

DOI: 10.19650/j.cnki.cjsi.J2311741

# 面向无人机数据采集的 LoRa 扩频因子预测模型研究\*

张铮<sup>1</sup>, 汪杰<sup>1</sup>, 倪西学<sup>2</sup>

(1. 上海海洋大学工程学院 上海 201306; 2. 上海博取仪器有限公司 上海 201315)

**摘要:**针对在缺少移动网络覆盖的偏远地区实现大面积数据采集与环境监测,首先设计了无人机移动网关与地面节点的 LoRa 通信协议;在此基础上提出了一种基于改进极限学习机(PG-ELM)的扩频因子预测模型,以实现扩频因子的动态调整。为提高预测准确度与效率,该模型以信号强度、信噪比、距离、丢包率、温度和相对湿度作为输入,以粒子群算法(PSO)和灰狼算法(GWO)联合算法对 ELM 模型进行改进。通过无人机移动通信试验获取 LoRa 通信数据样本集,进行模型训练获得优化的 PG-ELM 模型。试验结果表明,在 20 kB 数据大小的情况下,本方案的数据采集时间比单一 SF12、SF7 减少约 78% 和 26%,平均通信能耗比单一 SF12 降低 70% 以上,数据包投递率(PDR)高达 98%,在能效性和预测实时性等方面优势明显。

**关键词:** LoRa; 数据采集; 扩频因子; 预测模型

中图分类号: TH701 TN92 文献标识码: A 国家标准学科分类代码: 510.50

## Research on the LoRa spreading factor prediction model for UAV data collection

Zhang Zheng<sup>1</sup>, Wang Jie<sup>1</sup>, Ni Xixue<sup>2</sup>

(1. College of Engineering Science and Technology, Shanghai Ocean University, Shanghai 201306, China;

2. Shanghai Boqu Instrument Co., Ltd., Shanghai 201315, China)

**Abstract:** For large area data collection and environmental monitoring in remote areas with no mobile network coverage, this article first designs a LoRa communication protocol between the UAV mobile gateway and the ground nodes. Based on this, a spreading factor prediction model based on the improved extreme learning machine (PG-ELM) is proposed to achieve dynamic optimization and adjustment of the spreading factor. To improve the prediction accuracy and efficiency, the model uses signal strength, signal-to-noise ratio, distance, packet loss rate, temperature and relative humidity as inputs. The particle swarm optimization algorithm and the grey wolf optimization algorithm are fused to optimize the ELM model. The LoRa communication data sample sets are obtained through the UAV mobile communication experiment, which are then used to train and optimize the PG-ELM model. The results show that, with a data size of 20 kB, the proposed scheme reduces the data collection time by about 78% and 26% compared with single SF12 and SF7. It also lowers the average communication energy consumption by more than 70% compared with single SF12, achieves a packet delivery rate of 98%, and has significant advantages in energy efficiency and prediction real-time performance.

**Keywords:** LoRa; data collection; spreading factor; predictive model

## 0 引言

物联网技术是环境监测的常用手段之一,它可以实现对大面积区域的数据采集和分析。然而,在缺少移动网络覆盖的偏远地区,如何高效地进行环境监测仍然是

一个挑战<sup>[1]</sup>。本研究采用了基于 LoRa(long range radio)的低功耗广域网(low power wide area network, LPWAN)技术,该技术采用啁啾扩频(chirp spread spectrum, CSS)调制技术,具有远距离、低功耗、抗干扰等优点。LoRa 技术的低功耗、资源分配和通信距离等问题一直是相关人员的重点<sup>[2]</sup>。如何合理设置 LoRa 参数,在满

收稿日期:2023-07-31 Received Date: 2023-07-31

\* 基金项目:上海市教委水产动物良种创制与绿色养殖协同创新中心项目(2021 科技 02-12)、上海市崇明区农业科创项目(2021CNKC-05-06)资助

足通信性能需求的同时尽可能地降低能耗是本文的研究重点。

对于如何合理配置 LoRa 的通信参数,文献[3]旨在评估室内场景下的 LoRa 网络性能,提出了一种机器学习的方法来预测接收功率,结果表明,该方法在网络的中断概率和误码率等方面优势明显;文献[4]搭建了整数线性规划模型,同时对传输参数中的扩频因子(spreading factor, SF)和传输功率(transmit power, TP)进行了优化,结果表明,该模型能够在最少的能耗下可取得较高得数据包投递率(packet delivery ratio, PDR);文献[5]提出了一种基于匹配理论的信道和扩频因子分配算法,实验表明,该算法可实现低数据包冲突率、高数据提取率和低网络能耗。文献[6]侧重于优化 LoRaWAN 的参数设置,通过减少数据丢包率和重传次数从而降低整个网络的能耗。上述研究均以优化 LoRa 参数来改善无线通信网络的性能,而部分研究提出资源优化的方法来降低网络的能耗。文献[7]改进了 LoRaWAN 中的先听后说策略,有效降低信道碰撞率;文献[8]采用可变邻域搜索和最小成本生成树算法来优化扩频因子、等参数,使得网络能耗和数据采集时间最少。

