

太阳能无线传感器网络的能量预测与管理

王元翔,徐震

(武汉轻工大学 电气与工程学院, 武汉 430048)

摘要:无线传感器网络存在电池电量受限问题.为延长网络寿命,传感器节点可以通过太阳能电池板将太阳能转换成电能以供自身运转.基于太阳能的不确定性和间歇性等特点,提出了一种太阳能收集预测算法和能量管理方案,根据预测的能量,调整传感器节点的调度计划,实现节点的能量消耗中性,从而使无线传感器网络能够长期稳定地工作.仿真实验表明,所提出的方案在能量预测精度和能量管理策略方面有明显的优势.

关键词:无线传感器网络;太阳能;能量预测;能量管理

中图分类号:TP393

文献标志码:A

文章编号:1000-2367(2024)03-0080-08

无线传感器网络(wireless sensor network, WSN)是由部署在监测区域内的多个传感器设备节点组成,这些设备可以用来实时监控环境信息,并将采集的数据发给上级节点或者网关节点,然后进行下一步的分析处理.无线传感器网络适合在一些恶劣环境下使用,如环境数据监测^[1]、智能家居^[2]、矿洞监测^[3]和桥梁监控^[4]等领域都有广泛应用.

传感器节点由电池供电,电池通过提供维持节点每个组件所需要的电流来给电路供电.传感器、无线电、微控制器和闪存这些常见的物理组成部件在不同的能量状态下运行,消耗的总能量即为传感器节点的能量消耗.传感器节点的寿命定义为电池放电到低于传感器节点运行所需要的最低电量的时间.有限的电池容量使得传感器节点的寿命受到限制,无线传感器节点的维护成本大大增加.

为了延长传感器节点寿命,甚至使它的潜在寿命达到无限.一些学者研究能量收集无线传感网络^[5],其中最具有代表性的就是太阳能收集无线传感器网络^[6].在现实的环境中,太阳能电池收集的能量是间歇性的,使得收集的能量不足以在所有的情况下满足传感器节点的能量需求.当处于太阳能充足的环境中,太阳能电池会收集到多余的能量,给电池充电.在处于太阳能不足的环境中时,电池会放电来维持传感器节点的工作.如果长期处于这种环境中,太阳能采集系统收集不到足够的能量给电池充电,这会导致节点死亡.

在基于环境监测的 WSN 中,为了尽可能延长太阳能无线传感器节点的寿命,设计了一种太阳能能量收集系统,它利用太阳能电池收集到的能量来维持传感器节点的运行,并实现了 24 h 的能量中性,最大限度地延长了无线传感器节点的寿命.

1 相关研究

为了延长太阳能无线传感器节点的寿命,许多学者对能量预测算法和能量管理方案进行研究.在太阳能

收稿日期:2023-03-09;**修回日期:**2023-03-28.

基金项目:国家自然科学基金(61373091);湖北省自然科学基金(2017CKB893).

作者简介:王元翔(1999-),男,湖北潜江人,武汉轻工大学硕士研究生,主要从事无线传感器网络研究.

通信作者:徐震(1974-),男,河南信阳人,武汉轻工大学副教授,博士,主要从事无线传感器网络研究, E-mail: xuzhen2046@qq.com.

引用本文:王元翔,徐震.太阳能无线传感器网络的能量预测与管理[J].河南师范大学学报(自然科学版),2024,52(3):80-87.(Wang Yuanxiang,Xu Zhen.Energy prediction and management of solar wireless sensor networks[J].Journal of Henan Normal University(Natural Science Edition),2024,52(3):80-87.DOI:10.16366/j.cnki.1000-2367.2023.03.09.0001.)

预测算法方面,KANSAL等^[7]提出的EWMA(exponential weighted moving average)算法将一天分成相等的时隙,一天中某个时间段的能量定义为前一天同一时间获得的能量和上个时间段预测到的能量的加权平均.Pro-Energy算法^[8]利用了前一天的配置文件,以及之前的几天太阳能数据,将当天的能量数据与存储在矩阵中的所有配置文件进行比较.通过取当前数据和存储数据之间的平均绝对误差来判断近似度.最后通过上个时间段预测到的能量和最接近当天能量的数据的加权平均来进行能量预测.KOSUNALP等^[9]基于已经获得的历史天气数据和当天的天气数据,提出了q-learning算法,该算法加入了奖励函数来确定最佳的预测方案.SHU等^[10]提出了基于最小均方滤波器的双重预测方案,当预测结果出现较大误差时,将根据预测结果来改变预测系数来保证预测精度.DEB等^[11]提出了Enhanced-Pro的预测算法,根据数据中存在的规律进行预测,并将预测分为短期和中期,采用不同的调整因子进行预测.

