

基于全神经网络增强算法的 WSNs 故障预警与检测

兰娅勋¹, 蔡娟¹, 李振坤²

(1. 广州科技职业技术大学 信息工程学院, 广州 510550;

2. 广东工业大学 计算机学院, 广州 510005)

摘要: 针对现有 WSNs 故障检测算法存在的故障分类检测率低、耗时长、节点能耗控制差等问题, 提出一种全神经网络增强故障预警与检测算法; 全神经网络的神经元节点与临近层的节点连接, 形成具有强大故障数据训练功能的深度网络结构, 选择平滑性更好的 sigmoid 函数作为模型的激活函数, 并基于感知机合理调节相邻两个隐含层之间的阈值权重, 降低模型的训练损失; 采用 Adam 优化算法抑制模型的梯度膨胀和梯度消失等异常情况, 并消除训练中产生的数据冗余, 以降低故障数据训练中产生的虚预警; 实验结果显示: 提出算法的总体故障检测率和不同类型故障的分类检测率都优于传统算法, 此外全神经网络增强算法在节点故障检测耗时和能耗控制方面, 也具有显著优势。

关键词: 全神经网络; WSNs; 节点; sigmoid 函数; Adam 优化算法; 梯度

WSNs Fault Warning and Detection Based on Full Neural Network Enhancement Algorithm

LAN Yaxun¹, CAI Juan¹, LI Zhenkun²

(1. College of information Engineering, Guangzhou Vocational and Technical University of Science and Technology,

Guangzhou 510550, China;

2. Faculty of Computer, Guangdong University of Technology, Guangzhou 510005, China)

Abstract: Aimed at the problems of low fault classification detection rate, long time consumption, and poor control of node energy consumption in existing wireless sensor networks (WSNs) fault detection algorithms, a fully neural network enhanced fault warning and detection algorithm is proposed. The connection between neural nodes in full neural network and nodes in adjacent layers is carried out to form a deep network structure with strong fault training function. The sigmoid function with better smoothness is selected as the activation function of the model, and the weight threshold between two adjacent hidden layers is reasonably adjusted based on the perceptron to reduce the training loss of the model; The Adam optimization algorithm is used to reduce the gradient expansion and vanishing of the model, and eliminate the data redundancy generated during training, reducing the false warning generated by fault data training. The experimental results show that the overall fault detection rate and classification detection rate of different types of faults of the proposed algorithm are superior to traditional algorithms. In addition, the full neural network enhancement algorithm also has significant advantages in node fault detection time and energy consumption control.

Keywords: full neural network; WSNs; node; sigmoid function; Adam optimization algorithm; gradient

0 引言

WSNs (无线传感器网络) 由大量成本较为低廉的传感器节点构成^[1], 节点采用电池供电且具有一定的感知和信息处理能力, 在监测区域内节点之间采用了无线收发信号和多跳自组织的模式, 形成一个互通互联的网络结构^[2]。WSNs 具有组网便捷、成本低、可随机部署网络、节点开

发成本低等优势, 因此在环境监测^[3]、野外作业^[4]、户外勘测^[5]、医疗护理及军事侦查等领域都有十分广泛的应用。但受限于无线传感器节点的制造成本、通信功能和电能供应情况等, WSNs 链路通信的稳定性远低于有线网络^[6], 而且节点通常暴露在户外环境中更容易损坏或电能耗尽, 进而出现网络通信故障, 影响到区域内的监测结果。由此可

收稿日期: 2023-04-20; 修回日期: 2023-05-29。

基金项目: 2022 年广东省教育厅普通高校科研项目(2022WTSCX160)。

作者简介: 兰娅勋(1981-), 女, 硕士, 副教授。

引用格式: 兰娅勋, 蔡娟, 李振坤, 等. 基于全神经网络增强算法的 WSNs 故障预警与检测[J]. 计算机测量与控制, 2023, 31(11):

81-87.

见,实时监控 WSNs 的通信情况和网络故障状态必不可少,能够确保 WSNs 始终处于正常的工作状态。随着无线通信技术、故障在线检测技术和计算机软硬件技术的不断进步,各种智能化故障检测算法被不断地应用到 WSNs 故障预警和检测之中。

