

基于强化学习的大规模无线传感器数据语义关联聚合方法

杨正权¹
YANG Zhengquan

摘要

无线传感器网络通常部署在复杂多变的环境中, 而现有方法难以适应动态化的环境, 导致数据聚合效果不佳, 因此, 为提高大规模无线传感器数据聚合处理的效果, 提出基于强化学习的大规模无线传感器数据语义关联聚合方法。利用卷积神经网络来提取无线传感器数据语义, 将这些原始数据转换为可理解的信息, 更好地揭示数据之间的内在联系, 为后续聚合提供支撑。基于数据语义间的相似度, 对无线传感器数据语义进行关联聚合。为适应环境变化, 提高数据聚合效果, 将关联聚合结果作为输入, 通过强化学习对聚合结果进行优化调整, 进一步提高大规模无线传感器数据语义关联聚合效果。实验结果表明, 所设计的方法在实际应用中无线传感器通信网络吞吐量达到 630 bit/s, 数据丢失量趋近于 0, 聚合效果更好。

关键词

强化学习; 无线传感器网络; 数据语义关联; 数据聚合

doi: 10.3969/j.issn.1672-9528.2024.10.028

0 引言

无线传感器网络作为物联网 (IoT) 核心构成要素, 成为科研界与工业界竞相探索的热点。传感器节点通过先进的无线通信技术相互连接, 形成了一个灵活、可扩展且自组织的网络体系, 它们能够协同工作, 对收集到的海量数据进行预处理、融合与分析, 从而提炼出对应用场景具有深刻洞察力的信息, 为物联网提供丰富的数据来源, 所以无线传感器网络每天都会产生大量的数据。通过将所有数据发送到中心节点进行集中处理, 实现数据的聚合和分析。由于需要将所有数据发送到中心节点, 占用了大量的通信资源和网络带宽。而数据聚合技术作为一种高效的数据处理方式, 其核心功能在于对散布于各传感器节点的原始信息进行集中汇总与智能统计。这一过程不仅显著减少了数据集中的冗余部分, 还极大地优化了数据传输流程, 使得信息在网络中的流通更为迅速与高效。同时, 通过减少不必要的数据传输量, 数据聚合技术有效提升了网络资源的整体利用率, 为网络能耗的降低与网络寿命的延长奠定了坚实的基础。由此, 在上述背景下, 有研究学者针对数据聚合技术展开了研究。

文献 [1] 利用双层区块链架构, 对电动汽车充电隐私数

据进行处理, 根据隐私数据的特性, 设计隐私保护策略, 并建立相应的充电数据上传机制, 利用加密技术对其进行加密处理, 利用数据聚合算法对数据进行解密和聚合, 由此实现对隐私数据的聚合处理, 但该方法的聚合效果较差。文献 [2] 在区块链技术的作用下, 采用分布式网络结构对物联网隐私数据进行存储和传输, 通过定义隐私保护策略对隐私数据进行保护, 由此建立对应的数据传输机制, 将数据存储在多个数据节点上, 从而实现对隐私数据的聚合处理, 但该方法的聚合成本较高。文献 [3] 需要先根据无线传感器网络的特性, 确定数据安全聚合的目标, 由此构建对应的安全聚合模型, 并设计对应的安全聚合协议, 利用数据加密技术对数据进行加密和解密, 提高数据聚合处理的效果, 但该方法的聚合时间过长。

在以往研究的基础上, 本文提出基于强化学习的大规模无线传感器数据语义关联聚合方法。

1 大规模无线传感器数据语义关联聚合方法设计

1.1 无线传感器数据语义提取

无线传感器网络产生的数据通常是原始的、未经处理的, 可直接从传感器获取。语义提取的目的是将这些原始数据转换为可理解的信息, 以将低层次的数据抽象为高层次的信息, 从而简化数据处理的复杂性。由此, 通过语义提取结果, 可对不同传感器的数据进行相互关联, 揭示数据之间的内在联系, 为后续聚合提供支撑。

1. 江苏省金湖中等专业学校 江苏淮安 211600

[基金项目] 第五期江苏省职业教育教学改革研究立项课题“以赛促学视角下中职《网络综合布线》课程教学改革实践研究”(课题编号: ZYB530 主持人: 傅明娣 杨正权)

卷积神经网络 (convolutional neural network, CNN) 通过深度学习机制, 可实现对这类数据的高效特征提取与模式识别。在无线传感器数据语义提取的背景下, CNN 可以用于从传感器数据中提取特征, 并识别数据中的模式和结构^[4-7]。以下是使用 CNN 实现无线传感器数据语义提取的具体实现步骤。

