

基于 Attention 与改进 SCINet 模型的无线传感器网络能量预测与分簇路由算法

金崇强¹, 徐震¹, 王雪山²

(1.武汉轻工大学 电气与工程学院, 武汉 430048; 2.河南中烟工业有限责任公司 驻马店卷烟厂, 河南 驻马店 463000)

摘要:针对能量收集无线传感器网络中, 能量预测精度不佳、节点能量利用效率过低和网络难以持续运行等问题, 提出了一种改进样本卷积交互神经网络(sample convolution and interaction network, SCINet)预测模型, 并引入概率稀疏自注意力机制, 在新特征序列的每个时间步上计算注意力权重, 捕捉重要特征, 提高模型预测精度. 最后, 根据节点剩余能量、预测未来可收集的太阳能能量, 对分簇路由算法进行改进. 仿真实验结果表明, 该能量预测模型具备更高的预测精度和泛化能力. 在能量预测模型的基础上, 改进的分簇路由算法, 能有效地延长无线传感器网络的生命周期.

关键词: 能量预测; 样本卷积交互神经网络; 概率稀疏自注意力机制; 分簇路由算法

中图分类号: TP393

文献标志码: A

文章编号: 1000-2367(2025)05-0052-08

近年来, 物联网技术快速发展, 使得无线传感器网络得到了广泛的应用, 如环境监测、智慧农业、智慧交通等. 对于传统的无线传感器网络, 当传感器节点中的电池能量耗尽时, 节点将进入死亡状态进而使得网络性能下降甚至停止工作. 有限的电池容量限制了传感器节点的寿命, 使得无线传感器网络的维护成本大大增加.

为了满足未来无线传感器网络日益增长的应用需求, 学者们不断寻求合适的能量源以及便捷的供能方案给传感器节点提供能量. 能量收集无线传感器网络可以通过周围环境汲取能量, 并维持网络的正常运行, 因此得到了广泛的关注. 目前, 能量收集无线传感器网络可采集的能量有太阳能、热能、风能、机械能等.

太阳能具有高效、清洁、易获取等优势, 从而被广泛应用于 EH-WSNs 中. 利用太阳能的能量供给延长无线传感器网络的生命周期涉及能量管理^[1]、自适应功率调整^[2]、智能路由^[3]等技术. 然而, 太阳能受昼夜、天气、季节等变化影响较大, 具有随机性和不稳定性, 为了适应不断变化的太阳能能量, 提高能量利用率^[4], 学者们对能量预测算法进行了大量研究. 目前, 能量预测算法有基于统计学原理: 指数加权移动平均算法(exponential weighted moving average, EWMA)^[5]、WCMA^[6]、Pro-Energy^[7]等与基于机器学习原理: 知识神经网络^[8]、循环神经网络^[9]、长短期记忆神经网络(long short term memory, LSTM)^[10]等, 上述能量预测方法面临复杂天气和长期预测情况下精度不佳的问题, 能量预测精度不佳会造成无线传感器网络能量利用率低和节点提前死亡.

为延长无线传感器网络的生命周期, 本文提出了一种基于注意力机制与改进 SCINet 模型的能量预测模型, 和一种基于能量预测模型的分簇路由算法. 改进 SCINet 模型以残差融合结构替代残差链接结构, 并引

收稿日期: 2024-04-20; **修回日期:** 2024-05-22.

基金项目: 国家自然科学基金(62072319).

作者简介: 金崇强(1999—), 男, 浙江台州人, 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, 主要从事无线网络及机器学习方面的研究, E-mail: xuzhen2046@qq.com.

引用本文: 金崇强, 徐震, 王雪山. 基于 Attention 与改进 SCINet 模型的无线传感器网络能量预测与分簇路由算法[J]. 河南师范大学学报(自然科学版), 2025, 53(5): 52-59. (Jin Chongqiang, Xu Zhen, Wang Xueshan. Energy prediction and cluster routing algorithm for wireless sensor networks based on attention and improved SCINet modeling [J]. Journal of Henan Normal University(Natural Science Edition), 2025, 53(5): 52-59. DOI: 10.16366/j.cnki.1000-2367.2024.04.20.0001.)

入注意力机制,自适应地调整输入和输出在最终结果中的贡献度,提高模型的预测精度与泛化能力.在精确的能量预测的基础之上,根据每个节点自身的剩余能量和未来可以收集的能量,提出一种分簇路由协议,能量水平较高的节点具有更大的概率当选簇头.仿真实验证明,本文方法能有效延长无线传感网络的生命周期.

