

基于区间二型模糊神经网络的垂直切换算法

马 彬^{1,2}, 王双双^{1,2}, 陈海波^{1,2}

(1. 重庆邮电大学计算机科学与技术学院, 重庆 400065; 2. 重庆邮电大学计算机网络与通信技术重点实验室, 重庆 400065)

摘 要: 在超密集异构无线网络中, 针对传统垂直切换算法无法同时描述网络状态的模糊性和随机性, 导致网络性能得不到有效提升的问题, 提出一种基于区间二型模糊神经网络的垂直切换算法. 重构了两阶段判决算法: 在网络预筛选阶段, 定义了历史接入率, 结合当前候选网络集的数目设置阈值. 根据接收信号强度和剩余可用带宽, 对用户接收范围内的所有网络进行初步筛选; 再在垂直切换判决阶段, 将剩余候选网络的时延, 丢包率以及误码率作为区间二型模糊神经网络的输入, 利用前馈神经网络的结构完成模糊逻辑推理, 经训练之后计算得到输出判决值, 从而选择最佳接入网络. 实验结果表明, 该算法能在保证时间开销较低的同时, 有效降低切换决策的错误概率, 减少切换失败和切换次数, 提升网络总吞吐量.

关键词: 区间二型模糊神经网络; 超密集; 垂直切换; 模糊性; 随机性

中图分类号: TN915 **文献标识码:** A **文章编号:** 0372-2112 (2021)05-0928-08

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.12263/DZXB.20200850

Vertical Handover Algorithm Based on Interval Type-2 Fuzzy Neural Network

MA Bin^{1,2}, WANG Shuang-shuang^{1,2}, CHEN Hai-bo^{1,2}

(1. Institute of Computer Science and Technology, Chongqing University of Post and Telecommunication, Chongqing 400065, China;

2. Chongqing Key Laboratory of Computer Network and Communication Technology, Chongqing 400065, China)

Abstract: In the ultra-dense heterogeneous wireless network, the traditional vertical handoff algorithm can not describe the fuzziness and randomness of the network state at the same time, so the network performance can not be effectively improved. A vertical handoff algorithm based on the interval type II fuzzy neural network is proposed to solve above problem. A two-stage decision system is reconstructed; in the network's prescreening stage, the historical access rate is defined to set the threshold combine with the number of current candidate network sets. According to the received signal strength and the remaining available bandwidth, all the networks within the user's receiving range are preliminarily screened; The delay, packet loss rate and bit error rate of the remaining candidate networks are taken as the inputs of the it2fnn in the vertical handoff decision stage. The fuzzy logic reasoning is completed by using the structure of the feedforward neural network, and the output decision value is calculated after the training, and the optimal network is selected. The simulation results show that the algorithm can ensure low time consumption, and effectively reduce the error probability of handoff decision and the number of handoff failures and handoff times. Meanwhile, it can improve the total throughput of networks.

Key words: interval type II fuzzy neural network; ultra-dense; vertical handoff; fuzziness; randomness

1 引言

智能设备和信息通信技术的应用的增加, 加速了无线技术向 5G 网络的演进, 为了解决这些设备和数据流

量急剧增长所带来的问题, 在新的网络场景中采用宏、微基站与其他无线技术异构的超密集组网架构进行部署^[1]. 这种超密集部署通过在宏基站的范围内设置大量的微基站, 同时与其他无线网络并存, 相互补充, 满足

收稿日期: 2020-08-06; 修回日期: 2020-12-04; 责任编辑: 马兰英

基金项目: 重庆市自然科学基金 (No. CSTC2018jcyjAX0432); 重庆市教委科学技术研究计划重大项目 (No. KJZD-M201900602); 重庆市教委科学技术研究重点项目 (No. KJZD-K201800603)

用户的各类业务需求.但由于多种网络的衡量标准不同,不同终端对网络同一属性的需求程度也存在差异,而且这种差异无法精确度量.因此在高度重叠覆盖的网络环境下,如何得到促使网络综合性能最大化的切换判决,使用户得到更加准确的判决结果,减少切换失败,是当前研究的重点之一.

目前已有较多文献致力于研究垂直切换中的各种问题,如切换失败、不必要的切换以及乒乓切换^[2-5]等,且都取得了一定的成效.当前垂直切换算法主要可以分为以下几类:(1)基于阈值判决的垂直切换算法^[6,7],设定阈值来触发切换;(2)基于决策函数的垂直切换算法^[8,9],利用决策函数度量切换到各个网络的好坏;(3)基于人工智能的垂直切换算法,利用马尔可夫^[10,11]、模糊逻辑(Fuzzy Logic, FL)^[12-14]或神经网络^[15-17]等模型,智能地执行切换判决.但在超密集网络环境下,对于相似网络,利用以上算法的精确度量方式来执行切换判决,往往会以极小评分差筛选掉很多高服务质量的网络,使用户都去争取评分最高的网络,反而会造成阻塞,带来更多的切换失败,网络性能也无法得到提升.

