

doi:10.13756/j.gtxyj.2022.05.012

无线通信技术

基于强化学习的自适应网络覆盖优化算法研究

柳旭东, 赵 凤, 朱晓荣

(南京邮电大学 江苏省无线通信重点实验室, 南京 210003)

摘要:随着第五代移动通信技术(5G)的发展以及网络架构的演进,网络覆盖的分析以及优化不仅需要考虑到基站天线系统的链路预算,而且需要结合基站覆盖区域的时空特性,从而设计出更精确的覆盖优化方案。文章提出了一种基于Q学习的自适应网络覆盖优化算法,首先采用一种基于数据挖掘的网络覆盖预测模型,通过小区天线参数的配置预测出接入终端的覆盖情况,并基于真实数据验证模型预测的准确性;其次,改进强化学习中智能体的动作选择策略,根据覆盖率设置各小区不同的优化优先级,结合贪心策略,选择出需要优化的小区及其优化参数值,有效地降低了迭代过程中陷入局部最优的概率。仿真结果表明,文章所提算法可提高优化过程收敛速度,同时对网络覆盖率的提升幅度可达到20%。

关键词:蜂窝网络;覆盖优化;Q学习;贪心策略

中图分类号: TP391

文献标志码: A

文章编号: 1005-8788(2022)05-0066-08

An Adaptive Network Coverage Optimization Method based on Reinforcement Learning

LIU Xu-dong, ZHAO Su, ZHU Xiao-rong

(Jiangsu Key Laboratory of Wireless Communications, Nanjing University
of Posts and Telecommunication, Nanjing 210003, China)

Abstract: With the development of 5th Generation Mobile Communication Technology (5G) and the evolution of network architecture, the analysis and optimization of network coverage need to consider comprehensive factors, including not only the link budget of the base station antenna system, but also the geographical conditions and time characteristics of the area covered by the base station. Therefore, a more accurate network coverage optimization plan should be designed. This paper proposes an adaptive network coverage optimization algorithm based on Q-learning. The method first adopts a cellular network coverage prediction model based on data mining, which can predict the coverage situation of the access terminal through the configuration of the antenna of the cell, and verify the accuracy of the prediction based on real data. Then, a network coverage optimization algorithm based on Q-learning is proposed which modifies the action selection strategy of the agent in reinforcement learning process. According to the coverage of each cell, different optimization priorities are set. Combined with the greedy strategy, a cell and its antenna parameters are decided by the agent in each iteration. This method effectively reduces the probability of falling into a local optimum during the iteration process, and the method also has a good performance in reducing the convergence time of the optimization process. The simulation result shows that the algorithm can increase the network coverage by up to 20%.

Key words: cellular network; coverage optimization; Q-learning; greedy strategy

0 引言

移动通信网络在满足多样性需求的同时,也要提供高质量的服务支持^[1]。因此,稳定的广域覆盖成为网络发展中首要的技术保障^[2]。

对于覆盖问题,现阶段的研究方法主要为使用最优化方法求解基站参数的最佳调整值,从而提高覆盖率。文献[3]采用了黄金分割搜索;文献[4]采用了梯度下降法;文献[5]采用了粒子群算法;文献[6]采用了模拟退火算法。

上述方法依赖于对优化场景的大量假设,在实

际网络运行的过程中,无线信号传播环境的改变会影响对优化场景建立假设的准确性与灵活性,对网络环境的应变有较大的局限性。若使用现网数据构建网络场景模型,在通用性与基站部署环境的灵敏度上均有较好的表现。此外,随着网络规模的扩大,能够积累运维经验并自主形成优化策略的人工智能方法,能够进一步提高网络运维效率^[7]。

针对上述两个方面,本文使用将数据挖掘与强化学习相结合的思路,使用通过现网数据训练的预测模型作为强化学习环境,使用Q学习作为优化算法的主体,并在动作选择阶段,通过引入优先级调整

收稿日期:2021-08-12

基金项目:国家自然科学基金资助项目(61871237,92067101);江苏省高校“青蓝工程”和江苏省重点研发计划资助项目(BE2019017)