1 相关研究

文献[5]提出了 EWMA,它假设一天中给定时间内收获的能量与前几天同一时间的收获能量相似,并用加权平均的方式预测当天同一时间的能量.文献[6]在 EWMA 的基础上,将天气变化作为太阳能能量预测的重要因素,提出了天气条件移动平均算法(weather conditioned moving average, WCMA).文献[7]提出了轮廓能量预测模型,它进一步拓展了 WCMA,通过将当天的太阳能数据与前几天相同时段的太阳能数据进行比较,选择与当天太阳能数据最相似的一天,将前一个时间段观测到的能量与最相似天的当前时间段的能量相结合,以实现更准确的预测.

相比于上述基于统计学原理,基于机器学习原理的算法在复杂多变的环境中,能够有效处理和分析大规模、多变量的数据集,更能捕捉太阳能时间序列中的非线性变化.循环神经网络和长短期记忆网络^[8]等方法相继被应用于无线传感器网络中的太阳能能量预测研究.文献[9]提出一种基于自回归积分移动平均(auto-regressive intergrated moving average, ARIMA)-长短期记忆组合模型的能量预测方法,融合了 ARIMA 与 LSTM 的优势,提高了预测结果.由于误差累积,以上预测模型的准确性随着预测时长增加而降低,因此这些模型都只适用于短期能量预测.针对上述问题,文献[10]提出了样本卷积交互神经网络(sample convolution and interaction network, SCINet),通过丰富的卷积滤波器捕捉多分辨率下的动态时间依赖性来增强原始时间序列的可预测性,有效提高了长期能量预测的性能.

在分簇路由协议方面,文献[11]提出的 LEACH 协议首次通过引入簇的概念有效降低了无线传感器网络(WSN)的能耗,但该协议采用随机选举簇头的方式,使得部分能量较低的节点当选簇头造成节点死亡.文献[12]提出太阳能能量感知分簇路由协议,该协议优化了 LEACH 的簇头选举策略,由当前簇头来决定下一个簇头的产生,避免了同一节点多次连续当选簇头造成的节点死亡.文献[13]提出了自适应能量收集感知分簇路由协议,该协议根据短期内节点收集能量的速度选择簇头,收集能量的速度越快,当选簇头的概率就越大.

2 方案设计

本节首先对原始数据的处理;之后提出 ATT-Fuse-SCINet(SCINet with attention and residual fusion structure)能量预测模型和基于高精度能量预测模型下的分簇路由算法 EP-LEACH(energy prediction-based leach algorithm).

2.1 数据处理

将原始数据 $x_i(k)$ 进行归一化,得 $x'_i(k) = \frac{x_i(k) - x_{i,\min}}{x_{i,\max} - x_{i,\min}}$,使得所有特征在同一尺度上,加快学习算法的收敛速度.式中, $x_{i,\max}$, $x_{i,\min}$ 分别为特征 i 中最大值和最小值.

采用澳大利亚太阳能中心(DKASC)的 Tennant Creek 电站的公开辐照度数据集.该数据集除了太阳能直接辐照度,还有水平辐照度、倾斜辐照度、气温、湿度、风速、风向、降雨量等环境特征,但其中一些特征可能存在冗余或者与预测任务无关,为了减少计算资源,提高训练效率,采用皮尔森相关系数法分析其余特征与太阳能直接辐照度之间的相关性^[14].相关系数

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}},$$

其中, x , $\bar{x}$ 为目标值和平均值, y , $\bar{y}$ 为其他特征序列值及其平均值.

2.2 ATT-Fuse-SCINet 预测模型

首先,引入概率稀疏注意力机制对 SCI-Block 交互学习的方式生成的 2 个新的子序列自适应地分配注意力权重,使模型更专注于重要特征.经过多层 SCI-Block 后,重新组装成一个新的序列,通过残差融合(residual fusion)替代残差连接的方式将其加入到原序列中,进行预测,可以自适应地调整输入和输出在最终结果中的贡献度,提高模型的泛化能力.ATT-Fuse-SCINet 模型结构图如图 1 所示.




