

# 面向WSN的高精度预测算法和分簇路由研究

王冬梅, 葛钰晓, 杨耀宗, 史 猛

北方工业大学, 信息学院, 北京

收稿日期: 2023年5月16日; 录用日期: 2023年7月31日; 发布日期: 2023年8月8日

## 摘 要

无线传感器网络(WSNs)中的节点通常由电池供电, 能量是限制网络性能的重要因素。尽管部分节能路由和低功耗协议的提出在一定程度上缓解了此问题, 但是无法从根源上解决。太阳能是一种可再生清洁能源, 是解决网络能量受限问题的有效途径, 但由于能源具有不稳定性, 因此针对此类能量收集无线传感器网络(EH-WSN)进行充能预测和路由规划的研究具有重要意义, 它是EH-WSN中低功耗技术的重要研究内容。针对充能预测, 本文提出一种基于分类和递归的高精度预测算法k-LSTM, 以实现更高效的能源管理, 为WSN的路由规划提供有力支撑。此外, 针对分簇路由中簇首节点选择不合理导致节点耗能加剧, 网络性能不佳的问题, 本文改进簇首适应度函数提出了一种基于粒子群的分簇算法, 并对簇间路由由下一跳的选择提出新的代价函数, 进一步优化网络能源消耗。实验证明了所提方案对网络性能的提升优势, 延长了网络寿命, 并提高了网络吞吐量。

## 关键词

无线传感器网络, 低功耗, 能量收集, 充能预测, 分簇路由

# Research on High-Precision Prediction Algorithm and Clustering Routing for WSN

Dongmei Wang, Yuxiao Ge, Yaozong Yang, Meng Shi

College of Information, North China University of Technology, Beijing

Received: May 16<sup>th</sup>, 2023; accepted: Jul. 31<sup>st</sup>, 2023; published: Aug. 8<sup>th</sup>, 2023

## Abstract

Wireless Sensor Networks (WSNs) are usually powered by batteries, while energy is a critical factor limiting network performance. Although some energy-saving routing and low-power protocols have been developed to alleviate this problem to some extent, they cannot solve it fundamentally. Solar energy is a renewable and clean energy source that offers an effective solution to the prob-

lem of energy limitation in networks. However, due to the instability of energy, research on charging prediction and routing planning for energy-harvesting wireless sensor networks (EH-WSNs) is of significant importance and is a crucial research area in low-power technologies for EH-WSNs. For charging prediction, this paper proposes a high-precision prediction algorithm, k-LSTM, based on classification and recursion to achieve more efficient energy management and provide strong support for WSN routing planning. Moreover, to address the problem of energy consumption due to the unreasonable selection of cluster heads in cluster routing, which leads to poor network performance, we propose an improved cluster head fitness function and a PSO-based clustering algorithm. We also introduce a new cost function for selecting the next hop in inter-cluster routing to further optimize network energy consumption. Our experimental results demonstrate the advantages of the proposed solutions in improving network performance, significantly reducing the energy consumption of nodes, prolonging network lifetime, and increasing network throughput.

## Keywords

Wireless Sensor Networks, Low-Power, Energy Harvesting, Charging Prediction, Cluster Routing

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

随着物联网的快速发展和应用领域的不断扩展,无线传感器网络作为物联网的重要组成部分,越来越受到关注[1]。无线传感器网络是由大量的无线传感器节点组成的分布式网络,这些节点具有自组织、低功耗、自适应等特点,能够实时感知环境信息,对环境进行监测和控制。但是,由于无线传感器节点的能源有限,如何延长无线传感器网络的寿命成为了研究的重点之一。

为了解决由电池供电的传统 WSN 寿命有限问题,一些研究为传感器节点配备能量采集功能,能量收集成为了实现无线传感器网络(WSN)永久运行目标的最有前途的技术之一。由于光伏系统已得到极大改善[2],所以太阳能成为 WSN 供电的比较常见的能源之一。为了提高节点的能量利用效率和延长其寿命,需要对节点能量的充电和消耗情况进行预测和优化。而节点的充电情况与环境的能量供给密切相关,因此需要对环境能量进行分析和预测。现有与预测方案在天气频繁变化时准确率较低,以此作为能量感知路由的关键,节点死亡率较高。而低功率技术旨在采用适应于环境采集技术的路由协议和算法,通过优化能源效率维持网络稳定运行来延长整个传感器网络的寿命。大多研究采用分簇算法来对网络进行管理,降低网络功耗,但是由于分簇算法中簇首节点的重要地位,簇首节点的选举方式、能量消耗和位置不合理性极大地影响网络性能和数据传输质量,因此需要综合多方面因素选择簇首节点并对簇间路由进行优化,维持网络长期稳定运行。

## 2. 相关工作

### 2.1. 太阳能预测模型

在通信设备的小规模能量收集技术的快速普及以及其不确定的功率可用性带来的挑战的推动下,最近几年的许多工作都集中在能量收集无线传感器网络的能量预测技术[3] [4] [5] [6] [7]。常见的预测模型可以分为机器学习、统计学和随机三类[3]。考虑到随机模型的状态空间扩展困难这一较为显著的缺点,

