

基于深度信念网络的 WSN 链路质量预测

刘琳岚¹, 许江波¹, 李越², 杨志勇²

(1. 南昌航空大学信息工程学院, 江西 南昌 330063; 2. 南昌航空大学软件学院, 江西 南昌 330063)

摘要: 在分析现有链路质量预测模型的基础上, 提出基于深度信念网络的无线传感器网络链路质量预测模型。采用支持向量分类机对链路质量进行评估, 获得链路质量等级; 采用深度信念网络提取链路质量特征, 并采用 softmax 预测下一时刻的链路质量。在不同实验场景下, 与逻辑回归、BP 神经网络以及贝叶斯网络预测模型相比, 所提出模型具有更好的预测准确率。

关键词: 无线传感器网络; 链路质量预测; 深度信念网络; 链路质量等级

中图分类号: TP393

文献标识码: A

Deep belief network-based link quality prediction for wireless sensor network

LIU Lin-lan¹, XU Jiang-bo¹, LI Yue², YANG Zhi-yong²

(1. School of Information Engineering, Nanchang Hangkong University, Nanchang 330063, China;

2. School of Software, Nanchang Hangkong University, Nanchang 330063, China)

Abstract: After analyzing the existing link quality prediction models, a link quality prediction model for wireless sensor network was proposed, which was based on deep belief network. Support vector classification was employed to estimate link quality, so as to get link quality levels. Deep belief network was applied in extracting the features of link quality, and softmax was taken to predict the next time link quality. In different scenarios, compared with the model of link quality prediction based on logistic regression, BP neural network and Bayesian network methods, the experimental results show that the proposed prediction model achieves better precision.

Key words: wireless sensor network, link quality prediction, deep belief network, link quality level

1 引言

无线传感器网络 (WSN, wireless sensor network) 由部署在监控区域内大量感知节点以自组织方式组成, 节点以协作方式感知、采集和处理监控区域内的信息, 经过一跳或多跳汇聚到 sink 节点。WSN 作为物联网的重要组成部分, 在国防军事、环境监测、智能家居、医疗卫生、反恐抗灾等领域具有广阔的应用前景^[1]。

WSN 中, 节点间通过无线低功耗射频方式进

行通信, 容易受到多径效应、信号干扰及环境噪声等影响, 使 WSN 链路具有空间特性、非对称性、时间特性和干扰特性等多种特性, 在通信范围内存在过渡区域^[2]。高质量链路对于维护网络的连通性、建立高效的拓扑控制机制起着关键作用。若节点能够有效感知当前链路质量的变化并选择可靠路由, 可减少路由由频繁切换和数据重传带来的不必要能耗。因此, 建立一个良好的 WSN 链路质量预测机制, 可以提高网络吞吐量、延迟网络寿命和维持网络负载均衡。

收稿日期: 2017-09-21

通信作者: 刘琳岚, liulinlan@nchu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61363015, No.61762065, No.61501218); 江西省自然科学基金资助项目 (No.20171BAB202009, No.20171ACB20018); 江西省研究生创新专项基金资助项目 (No. YC2016-S348)

Foundation Items: The National Natural Science Foundation of China (No.61363015, No.61762065, No.61501218), The Natural Science Foundation of Jiangxi Province (No.20171BAB202009, No.20171ACB20018), The Innovation Foundation for Postgraduate Student of Jiangxi Province (No. YC2016-S348)

2 相关研究

2.1 链路质量评估与预测

近年来,国内外学者对 WSN 链路质量评估和预测进行了研究,可分为基于链路特性、基于概率估计和基于机器学习 3 类方法。

基于链路特性的方法,通过物理层参数对链路质量进行评估或预测,主要物理层参数如信号接收强度指示 (RSSI, received signal strength indicator)、信噪比 (SNR, signal to noise ratio) 和链路质量指示 (LQI, link quality indicator) 等。文献[3]采用局部线性核平滑方法和滑动窗口局部多项式预测方法,提出基于时间序列分析的实时链路质量预测算法,灵敏性良好,适用于节点移动频繁的网络;文献[4]改进基于误差的滤波器 (EF, error-based filter) 进行链路质量预测,在保证预测稳定性的前提下提高了对突发性链路的反应速度;文献[5]采用无参时间序列分析法预测瞬时链路质量,该方法比局部线性回归预测的精度更高且收敛速度更快,适用于动态网络。

