Deep Learning-Based Compressed Sensing Reconstruction for Sparse Data in WSN*

LI Cuiran[1*], YUE Jiaming[1], WANG Huiqin[2], XIE Jianli[1]
(1.School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou Gansu 730070, China;
2.School of Computer Science and Communication, Lanzhou University of Technology, Lanzhou Gansu 730050, China)

Abstract: Non-uniform clustering and the deep learning method are jointed to process wireless sensor network (WSN) permafrost monitoring data for the Qinghai-Tibet railway, aiming to prolong the network lifetime. A non-uniform clustering algorithm is proposed based on firefly algorithm optimizing fuzzy c-means and the Voronoi diagram, and an adaptive node adjustment strategy of the Voronoi diagram is adopted to optimize the clustering structure. The compressed data are transmitted by dynamically updating the head nodes and the minimum spanning tree between clusters. By utilizing the temporal and spatial correlation characteristics of the original monitoring data, a compressive-sensing reconstruction model for sparse data based on deep learning is designed. For data compression, the weight matrix of the fully connected layer is adopted as the measurement matrix for learning. Sparsity data was compressed at the cluster-head nodes. Data reconstruction is carried out by using the one-dimensional convolutional neural network, meanwhile, long short-term memory (LSTM) is introduced to enhance the Inception-Resnet-A module and improve the feature extraction ability of the network model, realizing the reconstruction of the one dimensional sparse data at the sink nodes. The experimental results show that the algorithm can prolong the network lifetime by 34% and 62% compared to the ESCVAD and LEACH algorithms under low compressed ratio scenarios, respectively, and has a high accuracy of data reconstruction compared with algorithms of DCSNet, CSNet, DCSM, and OMP.

Key words: wireless sensor network; deep learning; compressive sensing; Voronoi diagram; fuzzy C-means
EEACC: 7230 **doi**: 10.3969/j.issn.1004-1699.2026.09.024

基于深度学习的 WSN 稀疏数据压缩感知重构算法*

李翠然[1*], 岳嘉明[1], 王惠琴[2], 谢健骊[1]
(1.兰州交通大学电子与信息工程学院, 甘肃 兰州 730070; 2.兰州理工大学计算机与通信学院, 甘肃 兰州 730050)

摘 要: 联合非均匀分簇和深度学习方法来处理青藏铁路无线传感器网络(WSN)冻土监测数据以延长网络生命周期。提出一种基于萤火虫优化模糊 C 均值与 Voronoi 图的非均匀分簇算法, 采用 Voronoi 图的自适应节点调整策略优化分簇结构, 通过动态更新簇头节点及簇间最小生成树传输压缩数据。利用原始监测数据的时、空相关特性, 设计基于深度学习的稀疏数据压缩感知重构模型, 数据压缩采用全连接层的权值矩阵作为学习的测量矩阵, 压缩簇头节点稀疏后的数据; 数据重构采用一维卷积神经网络, 同时引入 LSTM 改进 Inception-Resnet-A 模块, 以增强网络模型特征提取能力, 实现 Sink 节点处的一维稀疏数据重构。实验结果表明, 低压缩率情形下, 所提算法相比 ESCVAD、LEACH 算法网络生命周期分别延长 34% 和 62%, 与 DCSNet, CSNet, DCSM 算法和 OMP 算法相比数据重构精度高。

关键词: 无线传感器网络; 深度学习; 压缩感知; Voronoi 图; 模糊 C 均值
中图分类号: TP393 **文献标识码**: A **文章编号**: 1004-1699(2026)09-2115-09

无线传感器网络(Wireless Sensor Network, WSN)运用在轨道交通等监测预警方面的技术更加成熟[1-2]。目前, 采用 WSN 技术对青藏铁路沿线的某些冻土区域持续进行环境数据采集和监测[3], 但由于该地区常年处于低温环境下, 降低了传感器节点电池的容量, 因此必须提高 WSN 中的能源效率。此外, 在 WSN 数据收集中感知数据通常具有较强的时、空相关性, 网络中传输较多冗余数据, 增大了传感器节点能耗。如何有效地均衡节点能耗、降低网络数据传输量是铁路环境监测下高效数据传输亟待解决的关键问题。

WSN 采用分簇路由协议实现资源的均衡分配。

项目来源: 国家自然科学基金资助项目(No.62161016); 兰州交通大学重点研发项目资助(ZDYF2304)
收稿日期: 2024-08-07 **修改日期**: 2024-10-04

针对节点能耗负载不均衡问题,已有大量研究成果。孙爱晶等[4]利用粒子群(Particle Swarm Optimization,PSO)算法针对模糊 C 均值(Fuzzy C-Means,FCM)进行优化,实现网络均匀分簇,平衡了网络能耗负载。余修武等[5]利用萤火虫优化 FCM 算法(Firefly Algorithm Optimized Fuzzy C-means,FFACM),所划分的簇更均匀紧密,簇头轮换考虑能量和距离的适应度函数,有效均衡网络负载。Ma 等[6]提出了基于 Voronoi 图自适应分簇的 WSN 节能(Energy-Saving Clustering by Voronoi Adaptive Dividing,ESCVAD)算法,成簇阶段采用 Voronoi 图划分的自适应分簇,利用距离和能量综合加权函数选举簇头节点,有效平衡节点间的能耗。Wang 等[7]提出传感器节点的自适应调整算法,使得簇内节点数目均等,实现网络能耗均衡。这些分簇算法成簇后均存在“热区问题”,且易出现较大簇和较小簇。此外,节点调整算法未有效解决较小簇的问题。

