

基于决策树的Wi-Fi网络链路质量估计方法研究

黄高远, 施伟斌, 靖浩翔, 洪芳吟

上海理工大学光电信息与计算机工程学院, 上海

收稿日期: 2025年3月16日; 录用日期: 2025年4月9日; 发布日期: 2025年4月17日

摘 要

目前机器学习正在成为Wi-Fi链路质量估计的主要工具, 模型的泛化能力对于链路质量估计尤为重要。现有方法在训练模型时, 需要在不同条件下采集多组数据, 建立模型的成本较高, 并且多数使用较复杂的模型。提出一种基于决策树的链路质量估计方法, 在预处理阶段对数据进行最小值填充和EWMA处理, 选择RSSI和RSSI均值作为模型输入参数, 利用一组噪声条件下采集的数据建模, 分别进行链路质量分类和回归估计。与现有方法比较, 提出的方法以较少的数据就可以获得良好的泛化性能。实验结果表明, 该方法的平均准确率达到96%, 训练时间为0.01 s, 回归估计的平均绝对误差为0.025。

关键词

Wi-Fi, 链路估计, EWMA, 分类, 回归

Research on Decision Tree Based Link Quality Estimation Methods for Wi-Fi Networks

Gaoyuan Huang, Weibin Shi, Haoxiang Jing, Fanghan Hong

School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Mar. 16th, 2025; accepted: Apr. 9th, 2025; published: Apr. 17th, 2025

Abstract

Currently, machine learning is emerging as a primary tool for Wi-Fi link quality estimation, with the model's generalization ability being particularly crucial for accurate estimations. Traditional

文章引用: 黄高远, 施伟斌, 靖浩翔, 洪芳吟. 基于决策树的 Wi-Fi 网络链路质量估计方法研究[J]. 建模与仿真, 2025, 14(4): 486-498. DOI: 10.12677/mos.2025.144303

methods often require collecting multiple datasets under varying conditions to train the models, leading to high costs and often relying on complex model architectures. This paper presents a link quality estimation approach based on decision trees. In the preprocessing stage, the data undergoes minimum value filling and exponentially weighted moving average (EWMA) filtering. The model inputs are selected as the RSSI value and its mean, and the modeling is performed using data collected under noisy conditions. This approach performs both link quality classification and regression estimation. Experimental results demonstrate that with a relatively small amount of data, this method achieves excellent generalization performance, yielding a classification accuracy of 96%, a training time of 0.01 seconds, and an average absolute error of 0.025 for regression estimation.

Keywords

WI-FI, Link Quality Estimation, EWMA, Classification, Regression

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

Wi-Fi 网络中,无线信道条件可能随时间和空间而显著变化,从而影响 Wi-Fi 链路的质量[1]。为了确保 Wi-Fi 网络的可靠和稳定,需要有效的链路质量估计(Link Quality Estimation, LQE)机制适配无线链路条件[2],并且可以选择替代的或更可靠的信道用于无线数据传输。影响链路质量的因素包括多径效应、外部干扰和收发器硬件故障等[3]。链路质量的有效预测可以获得多方面的性能回报,包括因减少分组丢弃而提高网络吞吐量、由减少重传而延长网络寿命、路由重新发现、较少的拓扑故障和提高的可靠性等[4]。

现有的链路质量建模方法可以概括为三种不同的方法:1) 基于理论模型的方法,根据通信理论得到包接收率与信噪比的关系[5][6]。2) 概率估计模型,计算最近传输的成功率来估计链路质量[7]。3) 机器学习预测模型,通过回归或分类的方法估计特征输入和链路质量输出之间的相关性[8]-[10]。基于理论模型的优势在于其可解释性和预测能力,尤其是在已知系统参数的情况下,能够提供精确的结果。这些模型虽然理论上精确,但在实际应用中往往需要大量的简化假设,尤其是在动态和多机器人场景中,模型的复杂性和假设可能导致其在实际环境中的表现不佳。大多数文献使用后面两种方法之一进行链路质量估计,概率估计模型在链路质量估计中具有计算效率高、实现简单等优点,但其缺点主要体现在对历史数据的依赖性、对动态环境的适应性不足以及对复杂场景的处理能力有限等方面。在实际应用中,通常需要结合其他方法(如理论模型或机器学习)来弥补这些不足,以提高链路质量估计的准确性和鲁棒性。其中机器学习预测模型运用了物理层映射、时间序列分析和机器学习等方面的技术[8],通过建立输入特征与链路质量之间的统计关系,为网络性能优化提供了重要支持。