基于概率估计的方法,通过计算接收端节点的分组接收率对链路质量进行评估或预测。文献[6]基于分组接收率 (PRR, packet reception rate)、LQI 和 SNR 建立 Triangle Metric 模型,只需较少的探测分组即可快速评估链路质量;文献[7]提出一种新的可以度量节点自身发送能力的指标 (QoF, quality of forwarding),实验表明基于该指标的聚集树协议可提高网络数据收集的吞吐量;文献[8]综合考虑 PRR、连续成功分组接收的数量、连续分组丢失数量将链路质量划分为好和薄弱,提出基于 Gilbert-Elliot 的链路质量评估机制,实验表明该方法可较准确地评估链路质量。由于 3 个参数均为统计量,适合于长期稳定的链路,不适合波动性较强的链路;文献[9]采用条件分布函数对突发 SNR 与接收确认分组进行建模,估计稳定传输周期的预期时间,使节点能够确定链路质量好或坏的保持时间。当链路质量好时,节点才传输数据。该方法同样只适合长期稳定的链路。

基于机器学习理论对链路质量进行评估或预测。文献[10]提出基于监督学习理论的链路质量预测方法,将 RSSI、上行和下行 PRR、信道负载估计、发送缓存大小、转发缓存大小 6 种参数作为模型输入的特征向量,以 0~100 的无量纲数作为预测输出值,该方法结合多种链路质量度量参数可以较

全面地反映链路质量的好坏,但是忽略了收集、计算以及存储带来的额外开销;文献[11]综合 RSSI、SNR、LQI 和 PRR,提出基于 4C 的预测机制,利用逻辑回归 (LR, logistic regression) 模型预测链路质量,实验表明该机制具有较高的预测准确度;文献[12]提出实时链路质量预测模型 (TALENT, temporal adaptive link estimator with no training),在无需先验知识和人为干预的情况下,该模型能够自适应地针对不同网络变化来预测中间链路的短期波动;文献[13]基于模糊逻辑理论设计了能够反映链路波动性和突发性的指标 (FLI, fuzzy-logic based link quality index),提出基于综合性评估的链路质量分类预测机制,采用贝叶斯网络对样本进行训练,实验表明具有良好的预测精度;文献[14]提出基于模糊支持向量回归机的链路质量预测模型,采用混沌粒子群优化算法对模型参数进行优化,实验结果表明该模型具有良好的预测精度和泛化能力。

上述 3 类方法中,基于链路特性方法所需参数可以直接获取,不需额外的计算,能耗低,但这些参数均依赖于节点,而硬件本身存在校准误差,并且忽略了因分组丢失易产生高估链路质量的问题;基于概率估计理论方法需发送大量探测分组计算 PRR 值,不仅增加了额外的通信开销,而且对链路状况的反映不够灵敏;基于机器学习方法通过离线学习能够有效地挖掘出训练样本的特征,相比上述两种方法,具有更高的准确性和稳定性,是目前 WSN 链路质量评估和预测机制的发展趋势。

2.2 支持向量分类机与深度信念网络

支持向量分类机 (SVC, support vector classification) 是由 Vapnik 等提出的一种基于 VC 维 (vapnik-chervonenkis dimension) 和结构风险最小化原则的机器学习算法^[14]。SVC 具有较为系统的理论基础和较高的学习性能,能够在一定程度上解决“维数灾难”和“过拟合”等问题,被广泛应用于事件的分类、语音识别、手写字体识别和图像识别等领域^[15]。

Hinton 等提出深度信念网络 (DBN, deep belief network),用对比散度 (CD, contrastive divergence) 快速学习算法来有效地训练受限波尔兹曼机 (RBM, restricted Boltzmann machine),并利用 Wake-sleep 算法对网络进行调优,在语音、大词汇量连续语音识别任务等领域得到了成功应用^[16]。文献[17]将纹理特征 LBP 与 DBN 的结合,实现人脸图像的准确识别;

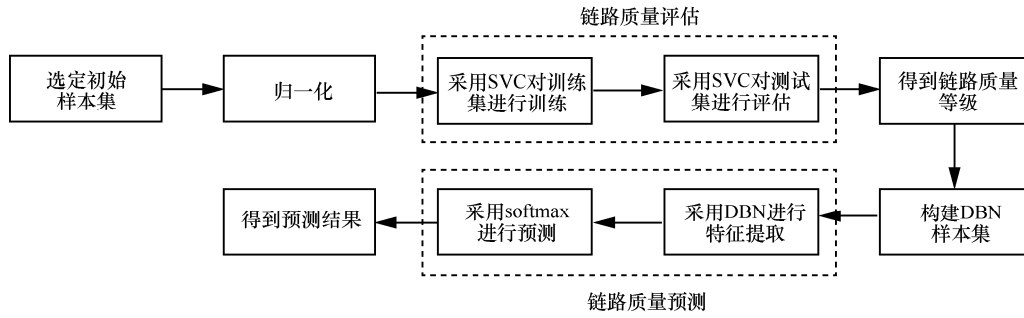


图 1 LQP-DBN 模型示意

文献[18]通过触发词来标识自然语言文本中的事件，针对文本中的事件识别，提出基于深度学习的事件识别模型，取得了较好的识别效果。

本文在分析上述链路质量评估和预测方法的基础上，提出基于 DBN 的 WSN 链路质量预测模型 (LQP-DBN, link quality prediction model based on DBN)。基于 SVC 理论对历史链路质量等级进行评估，基于 DBN 理论预测下一时刻的链路质量，具体流程如图 1 所示。