作者简介:柳旭东(1996—),男,新疆维吾尔自治区乌鲁木齐人。硕士,主要研究方向为移动通信网络覆盖优化。

通信作者:柳旭东,硕士。E-mail:Liuxudong0991@163.com

智能体选择动作的策略,得到具有自适应优先级的Q学习。算法仿真表明,使用改进的Q学习算法可以将覆盖率提升20%,并有效提高了收敛速度。

1 系统模型

1.1 系统框架

针对移动通信网络覆盖场景,本文提出的覆盖优化系统模型如图1所示。




图1 覆盖优化系统模型

Figure 1 Block diagram of coverage optimization system

首先,将从现网中采集到的路测数据在无线网络数据库中进行处理,包括数据去重、数据平衡化以及特征选择等操作。将处理后的数据根据网络覆盖标准,按照弱覆盖、重叠覆盖和正常覆盖3种情况添加标签。随后将已标记数据作为训练样本,进行覆盖预测建模,通过构建小区天线参数与其接入用户覆盖状况的映射关系,实现能够根据每个小区的不同参数调整,输出该小区内每个接入终端的覆盖标签,从而达到模拟真实网络环境的效果。本文使用的网络覆盖预测模型是随机森林(Random Forest, RF)算法^[8]。RF算法包含多棵决策树,每棵树都作为一个分类器,在进行分类时,RF算法会将决策树中得到投票最多的标签作为整体的输出^[9]。为保证模型的准确性,本文在第3节中使用现网数据对训练好的模型进行验证,并列出了覆盖场景中RF算法与其他常用算法的性能对比。

随后,本文提出了一种基于Q学习的自适应网络覆盖优化算法。Q学习属于强化学习的一种,通过学习求解出状态—动作与预计收益的映射表来实现优化的目的。如图1中覆盖优化模块所示,在每轮迭代开始时,智能体观测环境的状态,即计算网络中的瞬时覆盖率,并根据覆盖率维护一个优先级列表,覆盖率越低的小区会被设定越高的优化级。随后选择需要调整的小区,以及该小区的天线电子下倾角和天线发射功率的调整值,并将其输出到环境

中;随后环境输出小区内所有终端的覆盖情况,通过统计计算得出小区以及全局的覆盖率,反馈给智能体一个奖励,智能体通过最大化奖励不断与模型交互,求解出在不同网络状况下的最优参数配置方案。

1.2 覆盖分析

网络中的覆盖问题主要分为弱覆盖与重叠覆盖。弱覆盖也叫作覆盖不足,定义为服务小区不能为接入的终端提供有效覆盖,通常表现为无主导小区、覆盖间隙以及覆盖盲区等。重叠覆盖定义为网内小区为移动台提供了过多的有效覆盖,通常表现为无主导小区和主导小区信噪比低等情况。在移动通信网络中,衡量覆盖程度最关键的参数是参考信号接收功率(Reference Signal Receiving Power, RSRP)。

弱覆盖点的判定标准是,若终端从其服务小区接收到的RSRP小于阈值 K ,则认为该终端处于弱覆盖。无线网络优化中规定弱覆盖判定阈值为 -107 dBm。若假设用户设备位置为 x ,弱覆盖评价函数可表示为

$$W = -107 - \text{RSRP}(x), \quad (1)$$

$$\text{Point}_{\text{weak}} = \begin{cases} 1, & \text{if } W > 0 \\ 0, & \text{if } W \leq 0 \end{cases}, \quad (2)$$

式中: $\text{RSRP}(x)$ 为在 x 位置的参考信号接收功率大小; $\text{Point}_{\text{weak}}$ 为每个采样点的覆盖标签; W 为终端采样点与弱覆盖阈值的偏差值。若 $W > 0$,则处于 x 位置的终端RSRP低于阈值,将其判定为弱覆盖样本点,并标记 $\text{Point}_{\text{weak}} = 1$;若 $W \leq 0$,则将其判定为正常样本点,并标记 $\text{Point}_{\text{weak}} = 0$,表示该终端所处位置不存在弱覆盖问题。

在长期演进(Long Term Evolution, LTE)网络中对重叠覆盖的判定标准如下:

(1) 移动台 $\text{RSRP} > -105$ dBm表示移动台可以正常接收有效信号;

(2) 移动台接收到来自邻区的RSRP与主服务小区同频率,若有当前小区频率 $\text{earfcn}_{\text{cell}}$ 和相邻小区 i 的频率 $\text{earfn}_{\text{cell}_i}$,则表示为 $\text{earfcn}_{\text{cell}} = \text{earfn}_{\text{cell}_i}$,且信号强度差值小于6 dB,若有采样点收到来自主服务小区的参考信号接收功率 $\text{RSRP}_{\text{cell}}$ 和来自相邻小区 i 的参考信号接收功率 $\text{RSRP}_{\text{cell}_i}$,则有 $|\text{RSRP}_{\text{cell}} - \text{RSRP}_{\text{cell}_i}| < 6$ dB,表示移动台收到过多的有效信号;