下面针对基于统计和机器学习的模型进行介绍。

在基于统计的模型方面, Cammarano 等人提出了一种能量预测统计模型 Pro-Energy [4], 该模型将一天分为晴天、阴天或下雨并收集全天每个时间段的历史太阳辐照度, 通过寻找与当天最相似的日期来预测未来一段时间内的太阳辐照度。Deb [5]等人提出了一种利用过去及当前的能源观测来预测未来能源可用性的模型 Enhanced-Pro-Energy。其在 Pro-Energy 模型[4]的基础上, 引入两个微调参数来匹配过去和当前的天气情况, 进一步提高了预测精度。然而, 此模型使用了一个固定权重因子( $\alpha = 0.51$ )作为过去和当前辐照度的参考占比, 其取值对不同地区和季节的适用性仍需进一步验证和调整。基于传统概率统计的充能预测模型的准确度与天气稳定性关系密切, 在天气频繁变化的情况下, 预测误差较大。基于机器学习的充能预测算法中, Acikgoz [6]提出了一种基于卷积神经网络集成和深度特征选择的短期太阳辐射预测方法。该方法基于自适应噪声(EEMDAN)方法将全球太阳辐照度分解为莫函数, 然后采用小波变换重建数据特征, 利用级联卷积神经网络架构来提取深层特征。Rodríguez [7]等人提出了一种基于人工神经网络(ANN)的预测算法, 使用前 24 小时的辐照值来进行短期(10 分钟)预测, 实验证明该算法可提高对微电网控制的效率。但是, 机器学习相对于统计随机模型的计算开销更大, 与此同时算法耗时增加。此类模型大多基于类似的环境变化特征, 忽略了时间序列太阳辐照度的多尺度特性和现象内部波动, 预测准确率不理想。

## 2.2. 低功耗路由模型

近年来, WSN 在各行各业中得到了广泛应用, 但是, 由于传感器节点的能源受限, 其功耗问题一直是它的一大研究难题。一些研究采用了低功耗技术的分簇算法使其适用于 EH-WSN。Omek [8]等人设计了基于距离和能量约束的动态分簇协议来解决 WSN 寿命最大化问题。该协议根据所处位置和剩余电量合理选择簇头(CH), 并动态更新备选簇头设置的剩余能量阈值。Bozorgi [9]等人提出了一种新颖的节能分簇算法。这个分层路由协议包括处理和数据传输阶段。作者利用多跳路由根据传感器节点的当前能量来选择簇头。在这个协议中, 当执行集群分层和建立邻域信息的计算时, 会引入额外的能量消耗。Ren [10]等人提出了一个基于集群的方案。该方案为每个集群引入了一个调度节点概念, 该调度节点监控集群成员和簇头的剩余能量以减少簇头的工作量。同时, 所有传感器节点的通信半径可以动态调整, 但是该方案忽略了节点的消耗能量不能超过收获的能量, 如果消耗的能量大于收获的能量节点就会死亡。

由于引入太阳能采集技术后, 传感器节点由于部署环境和光伏板朝向等的因素导致了各节点收集能量不均衡, 其次, 各节点由于传输任务和转发数据的不同, 能量消耗也不尽相同, 这两者因素的叠加导致了各个传感器节点间能量不均衡情况加重, 严重将导致路由空洞现象的出现。部分节点虽然当前剩余能量较多但是未来充能较多且转发数据量少, 部分节点能量少但是转发任务重, 所处环境不利于其数据的大量收发导致了热节点过早死亡。综上, 针对低功耗技术中的分簇算法研究, 由于簇首节点承担传输和接收数据的重要任务, 其能量消耗严重影响网络的能量均衡性。所以, 现有分层路由算法仍需进一步改进, 例如簇首节点消耗大量能量, 选举方式较为随机, 簇首节点位置较为密集但是剩余能量过低的情况时有发生。彼时个别簇首节点耗能较大导致其死亡, 那么所在簇的节点数据将无法上传至基站, 用户质量无法保证。因此, 本文综合考虑节点剩余能量、预测充能、节点位置和簇结构的紧凑性, 用适应度函数修改粒子群算法, 通过优化簇头选择来优化能源效率。并在数据传输阶段综合考量多种因素来优化集群间下一跳路由的选择。通过优化簇头选择和路由重建, 来延长 WSN 寿命, 维持网络稳定运行。

### 3. 系统设计

#### 3.1. 太阳辐照度预测

##### 3.1.1. 模型设计

由于太阳能具有昼夜周期的循环特点, 经过实践, 我们发现直接使用回归模型难以精确地预测, 通过对数据的观察发现, 在不同类型的气候、季节和天气条件下, 光能充电会产生很大的差异。因此, 本文尝试设计一种算法, 先对天气进行分类, 再利用回归模型对天气进行预测, 准确率有了明显的提高, 超过了目前的研究方法[3] [7]。由于太阳辐照度是一类具有时间序列特征的数据, 而递归模型是处理时间序列数据的有效方法, 因此, 本文尝试使用递归神经网络中模型针对时间序列适用能力较强的 LSTM 神经网络训练具有强相关性的天气数据。本文提出了结合分类和回归的预测算法 k-LSTM。其中, k-means++ 算法用来对数据进行聚类, 以提高训练数据的相关性。LSTM 模型用来对分类数据进行训练, 以挖掘太阳辐照数据潜在的特征(周期性和变化趋势)以便实现更精准的预测, LSTM 网络的输出预测值可作为路由算法中能量因素的预测分量参与路由计算, 有效利用收获能量对路由算法进行改进。以下是实现太阳辐照度预测的步骤:

##### 1) 数据准备

收集历史太阳辐照度数据, 并将其划分为训练集和测试集。并对数据进行归一化, 以便更好地训练 LSTM 模型。将太阳辐照度数据组织为 25 维数据, 包括预测时间前 24 小时的太阳辐照度(24 维)、训练集中所有预测时间的平均太阳辐照度, 作为模型的训练数据。