WSNs 有大量节点构成,网络故障的原因源于节点本身出现故障或节点之间的通信链路或通信协议等出现故障。现有的国外研究主要围绕着网络节点的故障检测展开,具体的检测方法以人工智能算法、仿生算法及专家系统诊断方法等为主。其中人工智能故障诊断算法包括了神经网络、智能 SVM 故障分类、遗传算法等,或基于上述算法的融合算法,能够规避单一算法存在的不足;仿生算法以 PSO 算法、鱼群、蜂群等算法为主,借助粒子运动或动物群体智能行为等,判断 WSNs 网络节点的分布状态。而国内相关的学者对于 WSNs 节点故障的研究起步较晚,研究的主要方向为基于信息融合的角度对节点链路通信故障进行研究,或通过网络链路的负载情况、节点分簇情况等,来判断节点之间的通信是否存在异常。文献 [7] 设计了一种基于通信大数据驱动的 WSN 节点故障定位于故障诊断算法模型,先通过采集传感器节点之间的通信链路工作状态与通信信息,并构建空间范围内的多维向量,判断通信数据流是否存在异常。但多维向量的获取和状态判定难度较大,而且该种算法监控难度较大监测成本也较高,故障定位、预警和分类检测准确率有待提升;文献 [8] 提出了一种信息融合故障算法,通过融合多个传感器之间的通信信息,在正常的网络通信负载条件下,判断通信链路或传感器节点是否存在异常情况。该种无线通信监测技术的应用范围较为广泛,技术成本和相关的投入也较低。但基于多传感器融合数据监控算法工作效率较低,导致网络稳定性差,数据融合处理耗时也相对较长,导致节点的能耗消耗过快;文献 [9] 提出一种基于节点分簇的故障预警与检测算法,先根据节点分布情况和位置关系选取簇首节点和汇聚节点,再通过对簇首节点、汇聚节点和普通节点之间有效区域的划分形成最优通信链路,进而实现对节点故障和通信链路现存故障的判定和检测。但基于节点分簇的故障检测算法,更适用于规模较小的无线通信网络,如果 WSNs 的网络规模较大,故障检测的效率和检测精度都会同步降低。

随着人工智能和机器学习技术不断颈部和算法功能的不断增强,神经网络算法特别是深度学习算法的应用场景不断增加^[10-11]。为进一步利用深度神经网络在故障定位和数据处理方面的优势,本文设计了一种全神经网络增强算法,充分发挥出深度神经网络在处理海量通信链路数据和节点故障数据方面的数据训练优势,准确判断出节点的故障现象和通信链路的故障类型;针对于全连接神经网络参数较多及对故障数据训练时间较长的问题,本文对全神经网络模型进行了优化和改进,提升对 WSNs 故障预警与检

测的精度,并降低算法的复杂度。

1 WSNs 网络结构设计及故障分析

1.1 WSNs 的网络结构与节点构成

构成 WSNs 的节点包括普通节点,汇聚节点(簇首节点)^[12]和任务管理节点,在目标区域内随机投放的节点是普通节点,负责采集节点周围的信息,并传递给汇聚节点。普通节点之间也能够实现通信和数据传输。汇聚节点通过互联网与任务管理节点之间通信,负责将辐射范围内所有普通节点采集到的信息上传到任务管理节点,同时向下传递任务管理节点的指令。无线传感网络的基本结构图,如图 1 所示(设定 WSNs 的覆盖区域为边长为 3 km 正方形,包含了 1 个任务节点,3 个汇聚节点和 10 个普通节点):

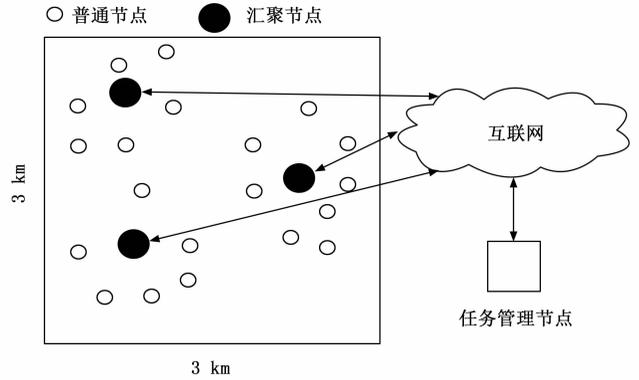


图 1 WSNs 的网络结构

WSNs 是一种无线自组织网络模型,节点的部署具有随机性,而且节点的位置并不是固定不变的,可以随着环境的变化而发生移动。节点的初始部署完成后,分属与不同区域的节点之间实现通信,其中能量较多、位置最优,且与任务节点通信距离合适的节点将成为汇聚节点,负责汇总各普通节点的信息并将信息通过互联网上传给任务管理节点。节点是构成 WSNs 的基础,每个节点(包括普通节点和汇聚节点)都是一个小型的嵌入式系统结构,包括以下 4 个基础模块。