部分研究利用 FL 进行垂直切换,但大多采用一型 FL 系统.文献[12]通过 FL 算法,得到待切换网络,并进行资源可用性检查,保障接入网络的可用性和切换成功率.文献[13]提出分级垂直切换算法,将一级 FL 系统的输出结合网络负载和费用作为二级 FL 系统的输入,能极大降低时间开销.文献[14]提出一种面向终端个性化服务的模糊垂直切换算法,基于负载预测进行预筛选,根据业务类型设计隶属函数,能有效降低阻塞率.以上基于 FL 的垂直切换算法仅实现了网络参数的模糊化,在确定隶属度值时回避了其本身具有的随机性.而且 FL 的规则往往有较强的主观经验,其自适应和学习能力较差.

考虑到 FL 和神经网络的优缺点,部分文献将二者相结合,用于研究垂直切换.文献[18]提出 FL 和神经网络结合 Q 学习能够自动调整存在于模糊规则中的系统状态和动作之间的关系,在保证 QoS 的同时具有较低阻塞率.文献[19]设计了自适应神经模糊推理系统,自动调整移动异构网络的数据速率,能适应多媒体业务中不断变化的流量负荷和用户速度.文献[20]提出了一种联合接入选择和带宽分配算法.利用五层模糊神经网络获取每个候选人的分数和带宽分配价值网络.

但当前的网络环境是由 5G 宏基站和微基站密集组网的无线蜂窝网络与无线局域网异构而成的,因此,由网络的随机性和模糊性构成的不确定性会更加突出,而前述的研究工作对此均没有很好的解决方案.因此本文提出了一种基于区间二型模糊神经网络(Interval Type-2 Fuzzy Neuro Network, IT2FNN)的垂直切换算

法.该算法利用前馈神经网络的结构实现了 FL 推理,能同时表达对象的模糊性和随机性,并采用不确定推理的方法,保持了这种不确定性,使判决过程更加符合真实的网络场景.本文的主要贡献可以概括如下:首次引入 IT2FNN 进行垂直切换,以期降低垂直切换决策的错误概率,减少切换失败.为了降低整个算法的时间开销,设计了候选网络筛选机制,其中定义了历史接入率概念,用于设置筛选阈值;同时,重构了两阶段智能判决算法.

2 系统建模与算法流程

2.1 垂直切换模型

考虑在网络场景中有 m 个用户, n 个网络,在 t 时刻,用户与网络的连接关系矩阵为

$$\mathbf{r}(t) = \begin{bmatrix} r_{11}(t) & r_{12}(t) & \cdots & r_{1n}(t) \\ r_{21}(t) & r_{2b}(t) & \cdots & r_{2n}(t) \\ \vdots & \vdots & \ddots & \vdots \\ r_{m1}(t) & r_{m1}(t) & \cdots & r_{mn}(t) \end{bmatrix} \quad (1)$$

其中, $a = 1, \dots, m$ 表示第 a 个用户, $b = 1, \dots, n$ 表示第 b 个网络.

$$r_{ab}(t) = \begin{cases} 1, & \text{在 } t \text{ 时刻,用户 } a \text{ 连接在网络 } b \text{ 中} \\ 0, & \text{在 } t \text{ 时刻,用户 } a \text{ 与网络 } b \text{ 无连接} \end{cases} \quad (2)$$

在 t 时刻,描述网络的覆盖范围与用户位置的关系矩阵为

$$\mathbf{h}(t) = \begin{bmatrix} h_{11}(t) & h_{12}(t) & \cdots & h_{1n}(t) \\ h_{21}(t) & h_{2b}(t) & \cdots & h_{2n}(t) \\ \vdots & \vdots & \ddots & \vdots \\ h_{m1}(t) & h_{m1}(t) & \cdots & h_{mn}(t) \end{bmatrix} \quad (3)$$

其中,

$$h_{ab}(t) = \begin{cases} 1, & \text{在 } t \text{ 时刻,用户 } a \text{ 处于网络 } b \text{ 的覆盖范围,} \\ 0, & \text{在 } t \text{ 时刻,用户 } a \text{ 不在网络 } b \text{ 的覆盖范围.} \end{cases} \quad (4)$$

显然,对于任意用户 a ,其只能接入到一个网络,或没有接入到任何网络,因此用户接入的网络总数 $\sum_{b=1}^n r_{ab}(t)$ 满足以下约束条件:

$$0 \leq \sum_{b=1}^n r_{ab}(t) \leq 1 \quad (5)$$

对任意网络 b ,接入进来的用户数 $\sum_{a=1}^m r_{ab}(t)$ 满足:

$$0 \leq \sum_{a=1}^m r_{ab}(t) \leq \min \left(\sum_{a=1}^m h_{ab}(t), \text{Max_Num}_b \right) \quad (6)$$

其中 Max_Num_b 为网络 b 可承载的最大用户数.

