

文章编号:1007-5321(2018)01-0134-05

DOI:10.13190/j.jbupt.2017-185

基于超限学习机的 WSNs 链路质量评估方法

刘琳岚¹, 许江波¹, 陈宇斌², 舒坚²

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

摘要: 提出基于超限学习机的链路质量评估方法. 选择非对称性指标、信噪比变异系数、均值信噪比为链路质量参数,以包接收率为链路质量评价指标,划分链路质量等级;采用粒子群算法优化超限学习机的输入层权重和偏置参数,构建链路质量评估模型. 不同场景下的实验结果表明,与支持向量分类机评估方法相比,所提方法具有更高的评估准确率.

关键词: 无线传感器网络; 链路质量评估; 超限学习机; 粒子群优化算法

中图分类号: TP393 **文献标志码:** A

A Link Quality Estimation Method for WSNs Based on Extreme Learning Machine

LIU Lin-lan¹, XU Jiang-bo¹, CHEN Yu-bin², SHU Jian²

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

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

Abstract: An approach of estimating link quality was proposed which is based on extreme learning machine. The index of link asymmetry, the coefficient of variation of signal to noise ratio and mean signal to noise ratio are chosen as link quality parameters. Link quality level is classified by link packet receive rate which is the evaluation index. Particle swarm optimization algorithm is employed to optimize input weights and offset parameter, so that link quality model is built. In different scenarios, compared with the support vector classification machine estimate methods, the experimental results show that the proposed estimation method achieves better precision.

Key words: wireless sensor networks; link quality estimation; extreme learning machine; particle swarm optimization algorithm

无线传感器网络 (WSNs, wireless sensor networks) 是一种由大量部署在监控区域的节点以自组织方式形成的网络,广泛应用于军事、环境监测、交通运输及医疗保健等领域^[1]. 由于受环境噪声和多径效应影响,采用低功率射频通信的节点间链路质量呈现出波动性、非对称性等时空特性,导致节点间

通信具有不稳定性,如能有效评估链路质量,不仅能保障数据稳定传输,提高网络吞吐率,还能降低节点能耗,延长网络的生存周期.

国内外在 WSNs 链路质量评估方面进行了大量的研究,主要包括基于物理层参数的评估、基于链路层参数的评估、综合性评估以及基于机器学习的评

收稿日期: 2017-09-15

基金项目: 国家自然科学基金项目 (61363015, 61762065, 61501218, 61501217); 江西省自然科学基金重点项目 (20171BAB202009, 20171ACB20018); 江西省研究生创新专项项目 (YC2016-S348)

作者简介: 刘琳岚 (1968—), 女, 教授, 硕士生导师, E-mail: liulinlan@nchu.edu.cn.

估. 相比单一物理层参数或链路层参数的评估方法, 综合性评估方法能更准确、更全面地评估链路质量^[2]. 典型的综合性评估方法有基于模糊规则的链路质量评估方法^[3]、基于模糊逻辑的链路质量综合评价指标^[4]以及优化的基于模型规则链路评估方法^[5]等. 机器学习的方法越来越多地应用到链路质量评估中^[6-7].

超限学习机(ELM, extreme learning machine)由Huang等提出, 是一种随机权值的单隐层前馈神经网络学习算法, 算法对参数设置要求低, 模型简单, 广泛应用于语种识别、图像识别等多分类问题^[8].

笔者从链路的非对称性、波动性以及信道质量 3 个方面综合评估链路质量, 借助 ELM 学习速度快、模型简单、分类精度较高的优势, 采用粒子群优化算法(PSO, particle swarm optimization algorithm)优化 ELM^[9], 构建基于 PSO 优化的 ELM 的链路质量评估模型(LQE-IELM, link quality estimation model based on improved extreme learning machine).

1 链路质量参数的选择

考虑 WSNs 受环境噪声以及多径效应等因素的影响, 链路质量呈现出波动性以及非对称性, 通过上行和下行的均值信噪比(ASNR, average signal to noise ratio)差的绝对值来定义链路的非对称性指标(ASL, asymmetry level)^[3], 如

$$\varphi = |\bar{\chi}_0 - \bar{\chi}_1| \quad (1)$$

其中: φ 为 ASL 的值, $\bar{\chi}_0$ 为上行 ASNR, $\bar{\chi}_1$ 为下行 ASNR.