图1 ATT-Fuse-SCINet整体结构
Fig.1 Overall structure of ATT-Fuse-SCINet

2.2.1 SCI-Block

SCI-Block 是 SCINet 的基本单元.将输入数据或特征降采样为一个奇序列 F_{odd} 和一个偶序列 F_{even} ,然后用一组一维卷积模块 φ 和 ψ 将 F_{odd} 和 F_{even} 转换为以 e 为底的指数函数,并 F_{odd} 和 F_{even} 与进行元素层面的交互 Hadamard 乘积操作,得到 $F_{odd}^s = F_{odd} \odot \exp(\phi(F_{even}))$ 和 $F_{even}^s = F_{even} \odot \exp(\psi(F_{odd}))$, 其中, $\odot$ 表示 Hadamard 乘积.

再通过另一组一维卷积模块 ρ 和 η 将 F_{odd}^s 和 F_{even}^s 子序列映射到隐藏状态,并和 F_{odd}^s 和 F_{even}^s 进行交互式的加减操作,最终得到新的子特征 $F'_{odd} = F_{odd}^s \pm \rho(F_{even}^s)$ 和 $F'_{even} = F_{even}^s \pm \eta(F_{odd}^s)$. 用这种交互学习的策略可以补偿降采样中的信息损失^[15].

SCINet 由多个 SCI-Block 以二叉树的结构搭建而成,第 i 层就有 $2i-1(i=1,2,3,\cdots,L)$ 个 SCI-Block. 通过对输入时间序列进行 L 层的降采样-卷积-交互学习操作后,再对所有子序列中的元素按逆奇偶分裂进行排列并连接成新的序列表示,用残差连接^[16]的方式将其添加到原序列中,最后经过全连接层解码得到最终的预测结果 $\hat{X}(\hat{X} = \{\hat{x}_{i+1}, \hat{x}_{i+2}, \cdots, \hat{x}_{i+\tau}\})$. 这种设计的一个显著优势是每个 SCI-Block 都对整个时间序列有局部和全局视角,从而有助于提取有用的时间特征,有利于长期预测的稳定.

2.2.2 概率稀疏自注意力机制

注意力机制通过在每个 SCI-Block 的输出 F'_{odd} 和 F'_{even} 上动态地调整重视程度,以此突显关键信息并提高网络对重要信息的关注,从而提高预测精度.传统的自注意力机制本质上是对样本进行权重分配,利用注意力函数将一个查询向量和一组键值向量映射到输出向量上^[17].

概率稀疏自注意力机制(probSparse self-attention)是对传统自注意力机制(self-attention)的发展,稀疏的自注意力机制呈现出长尾效应,其中主要的注意力集中于少数几个点积上,而其他点积的贡献相对较小,甚至可以忽略.因此,通过减少一些元素间的联系,可以有效减少计算的复杂性^[18].文献[19]作者首先提出一个 query 稀疏程度的度量方法,然后筛选出重要的 query,第 i 个 query 的稀疏性

$$M(q_i, \mathbf{K}) = \ln \sum_{j=1}^{L_K} e^{\frac{q_i k_j}{\sqrt{d}}} - \frac{1}{L_K} \sum_{j=1}^{L_K} \frac{q_i k_j}{\sqrt{d}},$$

其中, q_i 为 $\mathbf{Q}$ 中第 i 个元素; k_j 为 $\mathbf{K}$ 中第 j 个元素, $L_{\mathbf{K}}$ 为 $\mathbf{K}$ 的长度.

对于输入序列 $\mathbf{X} = \{x_1, x_2, x_3, \dots, x_n\}$, 有如下计算:

$$\begin{cases} \mathbf{A} = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}_{\text{sparse}}^T}{\sqrt{d_k}}\right), \\ \mathbf{Q} = \mathbf{X} \times \mathbf{W}_q, \\ \mathbf{K}_{\text{sparse}} = \mathbf{X} \times \mathbf{W}_k, \\ \mathbf{V}_{\text{sparse}} = \mathbf{X} \times \mathbf{W}_v, \end{cases}$$

其中, $\mathbf{A}$ 为自注意力分数矩阵; $\mathbf{Q}$ 为 query 向量; d_k 为输入键值向量的维度; $\mathbf{K}_{\text{sparse}}$ 为概率稀疏化的键值向量; $\mathbf{V}_{\text{sparse}}$ 为对应 $\mathbf{K}_{\text{sparse}}$ 的值向量. $\mathbf{W}_q, \mathbf{W}_k, \mathbf{W}_v$ 为可训练的投影矩阵.