由于能量收集无线传感网络收集到的能量随着环境的变化而变化,因此,能量收集无线传感器节点的能量管理必须适应不断变化的能量收集水平.HSU等^[12]提出了一种基于强化学习的动态电源管理方法,该方法根据对环境状态的观察,确定WSN的工作周期,并接收环境的奖励值反馈进行管理.文献^[13]提出了一个基于强化学习的能量管理器,该管理器能够基于电池的充电状态根据变化的环境来调整能量管理策略.HSU等^[14]提出了一种基于Fuzzy Q-learning(FQL)的动态能量管理方法,该方法基于收集到的能量数据变化改变相应的管理策略,来维持能量收集无线传感网络的永久运行.LIU等^[15]基于动态规划提出了一种能量管理优化算法,该方法通过递归找出最适合下个时段的能量管理方案,从而延长节点寿命.PRAUZEK等^[16]提出了一种基于Q-learning的管理方案,该方案根据昼夜变换来改变节点的能量管理策略,来减少没有能量摄入时的能量消耗,从而保证节点不会因为能量耗尽而死亡.

2 太阳能电池消耗模型

2.1 太阳能电池

太阳能电池是由晶体态的半导体材料组成,通过光伏效应将光子的能量转化为电能.太阳能电池的效率(σ)定义为太阳能电池吸收的入射光转换为电能的转换效率,其计算公式为:

$$\sigma = \frac{P_{\max}}{D \times S}, \quad (1)$$

其中 P_{\max} 是电池提供的最大输出功率(W), D 是辐照度,表示单位面积上的入射功率密度(W/m^2), S 是太阳能电池表面面积(m^2).本文选择MSX-005F太阳能电池,表1为该电池的相关数据.该太阳能电池的效率即使在冬季也能保持在10.83%左右.

表1 MSX-005F 太阳能电池参数
Tab. 1 MSX-005F solar cell parameters

电池参数	额定负载电压 (V_{ld})/V	额定负载电流 (I_{ld})/mA	开路电压 (V_{oc})/V	短路电流 (I_{sc})/mA	最大输出功率 (P_{\max})/mW	表面积 (S)/ cm^2
数值	3.3	150	4.6	160	500	36

2.2 能量模型

设 B_{\max} 是WSN节点的最大电池容量, B_{\min} 为维持节点运行所需的最小电池容量.WSN节点的电量可以用式(2)表示为:

$$B(t) = B(t-1) + \sigma \hat{E}(t) - c(t), B_{\min} \leq B(t) \leq B_{\max}, \quad (2)$$

其中, $\hat{E}(t)$ 是太阳能电池在 t 时刻预期收集到的能量, $c(t)$ 是节点在 t 时刻消耗的能量, $B(t)$ 和 $B(t-1)$ 分别是 t 和 $t-1$ 时刻节点的电池电量, σ 是太阳能电池的充电效率.

考虑到节点自身存在能量损耗,例如发热等情况下的能量消耗,所以传感器节点的能量模型为:

$$B(t) = B(t-1) + \sigma \hat{E}(t) - c(t) - E_{\text{leak}}(t), B_{\min} \leq B(t) \leq B_{\max}, \quad (3)$$

其中 $E_{\text{leak}}(t)$ 为节点的自身能量损耗.

太阳落山之后能量输入趋近于0时,WSN节点能量模型为:

$$B(t) = B(t-1) - c(t) - E_{\text{leak}}(t), B_{\min} \leq B(t) \leq B_{\max}. \quad (4)$$

根据式(4),在日落之后,节点的电量一直处于下降的状态,若继续使用日落前的任务调度,节点的寿命将会缩短.因此需要调整节点的任务调度,实现无线传感器网络节点的能量中性管理,使节点可以不间断地运行.若连续两天存在相同时刻 t' ,使得 $B_1(t') = B_2(t')$,则传感器的能量管理是能量中性的.传感器节点收集太阳能的能量,能量生产周期为24 h.所以要实现一种24 h能量中性的能量管理策略.

3 太阳能采集预测

太阳能在自然界中具有较高的能量密度,在各种大自然能源中比较受欢迎.然而,太阳能电池产生的能量取决于太阳辐射强度,收集到的能量在日出之后逐渐增加,在午间达到峰值,此时太阳直射在太阳能电池板上,然后开始逐渐下降,直到天黑.另外,电压与太阳能电池有关.当太阳能电池达到饱和状态时,即使还未达到太阳辐射峰值,储存的能量也不会增加.论文提出了一种全新的太阳能预测算法,该算法使用过去观察到的太阳辐照度数据来预测未来的太阳辐照度.