通过信噪比(SNR, signal to noise ratio)的变异系数(CV, coefficient of variation)^[4]来度量波动性, 如

$$\gamma = \sigma(\chi) / \mu(\chi) \quad (2)$$

其中: γ 为 CV 的值, $\sigma(\chi)$ 为 SNR 的方差, $\mu(\chi)$ 为 SNR 均值. 通过 ASNR 来度量信道质量.

选择 ASL、CV 以及 ASNR 作为链路质量参数, 选择包接收率(PRR, packet reception rate)来评价链路质量.

2 链路质量等级的划分

用链路质量等级来描述链路质量状态, 根据 PRR 将链路质量划分为 5 个等级, 对应等级值为 1~5, 如表 1 所示.

表 1 链路质量等级

等级值	链路质量描述	PRR
1	非常差	[0, 10)
2	差	[10, 40)
3	一般	[40, 70)
4	好	[70, 90)
5	非常好	[90, 100]

3 基于 ELM 的链路质量评估

3.1 ELM 链路质量评估模型

采用 ELM 构建链路质量评估模型, 模型网络结构如图 1 所示.

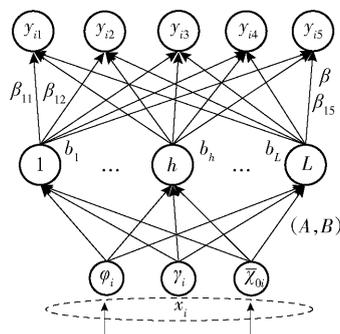


图 1 ELM 链路质量评估模型结构

设初始样本集为 $T = \{(\mathbf{x}_i, \mathbf{y}_i) \mid (i = 1, 2, \dots, N)\}$, N 为样本总数, $\mathbf{x}_i = (\varphi_i, \gamma_i, \bar{\chi}_{0i})^T$ 为第 i 个样本对应的 ASL、CV 以及上行 ASNR, $\mathbf{y}_i = (y_{i1}, y_{i2}, y_{i3}, y_{i4}, y_{i5})$ 为第 i 个样本的链路质量等级值 one-hot 编码. 对于一个有 L 个隐含层节点的 ELM 网络, 有

$$o_i = \sum_{h=1}^L \beta_h G(\mathbf{a}_h \mathbf{x}_i + b_h) \quad (3)$$

其中: $\mathbf{o}_i = (o_{i1}, o_{i2}, o_{i3}, o_{i4}, o_{i5})$ 为 ELM 在输出层上的输出; h 为隐含层节点数; $\beta_h = (\beta_{h1}, \beta_{h2}, \beta_{h3}, \beta_{h4}, \beta_{h5})$ 为第 h 个隐含层节点到输出节点的权重矩阵; \mathbf{a}_h 为隐含层节点与输入层节点的权值矩阵, $\mathbf{a}_h = (\rho_1, \rho_2, \dots, \rho_r, \dots, \rho_v)^T$, 其中 ρ_r 为第 h 个隐含层节点与第 r 个输入层节点的权重, v 为输入层节点个数, 本文中为 3; b_h 为第 h 个隐含层节点的偏置; G 为激活函数, 选用 Sigmoid 作为激活函数.

ELM 训练的目标是使得期望输出与实际输出的误差最小, 即

$$\sum_{i=1}^N \|\mathbf{o}_i - \mathbf{y}_i\| = 0 \quad (4)$$

存在 $\beta_h, \mathbf{a}_h, b_h$, 使得

$$y_i = \sum_{h=1}^L \beta_h G(a_h x_i + b_h), i=1, 2, \dots, N \quad (5)$$

转换成矩阵形式,即

$$H\mathbf{B} = \mathbf{Y} \quad (6)$$

其中: \mathbf{H} 为隐含层节点的输出矩阵,

$$\mathbf{H} = \begin{bmatrix} G(\mathbf{a}_1 \mathbf{x}_1 + b_1) & \cdots & G(\mathbf{a}_L \mathbf{x}_1 + b_L) \\ \vdots & & \vdots \\ G(\mathbf{a}_1 \mathbf{x}_N + b_1) & \cdots & G(\mathbf{a}_L \mathbf{x}_N + b_L) \end{bmatrix} \quad (7)$$

