

基于改进 BiLSTM-KF 的 WSN 数据漂移盲校准算法

史志强^{1,2,3}, 古丽米拉·克孜尔别克^{1,2,3}, 韩博^{1,2,3}, 张瑛进^{1,2,3}

- 新疆农业大学 计算机与信息工程学院, 新疆 乌鲁木齐 830052;
- 智能农业教育部工程研究中心, 新疆 乌鲁木齐 830052;
- 新疆农业信息化工程技术研究中心, 新疆 乌鲁木齐 830052)

摘要:无线传感器网络数据的准确性对智能系统的决策和环境监测的优化至关重要。针对传感器设备在工作过程中易受外部环境变化及自身特性的影响产生数据漂移现象,导致数据精确度产生偏差的问题,该文提出一种基于 CNN-BiLSTM-Attention-KF 的无线传感器网络数据漂移校准方法。首先,利用 CNN 提取数据的局部特征,BiLSTM 捕获时序数据的长期依赖关系,并引入 Attention 增强模型处理数据序列中的关键信息,根据节点数据的时空相关性进行建模,得到待校准节点的预测值。其次,将其预测值与节点的实际观测值作为卡尔曼滤波器的输入,实现对漂移数据的跟踪和校准。在公开数据集 IBRL 上进行实验,结果表明该方法在各评价指标有所改善,其中平均绝对误差(MAE)降至 0.325 5,均方误差(MSE)降至 0.228 9,相关系数(R^2)达到 0.988 2,均优于其他算法。CNN-BiLSTM-Attention-KF 具有较好的校准效果,对于传感器在长时间工作中保持数据准确性具有重要意义。

关键词:无线传感器网络;数据漂移;双向长短期记忆网络;卡尔曼滤波器;盲校准

中图分类号:TP274.2

文献标识码:A

文章编号:1673-629X(2025)02-0122-08

doi:10.20165/j.cnki.ISSN1673-629X.2024.0320

WSN Data Drift Blind Calibration Algorithm Based on Improved BiLSTM-KF

SHI Zhi-qiang^{1,2,3}, GULIMILA Kezierbieke^{1,2,3}, HAN Bo^{1,2,3}, ZHANG Ying-jin^{1,2,3}

- School of Computer and Information Engineering, Xinjiang Agricultural University, Urumqi 830052, China;
- Intelligent Agriculture Engineering Research Center of the Ministry of Education, Urumqi 830052, China;
- Xinjiang Agricultural Informatization Engineering Technology Research Center, Urumqi 830052, China)

Abstract: The accuracy of wireless sensor network data is highly important for intelligent system decision-making and environmental monitoring optimization. To counter the problem that sensor equipment is susceptible to the influence of external environmental alterations and its inherent attributes during the working process, subsequently resulting in the data drift phenomenon and the deviation of data accuracy, we proffer a data drift calibration approach based on CNN-BiLSTM-Attention-KF in wireless sensor networks. Initially, CNN was harnessed to extract the local traits of the data, BiLSTM seized the long-term dependency relationship of the time series data, and Attention was incorporated to augment the model's capacity to handle the key information in the data series. It was modelled in line with the spatiotemporal correlation of the node data, and the predicted value of the node requiring calibration was acquired. Subsequently, the predicted value and the actual observed value of the node were utilized as the input of the Kalman filter to monitor and calibrate the drift data. Experiments are carried out on the public dataset IBRL evince that the proposed method has manifested improvements in diverse evaluation indicators. Among them, the mean absolute error (MAE) is lowered to 0.325 5, the mean square error (MSE) is reduced to 0.228 9, and the correlation coefficient (R^2) ascends to 0.988 2, all of which outshine other algorithms. The CNN-BiLSTM-Attention-KF methodology exhibits a superb calibration effect and holds great influence for the sensor to uphold data accuracy during prolonged working hours.

Key words: wireless sensor networks; data drift; bidirectional long short-term memory networks; Kalman filters; blind calibration

收稿日期:2024-07-04

修回日期:2024-11-06

基金项目:科技部科技创新 2030 重大项目(2022ZD0115800);新疆维吾尔自治区重大科技专项(2022A02011-4)

作者简介:史志强(1998-),男,硕士研究生,CCF 会员(U4423G),研究方向为深度学习应用、信号与信息处理;通讯作者:古丽米拉·克孜尔别克(1970-),女,硕导,副教授,研究方向为农业信息化、计算机应用。