3.1 预测算法

太阳能预测算法的主要思想是利用收集到的一些具有代表性的太阳能辐照度和近期的太阳能辐照度(包括前几天和当天前几个时间段的辐照度)进行预测.例如,天气可以分为晴天、雨天或阴天,这些天气收集到的太阳能数据在预测的过程当中和当天的数据进行对比,然后找出最相似的辐照度数据来进行预测.考虑到一天中天气的变化可能比较大,例如上午是晴天,下午变成了阴天.这种情况就需要加上近期的辐照度数据来提高预测的准确性.

3.1.1 典型太阳能数据

为了实现当前数据和典型太阳能辐照度的匹配,需要将收集到的太阳能辐照度数据存储到一个长度为 N 的矢量 \mathbf{C} 中,矢量 \mathbf{C} 包含每个时间段获得的能量.典型太阳能辐照度数据保存在一个矩阵 \mathbf{E} 中,大小为 $D * N$.

通过查找与当前最相似的天气辐照度数据来提供能量预测,它们之间的相似性定义为平均绝对误差,所以与实际数据最相似的数据可以用式(5)表示:

$$E^d = \min | C^d(t) - E^d(t) |, E^d \in \mathbf{E}, \quad (5)$$

其中 E^d 是与当天实际数据最相似的数据, C^d 为当天的实际数据.

更多的情况下,需要考虑最近的几次辐照度观测.假设需要考虑最近 K 次的能量数据,所以在 t 时段与当天的数据 C 最相似的数据 E^d 可以用式(6)表示:

$$E^d = \sum_{i=t-K}^t \frac{1}{K} \min | C^d(i) - E^d(i) |, E^d \in \mathbf{E}, K < t. \quad (6)$$

3.1.2 过去的太阳能数据

太阳辐照度具有不可预测性.例如,近期如果出现了季节性的变换,导致近几天的辐照度数据和矩阵 \mathbf{E} 中的辐照度数据差别较大,进而使得预测效果不够理想,或者当天的天气变化较大也会对预测产生一些影响.因此过去几天的太阳辐照度数据和当天辐照度的变化趋势是十分重要的.

假定 $E_{\text{se}}^d(t)$ 表示 d 天 t 时段的季节性影响,则有:

$$E_{\text{se}}^d(t) = \beta [C^{d-1}(t) - C^{d-2}(t)] + (1 - \beta) [C^{d-2}(t) - C^{d-3}(t)], \quad (7)$$

其中, $C^{d-1}(t), C^{d-2}(t), C^{d-3}(t)$ 是 $d-1, d-2$ 和 $d-3$ 天 t 时段实际的太阳辐射度, β 是调整参数, $\beta \in [0, 1]$.

3.2 预测算法

在进行能量采集预测时,预测算法会尝试将当天观测到的太阳辐照度与存储在数据池中的典型辐照度数据进行匹配.具体来说,算法根据存储配置文件中当前时段的下一个时段的辐照度和当前时段实际观察到的辐照度 $C(t)$ 计算下一个时段的预测值.预测算法需要找到一个数据文件 E^d ,在这个数据文件上记录有一天12 h的光辐照度数据文件,选择从当天上午6时到当前时段 t 为止与当天光辐照度最相似的数据文件 E^d ,

所以下一个时段 $t + 1$ 的预测辐照度 $\hat{E}(t + 1)$ 定义如下:

$$\hat{E}(t + 1) = \alpha \cdot C(t) + (1 - \alpha)E^d(t + 1), \quad (8)$$

式中, $C(t)$ 是当天 t 时刻实际的辐照度数据, $E^d(t + 1)$ 表示与当天最匹配的存储数据在 $t + 1$ 时段的辐照度数据. α 为调整因子, $\alpha \in [0, 1]$.

考虑到季节因素对辐照度的影响和当天的辐照度变化趋势的影响, 当天的变化取决于当天前 2 个时段的实际辐照度和预测辐照度的差值. 当天的辐照度的变化趋势 $E_{de}^d(t)$ 定义如下:

$$E_{de}^d(t) = \partial[C^d(t - 1) - \hat{E}(t - 1)] + (1 - \partial)[C^d(t - 2) - \hat{E}(t - 2)]. \quad (9)$$

下一个时段预测到的辐照度数据 $\hat{E}(t + 1)$ 为:

$$\hat{E}(t + 1) = \alpha \cdot C(t) + (1 - \alpha)E^d(t + 1) + E_{sc}^d(t) + E_{de}^d(t). \quad (10)$$

式(9)和(10)中 α 和 ∂ 为调整因子, $\alpha, \partial \in [0, 1]$.