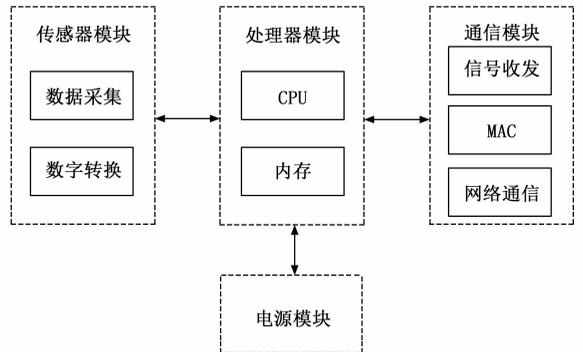


图 2 WSNs 节点内部结构设计

处理器模块是节点的核心部分,包括了 CPU 单元和内

存存储器, 在软件方面还包括了嵌入式的操作系统。处理器能够控制节点的运行、能耗管理和信息的收发等。但受限于成本、体积等, WSNs 节点的运算能力和管理能力都十分有限; 电源模块负责为节点其他模块提供能耗, 通常情况下节点会采用电池供电, 作为汇聚节点无论是在电能供应和计算能力方面都要优于普通节点; 传感器模块内置不同类型的传感器, 能够采集节点周围的温度、湿度、气压等信息, 并实现数据信息的 A/D 转换^[13-14]; 无线通信模块包含信息收发单元、MAC 单元和网络通信单元, 主要负责与汇聚节点和其他普通节点之间的数据交互。WSNs 节点的通信距离有限, 节点会根据有效的通信半径选择合适的汇聚节点, 而且通信效果与节点电池能力密切相关, 随着电池能耗的不断降低通信能力和通信质量会随之下降。

1.2 无线传感网络故障类型汇总分析

WSNs 出现度故障主要是节点故障, 而且节点的几个组成部分都有可能出现一个或多个故障。首先处理器模块的故障有温度过高出现预警和数据传输失效, 处理器由于超频工作、服役过久或嵌入式系统故障, 而导致 WSNs 局部功能失效; 最后由于节点内存老化, 读写错误等导致数据存储功能失效; 其次, 电源模块的故障主要表现为电压降低、电压波动或不稳。通常情况下由于电能消耗节点供电电压都会出现一定程度的降低, 但如果服役时间较短的节点供电电压低于 2 V, 节点正常的通信工作将无法完成, 或传递的数据质量呈现出显著下降的趋势。

传感器模块和通信模块是故障率较高的模块, 首先可以通过判断传感器的数字转换效率和质量, 判断出传感器是否处于故障状态。在 t 时刻采集到的节点传感器信号表示为 $f(t)$:

$$f(t) = \eta f'(t) + \kappa + \varepsilon(t) \quad (1)$$

其中: $f'(t)$ 为传递信号的真实值, η 为放大倍数, κ 为偏置量, $\varepsilon(t)$ 为信号采集误差。与传感器信号相关的几个变量, 如放大倍数、偏置量等都可能影响到信号的采集。通信模块的故障大都集中于信号的收发单元, 可以通过测量数据接收率和发送率的值, 判断节点通信模块是否存在故障。节点数据接受率 r 的计算过程如下:

$$r = \frac{\sum_{i=1}^m a_0}{ma_1} \quad (2)$$

其中 $m = \frac{T_0}{T}$, T_0 为接收统计时长, T 为采样周期, a_0 为统计周期内接收到的数据总量, a_1 为观测周期内接收到的数据总量。通过判断接受率 r 值的大小, 进而评估出节点通信模块是否存在故障。节点数据发送率 s 的计算过程如下:

$$s = \frac{\sum_{i=1}^q b_0}{qb_1} \quad (3)$$

其中: $q = \frac{T_1}{T}$, T_1 为发送统计时长, T 为采样周期, b_0

为统计周期内接收到的数据总量, b_1 为观测周期内接收到的数据总量。同理, 通过判断节点数据接受率 s 值的大小, 进而评估出节点通信模块是否存在数据通信方面的故障。

2 全神经网络增强算法模型构建与梯度优化

实时汇总和分析节点通信过程中产生的数据流, 并形成故障数据集, 通过判断数据集是否存在异常进而实现对 WSNs 的故障预警和检测。由于 WSNs 中节点通信实时存在, 通信故障集的规模较大, 因此实时处理故障数据集的难度较大。

2.1 全神经网络模型的层次结构

本文提出全神经网络增强算法中所构建的全神经网络模型, 不同于普通的深度神经网络模型, 其包含多个隐含层而且可以根据数据集的规模与复杂程度, 提高隐含层的数量。每个隐含层中又包含多个神经元结构。各隐含层之间神经元采用全连接方式, 而处于同一层的神经元互不连接。当全神经网络的隐含层数量较多时, 神经元之间形成的网络结构复杂度就越高, 网络的数据训练和信息表达能力也就更强, 达到检测算法增强的目的。但全神经网络由于结构过于复杂, 导致参数集的规模较大, 会面临参数调整和参数优选等问题, 因此本文在全连接神经网络的设计过程中通过优化损失函数和激活函数等方式, 控制模型的梯度变化并确保神经网络模型的数据训练和处理能力^[15-16]。全神经网络的基础结构设计, 如图 3 所示 (为简化设计, 本文以一个四层次的全神经网络为例)。

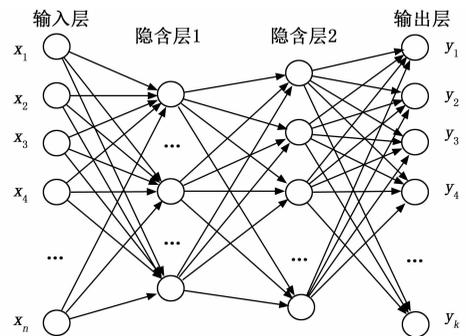


图 3 全连接神经网络结构简图

在四层次的网络结构中上一层为下一层次的输入层, 每个层次的神经元节点都包含输入、输出、权值、偏置函数和激活函数^[17], 通过权值分配完成相应的计算任务, 网络结构的复杂程度和训练计算能力成正比, 但相应计算代价和参数集复杂度也有所提升。