文献[9]使用时间序列分析估计社区无线网状网络(Community Wireless Mesh Network, CWMN)的链路质量,并通过四种学习方法对时间序列建模。在此基础上,为了满足链路质量预测的适应性和即插即用性,文献[10]提出了一种结合基准算法和在线机器学习算法的混合在线算法来预测 CWMN 中的链路质量。文献[11]将吞吐量作为输入特征,使用 AROW 回归算法进行吞吐量的计算。针对传统 Wi-Fi 标准提出的多种速率自适应解决方案缺乏可扩展性问题,文献[12]提出基于机器学习的全面的速率自适应解决方案,通过利用机器学习自动识别速率、吞吐量和链路质量之间的相关性来实现可扩展性。文献[13]和文献[14]

为提高对少数类分类的公平性,提出了新的基于树的链路质量分类模型,通过分析特征选择和重采样技术对提高每类分类的影响,得出了性能最好的特征组合和重采样方法。由于环境的动态波动,导致无线通信网络的链路质量(Link Quality, LQ)的预测成为一项复杂的任务,文献[15]提出了一种基于深度学习的方法来准确预测无线通信网络中的 LQ,即使用两种深度递归神经网络的变体:长短期记忆递归神经网络和门控递归单元,通过学习和利用 LQ 时间序列中的上下文处理 LQ 的波动。

目前 Wi-Fi 链路质量估计方法存在以下问题: 1) 现有模型为了提高模型的泛化能力需要在不同条件下测量数据,训练模型所需的数据量较大[16]。2) 为了提高估计精确度,大多数研究采用多个物理层指标来建立模型,使模型复杂度以及数据获取和处理的难度增加。3) 缺少适合机器学习的数据集。虽然关于 802.11 有不少公开的 IEEE 802.11 网络数据集,如 Rutgers [17]、Packet-metadata [18]、University of Michigan [19]、Evarilos [20]和 Colorado [21]等,但是除了 Rutgers 数据集,大多数存在数据格式不一致、序列号缺失和文件不完整等问题。

针对上述问题,本文提出了一种基于决策树的链路质量估计方法。在预处理阶段对数据进行最小值填充和指数加权移动平均(Exponential Weighted Moving Average, EWMA)滤波处理,选择 EWMA 后的接收信号强度(Received Signal Strength Indication, RSSI)和 RSSI 的均值作为模型输入特征,EWMA 处理后的包接收率(Packet Reception Ratio, PRR)作为输出量。利用一组噪声条件下采集的数据分别建立链路质量分类和回归估计模型,能够对不同条件的链路质量进行准确估计。与现有方法相比,本文提出的方法以较少的数据就可以获得良好的泛化性能,并且预测的准确度、精确度、召回率等都比较高。

2. 链路质量估计模型

2.1. 缺失值填充

在处理数据缺失问题时,常用方法包括零填充、最小值填充以及均值填充。图 1 是不同缺失值处理后 RSSI 和 PRR 的相关系数,可以看出零填充和最小值填充能显著地提高 RSSI 和 PRR 的相关性,在 RSSI 小于 0 的情况下,虽然填充 0 也能够获得较高的相关性,但与通信理论不一致,所以选择最小值填充。




Figure 1. Comparison of correlation coefficients between RSSI and PRR under different missing value treatments

图 1. 不同缺失值处理 RSSI 与 PRR 的相关系数对比

2.2. 参数选择

为了减少计算开销,本文使用 PRR 的 EWMA 作为模型输出量,PRR 的 EWMA 也被称为 WMEWMA (Window Mean with Exponentially Weighted Moving Average) [22], 同时为了提高模型的预测准确度,对输入特征也做 EWMA 处理。EWMA 算法通过赋予新数据样本更高的权重,能够有效过滤随机噪声,同时保留了信号的主要变化趋势。EWMA 的计算公式如下所示:

$$EMA_t = \alpha \times x_t + (1 - \alpha) \times EMA_{t-1} \quad (1)$$

其中 EMA_t 和 EMA_{t-1} 表示时刻 t 和 $t-1$ 的指数加权移动平均值, x_t 表示时间 t 的观测值。 α 表示平滑因子,取值范围为 $[0, 1]$, α 决定了新数据在 EWMA 计算中的权重。图 2 为平滑因子 α 取不同值时,分类模型预测下一窗口的 PRR 的准确度,图 3 为回归模型预测的平均绝对误差,分类模型中 α 取 0.1 时预测的准确度最高,回归模型中 α 取 0.1 时预测的平均绝对误差最小,所以按回归模型的预测结果选择 α 为 0.1。