3.3 存储配置文件更新

预测算法需要存储 D 组太阳辐照度数据, 每一组数据都代表了不同的天气状况. 为了使预测算法在不断变化的天气中保持良好的准确度, 存储太阳辐照度的数据池必须定期更新. 在每天结束时, 算法决定是否将当天观察到的数据 C 存储到数据池中. 具体来说, 算法给出了 3 种情况之下的更新: (1) 如果一组太阳能数据在数据池中使用达到了一定的天数, 则用当天观察到的数据 C 对它进行一个替换. (2) 如果数据池中有相似的数据时, 即它们之间的平均绝对误差低于一个阈值, 则用当天观察到的数据 C 替换掉这些数据中与数据 C 最相似的一组. (3) 当季节性影响较大时, 即 $E_{sc}^d(t)$ 的绝对值高于一个阈值时, 表示近期的季节变换较大, 则用当天观察到的数据 C 替换掉与数据 C 最相似的数据.

第 1 种策略是丢弃过时的太阳辐照度数据, 第 2 种策略是通过丢弃非常相似太阳辐照度数据, 来更新代表不同天气条件的太阳辐照度数据池, 而第 3 种策略是在天气变化较大时, 丢弃与数据 C 相似的数据来更新太阳辐照度数据池来保证预测的准确性.

3.4 仿真结果

本文所提方案测试环境基于 Windows 11, 运行内存 16 GB, 处理器为 Intel i7-11800H @ 2.30 GHz, 用 MATLAB 2022a 进行仿真实验. 实验数据采用美国国家可再生能源实验室(NERL)公开的太阳能数据(https://www.nrel.gov/grid/solar-resource/confirm.html#paneld14e112_6). 实际的光辐照度数据如图 1 所示. 为了使预测算法有更好的预测效果, 只考虑了白天早上 6:00 到下午 6:00 的数据, 晚上收集的能量几乎没有, 会影响到平均误差的计算, 不纳入预测, 因此论文将白天(12 h)分为 48 个时间段, 每个时间段为 15 min.

论文把平均绝对百分比误差(mean absolute percentage error, MAPE)^[17] 作为评价指标, 通过比较预测光辐照度与实际光辐照度来计算预测算法的误差, 来评估预测算法的性能, 计算公式如下:

$$MAPE = \frac{1}{T} \sum \left| \frac{\hat{E}_t - C_t}{C_t} \right|, \quad (11)$$

其中, T 为总时隙数, \hat{E}_t 为 t 时隙预测的光辐照度, C_t 为 t 时隙实际的光辐照度. 本文所提算法在不同的 α, β, ∂ 情况下的平均误差如图 2 所示.

图 2 表明, 本文所提算法在 $\alpha = 0.4, \beta = 0.6, \partial = 0.6$ 时取得的平均误差值最优, 误差可以降低到 8.6%. 图 3 为在 $\alpha = 0.4, \beta = 0.6, \partial = 0.6$ 时的能量数据. 从图 3 结果观察发现, 在 50 时序到 100 时序之间天气变化平稳时预测数据与原始数据几乎一样, 此时 3 种预测算法的平均误差很小, 而 EWMA 算法仍有一定的预测误差, 相比于本文的预测算法, 误差率高出 52.2%. 在 100 时序到 200 时序之间天气变化较大, 本文算法和 EWMA 算法虽然都根据环境的变化进行一些调整, 但误差仍然增大. Pro-Energy 算法由于没有考虑到当天和最近几天的能量趋势, 准确性也没有本文方案高, 误差相对本文方案高出 48.0%. 本文算法通过对当天辐照度趋势 $E_{de}^d(t)$ 的反馈, 对下个时隙的预测数据进行更新, 准确率可以达到 91.4%.

4 能量管理优化和任务调度方案

对于能量受限的无线传感器网络, 为了尽可能延长传感器节点的寿命, 通过采用太阳能能量收集方案试

图使得节点调度方案是能量中性的,就可以保持节点的稳定运行.但是太阳能收集方案受天气影响,使得节点收集的能量是波动的.夏季的能量中性调度计划可能不适合用在冬天,这可能导致节点的死亡.虽然太阳能资源具有不确定性,但是通过对可以收集的太阳能能量进行预测,使节点根据收集太阳能能量的多少动态地改变它的任务调度,从而使节点的能量控制达到能量中性.