输入元素 x_i 对应的输出 x'_i 是所有 $\mathbf{V}_{\text{sparse}}$ 的加权和, 权重由相应的注意力分数注意力分数矩阵给出

$$x'_i = \sum_{j=1}^m A_{ij} V_{j, \text{sparse}},$$

其中, $V_{j, \text{sparse}}$ 是概率稀疏化的值向量的第 j 个元素, m 为概率稀疏自注意力机制下被选中参与计算的元素数量.

2.2.3 ATT-Fuse-SCINet

经过 L 层 SCI-Block 的输出序列, SCINet 模型采用残差连接结构, 残差连接是一种常见的神经网络架构, 将输入直接加到网络的输出上. 可以在深层网络的反向传播时, 梯度更有效地回流, 减少误差积累, 缓解梯度消失. 残差连接公式 $H(\mathbf{X}) = F(\mathbf{X}) + \mathbf{X}$, 其中, $H(\mathbf{X}) = \{h(x_1), h(x_2), \dots, h(x_t)\}$ 为残差连接后的序列; $\mathbf{X}(\mathbf{X} = \{x_1, x_2, x_3, \dots, x_t\})$ 为输入序列; $F(\mathbf{X}) = \{f(x_1), f(x_2), \dots, f(x_t)\}$ 为经过层处理的输出序列. 而残差融合 (Residual Fusion) 则是一种更加灵活的结构, 对输入 $\mathbf{X}$ 和网络输出 $F(\mathbf{X})$ 进行网络训练, 根据数据特性和误差寻找最优权重进行加权融合 (fuse), 自适应地调整输入和输出在最终结果中的贡献度, 以提高模型的表示能力, 即

$$c(x_i) = w_{\text{norm},1} f(x_i) + w_{\text{norm},2} x_i,$$

其中, 归一化处理的权重 $w_{\text{norm},i} = \frac{\text{Swish}(w_i)}{\sum_j \text{Swish}(w_j) + \epsilon}$, Swish 激活函数 $\text{Swish}(w) = \frac{2}{1 + e^{-w}}$, w 为权重参数,

初始值为 1, 在网络训练的迭代过程中计算损失并通过反向传播自动更新权重参数; ϵ 为一个很小的数, 防止分母为 0, 保证训练过程中数值稳定. 融合序列 $C(\mathbf{X}) = \{c(x_1), c(x_2), \dots, c(x_t)\}$.

2.3 基于能量预测的分簇路由算法

2.3.1 分簇路由算法

文献[12]提出的 LEACH 协议通过引入簇的概念有效降低了无线传感器网络的能耗. 在形成簇的过程中, 该协议采取了循环的簇头选举机制, 确保每个节点有相同的概率成为簇头. 具体来说, 网络中的每个节点会生成 $[0, 1]$ 随机数, 如果这个数小于设定的阈值 T , 该节点便被选为簇头. 对于每个非簇头的节点, 在第 r 轮中, 其簇头选举阈值

$$T(r) = P / (1 - P(r \bmod(1/P))),$$

其中, P 为预期簇头在所有节点中所占的比例.

文献[13]对 LEACH 协议做了改进, 将剩余能量加入簇头选举的考虑因素中, 增加剩余能量多的节点当选簇头的概率, 新的簇头选举阈值

$$T(r) = PE_i^{\text{res}} / ((1 - P(r \bmod(1/P))) E_{\text{av}}),$$

式中, E_i^{res} 为节点剩余能量, $E_{\text{av}} = (\sum_{i=1}^n E_i^{\text{res}}) / n$ 为网络平均能量.

2.3.2 EP-LEACH 协议算法

对于环境能量收集无线传感器网络而言, 路由协议如果只考虑节点剩余能量而不考虑节点未来能量收集, 会造成能量的浪费和效率的低下. 因此, 基于高精度的能量预测模型, 提出了一种分簇型路由协议 EP-LEACH. 该协议将节点剩余能量、以及预测的未来可收集的能量作为簇头选举的关键因素, 能量水平越高的

节点拥有更大的概率当选簇头,避免能量水平较低的节点当选簇头消耗过多的能量,延长节点存活时间.改进后的簇头选举阈值

$$T(r)=P\eta/(1-P(r\mod(1/P))),\eta=\frac{[E_i^{\text{res}}(r)+E_i^{\text{pre}}(r)]/E_i^{\text{init}}}{(\sum_i[E_i^{\text{res}}(r)+E_i^{\text{pre}}(r)]/\sum_iE_i^{\text{init}})},$$

其中, E_i^{res} 为当前节点剩余能量; E_i^{pre} 为当前节点在本轮结束时的预测能量. E_i^{init} 为当前节点的初始能量.