(3) 满足条件(2)的邻区数量 ≥ 3 个。

由此,重叠覆盖的评价函数可表示为

$$E = (RSRP_i(x) + 6) - RSRP_0(x), \quad (3)$$

$$Point_{over} = \begin{cases} 1, & \text{if } |\{E > 0 \mid cell_i \in neighbors\}| \geq 3 \\ 0, & \text{if } |\{E > 0 \mid cell_i \in neighbors\}| < 3 \end{cases}, \quad (4)$$

式中： $RSRP_0$ 为从主服务小区接收到的 RSRP； $RSRP_i$ 为来自第 i 个邻区的 RSRP^[10]； E 为主服务小区的 RSRP 与相邻小区的 RSRP 的差值； $cell_i$ 为在目标区域内的基站； $neighbors$ 为当前主服务小区的相邻小区集合； $Point_{over}$ 为 1 表示该样本所处位置存在重叠覆盖问题， $Point_{over}$ 为 0 表示该样本所处位置不存在重叠覆盖问题。

1.3 优化参数

无线网络覆盖问题产生的原因可概括如下：

(1) 不合理的基站选址。

(2) 网络规划的结果与实际的覆盖效果产生偏差。在网络规划和部署之初，工作人员会根据基站部署地周边的传播环境和地理信息，结合指定的覆盖要求做相关的链路预算，并根据计算出的预留量来设定基站工程参数，如天线下倾角和发射功率等。随着基站周围的环境发生变化，如产生新的建筑造成遮挡，或产生新的覆盖需求等原因，最初的基站工程参数配置已不是最优配置。

(3) 基站的硬件设施故障。

解决弱覆盖的思路是，在弱覆盖地区找到一个合适的信号，并使之加强，加强信号主要通过调整天线的方位角和下倾角等工程参数以及修改功率等方式实现。另外在弱场引入远端射频单元(Remote Radio Unit, RRU)拉远也可以解决问题。重叠覆盖的解决思路也很明确，就是减小重叠覆盖小区的覆盖范围，使之对其他小区的影响减到最小。对下倾角和功率等参数的调整能够有效地减轻重叠覆盖问题^[11]。

远程调整基站参数优化成本低，可操作性高，是实际工作中重点研究的优化对象和优化手段。此外，为了保证优化过程中不对网络造成负面影响，要求保证基站的正常运作，在改变天线挂高和机械下倾角时，需要关闭整个系统，实际工作中很少调整这些参数。本文使用调整天线的电子下倾角和天线发射功率作为优化手段提升覆盖率。

1.4 覆盖预测模型

本文采用 RF 算法构建小区天线参数与小区内采样点覆盖情况的映射关系，可以根据小区调整后的工程参数设置，预测出小区内接入终端覆盖情况的变化。RF 算法属于多分类器系统，是集成学习

算法之一，该算法通过构建并结合多个监督学习模型实现学习任务。

RF 算法是基于集成学习框架下的决策树模型的，其算法流程如下：

(1) 对于数据集大小为 N 的训练集合，随机有放回地从中抽取 N 条数据样本作为决策树的训练集合，重复 K 次，产生 K 组训练集合；

(2) 从总量为 L 的特征向量中随机选择 l 个特征；

(3) 利用已选取的 l 个特征训练决策树；

(4) 使用加权投票法产生最终预测结果 $H(x)$ ：

$$H(x) = \arg \max \sum_{i=1}^K w_i h_i(x), \quad (5)$$

式中： w_i 为决策树的预测权重； $h_i(x)$ 为每个决策树的预测结果。

因为 RF 算法在训练过程中引入了随机样本与随机特征，使得训练后的模型不容易陷入过拟合。此外由于多棵决策树的组合，使得 RF 算法在处理非线性数据时也能得到较好的效果，这些特性使得 RF 算法在网络覆盖预测的应用场景中能够有出色的表现。

1.5 优化目标

将单个小区的网络覆盖率表示为该小区内正常接入的终端采样点与总终端采样点的比值，若用 $Point$ 表示小区内的采样点，则有：

$$ratio_{cell_i} = \frac{\sum Point - (\sum Point_{weak} + \sum Point_{over})}{\sum Point}, \quad (6)$$

$$ratio_{whole} = \frac{1}{M} \times \sum_i ratio_{cell_i}, \quad i \in M, \quad (7)$$

