

УДК 621.396.721

Метод управления мощностью в беспроводной двухуровневой гетерогенной сети

Багаев Е. С.

Санкт-Петербургский государственный университет телекоммуникаций им. проф. М. А. Бонч-Бруевича
Санкт-Петербург, 193232, Российская Федерация

Постановка задачи: увеличение структурной сложности беспроводных сетей связи актуализирует вопросы обеспечения их устойчивости к воздействиям дестабилизирующих факторов. Одним из таких факторов являются помехи от устройств, работающих рядом друг с другом. **Целью работы** является разработка метода управления мощностью в системе беспроводной связи. **Предлагается** применять способы управления мощностью для двухуровневой гетерогенной сети. **Используемые методы:** решение задачи управления мощностью основано на применении алгоритмов искусственного интеллекта, в частности на обучении с подкреплением. В качестве параметра, благодаря которому возможно определение дальнейшего действия агента, предложено использовать отношение сигнал/шум. **Новизна:** элементами новизны представленного решения являются использование алгоритмов Q-Learning и учет дестабилизирующих факторов в виде помех от соседних базовых станций и пользовательских устройств. **Результат:** использование представленного решения по управлению мощностью в двухуровневой гетерогенной сети позволяет снизить мощность излучаемого сигнала, при этом происходит увеличение скорости передачи данных от базовой станции к пользовательским устройствам; при этом показано, что при предлагаемом методе управления мощностью с ростом числа базовых станций скорость передачи снижается медленнее, чем при экспоненциальном, квадратичном и жадном алгоритмах.

Ключевые слова: сеть связи, искусственный интеллект, машинное обучение, базовые станции, управление мощностью

Введение

В настоящее время беспроводные сотовые сети обычно развертываются как однородные сети, в которых для всех базовых станций характерны одинаковые уровни мощности излучаемого сигнала, диаграммы направленности антенн и т. д. Также все базовые станции обслуживают примерно одинаковое количество пользовательских терминалов со схожими требованиями к качеству обслуживания.

Процедура планирования сети основана на тщательном выборе будущего местоположения базовых станций. Последующая настройка параметров базовых станций позволяет достичь оптимального покрытия сети сотовой связи даже на обширной территории. Данный способ развертывания сетей влечет за собой возникновение так называемых теневых областей, особенно на границах зоны действия базовой станции, в которых уровень сигнала недостаточно высок.

Гетерогенные сети способны исправить этот недостаток за счет внедрения дополнительных базовых станций. Такая сеть состоит из основных базовых станций, для которых уровень излучаемой мощности обычно равен от 5 до 40 Вт. Также в радиусе действия основной базовой станции располагаются подконтрольные ей пико- и фемтобазовые и ретрансляционные станции, мощность излучения которых не превы-

Библиографическая ссылка на статью:

Багаев Е. С. Метод управления мощностью в беспроводной двухуровневой гетерогенной сети // Вестник СПбГУТ. 2023. Т. 1. № 2. С. 2. EDN: KIZLYW

Reference for citation:

Bagaev E. Power Management Method in a Wireless Two-Level Heterogeneous Network // Herald of SPbSUT. 2023. Vol. 1. Iss. 2. P. 2. EDN: KIZLYW

шает 2 Вт. Размещение таких малых станций обычно имеет незапланированный характер, основным критерием для выбора мест их расположения является устранение теневых зон в покрытии сети и повышение пропускной способности. Благодаря меньшей мощности передачи и небольшим физическим размерам малые базовые станции могут обеспечивать гибкость при подключении к сети.

В однородной сети каждое пользовательское устройство обслуживается базовой станцией с самым высоким уровнем сигнала, в то время как сигналы, принимаемые от других базовых станций, воспринимаются как помеха. В гетерогенной сети такой принцип может привести к значительному снижению производительности из-за роста количества базовых станций. В двухуровневых гетерогенных сетях координация ресурсов между базовыми станциями, более совершенные методы выбора серверов и более продвинутые алгоритмы управления мощностью могут обеспечить существенный прирост пропускной способности по сравнению с традиционным подходом к развертыванию сети.

Постановка задачи

Для формальной постановки и решения задачи в работе введены обозначения, представленные в таблице 1.