以上方法均在固定网关与节点的场景下得到验证。近年来有部分研究利用无人机的机动性进行地面传感器节点数据采集<sup>[9]</sup>。文献[10]为提高在无基础设施地区数据采集的效率,设计了一种具有双通道的 LoRa 自适应数据率策略,可有效提高无人机数据采集的效率;文献[11]提出的策略有效提高了基于无人机的 LoRa 网络规模;文献[12]研究了无人机在采集数据时减少终端节点的数据包传输能耗的方法,与固定网关和单一 SF 相比,该方法在能耗和数据包投递率方面具有明显优势。

极限学习机(extreme learning machine, ELM)是一类前馈神经网络算法,该算法随机产生输入层与隐藏层间的连接权重及隐藏层神经元的阈值<sup>[13]</sup>,文献[14]使用灰狼算法(grey wolf optimization, GWO)对 ELM 进行参数择优以提高精度,相较于其他寻优算法具有参数更少、收敛性速度快的特点和通用性强。

本文面向缺少移动网络覆盖的偏远地区环境监测应用场景,利用无人机作为移动网关进行地面节点数据采集。在此场景下,节点间距离较远,分布稀疏,组网难度大;而不合理的 LoRa 参数配置又会造成节点能耗高,采集效率低等问题。针对上述问题,本文主要进行以下研究:

1) 利用无人机作为 LoRa 移动网关,实现了大面积的数据采集,在此基础上设计了一种无人机移动网关与地面节点的通信协议;

2) 提出了一种基于改进极限学习机(improve extreme learning machine, PG-ELM)的扩频因子预测模型,该模型

不仅考虑了信号强度(received signal strength indicator, RSSI)、信噪比(signal to noise ratio, SNR)、距离、丢包率等参数作为模型输入,还引入了温度和相对湿度等环境因素,提高了模型的泛化能力;

3) 将 GWO 算法和粒子群算法(particle swarm optimization, PSO)相结合。将 GWO 算法中的最佳代理替换 PSO 算法中的部分种群,获得输入层权重和隐藏层偏置的最优解,进一步优化了 ELM 模型参数,提高了预测准确度;

4) 通过现场试验获取模型的数据样本集,并进行训练得到可用的 PG-ELM 模型;通过仿真和现场试验对比,本模型在保证 PDR 的同时,提高了 LoRa 通信的能效性,延长了节点电池寿命。

## 1 系统模型

### 1.1 问题描述

LoRa 技术的长距离通信得益于其扩频调制技术,可大幅提高接收灵敏度,在室温下,接收灵敏度可表示为:

$$S = -174 + 10\lg BW + NF + SNR_{\min} \quad (1)$$

其中,  $-174$  为大自然基地噪声密度,单位为 dBm/Hz;  $BW$  为带宽;  $NF$  为接收端的噪声系数,其值由硬件决定。根据式(1),在相同带宽的情况下,扩频因子越大,接收灵敏度越高,传输距离越远,但数据速率越低。LoRa 的数据速率可用式(2)表示:

$$Dr = SF \times \left( \frac{BW}{2^{SF}} \right) \times CR \quad (2)$$

其中,  $CR$  为编码率。由式(2)可知 LoRa 的数据速率随着扩频因子的增大而减小。由此可见,在带宽相同的情况下,扩频因子越大,数据速率越低,传输距离越远。因此,为满足不同应用场景的数据率和通信距离需求,需要对 LoRa 扩频因子进行合理的配置。

在缺少移动网络覆盖的偏远地区进行环境监测时,各 LoRa 节点之间相距较远,分布稀疏而不易组网。本文采用无人机移动网关和 LoRa 网络的组合方案,进行地面节点数据采集,在一定程度上减小了遮挡物对地面间无线通信的影响,具有一定的可靠性。

如图 1 所示,地面节点只需与无人机网关通信,且已知节点位置信息,无人机网关遍历地面节点布设区域,完成数据采集任务。以常见的环境监测场景为例,多参数传感器节点采集如温度、湿度、风速、空气质量等数据,每次采集量可达上百字节,假设 5 min 采集一次数据,每天 LoRa 节点储存的数据量约为 30 kB 左右。在此应用场景下,为高效完成无人机移动网关数据采集任务,尽可能降低节点能耗,本文设计了专门的通信协议和扩频因子预测模型。




图1 网络架构

Fig.1 Network architecture

## 1.2 通信协议

本文设计了一种基于扩频因子预测模型的无人机网关和 LoRa 节点之间的通信协议,该协议可实现扩频因子的动态优化调整,提高数据传输的效率和可靠性。该协议具体流程如下:

1) 为了降低地面节点能耗,本研究将所有 LoRa 节点设置为低功耗侦听 (low power listening, LPL) 模式,在该模式下扩频因子的值为 12。无人机网关根据地面节点的位置信息,以 SF12 发送带有相应节点 ID 的唤醒包,如图 2 所示,当对应 ID 的 LoRa 节点接收到唤醒包后,向无人机网关上传节点存储的数据,待数据传输完成,继续进入 LPL 模式,而其他 ID 不符的节点则会直接进入 LPL 模式。