式中： $ratio_{whole}$ 为全局覆盖率； $ratio_{cell_i}$ 为第 i 个小区的覆盖率； M 为小区总数。覆盖优化的目标为弱覆盖率和重叠覆盖率最小，即最大化全局覆盖率。具体地，每次迭代产生小区的天线参数调整值，将其输入到覆盖预测模型中，对小区内所有采样点更新覆盖标签，进而计算出小区覆盖率。需要强调的是，式(7)中计算全局覆盖率的方式为所有小区的覆盖率加权求和，为消除每个小区终端数量的差异带来的全局覆盖率计算偏差，在进行仿真前保证每个小区中采样点数量近似。

2 基于强化学习的覆盖优化算法

2.1 强化学习概述

强化学习是一类特定的机器学习问题，一个强

化学习系统由环境与智能体两部分组成,智能体通过观察环境,做出行动,随后获取来自环境的奖励,因此强化学习是一个通过与环境的交互来学习如何最大化奖励的优化过程,本文使用 Q 学习作为覆盖优化算法。

若定义回报 G_t 为强化学习的奖励和,则有:

$$G_t = R_{t+1} + \gamma R_{t+2} + \dots + \gamma^T R_T, \quad (8)$$

式中: t 为一个确定性的变量,表示回合数; T 为回合的总步数,是一个随机变量; γ 为折扣系数; R 为奖励信号。基于回报的定义,可以得到 Q 学习中对于价值函数 q_π 的表示:

$$q_\pi(s, a) = E_\pi[G_t | S_t = s, A_t = a], \quad (9)$$

式中: S_t 为当前状态; A_t 为当前动作; s 为属于状态空间 S 内的状态; a 为属于动作空间 A 中的动作; π 为策略; E 为期望。将 π 定义为从状态到动作的转移概率,表示为

$$\pi(a | s) = P[A_t = a | S_t = s], \quad s \in S, a \in A, \quad (10)$$

式中: P 为动作为 a 且状态为 s 的转移概率。

强化学习训练智能体的目的在于,在迭代的过程中,通过最大化回报来求解出最优策略。对于不同的策略 π 和 π' ,若有任意 $s \in S$,都有 $q_\pi(s, a) < q_{\pi'}(s, a)$,表示策略 $\pi < \pi'$ 。对于一个强化学习模型来说,总是存在一个或多个 π 大于其他策略,我们将这一个或多个策略称之为最优策略,最优策略 π^* 可表示为

$$\pi^*(s) = \arg \max_{a \in A} q^*(s, a), \quad s \in S, \quad (11)$$

式中, $q^*(s, a)$ 为最优(动作)价值函数。

若有不止一个动作使得 $q^*(s, a)$ 最大,则随机选取一个动作执行即可^[12]。 $q^*(s, a)$ 可表示为

$$q^*(s, a) = \max_\pi (q_\pi(s, a)), \quad s \in S, a \in A, \quad (12)$$

式中, $\max_\pi$ 为在策略 π 下的最大动作状态函数值。

强化学习框图如图 2 所示,在每次迭代过程中, Q 学习智能体将本次迭代所调整的小区编号、天线电子下倾角与天线发射功率作为动作输入到覆盖预测模型中,该模型会遍历小区中所有的采样点,输出与该小区对应的每个采样点的覆盖标签,从而计算出小区的覆盖率,以提高覆盖率为依据,环境在每一轮迭代中向智能体反馈奖励信号,智能体根据奖励信号更新价值函数。Q 学习算法的输出是一张 Q 值表格,表示在每一个网络覆盖状态 s 下,选取优化动作 a 所能带来的回报,回报越高,表示选择该动作对于覆盖率的提升有越好的效果。




图 2 强化学习框图

Figure 2 Reinforcement learning block diagram

2.2 Q 学习问题映射

针对网络覆盖优化场景的 Q 学习问题,映射分为状态空间、动作空间、奖励函数、Q 值更新以及改进的自适应优先级动作搜索算法 5 个方面,下面依次进行说明。

2.2.1 状态空间

将 Q 学习算法应用在网络覆盖优化场景中时,需要对状态空间进行一定的设置和约束。Q 学习的状态反映了当前的无线网络性能状态,在本文的覆盖优化场景中,智能体每次选择区域中多个小区中的一个小区作为优化目标,调整其天线参数配置。将调整后的网络覆盖率和本轮迭代被调整的小区作为 Q 学习的状态,因此,本文描述的覆盖优化问题所对应的状态空间 $State$ 可表示为

$$State = \{Current_{eci}, Coverage_{eci}, Coverage_{total}\}, \quad (13)$$

式中: $Current_{eci}$ 为当前调整的小区编号; $Coverage_{eci}$ 为该小区对应的局部覆盖率; $Coverage_{total}$ 为整个待优化区域的全局覆盖率。

