

# 无线传感器网络异构数据融合模型优化研究

黄婷婷 冯 锋

宁夏大学信息工程学院 银川 750021

(2375975726@qq.com)

**摘要** 针对无线传感网中存在的能耗和网络的安全性等问题,从数据融合的角度出发,提出一种无线传感器网络数据融合模型。模型引入信息熵来实现一种新的信任度的计算方式,配合对异常数据的监测及过滤方式建立信任机制,通过信任机制来提高无线传感器网络的安全性和可靠性;采用混合簇结构来减少网络时延,降低系统能耗;根据节点的剩余能量、节点到基站的距离以及信任度等因素来完成对簇头的阶段性重选,通过对节点的阶段性重选达到负载均衡、延长网络生命周期的目的;为解决无迹卡尔曼滤波在强非线性系统中估计效果差和滤波发散的问题,该算法将无迹卡尔曼滤波算法叠加使用,同时在第一次使用无迹卡尔曼滤波时在观测噪声协方差矩阵中引入衰减因子。算法的仿真结果表明,相比于传统算法,所提算法提高了滤波结果的精度。

**关键词:** 多传感器数据融合;信任机制;混合簇结构;无迹卡尔曼滤波;算法优化

**中图分类号** TP212.9

## Study on Optimization of Heterogeneous Data Fusion Model in Wireless Sensor Network

HUANG Ting-ting and FENG Feng

School of Information Engineering, Ningxia University, Yinchuan 750021, China

**Abstract** Aiming at the problems of energy consumption and network security in wireless sensor network, this paper proposes a data fusion model of wireless sensor network from the point of view of data fusion. The model introduces information entropy to realize a new way of calculating trust degree, completes the establishment of trust mechanism with monitoring and filtering of abnormal data, and improves the security and reliability of wireless sensor network through trust mechanism. In order to solve the problem of poor estimation effect and filtering divergence in strong nonlinear systems, the unscented Kalman filter algorithm is super imposed and the attenuation factor is introduced in the observation noise covariance matrix when the unscented Kalman filter is used for the first time. The simulation results show that the proposed algorithm improves the accuracy of filtering results compared with the traditional algorithm.

**Keywords** Multi-sensor data fusion, Trust mechanism, Mixed cluster structure, Unscented Kalman filter, Algorithm optimization

### 1 引言

随着信息技术的发展,网络规模也在逐渐增大,无线传感器网络中的节点数量也会增加。一般情况下,无线传感器网络中的节点设备都是采用电池进行供电的,网络中节点之间的数据传输需要消耗非常多的能量,电池的电量都是有限的,这就导致传感器网络整体的运行时间有限。若要延长网络寿命,降低网络能耗是最便利的手段。在把节点采集到的原始数据发送至汇聚节点前,可以通过数据融合技术先对其进行内部融合处理,剔除冗余信息后,再把精简后的有效数据发送至汇聚节点<sup>[1]</sup>。虽然采用数据融合技术来处理数据增加了节点的计算能耗,但传输能耗远高于计算能耗<sup>[2]</sup>,同时该技术在很大程度上减少了传递过程中的冗余数据、传输次数和通信开销,同时也减少了网络拥堵情况的发生,从而降低了系统能耗,延长了网络生存周期。

Zou<sup>[1]</sup>提出了一种基于动态最优权重分配的网内数据融

合算法(DOWA),该算法根据总均方误差最小的最优条件,用最小方差法来实现最优权重的动态分配,从而使得融合后的数据最优。Liu等<sup>[2]</sup>提出了一种基于混合延迟感知聚类(HDC)的无线传感器网络智能数据融合算法来降低网络的能耗,实现负载均衡。Qiu达等<sup>[3]</sup>引入深度学习模型,提出一种将层叠自动编码器(SAE)和分簇协议相结合的数据融合算法SAEMDA,该算法在各个簇内构建特征提取分类模型SAEM,通过SAEM对节点数据进行特征提取和分类,之后将同类特征融合并发送给汇聚节点。Zhang等<sup>[4]</sup>提出一种基于信任和权重的无线传感器网络数据融合模型(TWDFM)。在该模型中,传感器节点通过构建信任表选举可靠簇头,簇头根据权重检测异常节点并融合可信数据。Liang等<sup>[6]</sup>提出了一种基于遗传算法的数据融合方法,并在合理范围内以最小的基尼系数熵进行数据融合。Ye等<sup>[7]</sup>为了抵御无线传感器网络内部的恶意攻击行为和故障节点的误操作行为对数据融合结果的影响,提出一种基于信任模型的多层不均匀分簇无

基金项目:国家自然科学基金(71561023);宁夏重点研发计划重点项目(2018BFG02003)

This work was supported by the National Natural Science Foundation of China (71561023) and Ningxia Key R&D Program Key Project (2018BFG02003).