##### 2) k-means++ 算法聚类

通过对训练集数据进行聚类, 来识别不同的辐照度模式。本文采用均方根误差(RMSE)来衡量预测值与真实值之间的距离, 通过寻找最小的 RMSE 来确定聚类数量  $K$ 。具体地, 评估公式如(1)所示:。

$$RMSE = \sqrt{\frac{1}{n} \sum_{n=1}^N (E_{pre} - E_{real})^2} \quad (1)$$

我们在选择聚类数量的范围为[1] [10], 对不同聚类下的均方根误差进行评估, 以确定最佳聚类  $K$ , 详细效果如图 1。但是聚类数量的增加使模型的过拟合程度增强, 导致误差变大, 此时不利于模型的训练。可以看出, 在聚类数量  $K=4$  时, 均方根误差达到最小值, 但是随着聚类数量增加到 5, 预测误差开始上升。因此可以得出结论, 太阳辐照度呈现出 4 种强相关的变化趋势, 此时的模型有更好的预测能力。因此, 本文将太阳辐照度分为 4 个聚类。

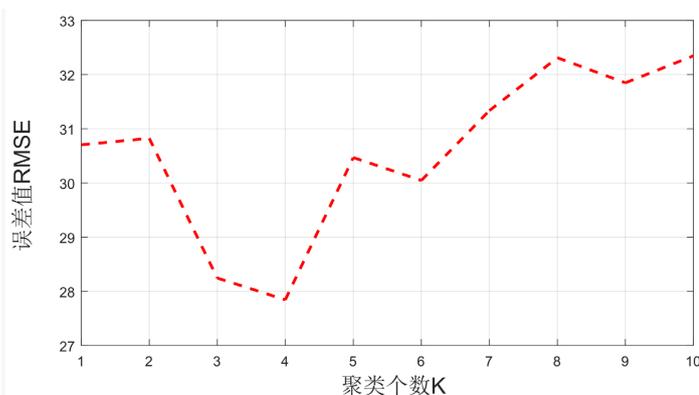


Figure 1. The relationship between the number of clusters and the value of the error  
图 1. 聚类个数与误差值的关系

### 3) LSTM 模型构建

将每个聚类中的时间序列数据转换为 LSTM 网络的输入序列。构建 LSTM 模型，将聚类组中的代表性辐照度值作为输入，并使用历史辐照度数据训练模型。模型的输出为下一个时刻的辐照度预测值。

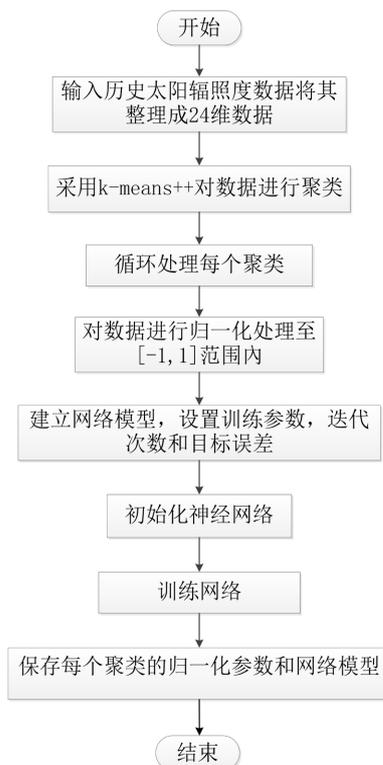
### 4) 模型训练和调整

采用训练数据集训练 LSTM 模型，并使用测试数据集进行 LSTM 模型参数调整，以获得最佳性能。LSTM 的输入层包含 25 个神经元，即 1) 中所述 25 维数据，隐含层采用经验公式(2)所示，经过实验，当隐含层个数为 7 时，效果更好，所以 LSTM 隐含层神经元个数设定为 7。输出层神经元个数设为 1，因为要预测的是单序列变量，即预测时刻的太阳辐照度。

$$n = \sqrt{(m + p)} + a \quad (2)$$

### 5) 辐照度预测

本文对于模型的训练和预测过程都是在与 sink 节点相连的基站进行的。实际应用里，输入历史数据进行训练，LSTM 网络对每个时间点的序列信息进行预测，输出下一个时间点的预测值。LSTM 模型训练的流程如图 2 所示。



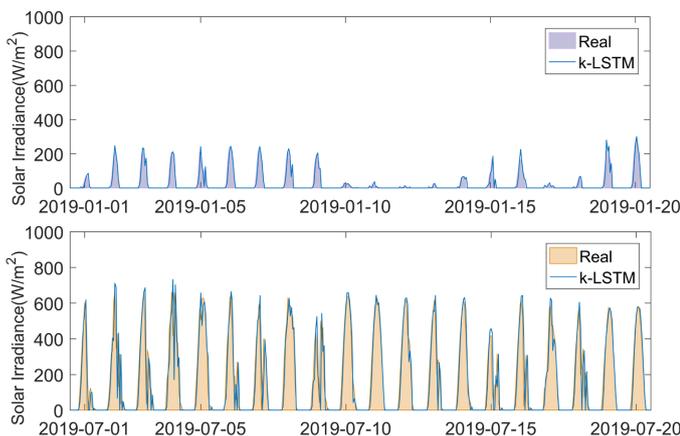
**Figure 2.** The process of training an LSTM model  
**图 2.** LSTM 模型训练的流程

#### 3.1.2. 仿真实验

为了验证本文提出的预测算法在不同季节下的准确性，本文拟增加数据集的数量，采用可再生能源权威数据库中的数据集[11]来预测不同季节下的太阳辐照数据。

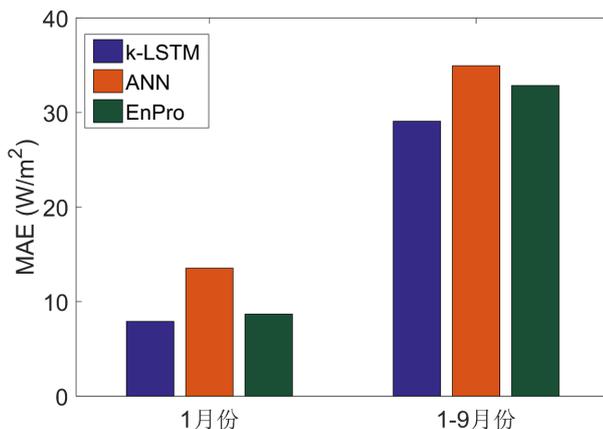
我们选取冬季和夏季天气频繁变化较为典型的月份 1 月份和 7 月份各 20 天的太阳辐照度，以此来验证本文提出的预测算法 k-LSTM 在频繁变化天气状况下的优化效果。由图 3，1 月份的太阳辐照度值低