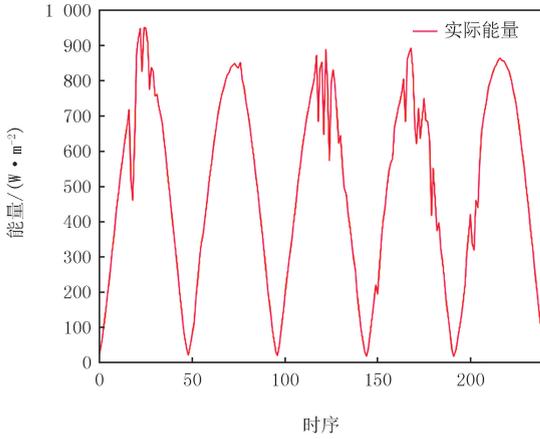
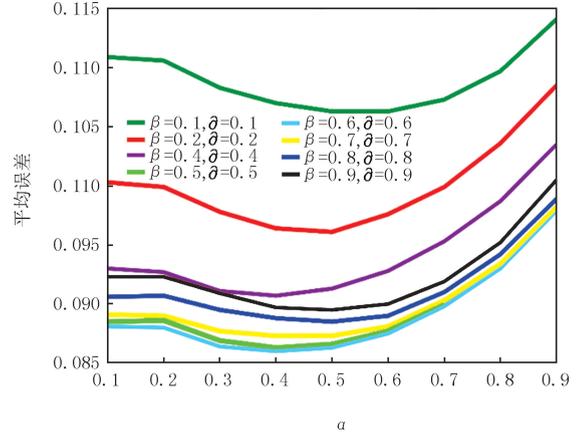


图1 连续5天能量波形图

Fig.1 Energy waveform for five consecutive days

图2 算法在不同 α, β, δ 时的平均误差Fig.2 Average error of the algorithm at different α, β, δ

将 1 d(24 h)划分为等时长的 N 个时段,每个时段持续时间为 $\Delta T = \frac{3\ 600 \times 24}{N}$.对于每个时段 i ,选择一个任务调度计划 $S(i)$.为了实现节点的能量中性目标,论文提出一种任务调度算法,通过动态地改变任务调度,使网络整体收集的能量和消耗保持相当. $\hat{E}(i)$ 定义为时段 i 预测的太阳辐照度数据.

$B(i)$ 表示时段末尾的电池电量, B_{\min} 表示传感器工作所需要的最小电量, B_0 表示初始电量.每个时段的电池电量 $B(i)$ 可以表示如下:

$$B(i) = \min\{B_{\max}, B(i-1) + \sigma\hat{E}(i) - c(i) - E_{\text{leak}}(t)\}. \quad (12)$$

保持能量中性需要满足以下条件:

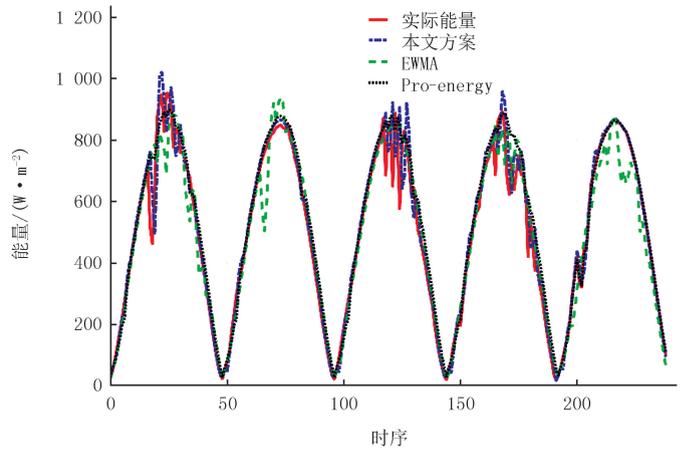
$$\sigma \sum_{i=1}^N \hat{E}(t) \geq \sum_{i=1}^N c(i), \quad (13)$$

$$B_{\min} \leq B(i), \forall i \in [1, N]. \quad (14)$$

其中式(13)要求算法对调度计划的分配是能够保持能量中性的.式(14)是保证电池的电量永远不能低于 B_{\min} ,不然传感器节点将会停止工作.

4.1 任务调度算法

论文设定了 6 个任务调度计划 $M[M(1), \dots, M(6)]$,它们的能量消耗依次增加.任务调度算法开始为所有时段分配任务调度计划 $M(1)$.算法通过比较初始电量和时段 i 的电池电量以及预测能量与消耗能量的差值来评估能量中性条件.如果时间段 i 的电池容量和初始电量相等并且所有时段的电池电量至少为 B_{\min} ,而且预测收集到的太阳能与消耗的能量相等,则表明目前的解决方案是最优的.否则,可能会出现下面 4 种情况:(1) 如果 i 时段的电池电量大于初始电量,且此时充入电池的电量高于消耗的能量,因此可以选择更高能

