

DOI:10.15923/j.cnki.cn22-1382/t.2018.3.11

收包率自适应功率控制方法

郑曼¹, 胡黄水^{1*}, 赵航¹, 王博²

(1.长春工业大学 计算机科学与工程学院, 吉林 长春 130012;

2.长春客车股份有限公司, 吉林 长春 130012)

摘要:通过神经模糊控制器来动态调节节点的目标收包率,使节点传输功率接近或达到该收包率。神经模糊控制器包含两个模糊推理系统(Fuzzy Interference System, FIS),FIS1采用神经网络学习来替代繁杂的模糊控制器参数调整过程,调节每个节点的传输功率,使节点的实际收包率达到目标值。FIS2采用“输入—输出—反馈”机制根据目标收包率和节点剩余能量偏差来调整其目标收包率,从而自适应地依据节点剩余能量调节传输功率,均衡网络能量消耗,延长网络生命周期。

关键词:无线传感器网络;模糊;神经;数据包接收率;自适应性

中图分类号: TP 391.9 **文献标志码:** A **文章编号:** 1674-1374(2018)03-0271-07

Package reception ratio adaptive power control algorithm

ZHENG Man¹, HU Huangshui^{1*}, ZHAO Hang¹, WANG Bo²

(1.College of Computer Science and Engineering, Changchun University of Technology, Changchun 130012, China;

2.CRRC Changchun Railway Vehicles Co. Ltd., Changchun 130012, China)

Abstract: A neural fuzzy controller is used to dynamically adjust the packet reception ratio of the nodes to adjust the node transmission power for optimizing the packet ratio. The fuzzy controller consists of two fuzzy interference systems (FIS). One is to use neural network learning for replacing the parameter adjustment process in fuzzy controller and check the transmission power of each node to ensure the optimal packet reception ratio. The other applies input-output-feedback mechanism to adjust the packet reception ratio according to both the current packet reception ratio and remaining energy of nodes. Based on the remain energy, the transmission power is adjusted to balance the energy consumption in the network and prolong the network life cycle.

Key words: wireless sensor networks; fuzzy; neural; packet reception ratio; adaptivity.

收稿日期: 2018-04-10

基金项目: 吉林省科技厅基金资助项目(20160312002ZG); 吉林省发改委省级产业创新专项资金项目(2018C039-2); 吉林省教育厅“十三五”科技项目(JJKH20181013KJ)

作者简介: 郑曼(1994—),女,汉族,湖北荆门人,长春工业大学硕士研究生,主要从事列车通信网络方向研究,E-mail:1839642147@qq.com.* 通讯作者:胡黄水(1974—),男,汉族,湖南隆回人,长春工业大学副教授,博士,主要从事无线传感器网络及列车通信网络方向研究,E-mail:huhs08@163.com.

0 引言

无线传感器网络 (Wireless Sensor Networks, WSNs) 作为信息物理系统和物联网感知层支撑技术^[1-2], 由大量资源受限的节点构成, 且广泛应用于环境监测、军事侦察、医疗健康和科学勘探等领域^[3-5]。由于节点能量受限, 如何延长网络生命周期依然是无线传感器网络面临的主要问题。而大量研究已经表明, 功率控制是减少 WSNs 能耗和保持通信可靠的有效方法之一^[6]。传输功率对链路质量产生显著影响^[4,7], 因此可采用链路级功率控制方法来延长无线传感器网络生命周期, 同时提升网络性能^[3,7]。如文献[6-8]采用基于接收节点链路质量指示值 (Link Quality Indicator, LQI) 来调节发送节点发射功率, 文献[9]采用接收信号强度指示值 (Received Signal Strength Indication, RSSI) 来调整节点发送功率。这些方法在保证链路质量的同时, 在一定程度上降低了网络能耗。但实际无线环境中, LQI、RSSI 变化无规律且频繁, 将导致功率的不断调节, 从而降低网络性能。而收包率 (Packet Reception Rate, PRR) 相较 LQI、RSSI 而言, 更能直接体现链路质量^[1,3,10-12]。链路质量参数容易受到一些不确定性因素影响, 如环境、动物干扰等, 而模糊逻辑系统可以处理这些意外干扰和不确定性因素^[13-15]。因此, 文献[12]提出基于模糊控制器的无线传感器网络功率控制算法 (Neural Fuzzy Controller Based Transmission Power Control Algorithm for Wireless Sensor Networks, FCTP), 该方法通过闭环回路控制邻居数量来对节点的传输功率进行调节, 但每个节点的期望节点度不能随网络动态变化, 很容易导致