2.2.2 动作空间

本文中涉及的覆盖优化问题是小区天线电子下倾角和天线发射功率的多维优化问题,因此将本文的动作集合 $Action$ 设置为

$$Action = \{action_{eci}, action_{down_tilt}, action_{power}\}, \quad (14)$$

式中: $action_{eci}$ 为选择调整参数的小区编号; $action_{down_tilt}$ 和 $action_{power}$ 分别为天线电子下倾角和天线发射功率的调整,可表示为 $\{increase, keep, decrease\}$,分别为增加、保持当前不变和减少 3 个动作,在仿真部分会针对不同的调整步长做比较分析。

2.2.3 奖励函数

Q 学习作为强化学习的经典模型,学习的最终目标是构建一个 $q(s, a)$ 值表格,这个表格反映了在每个状态下选择不同动作的收益,值越大表示该动作所带来的收益越高,收益由奖励信号通过式(8)和式(9)得出。

奖励信号为环境系统对于智能体上一步操作的评价。小区天线参数调整的目标是提高基站覆盖

率,即将处于重叠覆盖或弱覆盖的接入终端数量降到最低,因此Q学习中的奖励信号参考全局覆盖率变化这一个量纲,由式(6)和式(7)得出。若有 $coverage_{cur}$ 表示当前覆盖率, $coverage_{past}$ 表示上一时刻覆盖率, n 表示奖励的取值,则对奖励函数 $Reward$ 的计算可表示为

$$Reward = \begin{cases} n, & \text{if } coverage_{cur} - coverage_{past} > 0 \\ -1, & \text{if } coverage_{cur} - coverage_{past} = 0 \\ -n, & \text{if } coverage_{cur} - coverage_{past} < 0 \end{cases} \quad (15)$$

当全局覆盖率提升时,表示当前小区的参数调整为积极有效的调整,此时应反馈给智能体一个正值奖励;若全局覆盖率下降,则表示当前调整为消极错误的调整,应反馈给智能体一个负值奖励;此外,当全局覆盖率在一次迭代后维持不变时,也应该反馈给智能体一个较小的负值奖励,表示当前的调整为无效调整,这样的设置可以缩短优化算法的收敛时长。

2.2.4 Q值更新

在起始阶段,Q表中的每一个值会被随机赋值,当智能体每采取一个动作并执行后,就会产生一个相应的回报,智能体以此回报更新Q表内的数值。Q表中的值可以根据价值函数来进行更新,价值函数的更新可表示为

$$Q_{t+1}(s,a) = (1 - \alpha_t)Q_t(s,a) + \alpha_t(r_t + \gamma \max_{a'}(Q_t(s,a'))), \quad (16)$$

式中: $Q_t(s,a)$ 为状态—动作对在 t 时刻的值函数; $\alpha_t \in [0,1]$ 为学习因子,用于控制学习速度,其值越大收敛速度越快,但是可能导致无法获得最优解;若有 r_t 表示Q学习中当前瞬时的回报值,则 $(r_t + \gamma \max_{a'}(Q_t(s,a')))$ 为主要的更新内容。

2.2.5 改进的自适应优先级动作搜索算法

策略更新算法可能会以一个并不好的策略作为起始,在迭代过程中仅仅经过一些较差的状态,导致更好状态的价值函数没有得到更新,伴随着回合更新次数的增加,最优策略却没有找到。为解决此问题,可使用贪心策略进行动作选择,用于在迭代过程中覆盖所有的状态动作对。贪心策略可表示为

$$\pi(a | s) = \begin{cases} 1 - \epsilon + \frac{\epsilon}{|A(s)|}, & a = a^* \\ \frac{\epsilon}{|A(s)|}, & a \neq a^* \end{cases}, \quad s \in S, a \in A(s), \quad (17)$$