3 链路质量评估

3.1 链路质量参数的选择

物理层参数 RSSI、SNR 和 LQI 可以直接从节点获取，能快速感知链路质量的变化，PRR 可以较好地反映链路质量。考虑 WSN 受环境噪声、多径效应等因素影响，且单一链路质量参数不能全面刻画链路质量，本文选择均值 RSSI、均值 SNR 和均值 LQI 作为链路质量参数，选择 PRR 评价链路质量。

3.2 链路质量等级的划分

根据链路呈现的不同特性，可以将链路通信范围划分为高效区、过渡区和空白区。将处于高效区的链路质量定义为 very good link 等级，将处于过渡区的链路质量划分为 good link、intermediate link 和 bad link 3 个等级，将处于空白区的链路质量定义为 very bad link 等级。对 5 个等级赋予对应等级值 (level value, LV)，如表 1 所示。

表 1 链路质量等级划分及赋值

链路质量等级	PRR	等级值
very good link	90% ≤ PRR ≤ 100%	1
good link	70% ≤ PRR < 90%	2
intermediate link	40% ≤ PRR < 70%	3
bad link	10% ≤ PRR < 40%	4
very bad link	0 ≤ PRR < 10%	5

3.3 基于 SVC 的链路质量评估

将 WSN 链路质量评估问题转化为链路质量等级划分问题，对历史链路质量进行等级评估。

设初始样本集定义 $T = \{t_i\}$ ，其中， $t_i = (x_i, y_i)$ ， $i = 1, 2, 3, \dots, N$ ， N 为最大样本数，本文中输入为 $x_i = (\overline{RSSI}_i, \overline{SNR}_i, \overline{LQI}_i)$ ，输出为 $y_i = (PRR_i)$ 。

通过定义最优线性超平面，SVC 将寻找最优线性超平面问题转化为求解最优化问题。在线性可分的基础上，引入松弛因子 ξ 和惩罚因子 c 对线性不可分离问题建立线性模型。此时，分类面 $\omega x + b = 0$ 满足式(1)。

$$y_i(\omega x_i + b) \geq 1 - \xi_i \quad (1)$$

其中， ω 为法向量， b 为偏置常量， ξ 为样本点到分类边界的距离。当 $0 < \xi_i < 1$ 时，样本点能被正确分类；当 $\xi_i \geq 1$ 时，样本点被错分。在最小化目标 $\frac{1}{2} \|\omega\|^2$ 中引入惩罚项 $c \sum_{i=1}^n \xi_i$ ，得到最优超平面决策函数如式(2)所示。

$$M(x) = \text{sgn}(\sum_{i=1}^N a_i y_i (x_i, x) + b_0) \quad (2)$$

其中， a 为拉格朗日系数， sgn 为阶跃函数。

通过非线性变换 $\varphi(x)$ ，SVC 将样本空间不可分离的问题映射到高维特征空间的线性可分离问题。引入核函数 $K(x, y)$ ，SVC 巧妙解决了该非线性变换可能具有的复杂性与不易实现等问题。那么，最优超平面决策函数可改写为式(3)。

$$M(x) = \text{sgn}(\sum_{i=1}^N a_i y_i K(x_i, x) + b_0) \quad (3)$$

其中，核函数 $K(x, y)$ 需满足 Mercer 条件 $K(x, y) = (\varphi(x)\varphi(y))$ 。常见核函数有感知器核函数 (Sigmoid)、多项式核函数 (Poly) 与径向基核函数 (RBF, radial basis function) 等。RBF 是一个普

适的核函数，适用于任意分布的样本，本文选取 RBF 作为核函数，如式(4)所示。

$$K(x, y_i) = \exp\left(-\frac{\|x - x_i\|_2^2}{2\sigma^2}\right) \quad (4)$$

其中， σ 是核函数宽度。

本文设置随机选取初始样本空间 T 的 70% 作为训练集，剩余 30% 作为测试集。为提高梯度下降法求解最优解的速度，将样本数据归一化到 $[0, 1]$ ，并采用 k -折交叉验证算法 (k -fold cross validation method) 对参数进行优化^[19]，以提高链路质量评估的准确率。