某些节点过早死亡, 从而减小网络生命周期。文献[16]提出自适应传输功率算法 (Adaptive Transmission Power Control, ATPC), 基于研究链路质量调节发射功率, 但该算法在调节的过程中没有考虑节点的剩余能量, 因此不能很好地延长网络生命周期、降低节点平均能耗。文献[14]提出了自适应模糊控制算法 (Self-adaptive Fuzzy Controller Based Power Control, SAFPC), 该算法采用模糊闭环反馈系统, 根据剩余能量来自适应动态调节期望节点度, 从而控制节点发射功率达到目标节点度。该方法能有效克服 FCTP 的缺点, 但依然通过构建隶属度函数和 if-then 规则来设计模糊逻辑控制器, 其对复杂且动态的实际无线传感器来说很难获得期望的性能。

针对现有方法存在的问题, 文中提出一种基于自学习 NFTC 方法, 其根据节点的剩余能量自适应调整节点目标收包率, 并基于该收包率控制节点的传输功率。具体为采用包含两个模糊推理系统 FIS 的神经模糊控制器, FIS1 采用神经网络学习来替代繁杂的模糊控制器参数调整过程, 调节每个节点的传输功率, 使节点的实际收包率达到目标值。FIS2 采用“输入—输出—反馈”机制, 根据节点剩余能量调整其目标收包率, 从而自适应地依据节点剩余能量调节传输功率, 均衡网络能量消耗, 降低网络收敛时间及延长网络生命周期。

1 NFTC 算法设计

NFTC 的神经模糊控制器用于根据节点的剩余能量自适应调整其目标收包率, 并基于该目标收包率控制节点的传输功率, 其由两个模糊推理系统 FIS1 和 FIS2 构成, 如图 1 所示。

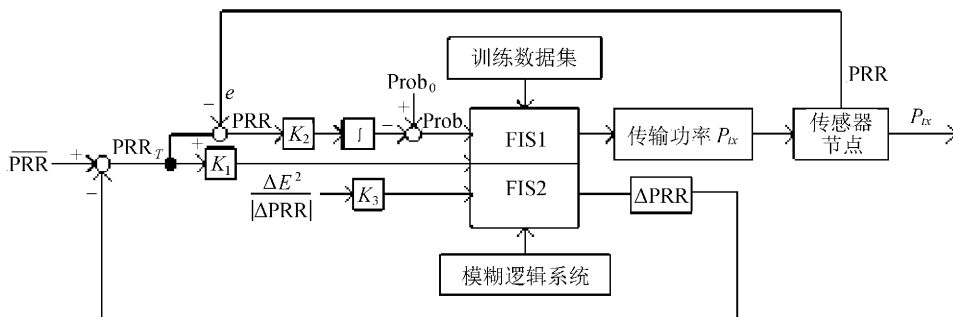


图 1 NFTC 的结构

模糊控制以模糊理论为主要计算方法^[13], 可以实现复杂的非线性映射, 神经网络能够通过已知的数据进行学习和归纳, 两者的结合使控制系统既具有模糊逻辑推理能力, 同时也可以通过系统自适应来不断改进和调整, 从而达到更好的控制效果。