于7月份,采用k-LSTM预测的效果与真实值的差异较低,尽管有部分天数的预测值出现偏离,但总体而言预测值与真实值的范围几近相似。



**Figure 3.** Predicting solar irradiance in summer and winter  
**图 3.** 夏季与冬季的太阳辐照度预测

为了更进一步验证本文提出的算法的预测误差,本文选取了2019年1月~9月份的数据并采用三种预测方法 EnPro [3]、ANN [7]和k-LSTM 对其进行处理,使用平均绝对误差 MAE 来评估预测准确度,此时预测步长为1小时。由图4所示,在一月份时,EnPro 的 MAE 为 8.68, k-LSTM 的 MAE 为 7.91, ANN 的 MAE 为 13.54。随着预测时间线延长至9个月,整体的预测误差增加,但是可以看出 k-LSTM 的预测误差度表现更优。这是因为 k-LSTM 首先采用 k-means++ 聚类算法对天气状态进行分类并有针对性地对每个聚类进行训练学习,找出非线性的太阳辐照度数据内部强相关关系的序列,然后基于长短期神经网络 LSTM 对强相关关系的子序列进行预测,可以有效应对长期和短期的天气波动,大大提高了预测模型的准确度。



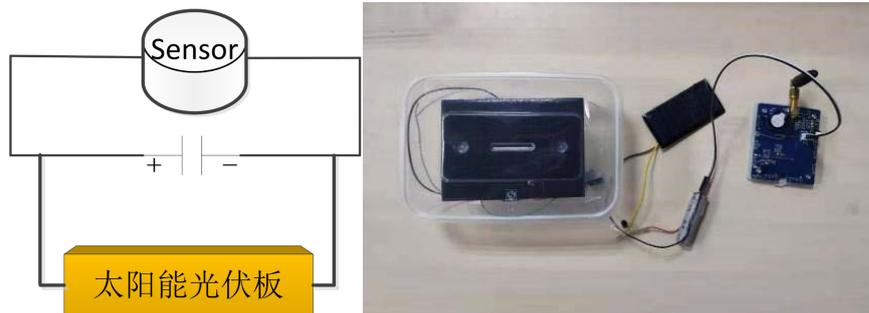
**Figure 4.** Comparison of forecast accuracy for different time series  
**图 4.** 不同时间序列的预测精度对比

### 3.1.3. 硬件选型和户外应用

本文的 EH-WSN 中,我们选取太阳能作为环境补充能源,选取常见 ZigBee 节点 SM14Z2538 开发板作为实验节点,搭建了基于锂电池的能量采集型传感器节点,为太阳能模型训练和能量预测的研究提供

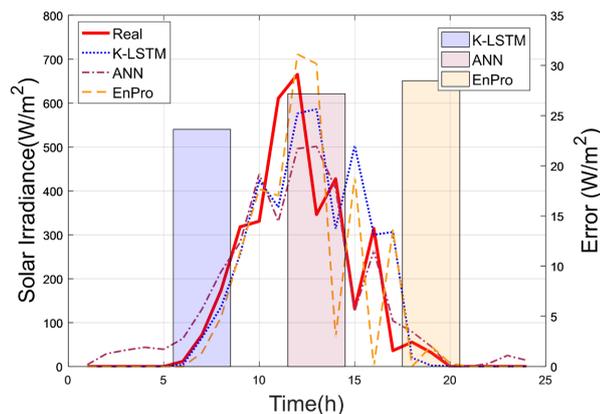
了数据支撑依据。

本文采用改造后的系统装置(图 5)在室外进行太阳能数据采集,并实时返回太阳辐照度数据。通过在室外进行数据采集监测及测试,验证了系统的可行性。



**Figure 5.** Hardware connection diagram of the energy harvesting system  
**图 5.** 能量收集系统的硬件连接图

为了验证预测算法在实际应用中对环境的适用性,我们对进行真实节点部署和实验,采取了两个月的室外太阳辐照度数据,以此验证 K-LSTM 的户外精确度。由图 6 所示,折线分别代表一天中各预测算法的预测值,柱状图代表两个月的预测误差。本文所提算法相对与 ANN 和 EnPro 分别提升了 14.8% 和 17.8%。实验证明 K-LSTM 在户外确实有更高的准确度。



**Figure 6.** Comparison of prediction errors for outdoor deployment  
**图 6.** 户外部署预测误差比较

## 3.2. 基于粒子群改进优化分簇路由

### 3.2.1. 系统模型

本文将户外 EH-WSN 中的簇抽象为一个无向联通图  $G = \{V, E\}$ , 其中  $V$  是由  $n$  个随机部署的传感器节点组成的监控区域内的集合,  $E$  是两个节点间的一条边, 表示节点间可以直接通信。 $v$  表示一个簇中的传感器节点, 其中  $v \in V$ , 边  $e = (u, v) \in E$  表示节点  $u$  和  $v$  对应节点之间可以互相通信。 $S$  为 sink 节点, 每个节点由太阳能供电, 其能量用于数据接收和传输。

