少有文献考虑到检测数据的精确度以及簇与簇之间存在对同一区域检测的重复而造成的数据冗余的问题.本文在保证精确度的同时,尽量减少数据冗余.提出了基于邻里支持度的动态分簇算法.并且,为了防止当选簇头因为能量不足而导致结点过早死亡,本文设置能量阈值 E_l ,当节点剩余能量 E_r 大于 E_l 时,才能当选簇头.

详细分簇算法如下:

(1)初始化:汇聚节点根据单跳通信的方式向节点发送汇聚节点位置信息,节点根据汇聚节点发送的位置信息,获取自己的位置信息.获取自己位置信息后,通过简单的信息交换和 1.2 节介绍的方法计算并判断其邻里节点.节点初始化后,无线传感器网络不进行分簇.每个节点处于 C_1 (正常)状态.

(2)当检测区域的某个传感器,其检测值 data 大于等于硬阈值 HT 时,即 $data \geq HT$,该传感器从 C_1 状态变为 C_2 状态.然后判断其检测值 data 与硬阈值的差是否大于等于软阈值,即 $data - HT \geq$

ST,如果小于,该传感器保持 C_1 状态.如果大于等于,保持状态 C_2 .再然后,计算其邻里支持度 NS,如果其邻里支持度大于设定的邻里支持度阈值,即 $NS \geq th$ 且 $E_r \geq E_l$ 该节点成为簇头,并向周围节点广播其成簇信息.为了方便讨论成簇生命周期和成簇广播跳数,引入评判标准式,考虑到节点支持度和节点剩余能量,用式(4)表示.

$$EC = \alpha \cdot NS + \beta \cdot E_r \quad (4)$$

式中, α 和 β 为常量.

成簇的生命周期用 CT 表示,计算表达式如式(5)所示.

$$CT = \gamma \cdot EC \quad (5)$$

式中, γ 为成簇周期系数.

节点成簇后广播其成簇跳 H,计算表达式如式(6)所示.

$$H = \delta \cdot EC \quad (6)$$

式中, δ 为成簇跳数系数.

(3)簇头节点完成上述步骤后,向周围广播其成簇信息.包括簇头的标志、身份、跳数 H、成簇周期 CT、评判标准式 EC 以及节点剩余能量 E_r .

(4)当周围节点收到簇头节点的成簇消息后,由于在同一区域内节点处于四种不同的状态,正常、可疑、异常以及误报.每种状态的传感器会做出不同的响应,加入最合适的簇.具体转化活动如下所示:

(1)正常:处于正常状态的节点只负责数据的传输,其本身并不采集数据.

(2)可疑:处于可疑状态的节点先判断是否 $H-1 > 0$,如果大于,节点修改 H 值并转发其消息.如果节点同时接收到相同簇头的成簇信息后,优先选择 H 值较大的路径成簇.

(3)异常:与 b 相同.

(4)误报:处于误报状态的节点,不加入簇.

(5)如果在邻近区域内有多个处于异常状态节点要求成簇.在其成簇过程中,已经成簇的节点会根据自身情况,包括其支持度 NS,成簇周期 CT,评判标准式 EC 以及节点剩余能量 E_r 等,来考虑是不是放弃其簇头身份并加入优于其自身情况的簇头,选择加入.并且其簇成员也不会因其 TH 大而形成新的簇头.

(6)如果簇形成的时间 T 大于簇的生命周期 CT,则簇内所有节点包括簇头节点都转为 C_1 正常状态.当有新的节点的邻里支持度大于设置的邻里支持度阈值 TH 时,重新竞争簇头并形成簇.

3 基于邻里支持度动态分簇算法和 BP 神经网络的数据融合算法

神经网络算法是具有适应性的简单单元组成的广泛并行互连的网络^[7].其感知层的每个神经元对应着无线传感器网络的离散分布的传感器.能够并行处理大量离散型数据.通过 BP 神经网络算法进行数据的融合能够把多个传感器的检测值转换为一个能够代表该簇的情况的特征值,簇头节点将该特征值传输至汇聚节点.以进一步减少数据传输.本文将 2.3 节介绍的基于邻里支持度的动态分簇算法与 BP 神经网络算法进行结合,提出了一种新的数据融合算法 NBND A.

研究表明,BP 神经网络的隐藏层的神经元的个数只要足够多,就有处理任意非线性函数的能力^[8].本文提出的 NBND A 算法使用三层神经网络,即输入层,隐含层以及输出层来处理簇内数据.输入层存在于簇成员节点内,仅仅是接受数据并把数据传输到簇头节点而其本身并不进行数据处理,隐含层和输出层存在于簇头结点,都是拥有激活函数的功能神经元.隐含层我们选用 tansig 函数,函数模型为式(7)所示:

$$f(x) = (1 - e^{-x}) / (1 + e^{-x}) \quad (7)$$

输出层选用线性函数作为激活函数函数,函数模型为式(8)所示:

$$f(x) = ax + b \quad (8)$$

假设簇结构内有 m 个传感器,则输入层的神经元个数为 m ,输出层具有 n 个神经元, n 的取值根据具体应用来设置.用试用法计算隐含层的神经元个数 k .计算公式如式(9)所示.

$$k = \sqrt{m + n} + \theta \quad (9)$$

式中, θ 为常量,取值范围为 $[1, 10]$.簇头节点首先对簇成员节点进行数据预处理,然后通过训练好的神经网络的隐含层和输出层对数据进行处理,得到相对精确的特征值,并传输到汇聚节点,NBND A 的模型如图 1 所示:

神经网络模型建好后,需要训练网络参数即神经元之间的权值和偏值.为了减少簇头承担的任务过多,而过早的死亡,将训练参数的任务交给汇聚节点.汇聚节点根据样本数据库进行神经网络训练,并将训练好的权值和阈值发送给簇头.具体流程如图 2 所示.