基于压缩感知(Compressed Sensing,CS)的数据收集方式利用感知数据的时、空相关性,数据压缩采用低压缩率(Compressed Ratio,CR),减少了数据传输量,进而降低传感器节点能耗。Zhang 等[8]提出了基于树和簇的混合 CS 收集路由协议,降低网络能耗。在稀疏假设下,传统的 CS 重构算法主要基于贪婪算法。例如正交匹配追踪(OMP)算法[9]或其他变体算法[10]。同时,这些算法采用随机生成与数据无关的高斯随机测量矩阵,低 CR 压缩数据的重构精度差,并存在数据稀疏性的限制。为解决以上问题,已有许多基于深度学习的数据重构方法。Zhang 等[11]提出了基于学习的稀疏数据重构算法,采用端到端的学习方法构建测量矩阵和高效高精度重构网络。减少了网络中数据传输量,并在较低 CR 下压缩数据重构精度较高。Zhang 等[12]提出了 ECG 信号压缩感知的深度学习(Compressive Sensing Network,CSNet)算法,结合神经网络和长短期记忆(Long Short-Term Memory,LSTM)网络直接学习测量值的升维信号与原始信号之间的映射关系,在低 CR 下相比传统算法具有更高的重构精度。Hua 等[13]提出了改进的 Inception 和 LSTM 的 ECG 信号深度压缩感知算法,利用卷积层压缩数据,采用深度网络重构信号,提高在低 CR 下的重构精度。这些算法主要用于图像和 ECG 信号领域的重构,但无法满足 WSN 一维感知数据的重构需求,同时采用简单的卷积残差网络和 LSTM,对于信号的特征提取能力不够,卷积层采用大卷积核增加了模型计算量。

综上考虑,本文根据青藏铁路冻土路基安全监测的 WSN 应用需求,提出了一种基于深度学习的分簇 WSN 稀疏数据压缩感知重构算法。首先,提出一种基于 FFACM 与 Voronoi 图的非均匀分簇算法,降低了较大簇和较小簇出现概率,并设计基于 Voronoi 图的自适应节点调整策略,优化初始分簇,该分簇路由算法使得网络能耗负载更均衡。其次,构建了改进的深度压缩感知网络(Improved Deep Compressed Sensing Network,IDCSNet),降低数据量的同时实现了一维稀疏数据的准确重构。所提出算法能够有效减少铁路冻土环境监测的传感器节点能耗,延长无线传感器网络生命周期。

1 网络模型与算法原理

1.1 分簇 WSN 网络模型

青藏铁路冻土监测的分簇 WSN 网络模型如图 1 所示[3],WSN 划分成多个簇,节点类型分为普通簇成员(Cluster Member,CM)节点和簇头(Cluster Head,CH)节点。首先,采用分簇算法形成分簇 WSN 网络,由 CM 节点收集原始监测数据并传输至 CH 节点,CH 基于簇间最小生成树路由传输压缩数据,最后 Sink 节点接收数据并重构原始数据。

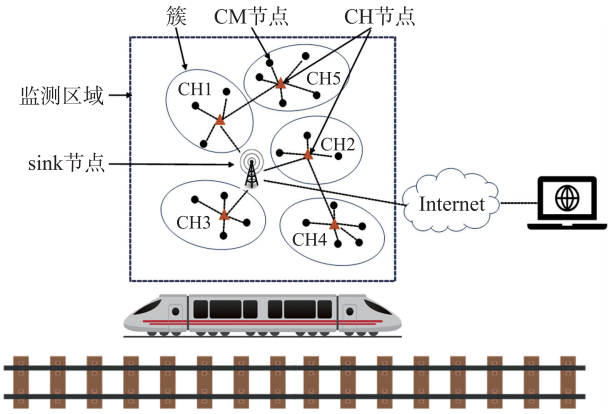

图 1 青藏铁路冻土监测的分簇 WSN 网络模型

假设 WSN 网络中传感器节点有如下性质[4]:

①节点具有相同初始能量,所有节点是同构的;

②Sink 节点资源不受限,位于区域中心位置;

③节点随机部署在监测区域内,可通过 GPS 或者其他定位技术获得自己的位置信息。

WSN 节点能耗主要产生于感知数据的发送与接收,节点发送、接收 k_{tran} bit 数据的能量消耗为[5]:

$$E_{\text{TX}}(k_{\text{tran}},d)=\begin{cases}k_{\text{tran}}E_{\text{elec}}+k_{\text{tran}}\varepsilon_{\text{fs}}d^2 & d<d_{\text{th}}\\ k_{\text{tran}}E_{\text{elec}}+k_{\text{tran}}\varepsilon_{\text{amp}}d^4 & d\geqslant d_{\text{th}}\end{cases} \tag{1}$$

$$E_{\text{RX}}(k_{\text{tran}})=k_{\text{tran}}E_{\text{elec}} \tag{2}$$

式中:ε_{fs}、ε_{amp}分别代表自由空间和多径衰减信道模型下放大电路的能耗参数,E_{elec}为发送电路或接收

电路传输 1 bit 数据所需的能耗,设 $d_{th}=\sqrt{\varepsilon_{fs}/\varepsilon_{amp}}$ 为距离阈值,d 为节点间的欧氏距离。

1.2　基于深度学习的分簇 WSN 稀疏数据压缩感知重构算法原理

基于深度学习的分簇 WSN 稀疏数据压缩感知重构算法原理如图 2 所示。算法包括以下 5 个步骤:

Step 1　设计能量均衡的 WSN 分簇路由算法。

Step 2　设计并线下训练 IDCSNet 模型。设计 IDCSNet 模型,采用特定环境下 WSN 历史数据集在 Sink 节点上训练网络模型;重构网络作为数据重构部分部署在 Sink 节点上,数据压缩网络中的权值矩阵作为学习的测量矩阵。

Step 3　分配稀疏基和测量矩阵。Sink 节点分配 DCT 稀疏基和学习的测量矩阵到 CH 节点。

Step 4　混合 CS 的 WSN 数据收集。CH 节点收集并稀疏化 CM 节点的感知数据[14],并采用学习的测量矩阵进行数据压缩;压缩数据通过簇间路由传输到 Sink 节点。

