

基于 LSTM-KF 的无线传感器网络数据漂移盲校准算法

黄庆东 郭民鹏

(西安邮电大学通信与信息工程学院信息与通信技术国家级实验教学中心 陕西 西安 710121)

摘要 针对无线传感器网络中传感器节点易发生数据漂移而导致采集数据失准难以使用的问题,提出一种基于 LSTM-KF 的无线传感器网络数据漂移盲校准算法。根据传感器网络拓扑情况建立连通支配集,以增强传感器节点间的时空相关性;训练 LSTM 网络,对目标节点与周围节点的测量数据建模;使用卡尔曼滤波器追踪和校准测量数据中的漂移量。仿真结果表明,该算法能够适应不同的拓扑情况,且具有较高的数据漂移盲校准精度,提高了无线传感器网络的数据采集质量。

关键词 无线传感器网络 盲校准 数据漂移 LSTM 神经网络 卡尔曼滤波器

中图分类号 TP3 TN929.5

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2022.03.022

BLIND CALIBRATION ALGORITHM BASED ON LSTM-KF FOR WIRELESS SENSOR NETWORKS

Huang Qingdong Guo Minpeng

(Information and Communications Technology of National Experimental Teaching Center, School of Communication and Information Engineering, Xi'an University of Posts and Telecommunications, Xi'an 710121, Shanxi, China)

Abstract Aiming at the problem that data collection by the sensor in WSN is easily drifted, which leads to data misalignment and difficult to use, a wireless sensor network data drift blind calibration method based on LSTM-KF is proposed. A connect dominating set was constructed according to the topology of sensor network to enhance spatiotemporal correlations between sensor nodes; LSTM neural network was trained to model measurement data of target node and surrounding node; the data drift of the measurement data was tracked and calibrated by a Kalman filter. The simulation results show that the proposed algorithm can adapt to different topological situations, and has superior data drift blind calibration precision. It improves the quality of data collection by wireless sensor network.

Keywords Wireless sensor network Blind calibration Data drift LSTM neural network Kalman filter

0 引言

无线传感器网络(Wireless sensor networks, WSN)通过在环境中布置大量具有无线通信能力的传感器节点,并使这些节点协同有序的工作,能够监测和处理环境中各种的目标信息^[1]。受限于传感器节点自身硬件的影响,长期使用后读数会发生数据漂移现象,造成数据失准无法使用的后果。然而,无线传感器网络越发现规模庞大且部署在复杂环境中,手动校准发生数据漂移的传感器难度很大。因此,需要一种在环境真实信

息未知的情况下校准传感器节点读数的方法,该方法称为盲校准^[2]。

通常,盲校准方法以节点密集部署或监测相同目标为前提^[3],当网络中传感器节点未产生数据漂移时,节点间应具有相关的读数^[4]。然而,受限于实际应用中的环境和成本限制,密集部署的条件往往难以满足。文献[2]提出了一种基于子空间投影的非密集部署盲校准方法,在满足一定先验条件的情况下,假设实际信号存在于测量信号的低维子空间中,利用信号的子空间投影将校准任务转化为求解齐次线性方程组。文献[5-6]利用子空间投影的思想,分别结合稀疏贝叶斯

和卡尔曼滤波方法对传感器数据进行盲校准。文献[7]结合深度学习思想,对子空间投影方法进一步拓展,提出了一种投影恢复网络结构,在数据漂移盲校准任务中取得了良好的效果。文献[8]提出了一种移动节点的数据漂移校准方法,通过设定一组人工校准节点与其他待校准节点交互,达到对节点校准的目的。