Таблица 1. Принятые обозначения

Обозначение	Физический смысл обозначения
MBS	макробазовая станция
FBS	фемтобазовая станция
$SINR$	отношение сигнал/шум
MDP	марковский процесс принятия решений
A_k	набор действий для базовой станции
p_{min}	минимальная мощность передачи
p_{max}	максимальная мощность передачи
X_k	набор состояний для базовой станции
$a' \in A$	скорость обучения
R	вознаграждение для агента
CQI	индикатор качества канала
k, t	счетчики

Машинное обучение в современных сетях радиосвязи

Методы машинного обучения успешно применяются во многих областях, таких как компьютерное зрение, обработка естественного языка и т. д., и все чаще используются в системах беспроводной связи из-за преимуществ искусственного интеллекта. Множество исследований демонстрируют, что алгоритмы машинного обучения могут не только обеспечить отличную производительность линий связи, но и снизить вычислительную мощность. Алгоритмы машинного обучения позволяют реализовать распределение мощности в реальном времени. В ряде исследований [1–3] показано, что применение таких алгоритмов ведет к увеличению пропускной способности сети, снижению времени вычислений; предложенные методы оказываются эффективными даже при наличии шума на входе системы.

В данной работе предлагается использовать для управления мощностью один из алгоритмов обучения с подкреплением – Q-Learning. Применение Q-Learning с целью оптимизации ресурсов в системах беспроводной связи основано на том, что все основные составляющие сети могут быть представлены как одна из структурных частей алгоритма обучения с подкреплением. Опишем двухуровневую гетерогенную сеть так, чтобы данное представление позволяло определить взаимодействие всех элементов и давало возможность реализовать управление мощностью базовых станций с помощью Q-Learning.

Основным элементом двухуровневой гетерогенной сети является базовая станция, которая имеет в своем управлении некоторое количество других базовых станций, имеющих значительно меньший радиус обслуживания. Обозначим главную базовую станцию – макробазовую станцию – как MBS (*аббр. от англ. Macro Base Station*), а подчиняющиеся ей фемтобазовые станции как FBS (*аббр. от англ. Femto Base Station*). Дальнейшая разработка метода управления мощностью с помощью искусственного интеллекта требует определения основных функциональных узлов сети в качестве элементов схемы обучения с подкреплением. Таким образом, FBS и MBS в нашем случае будут представлены как агент и окружающая среда. Основными функциями агента являются обслуживание подконтрольных ему пользовательских устройств (User Equipment) и, как следствие, обеспечение необходимого уровня мощности излучаемого сигнала. Описанная структура приведена на рисунке 1.




Рис. 1. Двухуровневая гетерогенная сеть с точки зрения Q-Learning

На рисунке также обозначены данные, которые MBS передает агенту, – значения отношения сигнал/шум – SINR (*аббр. от англ. Signal Interference + Noise Ratio*). Значения SINR необходимы агенту для принятия решения об изменении мощности излучаемого сигнала.

Важно отметить, что все процессы принятия решений об изменении мощности на FBS будут марковскими процессами принятия решений – MDP (*аббр. от англ. Markov Decision Process*). Это означает, что увеличение или уменьшение мощности на FBS будет основано лишь на настоящем состоянии системы, при этом предыдущие состояния не учитываются.

Для дальнейшей разработки метода управления мощностью представим описанную ранее двухуровневую гетерогенную сеть как многоагентный MDP:

- среда для FBS выглядит как макросота и набор фемтосот;
- агент представлен как FBS и является независимым агентом в MDP;
- цели агента: повышение общей скорости передачи данных, гарантированное обеспечение SINR для пользователей, а также для всех макропользовательских устройств – MUE (*аббр. от англ. Macro User Equipment*);