图3 算法在 $\alpha=0.4, \beta=0.6, \delta=0.6$ 时能量数据Fig.3 Energy data of the algorithm at $\alpha=0.4, \beta=0.6, \delta=0.6$

量消耗的任务调度计划.算法在 M 中选择具有更高消耗的任务调度计划,替换掉之前分配的任务调度.(2) 如果时段 i 的电池电量大于初始电量,且此时预测收集到的能量低于消耗的电量,这意味着此时电池中高于的电量可能在下个时段消耗,算法保持当前的任务调度.(3) 如果时段 i 的电池电量低于时段 0 的电池电量,且此时预测收集到的太阳能高于消耗的电量,这意味着此时电池中低于 B_0 的电量可能在后续时段被补充,此时算法保持当前任务调度不变.(4) 如果时段 i 的电池电量低于初始电量或者存在时段 i 的 $B(i) < B_{\min}$,且此时预测收集到太阳能低于消耗的电量,这意味着当前电池电量会持续消耗,算法需要在 M 中选择较低能量消耗的任务调度,替换当前的任务调度.

任务调度算法

```

算法输入:
    初始电量  $B(0)$  预测到的太阳能  $\hat{E}(i)$ , 充电效率  $\sigma$ 
算法输出:
    电池电量  $B(t)$  每个时间段调度计划  $S(t)$ 
1 all  $S(t) = M(1)$ 
2 if  $B(t-1) > B_0 \wedge \sigma \hat{E}(i) > M(1)$ 
3   for  $n = 1$  to 6
4     if  $M(n) > S(t-1)$ 
5        $P(t) = M(n)$ 
6        $S(t) = P(t)$ 
7     break
8 if  $B(t-1) > B_0 \wedge \sigma \hat{E}(i) < M(1)$ 
9    $S(t) = S(t-1)$ 
10 if  $B(t-1) < B_0 \wedge \sigma \hat{E}(i) > M(1)$ 
11    $S(t) = S(t-1)$ 
12 if  $B(t-1) > B_0 \wedge \sigma \hat{E}(i) > M(1)$ 
13   for  $n = 1$  to 6
14     if  $M(n) < S(t-1)$ 
15        $P(t) = M(n)$ 
16        $S(t) = P(t)$ 
17     break
    
```

4.2 任务调度仿真结果

本文用 MATLAB 2022a 进行仿真实验,实验将 1 d(24 h)分为 96 个时段,每个时段的持续时间为 15 min.仿真数据是来自美国国家可再生能源实验室(NERL)的太阳能数据,一共 15 d,720 个时隙的太阳能数据.节点参数设定如表 2 所示,节点能量消耗模型依据式(3).由于 0 点到 6 点,18 点到 24 点收集到的太阳能趋近于 0,所以仿真实验中将这两个时间段收集的能量默认为 0.

表 2 仿真参数

Tab. 2 Simulation parameters

电池参数	初始电量/mAh	电池最大容量 B_{\max} /mAh	太阳能电池效率 $\sigma/\%$	接收模式电流/mA	发送模式电流/mA	空闲模式电流/ μ A	睡眠模式电流/ μ A	处理器电流/mA
数值	2 000	2 500	10.83	19.7	11	10	1	6

为评价本文所提方案性能,将本文方案同 DDCA(dynamic duty cycle adaption)算法^[18]和 Q-Leaning 算法进行对比实验.DDCA 算法需要设置两个阈值,分别为最大电量 BMAX 和最小电量 BMIN,当电池电量处于最大电量和最小电量之间时,算法根据节点收集到的能量和消耗掉的能量进行能量管理,当电量小于最小电量时,算法会将节点调整为睡眠模式.DDCA 算法的参数设置为 BMAX = 2 500 mAh, BMIN = 1 950 mAh.Q-Leaning 算法是一种异策略更新方法,这种方法能根据行为策略获得更大的探索范围.Q-Leaning 算法需要确定控制收敛速度的学习速率 η ,折扣因子 γ 和奖励因子 K .在本文对比实验中 $\eta = 0.5$, $\gamma = 0.5$, $K = 1$.