4 链路质量预测

在分类评估的基础上，采用 DBN 模型提取链路质量特征，采用 softmax 回归器预测下一时刻的链路质量。

4.1 DBN 样本集的构建

采用 SVC 对历史链路质量样本进行分类评估，得到链路质量等级值集合 $lv = \{lv_i\}$ ，其中， lv_i 为第 i 个时刻链路质量等级值。利用滑动窗口机制将集合 lv 转换成 DBN 样本数据集 $T = \{(x_k, y_k)\}$ ， $x_k = (lv_k, \dots, lv_{k+n-2})$ 作为特征输入， $y_k = (lv_{k+n-1})$ 作为标签值，其中， k 为滑动窗口的序号， n 为滑动窗口的大小，窗口滑动步长为 1， $n \leq N$ ， $k \leq N - n$ 。

4.2 训练阶段

DBN 是一种具有多隐含层的神经网络，由多层无监督的 RBM 和一层有监督的 BP 神经网络堆叠而成^[16]。DBN 的训练可分为预训练和微调 2 个阶段：采用非监督贪婪逐层训练方法预训练获取权值；采用有监督学习训练 BP 神经网络，并将实际值与预测值的误差逐层反向传播，实现对权值的微调。

DBN 结构模型如图 2 所示。

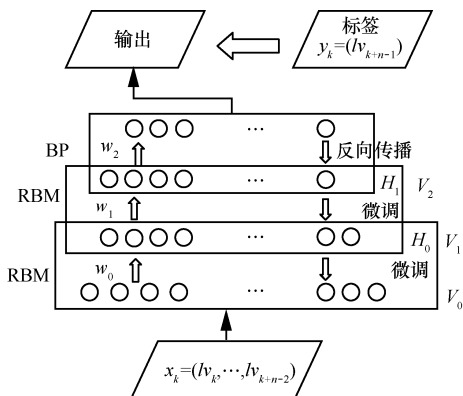


图 2 DBN 模型

本文通过实验确定各个场景的 RBM 层数，首层 RBM 输入层神经元个数为滑动窗口大小 n 减 1，通过实验确定各个场景的 n 。

RBM 由可视层 V 和隐含层 H 构成，如图 3 所示。各层内节点之间没有连接，所有节点只能在 0 和 1 之间随机取值，全概率分布满足波尔兹曼 (Boltzmann) 分布。




图 3 RBM 模型

RBM 通过非监督贪婪逐层方法预训练获得生成模型的权值。训练时先将可视值映射给隐含层单元，然后隐层单元重建为可视单元。对于有 n 个可见单元和 m 个隐单元的 RBM，用向量 V 和 H 分别表示可见单元和隐单元的状态， v_i 为第 i 个可见单元的状态， h_j 为第 j 个隐单元的状态， w_{ij} 表示可见单元 i 与隐单元 j 之间的连接权重， a_i 为可见单元 i 的偏置， b_j 为隐单元 j 的偏置。

在已知可见层的情况下，所有隐藏层节点之间相互独立，隐藏层中第 j 个节点的概率分布如式(5)所示。

$$\begin{cases} p(V | H) = \prod_i p(h_j | v) \\ p(h_j = 1 | v) = f(b_j + \sum_i w_{ij} v_i) \\ p(h_j = 0 | v) = 1 - p(h_j = 1 | v) \end{cases} \quad (5)$$

其中， p 表示概率， f 是 Sigmoid 激活函数，归一化因子，如式(6)所示。

$$f(z) = \frac{1}{1 + e^{-z}} \quad (6)$$

其中， z 为 R 变量。

在已知隐藏层的情况下，所有可见层节点之间条件独立，可见层中第 i 个节点的概率分布如式(7)所示。

$$\begin{cases} p(V | H) = \prod_i p(v_i | h) \\ p(v_i = 1 | h) = f(a_i + \sum_j w_{ij} h_j) \\ p(v_i = 0 | h) = 1 - p(v_i = 1 | h) \end{cases} \quad (7)$$

对于一组给定的状态 (v, h) ，RBM 能量函数定义如式(8)所示。

$$E(v, h | \theta) = -\sum_{i=1}^n a_i v_i - \sum_{j=1}^n b_j h_j - \sum_{i=1}^n \sum_{j=1}^n v_i w_{ij} h_j \quad (8)$$