0 引言

随着物联网技术的发展,无线传感器网络(Wireless Sensor Network, WSN)已经成为现代智能系统的重要组成部分,广泛应用于环境监测、工业自动化、农业监控等多个领域^[1]。WSN 通过部署大量自主运行、多功能的传感器节点实时采集、处理并传输监测环境的关键数据。然而在实际应用过程中,由于传感器制造工艺、测量精度存在差异以及长期处于复杂环境工作等因素影响,导致传感器出现不同程度的数据漂移现象,造成测量值与实际值之间产生偏差。数据漂移不仅影响测量结果的准确性,还会降低整个无线传感器网络的性能和可靠性。因此,对传感器的漂移数据进行校准至关重要。研究数据漂移校准的方法可以分为两类:非盲校准和盲校准。

非盲校准方法需要使用外部参考或先验知识来进行校准,依赖于已知的准确数据或标准参考设备来校准传感器的数据漂移^[2]。通常情况下传感器会在出厂阶段由人工根据设备标准值进行手动校准,但是传感器经过长时间使用后需要定期进行校准,此方法只适用于小规模传感器部署环境,在大规模网络的部署中并不实用^[3],手动校准传感器设备不仅消耗人力,成本也比较高。

而盲校准方法通常以节点密集部署或监测相同目标为前提^[4-5],通过对传感器数据进行统计分析和建模来估计和校准传感器的漂移,不需要依赖外部参考。在大规模部署的 WSN 中,很难获得环境真实值作为传感器数据校正的参考,盲校准方法可以根据收集到的观测数据对网络中各个传感器的数据进行校正。基于邻近节点间的相关性,Takruri 等^[6]提出了一种分布式递归贝叶斯(DRB)盲校准算法,通过使用邻居节点数据的平均值来预测漂移节点的数据;为了更好地拟合各节点间的时空关联性,Takruri 等^[7]进一步提出了一种结合支持向量回归(SVR)和卡尔曼滤波的传感器校准方法,该方法通过 SVR 模型对测量值进行预测,然后使用卡尔曼滤波器对预测值进行漂移校正。然而,SVR 在训练过程中存在精度较低的问题,Kumar 等^[8]提出使用克里金插值法替换 SVR 作为预测部分的方法。

随着深度学习的发展,在传感器数据漂移校准中应用逐步广泛。Wang 等^[9]提出了神经网络投影-恢复网络(PRNet)方法,将测量值投影至特征空间,使用卷积神经网络恢复无漂移测量值。该方法不依赖特殊假设,但需要集中式数据处理。随后,黄庆东等^[10]提出了一种改进投影-恢复网络(D-PRNet)盲校准算法,该算法采用分布式结构,只需要在各节点内部独立完成校准。Wu 等^[11]提出了一种基于约束极值学

习机和卡尔曼滤波的传感器数据漂移跟踪与校正算法。黄庆东等^[12]提出了一种基于 LSTM-KF 的数据漂移校准算法。武加文等^[13]提出了一种基于遗传算法优化 BP 神经网络结合卡尔曼滤波器的方法。多数研究方法都是通过建立模型得到预测值,然后使用卡尔曼滤波器进行漂移数据校准。最终的校准性能受到模型预测精度的影响,如果精度误差较大,校准效果也是不理想的。因此,提高模型的预测精度对提升校准性能也是首要任务。

该文提出了一种融合 CNN-BiLSTM-Attention 与卡尔曼滤波器的无线传感器网络数据漂移盲校准算法,该算法结合 CNN 的多尺度特征学习和 BiLSTM 的时序分析能力,配合注意力机制强化关键特征识别,得到精度较高的节点预测数据,然后将待校准节点的预测值和测量值输入到卡尔曼滤波器中,通过卡尔曼滤波递归机制实现数据漂移的跟踪和校准。实验结果表明,该算法能够有效地对传感器节点的漂移数据进行校准,具有良好的数据漂移校准性能。

1 相关理论介绍

1.1 卷积神经网络

卷积神经网络(Convolutional Neural Network, CNN)是一种在深度学习领域广泛应用的网络模型架构,主要组成部分包括:输入层、卷积层、池化层以及输出层,其中卷积层和池化层是 CNN 模型的关键部分,卷积层提取数据中的局部特征信息;池化层对所提取的特征进行降维,增强模型的特征学习能力,常用的池化方法包括最大池化和平均池化。

1.2 双向长短期记忆神经网络

长短期记忆神经网络(Long Short-Term Memory, LSTM)是一种特殊的循环神经网络结构,在处理和分析时间序列数据领域广泛应用。LSTM 网络结构如图 1 所示。