Figure 2. Accuracy under different values of α
图 2. α 不同取值下准确度




Figure 3. MAE under different values of α
图 3. α 不同取值下的平均绝对误差

为了验证上述方法的有效性,进行了一组对照实验,对不同距离条件下的数据进行 EWMA 处理。实验结果如图 4 显示,在平滑因子设定为 0.1 条件下,经过 EWMA 处理后的各组数据在预测准确度上均有明显提升。

不同的 WMEWMA 窗口大小会影响计算与存储开销,以下是 PRR 的计算公式:




Figure 4. Accuracy before and after EWMA processing

图 4. EWMA 处理前和处理后的准确度

$$PRR = \frac{D}{W} \quad (2)$$

其中 W 是特定时间窗口 T 内发送的数据包数量, D 表示在 W 个包中成功接收的数据包数量。窗口越大, 意味着将有更多的信息提供给模型, 同时会增加模型的缓冲和处理需求, 图 5 显示, 在模型输入特征与输出窗口相同的条件下, 将 W 从 1 增加到 10 时, 预测准确度不会明显上升, 说明在 0~10 范围内选择不同大小的窗口对于预测准确度的影响并不显著。综合考虑计算与存储开销及响应速度, 本文将 W 设置为 5。当 PRR 取窗口为 5 时, 对输入特征统计窗口取不同值进行预测, 如图 6 所示, 只有输入特征也取 5 的情况下, 准确度最高。因此本文计算输入特征的统计窗口也取 5。




Figure 5. The accuracy of PRR under different windows

图 5. PRR 不同窗口下准确度




Figure 6. Accuracy with different window sizes for input features

图 6. 输入特征取不同窗口的准确度

在建立链路质量估计模型过程中, 特征选择是关键步骤, 常用特征包括直接可观测的物理层参数(接收信号强度指示(RSSI)、噪声(NOISE)等)和通过计算得到的合成特征(信噪比(SNR)、RSSI 的窗口平均值、RSSI 的标准差等)。由于 Rutgers 只给出了噪声均值, SNR 与 RSSI 分布相同, 没有给出更多信息; 本文实验中使用的模块也不提供瞬时噪声, 无法准确计算 SNR, 所以本文选择 RSSI 作为基础输入参数。

为了确定合成特征是否有助于建立更准确的模型, 研究了多种输入特征的组合(如表 1 所示), 图 7 对比了使用不同参数作为输入特征的效果, 与只使用 $RSSI_{ewma}$ (RSSI 的 EWMA)相比, 使用 $\overline{RSSI}_{5_ewma}$ (窗口取 5 的 RSSI 均值的 EWMA)作为输入特征能够明显提升模型的预测精度, 将 $RSSI_{ewma}$ 与 $\overline{RSSI}_{5_ewma}$ 相结合, 模型的精确度得到了进一步的提升, 而使用 $RSSI_{ewma}$ 、 $\overline{RSSI}_{5_ewma}$ 和 $RSSI_{5_SD_ewma}$ 窗口取 5 时 RSSI 的标准差的 EWMA)组合作为输入特征, 并不能使性能进一步提高, 因此选择 $RSSI_{ewma}$ 和 $\overline{RSSI}_{5_ewma}$ 作为模型的输入特征。




Figure 7. Accuracy under different characteristics

图 7. 不同特征下的准确度

Table 1. Combination of input features

表 1. 输入特征组合

特征组序号	定义
1	$RSSI_{ewma}$
2	$\overline{RSSI}_{5_ewma}$
3	$RSSI_{5_SD_ewma}$
4	$RSSI_{ewma}$, $\overline{RSSI}_{5_ewma}$
5	$RSSI_{ewma}$, $\overline{RSSI}_{5_ewma}$, $RSSI_{5_SD_ewma}$