通信作者:冯锋(2375975726@qq.com)

线传感器网络安全数据融合算法。Gao 等<sup>[8]</sup>针对多传感器非线性随机系统,提出了一种基于自适应衰落无迹卡尔曼滤波的数据融合方法。该方法采用两层融合结构,有效地避免了过程建模误差对融合结果的影响,提高了非线性随机系统数据融合的适应性和鲁棒性。Sun 等<sup>[10]</sup>针对无线传感器网络数据融合精度低、稳定性差的问题,提出了一种基于信任度和改进遗传算法的多传感器数据融合算法。DAS 等<sup>[11]</sup>提出了一种基于贝叶斯方法和蚁群优化技术的无线传感器网络多传感器数据融合方法,该方法提高了信息的可靠性和准确性,同时降低了系统能耗,延长了网络的整体生存周期。Gao<sup>[12]</sup>针对高可信的物联网数据聚合问题,提出了基于上下文感知和数据密度相关度的可信数据聚合算法。该算法提高了数据可信度计算的准确性和恶意攻击下系统抗攻击的能力以及网络吞吐量。

在无线传感器网络中,除了能耗问题,还存在融合后数据的真实性和安全性问题。无线传感器节点受一些环境因素的影响,采集到的数据不一定真实有效,有些可能是虚假信息<sup>[13]</sup>。这些因素在数据融合过程中,都需要考虑到。但现存的很多数据融合算法在进行数据融合处理时,单纯注重降冗率,而忽视了其他方面的影响,如融合后数据的质量和可靠性、系统的生命周期、网络的整体安全性以及负载均衡和网络延迟等因素。

本文针对上述问题,从延长网络生存周期、提升网络整体安全性能出发,提出了一种改进的无线传感器网络数据融合模型,旨在解决现存的数据融合方法的不足,提高数据采集精准度和融合后数据的质量,减少网络整体能耗,最大可能提升网络安全性和可靠性,同时实现网络负载均衡,减小网络时延,将各方面的性能折中,从各个方面提升数据融合的效果,从而提高网络的整体性能。

## 2 融合模型的分析与设计

### 2.1 模型结构设计

在数据融合模型中,不仅要考虑数据的降冗率,还要考虑数据融合后的数据质量和精准度;由于无线传感器网络的特殊性,降低能量开销、延长网络生命周期也是数据融合过程中必须考虑到的一个问题。现存的数据融合模型,大部分忽略了数据融合后网络的整体安全性以及可靠性。本文提出的数据融合模型,尽可能将降冗率、数据精度、网络生命周期、负载均衡、网络整体安全性和可靠性、网络延迟性能进行折中,从数据融合过程中能考虑到的各方面出发,提高网络的整体性能。现存的数据融合技术对数据的降冗率和数据精度已经有了很大程度的改善,本文提出的数据融合模型旨在降低能耗,延长网络生命周期,实现网络负载均衡,减少网络延迟,提高网络整体安全性。

本模型主要通过簇结构的设计、簇头的选举和阶段性自适应重选来减少能量损耗,延长网络的生存周期,同时实现网络负载均衡,减少网络延迟。对于提高网络整体安全性和可靠性,本文设定了一种信任机制,与簇结构的选择和簇头的选举配合使用,从各个阶段提高网络的安全性。

#### 2.1.1 信任机制的设定

在无线传感器网络中,通过观察某个节点过去的行为,将信任度作为某个节点可靠性的预测<sup>[4]</sup>。节点信任度主要涉及包转发及是否存在包修改或者包地址修改的情况,通常这

些信息都可以通过监听转发过程的应答来掌握。对于信任机制的建立,完成对节点信任度计算的同时,对异常数据的过滤也是不容忽视的过程。

$$t_i = \omega_{i1} * \frac{f_i}{r_i} + \omega_{i2} * (1 - \frac{dm_i}{f_i}) + \omega_{i3} * (1 - \frac{am_i}{f_i}) \quad (1)$$