2.2 神经元结构与激活函数的选择

神经元节点是全神经网络的基础结构, 神经元之间的连接键决定了节点之间的关联关系, 设 x_i 为第 i 个神经元的输入项, y_i 为输出项, 神经元的 WSNs 通信数据训练过程描述如下:

$$y_i = f\left(\sum_{i=1}^n \omega_i \cdot x_i + \xi\right) \quad (4)$$

其中: f 为激活函数 (本文选用通用性和兼容性更好的 sigmoid 函数), ω_i 是节点对应连接权重, ξ 为神经元之间的连接阈值。sigmoid 函数的取值区间在 0 至 1 之间, 在有效的输出值区间范围内 sigmoid 函数的优势在于过度平滑容易求导, sigmoid 激活函数表示为:

$$f(x) = \frac{1}{e^{-x} + 1} \quad (5)$$

但 sigmoid 函数也有一定缺点, 即存在梯度过饱和问题会影响到全神经网络的训练效率。

2.3 感知机与损失函数

全神经网络包括多个中间隐含层, 每层的神经元都与上下层的其他神经元连接, 神经元之间能够通过调整连接权重的方式来降低数据训练过程中的损耗。感知机能够调节相邻两个隐含层之间的权重阈值, 进而判断出故障数据集训练过程中存在的误差大小。设当前的一组训练集为 (x_i, y_i) , 则感知机的预期输出为 \hat{y}_i , 则感知机对应的权重增量 $\Delta\omega_i$ 和连接阈值增量 $\Delta\xi$ 分别表示如下:

$$\Delta\omega_i = \kappa(y_i - \hat{y}_i)x_i \quad (6)$$

$$\Delta\xi = y_i - \hat{y}_i \quad (7)$$

其中: κ 为全神经网络模型数据训练过程中的学习率, 用于控制权重调整的幅频。根据感知机规则和要求当样本输入中间隐含层时神经元权重比例随之调整, 便于及时观测输出值与期望值之间的偏差。WSNs 节点故障和通信故障问题属于典型的非线性问题, 故障集无法被线性分割, 感知机在处理该类问题时通常会在多次迭代后趋于收敛, 此时根据收敛结果确定最合适的权值向量。基于学习率 κ 和感知机评价工具能够对输出值和期望之间的误差进行评估, 为进一步降低全神经网络的输出误差, 本文选择了平方误差函数 (MSE 函数) 作为全神经网络模型的损失函数。MSE 函数主要用于对神经网络模型的参数质量进行评估, 由于全神经网络模型的规模较大, 参数系统较为复杂, 选择最优的模型参数能够有效地提高数据集训练效率, 并缩小真实输出值与期望值之间的偏差, MSE 函数的表达式如下:

$$M(y_i) = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (8)$$

以 MSE 函数作为全神经网络的损失函数, 能够在感知机的基础上对参数集的选择误差情况进行有效地评估, 进一步完善全神经网络的功能。

2.4 对全神经网络模型的改进与算法增强

全神经网络模型具有强大的数据训练能力, 但其结构和参数集都过于复杂, 导致计算代价较高, 而且选择 sigmoid 函数作为模型的激活函数还容易造成模型的梯度波动、过拟合^[18]、梯度爆炸或梯度消失等问题。因此本文从优化全神经网络的模型结构和提升模型的梯度优化能力等两个视角对全连接神经网络模型进行优化和改进。

对于普通的神经网络模型而言, 随着网络结构复杂度的提升和中间隐含层数量的增加, 网络会出现功能退化、计算代价提升、数据训练效率降低及精度下降等问题。为

此本文先设计了一种跳跃结构, 提升模型数据训练的准确率。跳跃结构就是在普通层和输出层之间增加了一个跳跃式网络结构, 控制网络残差并解决多层网络结构的退化问题。如果在输入层的映射函数表示为 $g_i(x)$, 输出层为 y_i , 则跳跃层结构是位于两者之间的一种映射函数:

$$y_i = g_i(x) + h(g_i(x)) \quad (9)$$

其中: $h(g_i(x))$ 即为全连接神经网络的跳跃结构, 负责解决各层次之间的函数映射恒等问题, 即使网络结构复杂度较高, 各层次集各神经元之间的映射关系也较为清晰, 同时也有助于抑制模型梯度波动过高的问题。优化的全神经网络模型选择了 sigmoid 函数作为激活函数, 主要是由于 sigmoid 函数的平滑属性, 但 sigmoid 函数会引起模型的梯度波动, 本文基于 Adam 优化算法对全神经网络的过拟合问题和梯度波动问题进行优化处理。Adam 优化算法的思路是对梯度指数进行加权处理, 进而平滑神经网络的参数, 并使故障数据集训练中的梯度波动的情况得到有效抑制。令 v_t 为第 t 期的梯度指数, 迭代过程如下:

$$v_t \leftarrow \gamma v_{t-1} + \eta \varphi_t \quad (10)$$

$$x_t \leftarrow x_{t-1} + v_t \quad (11)$$

其中: γ 为模型的待更新的平滑参数, η 为全神经网络的学习率, φ_t 为第 t 期的偏一阶矩估计, x_t 和 x_{t-1} 分别为第 t 期和第 $t-1$ 期的输入故障数据集。Adam 优化算法通过多次的迭代, 对全神经网络的神经元的权重集偏置梯度做指数级的加权移动评价和平滑处理, Adam 优化算法将有助于控制故障集训练过程中出现的梯度波动异常问题, 避免了提出震荡过大现象的发生。利用 Adam 优化算法控制模型梯度优化, 首先要对模型和 sigmoid 函数进行初始化设置, 每次迭代寻优都要更新函数的梯度值和模型的梯度值, 然后根据模型梯度值的最新更新结果, 调整偏一阶矩估计值作为偏二阶矩估计值的参考值, 计算一阶矩估计修正偏差值, 及二阶矩估计修正偏差值。最后通过以上两种值的融合结果, 对模型的参数集进行持续更新, 并筛选出最佳的模型参数组合用户故障集的训练和测试。与传统梯度优化算法相比, Adam 优化算法能够同时对一阶矩估计和对二阶矩估计, 从强化对模型梯度消失和梯度膨胀的抑制, 模型的优化控制效果更加明显。Adam 优化算法能够独立地设置与隐含层神经元相匹配的学习率, 提升神经网络数据训练性能和模型的收敛速度。sigmoid 函数的输出值范围在 0~1 之间, 因此学习率的取值也存在上下限, 从另一个层面限制的可用参数的范围, 避免参数集取值范围过大。

3 基于全神经网络增强算法故障检测的实现

3.1 全神经网络增强算法的流程

在 WSNs 节点故障诊断和通信链路故障诊断方式上, 主要采用周期性数据采集和储存模式, 形成具有一定规模的故障集, 再集中对一段时间内故障集进行故障预警和检测。首先, 由汇聚节点采集其他节点的工作信息和通信链路信息, 并将相关的信息存储于节点内存之中; 其次, 汇聚节点将各

节点信息和通信链路信息进行汇总和整理, 并通过互联网上传到任务管理节点; 最后, 由于任务节点的数据处理功能较为强大, 可以利用全神经网络增强算法模型, 判断出一个周期的数据集的内部是否存在确定的故障点, 并同步做出相应的预警和检测, 故障诊断流程如图 4 所示。

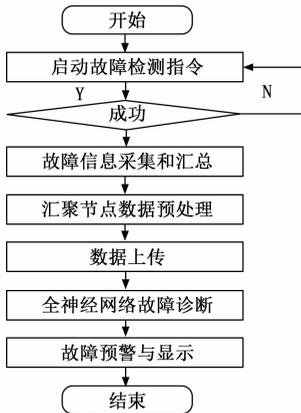


图 4 全神经网络故障预警与检测流程

3.2 虚预警的判定与冗余信息消除

如果 WSNs 节点之间的通信信号不稳定, 检测系统会将这些瞬时的信号中断误认为通信故障, 进而产生大量的伪通信信号冗余, 在基于全神经网络增强算法的故障检测过程中, 还要消除这些冗余信息对故障诊断的影响。设节点 i 发生真实故障的概率为 p_{iA} , 对应的故障集为 A , 节点 i 发生瞬时故障的概率为 p_{iB} , 对应的故障集为 B :

$$p_{iA} = p(A) \quad (12)$$

$$p_{iB} = p(B | A) \quad (13)$$

当 p_{iA} 的取值范围在 $0 \sim 1$ 之间时, 表明 WSNs 的节点或节点之间的通信链路真实发生了故障, 而当 p_{iB} 的概率不为零时, 诊断结果可能为真实的结果或为虚预警, 应对预警结果做进一步的判断^[19-20]。将节点的故障周期分割为 N 个离散的时间段, 即 $t_1 - t_N$, 给定一个具有参考意义的阈值边界 θ , 通过概率判断节点为正常状态的次数优先达到阈值后, 可以证明该节点的状态为正常状态 (节点存在虚预警情况); 如果节点经过多次迭代寻优后, 仍无法达到阈值边界 θ , 表明该节点自身通信存在问题, 或与该节点相关的通信链路也存在一定的问题:

$$\sum_{j=1}^N p(B | A) = 0 \quad (14)$$

在公式 (14) 的情况下, 表明节点的故障诊断和通信链路的结果正常, 不存在故障。

$$\sum_{j=1}^N p(B | A) = \theta \quad (15)$$

在公式 (15) 的情况下, 表明节点的故障诊断和通信链路的结果不正常, 可以视为已经出现了 WSNs 节点故障预警。当概率取值在 0 和 θ 之间时, 需要重复检测和判断并调整阈值范围, 并继续利用全神经网络增强算法训练故障