Step 5　数据重构。重构网络线上重构原始数据。

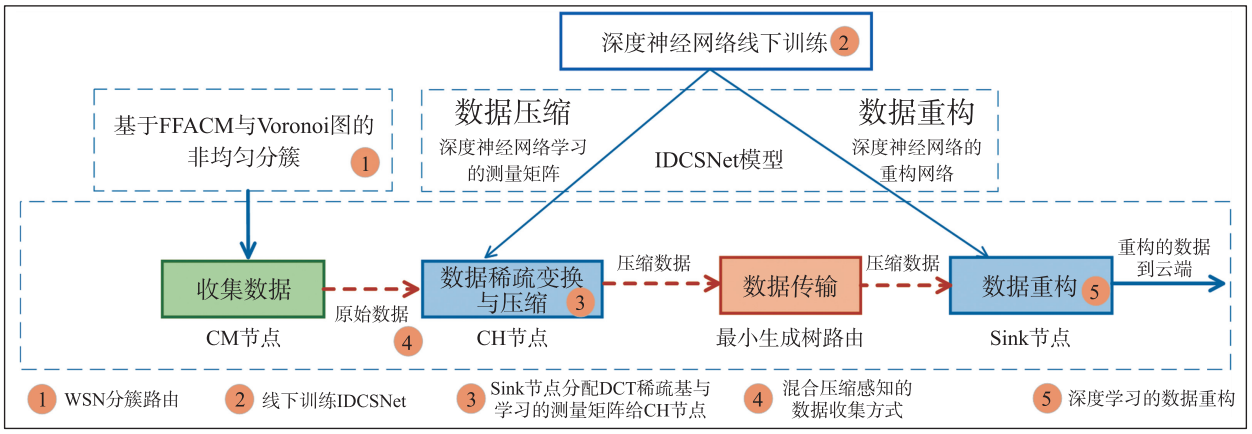

图 2　基于深度学习的分簇 WSN 稀疏数据压缩感知重构算法原理图

2　分簇路由算法

2.1　标准 FCM 算法

FCM 是一种软聚类算法[4],其划分聚类结果更加灵活。在 WSN 应用中,传感器节点的隶属度可以反映其对某一聚类中心的归属程度,表示为:

$$\sum_{j=1}^{N} u_{ij}=1 \tag{3}$$

式中:N 代表聚类中心数目,u_{ij} 为传感器节点 i 对第 j 个聚类中心的隶属度,且隶属度总和为 1。

假设 WSN 监测区域中存在 n 个随机部署的传感器节点,其中有 N 个聚类中心,FCM 通过最小化目标函数,将整个 WSN 中的传感器节点按位置信息划分为 N 个簇,目标函数定义为:

$$J_m=\sum_{i=1}^{n}\sum_{j=1}^{N}(u_{ij})^m(d_{ij})^2,m\in[1,+\infty) \tag{4}$$

式中:m 为模糊因子,通常取 2,d_{ij} 为传感器节点 i 与第 j 个聚类中心之间欧氏距离,隶属度计算表示为:

$$u_{ij}=\frac{1}{\sum_{h=1}^{N}\left(\frac{d_{ij}}{d_{ih}}\right)^{\frac{2}{m-1}}} \tag{5}$$

聚类中心 N_j 更新表达式为:

$$N_j=\frac{\sum_{i=1}^{n}u_{ij}^m x_j}{\sum_{i=1}^{n}u_{ij}^m} \tag{6}$$

2.2　基于 FFACM 与 Voronoi 图的非均匀分簇

萤火虫算法优化 FCM 算法[5],有效避免了 FCM 陷入局部最优的问题,获得最佳的初始聚类中心。文献[15]指出,FCM 算法和 Voronoi 图在空间数据聚类上有较好的契合点。FCM 算法基于欧氏距离评判节点与聚类中心之间的隶属度,其各所属类的节点到其所属聚类中心隶属度最大;Voronoi 图则是针对生成元划分生成 Voronoi 区域边界,在 Voronoi 区域中所有点与其生成元的距离最短[6]。

选择最佳簇数有利于降低网络的整体能耗,可以表示为[16]:

$$N=\sqrt{\frac{n}{2\pi}}\sqrt{\frac{\varepsilon_{fs}}{\varepsilon_{amp}}}\frac{S}{d_0^2} \tag{7}$$

式中:N 为最佳簇数,n 为节点数目,d_0 为节点与 Sink 节点间的距离,S 为监测区域的边长。

引入一个特殊的 Sink 节点簇,使得邻近 Sink 节点的部分节点加入到 Sink 簇中,Sink 节点作为该簇的 CH 节点,减少了节点回传所产生的额外能耗开

销。设置萤火虫个体的编码形式为 $\{x_1y_1x_2y_2\cdots x_Ny_Nx_{\text{Sink}}y_{\text{Sink}}\}$，$x_i$ 和 y_i 为聚类中心在监测区域中的坐标信息，x_{Sink} 和 y_{Sink} 为 Sink 节点坐标。FFACM 聚类中心优化过程中，仅更新该编码的前 $2N$ 个位，保持 x_{Sink}、y_{Sink} 不变，最终输出最优的聚类中心。

基于 FFACM 与 Voronoi 图的非均匀分簇算法如算法 1 所示。Voronoi 图分簇引入 FFACM 算法生成最佳的生成元，减少较大簇和较小簇出现的概率。

算法 1 基于 FFACM 与 Voronoi 图的非均匀分簇算法

①FA 算法种群初始化，参数初始化
②计算目标函数值，计算亮度和吸引度，确定移动方向，并更新萤火虫位置
③迭代次数到最大时，得到最优解
④FCM 初始聚类中心确定为 FA 输出的最优解，初始化隶属度矩阵
⑤计算新的隶属度矩阵，并计算聚类中心
⑥迭代次数到最大时，输出最优聚类中心
⑦Voronoi 图采用最优聚类中心作为生成元对整个网络进行划分，单个 Voronoi 区域即为一个簇区域

2.3 基于 Voronoi 图的自适应节点调整策略

采用基于 FFACM 与 Voronoi 图的非均匀分簇算法可能仍存在部分较大簇和较小簇，同时距 Sink 较近的簇存在“热区问题”，可通过调整节点实现能耗均衡[7,17]。为此，设计基于 Voronoi 图的自适应节点调整策略，如算法 2 所示。该算法关键是检查 Voronoi 图生成元 $C=\{C_1,C_2,\cdots,C_{N+1}\}$ 所在区域的节点数目 $M'=\{M'_1,M'_2,\cdots,M'_{N+1}\}$，簇内平均节点数 M'_{avg}，设定当 $|M_t'-M'_{\text{avg}}|>2$ 时，调整 C_t 区域边缘的部分节点，将簇内节点数控制在合理范围内。