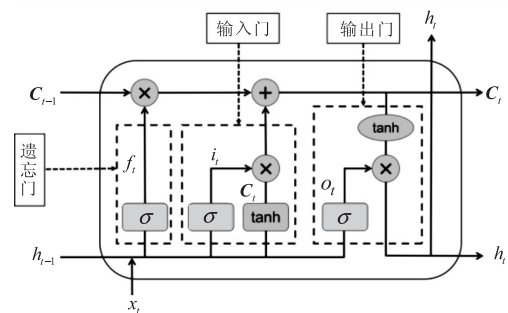


图 1 LSTM 网络结构

LSTM 通过引入输入门、遗忘门和输出门组成的门控单元来解决传统 RNN 存在的长期依赖和梯度消失问题^[14]。这些门控单元允许 LSTM 选择性地记住或忘记信息,并决定哪些信息应该传递给下一个时间

步。其中,遗忘门决定哪一部分信息需要被遗忘,计算过程如公式 1 所示。

$$f_t = \sigma[W_f \cdot (h_{t-1}, x_t) + b_f] \quad (1)$$

式中: σ 为 sigmoid 激活函数; f_t 为遗忘门; W_f 为权重矩阵; b_f 为偏置项。

输入门控制新信息的流入,计算过程如公式 2~4 所示。

$$i_t = \sigma[W_i \cdot (h_{t-1}, x_t) + b_i] \quad (2)$$

$$C_t = \tanh[W_c \cdot (h_{t-1}, x_t) + b_c] \quad (3)$$

$$U_t = i_t \cdot C_t + f_t \cdot C_{t-1} \quad (4)$$

式中: i_t 为输入门; C_t 为状态矩阵; U_t 为细胞状态; W_i 、 W_c 分别为输入门和记忆细胞的权重矩阵; b_i 、 b_c 分别为输入门和记忆细胞的偏置项。

输出门决定下一时刻的输出信息,计算过程如公式 5 和公式 6 所示。

$$o_t = \sigma[W_o \cdot (h_{t-1}, x_t) + b_o] \quad (5)$$

$$h_t = o_t \otimes \tanh(C_t) \quad (6)$$

式中: o_t 为输出门; W_o 为权重矩阵; b_o 为偏置项; h_t 为隐藏层的输出; \tanh 为双曲正切激活函数。

双向长短期记忆神经网络(Bi-directional Long Short-Term Memory, BiLSTM)是 LSTM 网络的优化改进算法。BiLSTM 在结构上包含两个 LSTM 层,分别为正向和反向处理输入序列,在处理复杂的时间序列数据方面展现出了显著的优势。传统的 LSTM 网络只能利用过去的时间序列信息预测下一刻的输出, BiLSTM 可以有效地挖掘过去与未来数据的相关性,提高对历史数据中潜在特征的利用率和模型的预测精度。研究表明 BiLSTM 在时序数据上的预测结果要优于 LSTM^[15]。BiLSTM 网络结构如图 2 所示。

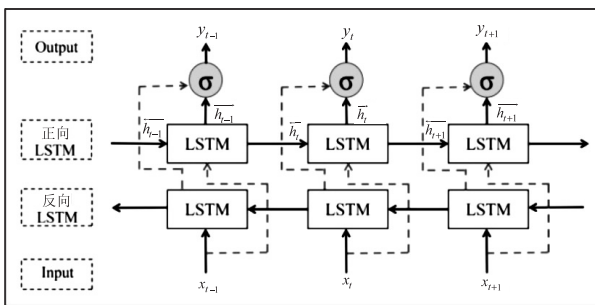


图 2 BiLSTM 网络结构

BiLSTM 计算过程如公式 7~9 所示。

$$\vec{h}_t = \text{LSTM}(x_t, \vec{h}_{t-1}) \quad (7)$$

$$\overleftarrow{h}_t = \text{LSTM}(x_t, \overleftarrow{h}_{t+1}) \quad (8)$$

$$y_t = w \vec{h}_t + \overleftarrow{w} \overleftarrow{h}_t + b_y \quad (9)$$

式中: \vec{h}_t 、 \overleftarrow{h}_t 分别为正向 LSTM 输出和反向 LSTM 输出; w 、 \overleftarrow{w} 分别为正向 LSTM 和反向 LSTM 的权重矩阵; b_y 为偏置项。

1.3 注意力机制

注意力机制(Attention Mechanism)是一种在深度学习中用于增强模型能力的关键技术。其关键在于能够识别输入数据在特定任务中起重要作用的信息,而忽略不太重要的部分^[16],增强模型有效捕获时间序列数据中关键特征和信息的能力。注意力机制网络结构如图 3 所示。