假设连接在同一网络下的用户获得等分的带宽,则在 t 时刻处于网络 b 下的用户 a 能够分得的带宽为 $BW_{ab}(t)$,假设每个网络的总带宽均为 BW_{total} ,则在 t

时刻,第 b 个网络的剩余可用带宽 (Remaining available Bandwidth, RBW) 为

$$RBW_b(t) = BW_{total} - BW_{ab}(t) \times \sum_{a=1}^m r_{ab}(t) \quad (7)$$

在 t 时刻,用户 a 从网络 b 获得的接收信号强度 (Received Signal Strength, RSS) 可表示为

$$RSS_{ab}(t) = \rho_b - l_b \lg(d_{ab}(t)) + \xi \quad (8)$$

其中, ρ_b 为网络 b 的发送功率, $d_{ab}(t)$ 为 t 时刻用户 a 到网络 b 的距离, l_b 为网络路径损失因子, ξ 为服从参数为 $(0, \delta^2)$ 的高斯随机变量。

误码率 (BER) 是信噪比 (SNR) 的函数, 而 t 时刻的信噪比近似表示为

$$SNR_{ab}(t) = RSS_{ab}(t) / L \quad (9)$$

其中, L 为干扰信号强度, 则 t 时刻的误码率可以表示为

$$BER_{ab}(t) = F(\sqrt{SNR_{ab}(t)}) \quad (10)$$

$$F(\lambda) = (1/\sqrt{2\pi}) \int_{\lambda}^{\infty} e^{(-\tau^2)/2} d\tau \quad (11)$$

2.2 垂直切换流程

在超密集异构无线网络环境下, 每个用户的候选网络较多, 为避免对性能较差的网络执行切换判决, 本文重构了两阶段智能判决算法。

第一阶段为网络预筛选阶段. 考虑网络中影响用户接入的两个基础参数: RSS 表示用户与网络之间的信号传输质量. RBW 用于描述每个网络的带宽占用情况. 当前部分研究根据 RSS 进行预筛选, 但基站数目很大时, 筛选力度不够, 在后续的切换判决中, 会增加不必要的时间开销. 另有文献只考虑目标网络的 RBW 大于当前网络的可用带宽, 也会引起频繁切换. 因此在第一阶段根据所有候选网络的 RSS 和 RBW 进行初步筛选. 此方案能有效减少候选网络的数目, 提高决策效率; 另一方面也能有效地平衡网络负载. 此外, 在筛选过程中结合剩余候选网络数目调整阈值, 以免删除过渡, 致使用户无法接入网络。

第二阶段为垂直切换判决阶段. 利用 IT2FNN 决策出最佳网络供用户接入. 为进一步降低垂直切换过程中的切换失败率, 提升用户体验, 时延 (Delay, D)、丢包率 (Packet Loss Rate, PLR) 和误码率 (Bit Error Rate, BER) 作为衡量网络性能的重要参数, 被选为第二阶段中候选网络的状态属性, 作为 IT2FNN 的输入。

本文算法具体流程如图 1 所示, 当用户的请求到达时, 后台发现所有连接范围内的网络, 生成候选网络集 1 (Candidate Network Set1, CNS_1), 搜集 CNS_1 的 RSS 和 RBW, 对 CNS_1 进行初步筛选之后, 生成 CNS_2. 若成功生成 CNS_2, 则进一步计算 CNS_2 中所有网络的

时延、丢包率和误码率作为 IT2FNN 的输入, 经学习训练得到每个网络的输出值, 选择值最大的网络作为目标网络; 否则, 选取 RSS 最大的网络作为目标网络. 找到目标网络之后, 用户立即执行切换以获得更优的服务。

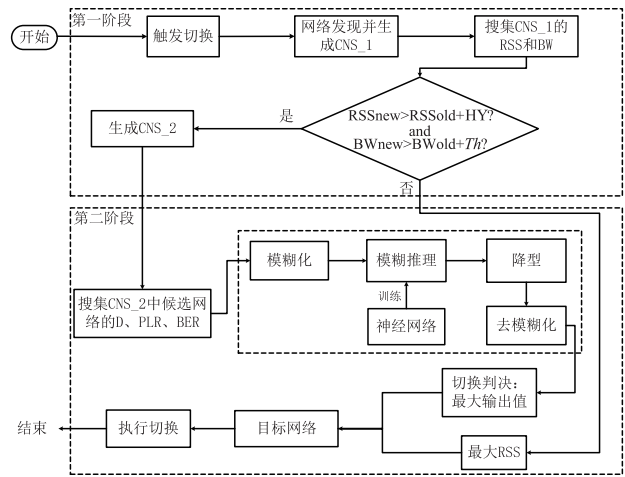


图1 算法流程图

3 网络预筛选阶段

在预筛选阶段, 针对 CNS_1 中的每一个网络, 进行双参数的阈值筛选. 利用文献 [21] 中添加滞后余量 (Hysteresis margin, HY) 的方式, 设置 RSS 的阈值. 然后针对每个网络的 RBW, 本文定义了网络 b 的历史接入率 v_b , 表示过去单位时间内接入到网络 b 的用户数, 可用式 (12) 描述:

$$v_b = \frac{Num_b}{T} \times 100\%, \quad 0 < v_b < 1 \quad (12)$$

其中 Num_b 表示过去一段时间 T 内接入到网络 b 的用户数, 根据候选网络 b 的历史接入率 v_b 和 CNS_1 中其他剩余网络数目 Num_{Net} 设置相应的阈值 Th . 若该候选网络的历史接入率和剩余候选网络数目均比较大, 那么阈值也相应的增大. 即

$$Th = Num_{Net} \times v_b \quad (13)$$

当候选网络的 RSS 和 RBW 同时满足条件式 (14) 时, 如下:

$$\begin{cases} RSS_{ab}(t) > RSS_{cur}(t) + HY \\ RBW_b(t) > RBW_{cur}(t) + Th \end{cases} \quad (14)$$

则候选网络 b 被选入 CNS_2. 其中 $RSS_{ab}(t)$ 和 $RSS_{cur}(t)$ 分别表示 t 时刻, 用户 a 从候选网络 b 和当前接入网络获得的 RSS, $RBW_b(t)$ 和 $RBW_{cur}(t)$ 分别表示 t 时刻, 候选网络 b 和当前接入网络的 RBW. 预筛选阶段得到的 CNS_2 中的候选网络进入切换判决阶段, 经 IT2FNN 决策得到最佳的网络供用户接入。

4 垂直切换判决阶段

4.1 IT2FNN 结构

本章设计的 IT2FNN 系统结构如图 2 所示,该系统以前馈神经网络的结构实现了区间二型模糊逻辑的推理过程,包含了 6 层神经元节点.




图2 IT2FNN结构

第一层为输入层,包含三个输入参数 $x_i, i = 1, \dots, 3$, 分别表示候选网络的时延、误码率和丢包率.

第二层为隶属函数层,进行输入参数的模糊化.将上述三个网络参数的精确值转换为模糊量,模糊等级设置为“低”、“中”、“高”.通过区间二型隶属函数将其映射于一个区域中,而不是仅仅将其映射于一个 $[0, 1]$ 区间上的精确值,区域中的值更具有随机性.由于隶属函数需要在学习阶段进行求导推理,本章选取易于推导的高斯型隶属函数作为主隶属函数,次隶属函数是区间集,其隶属度均设置为 1,能极大地降低计算开销.具有不确定均值的高斯型主隶属函数为

$$\bar{\mu}_i^k = [\underline{\mu}_i^k, \bar{\mu}_i^k] \quad (15)$$

其中, $k = 1, \dots, 3$ 分别表示模糊等级“低”、“中”、“高”.其中:

$$\bar{\mu}_i^k = \begin{cases} Z(\underline{m}_i^k, \sigma_i^k, x_i), & x_i \leq \underline{m}_i^k \\ 1, & \underline{m}_i^k < x_i < \bar{m}_i^k \\ Z(\bar{m}_i^k, \sigma_i^k, x_i), & x_i \geq \bar{m}_i^k \end{cases} \quad (16)$$

$$\underline{\mu}_i^k = \begin{cases} Z(\bar{m}_i^k, \sigma_i^k, x_i), & x_i \leq \frac{\underline{m}_i^k + \bar{m}_i^k}{2} \\ Z(\underline{m}_i^k, \sigma_i^k, x_i), & x_i > \frac{\underline{m}_i^k + \bar{m}_i^k}{2} \end{cases} \quad (17)$$

分别表示上下界隶属函数,其中:

$$Z(m_i^k, \sigma_i^k, x_i) = \exp\left(-\frac{(x_i - m_i^k)^2}{(\sigma_i^k)^2}\right), m_i^k \in [\underline{m}_i^k, \bar{m}_i^k] \quad (18)$$

m_i^k 表示第 i 个参数第 k 个模糊级别对应隶属函数的不确定均值, σ_i^k 为第 i 个参数第 k 个模糊级别对应隶属函

数的标准差.可以看出该层每个节点的输出为一个区间.以候选网络的时延为例,其区间二型隶属度函数如图 3 所示.




图3 时延隶属度函数

第三层为模糊规则层,其中每个节点分别与第二层对应三个输入的任一节点相连.每个输入语言变量包含 3 个模糊集,该层中的每个节点对应不同模糊集的组合,因此该层共有 $3^3 = 27$ 个节点.每个节点对应一条模糊规则,对节点上的输入数据采用模糊与操作,常用的模糊与运算为最小运算或乘积运算.本章通过对第二层的输出进行乘积运算计算每条规则的激发强度:

$$\bar{f}^j = \prod_{i=1}^3 (\bar{\mu}_i^k) \quad (19)$$

$$\underline{f}^j = \prod_{i=1}^3 (\underline{\mu}_i^k) \quad (20)$$

其中 $j = 1, 2, \dots, M$ 表示规则数.