算法 2 基于 Voronoi 图的自适应节点调整策略

输入：算法 1 划分 Voronoi 图 C 区域，节点隶属度矩阵，M'_{avg}、M'，假设 Sink 簇为第 s 个簇，$d_T=10$
输出：调整后的 Voronoi 分簇
① for $t=1:N+1$
② if $M_t'-M'_{\text{avg}}>2$
③ for $j=1:M_t'-M'_{\text{avg}}-2$
④ 查找 C_t 区域含 M_k' 最少的邻居 C_k 区域，及 C_t 中关于 C_k 隶属度最大的节点，该节点加入 C_k
⑤ end for
⑥ else if $M'_{\text{avg}}-M_t'>2$
⑦ for $j=1:M'_{\text{avg}}-M_t'-2$
⑧ 查找 C_t 区域含 M_k' 最多的邻居 C_k 区域，及 C_k 中关于 C_t 隶属度最大的节点，该节点加入 C_t
⑨ end for
⑩ else
⑪ C_t 区域内的节点不作调整
⑫ end if
⑬ if $t=s$
⑭ 将距 Sink 节点 d_T 范围内的节点加入到 C_s
⑮ end if
⑯ 更新 C 区域的节点
⑰ end for

2.4 簇头选举

分簇 WSN 数据收集中，CH 节点能耗更大。为平衡簇内节点的负载，考虑节点的剩余能量、距离动态更新 CH 节点，计算节点的适应度值，评价其是否担任簇头[4-6]。

选取簇内能量高的节点作为 CH 节点，均衡簇内节点的负载，节点剩余能量因子表示为[4]：

$$f_1(i)=\frac{E_{\text{res}}(i)}{\frac{1}{M'}\sum_{j=1}^{M'}E_{\text{res}}(j)} \tag{8}$$

式中：E_{res} 为节点剩余能量，M' 为簇内存活节点数目。

节点间的相对距离表示为：

$$f_2(i)=\frac{d_{C\max}-d(i,C)}{\frac{1}{M'}\sum_{h=1}^{M'}d(h,C)} \tag{9}$$

式中：$d_{C\max}$ 为生成元 C 与所属簇中节点的最大距离，$d(i,C)$ 为节点 i 到生成元 C 的距离。

节点适应度值表示为：

$$F(i)=\tau f_1(i)+\upsilon f_2(i) \tag{10}$$

式中：τ、υ 为权重因子，初值均设置为 0.5，且 $\tau+\upsilon=1$。

τ、υ 的取值可表示为[5]：

$$\tau=\frac{1}{2}+\frac{1}{2}\frac{E_{\text{tot}}-\sum_{i=1}^{M'}E_{\text{res}}(i)}{E_{\text{tot}}} \tag{11}$$

$$\upsilon=1-\tau \tag{12}$$

式中：E_{tot} 为初始簇内节点的总能量。

3 基于深度学习的稀疏数据压缩感知重构

3.1 压缩感知原理

根据压缩感知理论[9]，相比奈奎斯特采样定理，降低了采样频率，减少数据传输代价。根据式(13)，假设一个长度为 L 的原始数据 $X\in\mathbf{R}^{L\times1}$ 稀疏表示为 $\boldsymbol{\Psi\alpha}$，其中 $\boldsymbol{\Psi}\in\mathbf{R}^{L\times L}$ 为稀疏矩阵，投影系数 $\boldsymbol{\alpha}$ 为一个仅包含有限非 0 元素向量。测量矩阵 $\boldsymbol{\Phi}\in R^{M\times L}$ 必须满足约束等距条件(Restricted Isometry Property，RIP)，稀疏数据利用 $\boldsymbol{\Phi}$ 实现数据的线性测量。感知矩阵 $\boldsymbol{A}\in\mathbf{R}^{M\times L}$ 表示为 $\boldsymbol{\Phi}$ 与 $\boldsymbol{\Psi}$ 的乘积。此时，利用 $\boldsymbol{\Phi}$ 使得 X 降维，得到压缩数据 $Y\in\mathbf{R}^{M\times1}$，即

$$Y=\boldsymbol{\Phi}X=\boldsymbol{\Phi\Psi\alpha}=\boldsymbol{A\alpha} \tag{13}$$

当 $\boldsymbol{A}$ 满足 RIP 条件时，则压缩感知理论可以通过求解最小 L_0 范数稀疏恢复出 α，即：

$$\min \|\boldsymbol{\alpha}\| \text{ s.t. } Y=\boldsymbol{A\alpha}=\boldsymbol{\Phi\Psi\alpha} \tag{14}$$

求解式(14)属于完全 NP-hard 难题,在一定条件下,求解 L_0 范数问题可等价于求解 L_1 范数,常用方法有贪婪算法,凸松弛算法等。

3.2　相关模型

首先给出有关稀疏数据 CS 重构的网络模型,便于后文详细描述 CS 重构算法,相关模型如下所述。

3.2.1　LSTM 网络模型

LSTM 网络[13]是一种时间序列特征提取单元,可以学习时间序列数据的长短期依赖信息,增强特征提取能力。LSTM 网络架构包含遗忘门、输入门、记忆单元和输出门,如图 3 所示。