式中: ϵ 为既定的概率大小; $A(s)$ 为在状态为 s 时的

动作空间; a^* 为使得状态动作价值函数最大的动作。

针对覆盖优化场景,本文将自适应小区优化优先级的概念融入上述贪心策略。对于一个由多个小区组成的区域,全局覆盖率可以由各个小区覆盖率的加权累和求出,如1.5节式(7)所示。对于式(17)所示的传统贪心策略,选择动作时,有 $a \in A(s)$,表示从所有的小区编号、天线电子下倾角调整值和发射功率调整值的所有组合中选取一个动作,因此可以缩小动作空间 $A(s)$ 的范围为 $A'(s)$ 。具体地,在计算每个小区的覆盖率之后,智能体可以优先选择覆盖率较低的小区进行调整,根据小区覆盖率列表,将动作空间缩小为 $A'(s) = [ECI_{min}, Tilt, Power]$, 式中, $Tilt$ 为基站天线的电子下倾角; $Power$ 为天线的发射功率; ECI_{min} 为覆盖率最低的小区,即对于每一个时刻,智能体优先选择覆盖率最低的小区,在确定了优化目标小区后,使用贪心策略和Q值表,从参数组合中选择执行的动作。使用自适应优先级的动作算法会加速算法收敛,优化曲线更加平滑,提高优化效果和效率。

综上所述,改进的自适应优先级动作搜索算法的实现过程如下:

输入:环境、策略 π 。

输出:动作价值函数 $q(s,a)$ 。

1. 初始化: $q(s,a) \leftarrow$ 任意值, $s \in S, a \in A$ 。若有终止状态 s_{end} ,则令 $q(s_{end},a) \leftarrow 0, a \in A$ 。
2. 对每个回合执行以下操作:
 - 2.1. 初始化状态动作对:选择状态 s 。
 - 2.2. 如回合未结束,执行以下操作:
 - 2.2.1. 以 $cell_i$ 为单位,计算覆盖率并将其存入数组 $Dict[i]$,并用 i 表示对应的索引位置;
 - 2.2.2. 选择覆盖率最小的 ECI_{min} ;
 - 2.2.3. 在状态 s 下,按照改进的贪心策略决定动作 a ;
 - 2.2.4. 执行动作 a ,观测得到奖励 R 和新状态 s' ;
 - 2.2.5. 计算回报的估计值 U :

$$U \leftarrow R + \gamma \max_{a \in A(s)} q(s',a);$$
 更新 $q(s,a)$ 以减小 $[U - q(s,a)]^2$ 。

3 仿真结果与分析

为验证算法的可行性,本文使用来自江苏省南京市2020年7月某7天内的蜂窝网络数据,在经纬度 $31.770 \sim 31.784^\circ$, 东经 $118.820 \sim 118.862^\circ$, 约

4. 23 km² 区域内采样。

3.1 数据说明

本文使用的数据字段及其说明如表 1 和表 2 所示。

表 1 基站侧数据

Table 1 Base station side data

字段	描述
E-CGI	全球小区标识号
eNodeB-ID	基站编号
PCI	物理扇区标识
BS_Lng	基站经度
BS_Lat	基站纬度
Azimuth	天线方位角
Down_Tilt_M	机械下倾角
Down_Tilt_E	电子下倾角
High	基站站高
Power	天线发射功率

表 2 采样点数据

Table 2 Sampling point data

字段	描述
IMEI	设备号
Sample_Lat	采样点纬度
Sample_Lng	采样点经度
ECI	主服务小区编号
EARFCN	主服务小区频点
PCI	主服务小区物理小区标识
RSRP	主服务小区参考信号强度
SINR	信号与干扰加噪声比
EARFCN_n	邻区 n 频点
PCI_n	邻区 n 物理小区标识
RSRP_n	邻区 n 参考信号强度

表 1 基站侧的相关字段中,E-CGI 由 4 部分组成:移动国家码、移动网络码、位置区号码和小区标识码。在采样点侧属性中,ECI 为小区编号,提取基站侧属性 E-CGI 中的位置区号码和小区标识码字段,通过 ECI 将终端采样点数据与对其进行服务的小区数据进行关联拼接,作为一条完整的样本数据,即拼接后的数据中既包含终端采样点的数据,也包含该终端接入小区的工程参数配置数据,该样本数据用于训练覆盖预测模型。

3.2 数据处理

本文使用数据来自于城市配送服务工作者配备的路测设备,因此采集到的数据中会夹杂重复数据,此外,还存在部分字段值缺失的数据。在数据处理时,首先应该对冗余和无效数据进行清除,随后对数据添加覆盖标签,以用于训练覆盖预测模型。文本