基于相邻传感器节点采集的测量信号具有相关性的假设,能够利用邻近节点测量值对目标节点测量值进行预测^[9]。预测数据为校准传感器测量信号中的数据漂移提供依据。文献[10]采用基于克里金插值方法对目标节点值预测,然后通过卡尔曼滤波器获取数据漂移的估计。文献[9]提出了一种支持向量回归(Support Vector Regression, SVR)结合卡尔曼滤波器(Kalman filter, KF)的方法,首先训练 SVR 模型对相邻节点和目标节点测量值建模,然后通过 KF 数据漂移进行追踪。文献[11]使用遗传算法优化的 BP 神经网络代替 SVR 建立预测模型,并使用 KF 追踪测量信号中的数据漂移。上述方法都基于节点间的时空相关性来预测目标节点的测量值,预测准确性直接影响了校准精度。然而,上述预测模型没有参考测量信号的时序相关性,并且在邻居节点较少时,预测准确性较差,从而导致数据漂移校准精度降低。文献[12]提出了一种长短时记忆(Long Short-Term Memory, LSTM)神经网络,越来越多的学者使用 LSTM 网络处理序列信息相关的任务^[13-14],产生了不俗的效果。

基于以上分析,本文提出了一种基于 LSTM 神经网络与卡尔曼滤波器相结合的无线传感器网络数据漂移盲校准算法。算法首先根据网络中传感器节点拓扑情况建立连通支配集,构建模拟骨干网络;然后获取邻近节点数据并使用 LSTM 神经网络对目标节点测量数据建模,预测目标节点的测量数据;最后将 LSTM 神经网络对目标节点的预测值和传感器节点的测量值输入到卡尔曼滤波器中,通过卡尔曼滤波器对数据漂移追踪。仿真结果表明,本文算法能够有效地对无线传感器网络中各个节点进行盲校准,且具有良好的数据漂移盲校准性能。

1 基础理论

1.1 漂移模型

在一个无线传感器网络测量环境中,传感器的测量信号一般会受到漂移和噪声的影响。通常,漂移由非理想环境因素和传感器硬件误差造成^[15],是一个长期且平滑的过程,并且漂移值会跟随时间推移而积累,

而测量噪声却不会随时间积累。传感器测量信号可以表示为:

$$Y = X + D + V \quad (1)$$

式中: Y 表示测量信号值; X 表示为传感器的实际信号值; D 表示为漂移值; V 表示为测量噪声。理想情况下, Y 等于 X 。而在实际环境中往往存在由传感器自身原因产生的数据漂移 D 以及测量过程产生的测量噪声 V 。一般节点在部署前都已经经过校准,因此可以设定一个合理的假设,即节点在初始部署的一段时间内所采集的数据没有发生数据漂移,这些数据可以作为实际信号值使用。

1.2 连通支配集

无线传感器网络通过构建连通支配集的方法,形成虚拟骨干网络,以此达到提高节点信息交互效率、降低网络能耗等^[16-17]。连通支配集能够从网络的节点中构造出一个网络子集,如果一个节点不属于子集,那么必然是子集的邻居节点。可以用无向图 $G = (V, E)$ 表示一个无线传感器网络,其中 V 表示网络中所有节点的集合, E 表示网络中所有边的集合,每条边都表示两个节点互相在对方的通信范围内。假设图 $G = (V, E)$ 中存在非空节点子集 D ,对于任意 $u \in V - D$, D 中都有且至少有一个节点 v 与 u 存在一条边 $e \in E$,则非空节点子集 D 为图 G 的一个支配集。如果由 D 导出的子图是连通图,那么称 D 为连通支配集。

1.3 卡尔曼滤波器

卡尔曼滤波是一种通过建立状态方程来描述动态系统,采用预测加修正的形式,以线性最小方差估计为准则的最优估计理论。它能够将过去时刻的测量误差合并到新的测量误差中,并以此估计将来时刻的误差。卡尔曼滤波能够处理时变信号、非平稳信号等,且具有运算量小、存储量小、简单易行和自适应性等优势^[18]。依赖于这些优势,卡尔曼滤波已经在很多工程实践领域中广泛应用^[19]。