图2 网关与节点间的通信

Fig.2 Communication between the gateway and the nodes

2) 无人机网关接收到当前地面节点的数据包后,解析得到当前通信链路信息,并将该信息输入到训练好的扩频因子预测模型,得出适合当前通信状态的扩频因子值,并附加在应答包 (acknowledge, ACK) 中。当前 LoRa 节点收到无人机网关的 ACK 包后,更新自身扩频因子并继续上传数据,重复上述过程直到储存的数据全部上传完毕。当连续上传 3 次无应答时,则转入 LPL 模式,等待下一次的唤醒与数据请求。

3) 无人机继续根据遍历路线和与节点间的距离,唤醒下一个 LoRa 节点,重复上述流程直到完成所有地面节点的数据采集任务。

## 2 扩频因子预测模型

在采集数据的过程中,由于无人机移动网关与 LoRa 节点的距离时刻发生变化,需要动态调整 LoRa 节点的扩频因子,以保证数据传输的效率和可靠性。LoRa 射频芯片的通信距离与接收灵敏度有关,而接收灵敏度主要取决于扩频因子,扩频因子越高,接收灵敏度越高,通信距离越远。如图 1 所示,对于距离无人机网关较近的节点,采用较低的扩频因子,可获得较高的数据率,相同长度的数据包射频发射时间越短,有利于提高吞吐量,降低节点的通信能耗。

本文提出了一种基于 PG-ELM 的扩频因子预测模型,在节点位置已知的情况下,以无人机移动网关与节点的距离、RSSI、SNR、数据丢包率、设备部署环境的温度和相对湿度作为模型输入。目的是在保证 PDR 的前提下,根据通信环境的变化,动态调整扩频因子,以提高通信的能效性。

### 2.1 基于 PG-ELM 的扩频因子预测模型

为满足无人机网关采集数据的高实时性需求,本文选用 ELM 模型来预测扩频因子。ELM 是一种单层前向神经网络<sup>[14]</sup>,随机生成输入层权重和隐藏层偏置,并通过解方程组来确定输出层权重。对输入变量进行归一化处理,本研究的 ELM 模型可以表示为:

$$H = G \begin{pmatrix} \omega_d \\ \omega_r \\ \omega_s \\ \omega_t \\ \omega_h \\ \omega_l \end{pmatrix} x + \begin{pmatrix} b_d \\ b_r \\ b_s \\ b_t \\ b_h \\ b_l \end{pmatrix} \quad (3)$$

其中,  $H$  为网络的隐藏层输出矩阵;  $x$  为模型输入;  $G(\omega_i x + b_i)$  为激活函数。由于环境因素对无线通信的性能会造成影响<sup>[15]</sup>,本模型不仅选取距离、RSSI、SNR、丢包率等通信参数作为输入变量,还考虑了温度、相对湿度等环境因素。其中  $\omega_d, \omega_r, \omega_s, \omega_t, \omega_h, \omega_l, b_d, b_r, b_s, b_t, b_h, b_l$  分别为距离、RSSI、SNR、温度、相对湿度、丢包率的输入权重和偏置,  $\omega_d + \omega_r + \omega_s + \omega_t + \omega_h + \omega_l = 1$ 。

本文使用 PSO 和 GWO 联合优化算法获得最优的输入层权重和隐藏层偏置,以提高 ELM 模型的预测准确度。该算法寻求  $\omega_i$  和  $b_i$  最优解的过程中,当达到最大迭代次数或满足预设的收敛条件时,输出最优的  $\omega_i$  和  $b_i$ ,式(3)可以表示为式(4):

$$H = G \begin{pmatrix} \omega'_d \\ \omega'_r \\ \omega'_s \\ \omega'_t \\ \omega'_h \\ \omega'_l \end{pmatrix} x + \begin{pmatrix} b'_d \\ b'_r \\ b'_s \\ b'_t \\ b'_h \\ b'_l \end{pmatrix} \quad (4)$$



其中,  $\omega'_d, \omega'_r, \omega'_s, \omega'_t, \omega'_h, \omega'_l, \omega'_1, b'_d, b'_r, b'_s, b'_t, b'_h, b'_l$  分别为距离、RSSI、SNR、温度、相对湿度、丢包率的最优输入权重和偏置,使得目标函数具有最小的解:

$$\min E(W) = \min \| H\beta - T \| \quad (5)$$

式中:  $E(W)$  为目标函数的计算结果;  $T$  为网络期望输出矩阵。在该模型中,当输入确定的  $\omega_i$  和  $b_i$  时,即可确定唯一的输出矩阵  $H$ 。其最小二乘解为:

$$\hat{\beta} = H^{-1}T \quad (6)$$

式中:  $H^{-1}$  为隐藏层输出矩阵  $H$  的广义逆矩阵。网络的输出  $Y$  为:

$$Y = H\beta \quad (7)$$

### 2.2 PSO、GWO 联合算法

为提高 ELM 模型的预测准确性,本文引入结合 PSO 算法<sup>[16]</sup>和 GWO 算法的联合优化算法,该算法可以寻求网络的输入层权重和隐藏层偏置的最优解。在 PSO 中,粒子在运动过程中根据自身能力和相邻粒子的能力改变自己的位置和方向,为了优化粒子适应度函数会得到自身适应度值,从而改变粒子运动速度,速度更新如式(8)所示。

$$\begin{aligned} v_{i,j}^{t+1} &= av_{i,j}^t + c_1r_1(p_{best_{i,j}}^t - x_{i,j}^t) + c_2r_2(g_{best_{i,j}}^t - x_{i,j}^t) \\ x_{i,j}^{t+1} &= x_{i,j}^t + v_{i,j}^{t+1} \end{aligned} \quad (8)$$

其中,  $a$  为收敛因子;  $v_{i,j}^t$  指第  $t$  次迭代的第  $i$  个粒子的第  $j$  维的速度;  $x_{i,j}^t$  指第  $t$  次迭代的第  $i$  个粒子的第  $j$  维的位置;  $p_{best_{i,j}}^t$  指粒子个体最优位置;  $g_{best_{i,j}}^t$  指粒子全局最优位置;  $c_1$  和  $c_2$  为学习因子;  $r_1$  和  $r_2$  代表每次迭代生成的两个随机系数。

为了提高 PSO 算法的多样性和收敛性,本文将其与 GWO 算法相结合,形成一种联合优化算法。该算法在更新个体位置和速度时,不仅考虑了个体经验和全局最优解的引导作用,还引入了 GWO 算法中最佳代理、次佳代理和第 3 佳代理。PSO 的更新式(8)更为式(9):

$$\begin{aligned} v_{i,j}^{t+1} &= a(X_{i,j}^t - x_{i,j}^t) + c_1r_1(p_{best_{i,j}}^t - x_{i,j}^t) + \\ &c_2r_2(g_{best_{i,j}}^t - x_{i,j}^t) \\ x_{i,j}^{t+1} &= x_{i,j}^t + v_{i,j}^{t+1} \end{aligned} \quad (9)$$

在 PSO 的位置更新过程中,保留了其原本的个体经验和最优粒子的引导,并引入 GWO 的搜索策略  $X(t)$ ,在搜索过程中,其他粒子会包围式地向最优代理靠近,进一步提高算法的搜索能力。如图 3 所示为 PG-ELM 的模型框图。

## 3 现场试验与模型训练

### 3.1 无人机移动通信试验

在所有试验场景中,无人机移动网关基于 SX1301 模块,配备 GPS 模块;地面节点基于 SX1262 模块,均配备




图 3 PG-ELM 模型原理

Fig. 3 PG-ELM Model architecture

GPS 模块和温湿度传感器。当无人机网关采集数据时,节点将自身位置(经纬度坐标)和温湿度信息一并上传。所有测试均在 12.5 dBm 的固定传输功率下进行,带宽为 125 kHz, CR 为 4/5,前导码长度为 8,无线频段为 433 MHz,天线增益为 3 dBi。无人机的飞行高度为 30 m,飞行速度为 5 m/s。

首先测试距离对 RSSI 和丢包率的影响,LoRa 节点一次发 100 个数据包,数据包大小为 100 bytes,无人机按照规定航线飞向终端节点,直线距离为 2 800 m,步长为 50 m。每一次测试中,无人机分别通过 6 个不同的数据率 (date rate, DR) 获得 RSSI 样本均值和丢包率,并重复 20 次。SX1301 模块的 8 个通道可以接收 SF7-SF12 6 种速率的 LoRa 信号,分别对应着 DR5-DR0。如图 4、5 所示,随着距离的增加,所有 DR 下的 RSSI 都呈下降趋势,并且当距离超过某个阈值时,无人机网关几乎无法接收到数据。同样地,随着距离的增加,所有 DR 的丢包率也呈上升趋势。DR5、DR4、DR3、DR2、DR1 分别在距离超过 600、820、1 270、1 640、2 100 m 之后丢包率明显上升。

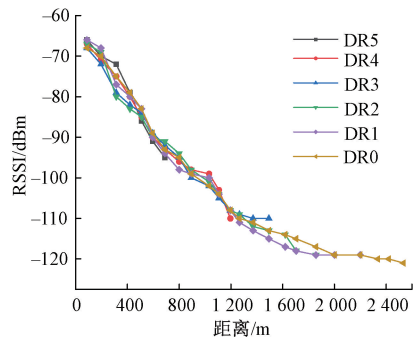


图 4 不同距离移动网关接收信号强度评估

Fig. 4 Performance of mobile gateways with different distances

为测试温度对 RSSI 的影响,本试验从 2022 年 7 月 1 日~7 月 14 日共测得有效数据 720 组,并记录了不同温度下的 RSSI 值。如图 6 所示为每个点代表 20 个接收数