β 为隐含层节点到输出层的权重矩阵,

$$\beta = (\beta_1, \beta_2, \dots, \beta_L)^T \quad (8)$$

\mathbf{Y} 为期望输出的链路质量等级编码矩阵,

$$\mathbf{Y} = (y_1, y_2, \dots, y_N)^T \quad (9)$$

在 ELM 输入层权重与偏置参数随机确定后,隐含层节点的输出矩阵 \mathbf{H} 得到确定,得到具有最小范数的唯一解 $\hat{\beta}$,

$$\hat{\beta} = \mathbf{H}^+ \mathbf{Y} \quad (10)$$

其中: \mathbf{H}^+ 为 \mathbf{H} 的 Moore-Penrose 广义逆, $\hat{\beta}$ 为隐含层节点到输出层的权重.

将初始样本集按 7:3 划分为训练集和测试集,隐含层节点数取经验值 150,训练得到 ELM 链路质量评估的模型 (LQE-ELM, link quality estimation model based on extreme learning machine).

3.2 评估模型参数的优化

ELM 中输入层权重矩阵 $\mathbf{A} = (a_1, a_2, \dots, a_L)$ 和偏置参数矩阵 $\mathbf{B} = (b_1, b_2, \dots, b_L)$ 是随机生成的,在隐含层节点数确定的情况下,其取值势必影响 ELM 评估模型的效果.采用 PSO 优化 ELM 模型参数 \mathbf{A} 、 \mathbf{B} ,得到 LQE-IELM,

$$V = \text{LQE-IELM}(\mathbf{A}, \mathbf{B}, \hat{\beta}, G(x), L, \zeta) \quad (11)$$

其中: V 为链路质量等级值, \mathbf{A} 的维度为 $L \times v$, v 为输入层节点个数; \mathbf{B} 的维度为 $L \times 1$; ζ 为模型输入, $\zeta = (\varphi, \gamma, \bar{x}_0)$.

PSO 是一种模拟鸟群觅食的仿生优化算法,每个粒子都表示问题的一个解,具有实现容易、精度高、收敛快等优点^[9].将 ELM 中 \mathbf{A} 和 \mathbf{B} 转换为 $\Psi \times 1$ 的矩阵 $\boldsymbol{\eta}$,其中 Ψ 为

$$\Psi = L(v+1) \quad (12)$$

定义粒子位置为 $\boldsymbol{\eta}$,粒子的速度定义为 v ,同样是 $\Psi \times 1$ 的矩阵.

将 ELM 模型的链路质量评估准确率作为粒子的适应度,适应度越大表示粒子位置越优.粒子通过式(13)更新自己的速度,利用式(14)更新自己的位置,得到评估准确率较高的 ELM 模型.

$$v_{kd}^{t+1} = wv_{kd}^t + c_1 \ell(\mathbf{h}_{kd}^p - \boldsymbol{\eta}_{kd}^t) + c_2 \ell(\mathbf{h}_{kd}^g - \boldsymbol{\eta}_{kd}^t) \quad (13)$$

其中: v_{kd}^{t+1} 、 v_{kd}^t 分别为第 k 个粒子在第 $t+1$ 和 t 次迭代中第 d 维上的速度, $d=1, 2, \dots, \Psi$; ℓ 为随机生成的范围在 $[0, 1]$ 之间的数; \mathbf{h}_{kd}^p 、 \mathbf{h}_{kd}^g 分别为粒子个体最优和群体最优的位置; w 为惯性权重,取经验值 1; c_1 和 c_2 为学习因子,分别取 1.5 和 1.7^[9].

$$\boldsymbol{\eta}_{kd}^{t+1} = \boldsymbol{\eta}_{kd}^t + v_{kd}^{t+1} \quad (14)$$

其中 $\boldsymbol{\eta}_{kd}^{t+1}$ 、 $\boldsymbol{\eta}_{kd}^t$ 分别为第 k 个粒子在第 $t+1$ 和 t 次迭代中的位置.

算法 1

输入:最大迭代次数 e ,期望准确率 τ ,隐含层节点个数 ϑ ,粒子种群数 λ ,数据集 U .

输出:LQE-IELM.

步骤 1 初始化参数, $e=50$, $\tau=0.95$, $\vartheta=150$, $\lambda=20$.