2 LSTM-KF 算法

在无线传感器网络测量环境中,目标节点的测量值读数与其邻居节点的测量值读数具有一定的相关性,因此邻居节点提供的测量值读数质量会影响对目标节点读数预测的准确率。同时,节点测量读数为时序信号,建立能够处理时间序列信号的预测模型,能够有效提高目标节点测量值的预测准确率。基于以上考虑,提出了一种基于 LSTM-KF 的无线传感器网络数据漂移盲校准算法。算法的具体框图如图 1 所示。




图1 算法校准框架

2.1 构建连通支配集

目标节点的预测需要使用邻居节点的测量信息，周围邻居节点提供的测量数据直接影响预测数据的准确性。一般在实际环境中传感器的部署位置是随机的，目标节点使用周围邻居节点信息对自身数据进行预测时，会出现因邻居节点较少而导致预测精度降低的情况，因此对网络建立支配集的预处理方法，能够保障节点的预测准确率。本文使用文献[20]中的方法生成连通支配集，网络通过支配集选出支配节点连接网络中全部节点，使邻居较少的节点能够获取距离较近的非邻居节点的数据，提高对自身读数的预测准确率，进而提升盲校准算法校准精度。

2.2 LSTM 神经网络模型

LSTM 神经网络模型是基于 RNN 神经网络模型的一种变体，其单元结构如图 2 所示。训练参数时，RNN 模型容易出现由权重较大或较小而导致的梯度消失和梯度爆炸问题，并且由于自身结构的限制，RNN 模型长期记忆能力较弱。LSTM 模型对 RNN 模型进行改进，设置遗忘门、输入门和输出门这三个门结构。相较于传统的 RNN 模型，LSTM 模型克服了 RNN 模型中存在的这些问题^[21]。

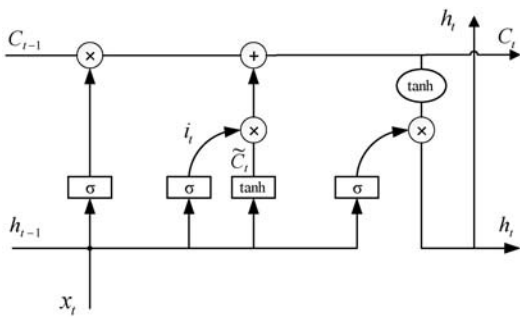


图2 LSTM 模型单元结构图

LSTM 模型单元结构中三种门结构的状态更新过程如下：

$$f_t = \sigma(W_{xf} \cdot x_t + W_{hf} \cdot h_{t-1} + W_{cf} \cdot C_{t-1} + b_f) \quad (2)$$

式中： f_t 表示遗忘门； σ 表示 sigmoid 激活函数； x_t 表示 t 时刻的输入； h_{t-1} 表示 $t-1$ 时刻的 LSTM 单元输出； C_{t-1} 表示 $t-1$ 时刻的状态值； W_{xf} 、 W_{hf} 和 W_{cf} 为权重系数； b_f 表示偏置项。遗忘门表示对之前状态的保留或舍弃。

$$i_t = \sigma(W_{xi} \cdot x_t + W_{hi} \cdot h_{t-1} + W_{ci} \cdot C_{t-1} + b_i) \quad (3)$$

式中： i_t 表示输入门； W_{xi} 、 W_{hi} 和 W_{ci} 为权重系数； b_i 表示输入门的偏置项。输入门决定将哪些值进行更新。

$$\tilde{C}_t = \tanh(W_{xc} \cdot x_t + W_{hc} \cdot h_{t-1} + b_c) \quad (4)$$

式中： \tilde{C}_t 表示新产生的候选状态向量； \tanh 为双曲正切激活函数； W_{xc} 和 W_{hc} 为权重系数； b_c 表示状态向量的偏置项。能够计算 t 时刻输入信息所产生的状态值。

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (5)$$

式中： C_t 表示状态量。旧状态值与遗忘门相乘表示丢弃旧状态中不需要的内容，候选状态值与输入门相乘表示将需要记忆的内容添加至状态中，将两部分相加就产生了更新的单元状态值。

$$o_t = \sigma(W_{xo} \cdot x_t + W_{ho} \cdot h_{t-1} + W_{co} \cdot C_t + b_o) \quad (6)$$