首先, 运用卷积层来捕捉数据中的局部特征。这一过程通过让滤波器 (或称卷积核) 在输入数据上滑动并执行卷积操作来实现, 生成一系列的特征映射, 揭示无线传感器数据中蕴含的语义特征。具体公式为:

$$Y[i, j] = \sum_{i=1}^m \sum_{j=1}^n X[i + m, j + n] K[m, n] \quad (1)$$

式中: m 和 n 为卷积核在输入数据上的滑动步长, X 为输入数据, K 为卷积核。

然后, 使用池化层来降低特征映射的维度, 同时保留重要的数据语义特征信息。具体表示为:

$$Y'[i, j] = \max_{m, n} Y[i, j] \quad (2)$$

最后, 在 CNN 的最后一层, 通常是全连接层, 输出数据的语义信息, 表示为:

$$Z = Y'[i, j] W + b \quad (3)$$

式中: W 表示权重系数, b 为偏置。

综上, 实现对无线传感器数据语义的提取。

1.2 无线传感器数据语义关联聚合

基于上述语义提取结果, 计算各无线传感器数据语义间的相似度, 并基于其结果对各数据语义结果进行关联聚合。再将聚合结果进行输入, 利用强化学习对聚合结果进行优化调整, 来进一步提高大规模无线传感器数据语义关联聚合效果, 以提高无线传感器网络的性能和效率。

1.2.1 基于相似度的数据语义关联聚合

基于上述提取的数据语义结果 $Z = (z_1, z_2, \dots, z_n)$, 计算无线传感器网络数据语义之间的相似度, 以对无线传感器数据语义进行关联。其具体计算过程为:

$$\begin{cases} d_w = d_{(z_i, z_j)} + lp(1 - d_{(z_i, z_j)}) \\ d_{(z_i, z_j)} = \frac{1}{3} \times \left(\frac{m}{|s_1|} + \frac{m}{|s_2|} + \frac{m-t}{m} \right) \\ t = \frac{t_s}{2} \end{cases} \quad (4)$$

式中: d_w 表示无线传感器网络数据语义间的相似度, $d_{(z_i, z_j)}$ 表示无线传感器网络不同数据语义 z_i 与 z_j 间的距离, p 表示随机常量, l 表示数据内部的相似程度, m 表示数据语义长度, s_1 、 s_2 分别表示该数据语义与前后数据语义之间的距离, t 表示数据交换的次数, t_s 表示数据换位发生的次数。

通过上述公式, 完成对数据语义相似度计算。基于该结果, 将相似度较高的数据进行关联聚合, 以此完成无线传感器数据语义关联聚合。

1.2.2 基于强化学习的数据语义关联聚合优化

无线传感器网络常常部署在复杂且多变的环境中, 因此, 其数据聚合的结果需能够灵活地适应不断变化的网络环境, 从而确保整个网络的高效性能。强化学习作为一种机器学习算法, 能够在智能体与环境交互过程中发挥巨大的作用, 帮助寻找最优方法^[8-10], 从而实现长期收益的最大化。将其应用到数据语义聚合协议的设计中, 能够更好地适应动态化的环境, 根据实时的环境反馈来调整聚合, 从而保证数据聚合的准确性^[11-12], 以达到更好的性能和效率。因此, 接下来, 将 1.2.1 节聚合结果作为输入, 利用强化学习对聚合结果进行优化调整, 来进一步提高大规模无线传感器数据语义关联聚合效果。

强化学习框架中, 智能体持续观测其所处的环境, 依据观测结果 O 和当前聚合策略, 智能体决定执行一个动作 A 以作用于环境。环境的响应体现在其状态 S 的转变上 (即调整聚合结果), 这一转变直接受到智能体动作的影响, 同时环境会根据动作的效果反馈给智能体一个奖励 R 。整个强化学习的目的就是学习到一个策略能够获取更高的奖励, 过程如图 1 所示。




图 1 基于强化学习具体过程

基于图 1 所示的过程, 基于强化学习的大规模无线传感器数据语义关联聚合优化过程如下:

环境由动力来表示, 对有限马尔可夫决策过程, 动力的定义为:

$$p(s', r | s, a) = \Pr[S_{t+1} = s', R_{t+1} = r | S_t = s, A_t = a] \quad (5)$$

式中: t 表示时刻, $\Pr[\cdot]$ 表示分布的概率。由此根据上式 (5) 可获得状态转移概率和状态-动作期望奖励, 分别如下所示。

$$p(s' | s, a) = \Pr[S_{t+1} = s' | S_t = s, A_t = a] \quad (6)$$

$$r(s, a) = E[R_{t+1} | S_t = s, A_t = a] = \sum_{r \in R} r \sum_{s' \in S} p(s', r | s, a) \quad (7)$$