2.3. 决策树分类和回归算法

使用分类算法建立模型, 需要对链路质量进行划分。链路质量等级是通过 PRR 的取值范围设置, 定义如下:

$$y = f(\text{PRR}) = \begin{cases} 0, & \text{if } (\text{PRR} \leq 0.1) \\ 1, & \text{otherwise} \\ 2, & \text{if } (\text{PRR} \geq 0.9) \end{cases} \quad (3)$$

其中 0 表示较差的链路质量, 1 表示中等质量的链路, 2 表示较好的链路。本文使用决策树分类算法, 根据 $\text{RSSI}_{\text{ewma}}$ 和 $\overline{\text{RSSI}}_{5_ewma}$ 两个参数, 对当前时刻的链路质量进行估计。在决策树的构造中使用熵作为分割标准:

$$H(S) = -\sum_{i=0}^2 p_i \log_2 p_i \quad (4)$$

其中 S 是决策树中节点的样本集合, p_i 表示数据集 S 中属于第 i 个类别的样本占总样本数的比例。根据信息增益来选择最佳划分特征:

$$IG(S, F) = H(S) - \sum_{v \in \{\text{坏}, \text{中等}, \text{好}\}} \frac{|S_v|}{|S|} H(S_v) \quad (5)$$

其中, $H(S)$ 表示父节点样本集合 S 的熵, $H(S_v)$ 表示在给定特征 F 条件下, S 被划分后得到的子集 S_v (其中 v 可以是“坏”、“中等”或“好”) 的熵。在处理训练数据时, 通过计算每个特征的信息增益, 选择信息增益最大的特征作为当前节点的划分特征, 通过递归可以构建特定深度的决策树。为了防止模型的过拟合, 通过 5 折交叉验证评估不同深度下模型的性能, 其中在深度为 4 的时候, 验证集表现最好。本文将决策树深度设置为 4。

建立决策树回归模型时, 以预测值与真实值之间的平方误差的平均值 MSE 作为选择特征分割节点的指标, 样本 MSE 的计算公式为:

$$\text{MSE} = \frac{1}{n} (y_i - \hat{y}_i)^2 \quad (6)$$

其中, n 是节点内的样本数量, y_i 是第 i 个样本的真实值, $\hat{y}_i$ 是该样本的预测值 (在回归树中, 通常是节点内所有样本真实值的平均值)。

3. 实验结果及分析

3.1. 数据集

本文分别采用公共数据集和自建的数据集进行实验。公共数据集选用 Rutgers 数据集[16], 该数据集基于 ORBIT 测试平台建立, 包括 4060 个不同链路的跟踪数据, 这些数据是从噪声强度为 0 dBm、-5 dBm、-10 dBm、-15 dBm 和 -20 dBm 的干扰下收集的, 以模拟实际通信条件。数据集包含 RSSI、序列号、节点 ID 及噪声水平等信息。

同时利用 ESP32 开发板以及厂商提供的 ESP-NOW 协议设计实验系统, 完成数据的采集。ESP-NOW 是由乐鑫公司开发的低功耗 2.4 GHz 无连接 Wi-Fi 通信协议, 不仅简化了无线通信的配置过程, 还能够缓解网络拥塞时因为丢包而导致的卡顿和延迟, 拥有更高的响应速度。

实验场景设定于学校办公楼的走廊和大厅, 如图 8 所示。为了研究不同噪声水平对无线信号传输的影响, 使用两个 CC2530 无线传感器网络节点作为可控干扰源, 并按照图 9 进行布置。

实验选取了 CC2530 的三种不同发射功率, 通过调节干扰源的功率和位置, 分别模拟了 -51 dBm、-61 dBm 和 -71 dBm 的干扰环境, 以便分析干扰对 ESP32-S3 模组间通信链路质量的影响。两个 ESP32S3 模组分别用于收发数据, 选择 Wi-Fi 的 12 信道, 干扰节点的信道选择和 Wi-Fi 频带重叠的 IEEE802.15.4 的 23 信道, ESP32 发送节点以广播方式发送 3000 个数据包, 接收节点收到包后保存序列号和 RSSI。