式中： o_t 表示输出门； W_{xo} 、 W_{ho} 和 W_{co} 表示权重系数； b_o 表示输出门的偏置项。输出门将基于自身输入和上一时刻输出决定输出值。

$$h_t = o_t \cdot \tanh(C_t) \quad (7)$$

式中： h_t 表示单元输出。单元输出由状态值和输出门的输出共同决定。

使用 LSTM 模型的单元结构，能够改善 RNN 模型中出现的长期记忆依赖问题，并且可以解决梯度爆炸或梯度消失问题。因此，LSTM 模型十分擅长解决时间序列问题和任务，与 RNN 相比有更好的优越性。在无线传感器网络数据漂移盲校准任务中，测量信号同时具有时间相关性和空间相关性。时间相关性是指当前时刻的测量数据与之前时刻的测量数据存在关联，空间相关性是指目标节点和邻居节点的测量数据存在关联。使用 LSTM 结构对目标节点测量信号建模，能够同时处理时间和空间相关性，因此能够更好地预测节点的数据。

2.3 基于 KF 的迭代数据漂移校准

为了使用卡尔曼滤波器追踪数据漂移值，首先假设漂移值是平滑的，然后对节点的数据漂移建立平滑的数学模型。设置传感器节点 i 在 k 时刻的测量信号值为 $r_{i,k}$ ，地面真实信号值为 $T_{i,k}$ ，平滑的数据漂移值为 $d_{i,k}$ 。各节点收集邻居节点的值并计算节点自身的校准值 $\hat{x}_{i,k}$ 。根据漂移的平滑特性对漂移值进行数据建模，其数学模型如下式所示：

$$d_{i,k} = d_{i,k-1} + v_{i,k} \quad v_{i,k} \sim N(0, Q_k) \quad (8)$$

式中： $v_{i,k}$ 为服从高斯分布的随机变量， Q_k 为状态噪声协方差。式(8)是节点数据漂移的跟踪方程，节点的漂移值是目标，目的是跟踪漂移的幅度随时间的推移，用来描述漂移值随时间变化的动态过程。

在理想环境中，数据漂移值 $d_{i,k}$ 可以由测量信号值减地面真实信号值得到，即：

$$d_{i,k} = r_{i,k} - T_{i,k} \quad (9)$$

实际环境中,地面真实信号值 $T_{i,k}$ 无法测量得到,假设传感器节点发生漂移后会被马上校准,即传感器不会同时开始漂移,因此在某一时刻,最多有一个传感器可能存在未知漂移,此时能够使用估计的校准值 $\hat{x}_{i,k}$ 代替 $T_{i,k}$,即:

$$z_{i,k} = r_{i,k} - \hat{x}_{i,k} \quad (10)$$

通常,测量信号会有含有噪声,因此观测方程表示为:

$$z_{i,k} = d_{i,k} + w_{i,k} \quad w_{i,k} \sim N(0, R_k) \quad (11)$$

式中: $w_{i,k}$ 表示高斯噪声; R_k 表示观测噪声协方差。式(8)和式(11)组成了卡尔曼滤波跟踪方程,能够利用卡尔曼滤波方法对节点漂移值进行跟踪。

3 实验仿真

3.1 数据集

3.1.1 真实数据集

为了验证校准算法的效果,选取了真实数据集作为一组实验证明效果。选用 Intel Berkeley 实验室在 2004 年 2 月 28 日至 4 月 5 日部署的 54 个传感器收集的数据作为真实信号数据值,由于无法得知采集的准确性情况,因此在本实验中将数据集所提供的数据作为无漂移真实数据使用。数据集中 54 个传感器的分布情况如图 3 所示。




图3 Intel Berkeley 实验室传感器分布情况

在此数据集中传感器节点部署位置是人为设置的,节点分布相对均匀,因此不会产生某些节点邻居较少的情况。且节点具体位置参数无法得到,因此在使用 Berkeley 数据集的实验中不再通过支配集选取节点,而是合理地选取部分邻近节点作为待测节点的邻居节点。