- набор действий A_k :
 - 1) уровень мощности передачи определяется действием FBS;
 - 2) FBS с номером k устанавливает уровень излучаемого сигнала из набора A_k , сюда входят значения, включающие в себя минимальную и максимальную мощность передачи p_{\min} и p_{\max} , соответственно;
 - 3) FBS не имеет представления об окружающей среде и выбирает свои действия с одинаковой вероятностью во всех случаях;
 - 4) следовательно, для построения множества A_k выбираются равные размеры шага Δp между p_{\min} и p_{\max} ;
- набор состояний X_k :
 - 1) установившееся состояние напрямую влияет на производительность MUE и FUE, требуется ввести 4 переменные, отображающие текущее состояние сети;
 - 2) переменные X_1 и X_2 — показатели эффективности для MUE и FUE;
 - 3) очень важным нюансом является взаимное расположение FBS относительно MUE и MBS, поскольку позволяет определить суммарную мощность помех в MUE, следовательно, переменная X_3 является индикатором помех для FBS, а переменная X_4 — индикатором помех для MBS;
 - 4) значения X_1 и X_2 могут быть равны 0 либо 1 (0 — для случаев, когда требование по минимальному SINR не удовлетворяется, 1 — требование удовлетворяется); значения для X_3 и X_4 лежат в пределах $\{0, 1, 2, \dots, N_i\}$ и указывают на расстояния от FBS до MUE и MBS, соответственно.

Модель управления мощностью для двухуровневой гетерогенной сети

Для решения поставленной задачи используем Q-Learning. Правило обновления Q-Learning при оценке политики для глобальной Q-функции может быть представлено в виде:

$$Q(x^{(t)}, a^{(t)}) \leftarrow Q(x^{(t)}, a^{(t)}) + \alpha^{(t)}(x, a) \left(R^{(t+1)}(x^{(t)}, a^{(t)}) + \beta \underbrace{\max_{a'} Q(x^{(t+1)}, a')}_{(M)} - Q(x^{(t)}, a^{(t)}) \right), \quad (1)$$

где $a' \in A$, $\alpha^{(t)}(x, a)$ — скорость обучения на временном интервале t ; $x^{(t+1)}$ — новое состояние беспроводной сети [4]; многочлен M — максимальное значение глобальной Q-функции, которая становится известна на состоянии $x^{(t+1)}$. После каждой итерации FBS будет получать отложенное вознаграждение $R^{(t+1)}(x^{(t)}, a^{(t)})$, и после этого будет происходить обновление глобальной Q-функции.

Применение Q-Learning с постоянной скоростью обучения встречается в работах, посвященных решению задачи оптимизации [5, 6]. Однако согласно [7] при функционировании на конечном числе итераций результативность Q-Learning может быть улучшена путем вычислений со сниженной скоростью обучения. Поэтому в дальнейшем будем использовать такую скорость обучения, которую можно задать как:

$$\alpha^{(t)}(x, a) = \frac{1}{[1 + t(x, a)]'} \quad (2)$$

где $t(x, a)$ — количество раз, когда устанавливается пара «состояние — действие» (x, a) на временном интервале t . Стоит отметить, что при применении данной скорости обучения необходимо будет отслеживать количество срабатываний пары «состояние — действие», что впоследствии приведет к увеличению потребляемой памяти.

Существуют две альтернативы для обучения новых FBS в случае, если они находятся в состоянии присоединения к беспроводной сети: они могут использовать либо независимое, либо совместное

обучение. При независимом обучении каждая FBS пытается максимизировать свою собственную Q-функцию. Другими словами, многочлен M из выражения 1 может быть представлен как:

$$M = \max_{a'} \sum_{k \in K} Q_k(x_k^{(t+1)}, a'_k) \approx \sum_{k \in K} \max_{a'_k} Q_k(x_k^{(t+1)}, a'_k). \quad (3)$$

При совместном обучении FBS согласованно используют свои Q-функции, и предполагается, что FBS в одном состоянии будут принимать одни и те же решения. Следовательно, многочлен M аппроксимируется как:

$$M = \max_{a'} \sum_{k \in K} Q_k(x_k^{(t+1)}, a'_k) \approx \max_{a'_k} \sum_{k \in K'} Q_k(x_k^{(t+1)}, a'_k), \quad (4)$$