图5 不同距离移动网关丢包率评估

Fig. 5 Performance of mobile gateways with different distances

据包的RSSI 中值随温度变化的情况。从图6中可以看出,在25℃~40℃范围内,RSSI呈离散式线性下降趋势,总共下降3 dBm,说明温度与RSSI存在负相关关系。在偏远地区,由于周边环境恶劣,昼夜温差较大,因此温度的变化对传输质量的影响不可忽视。




图6 不同温度下的接收信号强度

Fig. 6 RSSI with different temperatures

为测试湿度对RSSI的影响,本文在温度相同的条件下,选择了4个无明显遮挡物的位置做了试验。测试1~4分别取在离水面1、5、20、50 m的位置,测试相对湿度由高到低,RSSI值的变化情况。如图7所示为20个接收数据包的RSSI中值随湿度变化的曲线,从图中可以看出,在相对湿度较大的河边,RSSI的值更较高,说明相对湿度与RSSI存在正相关关系,与文献[17]中的结论一致。

本文将上述试验结果筛选并整理出模型训练的数据样本集,各环境下(不同距离、不同温度和湿度)都有一个最适合通信的扩频因子,即每次上传数据时,在保证数据包投递率的同时选择尽可能低的扩频因子,以达成较好的能效性。

### 3.2 模型训练

将试验获取的数据样本集中,95%的数据作为模型训练集,5%作为测试集。本文采用交叉验证以减轻特定样本造成的偏差,数据被分为10等份,训练过程在10次




图7 不同湿度下的接收信号强度

Fig. 7 RSSI with different humidity

迭代中进行,每次迭代过程90%的数据用于训练,10%的数据用于测试。10次交叉验证训练的过程将生成10个不同的模型,训练过程重复10次,最后取所有训练模型的平均值计算误差。参数如表1所示。

表1 相关参数设置

Table 1 Related parameters setting

参数	值	参数	值
激活函数	Sigmoid	$a$	从2减小到0
$c_1$	2	种群规模	30
$c_2$	2	迭代次数	100
惯性权重	0.2~0.9	训练次数	10

### 3.3 模型对比

如图8所示为SVM、BP、ELM、PG-ELM模型的预测结果对比图,横坐标为50个测试样本,纵坐标为SF的值,4种算法预测结果的拟合曲线由高到低排序依次为PG-ELM、BP、SVM、ELM。

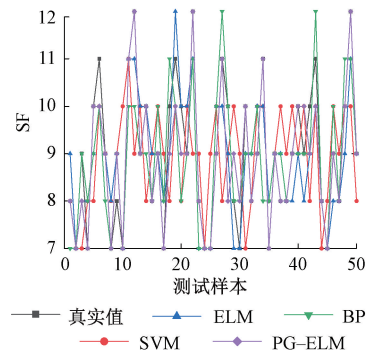


图8 模型预测结果对比

Fig. 8 Model prediction results comparison

如表 2 所示为各个模型的预测时间、均方根误差 (root mean squared error, RMSE) 和平均绝对百分比误差 (mean absolute percentage error, MAPE)。从表中可以看出,由于 ELM、SVM、BP 3 种模型的训练方法和网络结构等方面存在差异,模型的预测时间相差较大。PSO 和 GWO 联合优化算法通过优化这些参数使得 ELM 模型的映射方式更加有效合理。PG-ELM 模型具有最低的 RMSE 和 MAPE,说明该模型具有更好的预测准确度;虽然执行 PSO 和 GWO 优化算法增加了模型复杂度,但是对隐藏层节点数的选择以及算法参数的设置,预测时间没有明显增长,能够满足无人机移动网关采集数据的实时性需求。

表 2 预测模型对比分析

Table 2 Comparative analysis of prediction models

模型种类	模型预测时间/s	均方根误差	平均绝对百分比误差
ELM	0.024	0.798	0.071 2
SVM	5.840	1.648	0.183 1
BP	2.140	0.981	0.079 4
PG-ELM	0.037	0.594	0.028 9

## 4 仿真与试验

### 4.1 模型性能仿真

为了评估模型的性能,在本文提出的通信协议的基础上,进行了以下 4 种方案的仿真:SF12-LoRa:扩频因子固定为 12;SF7-LoRa:扩频因子固定为 7;ADR-LoRa:采用 LoRaWAN 中的 ADR 算法;PG-ELM-LoRa:采用本方案的扩频因子预测模型。本仿真仅采集一个节点的数据,移动网关开始与节点的距离为 2 500 m,网关移动速度为 5 m/s,每次上传的数据量为 200 bytes;通信参数同无人机移动通信试验,节点存储的数据量为 10~40 kB。仿

真采用以下 3 种指标来评估其性能:1) 数据采集时间:网关开始移动到数据采集完成的时间;2) 节点能量损耗:节点传输数据时的通信能耗;3) PDR:网关接收到的数据包与节点发送的数据包的比值。仿真相关数据和模型设置取自上述的无人机移动通信试验。