选取 ID 为 17、18、19、20、21、22、23 的 7 个节点,其中 21 号节点作为待校准节点,其余 6 个节点作为邻居节点 21 号节点的邻居节点。选取 2 月 28 日至 3 月 8 日的温度数据作为数据集的全部数据。数据集的测量周期为 31 s,但是数据集中存在大量缺失数据,为了

降低缺失数据的影响,因此数据预处理过程将采样间隔调整为 5 min。

3.1.2 模拟数据集

虽然有很多公共数据集提供了传感器的测量数据,但无法确定测量数据中是否包含了漂移量,并且人为固定拓扑情况无法对许多实际环境的分布进行模拟,所以仅使用这些实验室测量数据集无法全面地验证和说明算法校准性能。本文为了更加全面地验证 LSTM-KF 算法的实用性和校准性能,创建了一个传感器和信号源随机放置的随机拓扑环境来生成模拟数据集以仿真实际环境,并使用此模拟数据集进一步验证校准效果。

模拟数据集的创建方法为:在一个半径为 1 的圆形区域内,随机布置了 20 个传感器和 5 个信号源。传感器接收到的无漂数据由区域内所有信号源加权产生,公式表示为:

$$x_{i,t} = \sum_{j=1}^r a_{i,j} s_{j,t} \quad (12)$$

式中: r 表示信号源个数; $s_{j,t}$ 表示信号源 j 在 t 时刻的值; $a_{i,j}$ 表示传感器 i 和信号源 j 之间的权系数。权系数与距离有关表示为:

$$a_{i,j} = (\Delta_{i,j} + 1)^{-1.5} \quad (13)$$

式中: $\Delta_{i,j}$ 表示节点 i 和信号源 j 之间的距离。信号源通过 ARMA 低通滤波器产生,并对各信号源均增加了一个随机的信号,以模拟真实环境中信号源之间的差异性^[22]。图 4 显示了模拟数据集中部分传感器节点的测量数据。




图4 模拟数据集部分传感器节点测量数据

3.2 预测效果对比实验

为了验证邻居节点数目对目标节点预测结果的影响,使用真实数据集进行一组实验说明。当节点只选取通信范围内的节点作为邻居节点时,会出现某些节点只有少量的邻居节点,从而影响 LSTM 的预测精度。通过构建连通支配集,使目标节点获取除邻居节点外的部分非邻居节点数据,从而获得更多的数据来提升

自身预测效果。由于伯克利实验室传感器部署位置固定且传感器属性未知,因此选取伯克利数据集中 21 号节点为目标节点,并假设节点通信范围内的邻居只有 19 号节点,使用邻居节点训练 LSTM 网络并预测目标节点读数。对比的使用多个距离目标节点较近且不限于通信范围的邻近节点训练 LSTM 网络,然后预测目标节点的读数。图 5 显示了两种方案对目标节点读数预测的效果对比。




图5 目标节点读数预测效果对比

通过图 5 能够看出,多邻近节点对目标节点读数的预测明显有更高的拟合程度。选用均方误差 (Mean Squared Error, MSE) 作为模型预测准确性的判断依据, MSE 表示为:

$$MSE = \frac{1}{m} \sum_{k=1}^m (x_{i,k} - \hat{x}_{i,k})^2 \quad (14)$$

式中: m 表示预测样本个数; $\hat{x}_{i,k}$ 表示校准后数据, MSE 体现了预测结果的准确性。通过式 (14) 计算可得单邻居节点预测和多邻居节点预测与真实信号之间的 MSE 分别为: 9.33 和 0.84, 这表明对节点预测的准确率依赖于邻近节点提供的测量数据, 当邻居节点数据较少时, 目标节点的预测值准确率较低。因此可以对网络构建连通支配集, 邻居较少的目标节点通过连通支配集获取其他距离较近的非邻居节点数据, 从而提高对自身读数的预测准确率, 最终提升盲校准算法的校准效果。通过对比实验结果表明, 相较于距离较近而数量较少的邻居节点数据, 使用通过连通支配集提供的多个邻近节点的数据能够有效提高目标节点的预测准确率。