其中, 所有传感器节点为

$$N = \{N_1, N_2, \dots, N_n\} \quad (3)$$

簇首节点集合 CH 为

$$CH = \{h_1, h_2, \dots, h_m\} \quad (4)$$

簇内成员集合 CM 为:

$$CM = \{m_1, m_2, \dots, h_{n-m}\} \quad (5)$$

假设  $f_{ij}$  为 bool 变量, 则它满足条件:

$$f_{ij} = \begin{cases} 1, m_j \in h_j (\forall i, j: 1 \leq i \leq n, 1 \leq j \leq m) \\ 0, \text{其他} \end{cases} \quad (6)$$

$$\sum_{j=1}^m f_{ij} = 1, 1 \leq i \leq n \quad (7)$$

$$\sum_{j=1}^m D_{m_j}^{h_j} \times f_{ij} \leq d_{\max}, 1 \leq i \leq n, m_i \in N, h_j \in CH \quad (8)$$

节点未来收获的能量用  $E_h^i$  表示, 电池的容量用  $cap$  表示, 则有约束条件:

$$E_h^i + E_r^i \leq cap \quad (9)$$

$$\sum_{i=1}^n E_{rx}^i + E_{tx}^i + E_{DA}^i \leq \sum_{i=1}^n (E_h^i + E_r^i) \quad (10)$$

约束条件(7)表示一个传感器节点  $m_i$  只能发送数据给一个簇首节点。约束条件(8)表示分配的簇内成员在 CH 的通信范围。约束条件(9)表示节点剩余能量和未来收获能量之和要小于电池的容量。约束条件(10)表示节点消耗的总能量不能大于节点剩余能量和收获能量之和以维持网络能量中性。本节算法均需满足约束条件(7)~(10)。

### 3.2.2. 能耗模型

在 EH-WSN 中, 网络消耗的总能耗等于通信耗能与数据处理耗能之和, 通信耗能为发送能耗 + 接收能耗, 还要乘以相应的系数。

#### 1) 发送数据消耗能量

本文中 EH-WSN 的能量收发模型使用 WSN 中通用一阶无线电模型[12], 向距离为  $d$  处发送  $k$  比特消息时节点消耗能量为:

$$\begin{cases} E_{tx}(k, d) = k \times E_{elec} + k \times \epsilon_{fs} \times d^2, d < d_o \\ E_{tx}(k, d) = k \times E_{elec} + k \times \epsilon_{mp} \times d^4, d > d_o \end{cases} \quad (11)$$

#### 2) 接收数据消耗能量

节点接收  $k$  比特消息消耗能量为:

$$E_{rx}(k) = k \times E_{elec} \quad (12)$$

#### 3) 数据融合消耗能量

簇头作为融合节点也会消耗部分能量。假设一个簇内有  $n$  个簇内成员, 簇内成员收集环境信息将数据发送给簇头节点, 簇头节点需要融合成员信息  $l$  长度的耗能表示为:

$$E_{DA}(k) = n \times E_{DA} \times l \quad (13)$$

### 3.2.3. 簇首适应度函数选取

由于 EH-WSN 中供能的周期性和不确定性, 这将显著影响网络路由算法的效率, 所以在进行簇首节

点的选择时, 本文着重考虑簇首节点的耗能特点, 综合考虑能量、距离、簇紧凑性和能耗均衡四重因素来构建簇首节点选择函数。其中能量因素包括剩余能量和未来预测充能两部分, 由前文分析可知, 未来预测充能是构建路由算法必须要考虑的重要因素之一, 避免一些节点因为当前能量不足但未来充能较多或即便当前能量充足但是未来充能较弱导致的误差使路由规划不当造成网络寿命表现不佳。距离因素包括簇首距离到节点之间的距和节点到 sink 节点的距离。簇紧凑性即簇内节点到簇头的距离。能耗均衡是指选择的簇首节点能量相近。通过适应度函数各选择因子对簇首节点的综合评估, 以此增强 PSO 算法迭代寻求最优簇首节点集(即最优解)的能力。适应度函数值越大, 说明所选择的簇首节点越优。适应度函数各部分影响因子具体描述如下:

- 1) 能量因子: 节点的剩余能量  $E_r^i$  和未来预测充能  $E_h^i$

$$f_{CH1} = \overline{E_{CH}} = \sum_{i=1}^m (E_h^i + E_r^i) / m \quad (14)$$

- 2) 簇头到 sink 节点的距离因子

$$f_{CH2} = \overline{D_{CH}^{sink}} = \sum_{i=1}^m \frac{D_{CH_{max}}^{sink} - D_{CH_{min}}^{sink}}{(D_{CH_i}^{sink} - D_{CH_{min}}^{sink})} / m \quad (15)$$

- 3) 簇间距离因子

$$f_{CH3} = \overline{D_{CH}^{CM}} = \frac{(D_{CH_i}^{CM_j})_{max} - (D_{CH_i}^{CM_j})_{min}}{\sum_{j=1, CM_j \in CH_i}^{n=m} D_{CH_i}^{CM_j}} \quad (16)$$

- 4) 能效均衡因子

$$f_{CH4} = \frac{1}{\sqrt{\sum((E_h^i + E_r^i) - \overline{E_{CH}})^2}} = \frac{1}{\sqrt{\sum((E_h^i + E_r^i) - (\sum_{i=1}^m (E_h^i + E_r^i) / m))^2}} \quad (17)$$