где K' – набор FBS, находящихся в одинаковом состоянии $x_k^{(t+1)}$. Совместное обучение может привести к росту значения совместного вознаграждения [8]. Однако взаимодействие может привести к одинаковой политике для FBS с одинаковыми состояниями и дополнительным расходам на вычисление, поскольку Q-функции между FBS должны использоваться совместно по каналу обратной связи. Правило единичного обновления для k -й FBS может быть получено из выражения:

$$Q_k(x_k^{(t)}, a_k^{(t)}) \leftarrow Q_k(x_k^{(t)}, a_k^{(t)}) + \alpha^{(t)} \left(R^{(t+1)}(x_k^{(t)}, a_k^{(t)}) + \beta Q_k(x_k^{(t+1)}, a_k^*) - Q_k(x_k^{(t)}, a_k^{(t)}) \right), \quad (5)$$

где $R^{(t+1)}(x_k^{(t)}, a_k^{(t)})$ – функция вознаграждения k -й FBS; a_k^* – определяется следующим образом для самостоятельного и совместного обучения, соответственно:

$$\arg \max_{a'_k} Q_k(x_k^{(t+1)}, a'_k), \quad (6)$$

$$\arg \max_{a'_k} \sum_{k \in K'} Q_k(x_k^{(t+1)}, a'_k). \quad (7)$$

В нашей работе для представления Q-функции используется табличное представление, в котором строки таблицы относятся к состояниям, а столбцы – к действиям агента. Как правило, для больших наборов состояний нейронные сети более эффективны в случае, если они задаются в качестве функций. Однако здесь рассматривается влияние данных именно в формате переменных.

Процесс обучения для FBS происходит в течение L кадров. В начале каждого кадра FBS выбирает действие (т. е. ту мощность, с которой будет происходить передача). Затем FBS отправляет пакет данных в фемтопользовательское устройство – FUE (аббр. от англ. Femto User Equipment). Далее FUE возвращает все необходимые измерения, такие как индикатор качества канала – CQI (аббр. от англ. Channel Quality Indicator), чтобы FBS могла оценить SINR в FUE и рассчитать функцию вознаграждения.

Определение функции вознаграждения

Важным моментом в разработке метода распределения мощности в беспроводных сетях является формирование функции вознаграждения, поскольку именно она влияет на цели FBS. Как правило, количественного подхода к ее разработке не существует. Далее предложен системный подход к получению функции вознаграждения, основанный на изначально поставленной задаче оптимизации. Затем будет проведено сравнение разработанной функции с результатами, полученными ранее и приведенными в [5, 6, 9].

Функция вознаграждения для FBS с номером k обозначается как R_k . FBS располагает информацией о минимально требуемом SINR для MUE (Γ_0) и минимально требуемом SINR для связанного с ним FUE (Γ_k). Кроме того, после выполнения действия на каждом шаге k -я FBS имеет доступ к скорости передачи MUE (r_0) и скорости передачи FUE (r_k). Следовательно, R_k рассматривается как функция нескольких переменных $R_k: (r_0, r_k, \Gamma_0, \Gamma_k) \rightarrow \mathbb{R}$.

Для разработки функции вознаграждения требуется оценить прогресс k -й FBS в достижении цели оптимизации. Основываясь на входных аргументах для этой функции, определим две методики оценки прогресса: 1) $(r_0 - \log_2(1 + \Gamma_0))$ для MUE и 2) $(r_k - \log_2(1 + \Gamma_k))$ для k -й FBS. Чтобы упростить вычисления, возьмем функцию вознаграждения как полиномиальную функцию определенных оценок прогресса следующим образом:

$$R_k = (r_0 - \log_2(1 + \Gamma_0))^{k_1} + (r_k - \log_2(1 + \Gamma_k))^{k_2} + C, \quad (8)$$

где k_1 и k_2 – целые числа; $C \in \mathbb{R}$ – константа, называемая смещением функции вознаграждения.

Постоянная смещения C в функции вознаграждения оказывает два эффекта на алгоритм обучения, первый из которых – влияние смещения на конечное значение состояний. Предположим, что функции вознаграждения R_1 и R_2 задаются как $R_1 = f(\cdot)$ и $R_2 = f(\cdot) + C$, $C \in \mathbb{R}$. Обозначим значения состояния x для заданной политики π , используя R_1 в качестве $V_1(x)$ и значение состояния x для той же политики, как R_2 в качестве $V_2(x)$:

$$V_2(x) = \mathbb{E}_\pi \left[\sum_{t=0}^{\infty} \beta^t (f^{(t+1)}(\cdot) + C) \right] = \mathbb{E}_\pi \left[\sum_{t=0}^{\infty} \beta^t f^{(t+1)}(\cdot) \right] + C \sum_{t=0}^{\infty} \beta^t = V_1(x) + \frac{C}{1 - \beta}. \quad (9)$$

Как видно из этого выражения, смещение функции вознаграждения добавляет постоянную величину $\frac{C}{1-\beta}$ к значению состояний. Однако после сходимости алгоритма все значения состояний становятся одинаковыми.