3.3 校准精度实验

3.3.1 真实数据集数据校准效果

为了比较 LSTM-KF 算法与现有算法的校准性能, 使用真实数据集测试 LSTM-KF 算法和部分现有算法校准效果。图 6 展示了 LSTM-KF 算法与现有算法的校准效果的对比图。

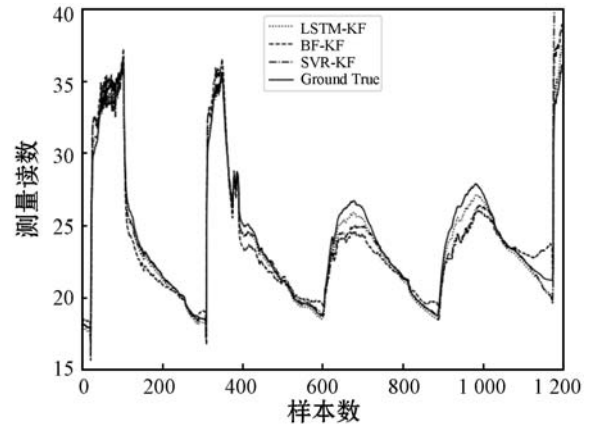


图6 LSTM-KF、SVR-KF、BP-KF 和真实数据对比图

图 6 为当卡尔曼滤波器参数 Q_k 和 R_k 分别设置为 0.1 和 0.01 时, LSTM-KF、BP-KF 和 SVR-KF 几种算法的校准效果对比图, 从图中可以直观地看出, LSTM-KF 曲线更接近目标节点真实读数, 因此表明 LSTM-KF 相较于其他几种算法校准精度更高。同时, 通过分析几种算法的平均绝对误差 (Mean Absolute Error, MAE) 可以更好地比较几种算法的效果, MAE 体现了校准后数据和真实数据之间差值的大小, 其中 MAE 的计算可由下式表示:

$$MAE = \frac{1}{m} \sum_{k=1}^m |x_{i,k} - \hat{x}_{i,k}| \quad (15)$$

通过计算可得在真实数据集上 LSTM-KF、BP-KF 和 SVR-KF 的 MAE 分别为: 0.41、0.92、0.68, 在相同实验环境下, 经过 LSTM-KF 所输出的校准后数据与真实值之间的误差, 相较于 BP-KF 和 SVR-KF 分别降低了 55.4% 和 39.7%。实验结果表明, LSTM-KF 算法相较于其他现有算法, 对目标节点真实数据的预测有更高准确率, 同时也表明了 LSTM-KF 算法具有更好的数据漂移盲校准效果。

3.3.2 模拟数据校准效果

为了更好地验证和说明 LSTM-KF 算法的校准效果, 下面使用模拟数据集对 LSTM-KF 校准效果进行验证。网络的拓扑情况如图 7 所示。




图7 随机场无线传感器网络拓扑情况

图7显示了本文仿真设置的随机场的传感器节点和信号源分布情况。其中三角为支配集算法选择出的支配节点,五角星为信号源位置。通过图7可以看出,连通支配集结构能够帮助邻居节点较少的节点获取更多的邻近节点数据。在此选取节点7为待校准目标节点,通过连通支配集结构能够将1、3、5、8、10号节点作为邻近节点而对自身预测。

图8显示了节点7的测量数据经过 LSTM-KF 算法后的校准结果与节点真实信号和测量信号的对比情况。从图中可以直观地看出,测量值相较于真实值发生了漂移,经过 LSTM-KF 算法校准后,得到的校准后数据与真实信号值基本一致。通过使用随机拓扑的模拟数据集对算法盲校准效果验证,表明了通过基于连通支配集的 LSTM-KF 算法能够适应不同的拓扑环境,并保持较高的数据漂移盲校准准确率。