如图 9(a) 所示,PG-ELM-LoRa 的数据采集时间最短,其原因在于网关在移动时便可开始采集数据,当移动到距离节点较近时,可降低 SF,提高 DR。SF7-LoRa 需网关移动到距离 LoRa 节点较近时,才可以高数据率传输数据,当数据量较大时,具有一定优势。SF12-LoRa 从网关移动时即可采集数据,但其 DR 最低,节点数据量越大,数据采集时间越长。当采集的数据量为 20 kB 时,移动网关到达节点位置后,也未能将完成所有数据采集,滞空时间较长,不符合实际情况下无人机网关的数据采集需求。ADR-LoRa 在唤醒节点后,从 SF=7 逐步上调,当增大到 SF=10 时,与节点取得较为良好的通信,同时网关与节点的距离越来越远,ADR-LoRa 无法调低 SF,使得数据采集时间较长;如图 9(b)、(c) 所示,SF7-LoRa 的通信能耗最低是因为 DR 高,上传时间较短,但是在距离节点较远时,丢包严重,故 PDR 最低。SF12-LoRa 以 SF=12 通信,PDR 较高,由于其 DR 最低,节点的通信能耗最高。ADR-LoRa 在采集数据时先以最低 SF 值通信,当达到 SF=10 后,与节点通信质量较稳,并保持该 SF 通信,而 PG-ELM-LoRa 先以 SF=12 通信,故在节点储存数据较低的情况下,ADR-LoRa 的通信能耗低于 PG-ELM-LoRa,但是节点数据量越大,移动网关随着数据采集时间越长距离节点越近,此时 ADR-LoRa 无法调低 SF,而 PG-ELM-LoRa 可根据链路质量,调整任一 SF 值通信,故数据量大于 35 kB 时,ADR-LoRa 的通信能耗超过 PG-ELM-LoRa。ADR-LoRa 刚与节点通信时,信号较弱,当不断测试调高 SF 后,才能达到较好的数据投递率。PG-ELM-LoRa 可保证 PDR 的同时,以尽可能低的 SF 通信,节点能量损耗也较低。




图 9 各方案随节点不同数据大小变化的性能仿真

Fig. 9 Performance simulation of various schemes varying with different data sizes of nodes

## 4.2 现场数据采集试验

为了进一步验证提出方法的有效性和可靠性,本文进行了现场试验。试验地点选择在上海浦东新区郊外,共部署5个节点,其中节点2部署在丛林中,与节点1、5有树木相隔,节点3部署在草坪上,节点4部署在河边。所有节点均配备GPS模块和温湿度传感器。无人机移动网关按规定路线飞行,飞行速度为5 m/s。节点1与节点2、3、4、5的距离分别为1.55、2.21、1.89、1.85 km。

本试验共实施了4种方案,分别为PG-ELM-LoRa、ADR-LoRa、SF12-LoRa和SF7-LoRa,实验参数同仿真。

如图10(a)所示,数据采集时间定义为无人机网关从出发到完成所有数据采集任务的时间。PG-ELM-LoRa采集数据的时间总是最少的,其原因在于PG-ELM-LoRa可根据距离等通信状态选择最合适的SF,无人机网关距离节点较近时,数据率提高,降低了数据包空中传输时间。ADR-LoRa方案唤醒节点后,首先以SF=7与无人机网关通信,在采集数据的过程中,若距离增加或通信质量下降将逐步上调SF。然而在数据量较小的情况下,无人机网关采集完一个节点数据后,与下一个要采集的节点相距较远,为保证高质量通信,逐步调高SF,而当距离该节点越来越近时,无法下调

SF,导致数据采集时间较长。SF7-LoRa中无人机网关需飞行到距离节点较近的位置,才可以高DR采集数据,在节点越多的情况下,与PG-ELM-LoRa的数据采集时间差距将越大。SF12-LoRa的DR最低,其数据采集时间随着节点数据的增加而大幅延长,当节点数据量超过20 kB时,无人机网关滞空时间达到其极限,无法完成数据采集任务。如图10(b)、(c)所示,SF7-LoRa具有最低的能耗和最低的PDR。ADR-LoRa由于无法在通信质量较好时下调SF,使得高SF的使用时间较长,DR低导致数据采集时间长,同时节点能耗也较高。在数据量较小时的通信能耗低于PG-ELM-LoRa的原因在于,后者刚开始采集数据时所用的SF大于前者。ADR-LoRa的PDR高于SF7-LoRa却低于其余两种方案,其原因在于该方案在识别出通信质量低后,上调到合适SF的速度较慢,在以低SF采集一段时间后才可以提高通信质量。PG-ELM-LoRa的能耗高于SF7-LoRa,然而SF7-LoRa的无人机飞行时间较长,其电池能耗不可忽视。PG-ELM-LoRa和SF12-LoRa的PDR均较高,但后者节点能耗远高于前者,其原因在于PG-ELM-LoRa可根据距离等通信状态,以尽可能高的DR通信,在无人机网关采集数据过程中,无需到达距离节点附近即可完成所有数据的采集。