式中: $p(s' | s, a)$ 为给定当前状态和动作, 下一状态是 s' 的条件概率。 $E[\cdot]$ 表示给定当前状态和动作下, 下一状态给出的奖励 R_{t+1} 的期望。

智能体根据其观测结合聚类策略做出动作以改变状态，其中聚类策略可定义为：

$$\pi(a|s) = \Pr[A_t = a | S_t = s] \tag{8}$$

根据价值函数的定义可以得到状态价值函数和动作价值函数，分别为：

$$v_{\pi}(s) = \sum_a \pi(a|s) q_{\pi}(s, a) v_{\pi}(s-1) \tag{9}$$

$$q_{\pi}(s, a) = r(s, a) + \gamma \sum_{s'} p(s'|s, a) v_{\pi}(s') q_{\pi}(s-1, a) \tag{10}$$

式中： $v_{\pi}(s)$ 表示当前聚合策略的状态价值函数； $q_{\pi}(s, a)$ 表示当前聚合策略的动作价值函数； $v_{\pi}(s-1)$ 表示当前聚合策略的上一状态价值函数； $v_{\pi}(s')$ 表示当前聚合策略的下一状态 s' 价值函数； $q_{\pi}(s-1, a)$ 表示当前聚合策略，上一状态下的动作价值函数； γ 为折扣因子。

强化学习的核心目标在于探索并确定一个最优策略 π ，在该策略指导下的智能体在与环境交互过程中，能够执行一系列决策动作，以获得最大化累积的回报值（即奖励 R ，其包含状态价值函数和动作价值函数）。若回报值达到最大，即可输出对应的状态，即聚合结果，完成大规模无线传感器数据语义关联聚合优化调整；若未达到最大，则循环上述公式（5）～（10）的步骤内容。

由此，根据回报值，完成对数据语义关联聚合优化调整，实现最终的大规模无线传感器数据语义关联聚合。

2 实验测试

2.1 实验准备

为验证本文设计的基于强化学习的大规模无线传感器数据语义关联聚合方法的实际效果，进行实验测试。实验中，以某企业的无线传感器网络为实验对象，其具体的实验参数如表1所示，实验环境如图3所示。

表1 实验参数

序号	实验参数	参数数值
1	网络节点传输能耗	0.72 μ J/bit
2	网络节点接收能耗	0.81 μ J/bit
3	网络覆盖区域	150 m $\times$ 150 m
4	网络节点总数	500 个
5	采样频率	50 Hz
6	数据传输效率	1 s
7	网络宽度占通信半径的比率	1.5
8	节点分布情况	随机分布
9	内存	16 GB
10	网络节点感知数据消息的大小	45 Byte




图3 实验环境

如图3所示，在上述实验环境中，多个传感器构建相应的无线传感器网络，利用数据处理器对获取的无线传感器网络数据进行优化处理，进一步提高无线传感器网络数据的质量，为后续的实验提供数据支持。在上述过程中，获取的无线传感器网络数据部分如图4所示。




图4 无线传感器网络数据

如图4所示，在上述无线传感器网络数据中，在不同的传感器网络节点上，节点的流量均不同，且随着时间还会继续发生变化。将上述数据作为实验数据的一部分，在后续实验中使用。同时，在本次实验中，将传统的聚合方法与设计的基于强化学习的大规模无线传感器数据语义关联聚合方法进行对比。其中，本文设计的基于强化学习的大规模无线传感器数据语义关联聚合方法为方法1，传统的聚合方法为方法2，基于数据分析和深度强化学习的传感器网络大数据聚合技术为方法3。对上述三种方法的实验结果进行分析，验证本文方法在实际应用中的性能。

2.2 实验结果讨论

实验中，为对比上述三种方法在实际应用中的性能，以无线传感器网络的吞吐量变化为评价指标，对比三种方法的实际性能。实验中，利用上述三种方法对无线传感器数据进行聚合，统计其聚合后的无线传感器网络吞吐量。其具体统计结果如图5所示。在应用上述三种方法后可以看出，方法1的无线传感器通信网络吞吐量在急剧上升，到达一定数值后趋于稳定，方法2和方法3虽然也在上升，但上升幅度低于方法1。因此，本文设计的聚合方法在实际应用中聚合效




图5 三种方法的吞吐量

如图5所示,为验证上述三种方法在实际应用中的效果,以聚合过程中无线传感器网络数据的丢失量为评价指标,进行实验测试。实验中,任意抽取10个无线传感器网络节点,利用三种方法对不同的节点进行数据聚合,统计其聚合过程中数据的丢失量。其具体统计结果如表2所示。