图 4 为本文方案、DDCA 算法^[18]和 Q-Leaning 算法^[13]3 种管理方案 5 d 电池的容量变化.每个时段的初始任务调度安排为最低消耗.在日出之后调度算法会根据预测到的能量和电池的电量来判断是否来选择更加符合当前能量摄入情况的任务调度.11 日到 15 日的能量收集维持在一个比较平均的水平.在第 96、192、288、384、480 个时序(即一天结束时的时序)本文方案的电池能量分别为 1 969.8、1 966.4、1 964.9、1 961.0、1 966.0 mAh,与初始电量相差 1.72%,说明此任务调度计划在 24 h 实现了能量中性原则(即 24 h 内节点的消耗和收集到的能量持平).DDCA 算法在一天结束时的时序的电池电量为 1 952.8、1 968.8、1 944.9、1 951.1、1 970.6 mAh,与本文的能量管理方案相比,损失的能量多出 20.9%.Q-Leaning 算法在一天结束时的时序的电池电量为 1 974.2、1 963.2、1 968.8、1 929.9、1 922.1 mAh,与本文方案相比损失的能量多出 40.6%,前面两天 Q-Leaning 算法的剩余电池电量维持在一个较好水平,随着时间推移电量逐渐降低,最后

一天的剩余与初始电量相差 3.9%。实验表明,本文方案优于 DDCA 算法和 Q-Leaning 算法。

表 3 列出了 DDCA 算法和 Q-Leaning 算法与本文算法的时间复杂性比较,时间复杂性用算法运行时间表示。表 3 表明本文方案与其他两种算法相比,在保证 24 h 能量中性的同时,保持了较小的时间复杂度。

为进一步评估本文方案的性能,物理实验在中国中南部城市武汉进行,时间是 2022 年 3 月。传感器网络在 TI CC2530 平台上实现,传感器节点用 TPS62737 的 TI BQ25505 芯片用于管理太阳能电池板收集的能量。这是一个集成的能量管理解决方案,非常适合满足超低功耗的特殊应用程序。MAXIX DS2780 芯片用于测量电池的剩余电量,DS2780 是一款 16 位专业测量 IC,用于估算可充电锂电池的可用容量。实验布置了 6 个集成式的传感器节点,每个传感器节点基于本文中提出的预测算法和能量管理算法。实验进行了 5 d 的能量预测和管理,节点在每天结束时的电量分别为 1 970.4、1 963.0、1 961.7、1 960.8、1 968.4 mAh。与初始电量相差 1.76%。物理实验表明本文方案在天气出现变化时迅速调整节点的任务调度,从而实现 24 h 的能量中性管理。

表 3 管理算法时间复杂性比较

Tab. 3 Manage algorithm time complexity comparison

算法	DDCA	Q-Leaning	本文方案
时间复杂度/s	5.046×10^{-3}	6.901×10^{-3}	4.876×10^{-3}

5 结束语

本文针对太阳能无线传感器网络提出一种太阳能收集预测算法和能量管理方案,根据预测的能量,调整传感器节点的调度计划,实现节点的能量消耗中性,从而使传感器节点能够长期稳定地工作。仿真实验表明,本文预测方案误差率只有 8.6%,相比 EWMA 预测算法和 Pro-Energy 算法误差降低了 52.2%和 48.0%。本文能量管理方案相比 DDCA 和 Q-Leaning 算法能量损失降低了 20.9%和 40.6%,说明本文提出的方案在能量预测精度和能量管理策略方面有明显的优势。

参 考 文 献

- [1] LANZOLLA A, SPADAVECCHIA M. Wireless sensor networks for environmental monitoring[J]. Sensors, 2021, 21(4): 1172.
- [2] ROKONUZZAMAN M, MISHU M K, AMIN N, et al. Self-sustained autonomous wireless sensor network with integrated solar photovoltaic system for Internet of smart home-building (IoSHB) applications[J]. Micromachines, 2021, 12(6): 653.
- [3] 詹华伟, 王良源, 陈思, 等. 基于 RSSI 的四边测距井下人员定位系统[J]. 河南师范大学学报(自然科学版), 2021, 49(4): 53-59.
ZHAN H W, WANG L Y, CHEN S, et al. Four-sided ranging underground personnel positioning system based on RSSI[J]. Journal of Henan Normal University (Natural Science Edition), 2021, 49(4): 53-59.
- [4] JUNESCO D, SUPRIYANTO E, HASAN A, et al. QoS analysis of WSN (Wireless Sensor Network) using node MCU and accelerometer sensors on bridge monitoring systems[J]. IOP Conference Series: Materials Science and Engineering, 2021, 1108(1): 012025.
- [5] ADU-MANU K S, ADAM N, TAPPARELLO C, et al. Energy-harvesting wireless sensor networks (EH-WSNs): a review[J]. ACM Transactions on Sensor Networks, 14(2): 1-50.
- [6] SHARMA H, HAQUE A, JAFFERY Z A. Solar energy harvesting wireless sensor network nodes: a survey[J]. Journal of Renewable and