1.1 系统输入与输出

由图 1 可以看出, NFTC 由两个推理引擎组成, 两个推理引擎有一个由期望收包率 \overline{PRR} 表示的共同输入。同时根据 \overline{PRR} 与 ΔPRR 计算出目标收包率 PRR_T , ΔPRR 是基于剩余能量, 通过

$$p_{ij}(P_{tx}, \varphi) = \left[1 - \frac{1}{2} \exp \left(\frac{P_n + P_0 + 10n \log_{10} \left(\frac{d_{ij}}{d_0} \right) + X\sigma - P_{tx}}{2} \right) \right]^{8\varphi} \quad (1)$$

式中: d_{ij} ——发射端与接收端之间的距离;

d_0 ——参考距离;

P_0 ——参考距离的路径损耗;

n ——路径损耗指数;

$X\sigma$ ——准偏差为 σ 的零均值高斯随机变量。

本底噪声通常是 -145 dB (Mica motes 节点^[3,8] 温度为 300 K)。正如文献[3,8]所述, Mica motes 节点提供的参数值为 $n=4, \sigma=4, d_0=1$ m, $P_0=55$ dB。对于能量模型, 采用文献[16]中描述的一阶无线电模型计算剩余能量偏差的方法。对于节点对 i, j 在线性通信发射状态下发射

FIS2 推理引擎估算的变化量。此外, FIS1 推理引擎输入是节点期望收包率 \overline{PRR} 的概率 Prob。在传感器节点中调整传输功率是一种常见的节点控制方法, 因此, FIS1 推理引擎输出是传输功率 P_{tx} 。另一方面, FIS2 推理引擎的第二个输入是剩余能量的偏差和收包率偏差的比值 $\frac{\Delta E^2}{|\Delta PRR|}$, 该比值表明依据收包率的能量消耗趋势。

在功率 P_{tx} 下, 节点 i 和 j 之间传输一个 φ 字节的数据包, 接收数据包的成功率由式(1)给出:

l 字节数据包的能量消耗和接收状态下接收 m 字节数据包的能量消耗由式(2)给出:

$$\Delta E = E_t - 8 \times (lE_e + lE_r d_{ij}^4 + mE_e) \quad (2)$$

式中: E_t ——发射前的剩余能量;

E_e ——相应电子电路所消耗的能量;

E_r ——功率放大器所消耗的能量。

正如文献[16]所述, 参数 E_e, E_r 都假定为 50 nJ/bit。

1.2 第一推理引擎

模糊推理系统由两个推理引擎组成。第一推理引擎 FIS1 主要包括一个模糊神经控制器, 结构如图 2 所示。

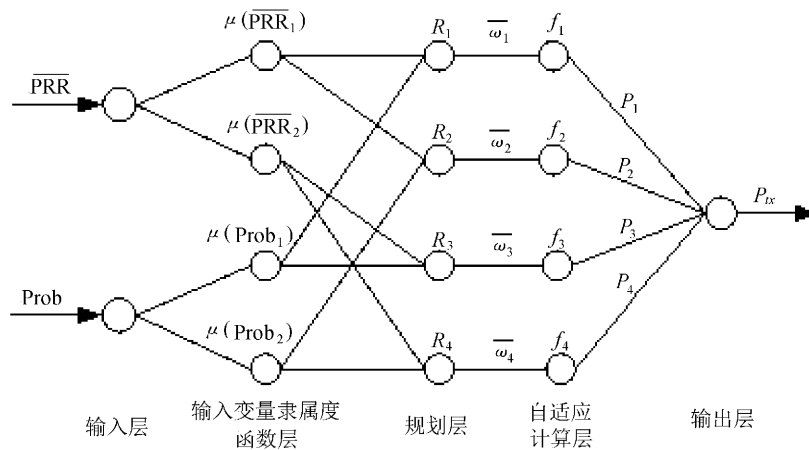


图 2 第一推理引擎结构

第一推理引擎 FIS1 的五层结构分别描述如下:

1) 输入层: 系统有两个输入, 即 \overline{PRR} 和 Prob。

2) 隶属度函数层: 根据收集到的 \overline{PRR} , Prob 和 P_{tx} , 建立训练数据集 $[\overline{PRR}, \text{Prob}, P_{tx}]$ 用于训练模型。采用钟型隶属度函数, 对于第 j 对数据

集,每个变量的隶属度函数由式(3)给出:

$$\begin{cases} \mu(\overline{\text{PRR}}_i) = \exp\left(-\frac{(\overline{\text{PRR}}^j - c_j^i)^2}{b_j^i}\right), \\ \mu(\text{Prob}_i) = \exp\left(-\frac{(\text{Prob}^j - c_j^i)^2}{b_j^i}\right), \end{cases} \quad i = 1, 2 \quad (3)$$

式中: i ——模糊子集的个数;

c_j^i, b_j^i ——隶属度函数的中心和宽度。

3)规则层:该层用于进行模糊运算。输出为

$$\begin{cases} \omega_1 = \mu(\overline{\text{PRR}}_1) \cdot \mu(\text{Prob}_1) \\ \omega_2 = \mu(\overline{\text{PRR}}_1) \cdot \mu(\text{Prob}_2) \\ \omega_3 = \mu(\overline{\text{PRR}}_2) \cdot \mu(\text{Prob}_1) \\ \omega_4 = \mu(\overline{\text{PRR}}_2) \cdot \mu(\text{Prob}_2) \end{cases} \Rightarrow \begin{cases} \overline{\omega}_1 = \frac{\omega_1}{\omega_1 + \omega_2 + \omega_3 + \omega_4} \\ \overline{\omega}_2 = \frac{\omega_2}{\omega_1 + \omega_2 + \omega_3 + \omega_4} \\ \overline{\omega}_3 = \frac{\omega_3}{\omega_1 + \omega_2 + \omega_3 + \omega_4} \\ \overline{\omega}_4 = \frac{\omega_4}{\omega_1 + \omega_2 + \omega_3 + \omega_4} \end{cases} \quad (4)$$

4)自适应计算层:该层结合四个控制规则完成自适应操作,并计算出每个规则所决定的输出。

各神经元输入取积后的归一化值,即对各个规则的激励强度归一化。每个节点输出由式(4)给出:

这一层的输出由式(5)给出:

$$\begin{cases} P_1 = \overline{\omega}_1 f_1 = \overline{\omega}_1 (p_1 \cdot \overline{\text{PRR}}^j + q_1 \cdot \text{Prob}^j + r_1) \\ P_2 = \overline{\omega}_2 f_2 = \overline{\omega}_2 (p_2 \cdot \overline{\text{PRR}}^j + q_2 \cdot \text{Prob}^j + r_2) \\ P_3 = \overline{\omega}_3 f_3 = \overline{\omega}_3 (p_3 \cdot \overline{\text{PRR}}^j + q_3 \cdot \text{Prob}^j + r_3) \\ P_4 = \overline{\omega}_4 f_4 = \overline{\omega}_4 (p_4 \cdot \overline{\text{PRR}}^j + q_4 \cdot \text{Prob}^j + r_4) \end{cases} \quad (5)$$

式中: $\{p_i, q_i, r_i\}$ ——该节点的结论参数。

自适应计算层四个节点的输出总和。

5)输出层:由预期收包率 $\overline{\text{PRR}}$ 和代表节点收包率为 $\overline{\text{PRR}}$ 的概率 Prob 来预测,网络训练的总输出为节点传输功率 P_{tx} ,其值由式(6)给出,是

$$P_{tx} = P_1 + P_2 + P_3 + P_4 \quad (6)$$

根据式(3)~式(5),整理式(6),该网络的输出值 P_{tx} 如下:

$$\begin{aligned} P_{tx} = & [\mu(\overline{\text{PRR}}_1) \cdot \mu(\text{Prob}_1) \cdot (p_1 \cdot \overline{\text{PRR}}^j + q_1 \cdot \text{Prob}^j + r_1) + \\ & \mu(\overline{\text{PRR}}_1) \cdot \mu(\text{Prob}_2) \cdot (p_2 \cdot \overline{\text{PRR}}^j + q_2 \cdot \text{Prob}^j + r_2) + \\ & \mu(\overline{\text{PRR}}_2) \cdot \mu(\text{Prob}_1) \cdot (p_3 \cdot \overline{\text{PRR}}^j + q_3 \cdot \text{Prob}^j + r_3) + \\ & \mu(\overline{\text{PRR}}_2) \cdot \mu(\text{Prob}_2) \cdot (p_4 \cdot \overline{\text{PRR}}^j + q_4 \cdot \text{Prob}^j + r_4)] / \\ & [\mu(\overline{\text{PRR}}_1) \cdot \mu(\text{Prob}_1) + \mu(\overline{\text{PRR}}_1) \cdot \mu(\text{Prob}_2) + \\ & \mu(\overline{\text{PRR}}_2) \cdot \mu(\text{Prob}_1) + \mu(\overline{\text{PRR}}_2) \cdot \mu(\text{Prob}_2)] \end{aligned} \quad (7)$$

1.3 第二推理引擎

第二推理引擎 FIS2 的两个输入变量是 $\overline{\text{PRR}}$ 和 $\frac{\Delta E^2}{|\Delta \text{PRR}|}$,输出变量是收包率的偏差 ΔPRR 。根据能耗的变化,模糊控制器可以通过一个闭环反馈系统调整 $\overline{\text{PRR}}$,得到相应的输出 P_{tx} ,从而降

低能耗。第二推理引擎包括模糊化、模糊规则和去模糊化,具体描述如下。

1.3.1 模糊化

输入的清晰值需要变为模糊语言变量。输入变量 $\overline{\text{PRR}}$ 的模糊语言变量为‘LOW’,‘LOW_MIDDLE’,‘MIDDLE’,‘MIDDLE_HIGH’,

‘HIGH’,其清晰值是-2,-1,0,1,2。输入变量 $\frac{\Delta E^2}{|\Delta PRR|}$ 的模糊语言变量为‘SMALL’, ‘MIDDLE’, ‘LARGE’,对应的清晰值为 0,1,2,并且 ‘LOW’, ‘HIGH’, ‘SMALL’, ‘LARGE’为梯形隶属度函数, ‘LOW_MIDDLE’, ‘MIDDLE’, ‘MIDDLE_HIGH’为三角形隶属度函数。输入变量 \overline{PRR} 和 $\frac{\Delta E^2}{|\Delta PRR|}$ 隶属度函数分别如图 3 和图 4 所示。




图 3 \overline{PRR} 隶属度函数




图 4 $\frac{\Delta E^2}{|\Delta PRR|}$ 隶属度函数

输出变量 ΔPRR 的模糊语言变量为‘D2S’, ‘D1S’, ‘HOLD’, ‘U1S’, ‘U2S’,其对应的五个清晰值分别为 -2, -1, 0, 1, 2。‘D2S’, ‘U2S’为梯形隶属度函数, ‘D1S’, ‘HOLD’, ‘U1S’, ‘D1S’为三角形隶属度函数。 ΔPRR 的隶属度函数如图 5 所示。




图 5 ΔPRR 隶属度函数

1.3.2 模糊规则和去模糊化

输入变量的清晰值在通过模糊化后得到相应的语言变量,然后经过模糊逻辑系统中的 if-then 规则库,对输入变量进行控制。该方法更加简洁,控制效果更好^[3]。FIS2 推理引擎的 if-then 模糊规则见表 1。