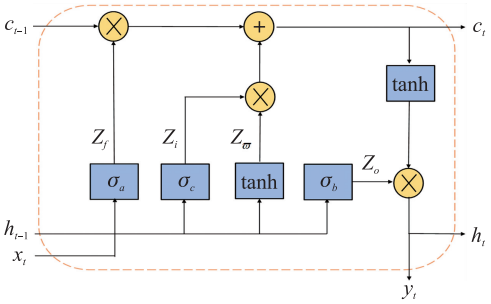

图 3　LSTM 网络模型图

遗忘门为 Z_f,清除前一个细胞 c_{t-1} 到当前细胞 c_t 信息,表示为:

$$Z_f=\sigma(\boldsymbol{W}_f\times[h_{t-1},x_t]+\boldsymbol{d}_f) \tag{15}$$

输入门 Z_i 与候选细胞 $Z_{\tilde{c}}$ 计算更新公式如下:

$$Z_i=\sigma(\boldsymbol{W}_i\times[h_{t-1},x_t]+\boldsymbol{d}_i) \tag{16}$$

$$Z_{\tilde{c}}=\tanh(\boldsymbol{W}_{\tilde{c}}\times[h_{t-1},x_t]+\boldsymbol{d}_{\tilde{c}}) \tag{17}$$

因此,根据式(15)~式(17),更新 c_t 如下:

$$c_t=Z_f c_{t-1}+Z_i Z_{\tilde{c}} \tag{18}$$

LSTM 模型的输出 y_t 及输出门 h_t 如下:

$$Z_o=\sigma(\boldsymbol{W}_o\times[h_{t-1},x_t]+\boldsymbol{d}_o) \tag{19}$$

$$y_t=h_t=Z_o\tanh(c_t) \tag{20}$$

式中:$\boldsymbol{W}$ 表示权重矩阵;$\boldsymbol{d}$ 为偏置向量;$\sigma(\cdot)$ 为 Sigmoid 激活函数;tanh 为双曲正切激活函数。

3.2.2　改进的 Inception-ResNet-A 网络模型

Inception-ResNet 是深度学习的经典模型[18],其卷积网络在同一层中采用不同大小的卷积核,增强了网络模型对于特征信息的感知能力,提取更丰富的不同尺度特征,通过减少卷积核的数量和网络模型参数,从而简化网络模型计算复杂度。并结合残差网络结构,解决了网络深度优化困难的问题。鉴于 WSN 的感知数据为一维长序列数据且样本有限,因此,设计改进的 Inception-ResNet-A 一维网络模型,如图 4 所示。其中,引入 LSTM 网络旨在提升网络对长序列数据特征的提取能力[19]。模型中采用了不同的并行卷积层,各层卷积网络分别采用 1×1、1×3、1×5 的卷积核,可从不同的感受野中获取信息,提取更多的局部特征。模型采用卷积步长为 1,并通过边界填充(padding)确保稀疏数据的维度不变,避免特征提取时数据信息的丢失。

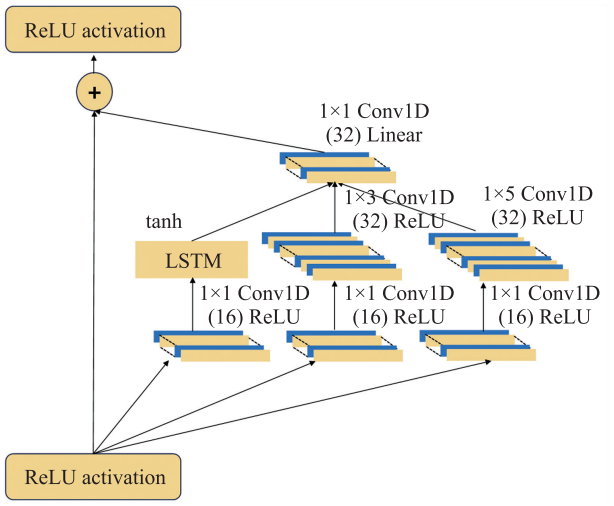

图 4　改进的 Inception-ResNet-A 网络模型

3.3　基于 IDCSNet 的稀疏数据压缩重构网络模型

传统 CS 重构算法需先验信息,并在采用低 CR 时重构精度差。本节提出一种基于 IDCSNet 的稀疏数据压缩重构网络模型,均采用一维的网络结构,实现感知数据的压缩和精准重构。文献[11]指出,设计基于深度学习数据压缩和重构网络,训练后可获得高精度的重构网络和学习的测量矩阵。

①数据压缩阶段

CH 节点处的数据压缩如图 5 所示,将输入的原始数据 X 映射到压缩数据 Y,以提取原始数据的特征,该数据特征支持数据压缩中的高精度重构。第一映射数据压缩表示为:

$$Y=\sigma(\boldsymbol{W}X)=F_{\Phi}(X) \tag{21}$$

式中:$\sigma(\cdot)$ 为激活函数,$\boldsymbol{W}$ 为训练学习的权重矩阵,$F_{\Phi}(\cdot)$ 代表 X 到 Y 的映射关系函数。

在 CS 中数据压缩与重构过程都依赖于 $\boldsymbol{\Phi}$,设计最优的 $\boldsymbol{\Phi}$ 至关重要,当 $\boldsymbol{\Phi}$ 满足相互一致性小原

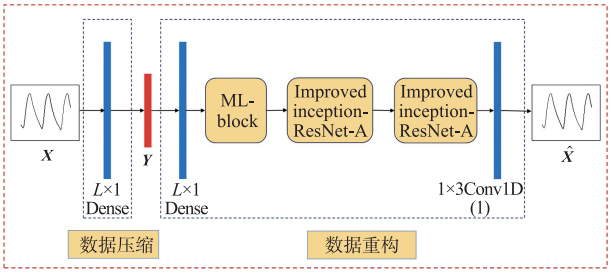

图 5　基于 IDCSNet 的稀疏数据压缩重构网络模型

则可以恢复 $\boldsymbol{X}$,已证明基于学习的 $\boldsymbol{\Phi}$ 满足该原则,证明见文献[11]。数据压缩采用一个全连接层(Dense),Dense 权重矩阵 $\boldsymbol{W}\in\mathbf{R}^{M\times L}$ 维度作为学习的测量矩阵,通过线下训练权重参数。