第四层为后续参数层,该层与第三层为全互连,其每个节点都是第三层规则节点的后续节点,以一个线性模型表示第三层与第四层的连接权值.该层每个节点的输出即为连接权值,表示每条规则的置信度.由于以往规则的置信度依赖于专家经验,有较强的主观性,因此本章在学习训练过程中利用神经网络对该权值进行调整.权值计算如下:

$$[\underline{\omega}^j, \bar{\omega}^j] = [c_0^j - s_0^j, c_0^j + s_0^j] + \sum_{i=1}^3 [c_i^j - s_i^j, c_i^j + s_i^j] x_i \quad (21)$$

即该层每个节点的输出上、下界分别为

$$\bar{\omega}^j = \sum_{i=0}^3 c_i^j x_i - \sum_{i=0}^3 s_i^j |x_i| \quad (22)$$

$$\underline{\omega}^j = \sum_{i=0}^3 c_i^j x_i + \sum_{i=0}^3 s_i^j |x_i| \quad (23)$$

其中 $x_0 \equiv 1, c_i^j$ 与 s_i^j 的初始值为随机设置.

第五层为输出处理层,该层计算每个输出的上、下边界值,输出函数结合了第三层和第四层的输出,设计因子 $[q, \bar{q}]$ 可以自适应的调整上下值,而不需要使用 K-M 迭代过程来寻找 L 和 R 端点^[22]. 当规则数量较大时,本文使用设计因子来降低二型 FL 系统的复杂性,因此第五层的输出为

$$\bar{y} = \frac{(1 - \bar{q}) \sum_{j=1}^M \bar{f}^j \bar{\omega}^j + q \sum_{j=1}^M f^j \underline{\omega}^j}{\sum_{j=1}^M (f^j + \bar{f}^j)} \quad (24)$$

$$\underline{y} = \frac{(1 - q) \sum_{j=1}^M f^j \underline{\omega}^j + \bar{q} \sum_{j=1}^M \bar{f}^j \bar{\omega}^j}{\sum_{j=1}^M (f^j + \bar{f}^j)} \quad (25)$$

第六层为降型层,是一型去模糊化过程的扩展. 任意二型模糊集降型的计算开销是非常高的,为简化计算复杂性,本文利用取平均值的方法计算得到输出:

$$y = \frac{\bar{y} + \underline{y}}{2} \quad (26)$$

经学习训练之后,得到使整个切换判决系统更加稳定的权值,最终得到 CNS_2 中每个候选网络的决策输出值 y , 选出该值最大的候选网络,作为目标网络,进行垂直切换,为用户提供更优的服务.

4.2 学习训练

IT2FNN 的结构可以看做一个多层前馈网络,因此可以像 BP 网络一样采用梯度下降法进行误差训练. 根据网络的时延、误码率和丢包率,生成 400 组指定范围内的随机值作为训练数据集,将其作为 FL 系统的输入,计算得到期望值. 将同一训练数据集作为 IT2FNN 的输入,每输入一组训练数据,计算得到实际的输出值,将其与期望值进行误差计算. 沿着误差减小的方向,从系统的第六层向前修正权值,随着不断学习,误差越来越小,直至无限接近 0,即训练结束,此训练过程采用离线训练的方式. 实际值与期望值的误差计算如下:

$$e = \frac{1}{2} [y(t+1) - y_d(t+1)]^2 \quad (27)$$

其中 $y(t+1)$ 和 $y_d(t+1)$ 分别表示 $(t+1)$ 时刻的实际值和期望值. $(t+1)$ 时刻的权值由 t 时刻的权值计算得到.

区间二型模糊逻辑系统中二型隶属函数的不确定均值和标准差更新为

$$\bar{m}_i^k(t+1) = \bar{m}_i^k(t) - \eta \frac{\partial e}{\partial \bar{m}_i^k} \quad (28)$$

$$\underline{m}_i^k(t+1) = \underline{m}_i^k(t) - \eta \frac{\partial e}{\partial \underline{m}_i^k} \quad (29)$$

$$\sigma_i^k(t+1) = \sigma_i^k(t) - \eta \frac{\partial e}{\partial \sigma_i^k} \quad (30)$$

每条规则的后件参数更新为

$$c_i^j(t+1) = c_i^j(t) - \eta \frac{\partial e}{\partial c_i^j} \quad (31)$$

$$s_i^j(t+1) = s_i^j(t) - \eta \frac{\partial e}{\partial s_i^j} \quad (32)$$

设计因子更新为

$$\bar{q}(t+1) = \bar{q}(t) - \eta \frac{\partial e}{\partial \bar{q}} \quad (33)$$

$$q(t+1) = q(t) - \eta \frac{\partial e}{\partial q} \quad (34)$$

其中 $\eta (0 < \eta < 1)$ 表示学习率 (Learning Rate, LR), 用以控制训练的速度. 学习率过高会导致学习过程极度振荡,学习率过低会导致收敛缓慢,增加时间开销,因此需要选择较为合适的学习率.