本模型中对节点信任度的计算主要通过式(1)完成,式(1)中涉及的相关的符号参数如表1所列。另外,包转发率、包修改率和包地址修改率在信任度评估过程中所占的比重会对网络性能产生一定程度的影响。为了解决个人主观对权重分配的影响,增强各影响因素的自适应性,本模型引入信息熵的概念综合计算节点信任度,具体计算过程如式(2)~式(7)所示。信息熵反映了多个评价指标对待评价事务的影响程度<sup>[5]</sup>。

$$h_{i1} = -\frac{f_i}{r_i} * \log_2(\frac{f_i}{r_i}) \quad (2)$$

$$h_{i2} = -(1 - \frac{dm_i}{f_i}) * \log_2(1 - \frac{dm_i}{f_i}) \quad (3)$$

$$h_{i3} = -(1 - \frac{am_i}{f_i}) * \log_2(1 - \frac{am_i}{f_i}) \quad (4)$$

$$\omega_{i1} = \frac{h_{i1}}{h_{i1} + h_{i2} + h_{i3}} \quad (5)$$

$$\omega_{i2} = \frac{h_{i2}}{h_{i1} + h_{i2} + h_{i3}} \quad (6)$$

$$\omega_{i3} = \frac{h_{i3}}{h_{i1} + h_{i2} + h_{i3}} \quad (7)$$

公式中涉及到的符号参数的具体含义如表1所列。

表1 信任值估计相关符号参数表

Table 1 Related symbol parameters of trust value estimation

符号	含义
$r_i$	节点 $i$ 数据包接收
$f_i$	节点 $i$ 数据包转发
$dm_i$	节点 $i$ 数据包修改
$am_i$	节点 $i$ 数据包地址修改
$t_i$	节点 $i$ 信任度
$h_{i1}$	节点 $i$ 数据包转发的信息熵
$h_{i2}$	节点 $i$ 数据包修改的信息熵
$h_{i3}$	节点 $i$ 数据包地址修改的信息熵
$\omega_{i1}$	节点 $i$ 数据包转发的权重
$\omega_{i2}$	节点 $i$ 数据包修改的权重
$\omega_{i3}$	节点 $i$ 数据包地址修改的权重

在信任机制的建立过程中,除了对信任度的计算之外,对异常数据的监测和过滤也是非常重要的一个过程。首先,要定义一个允许异常阈值  $\lambda_i$  进行异常数据的过滤,主要通过比较邻居节点与该节点收集数据的差值是否在允许的误差阈值范围内进行异常数据的判定。其中,相比其他邻居节点等上传的数据,该节点传输的数据为超出正常范围的异常数据,则为异常节点,否则该节点为正常节点。允许异常阈值  $\lambda_i$  主要通过式(8)来计算:

$$\lambda_i = \frac{1}{|N_i|} \sum_{j \in N_i} \left| \frac{x_i + \sum_{j \in N_i} x_j}{x_j - \frac{\sum_{j \in N_i} x_j}{|N_i| + 1}} \right| \quad (8)$$

其中,  $N_i$  表示节点  $i$  的邻居集合,  $|N_i|$  表示节点  $i$  的邻居节点的个数。

#### 2.1.2 簇结构的设计

在无线传感器网络中,簇结构主要分为两类,即单层簇结构和多层簇结构,一般情况下单层簇结构较为常见,其结构如图1所示。无线传感器网络中环境状况复杂,节点分布不均衡。针对这种情况,本文提出的数据融合模型结合单层簇结构和多层簇结构的优势,采用一种混合簇结构,其结构如图2所

示。簇中的每个节点都有对应的层,  $k$  代表节点所在的层数。




图1 单层簇结构

Fig.1 Single-layer cluster structure




图2 混合簇结构

Fig.2 Mixed cluster structure




图3 簇结构分析图

Fig.3 Cluster structure analysis

在某些情况下,这种混合簇结构还存在网络时延问题。当一个簇头将数据传输到基站后,若下一个簇头还没有完成对数据的采集和处理,将导致基站要额外等一段时间才能完成与该簇头的通信,如图4所示。当簇头1完成与基站的数据交互后,簇头2还没有完成数据的收集,而时隙2和时隙3都是空闲的,第2个簇头到第4个时隙才向基站传输数据。




图4 初始网络结构时延分析图

Fig.4 Delay analysis diagram of initial network structure

针对这种情况,在每一个簇头中增加一个字段,用簇节点数来显示簇中通信节点的数目,通信节点数越少,从集群头部收集数据所需的延迟就越低。簇头向基站传输数据时,可以按照簇中的节点数据升序传输,这样重新排序后,可以将基站的空闲时间压缩到最小,很大程度上减少网络的时延。在图5中可以看出,重新排序后将基站的所有时隙都充分利用