3 实验分析

3.1 数据集

采用澳大利亚太阳能中心(DKASC)的 Tennant Creek 电站的公开辐照度数据集.以 2023-09-29—2023-12-07 的数据为实验样本,设定数据集的前 80% 为训练集,后 10% 为测试集,中间 10% 为验证集.并采用皮尔森相关系数法分析水平辐照度、倾斜辐照度、气温、湿度、风速、风向等气象特征与直接辐照度之间的关联性,皮尔森相关系数大小分别为 0.958 3;0.944 4;0.712 4;−0.500 2;0.125 9;0.083 3.选用关联性绝对值较高的前 4 个组成一组新特征.

3.2 ATT-Fuse-SCINet 模型性能评估

太阳能能量预测实验采用均方根误差(RMSE)、平均绝对误差(MAE)、决定系数(R^2)、平均绝对百分比误差(MAPE)来评判模型的预测精度.

选用 LSTM、ARIMA-LSTM、SCINet、ATT-SCINet、Fuse-SCINet 模型作为比较对象,对未来连续多天进行滚动预测验证模型长期预测的效果,并选取 3 种不同的天气条件(晴天、多云、阴雨)下验证模型的泛化能力,如图 2 所示.评价指标实验结果见附录表 S1~S4.




图2 预测结果对比

Fig.2 The comparison of prediction results

在 8 天连续预测的对比实验中,ATT-Fuse-SCINet 模型取得了最高的精度,RMSE、MAE、MAPE 分别为 0.052 1、0.020 2、10.580 4%,相比于 SCINet,RMSE 减小了 5.96%,MAE 减小了 11.79%,MAPE 减小了 13.70%, R^2 值达到了最高值 0.973 3,实验表明 ATT-Fuse-SCINet 模型在长期预测领域有着明显的优势.

由于平稳天气缺少复杂的非线性关系,所以在晴天的天气条件下,大部分模型都有着较高的精度.在晴天天气下,ATT-Fuse-SCINet 取得了最高的预测精度,RMSE、MAE、MAPE 分别为 0.010 6、0.007 6、2.081%,均为所有模型中的最小误差值, R^2 达到了最高值 0.999 1,相比于 SCINet,RMSE 减小了 42.70%,

MAE 减小了 47.59%,MAPE 减小了 27.49%, R^2 比 SCINet 提升了 0.001 8.由于 ARIMA 时间滞后性的问题,使得 ARIMA-LSTM 模型在平稳天气下的精度受到了影响, RMSE、MAE、MAPE 达到了 0.037 6、0.032 7、8.998 3%, R^2 仅为 0.988 9.

在非平稳的天气条件下如多云天气和阴雨天气,LSTM 的表现最差,ATT-Fuse-SCINet 在所有指标中取得了最优的表现,Fuse-SCINet 模型次之.以天气复杂度最高的阴雨天气为例,ATT-Fuse-SCINet 的 RMSE、MAE、MAPE 仅为 0.075 8、0.047 7、15.698 5%,依然是所有模型中的最小误差值,相比于 SCINet 分别减小了 18.05%、25.71%、26.50%, R^2 为最高值 0.901 7.

由表 1 可知,ATT-Fuse-SCINet 和 ATT-SCINet 由于引入注意力机制训练时间高于 Fuse-SCINet、SCINet、ARIMA-LSTM 和 LSTM.ATT-Fuse-SCINet 相比于 ATT-SCINet 训练时长延长了 0.15%.推断时长即单次预测时长 6 种算法基本相同.实验结果表明本文所提的 ATT-Fuse-SCINet 能量预测模型以较小的时间开销为代价,获得了最高的预测精度和最好的泛化能力.

表 1 模型预测时间开销
Tab. 1 Prediction time overhead of models

模型	ATT-Fuse-SCINet	ATT-SCINet	Fuse-SCINet	SCINet	ARIMA-LSTM	LSTM
训练时间/s	681.312 7	680.314 6	611.089 1	613.996 9	602.524 0	602.524 0
推断时间/s	0.169 1	0.168 8	0.163 1	0.163 5	0.174 1	0.165 8

3.3 网络寿命比较

本实验采用 MATLAB 仿真,仿真参数见附录表 S5.将 EP-LEACH 分簇路由协议与 LSTM、SCINet、ATT-Fuse-SCINet 预测模型相结合,从存活节点数、网络剩余能量和死亡节点数 3 个方面与 LEACH 算法进行分析比较,评估 EP-LEACH 算法对网络寿命的延长效果,以及不同的能量预测模型对 EP-LEACH 性能的影响.