Figure 8. Corridor of office area and lobby of office area
图 8. 办公区域走廊和办公区域大厅




Figure 9. Interference source layout diagram
图 9. 干扰源布置图

3.2. 模型性能测试

经过数据预处理后, $\overline{RSSI}_{5_ewma}$ 和 PRR_{ewma} 之间的关系如图 10 所示, $RSSI_{ewma}$ 和 PRR_{ewma} 的关系也是类似。不同干扰条件下的数据近似沿一条直线分布, 因此使用其中一种干扰条件的数据建立模型, 可以反映出其它干扰条件下采集的数据的变化趋势, 从而可以准确的预测其它干扰条件的链路质量。




Figure 10. The relationship between RSSI and PRR under different interferences
图 10. 不同干扰下 RSSI 和 PRR 的关系

为了验证使用较少数据建立模型,也可以获得良好的泛化性能。采用 Rutgers 数据集中噪声为 0 dBm 的数据集建立决策树分类模型,使用其他干扰条件下的数据对模型进行测试,结果如表 2 所示,在 0 dBm 作为训练集,−20 dBm 作为测试集的情况下,准确率、精确度、召回率和 F1 都比较高。使用一种噪声条件数据集训练的模型,在应用于其他数据集时,性能没有明显下降,且干扰越小的情况下,预测准确度越高。

Table 2. Testing the performance of the model on different datasets
表 2. 不同数据集测试模型的性能

测试数据集	准确度(%)	精确度(%)	召回率(%)	F1 (%)
0 dbm	94	92	89	90
−5 dbm	95	93	90	91
−10 dbm	97	94	89	91
−15 dbm	98	94	87	90
−20 dbm	99	95	87	90

用同样的方法进行决策树回归性能测试,结果如图 11 所示,在预测−20 dBm 数据集时平均绝对误差 MAE 最小,在预测其他数据集时 MAE 也比较低。




Figure 11. Mean absolute error of the tested model with different datasets
图 11. 不同数据集测试模型的平均绝对误差

采用自建的数据集,利用在某种干扰条件下采集的数据训练模型,使用其他干扰条件下采集的数据对模型进行测试。如图 12 所示,实验结果显示:无论是哪一组数据训练的模型,均能够准确地预测其他几组噪声条件下的链路质量,且预测精确度均保持在较高水平。同时,使用所有数据集建立的模型和使用一组数据集建立的模型的预测精度水平相当,说明使用较少的数据训练模型能够获得良好的泛化性能。在保证高预测精度的前提下,有效降低了建模成本。

3.3. 不同机器学习模型的性能评估

为了比较不同模型的性能,本文采用决策树、支持向量机、逻辑回归和人工神经网络等分类的机器学习算法,并利用自建的数据集,分别建立了链路质量估计模型,每个分类模型的参数如表 3 所示。




Figure 12. Comparison of models across different datasets

图 12. 使用不同数据集训练的模型比较

不同模型的精确度和训练时间如表 4 所示，其中决策树、逻辑回归和支持向量机三种方法的预测精度都较高，但从运行模型的时间复杂度看，决策树分类较其他模型更为简单。使用 Rutgers 数据集测试的结果与上述实验结果相似，所以从总体上看，使用决策树分类模型进行 Wi-Fi 的链路质量估计效果较好。

Table 3. Parameters of different models

表 3. 不同分类模型的参数

算法类型	模型参数
决策树分类	最大深度为 4
逻辑回归	最大迭代次数为 1000
支持向量机	使用线性核函数，正则化参数 1.0
多层感知机	1 个隐藏层，每层神经元个数为 10，使用修正线性单元作为激活函数，最大迭代次数 1000

Table 4. Comparison of model performance across different classification algorithms

表 4. 不同分类算法的模型性能比较

算法类型	准确度(%)	精确度(%)	召回率(%)	F1(%)	训练时间(s)
决策树分类	96	95	76	84	0.01
逻辑回归	97	94	92	93	0.14
支持向量机	97	93	93	93	0.15
多层感知机	94	87	85	86	1.65

实际系统中，链路质量估计结果常采用连续值表示，因此，本文进一步探究了决策树回归模型的预测性能，并与常用的回归模型进行了比较，回归模型的参数如表 5 所示。

Table 5. Parameters of different regression
表 5. 不同回归模型的参数

算法类型	模型参数
决策树回归	最大深度为 4
k-最近邻	最近邻数量为 5
支持向量机	使用高斯核函数，正则化参数 1，不敏感损失为 0.01

实验结果如图 13 所示，使用支持向量机算法得到模型的预测误差最小，其次是决策树回归和 k-最近邻算法。得出支持向量机算法在回归上表现良好，而决策树在回归和分类上都有较好的表现。