按照式(2)和式(4),将正常采样点标记为 0,将处于弱覆盖的采样点标记为 1,处于重叠覆盖的采样点标记为 2。最终得到 6 880 条数据,标签为 0 的采样点数据量为 5 941 条,占比 86.3%;标签为 1 的数据量为 447 条,占比 6.5%;标签为 2 的数据量为 939 条,占比 13.6%。这是一个典型的不平衡数据集。使用类别标签失衡的数据集进行训练,会导致模型失效。合成少数类过采样(Synthetic Minority Over-sampling Technique, SMOTE)算法一直是解决不平衡数据集的一个有效方法^[13],本文通过 SMOTE 欠采样与过采样结合的方法,首先对大样本数据进行欠采样,随后对重叠覆盖以及弱覆盖采样点进行过采样。平衡化前后的采样点分布如图 3 所示,由图可知,在保证合理分布的情况下,增加了弱覆盖和重叠覆盖这些小样本数据的数量。




图 3 样本分布

Figure 3 Distribution of Samples

3.3 模型验证

本文使用基于强化学习的覆盖优化方法,是在覆盖预测模型的基础上进行迭代优化,因此覆盖预测模型的准确度是一个十分重要的性能指标。

本文选择的参与模型训练的特征包括:基站位置信息(经度和纬度)、接入终端位置信息(经度和纬度)、基站和基站与接入终端的距离信息、天线方位

角、天线电子下倾角、天线机械下倾角和基站站高。

为了验证预测模型的准确性,将带标签的现网数据集按比例切分为训练集合与测试集合,使用训练集合训练模型;随后使用测试集合来验证模型的预测性能。测试数据集与训练数据集拥有相同的结构,但对于模型来说属于陌生数据。将使用预测模型得到的标签与测试数据集中真实的标签计算,得到预测模型的准确率。

RF 算法与其他标准分类算法的性能比较如表 3 所示。其中原始数据表示直接使用未经过数据清洗的数据,特征工程表示使用经过平衡化并对特征进行归一化处理后的样本数据。

表 3 预测模型准确率对比

数据处理	模型			
	支持	K	决策	RF(%)
	向量机(%)	近邻(%)	树(%)	
原始数据	74	90	91	93
特征工程	79	93	93	95

对比结果表明,RF 算法对于新的输入数据具有很好的预测效果,且 RF 算法相较于其他预测算法,具有更好的预测性能。

3.4 优化结果分析

图 4 所示为覆盖优化过程的迭代对比图,使用基于改进的 Q 学习算法,并将天线下倾角调整步长设置为 1°,天线发射功率调整步长设置为 10 dBm 时,将强化学习奖励值 n 取值为 10,传统的 Q 学习在每一轮迭代中,随机选取一个小区进行优化,改进算法在优化过程中,优化动作被限定在覆盖率最低




图 4 覆盖优化迭代对比

Figure 4 Iterative comparison of coverage optimization

的小区所对应的动作空间中,因此在覆盖率提升方面呈现出稳定的逐步上升趋势,有更稳定的表现。在减少大量波动的情况下,迭代至 1 400 次时趋于收敛,相较于传统算法,收敛速度也得到了提升。优

化后总覆盖率提升接近 20%。

图 5 所示为对于天线下倾角和天线发射功率不同调整步长的迭代曲线对比。分别将天线下倾角和天线发射功率的调整步长设置为 1°和 5 dBm、1°和 7 dBm、1°和 10 dBm、2°和 5 dBm 以及 2°和 10 dBm。由图可见,当天线下倾角调整步长设置为 1°,天线发射功率调整步长调整为 5 dBm 时,算法拥有最快的收敛速度;当天线下倾角调整步长为 2°,天线发射功率调整步长设置为 10 dBm 时,收敛最慢,因此可知,仿真使用数据的覆盖率对于天线发射功率较为敏感,使用小步长动作空间的收敛速度明显优于使用大步长的。




图 5 覆盖优化参数对比

Figure 5 Comparison of coverage optimization parameters

需要指出的是,覆盖问题可能由多个因素造成,针对天线下倾角和发射功率的覆盖优化并不能解决所有的覆盖问题,在工程中,如果始终未能达到理想的覆盖效果,应该考虑多种因素和对应的解决方案。