节点所处层数主要根据节点与基站的距离来确定,同时节点的剩余能量、节点的信任度以及所在区域节点的分布情况等各因素也不可忽视。

假设节点分布状况如图3(a)所示,则一般情况下簇聚类如图3(b)所示,节点会根据周围节点的分布状况选择最近的簇头节点加入该簇。但针对周围几乎没有其他节点的状况,节点会以自身为簇头节点,自成一个簇,例如图中的节点9,节点会将自身采集到的信息直接传送给距离较远的基站。在这个过程中,传输信息的能耗非常大,会使得网络的生存周期明显缩短。与此同时,节点9自成一簇,对传送信息的可靠度也很难准确衡量,网络的安全性和可靠性无法得到保障。而本文采用的簇结构如图3(c)所示,对于距离基站较近的节点,直接采用单层簇结构将采集到的数据融合后直接传送给基站。对于图3(b)中节点9的情况,可以通过多层簇结构将节点9采集到的数据先传送给距离较近的节点8,节点8将节点9传送的数据传输给自己所在簇的簇头节点4,节点4再将数据传输给基站。这个过程大大缩短了数据的传输距离,节省了传输过程中的能量损耗;同时节点9也与邻近的簇产生了联系,在信任度建立的过程中有了更多的参考,提升了网络的整体安全性。

起来了,时隙1到时隙4都有数据的通信,将整个网络的时延从6个时隙减少到4个时隙。




图5 优化后的网络结构时延分析图

Fig.5 Delay analysis diagram of optimized network structure

### 2.1.3 簇头的选举和自适应重选

在无线传感器网络中,与其他簇成员相比,簇头承担着更多的工作,如数据融合、数据传输、簇内通信等,需要消耗更多的能量。因此,簇头的选举和阶段性重选对延长网络生存周期和提高网络整体性能具有非常重要的意义。由于簇头节点是在普通节点中选举产生的,因此簇头节点与普通节点的内部结构几乎相同,如图6所示。当节点以普通节点的状态存在时,为节省能耗,一些簇头节点才具备的功能处于休眠状态,只有一些基本的功能模块在运作;当节点被选举为簇头节点时,簇头节点独有的功能模块才处于唤醒状态。

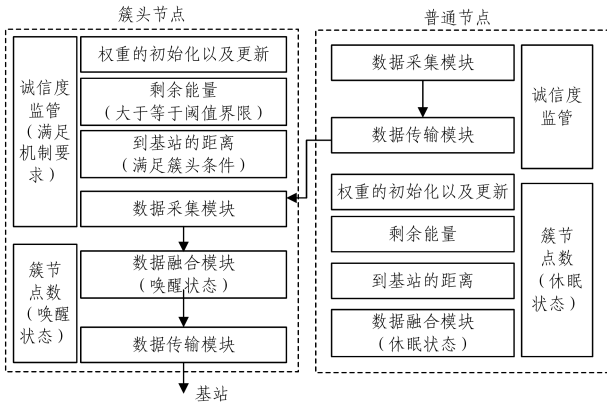


图6 节点功能模块示意图

Fig. 6 Schematic diagram of node function module

在本文提出的数据融合模型中,簇头的选举主要从以下3个方面考虑:节点的剩余能量、节点到基站的距离以及信任度。考虑到不同的使用场景具有不同的侧重点,可以通过指定参数来表示3个影响因子的首选项。

$$\omega_i = \alpha * e_i + \beta * t_i - \chi * d_i \quad (9)$$

其中,  $\omega_i$  表示节点  $i$  的权重,  $e_i$  表示节点  $i$  的剩余能量,  $t_i$  表示节点  $i$  的信任度,  $d_i$  表示节点  $i$  到基站的距离。  $\alpha, \beta$  和  $\chi$  是常数参数, 满足  $\alpha + \beta + \chi = 1$ 。

在簇头的选举过程中, 首先通过式(9)计算出每个节点的权重。簇头节点的剩余能量、节点到基站的距离以及信任度都要满足一定的条件。其中, 剩余能量和信任度的值要大于一定的阈值, 节点到基站的距离越小越好。同时, 根据3个影响因子计算得到的权重也要超过一定的阈值, 权重越大, 被选举为簇头节点的概率就越大。