Figure 13. Comparison of model performance across different regression algorithms
图 13. 不同回归算法的模型性能比较

4. 结束语

本文提出一种基于决策树的链路质量估计方法，选择 RSSI 和 RSSI 均值的 EWMA 作为模型的输入特征，通过预处理增强了输入特征与 PRR 的相关性。采用公共数据集和自建的数据集，验证了模型的泛化性能，实验结果表明决策树算法在进行链路质量分类和回归估计时都具有较好表现，并且只用少量的数据就能较好预测其它数据集，决策树分类模型准确率达到 96%，训练时间 0.01 s，回归模型的平均绝对误差为 0.025。未来将在实际的 Wi-Fi 系统中实现本文提出的链路质量估计方法，在线测试链路质量估计模型的性能。

基金项目

国家自然科学基金资助项目(61374040);
国防基础研究资助项目(JCKY2019413D001);
上海理工大学科技发展资助项目(2020KJFZ082)。

参考文献

[1] Szott, S., Kosek-Szott, K., Gawlowicz, P., Gomez, J.T., Bellalta, B., Zubow, A., *et al.* (2022) Wi-Fi Meets ML: A Survey on Improving IEEE 802.11 Performance with Machine Learning. *IEEE Communications Surveys & Tutorials*, **24**, 1843-1893. <https://doi.org/10.1109/comst.2022.3179242>