步骤 2 通过 ELM 评估模型输出得到初始粒子位置 $\boldsymbol{\eta}$,记录粒子 $\hat{\beta}$ 矩阵,依据评估准确率确定种群中的最优粒子.

步骤 3 粒子根据式(13)和式(14)更新自身速度和位置,结合 $\hat{\beta}$ 矩阵,由 ELM 评估模型计算得到评估准确率,更新 \mathbf{h}_{kd}^p 和 \mathbf{h}_{kd}^g .

步骤 4 若迭代次数大于 e 或模型准确率高于 τ ,则停止搜索,进入步骤 5;若未达到最大迭代次数且准确率低于 τ ,则返回步骤 3.

步骤 5 输出 LQE-IELM.

4 实验结果与分析

采用美国 CrossBow 公司研制的 TelosB 节点和如图 2 所示的南昌航空大学物联网技术研究所开发的链路质量测试平台在不同场景下获取链路质量信

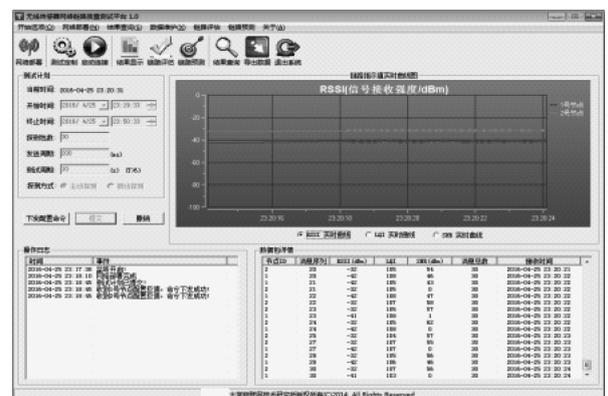


图 2 链路质量测试平台

息. 通过 Matlab 仿真平台实现 LQE-IELM, 并与 ELM、支持向量分类机(SVC, support vector classification machine)^[7] 链路质量评估方法进行了对比实验.

4.1 实验场景

选择小树林、室内走廊、广场 3 个场景进行链路质量测试实验, 构建星形网络, 包括 1 个 Sink 节点和 8 个感知节点, 如图 3 所示. 实验参数设置如表 2 所示.



图 3 实验场景图

表 2 实验参数设置

参数属性	参数值
发送功率/dBm	0
信道	26
探测包数/个	30
探测方式	主动探测
发包速率/(个·s ⁻¹)	10
测试周期/s	10

4.2 结果与分析

每个实验场景的实验数据都为 3 373 条, 其中训练样本 2 361 条, 测试样本 1 012 条, 平均训练 10 次, 随机抽取 20 个连续的测试样本, 得到 LQE-IELM 的评估结果如图 4~图 6 所示. 图中实际值为链路质量测试样本的链路质量等级值, LQE-SVC 评估值为采用基于 k -折交叉验证算法优化的 SVC 方法^[7] 得到的链路质量评估等级值, LQE-ELM 评估值为采用 ELM 方法得到的链路质量评估等级值, LQE-IELM 评估值为采用 LQE-IELM 方法得到的链路质量评估等级值.

由图 4~图 6 可以看出, LQE-IELM 评估值的分布与实际值分布基本吻合, LQE-ELM 评估值与 LQE-SVC 评估值的分布与实际值吻合度不高.

3 种方法在不同场景下的评估准确率见表 3.