集, 并消除冗余数据和虚预警现象。

3.3 全神经网络结构的优化与调整

全神经网络的主要结构的是全连接层, 根据输入数据集的规模调整网络层数, 并提取节点故障集和通信链路故障集的属性特征。当网络结果确定以后, 利用全神经网络训练故障集同时优选参数集, 但随着训练数据集规模的增大, 全神经网络结果也不是固定不变的, 需要根据数据训练情况、参数集优选情况、损失函数变化情况和激活函数取值情况等, 适时调整全神经网络的层数和数据训练能力。如果经过一段时间的训练以后, 故障集特征提取准确率较低且损失函数值较大, 证明模型在故障集训练效率较低或全神经网络模型存在不收敛的情况, 导致这种情况发生的原因包括学习率的取值存在问题, Adam 优化算法与学习率匹配存在问题等, 通过调整训练学习率或阈值边界 θ , 降低数据集的冗余度并解决模型存在的过拟合等问题, 改善全神经网络的故障集训练效率和故障分类检测的精度。

4 实验结果与分析

4.1 实验环境设置与故障特征样本提取

为验证本文提出的全神经网络增强算法在 WSNs 故障预警与检测中的表现, 基于 MATLAB 仿真软件设计了一组仿真实验。实验中所用 PC 机的配置如下: CPU intel Core i9 13900ks, CPU 最高主频 3.6 GHz, 运行内存为 16 GB, 存储规格为 2 TB, 操作系统为 Windows2010 专业版。为简化实验环境设置, 在 $1 \text{ km} \times 1 \text{ km}$ 的仿真区域内随机布置了 1 个汇聚节点和 8 个普通节点, 如图 5 所示。

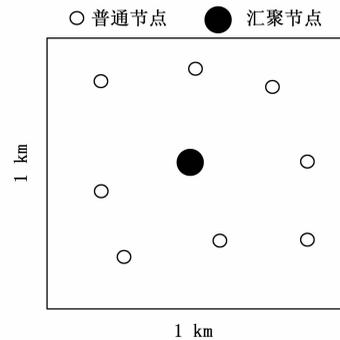


图 5 WSNs 仿真环境设置

无论是汇聚节点还是普通节点都被安装了故障属性特征检测器, 因此这些节点都具有有了故障特征提取功能, 实验的步骤设置如下。

1) 设置仿真环境和仿真区域, 同时在仿真环境下调试软硬件的运行情况。

2) 基于节点特征检测器, 提取相关的故障特征数据, 构建用于检验的数据集。

3) 选择实验验证的数值指标 (故障检测率、分类检测、虚预警率等)。

4) 提取数据并基于进行 MATLAB 仿真软件对数据的

结果进行分析。

包括汇聚节点在内的 9 个传感器节点的故障数据特征样本定义为 $C_1 - C_9$ (其中汇聚节点为 C_1 , 普通节点为 $C_2 - C_9$), 节点故障特征包括 4 种, 处理器故障 H_1 、电源故障 H_2 、传感器故障 H_3 、通信模块故障 H_4 , 节点之间通信链路故障 H_5 , 如果 WSNs 网络没有出现故障表示为 H_0 。从每个传感器中分别随机采集 1 000 组故障样本, 共 9 000 组样本, 每组样本中都包含有少量的 $H_1 - H_5$ 故障样本, 随机提取到的故障样本状态如表 1 所示。

表 1 部分故障样本状态分布统计

节点属性	H_0	H_1	H_2	H_3	H_4	H_5
C_1	0	0	1	0	1	0
C_2	0	1	0	1	0	0
C_3	0	0	0	0	0	1
C_4	0	0	0	0	1	0
C_5	0	1	0	0	0	1
C_6	0	0	1	1	1	0
C_7	0	0	0	0	0	0
C_8	0	0	0	1	0	0
C_9	0	0	1	0	0	1

表 1 中取值 0 表示节点或链路状态正常, 如果取值为 1 表明存在故障, 全部的故障集设为 X , 包含了 9 000 组样本作为模型的输入项, 输入数据的训练过程如公式 (16) 所示:

$$Y = f\left(\sum_{i=1}^n \omega_i \cdot X + \xi\right) \quad (16)$$

其中: X 为采集样本神经元的输入项, Y 为模型的输出项, ω_i 是节点对应连接权重, ξ 为神经元之间的连接阈值, f 为全神经网络模型的激活函数, 基于输出样本的结果, 进行后续指标对比分析, 数据的训练过程在 MATLAB 仿真环境下进行

4.2 各算法故障检测率、分类检测率和虚预警率的对比分析

将实验中形成 9 000 组故障样本混合并随机分为 10 组, 每组样本中都包含有不同的故障类型, 分别利用本文提出的全神经网络算法和 3 种传统算进行故障检测和故障分类, 判断各算法对于故障异常预警准确率 (检测出的故障样本数与每组全体样本总数的比值) 和分类准确率 (检测出的每种样本数与实际样本数比值, 再求 5 种故障样本分类准确率均值), 统计结果如表 2 和表 3 所示。