5 实验结果及分析

5.1 仿真场景和参数设置

为了评估本文所提算法的性能,利用 Matlab 仿真工具模拟了 5G 环境下网络的部署情况. 本章采用 5G 和 WiFi 两种接入技术组成的超密集异构无线网络环境,无线接入网络均采用正交频分复用 (Orthogonal Frequency Division Multiplexing, OFDM) 技术. 5G 宏基站的覆盖范围内包含 150 个 5G 微基站,其地理位置服从泊松分布,且环境中均匀分布有 10 个 WiFi 接入点. 用户随机分布在宏基站范围内,用户的移动速度均为恒定 5km/h,运动轨迹由有规律的随机点拟合而成. 为方便观察,本章所展示的网络场景图在 5G 宏基站的覆盖范围内设置有 7 个微基站和 3 个 WiFi 接入点,区域内包含有两个终端用户,如图 4 所示.

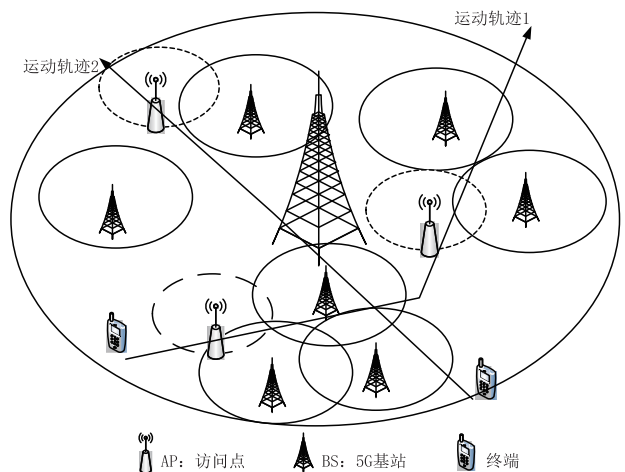


图4 网络场景图

将本文与基于模糊神经网络 (Fuzzy Neuro Network, FNN) 的垂直切换算法^[20] 和基于 FL 的垂直切换算法^[13] 进行对比. 基于以上三种算法,对比分析了四组实验,分别是切换失败率与用户数的关系、总切换次数与

用户数的关系、多次实验下的算法时间开销以及网络总吞吐量与用户数的关系,网络参数设置如表 1 所示.

表 1 网络仿真参数

| 网络 | 覆盖半径 | 发送功率 | 路经损失 | 总带宽 | 时延 |
|--------|---------------------------------|-------|-------|----------|------|
| 宏基站 | 全覆盖 | 50dBm | 54dBm | 10Mbit/s | 1ms |
| 微基站 | 150m | 33dBm | 34dBm | 10Mbit/s | 随机 |
| WiFi | 100m | 25dBm | 30dBm | 60Mbit/s | 20ms |
| 其他参数设置 | RSS 滞后余量 HY = 3dB, 学习率 LR = 0.7 | | | | |

为体现本文算法的普适性,其中隶属函数的标准差和均值、规则的后件参数及设计因子的初始值均设置为 $[0,1]$ 内的一组随机值,沿着误差减小的方向,经神经网络不断学习训练,得到使整个系统达到最稳定状态的值,作为最终权值,用于切换决策.利用梯度下降法进行误差训练的结果如图 5 所示,最终使得误差由 0.242 降至 0.001,即训练结束.

5.2 平均切换失败率分析

平均切换失败率反映了算法决策的精准性,图 6 对比了在用户数目逐渐增多的情况下,三种算法的平均切换失败率.随着用户增多,三种算法的平均切换失败率均呈现上升趋势,本文算法的平均切换失败率最低.在用户数低于 30 时,三种算法的平均切换失败率无明显差距,当用户数大于 30 时,其他两种算法的平均切换

失败率较本文算法上升更明显.本文算法的切换失败率曲线较为平缓,即使在用户数达到 80 时,失败率也不超过 0.05.这是因为,在基站数目较多时,本文算法对参数隶属度的设定更加随机,降低了不同主体在设置隶属函数时的主观影响,有效降低了错误决策的概率.结合 RSS 和 RBW 进行初步筛选,避免接入的网络无法为用户提供有效服务.因此大大降低了切换失败率.

5.3 切换次数分析

算法决策错误带来的切换失败必然引起下一次的切换触发,过高的切换次数会带来不必要的切换开销.图 7 表明,随着用户数的逐渐增加,基于三种算法得到的总切换次数均呈现上升趋势.其中,FL 算法的总切换次数最高,在用户数为 10 到 20 之间,切换次数逐渐高于 FNN 算法,而本文算法得到的切换次数明显低于前两种算法.这说明,本文所提算法能有效减少不必要的切换.其原因是本文算法在基站数目很多的情况下,结合 RSS 和 RBW,综合当前候选网络数目和历史接入率对网络进行了初步筛选,避免了对不可用网络的决策.此外,本文算法能同时体现参数隶属度的模糊性和随机性,较其他算法更符合切换判决的真实场景.且传统的垂直切换算法较容易以极小的评分差忽略高服务质量的网络,相比之下,本文算法能忽略相似网络的差异性,有效平衡负载,减少因阻塞引起的切换.