由表 3 可以看出, 传统 ELM 链路质量评估方法

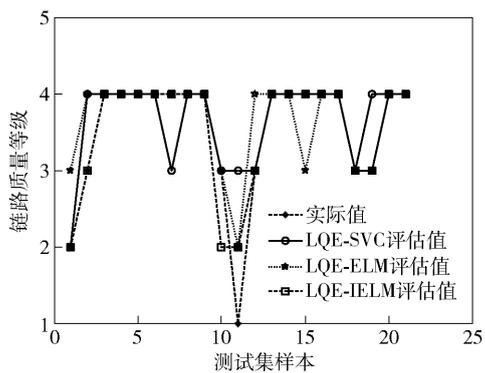


图 4 小树林场景评估结果

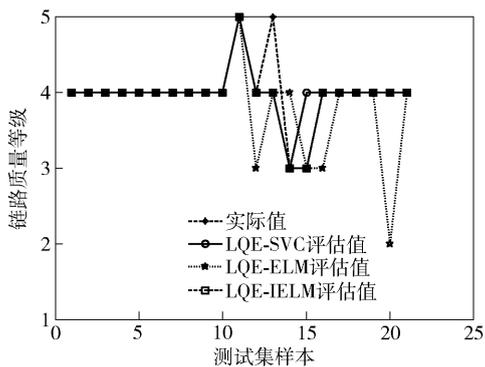


图 5 走廊场景评估结果

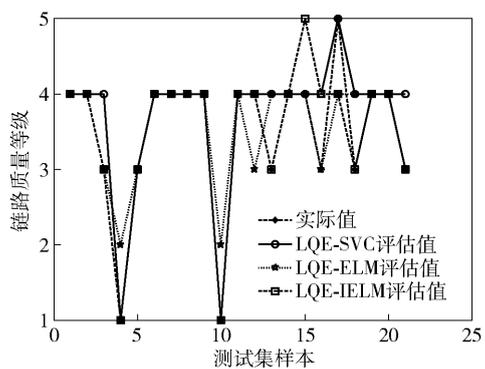


图 6 广场场景评估结果

表 3 不同场景下的评估准确率 %

模型	小树林	走廊	广场
LQE-ELM	88.23	90.23	82.48
LQE-SVC	90.20	93.31	83.12
LQE-IELM	93.24	94.23	89.13

与 k -折交叉检验优化的 SVC 方法相比, 评估准确率较低; 所提出的 LQE-IELM 链路质量评估方法与传统 ELM 以及 k -折交叉检验优化的 SVC 评估方法相比, 具有更高的评估准确率.

5 结束语

采用 ELM 的链路质量评估方法,选择 ASL、CV、ASNR 作为链路质量参数,可弥补单一链路质量参数的不足,以包接收率为链路质量评价指标,划分链路质量等级;采用 PSO 优化 ELM 输入层权重和偏置参数,构建基于粒子群优化的链路质量评估模型 LQE-IELM. 3 种场景下的实验结果表明,与 SVC 评估方法相比,所提出的方法具有较高的评估准确率.

参考文献:

- [1] 刘洲洲,王福豹. 能量有效的无线传感器网络无标度拓扑模型[J]. 北京邮电大学学报, 2015, 38(1): 87-91.
Liu Zhouzhou, Wang Fubao. Scale-free topology for wireless sensor networks with energy efficient characteristics [J]. Journal of Beijing University of Posts and Telecommunications, 2015, 38(1): 87-91.
- [2] Baccour N, Koubâa A, Jamâa M B, et al. RadiaLE: a framework for designing and assessing link quality estimators in wireless sensor networks[J]. Ad Hoc Networks, 2011, 9(7): 1165-1185.
- [3] Baccour N, Koubaa A, Youssef H, et al. Reliable link quality estimation in low-power wireless networks and its impact on tree-routing [J]. Ad Hoc Networks, 2015 (27): 1-25.
- [4] 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 Zhiqiang, Wang Qin, Wan Yadong, et al. A classification prediction mechanism based on comprehensive assessment for wireless link quality[J]. Journal of Computer Research and Development, 2013, 50(6): 1227-1238.
- [5] Rekik S, Baccour N, Jmaiel M, et al. Low-power link quality estimation in smart grid environments[C] // 11th Wireless Communications and Mobile Computing Conference (IWCMC). Dubrovnik: IEEE Press, 2015: 1211-1216.
- [6] Liu Tao, Cerpa Alberto E. Foresee (4C): wireless link prediction using link features [C] // 10th International Conference on Information Processing in Sensor Networks. Chicago: IEEE Press, 2011: 294-305.
- [7] Shu Jian, Liu Song, Liu Linlan, et al. Research on link quality estimation mechanism for wireless sensor networks based on support vector machine[J]. Chinese Journal of Electronics, 2017, 26(2): 377-384.
- [8] Cao Jiuwen, Zhang Kai, Luo Minxia, et al. Extreme learning machine and adaptive sparse representation for image classification [J]. Neural Networks, 2016, 81 (C): 91-102.
- [9] Yadav B, Ch S, Mathur S, et al. Estimation of in-situ bioremediation system cost using a hybrid extreme learning machine (ELM)-particle swarm optimization approach [J]. Journal of Hydrology, 2016(543): 373-385.