仿真数据分析结果显示: 无论是故障预警与检测率, 还是多种不同故障的分类检测率值, 全神经网络增强算法都要优于 3 种传统算法。这表明全神经网络增强算法模型的数据训练能力和分类检测能力均较强。全神经网络增强算法, 还对 WSNs 中的伪故障特征和冗余特征进行了处理, 有效控制了虚预警率, 检测各算法的虚预警率变化情况, 如图 6 所示。

表 2 故障预警与检测准确率

分组	故障检测算法 %			
	本文算法	数据驱动	信息融合	节点分簇
1	99.1	97.1	94.4	95.6
2	99.3	96.2	93.0	94.1
3	99.5	96.4	92.8	93.6
4	100	95.5	91.8	92.5
5	100	94.5	92.7	91.4
6	99.7	93.1	95.5	88.7
7	99.6	94.5	94.7	91.7
8	100	96.4	93.1	92.6
9	99.5	95.5	94.7	89.8
10	99.3	92.0	92.8	86.7
均值	99.6	95.1	93.6	97.1

表 3 不同类型故障分类检测率

分组	故障检测算法 %			
	本文算法	数据驱动	信息融合	节点分簇
1	99.7	91.2	87.5	87.6
2	99.5	88.7	88.4	88.2
3	99.4	86.4	89.4	86.9
4	99.3	89.9	90.4	92.8
5	99.8	90.0	91.6	91.6
6	100	91.9	93.8	94.1
7	99.5	92.7	87.7	93.5
8	99.3	91.3	86.4	88.6
9	100	88.6	90.1	87.2
10	99.7	87.5	89.3	86.3
均值	99.6	89.8	89.5	89.7

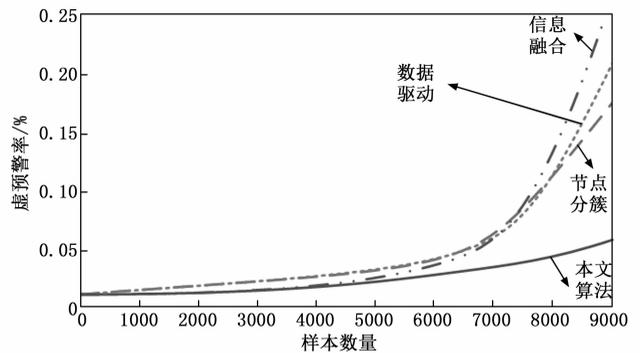


图 6 虚预警率变化曲线对比

当故障样本集规模超过 6 000 以后, 3 种传统算法的虚预警率开始增加, 当样本量超过 8 000 以后虚预警率快速增加, 表明传统故障检测算法在应对大规模数据集时的检测率衰减过快; 而全神经网络增强算法的虚预警率得到较好的控制, 这与算法在数据训练中剔除了大量冗余故障数据密切相关, 降低了数据训练的难度和数据集的规模。

4.3 检测耗时及各节点的剩余能耗分析

故障定位预警与故障检测的效率对于 WSNs 网络稳定运行至关重要, 如果 WSNs 中包含了大量节点, 意味了获

取到的故障集规模更大, 且节点发生故障的概率更高, 无论是从成本视角考虑还是从实用性角度考虑, 都有必要降低节点故障预警与检测的耗时, 在 4.1 节设定的仿真环境下, 分析不同算法对于每组故障数据集检测耗时情况, 统计分析结果如图 7 所示。

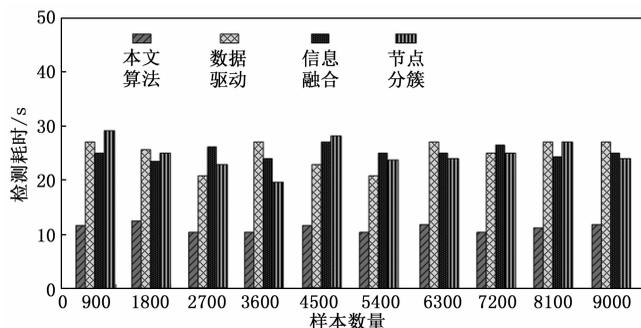


图 7 各组数据的故障检测耗时情况分析

全神经网络增强算法处理每组数据的耗时在 10 s 左右, 而其他 3 种传统算法的耗时都超过了 20 s, 当节点众多和故障集的规模较大时, 全神经网络增强算法的优势会更加明显。最后, 分析各算法模型处理完成故障集后, 各节点剩余能耗情况, 节点的能耗与 WSNs 网络寿命密切相关, 节点能耗消耗过快与不合理的链路匹配及数据冗余有关, 节点剩余能耗的统计分析结果, 如表 4 所示。

表 4 各节点剩余能耗占比分析 %

节点	C_1	C_2	C_3	C_4	C_5	C_6	C_7	C_8	C_9
本文算法	54.1	31.2	40.6	41.5	33.8	36.9	37.8	40.5	42.9
数据驱动	36.1	26.4	21.5	18.1	17.5	12.0	0	9.6	12.4
信息融合	35.4	0	12.8	24.4	21.6	0	17.8	19.6	21.5
节点分簇	32.6	8.7	12.5	0	21.8	17.6	15.9	20.8	18.8