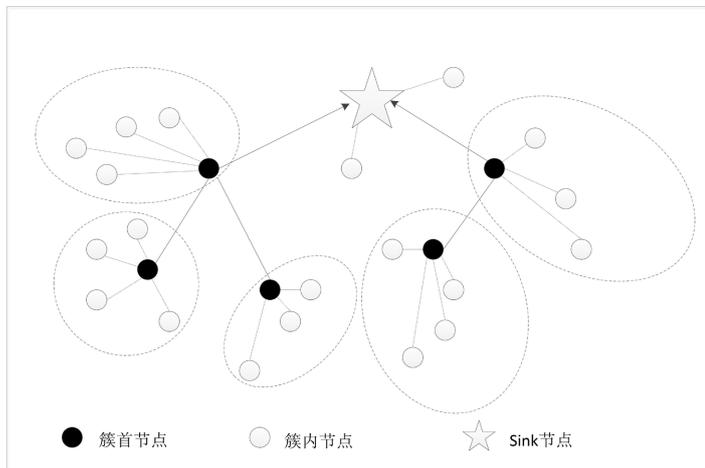
为了 PSO 算法的择优能力更强, 本文综合考虑四个因素来构造适应度函数, 对于簇首的选取考虑因素更加全面, 即具有更高可用能量、且位置分布距 sink 节点更近、簇更紧凑和能量相对均衡的节点被选为簇首节点的概率较高。通过将四个因素各自乘权重再相加的形式, 从而转化多目标函数为单目标函数。权值分别是  $\delta_1$ 、 $\delta_2$ 、 $\delta_3$  和  $\delta_4$ ,  $\delta$  的取值大小影响各部分影响力所占比重, 公式(18)和(19)表示单目标的适应度函数 *fitness* 和权重取值条件。

$$fitness = \delta_1 f_{CH1} + \delta_2 f_{CH2} + \delta_3 f_{CH3} + \delta_4 f_{CH4} \quad (18)$$

$$\delta_1 + \delta_2 + \delta_3 + \delta_4 = 1 \quad (19)$$

### 3.2.4. 数据传输阶段

数据传输阶段是 WSN 的核心环节。在分簇路由协议中, 数据传输阶段是将簇内的数据传输至簇首节点以及将聚合后的数据传输至 sink 节点的重要过程。分簇阶段完成后, 节点  $i$  首先判断自己与 sink 的距离  $D_i^{sink}$  和到簇头的距离  $D_i^{CH}$  的大小, 若  $D_i^{CH} > D_i^{sink}$ , 则节点直接将数据传输给 sink 节点, 否则, 将数据发送至簇首节点; 簇首节点对接收数据进行融合以多跳形式传输至 sink 节点, 规则为: 首先计算该簇首到中继簇首的距离  $D_{CH_i}^{CH_j}$ , 并与 sink 节点比较, 若  $D_{CH_i}^{sink} < D_{CH_i}^{CH_j}$ , 该簇首将数据直接传输给 sink 节点; 否则基于中继节点进行数据转发, 中继节点的选择方式如下文所述。构建簇间路由的主要思想是基于树结构, 建立以 sink 节点为根节点, CH 为叶节点的路由树, 然后向 sink 方向传输数据, 网络传输机制如图 7 所示。



**Figure 7.** Routing mechanism during the stable transmission phase  
**图 7.** 稳定传输阶段路由传输机制

路由的下一跳候选节点由贪婪算法得到, 选择代价函数的函数值最小的节点进作为下一跳传输节点, 代价函数如公式(20)表示。

$$F_{\text{cost}(j)} = \beta_1 \left( \frac{D_{CH_j}^{CH \text{ sink}}}{\max(D_{CH_{\text{next}}}^{\text{sink}})} \right) + \beta_2 \frac{\overline{E_{CH}}}{E_j(\text{re\_hav})} + \beta_3 \frac{E(CH_j) + E_R}{E_{\text{total}}} + \beta_4 \frac{N_{CH_{\text{next}}}}{N_{CH_j}} \quad (20)$$

$\beta_1$  决定候选簇首节点到基站的距离因子占比,  $\beta_2$  决定了候选节点的剩余能量和收获能量因子占比,  $\beta_3$  决定了簇头的能量消耗因子占比, 优先选择能量消耗少的节点, 以免一些簇头节点能量消耗过多过快死亡从而造成能量空洞。 $\beta_4$  决定了中继节点的簇群规模因子占比。簇头节点能量越大, 距离基站越近, 中继节点簇内成员越多并且邻居节点耗能较小的节点被选为下一跳的可能性越大。 $\beta_i$  加权因子之和为 1,  $F$  值越小, 选择的中继节点越好。当路由由候选节点同时被选为中继簇首时, 选择剩余能量和预测充能之和较可观的节点作为中继节点。通过上述设计, 能够实现不同因素之间的权衡和调节, 在考虑多种因素的情况下, 选取最优的下一跳簇首节点, 从而提高网络传输的效率、可靠性和能量利用率。

### 3.2.5. 仿真实验

本章的仿真实验旨在评估基于粒子群优化算法的分簇路由算法在无线传感器网络中的性能表现, 比较分簇路由算法的不同参数设置对性能表现的影响, 仿真平台采用 matlab 2020 64 位, 系统使用的是 windows 10 操作系统, 硬件配置为 Intel(R) Core(TM) i5-6200U 2.4HGz 处理器和内存 8 G。为了保证结果的可靠性, 我们进行了 20 次模拟并取其平均值。在多个随机选取的网络拓扑和通信距离下, 分别测试了不同参数设置下的算法性能。在实验中, 我们选用了吞吐量、网络生命周期和节点死亡率来衡量算法的性能。

吞吐量是一个非常重要的性能指标, 能够直接反映出网络的数据传输能力。当基站位于传感器网络中心时, 基站和簇头接收到的总数据消息如图 8 和图 9 所示。本小节对比了 3000 轮内算法 KLPSO 算法和 LEACH [13]、SEP [14]、DEEC [15]和 EECH [16]的吞吐量。从图中以看出, 所提出的 KLPSO 协议在相同的轮次下比其余协议传送了更多的数据量。本文所提算法 KLPSO 在数据传输方面比传统协议 LEACH 提高了约 3 倍, 比 EECH 提高了约 25%~40%。由图 9 所示, 我们观察到前 1200 轮次所有算法的吞吐量相差不大, 但随着轮次的增加, 本文所提算法 KLPSO 的优势更加明显, 在 Round = 3000 时, 网络中簇头节点相对较多, 能量消耗也较为均衡, 吞吐量还未达到整个网络的阈值。这是因为网络运行初