- [2] De Couto, D.S.J., Aguayo, D., Bicket, J. and Morris, R. (2003) A High-Throughput Path Metric for Multi-Hop Wireless Routing. *Proceedings of the 9th Annual International Conference on Mobile Computing and Networking*, San Diego, 14-19 September 2003, 134-146. <https://doi.org/10.1145/938985.939000>
- [3] Millan, P., Aliagas, C., Molina, C., Dimogerontakis, E. and Meseguer, R. (2019) Time Series Analysis to Predict End-To-End Quality of Wireless Community Networks. *Electronics*, **8**, Article 578. <https://doi.org/10.3390/electronics8050578>
- [4] Bi, J., Li, S., Yuan, H., Zhao, Z. and Liu, H. (2019) Deep Neural Networks for Predicting Task Time Series in Cloud Computing Systems. 2019 *IEEE 16th International Conference on Networking, Sensing and Control (ICNSC)*, Banff, 9-11 May 2019, 86-91. <https://doi.org/10.1109/icnsc.2019.8743188>
- [5] Gupta, P. and Kumar, P.R. (2000) The Capacity of Wireless Networks. *IEEE Transactions on Information Theory*, **46**, 388-404. <https://doi.org/10.1109/18.825799>
- [6] Iyer, A., Rosenberg, C. and Karnik, A. (2006) What Is the Right Model for Wireless Channel Interference? *Proceedings of the 3rd International Conference on Quality of Service in Heterogeneous Wired/Wireless Networks*, Waterloo, 7-9 August 2006, 2-es. <https://doi.org/10.1145/1185373.1185376>
- [7] Kudelski, M., Gambardella, L.M. and Di Caro, G.A. (2014) A Mobility-Controlled Link Quality Learning Protocol for Multi-Robot Coordination Tasks. 2014 *IEEE International Conference on Robotics and Automation (ICRA)*, Hong Kong SAR, 31 May-7 June 2014, 5024-5031. <https://doi.org/10.1109/icra.2014.6907595>
- [8] 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.
- [9] Millan, P., Molina, C., Medina, E., Vega, D., Meseguer, R., Braem, B., et al. (2015) Time Series Analysis to Predict Link Quality of Wireless Community Networks. *Computer Networks*, **93**, 342-358. <https://doi.org/10.1016/j.comnet.2015.07.021>
- [10] Bote-Lorenzo, M.L., Gómez-Sánchez, E., Mediavilla-Pastor, C. and Asensio-Pérez, J.I. (2018) Online Machine Learning Algorithms to Predict Link Quality in Community Wireless Mesh Networks. *Computer Networks*, **132**, 68-80. <https://doi.org/10.1016/j.comnet.2018.01.005>
- [11] Okamoto, H., Nishio, T., Morikura, M., Yamamoto, K., Murayama, D. and Nakahira, K. (2017) Machine-Learning-Based Throughput Estimation Using Images for mmWave Communications. 2017 *IEEE 85th Vehicular Technology Conference (VTC Spring)*, Sydney, 4-7 June 2017, 1-6. <https://doi.org/10.1109/vtcspring.2017.8108570>
- [12] Li, C., Chen, S., Kuo, C. and Chiu, C. (2020) Practical Machine Learning-Based Rate Adaptation Solution for Wi-Fi NICS: IEEE 802.11ac as a Case Study. *IEEE Transactions on Vehicular Technology*, **69**, 10264-10277. <https://doi.org/10.1109/tvt.2020.3004471>
- [13] Cerar, G., Yetgin, H., Mohorcic, M. and Fortuna, C. (2020) On Designing a Machine Learning Based Wireless Link Quality Classifier. 2020 *IEEE 31st Annual International Symposium on Personal, Indoor and Mobile Radio Communications*, London, 31 August-3 September 2020, 1-7. <https://doi.org/10.1109/pimrc48278.2020.9217171>
- [14] Cerar, G., Yetgin, H., Mohorcic, M. and Fortuna, C. (2021) Learning to Fairly Classify the Quality of Wireless Links. 2021 *16th Annual Conference on Wireless On-Demand Network Systems and Services Conference (WONS)*, Klosters, 9-11 March 2021, 1-8. <https://doi.org/10.23919/wons51326.2021.9415540>
- [15] Abdel-Nasser, M., Mahmoud, K., Omer, O.A., Lehtonen, M. and Puig, D. (2020) Link Quality Prediction in Wireless Community Networks Using Deep Recurrent Neural Networks. *Alexandria Engineering Journal*, **59**, 3531-3543. <https://doi.org/10.1016/j.aej.2020.05.037>
- [16] 张书毓, 施伟斌, 王文龙, 等. 基于线性回归的无线传感器网络链路 质量估计方法研究[J]. 计算机应用研究, 2022, 39(7): 2132-2136.
- [17] Kaul, S.K., Gruteser, M. and Seskar, I. (2006) Creating Wireless Multi-Hop Topologies on Space-Constrained Indoor Testbeds through Noise Injection. 2nd *International Conference on Testbeds and Research Infrastructures for the Development of Networks and Communities*, Barcelona, 1-3 March 2006, 511-521. <https://doi.org/10.1109/tridnt.2006.1649191>
- [18] Fu, S., Zhang, Y., Jiang, Y., Hu, C., Shih, C. and Marron, P.J. (2015) Experimental Study for Multi-Layer Parameter Configuration of WSN Links. 2015 *IEEE 35th International Conference on Distributed Computing Systems*, Columbus, 29 June-2 July 2015, 369-378. <https://doi.org/10.1109/icdc.2015.45>
- [19] Chen, Y.L., Wiesel, A. and Hero, A.O. (2011) Robust Shrinkage Estimation of High-Dimensional Covariance Matrices. *IEEE Transactions on Signal Processing*, **59**, 4097-4107. <https://doi.org/10.1109/tsp.2011.2138698>
- [20] Haute, T.V., Poorter, E.D., Lemic, F., Handziski, V., Wirström, N., Voigt, T., et al. (2015) Platform for Benchmarking of Rf-Based Indoor Localization Solutions. *IEEE Communications Magazine*, **53**, 126-133. <https://doi.org/10.1109/mcom.2015.7263356>

- [21] Anderson, E., Yee, G., Phillips, C., Sicker, D. and Grunwald, D. (2009) The Impact of Directional Antenna Models on Simulation Accuracy. 2009 *7th International Symposium on Modeling and Optimization in Mobile, Ad Hoc, and Wireless Networks*, Seoul, 23-27 June 2009, 1-7. <https://doi.org/10.1109/wiopt.2009.5291643>
- [22] Bote-Lorenzo, M.L., Gómez-Sánchez, E., Mediavilla-Pastor, C. and Asensio-Pérez, J.I. (2018) Online Machine Learning Algorithms to Predict Link Quality in Community Wireless Mesh Networks. *Computer Networks*, **132**, 68-80. <https://doi.org/10.1016/j.comnet.2018.01.005>