其中，实数 $\theta = \{w_{ij}, a_i, b_j\}$ 是 RBM 的参数。当参数确定时，基于该能量函数，可以得到 (v, h) 的联合概率分布如式(9)所示。

$$P(v, h | \theta) = \frac{e^{-E(v, h | \theta)}}{Z(\theta)} \quad (9)$$

其中， E 为期望值， $Z(\theta)$ 为式(10)所示归一化因子。

$$Z(\theta) = \sum_{v, h} e^{-E(v, h | \theta)} \quad (10)$$

Hinton 等采用 CD 快速学习算法减少了 RBM 预训练时间，加快了收敛速度^[16]。CD 算法中，首先将可视单元的状态设置成一个训练样本，然后利用式(5)计算所有隐层单元的状态；在所有隐层单元被确定后，再根据式(6)确定第 i 个可见单元为 1 的概率，进而产生可见层的一个重构。各参数的更新准则如式(11)所示。

$$\begin{cases} \Delta W_{ij} = \varepsilon (\langle v_i, h_j \rangle_{\text{data}} - \langle v_i, h_j \rangle_{\text{recon}}) \\ \Delta a_i = \varepsilon (\langle v_i \rangle_{\text{data}} - \langle v_i \rangle_{\text{recon}}) \\ \Delta b_j = \varepsilon (\langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{recon}}) \end{cases} \quad (11)$$

其中， ε 为预训练学习率， $\langle \rangle_{\text{data}}$ 为训练数据集中的分布的数学期望， $\langle \rangle_{\text{recon}}$ 表示一步重构后模型定义的分布的期望。本文设置 ε 为 0.1，以均方误差 (MSE, mean square error) 评价预测准确率，如式(12)所示。

$$MSE = \frac{1}{N} \sum_{k=1}^N (y_k - Plv_k)^2 \quad (12)$$

其中， y_k 为测试集中第 k 个标签值， Plv_k 为第 k 个预测值。 MSE 值越小，预测准确率越高，模型的性能越好；反之，则越差。

DBN 模型的参数设置如表 2 所示。

4.3 预测阶段

采用 softmax 回归器对提取的特征进行预测。softmax 回归器是对 Logistic 回归器的扩展，是一种可以解决多分类问题的监督学习算法^[20]。本文将链路质量划分成 5 个等级，所以类别数为 5。

表 2 DBN 模型参数设置

参数属性	参数值
首层 RBM 输入神经元个数	49,59,69,79,89,99,109
RBM 学习率	0.1
训练最大迭代次数	50
RBM 的层数	2,3,4,5,6
预测评价指标	MSE

5 实验结果与分析

实验选用美国 Crossbow 公司的 TelosB 节点，该系列节点遵循 IEEE 802.15.4 协议，通信范围约 100 m。通过在 TinyOS 系统下运行 NesC 程序以提取样本的各维数据^[14]，在图 4 所示无线传感器网络链路质量测试平台 (WSN-LQTP, link quality testing platform for wireless sensor network) 上收集不同实验场景下的链路质量参数，在 Matlab 仿真平台上实现 LQP-DBN 模型。

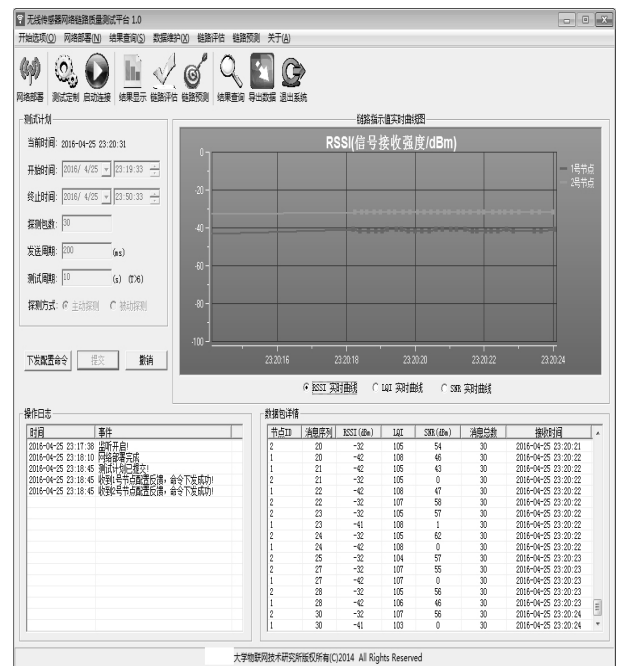


图 4 WSN-LQTP

5.1 实验参数设置与数据采集

实验考虑了环境中的噪声、邻近信道的干扰、障碍物和无线电波的多径效应对链路质量的影响，设定 3 个场景分别如图 5~图 7 所示。场景 1 为校园树林，场景 2 为校园室内走廊，场景 3 为校园广场，每个实验场景中部署了一个小型的 WSN，包括 2 个发送节点 TX-1、TX-2，一个接收 sink 节点 RX-1。

sink 节点通过 USB 接口与 WSN-LQTP 平台通信，实验参数设置如表 3 所示。通过 WSN-LQTP 平台收集节点的 ID、消息序列、RSSI、LQI、SNR、PRR、消息总数和接收时间等信息。