期, 节点死亡率较低, 簇头活动节点相差较小, 但随着网络周期的不断更新, 优化分簇路由算法的重要性逐渐明显, 节点的能耗分布和簇头活动节点个数都会影响网络的吞吐量。

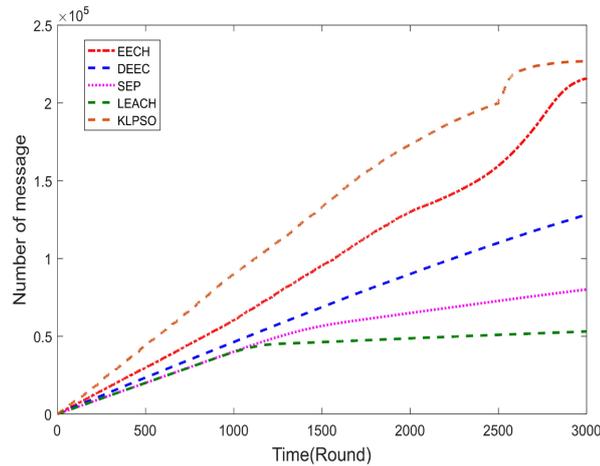


Figure 8. Data volume received by the base station (BS)

图 8. 基站接收数据量

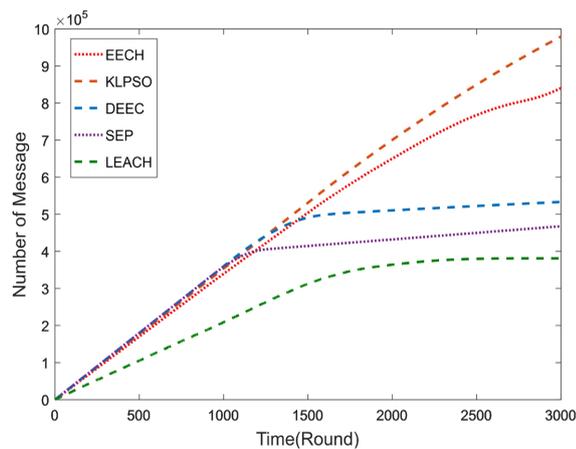


Figure 9. Data volume received by the cluster head (CH)

图 9. 簇头接收数据量

节点的生存周期是评估路由算法优劣的一个重要指标。在 LTS 2 下, 算法的优势表现得更明显。为了验证本文所提路由算法的独立贡献, 本文选取光照强度较低的黑夜或连续阴天作为实验条件, 图 10 和图 11 为几种算法在相同轮次下节点存活和死亡情况。可以看出, KLPSO 算法在 Round = 3000 时节点存活率最高, 此时 LEACH 和 SEP 节点数量已不足的 1/8。这是因为 LEACH 协议中簇首节点选举方式较为简单, 容易导致簇首节点的能量消耗过快, 从而影响网络寿命。SEP 在 LEACH 协议的基础上提出了更为稳定的簇首节点选举方法, 但簇首节点的位置无法动态调整、节点的能量消耗仍不均衡。DEEC 这种分布式的分簇路由协议, 通过综合考虑节点的位置、剩余能量因素来选举簇首节点, 从而实现均衡的能量分配, 并延长网络寿命。但是, DEEC 协议对于网络拓扑结构的要求较高, 且节点的选择机制较为复杂。对于本文的随机网络拓扑来说优化效果仍有待进一步提高。与其余分簇路由协议相比, 本文所提算法 KLPSO 改进了原始算法, 构建了适应度函数来优化簇头节点的选择。同时通过修改惯性权重, 避免粒子陷入局部最优, 加快算法收敛速度, 从而选择更合适的簇头节点。在进行簇间路由的构建时, 本文还

考虑了能耗与位置因素,使得网络能量消耗更加均衡,减少节点之间的冲突和能量消耗,并提高了数据传输的效率,从而延长了 WSN 的寿命。此外,基于粒子群的分簇策略对网络的动态变化更加适应,可以动态更新分簇结果,维持网络稳定运行,进一步优化网络寿命。