图5 训练误差




图6 切换失败率




图7 总切换次数

5.4 算法时间开销分析

算法的时间开销体现了一个算法执行的效率,本章通过具体的时间开销实验来对比分析三种算法,如图 8 所示.其中 FNN 算法的时间开销明显高于另外两种算法.这是因为 FNN 算法考虑了 7 个参数,规则库庞大,且还利用神经网络来不断训练.从整体来看,为保证网络性能的更大提升,本文算法的平均时间开销为 18.717s,略高于 FL 算法.这是因为在超密集异构无线网络环境下,本文重构的判决算法通过了两阶段的处理:首先定义了历史接入率,设计了预筛选机制,减少了切换判决阶段的输入参数数目,大大降低了算法的时间开销;同时减少了候选网络的数目,避免对性能较

差的网络执行判决,进一步降低了时间开销.且本文算法采用区间二型模糊集,无需设置次隶属函数,减少了降型的时间开销;最后利用设计因子调整边界值,避免了常规模糊神经网络中使用 K-M 迭代过程来寻找 L 和 R 端点的复杂过程.

5.5 网络总吞吐量分析

图 9 为基于三种算法的网络总吞吐量与用户数之间的关系,随着用户数逐渐增多,采用三种算法得到的网络吞吐量均呈现上升趋势.当用户数达到 60,网络开始阻塞,总吞吐量曲线上升趋于平缓,其中基于 FL 算法的总吞吐量略微下降.总体来看,在到达用户数相同的情况下,采用本文算法得到的网络总吞吐量最高,在




图8 算法时间开销

用户数为 80 时,网络总吞吐量达到了 320Mbps。这是因为在网络数目很多时,本文算法结合历史接入率和 RBW 对所有候选网络进行了筛选,避免接入网络时,因 RBW 不足而造成阻塞,同时有利于平衡网络负载,从而使数据传输不受太大影响。而 FL 算法考虑参数有限,若所选网络参数过多,势必会因规则的指数倍增长,带来更大的时间开销。且由于 FL 算法并未全面考虑网络的负载情况,可能会造成阻塞,导致网络利用率无法得到提升。




图9 网络总吞吐量

6 结束语

本文提出了基于 IT2FNN 的垂直切换算法,重构了两阶段智能判决算法。在网络预筛选阶段,定义了历史接入率,结合 RSS 与 RBW 进行初步筛选,减少了候选网络的数目;在切换判决阶段,引入 IT2FNN 进行决策,利用梯度下降法训练误差,不断更新决策过程中的隶属函数参数和权值。实验结果表明该算法在保证时

间开销较低的情况下,能有效降低切换判决的错误概率,降低切换失败,减少切换次数,提升网络总吞吐量。下一步的研究工作希望在保证网络性能的同时,进一步的降低智能算法在执行垂直切换决策时因规则库庞大而带来的时间开销。

参考文献

- [1] Ozhelvaci A, Ma M. Secure and efficient vertical handover authentication for 5G HetNets[A]. 2018 IEEE International Conference on Information Communication and Signal Processing[C]. Singapore, Singapore; IEEE, 2018. 27 - 32.
- [2] Xiao K, Li C. Vertical handoff decision algorithm for heterogeneous wireless networks based on entropy and improved TOPSIS[A]. 2018 IEEE 18th International Conference on Communication Technology[C]. Chongqing, China; IEEE, 2018. 706 - 710.
- [3] Yu H, Ma Y, Yu J. Network selection algorithm for multi-service multimode terminals in heterogeneous wireless networks[J]. IEEE Access, 2019, 7: 46240 - 46260.
- [4] Kanwal K, Safdar G A. Reduced early handover for energy saving in LTE networks[J]. IEEE communications letters, 2016, 20(1): 153 - 156.
- [5] Hasan M M, Kwon S, Oh S. Frequent handover mitigation in ultra-dense heterogeneous networks[J]. IEEE Transactions on Vehicular Technology, 2019, 68(1): 1035 - 1040.
- [6] Lee S K, Sriram K, Kim K, et al. Vertical handoff decision algorithms for providing optimized performance in heterogeneous wireless networks[J]. IEEE Transactions on Vehicular Technology, 2009, 58(2): 865 - 881.
- [7] Roy D S, Vamshidhar R S R. Signal strength ratio based vertical handoff decision algorithms in integrated heterogeneous networks[J]. Wireless Personal Communications, 2014, 77(4): 2565 - 2585.
- [8] Yu H W, Zhang B. A Hybrid MADM algorithm based on attribute weight and utility value for heterogeneous network selection[J]. Journal of Network and Systems Management, 2019, 27(3): 756 - 783.
- [9] 谢显中, 肖博仁, 马彬, 等. 代价函数权值可变的自适应的异构无线网络垂直切换算法[J]. 电子学报, 2011, 39(10): 2417 - 2421.
Xie X Z, Xiao B R, Ma B, et al. Cost function weight variable speed adaptive vertical switching algorithm for heterogeneous wireless networks[J]. Acta Electronica Sinica, 2011, 39(10): 2417 - 2421. (in Chinese)
- [10] Zang S, Bao W, Yeoh P L, Vucetic B, Li Y. Managing vertical handovers in millimeter wave heterogeneous networks[J]. IEEE Transactions on Communications, 2019, 67(2): 1629 - 1644.
- [11] Balouch S F, Ahmad M I. A markov-based framework for