图 3 为 LEACH 算法与 3 种不同预测模型下的 EP-LEACH 算法的节点存活数对比,前 158 轮 4 种算法都没有出现死亡节点,随着轮数的增加存活节点数不断减少.在第 400 轮时,LEACH 算法、EP-LEACH-LSTM、EP-LEACH-SCINet 算法的存活节点数分别是 EP-LEACH-ATT-Fuse-SCINet 的 79.3%、89.7%、93.1%;在第 800 轮时,LEACH 算法、EP-LEACH-LSTM、EP-LEACH-SCINet 算法的存活节点数分别是 EP-LEACH-ATT-Fuse-SCINet 的 27.8%、50.0%、90.7%.

图 4 为 LEACH 算法与 3 种不同预测模型下的 EP-LEACH 算法的网络剩余能量对比,随着轮数不断增加,网络剩余能量不断减小.LEACH 算法的网络剩余能量下降速度最快,EP-LEACH-ATT-Fuse-SCINet 算法下的网络剩余能量下降速度最慢,在第 400 轮时,LEACH 算法、EP-LEACH-LSTM、EP-LEACH-SCINet 算法的网络剩余能量分别为 EP-LEACH-ATT-Fuse-SCINet 算法的 63.6%、80.3%、89.1%;在第 800 轮时,LEACH 算法、EP-LEACH-LSTM、EP-LEACH-SCINet 算法的网络剩余能量分别为 EP-LEACH-ATT-Fuse-SCINet 算法的 15.4%、34.6%、76.9%.




图 5 为 LEACH 算法与 3 种不同预测模型下的 EP-LEACH 算法在不同节点数量下的网络寿命对比.当

节点数量为 200 时, EP-LEACH-ATT-Fuse-SCINet 算法的网络寿命比 LEACH、EP-LEACH-LSTM、EP-LEACH-SCINet 算法分别提高了 39.32%、21.24%、13.85%;当节点数量为 300 时, EP-LEACH-ATT-Fuse-SCINet 算法的网络寿命比 LEACH、EP-LEACH-LSTM、EP-LEACH-SCINet 算法分别提高了 53.59%、19.58%、8.46%。

实验结果证明, 结合能量预测模型的 EP-LEACH 算法比传统的 LEACH 算法的能量消耗速率更低, 节点死亡速度更慢, 其中, 结合 ATT-fuse-SCINet 能量预测模型的 EP-LEACH 算法对延长网络寿命的效果要明显优于结合其他预测模型的 EP-LEACH 算法。

4 结 论

为更好地利用太阳能, 延长无线传感器网络生命周期, 本文提出了一种基于 Attention 与改进 SCINet 模型的无线传感器网络能量预测与分簇路由算法, 结合实验分析, 可以得出以下结论:

- 1) ATT-Fuse-SCINet 模型和其他预测模型相比, 具有更好的稳定性和泛化能力, 不论在长期预测方面还是对非平稳天气情况下的太阳能能量预测方面, 都得到了极大的改善。
- 2) 通过在网络中引入精确的能量预测机制, EP-LEACH 能够有效优化能量资源利用, 减缓节点死亡速率和网络剩余能量消耗速率, 并延长网络的整体寿命。

附录见电子版(DOI:10.16366/j.cnki.1000-2367.2024.04.20.0001)。

参 考 文 献

[1] SAH D K, AMGOTH T. Renewable energy harvesting schemes in wireless sensor networks; a Survey[J]. Information Fusion, 2020, 63: 223-247.

[2] KHAN M N, RAHMAN H U, ALMAIAH M A, et al. Improving energy efficiency with content-based adaptive and dynamic scheduling in wireless sensor networks[J]. IEEE Access, 2020, 8: 176495-176520.

[3] AL-TOUS H, BARHUMI I. Reinforcement learning framework for delay sensitive energy harvesting wireless sensor networks[J]. IEEE Sensors Journal, 2021, 21(5): 7103-7113.

[4] 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 Y X, XU Z. Energy prediction and management of solar wireless sensor networks[J]. Journal of Henan Normal University(Natural Science Edition), 2024, 52(3): 80-87.

[5] 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.