Второй эффект характеризуется как влияние смещения в самом начале процесса обучения и описывается с помощью функции действия агента, т. е. Q-функции. Предположим, что Q-функция агента инициализирована нулевыми значениями, а функция вознаграждения определена как $R = f(\cdot) + C$. Далее представим, что первый переход агента из состояния x' в состояние x'' происходит за счет выполнения действия a на временном интервале t , что означает $x^{(t)} = x'$ и $x^{(t+1)} = x''$. Правило обновления на временном интервале t задается формулой (5) и записывается как:

$$\begin{aligned} Q(x', a) &\leftarrow Q(x', a) + \alpha^{(t)}(x', a) \left(R(x', a) + \beta \max_{a'} Q(x'', a') - Q(x', a) \right) \leftarrow \\ &\leftarrow \alpha^{(t)}(x', a) \left(f(\cdot) + \beta \max_{a'} Q(x'', a') \right) + \underbrace{\alpha^{(t)}(x', a) C}_{(A)}. \end{aligned} \quad (10)$$

Согласно приведенному выражению, после первого перехода из состояния x' в состояние x'' Q-функция для состояния x' смещается на величину (A) . Если $(A > 0)$, значение состояния x' увеличивается, а если $(A < 0)$ – уменьшается. Следовательно, те состояния, в которых агент уже когда-либо находился, будут более предпочтительны для него в начале процесса обучения. Это правило будет работать до тех пор, пока агент не изучит пространство состояний в достаточной мере.

Изменение поведения агента в процессе обучения может быть использовано для того, чтобы подтолкнуть его к желаемым действиям или состояниям. Но, как было сказано ранее, агент заранее ничего не знает об окружающей среде, поэтому выбирается смещение $C = 0$.

Функция вознаграждения для k -й FBS, $R_k: (r_0, r_k, \Gamma_0, \Gamma_k) \rightarrow \mathbb{R}$, является непрерывной и дифференцируемой функцией \mathbb{R}^2 :

$$R_k: (r_0, r_k, \Gamma_0, \Gamma_k) = (r_0 - \log_2(1 + \Gamma_0))^{k_1} + (r_k - \log_2(1 + \Gamma_k))^{k_2}, \quad (11)$$

где k_1 и k_2 — целые числа.

Целью FBS является увеличение скорости передачи. С другой стороны, достижение высокой скорости передачи на MUE — это основная задача для FBS, следовательно, R_k должна обладать следующим свойством:

$$\frac{\partial R_k}{\partial r_i} \geq 0, \quad i = 0, k. \quad (12)$$

Данное свойство означает, что более высокая скорость передачи для FBS или MUE приводит к более высокому вознаграждению. Следовательно, учитывая это, разрабатываемая функция вознаграждения будет способна мотивировать FBS на увеличение r_0 и r_k настолько, насколько это возможно:

$$R_k = (r_0 - \log_2(1 + \Gamma_0))^{2m-1} + (r_k - \log_2(1 + \Gamma_k))^{2m-1}, \quad (13)$$

где m — целое число.

Вышеуказанная функция вознаграждения учитывает требования к минимальной скорости передачи данных для FUE и MUE, в то же время поощряя FBS увеличивать скорость передачи данных.