②数据重构阶段

重构网络的 Dense 层将 Y 线性映射成与 X 相同维度的数据。重构网络旨在使重构数据映射到 X,构造一个自然恒等映射,采用残差网络将高阶特征和低阶特征融合,通过深度残差网络最小化残差来实现映射过程。映射学习模块(Mapping Learning Block,ML-Block)模块如图 6 所示,映射关系通过 ML-Block 联合改进的 Inception-ResNet-A 网络模块来学习,如图 5 所示。第二映射数据重构可以表示为:

$$\hat{X}=\sigma'(\boldsymbol{W}'Y)=D_{W'}(Y) \tag{22}$$

式中:$D_{W'}(\cdot)$ 表示 Y 到重构数据 $\hat{X}$ 的映射函数。

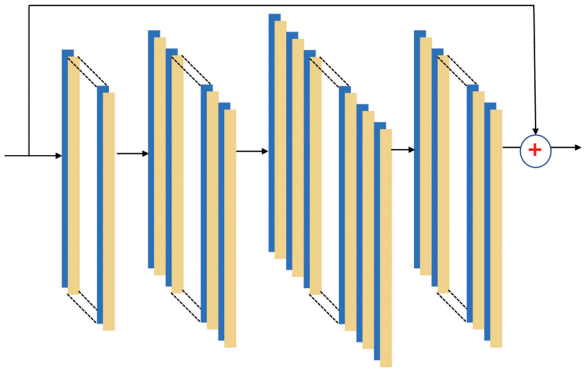

图 6 映射学习模块

给定 K 个未标记的训练样本 $X=\{X_l\}_{l=1}^{K}$,使得 IDCSNet 网络重构误差最小化的损失函数表示为

$$L(Y,\boldsymbol{\Phi},\boldsymbol{W}')=\operatorname{argmin}\|X-\hat{X}\|_2^2 \tag{23}$$

当数据压缩采用较小 CR 时,重构数据将不可避免地存在误差。采用随机梯度下降方法训练 IDCSNet 模型,获得最小的重构误差,即最小化 X 与 $\hat{X}$ 的 L_2 范数平方和,表示为

$$\min_{Y\in\mathbf{R}^{M\times 1},\boldsymbol{\Phi}\in\mathbf{R}^{M\times L},\boldsymbol{W}'}\sum_{l=1}^{L}\|X_l-\hat{X}_l\|_2^2 \tag{24}$$

4 仿真结果分析

4.1 仿真环境与参数

通过 MATLAB 仿真工具验证所提出的 WSN 分簇路由算法在延长网络生命周期和网络负载均衡等方面的性能,仿真参数如表 1 所示[5]。IDCSNet 压缩重构模型用 Python 编程实现,采用公开的位于青藏铁路沿线的那曲网络土壤温湿度观测数据集[20],提取其中标称深度为 5 cm 的温度观测数据[21],数据集包括为 1 000 组数据,每组数据包含长度 L 为 256 的温度值数据序列,其中数据的 80%作为训练集,数据的 20%作为测试集,通过仿真验证分析算法重构性能。

重构实验仿真硬件平台为 Intel Core i7-13799KG 处理器,24 GB 内存,GPU 为 RTX4070Ti 12 GB。软件环境为 PyTorch 框架,进行模型搭建,第 3 节中描述了网络参数,模型训练采用 Adam 优化器,设置初始学习率为 0.005,一阶矩衰减和二阶矩衰减系数分别为 0.9 和 0.999,批次 Batch Size 为 30,网络训练迭代 500 次,训练时采用均方误差作为损失函数。

表 1 仿真参数

参数	数值
节点数目	100
监测区域范围	100 m×100 m
Sink 节点坐标/m	(50,50)
初始能量/J	1
E_{elec}/(nJ·bit^{-1})	50
ε_{fs}/(pJ·bit^{-1}·m^{-2})	10
ε_{amp}/(pJ·bit^{-1}·m^{-4})	0.001 3
数据分组大小/bit	4 000

4.2 压缩重构性能评价指标

在实验中,压缩率 CR 表示为 CH 节点处数据的压缩程度,CR 表达式为[11]:

$$\mathrm{CR}=\frac{\text{压缩数据长度}}{\text{原始数据长度}} \tag{25}$$

均方误差(Mean Square Error,MSE)反映原始数据与重构数据之间的差异程度,表示为

$$\mathrm{MSE}=\frac{1}{L}\sum_{l=1}^{L}\|X_l-\hat{X}_l\|_2^2 \tag{26}$$

4.3 实验结果

4.3.1 簇的负载均衡性

基于 Voronoi 图的自适应节点调整前及调整后的示意如图 7 所示。通过算法 1 实现的初始 Voronoi 图分簇见图 7(a);当图 7(a)中的某些簇的节点数目较多或者较少时,采用算法 2 来平衡这些簇中的节点数目,如图 7(b)所示为调整后的 Voronoi 图分簇。可以看出,节点调整后,距离 Sink 节点较近簇中的节点数目较少,有效规避了“热区问题”和较大簇、较小簇缺陷,以实现分簇 WSN 网络负载均衡的目的。以 Sink 簇 C09 为例,初始分簇仅有节点 4、Sink,将邻居簇 C06、C07、C11 区域中节点 13、33、78、85、94 分配到 C09 簇中,平衡了邻居簇的簇内节点数量,并减少了数据回传的能耗。

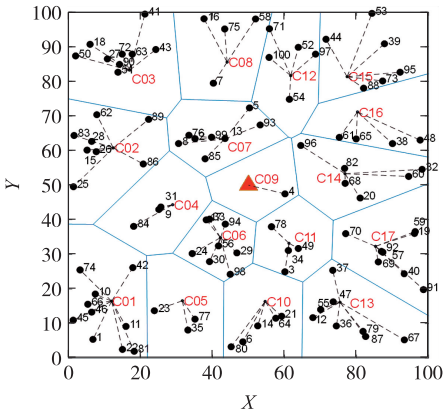

(a) 调整前的分簇图

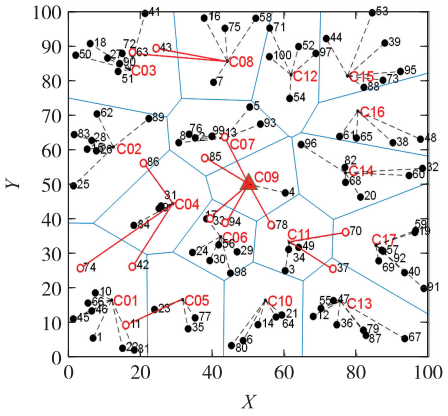

(b) 调整后的分簇图

图 7　基于 Voronoi 图的自适应节点调整图

4.3.2　网络生命周期

图 8 所示为当 CR = 1/32 时各算法的网络能耗对比,所提算法与对比算法 ESCVAD-CS[6]、LEACH-CS 的能量消耗差距不大,由于后两种算法在分簇时易形成较大簇和较小簇,导致了网络中节点能耗不均衡。所提分簇算法在 CH 节点选择及簇构建过程中均考虑了网络负载均衡性,相同轮数时的网络剩余能量最多。