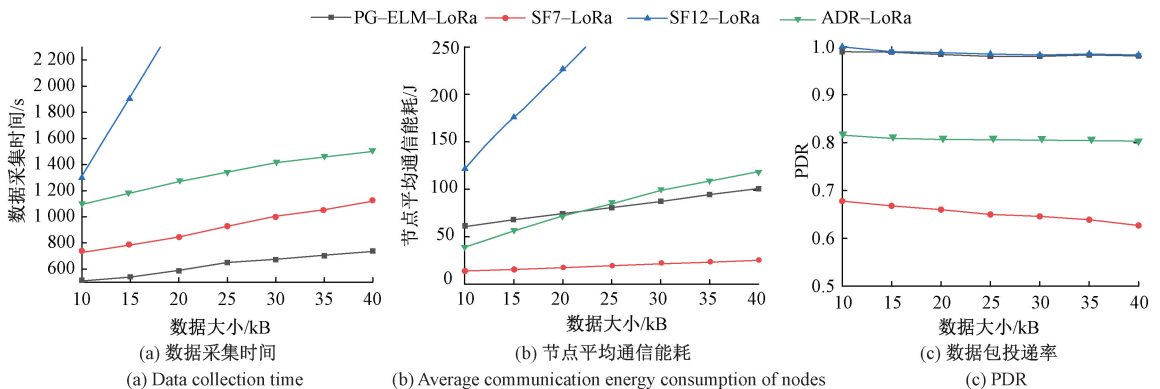


图10 各方案随节点不同数据大小变化的性能试验

Fig. 10 Performance tests of various schemes varying with different data sizes of nodes

本文对每个LoRa节点的通信性能进行评估,其中各节点储存数据大小为20 kB。如图11(a)、(b)所示,PG-ELM-LoRa和SF12-LoRa的PDR依然最高。SF7-LoRa由于使用低SF,PDR较低,而节点2和节点4由于部署在遮挡物较多和河边湿度较大的环境下,影响更为严重。SF12-LoRa使用SF=12,DR最低,故消耗了最多的能量。ADR-LoRa的PDR高于SF7-LoRa,其原因在于虽然在采集数据的开始阶段均使用低SF,但前者为提高通信质量逐步上调SF。在对信号质量较差的节点2和节点4进行数据

采集时,使用较高SF通信,DR较低,靠近节点时无法适当下调SF使得数据采集时间较长,在采集最后一个节点3时,SF最高,故通信能耗最高。PG-ELM-LoRa受环境的影响,节点2和节点4以较高的SF通信,故能耗高于其它节点;节点3的能耗接近SF7-LoRa是因为环境较为空旷,与无人机移动网关距离较近时,将以高DR通信。由试验结果可知,PG-ELM-LoRa方案在保证投送率的同时,尽可能降低SF,提高数据率,数据包空中传输时间减少,节点能耗降低,有效提高了节点的电池寿命。



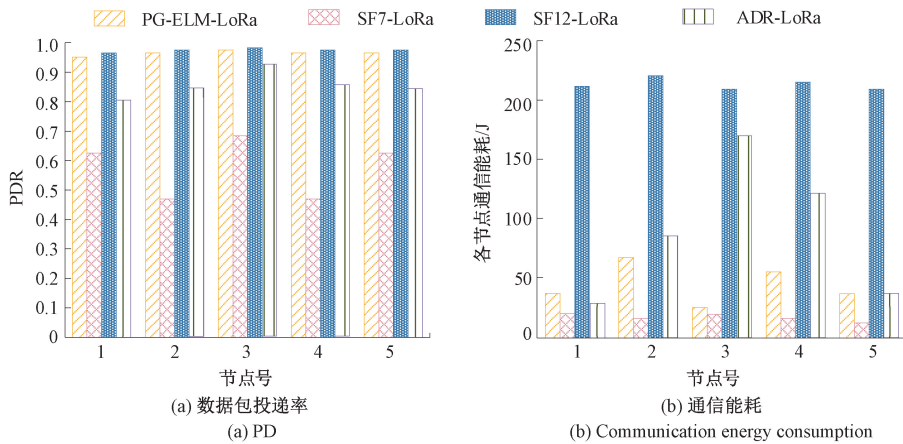


图 11 各节点的性能对比

Fig. 11 Performance comparison of each node

## 5 结 论

本文针对缺少移动网络覆盖的偏远地区数据采集与环境监测的应用场景,设计了面向无人机移动网关与地面节点的 LoRa 通信协议;在此基础上,针对 LoRa 扩频因子的合理动态配置问题,提出一种基于 PG-ELM 的扩频因子预测模型。该模型可准确快速地预测出最合适的扩频因子,在保证 PDR 的同时尽可能使用低扩频因子,提高通信的能效性。仿真和移动网关数据采集试验表明本协议及模型在能效性和实时性上均优于单一扩频因子和 LoRaWAN 的 ADR 算法,有效提高了数据采集效率,延长了地面节点的电池寿命。在下一步工作中,将进行更多场景下的试验,测试模型性能;进一步改进优化提升模型的预测准确度和泛化能力。

## 参考文献

- [1] LI C N, CAO Z C. LoRa networking techniques for large-scale and long-term IoT: A down-to-top survey[J]. ACM Computing Surveys, 2023, 55(3): 1-36.
- [2] MUHAMMAD A K, MUHAMMAD M A, AZNIDA A B S, et al. Requirements, deployments, and challenges of LoRa technology: A survey [J]. Computational Intelligence and Neuroscience, 2023, 15: 5183062.
- [3] GAGANDEEP K, SINDHU H G, HARLEEN K. Optimizing the LoRa network performance for industrial scenario using a machine learning approach [J]. Computers and Electrical Engineering, 2022, 100: 107964.
- [4] PREMSANKAR G, GHADDAR B, SLABICKI M, et al.