Чтобы внести ясность в нашу функцию вознаграждения, рассмотрим функции вознаграждения, показанные в более ранних работах других авторов. Функция вознаграждения в [5] является квадратичной, в [6] — экспоненциальной, а в [9] — приближенной функцией вознаграждения. Квадратичная функция вознаграждения разработана на основе консервативного подхода. Фактически FBS применяется для выбора действий, которые обеспечивают скорость передачи данных, близкую к минимальному требованию. Таким образом, более высокая или более низкая скорость приводит к той же величине вознаграждения. Квадратичную функцию вознаграждения можно описать следующим образом:

$$\frac{\partial R_k}{\partial r_i} \times (r_i - \log_2(1 + \Gamma_i)) \leq 0, \quad i = 0, k. \quad (14)$$

Ранее указанное свойство подразумевает, что, если скорость передачи на FBS или MUE выше минимального требования, действия, увеличивающие скорость передачи данных, уменьшают вознаграждение. Следовательно, эта функция препятствует скорости передачи данных в беспроводных сетях связи. Скорость передачи данных на FBS для экспоненциальной функции и приближенной функции вознаграждения задаются свойством из (12), а (14) задает скорость передачи на MUE для этих же функций. Другими словами, они удовлетворяют условию:

$$\frac{\partial R_k}{\partial r_0} \times (r_0 - \log_2(1 + \Gamma_0)) \leq 0, \quad \frac{\partial R_k}{\partial r_k} \geq 0. \quad (15)$$

По мере увеличения плотности расположения FBS, вышеуказанные функции приводят к возрастанию мощности передачи для достижения более высокой индивидуальной скорости для FUE, в то же время создавая более высокие помехи для MUE и других соседних FUE. Фактически, поскольку увеличение коэффициента FUE вознаграждается, выполнение действий, приводящих к росту коэффициента MUE, уменьшает вознаграждение. Однако у FBS должна быть возможность уменьшить мощность своей передачи, чтобы увеличить скорость MUE. Такая особенность работы FBS важна, поскольку это приводит к тому, что FBS будет создавать меньше помех для соседних фемтосот. Поэтому разрабатываемая модель предоставляет равные возможности для увеличения скорости передачи на MUE или FUE.

Значение функций вознаграждения для разных FBS различно. На рисунке 2 приведены графики для указанных функций. Важными моментами, на которые стоит обратить внимание при рассмотрении этих графиков, являются максимальные значения функций вознаграждения, изменения функций вознаграждения в зависимости от минимальных требований и в зависимости от r_k и r_0 .




Рис. 2. Функции вознаграждения: а) предложенная в работе функция вознаграждения для $m = 2$; б) квадратичная функция вознаграждения при максимуме в точке $(4; 0,5)$; в) экспоненциальная функция вознаграждения; г) приближенная функция вознаграждения

Предлагаемая в данной работе функция вознаграждения, изображенная на рисунке 2а, показывает, что FBS способна выбирать уровень мощности излучения, при котором достигается увеличение как r_k , так и r_0 . В то же время другие функции вознаграждения достигают своего максимума в точках, в которых переменные r_k и r_0 не достигают максимального значения на заданном интервале.

Применение модели распределения мощности для оптимизации двухуровневой гетерогенной сети

Для симуляции модели были заданы следующие начальные данные:

- радиус зоны покрытия макросоты равен 350 м;
- макросота назначает отдельный диапазон частот для каждого MUE.

Радиус действия каждой FBS ограничен малой площадкой с размерами 10×10 м. В центре находится MUE с поддержкой FUE на расстоянии до 5 м. Доступ к FBS для MUE закрыт — это значит, что MUE не может подключиться к FBS, но при этом FBS является источником помехового сигнала для MUE, так как они работают на одной частоте.

Пусть MUE и все FBS работают на одних и тех же поднесущих, что позволит учесть наихудший сценарий работы системы связи. Следующим шагом станет определение начальных данных. Пусть FBS и MBS работают на частоте $f = 2,0$ ГГц. Мощность излучения MBS составляет 33 дБм, а FBS выбирает свою мощность излучения из диапазона от 5 до 15 дБм с шагом в 1 дБм. Чтобы смоделировать потери на распространение сигнала, используем модель городскую модель, предложенную в [10]. Параметры на затухание сигнала приведены в таблице 2, где R – расстояние между приемником и передатчиком, в метрах; L_{ow} – потери на затухание в стенах (20 дБ) [10]; $d_{2D,indoor}$ – двухмерное расстояние. В нашем случае полагаем, что $d_{2D,indoor} = R$.