图 3 注意力机制网络结构

该文选用自注意力机制,输入的时间序列数据会与其他所有数据进行比较,以确定每条数据在序列中的相对重要性,计算公式如式 10 所示。

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (10)$$

式中: Q 、 K 、 V 分别为 Query、Key、Value 的向量; $\frac{1}{\sqrt{d_k}}$

为缩放因子; d_k 是 Key 向量的维度。

1.4 卡尔曼滤波器

卡尔曼滤波(Kalman Filter)是一种高效的自回归滤波器,能够在噪声干扰的环境中精确推断动态系统的当前状态,已被广泛应用于信号处理、目标跟踪等领域^[17-19]。卡尔曼滤波器主要通过两个关键步骤进行状态估计:预测和更新。预测是根据系统的动态模型和上一时刻的状态估计,推测出当前时刻的状态;更新是根据观测数据和预测的状态,调整和优化当前状态的估计。

2 基于 CNN-BiLSTM-Attention-KF 校准算法

2.1 基于 CNN-BiLSTM-Attention 的建模过程

在 WSN 环境中,待校准节点与相邻节点的测量数据具有一定的相关性,邻近节点的数据会影响到预测的准确率。为了得到更加准确的预测值作为卡尔曼滤波器的输入,提高校准过程的精度和可靠性,该文使用 CNN-BiLSTM-Attention 模型通过邻居节点与待校准节点的相关性,得到待校准传感器的预测数据,有效弥补待校准节点自身数据存在的缺失或不准确等问题,从而得到更可靠的预测结果。CNN-BiLSTM-Attention 模型网络结构如图 4 所示,模型的层级结构主要分为

输入层、CNN 层、BiLSTM 层、Dropout 层、Attention 层和输出层。




图 4 CNN-BiLSTM-Attention 模型网络结构

对于待校准节点数据的预测，CNN - BiLSTM - Attention 模型主要通过如下步骤实现：

(1)输入层:对邻居节点采集的温度数据进行重采样处理,确保数据在时间轴上的均匀性和连续性。并将处理后数据作为 CNN 层的输入,输入数据的维度为一维。

(2)CNN 层:模型中的 CNN 框架由两个一维卷积层和一个一维最大池化层组成,通过卷积层对输入的数据有效地提取局部特征,并通过池化层操作减少噪声和无关信息的干扰。

(3)BiLSTM 层:将 CNN 层输出的数据传递至 BiLSTM 层,BiLSTM 通过前向和向后双向 LSTM 单元,对数据进行双向时间序列建模,深入挖掘传感器数据时间序列中的长期依赖关系,从过去和未来两个方向全面捕捉数据的动态变化规律。BiLSTM 层的输出包含了过去和未来信息,从而提高对时间序列数据的理解能力。

(4)Dropout 层:引入 Dropout 层以防止模型的过拟合。Dropout 层在训练过程中随机丢弃一部分神经元的输出,使模型在不同的子网络上进行训练,从而提升模型的泛化能力。

(5)Attention 层:通过计算注意力权重,对各个时间步的数据进行加权,使得模型能够更加关注于数据中重要的部分。Attention 机制帮助模型识别出对预测结果影响较大的数据片段,从而提高预测的准确性和鲁棒性。

(6)输出层:输出 Attention 层加权求和的预测结果,然后将测试集输入训练好的模型得到待校准节点的温度数据的预测结果。

2.2 基于卡尔曼滤波的数据漂移校准算法

设定传感器节点 i 在 t 时刻采集的温度测量值为 $T_{i,t}$,真实值为 $R_{i,t}$,平滑漂移值为 $d_{i,t}$ 。 $d_{i,t}$ 代表测量值与真实值之间的偏差,是未知的,因此需要对节点的数据漂移建立数学模型来估计,如公式 11 所示。

$$d_{i,t} = d_{i,t-1} + w_{i,t}, w_{i,t} \sim N(0, Q_{i,t}) \quad (11)$$

式中: $w_{i,t}$ 为服从高斯分布 $N(0, Q_{i,t})$ 的过程噪声, $Q_{i,t}$ 为状态噪声协方差。

公式 11 表示节点数据漂移的状态跟踪方程,跟踪节点漂移值的动态变化。除了状态跟踪方程,还需要建立观测方程,将节点测量值与状态变量联系起来的桥梁,计算预测状态与测量值之间的差异,如公式 12 所示。

$$z_{i,t} = d_{i,t} + v_{i,t}, v_{i,t} \sim N(0, R_{i,t}) \quad (12)$$

式中: $v_{i,t}$ 为服从高斯分布 $N(0, R_{i,t})$ 的观测噪声, $R_{i,t}$ 为观测噪声协方差。

在理想情况下,数据漂移值 $d_{i,t}$ 由节点的测量值减去真实值得到,如公式 13 所示。

$$d_{i,t} = T_{i,t} - R_{i,t} \quad (13)$$

然而在复杂环境中,存在噪声、干扰或其他不确定性因素,真实值无法准确地测量得到,因此需要使用建立模型得到的预测值 $\hat{x}_{i,t}$ 代替 $R_{i,t}$,如公式 14 所示。