参数属性	参数值
发送功率/dBm	31
信道	26
探测分组数量/个	30
分组发送速率/(个·秒 ⁻¹)	5
发送周期/ms	200
测试周期/s	10
节点间距/m	20




图 5 场景 1




图 6 场景 2




图 7 场景 3

5.2 实验结果与分析

在 Matlab 上对 3 个场景的实验数据进行分析，得到 PRR 时序图如图 8~图 10 所示。




图 8 场景 1 的实验数据




图 9 场景 2 的实验数据

由图 8 可知，场景 1 下链路波动性较大，链路稳定性一般，突发性不高，这是因为该场景的主干扰源是树木、石头等障碍物，节点通信过程中易产生多径效应；由图 9 可知，场景 2 下链路质量较高且稳定性良好，这是因为场景 2 下的干扰源较单一，

主要为室内 Wi-Fi 信号；由图 10 可知，场景 3 下，在 0~200 时段链路呈现高突发性、不稳定性及波动性，之后链路整体表现稳定，这是因为该时间段是学生上、下课时间，大量人员走动、人员携带移动设备产生的无线信号均对链路产生干扰。




图 10 场景 3 的实验数据

RBM 层数与窗口大小 n 是影响预测性能和主要指标。本文设置 RBM 层数分别为 2、3、4、5， n 为 50、60、70、80、90、100、110，通过实验确定各个场景的 RBM 层数与窗口大小 n 。3 个场景下不同参数设置得到 LQP-DBN 预测模型的 MSE 值分别如表 4~表 6 所示。

由表 4~表 6 可知，场景 1 中， n 为 100、RBM 层数为 4 时，LQP-DBN 模型的预测性能最优；场景 2 中， n 为 100、RBM 层数为 5 时，LQP-DBN 模型的预测性能最优；场景 3 中， n 为 60、RBM 层数为 4 时，LQP-DBN 模型的预测性能最优。汇总如表 7 所示。

为进一步验证 LQP-DBN 模型的预测性能，在 3 种实验场景下，与 BP 模型^[21]、LR 模型^[11]、贝叶斯网络^[13] (BN, bayesian network) 模型进行对比，结果如表 8 所示。

表 4 场景 1 下 LQP-DBN 模型的 MSE

n 的值	MSE				
	2 层 RBM	3 层 RBM	4 层 RBM	5 层 RBM	6 层 RBM
50	0.312 500	0.322 920	0.328 130	0.343 750	0.307 290
60	0.402 120	0.333 330	0.312 170	0.349 210	0.328 040
70	0.306 450	0.295 700	0.301 080	0.317 200	0.370 970
80	0.284 150	0.311 480	0.371 580	0.377 050	0.322 40
90	0.338 890	0.288 890	0.305 560	0.366 670	0.277 78
100	0.305 080	0.338 980	0.265 540	0.378 530	0.344 63
110	0.373 560	0.344 830	0.310 340	0.327 590	0.304 60

表 5 场景 2 下 LQP-DBN 模型的 MSE

n 的值	MSE				
	2 层 RBM	3 层 RBM	4 层 RBM	5 层 RBM	6 层 RBM
50	0.407 960	0.333 330	0.358 210	0.452 740	0.313 43
60	0.459 600	0.409 090	0.439 390	0.368 690	0.247 47
70	0.271 790	0.492 310	0.394 870	0.548 720	0.338 46
80	0.390 630	0.348 960	0.385 420	0.463 540	0.317 71
90	0.222 220	0.428 570	0.460 320	0.280 420	0.174 60
100	0.559 140	0.208 600	0.268 820	0.134 410	0.408 60
110	0.196 720	0.426 230	0.431 690	0.387 980	0.524 459

表 6 场景 3 下 LQP-DBN 模型 MSE

n 的值	MSE				
	2 层 RBM	3 层 RBM	4 层 RBM	5 层 RBM	6 层 RBM
50	0.106 740	0.073 034	0.067 416	0.095 506	0.106 740
60	0.114 290	0.102 860	0.057 143	0.102 860	0.108 570
70	0.122 090	0.093 023	0.081 395	0.081 395	0.087 209
80	0.100 590	0.094 675	0.088 757	0.078 313	0.088 757
90	0.072 289	0.108 430	0.090 361	0.088 757	0.114 460
100	0.797 550	0.092 025	0.110 430	0.067 485	0.098 160
110	0.087 50	0.125 00	0.093 750	0.106 250	0.093 750