表 1 NFTC 模糊规则

编号	输入参数		输出参数
	\overline{PRR}	$\frac{\Delta E^2}{ \Delta PRR }$	ΔPRR
1	LOW	SMALL	U2S
2	LOW	MIDDLE	U2S
3	LOW	LARGE	U1S
4	LOW_MIDDLE	SMALL	U2S
5	LOW_MIDDLE	MIDDLE	U1S
6	LOW_MIDDLE	LARGE	U1S
7	MIDDLE	SMALL	HOLD
8	MIDDLE	MIDDLE	HOLD
9	MIDDLE	LARGE	HOLD
10	MIDDLE_HIGH	SMALL	D1S
11	MIDDLE_HIGH	MIDDLE	D1S
12	MIDDLE_HIGH	LARGE	D2S
13	HIGH	SMALL	D1S
14	HIGH	MIDDLE	D2S
15	HIGH	LARGE	D2S

系统采用中心法进行去模拟化,输出值 ΔPRR 清晰。具体去模糊化过程如下:

$$\Delta PRR = \frac{\sum_{i=1}^n x_i \mu_{\Delta PRR}(x_i)}{\sum_{i=1}^n \mu_{\Delta PRR}(x_i)} \quad (8)$$

2 仿真结果

为了验证 NFTC 性能,文中使用 Matlab 进行仿真测试,并与 ATPC^[16]、SAFPC^[14] 进行比较。设定节点随机部署在 100 m×100 m 的方形区域中,基站坐标为(50,50),每个节点的初始能量为 1 J,仿真次数为 50 次,结果取平均值。首先研究网络节点数量不同时节点平均能耗对比,然后比较不同初始发射功率时的网络收敛时间及不

同节点数目时的网络生命周期。

以 50 个节点数目为间隔,在 8 个不同节点数目下,得到节点的平均能耗,节点平均能耗对比如图 6 所示。

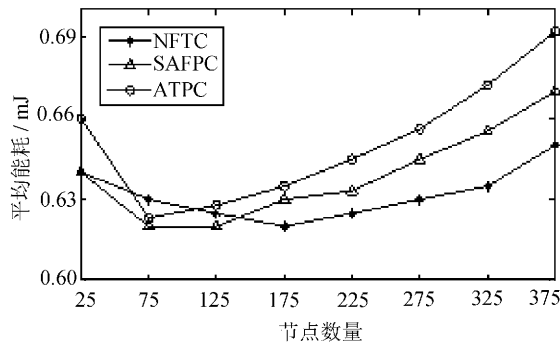


图 6 节点数量不同时平均能耗对比

从图 6 中可以得知,与 SAFPC 和 ATPC 算法相比,NFTC 算法平均能耗随节点数量增加上升缓慢。

在不同初始发射功率下的网络收敛时间,初始发射功率以 5 dBm 为梯级,在 -20 dBm 到 5 dBm 范围内的 6 个不同传输功率下,得到相应的网络收敛时间。两种算法的仿真实验结果比较如图 7 所示。