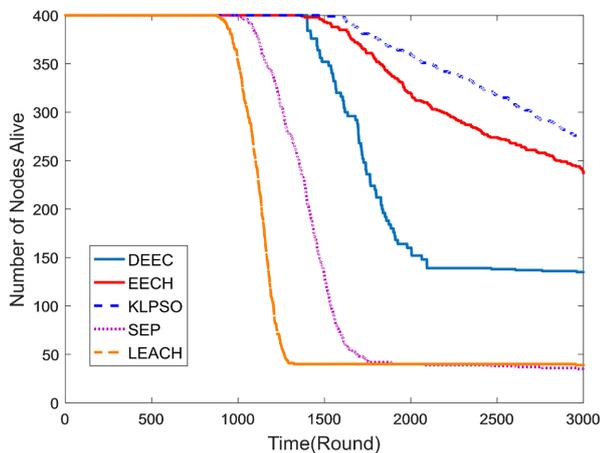


Figure 10. Comparison of node survival numbers under different rounds

图 10. 不同轮次下节点存活数量对比

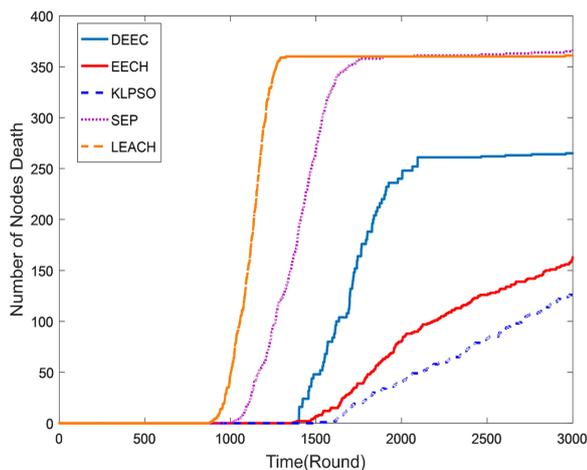


Figure 11. Comparison of node death numbers under different rounds

图 11. 不同轮次下节点死亡数量对比

#### 4. 结语

本文利用能量收集技术为 WSN 提供电量支持,提出了一种基于充能预测和分簇路由的低功耗技术。实验表明,本文的充能预测算法,可以将充能预测误差降低至 10% 以内,可有效提高了节点的能量利用效率;改进粒子群算法的分簇路由算法能够更好地平衡节点能量和网络负载,优化路由路径,减少能量消耗,提高了网络寿命。未来的研究方向包括进一步优化路由算法和充能预测算法,提高网络的可靠性和稳定性,拓展其在各个领域的应用。

#### 参考文献

- [1] Gulati, K., Kumar Boddu, R.S., Kapila, D., *et al.* (2013) A Review Paper on Wireless Sensor Network Techniques in

- Internet of Things (IoT). *Materials Today: Proceedings*, **51**, 161-165. <https://doi.org/10.1016/j.matpr.2021.05.067>
- [2] Bouguera, T., Diouris, J.-F., Andrieux, G., Chaillout, J.-J. and Jaouadi, R. (2018) A Novel Solar Energy Predictor for Communicating Sensors. *IET Communications*, **12**, 2145-2149. <https://doi.org/10.1049/iet-com.2018.5244>
- [3] Sah, D.K., Hazra, A., Kumar, R. and Amgoth, T. (2023) Harvested Energy Prediction Technique for Solar-Powered Wireless Sensor Networks. *IEEE Sensors Journal*, **23**, 8932-8940. <https://doi.org/10.1109/JSEN.2022.3208730>
- [4] Cammarano, A., Petrioli, C. and Spenza, D. (2012) Pro-Energy: A Novel Energy Prediction Model for Solar and Wind Energy-Harvesting Wireless Sensor Networks. 2012 *IEEE 9th International Conference on Mobile Ad-Hoc and Sensor Systems (MASS 2012)*, Las Vegas, 8-11 October 2012, 75-83. <https://doi.org/10.1109/MASS.2012.6502504>
- [5] Deb, M. and Roy, S. (2021) Enhanced-Pro: A New Enhanced Solar Energy Harvested Prediction Model for Wireless Sensor Networks. *Wireless Personal Communications*, **117**, 1103-1121. <https://doi.org/10.1007/s11277-020-07913-y>
- [6] Acikgoz, H. (2022) A Novel Approach Based on Integration of Convolutional Neural Networks and Deep Feature Selection for Short-Term Solar Radiation Forecasting. *Applied Energy*, **305**, Article ID: 117912. <https://doi.org/10.1016/j.apenergy.2021.117912>
- [7] Rodríguez, F., Fleetwood, A., Galarza, A. and Fontán, L. (2018) Predicting Solar Energy Generation through Artificial Neural Networks Using Weather Forecasts for Microgrid Control. *Renewable Energy*, **126**, 855-864. <https://doi.org/10.1016/j.renene.2018.03.070>
- [8] Omeke, K.G., Mollé, M.S., Ozturk, M., *et al.* (2021) DEKCS: A Dynamic Clustering Protocol to Prolong Underwater Sensor Networks. *IEEE Sensors Journal*, **21**, 9457-9464. <https://doi.org/10.1109/JSEN.2021.3054943>
- [9] Bozorgi, S.M., Rostami, A.S., Hosseinabadi, A.A.R. and Balas, V.E. (2017) A New Clustering Protocol for Energy Harvesting-Wireless Sensor Networks. *Computers & Electrical Engineering*, **64**, 233-247. <https://doi.org/10.1016/j.compeleceng.2017.08.022>
- [10] Ren, Q. and Yao, G. (2019) An Energy-Efficient Cluster Head Selection Scheme for Energy-Harvesting Wireless Sensor Networks. *Sensors*, **20**, Article No. 187. <https://doi.org/10.3390/s20010187>
- [11] Measurement and Instrumentation Data Center (MIDC). National Renewable Energy Laboratory (NREL). <https://midcdmz.nrel.gov/>
- [12] Heinzelman, W.B., Chandrakasan, A.P. and Balakrishnan, H. (2002) An Application-Specific Protocol Architecture for Wireless Microsensor Networks. *IEEE Transactions on Wireless Communications*, **1**, 660-670. <https://doi.org/10.1109/TWC.2002.804190>
- [13] Handy, M.J., Haase, M. and Timmermann, D. (2002) Low Energy Adaptive Clustering Hierarchy with Deterministic Cluster-Head Selection. *4th International Workshop on Mobile and Wireless Communications Network*, Stockholm, 9-11 September 2002, 368-372. <https://doi.org/10.1109/MWCN.2002.1045790>
- [14] Smaragdakis, G., Matta, I. and Bestavros, A. (2004) SEP: A Stable Election Protocol for Clustered Heterogeneous Wireless Sensor Networks. *2nd International Workshop on Sensor and Actor Network Protocols and Applications (SANPA 2004)*: Vol. 3, Boston, 1-11 August 2004.
- [15] Singh, S., Malik, A. and Kumar, R. (2017) Energy Efficient Heterogeneous DEEC Protocol for Enhancing Lifetime in WSNs. *Engineering Science and Technology, an International Journal*, **20**, 345-353. <https://doi.org/10.1016/j.jestch.2016.08.009>
- [16] Ren, Q. and Yao, G. (2019) An Energy-Efficient Cluster Head Selection Scheme for Energy-Harvesting Wireless Sensor Networks. *Sensors*, **20**, Article No. 187. <https://doi.org/10.3390/s20010187>