- handover process in heterogenous cellular networks[A]. 2nd International Conference on Computing, Mathematics and Engineering Technologies [C]. Sukkur, Pakistan: IEEE, 2019. 1 – 11.
- [12] Subramani M, Kumaravelu V B. A quality-aware fuzzy-logic-based vertical handover decision algorithm for device-to-device communication [J]. Arabian Journal for Science and Engineering, 2019, 44(3): 2413 – 2425.
- [13] 马彬, 李尚儒, 谢显中. 异构无线网络中基于模糊逻辑的分级垂直切换算法[J]. 电子与信息学报, 2020, 42(3): 629 – 636.
- Ma B, Li S R, Xie X Z. Hierarchical vertical handover algorithm based on fuzzy logic in heterogeneous wireless networks[J]. Journal of Electronics & Information Technology, 2020, 42(3): 629 – 636. (in Chinese)
- [14] 马彬, 张文静, 谢显中. 面向终端个性化服务的模糊垂直切换算法[J]. 电子与信息学报, 2017, 39(6): 1284 – 1290.
- Ma B, Zhang W J, Xie X Z. Fuzzy vertical handover algorithm for terminal personalized service[J]. Journal of Electronics & Information Technology, 2017, 39(6): 1284 – 1290. (in Chinese)
- [15] Rihani M, Mroue M, Prevotet J, et al. A neural network based handover for multi-RAT heterogeneous networks with learning agent[A]. 2018 13th International Symposium on Reconfigurable Communication-centric Systems-on-Chip[C]. Lille, France: IEEE, 2018. 1 – 6.
- [16] Subhedar M. Handover decision in wireless heterogeneous networks based on feedforward artificial neural network [A]. Computational Intelligence in Data Mining[C]. Singapore, Singapore: Springer, 2017, 556: 663 – 669.
- [17] Divya P, Malleswara R V. WOA-NN: A decision algorithm for vertical handover in heterogeneous networks [J]. Wireless Networks, 2020, 26: 165 – 180.
- [18] Chen Y H, Chang C J, Huang C Y. Fuzzy Q-Learning admission control for WCDMA/WLAN heterogeneous networks with multimedia traffic [J]. IEEE Transactions on Mobile Computing, 2009, 8(11): 1469 – 1479.
- [19] J Mar, H Nien. Intelligent data rate control in cognitive mobile heterogeneous networks [A]. 2011 6th International ICST Conference on Cognitive Radio Oriented Wireless Networks and Communications (CROWNCOM) [C]. Osaka, Japan: IEEE, 2011. 206 – 210.
- [20] Liang G, Yu H, Guo X, et al. Joint access selection and bandwidth allocation algorithm supporting user requirements and preferences in heterogeneous wireless networks [J]. IEEE Access, 2019, 7: 23914 – 23929.
- [21] 赵夙, 张涛, 朱晓荣. 超密集簇网络中基于预测门限滞后余量可调的切换算法[J]. 电子与信息学报, 2016, 38(3): 649 – 654.
- Zhao Su, Zhang Tao, Zhu Xiaorong. An adjustable handover algorithm based on predictive threshold lag margin in ultra-dense clustering networks [J]. Journal of Electronics & Information Technology, 2016, 38(3): 649 – 654. (in Chinese)
- [22] Lin Y Y, Liao S H, Chang J Y, et al. Simplified interval type-2 fuzzy neural networks [J]. IEEE Transactions on Neural Networks & Learning Systems, 2014, 25(5): 959 – 969.
- [23] Tsai K, Liu H, Liu Y. Using fuzzy logic to reduce ping-pong handover effects in LTE networks [J]. Soft Computing, 2016, 20(5): 1683 – 1694.

作者简介



马彬 男, 1978 年出生, 四川人, 博士, 重庆邮电大学教授, 主要研究方向为认知无线网络、异构无线网络、不确定智能算法等。
E-mail: mab_cqupt@sina.com



王双双(通信作者) 女, 1995 年生, 湖北宜昌人, 硕士研究生, 研究方向为超密集异构无线网络。
E-mail: 1271755437@qq.com