[6] RECAS PIORNO J, BERGONZINI C, ATIENZA D, et al. Prediction and management in energy harvested wireless sensor nodes[C]// 2009 1st International Conference on Wireless Communication, Vehicular Technology, Information Theory and Aerospace & Electronic Systems Technology, May 17-20, 2009, Aalborg, Denmark. IEEE, 2009: 6-10.

[7] 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), October 8-11, 2012, [S.l.]: IEEE, 2012: 75-83.

[8] 崔粟晋, 王雪. 基于长短时记忆太阳能无线传感节点能量预测[J]. 仪器仪表学报, 2018, 39(11): 147-154.

CUI S J, WANG X. Solar wireless sensor node energy prediction based on long-short term memory[J]. Chinese Journal of Scientific Instrument, 2018, 39(11): 147-154.

[9] 沈露露, 梁嘉乐, 周雯. 基于 ARIMA-LSTM 的能量预测算法[J]. 无线电通信技术, 2023, 49(1): 150-156.

SHEN L L, LIANG J L, ZHOU W. Energy prediction algorithm based on ARIMA-LSTM model[J]. Radio Communications Technology,




图5 不同节点数量的网络寿命比较
Fig.5 Comparison of network lifetime for different number of nodes

2023,49(1):150-156.

[10] LIU M,ZENG A,CHEN M,et al.Scinet:Time series modeling and forecasting with sample convolution and interaction[J].Advances in Neural Information Processing Systems,2022,35:5816-5828.

[11] HEINZELMAN W B,CHANDRAKASAN A P,BALAKRISHNAN H.An application-specific protocol architecture for wireless microsensor networks[J].IEEE Transactions on Wireless Communications,2002,1(4):660-670.

[12] VOIGT T,DUNKELS A,ALONSO J,et al.Solar-aware clustering in wireless sensor networks[C]//Proceedings.ISCC 2004.Ninth International Symposium on Computers and Communications(IEEE Cat.No.04TH8769).July 28,2004.[S.l.]:IEEE,2004:238-243.

[13] ZAHID KAUSAR A S M,REZA A W,SALEH M U,et al.Energizing wireless sensor networks by energy harvesting systems:Scopes, challenges and approaches[J].Renewable and Sustainable Energy Reviews,2014,38:973-989.

[14] 徐柔,章杰,赖松林,等.结合改进的 DCGAN 和 Attention-LSTM 的光伏功率预测[J].福州大学学报(自然科学版),2023,51(4):498-504.
XU R,ZHANG J,LAI S L,et al.Photovoltaic power prediction combining improved DCGAN and Attention-LSTM[J].Journal of Fuzhou University(Natural Science Edition),2023,51(4):498-504.

[15] 闫伟曦,陈鹏,唐鹏,等.基于 EEMD 和 SCINet 的高速公路交通流量预测[J].武汉理工大学学报,2022,44(10):30-39.
YAN W X,CHEN P,TANG P,et al.Traffic flow prediction of expressway based on EEMD and SCINet[J].Journal of Wuhan University of Technology,2022,44(10):30-39.

[16] AL-FALLUJI R A,YOUSSIF A A A,GUIRGUIS S K.Single image super resolution model using learnable weight factor in residual skip connection[J].IEEE Access,2019,7:58676-58684.

[17] 钟智伟,王誉翔,黄亦翔,等.基于概率稀疏自注意力的 IGBT 模块剩余寿命跨工况预测[J].上海交通大学学报,2023,57(8):1005-1015.
ZHONG Z W,WANG Y X,HUANG Y X,et al.Remaining useful life prediction of IGBT modules across working conditions based on ProbSparse self-attention[J].Journal of Shanghai Jiao Tong University,2023,57(8):1005-1015.

[18] ZHOU H Y,ZHANG S H,PENG J Q,et al.Informer:beyond efficient transformer for long sequence time-series forecasting[J].Proceedings of the AAAI Conference on Artificial Intelligence,2021,35(12):11106-11115.

[19] 韩宝慧,陆玲霞,包哲静,等.基于多头概率稀疏自注意力模型的综合能源系统多元负荷短期预测[J].电力建设,2024,45(2):127-136.
HAN B H,LU L X,BAO Z J,et al.Short-term forecasting of multienergy loads of integrated energy system based on multihead probabilistic sparse self-attention model[J].Electric Power Construction,2024,45(2):127-136.