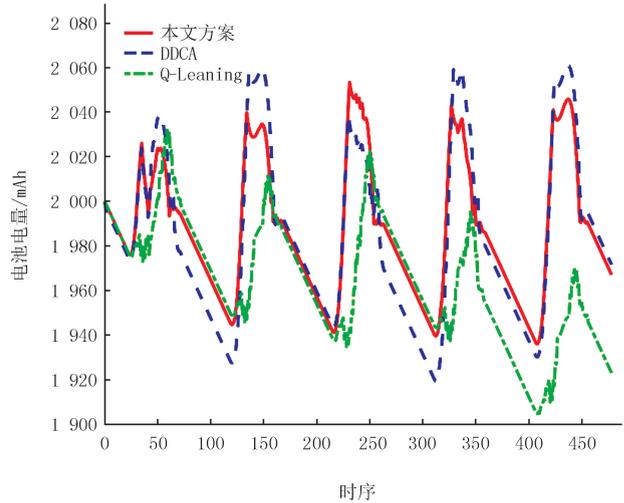


图4 5 d之中不同的管理方案电池的容量变化

Fig. 4 Battery capacity changes for different management schemes over five days

- Sustainable Energy, 2018, 10(2):023704.
- [7] KANSAL A, HSU J, ZAHEDI S, et al. Power management in energy harvesting sensor networks[J]. ACM Transactions on Embedded Computing Systems, 2007, 6(4):32.
- [8] CAMMARANO A, PETRIOLI C, SPENZA D. Pro-Energy: a novel energy prediction model for solar and wind energy-harvesting wireless sensor networks[C]//2012 IEEE 9th International Conference on Mobile Ad-Hoc and Sensor Systems(MASS 2012). Las Vegas: IEEE, 2013:75-83.
- [9] KOSUNALP S. A new energy prediction algorithm for energy-harvesting wireless sensor networks with Q-learning[J]. IEEE Access, 2016, 4:5755-5763.
- [10] SHU T X, CHEN J H, BHARGAVA V K, et al. An energy-efficient dual prediction scheme using LMS filter and LSTM in wireless sensor networks for environment monitoring[J]. IEEE Internet of Things Journal, 2019, 6(4):6736-6747.
- [11] DEB M, ROY S. Enhanced-pro: a new enhanced solar energy harvested prediction model for wireless sensor networks[J]. Wireless Personal Communications, 2021, 117(2):1103-1121.
- [12] HSU R C, LIU C T, WANG H L. A reinforcement learning-based ToD provisioning dynamic power management for sustainable operation of energy harvesting wireless sensor node[J]. IEEE Transactions on Emerging Topics in Computing, 2014, 2(2):181-191.
- [13] AIT AOUDIA F, GAUTIER M, BERDER O. RLMan: an energy manager based on reinforcement learning for energy harvesting wireless sensor networks[J]. IEEE Transactions on Green Communications and Networking, 2018, 2(2):408-417.
- [14] HSU R C, LIN T H, SU P C. Dynamic energy management for perpetual operation of energy harvesting wireless sensor node using fuzzy Q-learning[J]. Energies, 2022, 15(9):3117.
- [15] LIU X Z, QI N J, DAI K R, et al. Sponge Supercapacitor rule-based energy management strategy for wireless sensor nodes optimized by using dynamic programming algorithm[J]. Energy, 2022, 239:122368.
- [16] PRAUZEK M, KONECNY J. Optimizing of Q-learning day/night energy strategy for solar harvesting environmental wireless sensor networks nodes[J]. Elektronika Ir Elektrotechnika, 2021, 27(3):50-56.
- [17] ALI M I, AL-HASHIMI B M, RECAS J, et al. Evaluation and design exploration of solar harvested-energy prediction algorithm[C]//2010 Design, Automation & Test in Europe Conference & Exhibition(DATE 2010). [s.l.]: IEEE, 2010:142-147.
- [18] PENDEM S, SURESH K. Energy harvesting using adaptive duty-cycling algorithm-wireless sensor networks[J]. Energy, 2017, 13(3):100-109.

Energy prediction and management of solar wireless sensor networks

Wang Yuanxiang, Xu Zhen

(School of Electrical and Electronic Engineering, Wuhan Polytechnic University, Wuhan 430048, China)

Abstract: Wireless sensor networks face the challenge of limited battery power. To prolong the lifespan of the network, sensor nodes can utilize solar panels to convert solar energy into electricity for self-sustained operation. Given the uncertainty and intermittency of solar energy, a prediction algorithm for solar energy collection and an energy management scheme are proposed. According to the predicted energy levels, the scheduling plan for sensor nodes is adjusted to achieve energy consumption neutrality, ensuring the stable operation of the wireless sensor network over an extended period. The simulation results demonstrate that this scheme offers clear advantages in energy prediction accuracy and energy management strategy.

Keywords: wireless sensor network; solar energy; energy prediction; energy management

[责任编辑 陈留院 赵晓华]