相比于一般的成员节点, 簇头节点能量消耗更大, 寿命更短。为了延长网络的整体生命周期, 实现节点的负载均衡, 本文提出的数据融合模型引入簇头的阶段性自适应重选。在网络运行一段时间后, 当簇头节点的剩余能量等于阈值时, 再次利用式(9)计算节点的权重, 与第一次选举簇头节点的方式相同, 在簇内重新选择簇头节点, 平衡网络能耗, 从而达到节点负载均衡的目的。

## 2.2 融合算法的优化

关于滤波算法的优化在近些年也有很多相关研究<sup>[14-20]</sup>。为了解决无迹卡尔曼滤波在非强非线性系统中计算效果不理想的问题, 本文模型采用的融合算法主要是在无迹卡尔曼滤波算法的基础之上进行进一步的优化。其核心思想是先采用一次无迹卡尔曼滤波算法对每个带权值的采样点进行更新, 而后用最新的量测值对每个采样点的权值进行更新, 并对更新后的采样点进行加权求和, 得到下一时刻的初始估计值; 然后将该初始估计值作为预测值运行第二次无迹卡尔曼滤波算法, 从而得到最终估计值。与此同时, 考虑到无迹卡尔曼滤波中存在的滤波发散问题, 第一次采用无迹卡尔曼滤波算法进行数据更新时, 在观测噪声协方差矩阵中引入衰减因子  $S$  来降低旧测量数据的估值权重。

非线性系统的状态方程和测量方程分别为:

$$x_{k+1} = f(x_k) + \omega_k \quad (10)$$

$$z_{k+1} = h(x_{k+1}) + v_{k+1} \quad (11)$$

其中,  $x_k$  为  $k$  时刻  $n$  维的状态向量;  $z_{k+1}$  为时刻  $k+1$  的测量

向量;  $\omega_k$  为  $m$  维的过程噪声, 服从均值为 0、方差为  $Q$  的高斯分布;  $v_{k+1}$  为  $m$  维的测量噪声, 服从均值为 0、方差为  $R$  的高斯分布。状态初始值  $\hat{x}_0 = E(x_0)$ , 初始协方差  $\hat{P}_0 = E((x_0 - \hat{x}_0)(x_0 - \hat{x}_0)^T)$ 。由于噪声的存在, 要对初始状态进行扩维操作:

$$\hat{x}_0^a = [\hat{x}_0 \quad 0 \quad 0]^T \quad (12)$$

$$P_0^a = \begin{bmatrix} P_0 & 0 & 0 \\ 0 & Q & 0 \\ 0 & 0 & R \end{bmatrix} \quad (13)$$

(1) 第一次更新

在  $k$  时刻, 选取  $N = 2n + 1$  个 sigma 点, 这些点及其权值可以表示为:

$$\begin{cases} \hat{x}_{1,k} = \bar{x} \\ \{\hat{x}_{i,k}\}_{i=2}^{N-n} = \bar{x} + \sqrt{(n+l)} (\sqrt{P_{xx}})_{i-1} \\ \{\hat{x}_{i,k}\}_{i=N-n+1}^N = \bar{x} - \sqrt{(n+l)} (\sqrt{P_{xx}})_{i-n+1} \end{cases} \quad (14)$$

$$\begin{cases} \omega_{1,k}^m = \omega_{i,k}^c = \frac{l}{n+l} \\ \{\omega_{i,k}^m\}_{i=2}^N = \{\omega_{i,k}^c\}_{i=2}^N = \frac{1}{2(n+l)} \end{cases} \quad (15)$$

其中,  $\{\hat{x}_{i,k}\}_{i=1}^N$  为 sigma 点, 其权值对应的一阶矩和二阶矩分别为  $\omega_{i,k}^m$  和  $\omega_{i,k}^c$ ,  $\bar{x}$  表示均值,  $n$  为均值  $\bar{x}$  的维数,  $P_{xx}$  表示协方差,  $(\sqrt{P_{xx}})_i$  则表示平方根矩阵的第  $i$  列或行,  $l$  是比例参数 (调节 sigma 点与  $\bar{x}$  之间的距离)。

对于每个 sigma 点, 用式(14)和式(15)选取  $M$  个 sigma 点  $\{\hat{x}_{j,i,k}\}_{j=1}^M$ , 其一阶矩和二阶矩为  $\omega_{j,i,k}^m$  和  $\omega_{j,i,k}^c$ , 同时在观测噪声协方差矩阵中引入衰减因子  $S$ :

$$R_{k+1} = S \times R_k \quad (16)$$

其中,  $S$  是一个大于等于 1 但又不过大的经验值。引入衰减因子, 意味着随着时间的增加, 之前测量的旧数据的协方差增大, 这样便有效降低了之前测量数据的估值权重。