表 7 LQP-DBN 模型的窗口 n 和 RBM 层数

实验场景	n	RBM 层数	MSE
场景 1	100	4	0.265 540
场景 2	100	5	0.134 410
场景 3	60	4	0.057 143

表 8 3 种实验场景下的 MSE

实验场景	BP	LR	BN	LQP-DBN
场景 1	0.349 500	0.339 806	0.330 023	0.265 540
场景 2	0.104 200	0.098 958	0.103 482	0.057 143
场景 3	0.513 900	0.148 148	0.151 005	0.134 410

场景 1、场景 2 下，LQP-DBN 模型的预测性能优于其他模型；场景 3 下，LQP-DBN 模型的预测性能明显优于 BP 模型与 BN 模型，略优于 LR 模型。这是因为 LQP-DBN 模型为深度学习，LR、BP 神经网络为浅层学习，深度学习的特征提取能力比浅层学习更强；BN 模型对链路质量参数之间的相关性敏感，性能与 LR 相近，优于 BP 神经网络；LR 模型的自变量多重共线性较为敏感，稳定场景下链路质量参数相关性较强，导致 LR 模型预测性能不理想，但是不稳定场景下链路质量参数相关性相对较弱，其预测性能接近于 LQP-DBN 模型。

在场景 2 下验证模型的时间复杂度，以 7:3 的比例划分训练测试集，取 LQP-DBN 模型的 n 为 60、RBM 层数为 4，取 BP 模型的隐含层数为 9、学习率为 0.1，平均训练时间、平均预测时间如表 9 所示。

表 9 模型的时间复杂度

模型	平均训练时间/s	平均预测时间/s	模型类别
BP	3.354 0	0.031 2	非线性
LR	0.483 6	0.001 2	线性
BN	2.277 6	0.015 6	非线性
LQP-DBN	67.813 6	0.075 4	非线性

由表 9 可知，LQP-DBN 模型的训练时间、预测时间较长，这是因为多层的 RBM 训练与预测，使计算复杂度较高。

6 结束语

本文在分析现有链路质量评估和预测方法的基础上，综合考虑物理层与链路层对链路质量的影响，可弥补单一链路质量参数评价的不足，能够更全面地反映链路质量的状态；将 WSN 链路质量评估问题转化为链路质量等级划分问题，借助 SVC 在分类上的优势，并采用 k-折交叉验证算法对 SVC 的参数进行优化，从而实现对历史链路质量的等级评估；借助 DBN 在特征提取上的优势，运用离线训练得到的等级划分，采用 softmax 回归器预测下一时刻的链路质量。3 种实验场景下的预测结果表明，与 BP 模型、LR 模型以及 BN 模型相比，LQP-DBN 模型具有更高的准确率和适用性。

LQP-DBN 模型存在着计算成本高、效率较低等问题，本文以链路质量预测准确率为目标，如何在保证准确率的前提下，降低模型的训练时间与预测时间，是下一步研究工作的方向之一。

参考文献：

[1] 付帅, 马建峰, 李洪涛, 等. 无线传感器网络中匿名的聚合节点选举协议[J]. 通信学报, 2015, 36(2):88-97.
FU S, MA J F, LI H T, et al. Anonymous aggregator election protocol for wireless sensor networks[J]. Journal on Communications, 2015, 36(2):88-97.

[2] BACCOUR N, KOUB, ANIS A, et al. Radio link quality estimation in wireless sensor networks: a survey[J]. ACM Transactions on Sensor Networks, 2012, 8(4):688-722.

[3] 翁丽娜, 杨杰, 柯海舟, 等. 基于时间序列分析的链路质量预测和稳定路由算法研究[J]. 电子与信息学报, 2011, 33(4):885-890.