$$d_{i,t} = T_{i,t} - \hat{x}_{i,t} \quad (14)$$

式 11 和式 12 组成卡尔曼滤波方程,根据预测值和测量值迭代更新状态估计,实现对目标节点漂移数据的跟踪和校准。

该文通过卡尔曼滤波将传感器的测量值和 CNN-BiLSTM-Attention 模型预测值相结合,通过不断地更新估计值和协方差矩阵,即便是存在测量噪声和系统不确定性的情况下,卡尔曼滤波也能够实时跟踪传感器的数据漂移趋势,准确地估计数据的真实状态,并对测量值进行校正,实现对漂移数据的校准,从而提高传感器数据的准确性和可靠性。算法的校准框架如图 5 所示。

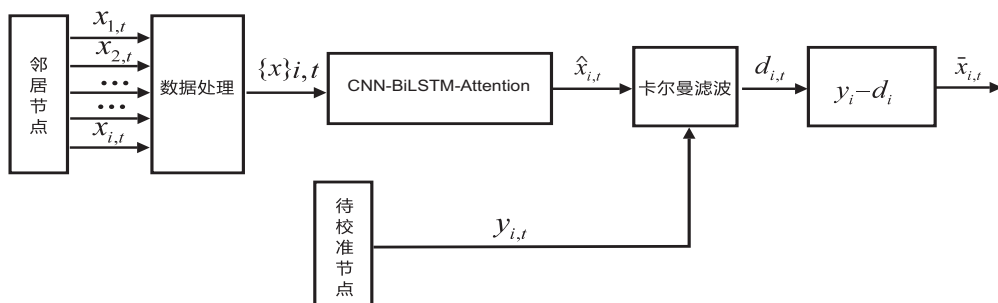


图 5 CNN-BiLSTM-Attention-KF 算法的数据漂移校准框架

3 实验结果及分析

3.1 实验环境

实验的环境配置:操作系统为 CentOS 7.9.2009, 显卡为 NVIDIA GeForce RTX 3080, 深度学习框架为 TensorFlow 2.9.0, 集成开发环境选用 Anaconda。

3.2 数据集

选取 Inter Berkeley 实验室在 2004 年 2 月 28 日至 4 月 5 日部署的 54 个传感器采集的数据, 主要包括空气湿度、温度、光照和电压值数据, IBRL 数据集中 54 个传感器的分布如图 6 所示。




图 6 Inter Berkeley 实验室的节点分布

IBRL 数据集的采样周期为 31 s, 由于数据存在大量的缺失值, 可能会影响后续的分析 and 校准过程, 因此, 在数据预处理阶段对每个节点分别以 5 min 的间隔进行重采样处理, 在漂移数据校准实验中只选用传感器采集的温度数据作为研究对象。

实验选取 ID 为 17、18、19、20、21、22、23 的 7 个节

点作为研究节点, 其中 21 号节点作为待校准节点, 其余节点作为 21 号节点的邻居节点, 实验数据取 2 月 29 日至 3 月 8 日的 9 天的温度数据作为研究所需的数据集。处理后的实验数据如表 1 所示。其中训练集和测试集各占数据集总样本的 50%。

表 1 实验数据样本示例

日期时间	节点 17	节点 18	节点 19	节点 20	节点 21	节点 22	节点 23
2004-02-29 00:00:00	18.685	18.993	18.900	18.319	18.882	18.318	18.918
2004-02-29 00:05:00	18.636	18.965	18.833	18.309	18.839	18.277	18.888
2004-02-29 00:10:00	18.640	18.935	18.800	18.288	18.815	18.253	18.856
2004-02-29 00:15:00	18.611	18.889	18.738	18.249	18.761	18.227	18.829
2004-02-29 00:20:00	18.545	18.851	18.712	18.218	18.713	18.183	18.785
2004-02-29 00:25:00	18.536	18.827	18.685	18.176	18.701	18.157	18.762

3.3 模拟漂移数据

由于实验选用的是公开数据集, 在本实验中的数据均作为无漂移真实数据。为了实现传感器漂移数据的校准, 将待校准节点 21 采集的数据加入高斯噪声和漂移值模拟真实情况下的漂移数据, 生成漂移值结果如图 7 所示。