时间更新:

$$\hat{x}_{j,i,k+1|k}^x = f(\hat{x}_{j,i,k}^x, \hat{x}_{j,i,k}^o) \quad (17)$$

$$\hat{x}_{i,k+1|k}^x = \sum_{j=1}^M \omega_{j,i}^m \hat{x}_{j,i,k+1|k}^x \quad (18)$$

$$P_{i,k+1|k}^x = S \times \sum_{j=1}^M \omega_{j,i}^c (\hat{x}_{j,i,k+1|k}^x - \hat{x}_{i,k+1|k}^x) \times (\hat{x}_{j,i,k+1|k}^x - \hat{x}_{i,k+1|k}^x)^T + Q \quad (19)$$

测量更新:

在计算出预测值  $\hat{x}_{i,k+1|k}$  和预测协方差  $P_{i,k+1|k}^x$  的基础之上, 产生新的  $M$  个 sigma 点  $\{\hat{x}_{j,i,k+1|k}^x\}_{j=1}^M$ 。

$$z_{j,i,k+1|k} = h(\hat{x}_{j,i,k+1|k}^x, x_{j,i,k+1|k}^o) \quad (20)$$

$$\hat{z}_{i,k+1|k} = \sum_{j=1}^M \omega_{j,i}^m z_{j,i,k+1|k} \quad (21)$$

$$P_{i,\infty} = \sum_{j=1}^M \omega_{j,i}^c (z_{j,i,k+1|k} - \hat{z}_{i,k+1|k}) \times (z_{j,i,k+1|k} - \hat{z}_{i,k+1|k})^T + R \quad (22)$$

$$P_{i,\infty} = \sum_{j=1}^M \omega_{j,i}^c (\hat{x}_{j,i,k+1|k}^x - \hat{x}_{i,k+1|k}^x) \times (z_{j,i,k+1|k} - \hat{z}_{i,k+1|k})^T \quad (23)$$

$$K_{i,k+1} = P_{i,\infty} P_{i,\infty}^{-1} \quad (24)$$

$$\hat{x}_{i,k+1} = \hat{x}_{i,k+1|k} + K_{i,k+1} (z_{k+1} - \hat{z}_{i,k+1|k}) \quad (25)$$

$$P_{i,k+1}^x = P_{i,k+1|k}^x - K_{i,k+1} P_{i,\infty} K_{i,k+1}^T \quad (26)$$

在第一次更新后, 参考无迹粒子滤波<sup>[18]</sup>, 一阶矩和二阶

矩的权值同时更新为:

$$\begin{cases} \omega_i^m = \omega_i^m \frac{p(z_{k+1} | \hat{x}_{i,k+1}) p(\hat{x}_{i,k+1} | \hat{x}_{i,k})}{q(\hat{x}_{i,k+1} | z_{1:k})} \\ \omega_i^c = \omega_i^c \frac{p(z_{k+1} | \hat{x}_{i,k+1}) p(\hat{x}_{i,k+1} | \hat{x}_{i,k})}{q(\hat{x}_{i,k+1} | z_{1:k})} \end{cases} \quad (27)$$

对权值进行归一化处理:

$$\begin{cases} \omega_i^m = \frac{\omega_i^m}{\sum_{i=1}^N \omega_i^m} \\ \omega_i^c = \frac{\omega_i^c}{\sum_{i=1}^N \omega_i^c} \end{cases} \quad (28)$$

$k+1$  时刻的初始估计值和协方差表示为:

$$\hat{x}_{k+1}^I = \sum_{i=1}^N \omega_i^m \hat{x}_{i,k+1} \quad (29)$$

$$P_{k+1}^I = \sum_{i=1}^N \omega_i^c (\hat{x}_{i,k+1} - \hat{x}_{k+1}^I) (\hat{x}_{i,k+1} - \hat{x}_{k+1}^I)^T + Q \quad (30)$$

(2)第二次更新

基于  $\hat{x}_{k+1}^I$  和  $P_{k+1}^I$ ,通过式(14)和式(15)选取  $N$  个带权值的 sigma 点  $\{x_{i,k+1}^I\}_{i=1}^N$ 。