图8 模拟数据集节点7的预测与实际信号对比

3.4 校准稳定性实验

目标节点数据漂移的校准需要参考周围邻居节点测量信号,为了测试邻居节点数据不准确对目标节点校准效果的影响,使用真实数据集对校准效果进行实验。随机地从邻居节点中选取多个节点作为出现数据不准确的节点,经过10次重复实验并取平均的实验结果如图9所示。




图9 邻居节点失准时目标节点 MAE 变化

图9显示了当多个邻居节点出现数据不准确时,目标节点校准数据与真实信号之间的 MAE 值。其中,未校准信号与真实信号之间的 MAE 为 1.65,当出现 1 个、2 个、3 个和 4 个邻居节点产生不准确数据时,目标节点校准信号与真实信号之间的 MAE 分别为 0.644、0.747、0.878 和 1.064。实验结果表明,目标节点的校准性能随着失准邻居节点个数的增加而出现了一定程度的降低,但相较于未校准信号,MAE 值仍然分别降低了 60.9%、54.7%、46.8% 和 35.6%。综上所述,在邻居节点数据能够保证较为准确或已经过校准的情况下,LSTM-KF 算法有较高的校准性能,当多个邻居节点出现数据失准时,LSTM-KF 算法校准性能略有降低,但依然能够有效地标准测量信号。

4 结语

本文针对无线传感器网络容易出现数据漂移的问题,提出了一种基于 LSTM-KF 的数据漂移盲校准算法。算法根据无线传感器网络拓扑情况构建连通支配集,确保目标节点获取足够多邻近节点数据,从而适应不同无线传感器网络拓扑环境,保证目标节点读数有较高的预测准确率。结合无线传感器网络的时间相关性与空间相关性,利用 LSTM 神经网络模型对信号的时间相关性与空间相关性建模并训练参数,使数据漂移盲校准方法准确率更高。对真实数据集和模拟数据集的仿真实验证明,与现有同类型算法相比,本文提出的基于连通支配集的 LSTM-KF 数据漂移盲校准算法能够很好地适应不同拓扑环境,并且具有更高的校准精度。