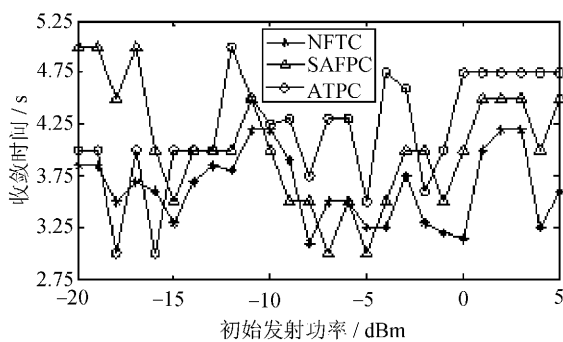


图 7 不同初始发射功率时的收敛时间

NFTC 算法与 SAFPC 和 ATPC 算法相比,网络收敛时间普遍降低,收敛速度更快,具有更好的网络性能。

由于 NFTC 算法考虑节点能耗的同时,调整了传输功率,比较两种算法不同节点数目下的网络生命周期如图 8 所示。

由仿真结果可知,NFTC 算法比 SAFPC 和 ATPC 算法的网络生存时间更长。因此,NFTC 算法可更好地延长网络寿命。




图 8 不同节点数目时的网络生命周期

3 结 语

从控制节点传输功率的角度出发,提出了一种面向无线传感器网络的自学习模糊神经网络功率控制算法 NFTC,其在人工神经网络学习训练集的基础上建立模糊控制系统,避免传统方法的复杂参数调节过程,并通过反馈、循环机制调整节点传输功率,以获得期望的节点能量消耗。从收敛时间、平均能耗以及生命周期方面对算法进行了仿真分析,结果表明,相比 ATPC 和 SAFPC 算法,NFTC 算法性能较优,能有效控制节点能耗,延长网络生命周期。

参考文献:

- [1] Guo Z Q, Wang Q, Li M H, et al. Fuzzy logic based multidimensional link quality estimation for multi-hop wireless sensor networks[J]. IEEE Sensors Journal, 2013, 13(10): 3605-3615.
- [2] Vicente H D, Jose F M, Nestor L M, et al. Self-adaptive strategy based on fuzzy control systems for improving performance in wireless sensors networks [J]. ACM Transaction on Sensor Networks, 2015, 15(9): 24125-24142.
- [3] Shan L, Fei M, Jingbing Z, et al. ATPC: adaptive transmission power control for wireless sensor networks[J]. Sensors, 2016, 12(1): 1-6, 31.
- [4] 王福豹,史龙,任丰原.无线传感器网络中的自身定位系统和算法[J].软件学报, 2005, 16(5): 857-868.
- [5] 沈玮娜,胡黄水,王宏志,等.自适应模糊无线传感器网络路由选择[J].长春工业大学学报, 2017, 38(2): 144-149.
- [6] 吴鹏杰.一种新颖的无线传感器节点模糊功率控制算法[D].北京:北京邮电大学, 2010: 22-29.
- [7] 邵奇可,冯淑娜,毛科技.面向 WN 的自适应模糊功率控制算法研究[J].传感技术学报, 2015, 28(4):

- 563-571.
- [8] Huseyin U Y, Bulent T. Transmission power control for link-level handshaking in wireless sensor networks[J]. *IEEE Sensors Journal*, 2016, 16(2): 561-576.
- [9] 陈焕,汪正祥,傅忠云.基于发射功率自适应调节的无线通信网抗扰研究[J]. *电子科技*, 2016, 29(1): 71-74.
- [10] 李成法,陈贵海,叶懋,等.一种基于非均匀分簇的无线传感器网络路由协议[J]. *计算机学报*, 2007, 30(1): 27-36.
- [11] 袁正午,梁均军.累积链路质量无线传感器网络路由算法研究[J]. *计算机工程与应用*, 2011, 47(14): 66-69.
- [12] 王骐,王殊,孟中楼.无线传感器网络中一种基于接收功率异常的入侵检测算法[J]. *计算机科学*, 2009, 36(3): 34-37.
- [13] Zhang J, Chen J, Sun Y. Transmission power adjustment of wireless sensor networks using fuzzy control[J]. *Wireless Communication & Mobile Computing*, 2009, 9(6): 805-818.
- [14] 胡黄水,沈玮娜,王出航,等.基于自适应模糊控制器的无线传感器网络功率控制[J]. *计算机应用*, 2017, 37(9): 2470-2473, 2562.
- [15] Geeta D D, Nalini N, Rajashekhar C B. Fault tolerance in wireless sensor network using hand-off and dynamic power adjustment approach[J]. *Journal of Network and Computer Applications*, 2013, 36(4): 1174-1185.
- [16] Pappas G J. ATPC: Adaptive transmission power control for wireless sensor networks [J]. *Acm Transactions on Sensor Networks*, 2016, 12(1): 6.