测量更新:

$$z_{i,k+1}^I = h(x_{i,k+1}^{I,x}, x_{i,k+1}^{I,v}) \quad (31)$$

$$\hat{z}_{k+1}^I = \sum_{j=1}^M \omega_j^m z_{i,k+1}^I \quad (32)$$

$$P_{zz}^I = \sum_{i=1}^M \omega_i^c (z_{i,k+1} - \hat{z}_{k+1}^I) (z_{i,k+1} - \hat{z}_{k+1}^I)^T + R \quad (33)$$

$$P_{zx}^I = \sum_{i=1}^M \omega_i^c (x_{i,k+1}^I - \hat{x}_{k+1}^I) (z_{i,k+1} - \hat{z}_{k+1}^I)^T \quad (34)$$

$$K_{k+1}^I = \frac{P_{zx}^I}{P_{zz}^I} \quad (35)$$

$$\hat{x}_{k+1} = \hat{x}_{k+1}^I + K_{k+1}^I (z_{k+1} - \hat{z}_{k+1}^I) \quad (36)$$

$$P_{k+1} = P_{k+1}^I - K_{k+1}^I P_{zz}^I (K_{k+1}^I)^T \quad (37)$$

重复式(17)一式(37),可求得每个时刻的  $\hat{x}_k$ 。

### 3 实验仿真

本节主要验证本文提出的融合算法的性能,由于该算法主要是为了保证融合后数据的质量,所以实验仿真主要围绕融合后数据的准确率和误差进行。本节涉及到的所有实验均在速度为 2.70 GHz,内存为 2GB 的奔腾(R)双核 E5400 处理器上的 MATLAB 7.10.0 (2010a) 环境下进行仿真。将扩展卡尔曼滤波算法 EKF、无迹卡尔曼滤波算法 UKF 和本文提出的算法进行仿真对比分析,用滤波算法估计值与真实值之间的对比来表示滤波算法的优化效果。为了方便表示,用 DUKF 代表本文提出的算法,其状态方程和测量方程分别为:

$$x_{k+1} = 0.5x_k + \frac{2.5x_k}{1+x^2} + 2\cos(1.2k) + \omega_k \quad (38)$$

$$z_{k+1} = 0.05x_{k+1}^2 + v_{k+1} \quad (39)$$

其中,  $\omega_k$  表示过程噪声,  $v_{k+1}$  表示测量噪声,都是均值为 0、方差为  $1 \times 10^{-5}$  的高斯白噪声。为了更好地验证实验效果,初始状态  $x_0$  为服从均值为 0、标准差为 2 的 8 行 1 列的正态分布随机数矩阵,每一个初始值对应产生一个结果。DUKF 中衰减因子  $S=1.2$ ,仿真时间为 100s,由于 8 组数据最终的仿真效果趋势相同,本文主要选择第六组数据的仿真效果进行展示。

图 7 展示了扩展卡尔曼滤波算法 EKF、无迹卡尔曼滤波

算法 UKF 和本文提出的算法 DUKF 的估算效果,可以看出 DUKF 的估算值与真实数据几乎一致,配合图 8 中 EKF、UKF 和 DUKF 的估算误差协方差的示意图可以看出,本文提出的算法 DUKF 明显比 EKF 和 UKF 误差要小,滤波的精度更高。




图 7 估计效果对比图

Fig. 7 Comparison chart of estimated effect




图 8 估计误差协方差

Fig. 8 Estimation error covariance

为了进一步验证本文提出的算法,对 8 组数据的估计误差协方差进行统计。从图 9—图 11 可以看出,EKF 算法相对更稳定,8 组数据的估计误差协方差波动不大,但是比其他两个算法误差更大;UKF 算法误差一直在一个合理的范围之内波动,但是在 8 组数据中,每组数据运行得到的结果都不相同,算法稳定性不足;相比 EKF 和 UKF 算法,DUKF 算法精确度和稳定性都有所提升。




图 9 EKF 估计误差协方差对比图

Fig. 9 Covariance comparison chart of EKF estimation error




图 10 UKF 估计误差协方差对比图

Fig. 10 Comparison chart of UKF estimation error covariance




图 11 DUKF 估计误差协方差对比图

Fig. 11 Comparison chart of DUKF estimation error covariance

**结束语** 本文提出的无线传感器网络数据融合模型通过簇结构的设计、簇头的选举和阶段性自适应重选来减少能量损耗,延长网络的生存周期,同时实现网络负载均衡,降低网络延迟。为了提高网络整体安全性和可靠性,本文设定了一种信任机制,与簇结构的选择和簇头的选举配合使用,可以从各个阶段提高网络的安全性。与此同时,通过对无迹卡尔曼滤波算法的优化,不仅提高了算法的精度,也解决了无迹卡尔曼滤波中存在的滤波发散问题。仿真结果表明,相比于传统的扩展卡尔曼滤波算法和无迹卡尔曼滤波算法,本文提出的算法可以获得更好的滤波估计结果。