表2 三种方法的数据丢失量

无线传感器网络节点	三种方法的数据丢失量/bit		
	方法1	方法2	方法3
#01	0	3.5	8.9
#02	0	4.5	9.6
#03	0	6.2	7.5
#04	0	5.3	8.9
#05	1.1	4.3	6.7
#06	0	6.1	10.1
#07	2.3	5.9	12.3
#08	0	5.3	9.2
#09	1.5	4.2	10.5
#10	0	3.9	10.4

如表2所示,从上述实验结果中可以看出,对于不同的网络节点,方法1的数据丢失量趋近于0,仅有节点4、7、9存在数据丢失的情况,且丢失量不大。方法2和方法3在聚合过程中,每个节点都存在数据丢失的情况,且数据丢失量远高于方法1,由此可见,方法1的数据丢失量最小。因此,本文设计的聚合方法在实际应用中聚合效果最好。

综上所述,本文设计的基于强化学习的大规模无线传感器数据语义关联聚合方法在实际应用中吞吐量较高,数据丢失量较小,聚合效果较好,能够有效聚合无线传感器数据,减小无线传感器网络的计算压力。

3 结语

本文设计的基于强化学习的大规模无线传感器数据语义关联聚合方法,可以实现对无线传感器大量数据的自动处理和分析,提高数据聚合的准确性和效率。利用卷积神经网络来提取无线传感器数据语义,并基于数据语义间的相似度,对无线传感器数据语义进行关联聚合。为适应环境变化,提高数据聚合效果,通过强化学习对聚合结果进行优化调整,来进一步提高大规模无线传感器数据语义关联聚合效果。未来,可

以通过进一步的研究和实践,不断完善和优化该方法,推动其在无线传感器网络数据聚合领域的更广泛应用和发展。

参考文献:

- [1] 李达,冯景丽,平健,等.基于双层区块链的电动汽车充电隐私数据可信聚合方法[J].电力建设,2023,44(11):13-22.
- [2] 曾纪钧,江疆.基于区块链技术的物联网终端隐私数据聚合方法[J].自动化技术与应用,2022,41(8):71-75.
- [3] 房保钢,钟伯成,张家磊.无线传感器网络中数据安全聚合方法[J].传感器与微系统,2022,41(4):146-148+152.
- [4] 云涛,潘泉,郝宇航,等.基于HRRP时频特征和多尺度非对称卷积神经网络的目标识别算法[J].西北工业大学学报,2023,41(3):537-545.
- [5] 左佳倩,王煜凯,王红球,等.基于卷积神经网络特征提取的拉曼光谱分类研究[J].光散射学报,2022,34(1):1-5.
- [6] 毛琳,任凤至,杨大伟,等.基于卷积神经网络的全景分割Transformer模型[J].软件学报,2023,34(7):3408-3421.
- [7] 张丽丽,陈子坤,潘天鹏,等.融合多尺度特征卷积神经网络的多光谱图像压缩方法[J].光学精密工程,2024,32(4):622-634.
- [8] 孙正伦,乔鹏,窦勇,等.面向执行-学习者的在线强化学习并行训练方法[J].计算机学报,2023,46(2):229-243.
- [9] 马廷淮,彭可兴,周宏豪,等.具有实时注意力的多智能体强化学习通信模型[J].计算机仿真,2023,40(8):445-450.
- [10] 徐弘升,陆继翔,杨志宏,等.基于深度强化学习的激励型需求响应决策优化模型[J].电力系统自动化,2021,45(14):97-103.
- [11] 王斌.基于大数据的物流运输网络优化分析[J].中国储运,2022(9):132-133.
- [12] 胡柏吉,李元诚,房方,等.基于轻量级区块链的隐私保护传染病监测数据聚合[J].中国科学:信息科学,2021,51(11):1885-1899.
- [13] 夏喆,罗宾,徐桂彬,等.智能电网中支持细粒度访问控制的隐私保护数据聚合方案[J].信息安全学报,2021,21(11):28-39.
- [14] 占力戈,沙乐天,肖甫,等.基于强化学习的自动化Windows域渗透方法[J].网络与信息安全学报,2023,9(4):104-120.
- [15] 韩艺琳,王丽丽,杨洪勇,等.基于强化学习的多机器人系统的环网编队控制[J].复杂系统与复杂性科学,2023,20(3):97-102.

【作者简介】

杨正权(1987—),男,江苏淮安人,硕士,讲师,研究方向:网络布线和网络搭建。

(收稿日期:2024-07-03)