图 7 生成漂移数据结果

3.4 数据归一化

由于不同传感器采集的数据存在差异, 会影响模

型的稳定性和泛化能力, 因此采用数据归一化处理, 将数据大小归一化在 [0, 1] 之间, 确保不同传感器采集的数据在统一尺度下进行比较和分析, 提高模型的收敛速度。计算过程如公式 15 所示。

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (15)$$

式中: x^* 是归一化后的值, x 是当前值, x_{\max} 和 x_{\min} 分别是数据的最大值和最小值。

3.5 模型结构及实验参数

为了验证 CNN-BiLSTM-Attention 模型的优越性, 将其与 CNN、LSTM、CNN-LSTM、CNN-LSTM-Attention、BiLSTM、CNN-BiLSTM 神经网络模型进行比较, 各模型结构参数如表 2 所示。在模型实验对比中, 为确保对各模型的公平评估, 实验训练时参数统一设置: 学习率为 0.001, batch_size(批量大小)为 32, each_epoch(训练轮次)为 100, 优化算法采用 Adam 算法。为防止实验训练过程出现过拟合现象, 引入了基于

Dropout 的网络正则化方法,并将 Dropout 率设置为 0.2,以防止过拟合的发生。

表 2 网络模型结构参数

网络模型	网络结构参数(括号内为该层神经元数)
CNN	Conv1D(128)-Conv1D(64)-MaxPooling(1)-Dense(1)
LSTM	LSTM(128)-LSTM(64)-Dense(1)
CNN-LSTM	Conv1D(128)-Conv1D(64)-MaxPooling(1)-LSTM(128)-LSTM(64)-Dense(1)
CNN-LSTM-Attention	Conv1D(128)-Conv1D(64)-MaxPooling(1)-LSTM(128)-LSTM(64)-Attention(特征数)-Dense(1)
BiLSTM	BiLSTM(128)-BiLSTM(64)-Dense(1)
CNN-BiLSTM	Conv1D(128)-Conv1D(64)-MaxPooling(1)-BiLSTM(128)-BiLSTM(64)-Dense(1)
CNN-BiLSTM-Attention	Conv1D(128)-Conv1D(64)-MaxPooling(1)-BiLSTM(128)-BiLSTM(64)-Attention(特征数)-Dense(1)

3.6 评价指标

实验选用均方误差(MSE)、平均绝对误差(MAE)和相关系数(R^2)三个指标来衡量校准方法的性能表现,其中 MSE 和 MAE 值越小,说明模型的拟合程度越好; R^2 值越接近于 1,表明模型的精度越高。计算公式如公式 16~18 所示。

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2 \quad (16)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (17)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (18)$$

式中: n 表示训练样本个数; x_i 为第 i 个的真实值; \hat{x}_i 为第 i 个的预测值; \bar{x} 为样本的平均值。

3.7 实验结果分析

3.7.1 消融实验

为了验证文中模型各模块的有效性,表 3 为 CNN-BiLSTM-Attention 算法与各模块结合组成不同算法的预测性能对比结果。

表 3 预测性能对比结果

模型	MSE	MAE	R^2
CNN	0.585 5	0.512 2	0.969 9
LSTM	0.908 7	0.679 0	0.953 4
CNN-LSTM	0.426 6	0.484 5	0.978 1
CNN-LSTM-Attention	0.328 8	0.433 6	0.983 1
BiLSTM	0.627 0	0.601 0	0.967 8
CNN-BiLSTM	0.384 5	0.476 5	0.980 2
CNN-BiLSTM-Attention	0.215 8	0.337 0	0.988 9

从表 3 可以看出,单独使用 CNN、LSTM 算法也可以实现预测效果,但是模型对时序数据特征的捕获能力较差,相比其他算法各项指标表现较差。与 LSTM 相比,BiLSTM 能够同时处理过去和未来的传感器数

据,处理时间序列数据的效果表现更好,将 CNN 与 BiLSTM 结合,可以更好地获取数据的空间特征和时间依赖性,CNN-BiLSTM 的 MSE 与 MAE 比 BiLSTM 分别降低了 0.242 5 和 0.124 5, R^2 提升了 0.012 4。但是在模型拟合程度上还有提升,在此基础上,加入 Attention 增强模型对序列中特定部分的关注,提升预测效果,与 CNN-BiLSTM 相比,CNN-BiLSTM-Attention 的 MSE 降低了 0.168 7,MAE 降低了 0.139 5, R^2 提升了 0.008 7;与 BiLSTM 相比,CNN-BiLSTM-Attention 的 MSE 降低了 0.411 2,MAE 降低了 0.264 0, R^2 提升了 0.021 1;与 LSTM 相比,CNN-BiLSTM-Attention 的 MSE 降低了 0.692 9,MAE 降低了 0.342 0, R^2 提升了 0.035 5。因此,CNN-BiLSTM-Attention 算法的模型拟合程度均优于其他算法。