Optimal configuration of LoRa networks in smart cities[J]. IEEE Transactions on Industrial Informatics, 2020, 16(12): 7243-7254.

- [5] 杨茂恒, 章辉, 周超. 基于匹配理论的 LoRa 参数双重匹配优化[J]. 计算机工程与科学, 2023, 45(6): 995-1002.  
YANG M H, ZHANG H, ZHOU CH. Double matching optimization of LoRa parameters based on matching theory[J]. Computer Engineering & Science, 2023, 45(6): 995-1002.
- [6] ZHAO Z, GAO W, DU W, et al. Towards energy-fairness in LoRa networks [J]. IEEE Transactions on Mobile Computing, 2023, 22(9): 5597-5610.
- [7] AHSAN S, HASSAN S A, ADEEL A, et al. Improving channel utilization of LoRaWAN by using novel channel access mechanism[C]. 2019 15th International Wireless Communications & Mobile Computing Conference (IWCMC), 2019: 1656-1661.
- [8] GAVA M, ROCHA H, FABER M J, et al. Optimizing resources and increasing the coverage of Internet-of-Things (IoT) networks: An approach based on LoRaWAN[J]. Sensors, 2023, 23(3): 1239.
- [9] GHAZALI M H M, TEOH K, RAHIMAN W. A systematic review of real-time deployments of UAV-based LoRa communication network [J]. IEEE Access, 2021, 9: 124817-124830.
- [10] ZHANG Z, ZHOU C, SHENG L, et al. Optimization schemes for UAV data collection with LoRa 2.4 GHz technology in remote areas without infrastructure [J]. Drones, 2022, 6(7): 173.

- [11] KHUN A, SHAN L, LIM Y, et al. MCST scheme for UAV systems over LoRa networks [J]. *Drones*, 2023, 7(6): 371.
- [12] XIONG R, LIANG C, ZHANG H, et al. FlyingLoRa: Towards energy efficient data collection in UAV-assisted LoRa networks [J]. *Computer Networks*, 2023, 220: 109511.
- [13] 王彦, 朱伟, 汪俊亮, 等. 基于 ELM 算法的柔性 FBG 形状重构末端分析 [J]. *仪器仪表学报*, 2023, 44(5): 81-89.  
WANG Y, ZHU W, WANG J L, et al. Terminal analysis of flexible FBG shape reconstruction based on ELM algorithm [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(5): 81-89.
- [14] 唐圣学, 马晨阳, 勾泽. 基于时频特征融合与 GWO-ELM 的棒控电源早期故障状态辨识方法 [J]. *仪器仪表学报*, 2023, 44(1): 121-130.  
TANG SH X, MA CH Y, GOU Z. Early fault state identification method of the rod control system power equipment based on time-frequency characteristics fusion and GWO-ELM [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(1): 121-130.
- [15] CATTANI M, BOANO C, RÖMER K. An experimental evaluation of the reliability of LoRa long-range low-power wireless communication [J]. *Journal of Sensor and Actuator Networks*, 2017, 6(2): 7.
- [16] 王红尧, 郑鸿林, 田劼, 等. 面向矿井动目标的 PSO-SVR 模型与 UWB Chan 优化距离指纹融合定位方法 [J]. *电子测量与仪器学报*, 2022, 36(7): 106-114.  
WANG H Y, ZHENG H L, TIAN J, et al. Fusion location method of PSO-SVR model and UWB Chan optimal fingerprint matching for mine moving target [J]. *Chinese Journal of Scientific Instrument*, 2022, 36(7): 106-114.
- [17] JEFTENIĆ N, SIMIĆ M, STAMENKOVIĆ Z. Impact of environmental parameters on SNR and RSS in LoRaWAN [C]. 2020 International Conference on Electrical, Communication, and Computer Engineering (ICECCE), 2020: 1-6.

### 作者简介



张铮(通信作者), 分别在 2003 年、2007 年于郑州大学获得学士学位和硕士学位, 2015 年在上海交通大学获得博士学位, 现为上海海洋大学副教授, 主要研究方向为物联网工程、智能仪器设计。

E-mail: z-zhang@shou.edu.com

**Zhang Zheng** (Corresponding author) received his B. Sc. and M. Sc. degrees both from Zhengzhou University in 2003 and 2007, respectively, and received his Ph. D. degree from Shanghai Jiaotong University in 2015. He is currently an associate professor at Shanghai Ocean University. His main research interests include IoT and intelligent instrument design.