- WENG L N, YANG J, KE H Z, et al. A time series analysis-based link quality prediction algorithm and its application to reliable routing[J]. Journal of Electronics & Information Technology, 2011, 33(4):885-890.
- [4] 尚凤军, 龚文娟, 耿哲. 基于链路预测和网络编码的 MAC 机制[J]. 通信学报, 2016, 37(1):17-27.
SHAN F J, GONG W J, GENG Z. MAC mechanism based on link prediction and network coding[J]. Journal on Communications, 2016, 37(1):17-27.
- [5] WENG L N, ZHANG P, FENG Z Y, et al. Short-term link quality prediction using non-parametric time series analysis[J]. Science China Information Sciences, 2015, 58(8):1-15.
- [6] BOANO C A, ZUNIGA M A, VOIGT T, et al. The triangle metric: fast link quality estimation for mobile wireless sensor networks[C]//The 19th International Conference on Computer Communications and Networks. 2010:1-7.
- [7] WANG J, LIU Y, HE Y, et al. QoF: towards comprehensive path quality measurement in wireless sensor networks[J]. IEEE Transactions on Parallel and Distributed Systems, 2014, 25(4):1003-1013.
- [8] BILDEA A, ALPHAND O, ROUSSEAU F, et al. Link quality estimation with the gilbert-elliott model for wireless sensor networks [J]. Kips Transactions Partc, 2015, 88(4):495-504.
- [9] WEN J, AASAR Z, DARGIE W. A link quality estimation model for energy-efficient wireless sensor networks[C]//The 2015 IEEE International Conference on Communications (ICC). 2015:6694-6700.
- [10] WANG Y, MARTONOSI M, PEH L S. Predicting link quality using supervised learning in wireless sensor networks[J]. ACM Sigmoblie Mobile Computing & Communications Review, 2007, 11(3):71-83.
- [11] LIU T, CERPA A E. Foresee (4C): wireless link prediction using link features[C]//International Conference on Information Processing in Sensor Networks. 2011:294-305.
- [12] LIU T, CERPA A E. Talent: temporal adaptive link estimator with no training[C]//The 10th ACM Conference on Embedded Network Sensor Systems. 2012:253-266.
- [13] 郭志强, 王沁, 万亚东, 等. 基于综合性评估的无线链路质量分类预测机制[J]. 计算机研究与发展, 2013, 50(6):1227-1238.
GUO Z Q, WANG Q, WAN Y D, et al. A classification prediction mechanism based on comprehensive assessment for wireless link quality[J]. Journal of Computer Research & Development, 2013, 5(6):1227-1238.
- [14] 舒坚, 汤津, 刘琳岚, 等. 基于模糊支持向量回归机的 WSNs 链路质量预测[J]. 计算机研究与发展, 2015, 52(8):1842-1851.
SHU J, TANG J, LIU L L, et al. Fuzzy support vector regression-based link quality prediction model for wireless sensor networks[J]. Journal of Computer Research & Development, 2015, 52(8):1842-1851.
- [15] 卢记仓, 刘粉林, 罗向阳, 等. 基于辨识性统计特征的 PQ 隐密图像识别算法[J]. 通信学报, 2015, 36(3):197-206.
LU J C, LIU F L, LUO X Y, et al. Recognition of PQ stego images based on identifiable statistical feature[J]. Journal on Communications, 2015, 36(3):197-206.
- [16] MOHAMMAD A K, MOHAMMAD M H. Deep belief network training improvement using elite samples minimizing free energy[J]. International Journal of Pattern Recognition & Artificial Intelligence, 2015, 29(5):1-18.
- [17] 梁淑芬, 刘银华, 李立琛. 基于 LBP 和深度学习的非限制条件下人脸识别算法[J]. 通信学报, 2014, 35(6):154-160.
LIANG S F, LIU Y H, LI L C. Face recognition under unconstrained based on LBP and deep learning. Chinese relation extraction based on deep belief nets[J]. Journal on Communications, 2014, 35(6):154-160.
- [18] 张亚军, 刘宗田, 周文. 基于深度信念网络的事件识别[J]. 电子学报, 2017, 45(6):1415-1423.
ZHANG Y J, LIU Z T, ZHOU W. Event recognition based on deep belief network[J]. ACTA Electronica Sinica, 2017, 45(6):1415-1423.
- [19] 顾珊波, 邵枫, 蒋刚毅, 等. 基于支持向量回归的立体图像客观质量评价模型[J]. 电子与信息学报, 2012, 34(2):368-374.
GU S B, SHAO F, JIANG G Y, et al. Objective stereoscopic image quality assessment model based on support vector regression[J]. Journal of Electronics & Information Technology, 2012, 34(2):368-374.
- [20] RAHHAL M M A, BAZI Y, ALHICHRI H, et al. Deep learning approach for active classification of electrocardiogram signals[J]. Information Sciences, 2016, 345(C):340-354.
- [21] 刘琳岚, 樊佑磊, 舒坚, 等. 一种基于 BP 神经网络的 WSNs 链路质量预测方法[J]. 计算机研究与发展, 2011, 48(Suppl):212-215.
LIU L L, FAN Y L, SHU J, et al. A link quality prediction method for WSNs based on BP artificial neural network[J]. Journal of Computer Research & Development, 2011, 48(Suppl):212-215.

作者简介:



刘琳岚 (1968-), 女, 湖南东安人, 南昌航空大学教授, 主要研究方向为物联网、软件工程。

许江波 (1991-), 男, 安徽桐城人, 南昌航空大学硕士生, 主要研究方向为无线传感器网络。

李越 (1991-), 男, 江西抚州人, 南昌航空大学硕士生, 主要研究方向为无线传感器网络。

杨志勇 (1982-), 男, 河南开封人, 南昌航空大学讲师, 主要研究方向为物联网。