图 8 表示几种不同算法针对节点 21 得到的预测结果,其中 Real_data 的曲线表示真实值。从图中可以看出,CNN-BiLSTM-Attention 算法的拟合程度更好,得到的预测值更接近于真实值。




图 8 不同算法的预测结果

在使用卡尔曼滤波器进行校准时,其参数观测噪声协方差 R 和状态噪声协方差 Q 决定了滤波器对于观测数据和预测状态的不确定性处理。如果参数设置过高,滤波器将过度依赖预测模型而忽略观测数据,从而引入较大误差;反之,则可能导致滤波器过度依赖观测数据,对噪声过于敏感。因此,在本实验中,利用网格搜索法来调整这两个参数寻找最优解,最终卡尔曼

滤波参数 Q 和 R 分别设置为 0.01 和 5。表 4 是 CNN-BiLSTM-Attention-KF 算法与各模块结合组成不同算法的漂移校准性能对比结果。

表 4 漂移校准性能对比结果

模型	MSE	MAE	R^2
CNN-KF	0.699 6	0.551 4	0.964 1
CNN-LSTM-KF	0.499 8	0.483 4	0.974 3
CNN-LSTM-Attention-KF	0.338 9	0.396 4	0.982 6
BiLSTM-KF	0.600 2	0.526 3	0.969 2
CNN-BiLSTM-KF	0.417 4	0.453 0	0.978 5
CNN-BiLSTM-Attention-KF	0.228 9	0.325 5	0.988 2

从表 4 可以看出,模型预测值的精准度影响卡尔曼滤波的校准效果,CNN-BiLSTM-Attention-KF 算法的校准性能较为突出,与 BiLSTM-KF 相比,CNN-BiLSTM-Attention-KF 的 MSE 降低了 0.371 3,MAE 降低了 0.200 8, R^2 提升了 0.019。实验表明,CNN-BiLSTM-Attention-KF 算法具有较好的漂移数据校准性能。

图 9 表示几种不同算法的校准结果对比,其中 Drifted_data 表示漂移数据。从图中可以看出,节点 21 构建的模拟漂移数据经过 CNN-BiLSTM-Attention-KF 算法进行漂移校准后的值更接近节点的真实值,因此表明 CNN-BiLSTM-Attention-KF 相较其他几种算法校准精度更高。




图 9 不同算法的校准结果

3.7.2 对比实验

为了验证 CNN-BiLSTM-Attention-KF 模型的校准效果,将文中算法与已存在的研究数据漂移校准算法进行对比,并且在文中数据集上进行训练,对节点 21 的漂移数据进行校准。表 5 为不同算法漂移数据校准性能对比结果。

从表 5 可以看出,CNN-BiLSTM-Attention-KF 算法在各评价指标上均优于其他算法,与 LSTM-KF 相比,MSE 降低了 0.848 9,MAE 降低了 0.459 7, R^2 提升了 0.043 6;与 GABP-KF 相比,MSE 降低了 0.300 9,MAE 降低了 0.214 8, R^2 提升了 0.015 4。由此可见,CNN-BiLSTM-Attention-KF 算法在处理数据漂移校准问题时表现出较高的精度,在模型的稳定性和预测能

力方面也具有更好的表现。

表 5 不同漂移校准算法的性能对比结果

模型	MSE	MAE	R^2
SVR-KF ^[7]	1.011 4	0.686 2	0.948 1
PRNet ^[9]	2.826 4	1.119 2	0.855 0
D-PRNet ^[10]	1.927 3	0.917 6	0.901 1
LSTM-KF ^[12]	1.078 8	0.785 2	0.944 6
GABP-KF ^[13]	0.529 8	0.540 3	0.972 8
CNN-BiLSTM-Attention-KF	0.228 9	0.325 5	0.988 2

4 结束语

该文提出一种基于 CNN-BiLSTM-Attention-KF 的 WSN 数据漂移盲校准算法,旨在解决无线传感器网络中数据漂移导致的数据准确性下降问题。与同类预测方法相比,CNN-BiLSTM-Attention 算法在相同的数据集和实验场景下均展现出了较高的预测精度,表现出一定的优越性。在校准阶段,将 CNN-BiLSTM-Attention 模型与卡尔曼滤波器有效融合,显著改善了模型对数据漂移的校准效果。实验结果表明,该融合模型在处理数据漂移问题时,校准误差大幅降低,数据的准确性和可靠性得到了显著提升。