4 实验分析

本文提出的 NBND A 算法,弥补了 LEACH 协




图1 NBND 数据融合模型




图2 BP 神经网络训练流程图

议的抗噪能力不足的问题. 首先根据传感器的状态建立簇结构,抑制了处于正常状态的节点采集并传输冗余信息. 同时加入 BP 神经网络进行数据的融合,通过 BP 神经网络提取簇内传感器节点检测值的特征值并由簇头向汇聚节点传输. 大大减少了数据的冗余,从而减少数据传输量,进而节省了能量的消耗. 为了分析和比较 NBND 的性能,本文使用 MATLAB2015a 对改进的 NBND 进行仿真,同时与 LEACH 协议进行比较. 主要从精确度和耗电量两个性能指标来考虑. 本文以环境监测为应用场景,本实验设计的传感器为温度传感器来采集温度. 本实验的设置参数如表 1 所示.

为了测试 NBND 的性能,假设 LEACH 协议和 NBND 算法不受数据融合的影响,在检测区域内随机部署 5 个受损坏的传感器节点. 图 3 显示在不同允许的误差阈值下两种算法检测数据的精确度. NBND 的精确度明显高于 LEACH. 在整体数

据上取平均值,本文算法比 LEACH 精确度高 10% 左右,说明本文算法具有一定的抗噪能力.

表 1 实验参数

参数	参数取值
网络范围	100 m × 100 m
节点数	100
汇聚节点坐标	(50,175)
节点初始能量	2 J
广播包长度	25 byte
数据包长度	500 byte
包头长度	25 byte
电路损耗能量	50 nJ/bit
邻里支持度阈值	80%
判定邻里的距离 r	5 m
节点通信距离	30 m
仿真时间	1000 s




图3 在不同允许误差阈值下的检测数据的精确度

无线传感器节点的能耗主要来自无线传感器的节点之间通信带来的能耗. 为了减少能耗,本文提出的 NBND 首先根据传感器的状态建立簇结构,然后构建 BP 神经网络进行数据融合. 大大减少了簇头节点的能量消耗. 图 4 显示 NBND 算法和 LEACH 协议随着运行时间的增加,传感器节点平均能量消耗. 从图中可以看出,使用本文算法,传感节点的平均能量消耗低于使用 LEACH 协议. 在运行到 700 秒时,使用 LEACH 协议的节点平均能量消耗达到了本文设置的节点能量,换言之,节点已经死亡. 在运行至 900 秒时,使用本文算法的节点平均能量消耗才达到本文设置的节点能量. 在传感器生命周期上增加了 200 秒左右. 说明使用本文算法在一定程度上减少了传感器的能量消耗,增加了传感器网络的使用寿命.




图 4 网络节点平均能耗

5 结束语

本文提出了基于邻里支持度和 BP 神经网络的数据融合算法 NBNDA,该算法以本文提出的基于邻里支持度的动态分簇算法进行分簇,在簇内使用 BP 神经网络提取检测数据的特征值.仿真实验表明,该算法具有一定的抗噪能力,提高了监测数据的精确度.同时,减少数据的传输量,降低了传感器节点的能量消耗.

参考文献:

[1] ACHARYA S,TRIPATHY C R. A reliable fault-tolerantANFIS model based data aggregation scheme for Wireless Sensor Networks[J]. Journal of King Saud University - Computer and Information Sciences,2017, 11(1):1319-1322.

[2] 余修武,张枫,周利兴,等. WSN 中事件驱动与信任分配加权的层次数据融合[J]. 传感技术学报,2017, 30(12):1948-1953.

[3] 谭德坤,付雪峰,赵嘉,等. 基于异常数据驱动的 WSN 簇内数据融合方法[J]. 传感技术学报. 2017, 30(2): 306-312.

[4] 范时平,何超杰. 基于 NARX 神经网络的分簇数据融合算法[J]. 计算机工程与设计,2018,39(4):938-942.

[5] 孙凌逸,黄先祥,蔡伟,等. 基于神经网络的无线传感器网络数据融合算法[J]. 传感技术学报, 2011, 24(1): 122-127.

[6] 杨永健,刘帅. 基于 SOFM 神经网络的无线传感器网络数据融合算法[J]. 传感技术学报, 2013, 26(12): 1757-1763.

[7] 张浩,张静静. 无线传感器网络数据融合算法综述[J]. 软件,2017,38(12):296-304.

[8] DING S F,SU C Y,YU J Z. An optimizing BP neural-network algorithm based on genetic algorithm[J]. Artificial Intelligence Review, 2011, 36(2):153-162.

作者简介:

梁俊卿 女,(1977-),硕士,副教授. 研究方向为物联网、智能信息处.

赵建视(通讯作者) 男,(1991-),硕士研究生. 研究方向为无线传感器网络、机器学习.

E-mail: hnzhaojianshi@gmail. com.

吕笑琳 女,(1995-),硕士研究生. 研究方向为机器学习、智能信息处理.