网络生命周期是网络从开始的运行轮数到节点死亡所运行的轮数,用来评价在该 WSN 分簇路由算法下网络性能。网络生命周期可以表示为三种形式:第一个传感器节点死亡、一半传感器节点死亡和全部传感器节点死亡。

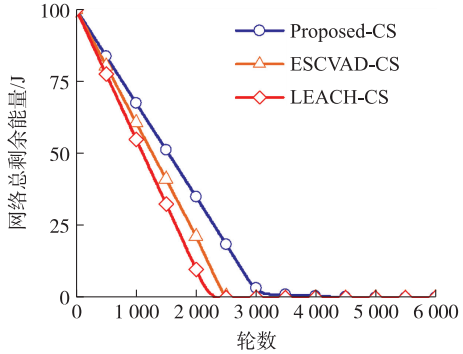

图 8　网络剩余能量变化曲线(CR = 1/32)

3 种分簇路由算法采用压缩感知数据收集方式,网络生命周期对比如图 9 所示。当 CR = 1/32 时,可以看到,本文所提出算法、ESCVAD-CS 算法和 LEACH-CS 算法首次出现死亡节点的时间分别为 2 895、2 166 和 1 784 轮,所提算法相比 ESCVAD-CS、LEACH-CS 算法分别提升了 34% 和 62%。当采用 CR = 1/4 时,3 种算法首次出现死亡节点的时间分别为 2 331、1 721 和 1 464 轮,相比 CR = 1/32 的情形,每种算法首次出现节点死亡的时间分别缩短了 19%、20%和 17%。这说明,压缩感知 WSN 数据收集采用小 CR,对于延长网络生命周期的效果更为显著。

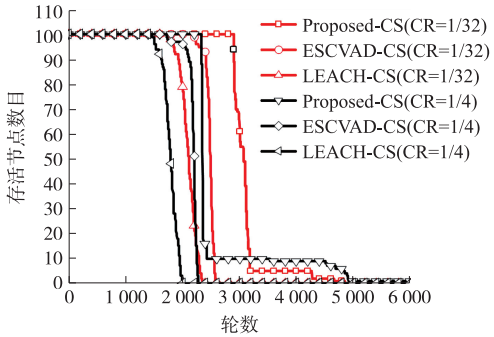

图 9　存活节点数目变化曲线

4.3.3　重构性能

实验模拟了簇内收集 256 个温度值的数据序列,随机选取测试集中的数据在不同 CR 下的数据重构情况。所提算法的重构数据曲线以及不同算法的重构误差对比分别见图 10 和图 11。

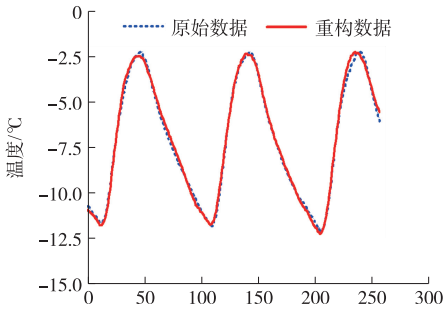

(a) CR = 1/32

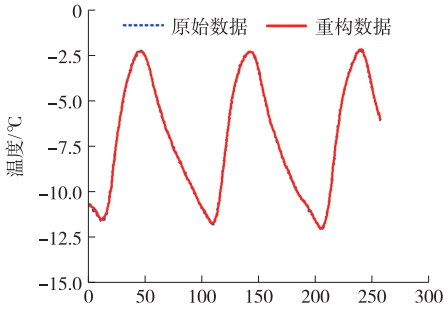

(b) CR = 1/4

图 10　IDCSNet 重构数据图

由图 10 可知,当 CR 分别取值为 1/32、1/4 时,重构数据与原始数据的 MSE 分别为 0.041 和 0.004 1。由此表明,重构算法在高 CR 下的重构精度更高。

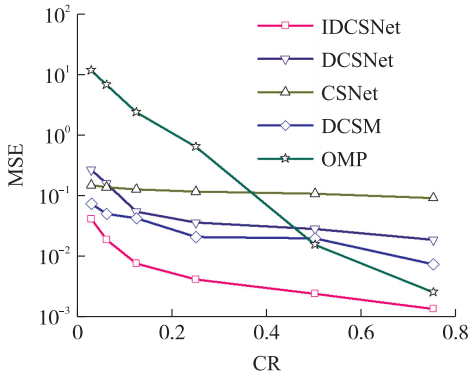

图 11 几种算法的重构误差对比

图 11 所示为 5 种重构算法的 MSE 随 CR 的变化曲线。对比算法包括 3 种基于深度学习的重构算法 DCSNet[11]、CSNet[12] 和 DCSM[13] 以及传统重构算法 OMP。可以看出,CR 越大原始数据与重构数据之间的 MSE 越小;相同 CR 时,所提 IDCSNet 算法的重构误差低于对比算法。比如,当 CR = 1/32 时,IDCSNet 算法的 MSE 相比 DCSNet、CSNet、DCSM、OMP 算法分别降低了 84.2%,72.3%,43.6%和 99.6%,说明所提算法是一种高精度数据重构算法。