## 参考文献

- [1] ZOU P H. Research on wireless sensor network security and data fusion technology [D]. Beijing: Beijing Jiaotong University, 2018.
- [2] LIU X Z, ZHU R B, ANJUM A, et al. Intelligent data fusion algorithm based on hybrid delay-aware adaptive clustering in wireless sensor networks[J]. Future Generation Computer Systems, 2020, 104: 1-14.
- [3] QIU L D, LIU T J, LIN N, et al. Data fusion algorithm of wireless sensor network based on deep learning model [J]. Journal of Sensor Technology, 2014, 27(12): 1704-1709.
- [4] ZHANG F, ZHENG H Y, DING Q L. Data fusion model of wireless sensor networks based on trust and weight [J]. Computer Science, 2017, 44(5): 37-41, 60.
- [5] SU F J, DU K Y. An energy-saving opportunity routing algorithm based on trust in WSNs [J]. Computer Science, 2020, 47(2): 300-305.
- [6] LIANG S, DENG X Y, JIANG W. Optimal data fusion based on information quality function [J]. Applied Intelligence, 2019, 49(11).
- [7] YE Z W, WEN T, LIU Z Y, et al. Wsns secure data fusion algorithm based on trust model [J]. Journal of Northeastern University (Natural Science Edition), 2019, 40(6): 789-794.
- [8] GAO B B, HU G G, GAO S S, et al. Multi-Sensor Optimal Data Fusion Based on the Adaptive Fading Unscented Kalman Filter [J]. Sensors, 2018, 18(2).
- [9] MASCHI LUIS F C, PINTO ALEX S R, MENEGUETTE R I, et al. Data Summarization in the Node by Parameters (DSNP):

Local Data Fusion in an IoT Environment[J]. Sensors, 2018, 18(3).

- [10] SUN G L, ZHANG Z Y, ZHENG B W, et al. Multi-Sensor Data Fusion Algorithm Based on Trust Degree and Improved Genetics[J]. Sensors, 2019, 19(9).
- [11] DAS S, BARANI S, WAGH S, et al. Extending lifetime of wireless sensor networks using multi-sensor data fusion [J]. Sādhanā, 2017, 4: 1083-1090.
- [12] GAO Y Q. Research on key technologies of data aggregation in the Internet of things environment [D]. Beijing: Beijing University of Posts and Telecommunications, 2019.
- [13] YIN N. Research on Trust Security Related Technologies in Wireless Sensor Networks [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2018.
- [14] ALPER AKCA M, ÖNDER E. Multiple Model Kalman and Particle Filters and Applications: A Survey[J]. IFAC-Papers On-Line, 2019, 52(3): 73-78.
- [15] YANG F, ZHENG L T, WANG J Q, et al. Double-layer unscented kalman filter [J]. Journal of Automatic Chemistry, 2019, 45(7): 1386-1391.
- [16] CUI L L, WANG X, XU Y G, et al. A novel Switching Unscented Kalman Filter method for remaining useful life prediction of rolling bearing[J]. Measurement, 2019, 135: 678-684.
- [17] WANG G Q, ZHANG Y G, WANG X D. Iterated maximum correntropy unscented Kalman filters for non-Gaussian systems [J]. Signal Processing, 2019, 163: 87-94.
- [18] WANG Y J, CHEN Z H. A framework for state-of-charge and remaining discharge time prediction using unscented particle filter[J]. Applied Energy, 2020, 260.
- [19] LI X M, ZHAO C S, ZHANG L K. Adaptive square root untracked particle filtering algorithm and its application [J]. Bulletin of Surveying and Mapping, 2018(12): 6-9, 14.
- [20] ZHANG K, TAO J F, HE S S. Improved particle filtering algorithm based on ukf and optimal combination strategy[J]. Computer Engineering and Science, 2017, 39(8): 1483-1488.



**HUANG Ting-ting**, born in 1995, post-graduate, is a member of China Computer Federation. Her main research interests include Internet of things technology and applications.



**FENG Feng**, born in 1971, Ph.D, professor, master's supervisor. His main research interests include information systems engineering and applications and Internet of things technology and applications.