参考文献

- [1] Kassim M R M, Harun A N. Applications of WSN in agricultural environment monitoring systems[C]//2016 International Conference on Information and Communication Technology Convergence (ICTC). IEEE, 2016:344-349.
- [2] Balzano L, Nowak R. Blind calibration of sensor networks [C]//International Conference on Information Processing in Sensor Networks. ACM, 2007:79-88.
- [3] Takruri M, Challa S. Drift aware wireless sensor networks [C]//2007 10th International Conference on Information Fusion. IEEE, 2007.
- [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] Wang Y, Yang A, Li Z, et al. Blind drift calibration of sensor networks using sparse Bayesian learning[J]. *IEEE Sensors Journal*, 2016, 16(16):6249–6260.
- [6] Wang Y, Yang A, Li Z, et al. Blind drift calibration of sensor networks using signal space projection and Kalman filter [C]//*IEEE Tenth International Conference on Intelligent Sensors*. IEEE, 2015:1–6.
- [7] 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.
- [8] Miluzzo E, Lane N D, Campbell A T, et al. CaliBree: A self-calibration system for mobile sensor network[C]//*IEEE International Conference on Distributed Computing in Sensor Systems*. Springer, 2008:314–331.
- [9] Takruri M, Rajasegarar S, Challa S, et al. Online drift correction in wireless sensor networks using spatio-temporal modeling[C]//*Proceedings of 2008 11th International Conference on Information Fusion*. IEEE, 2008.
- [10] Kumar D, Rajasegarar S, Palaniswami M. Automatic sensor drift detection and correction using spatial Kriging and Kalman filtering [C]//*Proceedings of 2013 IEEE International Conference on Distributed Computing in Sensor Systems*. IEEE, 2013:183–190.
- [11] 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.
- [12] Hochreiter S, Schmidhuber J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8):1735–1780.
- [13] 王鑫,吴际,刘超,等. 基于 LSTM 循环神经网络的故障时间序列预测[J]. *北京航空航天大学学报*, 2018, 44(4):772–784.
- [14] Kumar S D, Subha D. Prediction of depression from EEG signal using long short term memory(LSTM) [C]//*2019 3rd International Conference on Trends in Electronics and Informatics(ICOEI)*. IEEE, 2019:1248–1253.
- [15] Ni K, Ramanathan N, Chehade M N H, et al. Sensor network data fault types[J]. *ACM Transactions on Sensor Networks*, 2009, 5(3):1–29.
- [16] Shi T, Shi X, Fang X. A virtual backbone construction algorithm based on connected dominating set in wireless sensor networks[C]//*2014 International Conference on Computer, Communications and Information Technology (CCIT 2014)*. Atlantis Press, 2014.
- [17] Mohanty J P, Mandal C, Reade C. Distributed construction of minimum connected dominating set in wireless sensor network using two-hop information [J]. *Computer Networks*, 2017, 123:137–152.
- [18] 杨丹. 卡尔曼滤波器设计及其应用研究[D]. 湖南:湘潭大学, 2014.
- [19] 权义萍,金鑫,张蕾,等. 基于 Mean-Shift 的卡尔曼粒子滤波车辆跟踪算法研究[J]. *计算机应用与软件*, 2014, 31(9):236–239.
- [20] Wu J, Li H L. A dominating-set-based routing scheme in ad hoc wireless networks [J]. *Telecommunication Systems*, 2001, 18(1/3):13–36.
- [21] 孙瑞奇. 基于 LSTM 神经网络的美股股指价格趋势预测模型的研究[D]. 北京:首都经济贸易大学, 2016.
- [22] Cryer J D, Chan K S. Time series analysis: With applications in R[M]. 2nd ed. Berlin:Springer, 2010.
- ~~~~~
- (上接第 126 页)
- [3] Shahab M B, Irfan M, Kader M F, et al. User pairing schemes for capacity maximization in non-orthogonal multiple access systems [J]. *Wireless Communications and Mobile Computing*, 2016, 16(17):2884–2894.
- [4] Sun Q, Han S, Chin L I, et al. On the ergodic capacity of MIMO NOMA systems[J]. *IEEE Wireless Communications Letter*, 2015, 4(4):405–408.
- [5] Choi J. Power allocation for max-sum rate and max-min rate proportional fairness in NOMA [J]. *IEEE Communications Letters*, 2016, 20(10):2055–2058.
- [6] Celik A, Radaideh R M, Al-Qahtani F S, et al. Resource allocation and cluster formation for imperfect NOMA in DL/UL decoupled HetNets [C]//*IEEE Globecom Workshops (GC Wkshps)*, 2017:1–6.
- [7] Ding Z G, Fan P Z, Poor H V. Impact of user pairing on 5G non-orthogonal multiple-access downlink transmissions[J]. *IEEE Transactions on Vehicular Technology*, 2016, 65(8):6010–6023.
- [8] Wang C L, Chen J Y. Power allocation for a downlink non-orthogonal multiple access system [J]. *IEEE Wireless Communications Letters*, 2016, 5(5):532–535.
- [9] Liu F, Onen P M, Petrova M. Proportional fairness-based power allocation and user set selection for downlink NOMA systems [C]//*IEEE ICC 2016-Mobile and Wireless Networking Symposium*, 2016:1–6.
- [10] Yang Z, Ding A G, Fan P Z. A general power allocation scheme to guarantee quality of service in downlink and uplink NOMA systems[J]. *IEEE Transactions on Wireless Communications*, 2016, 15(11):7244–7257.
- [11] Fang F, Zhang H J, Cheng J L, et al. Energy-efficient resource allocation for downlink non-orthogonal multiple access network [J]. *IEEE Transactions on Communications*, 2016, 64(9):3722–3732.