Таблица 2. Модель распространения сигнала в городской среде

Направление канала связи	Потери на распространение сигнала, дБ
от MBS к MUE	$15,3 + 37,6 \log_{10} R$
от MBS к FUE	$15,3 + 37,6 \log_{10} R + L_{ow}$
от FBS к FUE	$56,76 + 20 \log_{10} R + 0,7d_{2D,indoor}$
от FBS к FUE	$\max(15,3 + 37,6 \log_{10} R + 38,46 + 20 \log_{10} R) + 18,3 + 0,7d_{2D,indoor}$

Минимальные требования к SINR для MUE и FUE определяются на основе необходимой скорости передачи данных для поддержки обслуживаемого пользователя. В дальнейших расчетах предполагается, что минимальная требуемая скорость передачи для обеспечения качества обслуживания – QoS (аббр. от англ. Quality of Service) на MUE равна:

$$\log_2(1 + \Gamma_0) = 4 \text{ б/с/Гц.} \quad (16)$$

Минимальная скорость для FUE:

$$0,5 \log_2(1 + \Gamma_k) = 4 \text{ б/с/Гц.} \quad (17)$$

Для выполнения процесса Q-Learning требуется минимальное количество кадров L , которое вычисляется исходя из достижения показателя оптимальности в 90 %, с вероятностью не менее 0,9, т. е. $\delta = 0,1$. Все перечисленные исходные данные для симуляции приведены в таблице 3. Значения для параметров Q-Learning выбираются в соответствии с [11].

Таблица 3. Модель распространения сигнала в городской среде

Параметр	Значение
Длительность кадра	2 мс
Тепловой шум	-174 дБм/
Модель трафика	Полный буфер
Радиусы колец d'_1, d'_2, d'_3	50; 100; 400 м
Радиусы колец d_1, d_2, d_3	17,5; 22,5; 45 м
Количество итераций L	$T \times X A_k $
Обучающий параметр β	0,9
Вероятность обучения (исследовательская вероятность)	10 %
p_{\min}	5 дБм
p_{\min}	15 дБм
Δp	1 дБм

Сначала симуляция проходит для одной фемтосоты. После первого приближения в сеть добавляется новая FBS, которая также начинает выполнять алгоритм, в то время как первая FBS уже завершила процесс обучения и лишь принимает решение о выборе уровня излучаемой мощности. После того, как новая FBS завершила процесс обучения, в сеть добавляется еще одна FBS и т. д. Результаты моделирования в этой работе представлены в зависимости от количества FBS: от 1 до 10.

Анализ результатов симуляции

Продемонстрируем результаты симуляции для распределения мощности, определив сначала два набора состояний: $\chi_1 = \{X_1, X_3, X_4\}$ и $\chi_2 = \{X_2, X_3, X_4\}$. В обоих случаях FBS будут знать о своем местоположении относительно MUE и MBS благодаря наличию X_3, X_4 в наборах. Набор состояний χ_1 передает информацию о состоянии FUE в FBS, а набор χ_2 — о состоянии MUE в FBS.

Для того чтобы оценить разницу между независимым и совместным обучением, а также разницу между обучением при разных наборах состояний, используем четыре различные конфигурации обучения: независимое и совместное обучение с применением обоих наборов состояний ($IL + \chi_1$), ($IL + \chi_2$) и ($CL + \chi_1$), ($CL + \chi_2$). Результаты представлены на рисунке 3 и сравниваются с так называемым жадным алгоритмом (Greedy algorithm), в котором каждая FBS выбирает максимум излучаемой мощности.