分析处理各组故障集完毕后, 在全神经网络增强算法控制下 WSNs 未出现死亡节点, 每个节点剩余能量占比也要优于 3 种传统算法; 而 3 种传统算法控制下都出现了能量耗尽的死亡节点, 会 WSNs 的功能产生一定的不利影响, 加速网络通信功能的衰减。

5 结束语

随着网络通信技术的发展, WSNs 的应用场景越来越多, WSNs 具有组网便捷和适应性强等特点, 尤其在野外和相对恶劣的环境下优势更加明显。但受限于节点的成本和功能, WSNs 的网络稳定性有待强化, 因此实时对网络运行状态进行监控并及时排除故障, 能够确保 WSNs 的基础功能正常发挥。为提升对通信故障集分类检测的准确率, 本文设计了一种全神经网络增强算法模型, 从网络总体层次结构设计、激活函数选择、梯度异常波动抑制和虚预警率控制等多个方面, 全面优化 WSNs 的性能。仿真结果显示, 全神经网络增强算法的故障分类检测率更高, 耗时较少, 通信效率高且网络的稳定性较强。

参考文献:

- [1] 陈辉, 高岩. 基于双簇头的 WSNs 非均匀分簇路由算法 [J]. 计算机工程, 2022 (10): 184-192.
- [2] 李振美, 王翠平. 基于布尔方程与数据分析的 WSNs 链路故障恢复 [J]. 计算机仿真, 2021, 38 (6): 357-361.
- [3] 陈明霞, 王晓文, 张寒, 等. 基于 GRNN 优化的 WSNs 温室大棚异常数据检测方案 [J]. 农机化研究, 2021, 43 (8): 176-180.
- [4] 何进, 仲元昌, 孙利利, 等. 基于光伏获能的 WSNs 节点能量管理策略 [J]. 重庆大学学报: 自然科学版, 2020 (1): 90-99.
- [5] 宾康成, 张晓普, 佟训乾, 等. 基于 WSN 的分布式节点地震仪分层通信网络 [J]. 地球物理学报, 2017, 60 (11): 4313-4320.
- [6] 郁滨, 熊俊. 基于平衡迭代规约层次聚类的无线传感器网络流量异常检测方案 [J]. 电子与信息学报, 2022, 44 (1): 305-313.
- [7] 杨昊晨, 黄如. 模糊群智能驱动的软件定义型传感路由优化 [J]. 华东理工大学学报 (自然科学版), 2022, 48: 1-14.
- [8] 刘仲驰. 移动无线物联网感知层传感节点定位算法研究 [J]. 传感技术学报, 2022 (7): 985-989.
- [9] 陈卡. 基于跳距修正的 WSNs 的无线传感网络节点定位算法 [J]. 组合机床与自动化加工技术, 2021 (12): 23-26.
- [10] 李自强, 李新阳, 高泽宇, 等. 基于深度学习的自适应光学波前传感技术研究综述 [J]. 强激光与粒子束, 2021, 33 (8): 1-13.
- [11] 沈伟国, 王巍. 基于深度学习的无线网络节点个体识别技术 [J]. 通信学报, 2018, 39 (A2): 61-65.
- [12] 王海峰, 张利. 考虑节点间距的无线传感网络节点分配算法 [J]. 传感技术学报, 2022 (7): 980-984.
- [13] 马国旗, 曹丹平, 尹教建, 等. 分布式声传感井中地震信号检测数值模拟方法 [J]. 石油地球物理勘探, 2020, 55 (2): 311-320.
- [14] 苗军, 周建亭, 袁睿思, 等. 基于傅里叶变换和 CELM 的光纤传感信号的识别研究 [J]. 现代电子技术, 2019, 42 (16): 40-43, 48.
- [15] 孙浩, 陈泽宇, 吴思凡, 等. 基于策略梯度的智能车辆模型预测运动控制算法 [J]. 汽车技术, 2021 (12): 7198-7211.
- [16] 王延翔. 基于均值算法的混合噪声图像滤波算法的研究与实现 [D]. 北京: 北京邮电大学, 2010.
- [17] 张震, 安建伟, 张鹏. 噪声在图像和幻方置乱中的影响 [J]. 计算机与数字工程, 2008, 36 (5): 139-141.
- [18] 高文华, 钟衍楠. 多智能体系统的多步近似次梯度随机投影优化算法 [J]. 控制与决策, 2022, 37 (2): 431-437.
- [19] 杨艳超, 任秀丽. 基于时间序列相似度的无线传感网故障检测算法 [J]. 计算机应用研究, 2021, 38 (8): 2401-2406.
- [20] 游东东, 黎家良, 刘高俊, 等. 基于贝叶斯 BiLSTM 模型的核心网传感器故障预警方法 [J]. 华南理工大学学报 (自然科学版), 2021 (12): 43-52.