Energy prediction and cluster routing algorithm for wireless sensor networks based on attention and improved SCINet modeling

Jin Chongqiang¹, Xu Zhen¹, Wang Xueshan²

(1. School of Electrical and Electronic Engineering, Wuhan Polytechnic University, Wuhan 430048, China;
2. Zhumadian Cigarette Factory, Henan China Tobacco Industry Co., Ltd., Zhumadian 463000, China)

Abstract: To address the issues such as poor energy prediction accuracy, low energy utilization efficiency of nodes, and difficulty in sustaining operations in energy-harvesting wireless sensor networks, an improved sample convolutional and interaction network(SCINet) prediction model is proposed. This model incorporates the Probabilistic Sparse Self-Attention mechanism, which calculates attention weights at each time step of the new feature sequence to capture important features and enhance model prediction accuracy. Finally, the clustering routing algorithm is improved based on the remaining energy of the nodes and the predicted solar energy that can be collected in the future. Simulation results demonstrate that this energy prediction model has higher prediction accuracy and generalization capability. Based on the energy prediction model, the improved clustering routing algorithm can effectively extend the lifespan of wireless sensor networks.

Keywords: energy prediction; sample convolutional and interaction network; probabilistic sparse self-attention mechanism; clustering routing algorithm

[责任编辑 杨浦 刘洋]

附 录

表 S1 8 d 预测结果评估

Tab. S1 Evaluation of 8-day prediction results				
模型	RMSE	MAE	R^2	MAPE/%
ATT-Fuse-SCINet	0.052 1	0.020 2	0.973 3	10.580 4
ATT-SCINet	0.054 1	0.022 4	0.971 3	11.946 7
Fuse-SCINet	0.052 3	0.020 8	0.973 2	11.194 2
SCINet	0.055 4	0.022 9	0.969 8	12.26 0 1
ARIMA-LSTM	0.060 6	0.026 3	0.963 9	14.597 0
LSTM	0.075 6	0.036 1	0.943 8	18.959 7

表 S2 晴天预测结果评估

Tab. S2 Evaluation of sunny day prediction results				
模型	RMSE	MAE	R^2	MAPE/%
ATT-Fuse-SCINet	0.010 6	0.007 6	0.999 1	2.081 0
ATT-SCINet	0.016 5	0.012 3	0.997 9	3.597 5
Fuse-SCINet	0.017 9	0.014 9	0.997 5	3.812 2
SCINet	0.018 5	0.014 5	0.997 3	2.869 8
ARIMA-LSTM	0.037 6	0.032 7	0.988 9	8.998 3
LSTM	0.031 6	0.023 9	0.992 2	7.555 3

表 S3 多云预测结果评估

Tab. S3 Evaluation of cloudy day prediction results				
模型	RMSE	MAE	R^2	MAPE/%
ATT-Fuse-SCINet	0.076 0	0.040 6	0.943 0	9.376 3
ATT-SCINet	0.075 8	0.043 8	0.943 3	9.934 0
Fuse-SCINet	0.075 9	0.040 5	0.943 2	9.761 0
SCINet	0.083 3	0.046 4	0.931 6	11.941 0
ARIMA-LSTM	0.078 4	0.042 8	0.939 4	10.897 6
LSTM	0.083 9	0.051 8	0.930 6	12.850 7

表 S4 阴雨天预测结果评估

Tab. S4 Evaluation of rainy day prediction results				
模型	RMSE	MAE	R^2	MAPE/%
ATT-Fuse-SCINet	0.075 8	0.047 7	0.901 7	15.698 5
ATT-SCINet	0.087 8	0.056 8	0.867 9	18.579 2
Fuse-SCINet	0.078 6	0.052 1	0.894 4	17.618 1
SCINet	0.092 5	0.064 2	0.853 4	21.357 8
ARIMA-LSTM	0.097 9	0.060 6	0.835 9	21.235 8
LSTM	0.124 5	0.080 7	0.734 8	27.797 3

表 S5 仿真参数

Tab. S5 Simulation parameters

Parameter	Value	Parameter	Value
节点个数 n	200	融合能耗	5 nJ/bit
区域面积	200 m×200 m	自由空间模型系数	10 pJ/(bit • m ²)
基站坐标	(100 m,300 m)	双射线地面传播模型系数	0.001 3 pJ/(bit • m ⁴)
初始簇头概率	0.05	数据包长度	4 000 bit
初始能量	0.05 J	控制包长度	200 bit
接收/发送能量损耗	50 nJ/bit		