在大规模 WSN 的应用中,传感器可以同时测量多种属性的数据,该文只考虑了单一属性下的漂移校准情况,在未来的研究中,会进一步深入分析不同属性之间的相互关系和影响,构建更全面的数据漂移校准模型,以适应实际应用中复杂多变的环境。

参考文献:

- [1] AMUTHA J, SHARMA S, NAGAR J. WSN strategies based on sensors, deployment, sensing models, coverage and energy efficiency: review, approaches and open issues[J]. Wireless Personal Communications, 2020, 111(2): 1089-1115.
- [2] TAN R, XING G, YUAN Z, et al. System-level calibration for data fusion in wireless sensor networks[J]. ACM Transactions on Sensor Networks, 2013, 9(3): 1-27.
- [3] ZHANG G, WANG T, WANG G, et al. Detection of hidden data attacks combined fog computing and trust evaluation method in sensor-cloud system[J]. Concurrency and Computation: Practice and Experience, 2018, 33(7): 1.
- [4] LEE B T, SON S C, KANG K. A blind calibration scheme exploiting mutual calibration relationships for a dense mobile sensor network[J]. IEEE Sensors Journal, 2014, 14(5): 1518-1526.
- [5] STANKOVIĆ M S, STANKOVIĆ S S, JOHANSSON K H. Asynchronous distributed blind calibration of sensor networks under noisy measurements[J]. IEEE Transactions on Control of Network Systems, 2016, 5(1): 571-582.

- [6] TAKRURI M, ABOURA K, CHALLA S. Distributed re-cursive algorithm for auto calibration in drift aware wireless sensor networks [C]//Innovations and advanced techniques in systems, computing sciences and software engineering. Bridgeport; Springer, 2008: 21-25.
- [7] TAKRURI M, RAJASEGARAR S, CHALLA S, et al. Online drift correction in wireless sensor networks using spatio-temporal modeling [C]//2008 11th international conference on information fusion. Cologne; IEEE, 2008: 1-8.
- [8] KUMAR D, RAJASEGARAR S, PALANISWAMI M. Automatic sensor drift detection and correction using spatial Kriging and Kalman filtering [C]//2013 IEEE international conference on distributed computing in sensor systems. Cambridge; IEEE, 2013: 183-190.
- [9] WANG Y, YANG A, CHEN X, et al. A deep learning approach for blind drift calibration of sensor networks [J]. IEEE Sensors Journal, 2017, 17(13): 4158-4171.
- [10] 黄庆东, 郭民鹏, 石斌宇, 等. 一种分布式 WSN 数据漂移盲校准算法 [J]. 西安邮电大学学报, 2020, 25(3): 14-20.
- [11] WU J, LI G. Drift calibration using constrained extreme learning machine and Kalman filter in clustered wireless sensor networks [J]. IEEE Access, 2019, 8: 13078-13085.
- [12] 黄庆东, 郭民鹏. 基于 LSTM-KF 的无线传感器网络数据漂移盲校准算法 [J]. 计算机应用与软件, 2022, 39(3): 132-138.
- [13] 武加文, 李光辉. 基于 GABP-KF 的 WSN 数据漂移盲校准算法 [J]. 智能系统学报, 2019, 14(2): 254-262.
- [14] AN Q, TAO Z, XU X, et al. A data-driven model for milling tool remaining useful life prediction with convolutional and stacked LSTM network [J]. Measurement, 2020, 154: 107461.
- [15] SIAMI-NAMINI S, TAVAKOLI N, NAMIN A S. The performance of LSTM and BiLSTM in forecasting time series [C]//2019 IEEE international conference on big data (Big Data). Los Angeles; IEEE, 2019: 3285-3292.
- [16] CHAUDHARI S, MITHAL V, POLATKAN G, et al. An attentive survey of attention models [J]. ACM Transactions on Intelligent Systems and Technology, 2021, 12(5): 1-32.
- [17] 韦黔, 陈迪, 林树靖, 等. 基于迭代卡尔曼滤波的传感器数据融合仿真 [J]. 计算机技术与发展, 2017, 27(9): 137-140.
- [18] WANG Y, YANG A, LI Z, et al. Blind drift calibration of sensor networks using signal space projection and Kalman filter [C]//2015 IEEE tenth international conference on intelligent sensors, sensor networks and information processing (ISSNIP). Singapore; IEEE, 2015: 1-6.
- [19] 季露, 陈志, 岳文静. 基于模型融合和特征关联的视频目标跟踪算法 [J]. 计算机技术与发展, 2018, 28(6): 93-96.