4 结束语

针对移动通信网络覆盖场景,本文提出了基于 Q 学习的自适应网络覆盖优化算法,使用 RF 模型模拟网络环境,并以此作为 Q 学习的环境,使用基于优先级的动作决策算法进行覆盖优化,减少对于环境假设以及数学建模的依赖。通过改进的 Q 学习算法,优化区域覆盖率提升达到 20%,有效降低了重叠覆盖率与弱覆盖率,同时相较于传统的 Q 学习算法,将收敛速度提升至 1 500 次内,此外缩小天线参数调整的步长,可以将收敛速度进一步提升。相较于启发式天线参数优化算法,本文提出的算法具有经验积累和自主优化的优势,训练后的模型能够识别覆盖问题,并快速做出优化决策;与针对仿真场景提出的天线参数优化方法相比,本算法从实际的网络场景出发,使用现网数据训练模型,具有一定的工程实践基础以及运维工作指导意义。

根据本文研究内容,下一步需要将优化问题扩展为小区容量与覆盖联合优化模型,在保证覆盖率的同时合理地分配网络资源^[14]。

参考文献:

- [1] IMT-2020(5G) 推进组. 5G 概念白皮书[EB/OL]. (2015-02-11) [2021-08-12]. <http://www.imt2020.org.cn/zh>.
IMT-2020(5G) White Paper on Propulsion Group-5G concept[EB/OL]. (2015-02-11) [2021-08-12]. <http://www.imt2020.org.cn/zh>.
- [2] Bhushan N, Li J, Malladi D, et al. Network Densification: The Dominant Theme for Wireless Evolution into 5G[J]. Communications Magazine, IEEE, 2014, 55(2):82—89.
- [3] 夏永康, 梁晓霞. LTE 网络天线倾角自优化算法[J]. 无线电工程, 2014 (3):11—14.
Xia Y K, Liang X W. An Algorithm of Antenna Tilt Self-optimization in LTE Networks[J]. Radio Engineering of China, 2014 (3): 11—14.
- [4] Eckhardt H, Klein S, Gruber M. Vertical Antenna Tilt Optimization for LTE Base stations[C]// Vehicular Technology Conference (VTC Spring). Budapest, Hungary: IEEE, 2011:5956370.
- [5] Ma H, Sahoo P K, Chen Y W. Computational Geometry based Distributed Coverage Hole Detection Protocol for the Wireless Sensor Networks[J]. Journal of Network and Computer Applications, 2011, 34(5): 1743—1756.
- [6] Siomina I, Varbrand P, Yuan D. Automated Optimization of Service Coverage and Base Station Antenna Configuration in UMTS Networks[J]. IEEE Wireless Communications, 2006, 13(6):16—25.
- [7] 范绍帅. 自组织网络智能化控制与优化策略研究[D]. 北京:北京邮电大学, 2015.
Fan Z S. Research on Intelligent Control and Optimization Strategy in Self-Organizing Networks[D]. Beijing: Beijing University of Posts and Telecommunications, 2015.
- [8] Breiman L. Random Forest [J]. Machine Learning, 2001, 45(1):5—32.
- [9] 周志华. 机器学习[M]. 北京:清华大学出版社, 2016.
Zhou Z H. Machine learning[M]. Beijing: Tsinghua University Press, 2016.
- [10] Lin Z, Ouyang Y, Su L, et al. A Machine Learning Assisted Method of Coverage and Capacity Optimization (CCO) in 4G LTE Self Organizing Networks (SON)[C]// 2019 Wireless Telecommunications Symposium (WTS). New York, NY, USA: IEEE, 2019: 8715538.
- [11] 谷欣杏. LTE 网络覆盖优化及无线定位优化算法的研究[D]. 北京:北京邮电大学, 2019.
Gu X X. Research on Lte Network Coverage Optimization and Wireless Positioning Algorithm[D]. Beijing: Beijing University of Posts and Telecommunications, 2019.
- [12] 肖智清. 强化学习: 原理与 Python 实现[M]. 北京:机械工业出版社, 2019.
Xiao Z Q. Reinforcement Learning Theory and Python Implementation [D]. Beijing: Machinery Industry Press, 2019.
- [13] 衷宇清, 陈文文, 李昭桦. 不平衡数据分类中的数据重采样比较研究[J]. 通信技术, 2020, 53(6):1376—1384.
Zhong Y Q, Chen W W, Li Z H. An Algorithm of Antenna Tilt Self-optimization in LTE Networks[J]. Communications Technology, 2020, 53(6): 1376—1384.
- [14] 彭木根, 李勇. 宽带移动通信系统的网络自组织 (SON) 技术[M]. 北京:北京邮电大学出版社, 2013.
Peng M G, Li Y. Self-Organization Networking Techniques in Broadband Mobile Communication Systems [M]. Beijing: Beijing University of Posts and Telecommunications Press, 2013.