数据的重构时间也是关键因素,本实验采用测试集上的 200 条数据,比较各算法在不同 CR 下,执行 50 次的平均重构时间,如表 2 所示。不同 CR 时,IDCSNet、DCSNet、CSNet 和 DCSM 等深度学习算法的重构时间短且非常接近,而深度学习方法比传统 OMP 算法的重构速度提高约 3 倍以上。

表 2 IDCSNet 与其他算法重构时间对比单位:s

算法	CR					
	1/32	1/16	1/8	1/4	1/2	3/4
IDCSNet	0.361	0.356	0.359	0.359	0.357	0.357
DCSNet	0.362	0.360	0.328	0.346	0.327	0.342
CSNet	0.360	0.364	0.357	0.351	0.340	0.340
DCSM	0.366	0.359	0.368	0.361	0.359	0.357
OMP	1.282	1.304	1.344	1.466	1.552	1.678

5 结论

针对压缩感知的 WSN 数据收集时能量受限、数据冗余的问题。本文提出一种基于深度学习的分簇 WSN 稀疏数据压缩感知重构算法。首先,设计了一种 FFACM 与 Voronoi 图的非均匀分簇算法,在此基础上,利用基于深度学习的稀疏数据压缩重构模型构建学习的测量矩阵和高效高精度重构网络。提高了较低 CR 下数据的重构精度,降低了网络中的数据传输量。仿真结果表明,本文算法能够有效延长网络生命周期。然而,由于重构网络受数据的影响,适合大量历史数据的特定场景下,才能有效完成数据的精准重构。下一步工作将针对该模型优化和提高重构算法的普适性上作进一步研究。

参考文献:

[1] 陈丽琴,顾静军. 基于无线传感器网络的地铁通信传输延迟优化方法[J]. 传感技术学报,2022,35(5):698-702.
[2] 孟建军,王建明,李德仓,等. 铁路沿线线型无线传感器网络节点部署策略[J]. 传感技术学报,2021,34(6):829-834.
[3] 唐松,尼玛扎西,高定国. 无线传感器网络在青藏铁路冻土监测领域的应用[J]. 重庆理工大学学报(自然科学),2015,29(5):112-118.
[4] 孙爱晶,李世昌,张艺才. 基于 PSO 优化模糊 C 均值的 WSN 分簇路由算法[J]. 通信学报,2021,42(3):91-99.
[5] 余修武,秦晓坤,刘永. 基于萤火虫算法优化 FCM 的 WSN 路由算法[J]. 北京邮电大学学报,2022,45(2):50-56.
[6] Ma N,Zhang H,Hu H,et al. ESCVAD:An Energy-Saving Routing Protocol Based on Voronoi Adaptive Clustering for Wireless Sensor Networks[J]. IEEE Internet of Things Journal,2022,9(11):9071-9085.
[7] Wang S,Nguyen T L N,Shin Y. Energy-Efficient Clustering Algorithm for Magnetic Induction-Based Underwater Wireless Sensor Networks[J]. IEEE Access,2019,7:5975-5983.
[8] Zhang Y,Liu L,Wang M,et al. An Improved Routing Protocol for Raw Data Collection in Multihop Wireless Sensor Networks[J]. Computer Communications,2022,188(C):66-80.
[9] Tropp J A,Gilbert A C. Signal Recovery from Random Measurements via Orthogonal Matching Pursuit[J]. IEEE Transactions on Information Theory,2007,53(12):4655-4666.
[10] Song Y C,Wu F Y,Ni Y Y,et al. A Fast Threshold OMP Based on Self-Learning Dictionary for Propeller Signal Reconstruction[J]. Ocean Engineering,2023,287:115792.
[11] Zhang M,Zhang H,Yuan D,et al. Learning-Based Sparse Data Reconstruction for Compressed Data Aggregation in IoT Networks[J]. IEEE Internet of Things Journal,2021,8(14):11732-11742.
[12] Zhang H,Dong Z,Wang Z,et al. CSNet:A Deep Learning Approach for ECG Compressed Sensing[J]. Biomedical Signal Processing and Control,2021,70:103065.
[13] Hua J,Rao J,Peng Y,et al. Deep Compressive Sensing on ECG Signals with Modified Inception Block and LSTM[J]. Entropy 2022,24(8),1024.
[14] 陈善雄,何中市,熊海灵,等. 一种基于压缩感知的无

线传感信号重构算法[J]. 计算机学报,2015,38(3):614-624.

[15] 林福根,温祥西,吴明功等. 基于 Voronoi 图和改进 *K*-Means 的扇区优化研究[J]. 西北工业大学学报,2023,41(1):170-179.

[16] Fang W, Zhang W, Yang W, et al. Trust Management-Based and Energy Efficient Hierarchical Routing Protocol in Wireless Sensor Networks[J]. Digital Communications and Networks,2021,7(4):470-478.

[17] Zhu B T,Bedeer E,Nguyen H H,et al. Improved Soft-*K*-Means Clustering Algorithm for Balancing Energy Consumption in Wireless Sensor Networks[J]. IEEE Internet of Things Journal,2020,8(6):4868-4881.

[18] Tan A L,Wang Y X,Zhao Y,et al. 1D-Inception-Resnet for NIR Quantitative Analysis and its Transferability between Different Spectrometers[J]. Infrared Physics & Technology,2023,129:104559.

[19] Wang L, Zhou X. Detection of Congestive Heart Failure Based on LSTM-Based Deep Network via Short-Term RR Intervals[J]. Sensors. 2019,19(7):1502.

[20] 国家青藏高原科学数据中心. 青藏高原土壤温湿度观测数据(2008—2016)[EB/OL]. (2021-04-19). https://data.tpdc.ac.cn/en/data/a08ac15d-06a1-4150-806c-50b8d80f72a/.

[21] Zeng Y J, Su Z B, Van der Velde R, et al. Blending Satellite Observed,Model Simulated,and in Situ Measured Soil Moisture over Tibetan Plateau[J]. Remote Sensing,2016,8(3):268.

李翠然(1975—),女,山西黎城人,博士,兰州交通大学教授、博士生导师,主要研究方向为高铁智能无线通信、无线传感器网络、协同通信技术等,licr@ mail.lzjtu.cn。