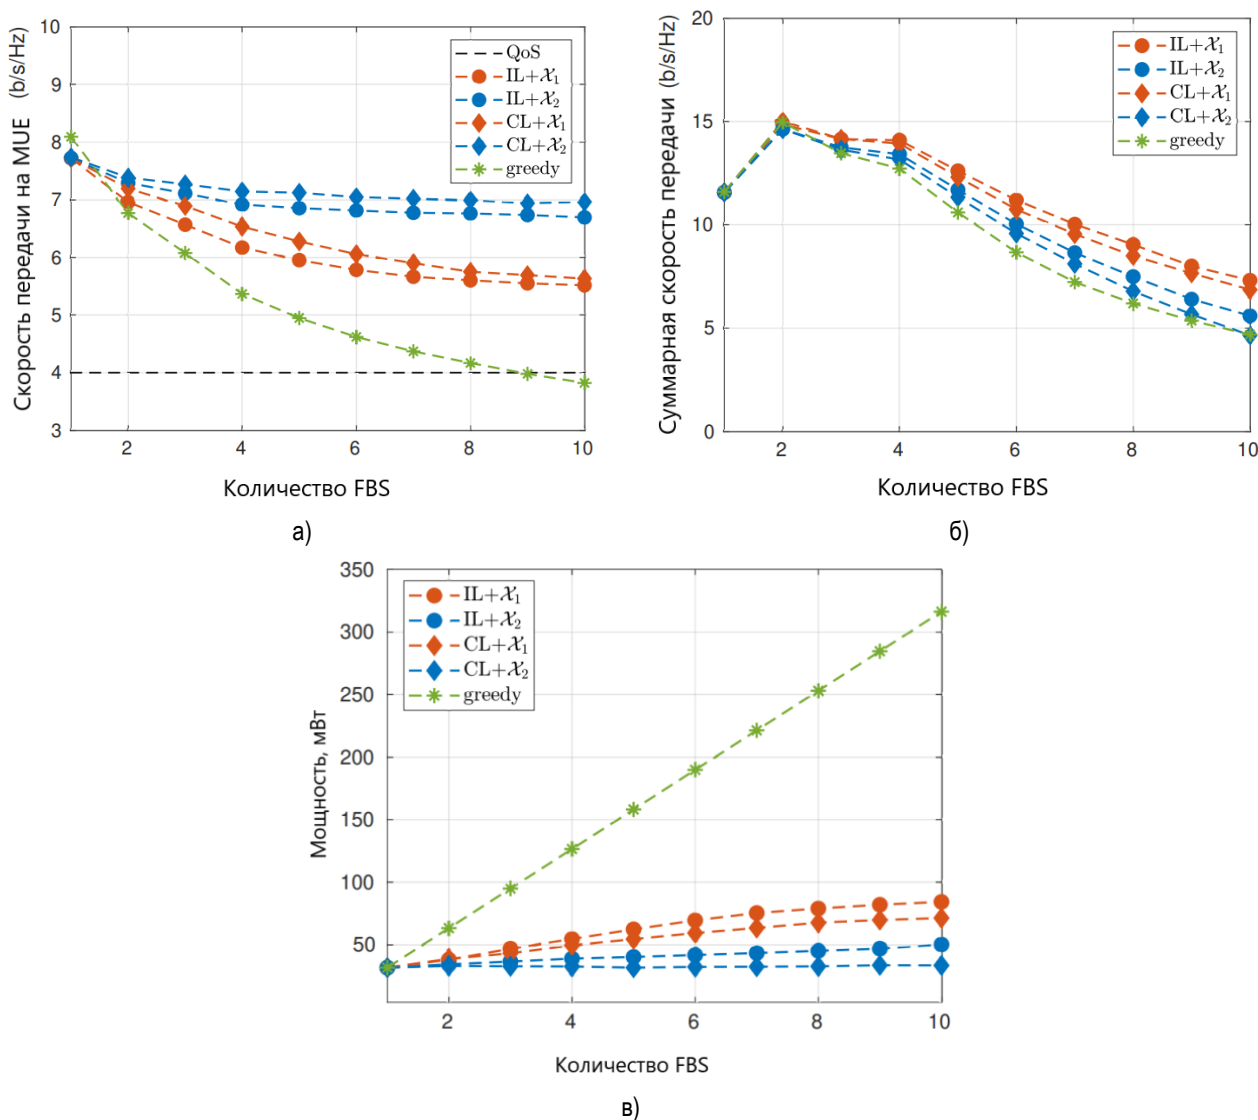


Рис. 3. Результаты симуляции при использовании независимого и совместного обучения с применением двух наборов состояний: а) скорость передачи данных на MUE; б) суммарная скорость передачи данных для FUE; в) суммарная скорость передачи данных для FBS

Из рисунка 3а видно, что при жадном алгоритме каждая FBS использует максимум доступной мощности, вследствие чего помехи для MUE максимальны, а скорость передачи минимальна. При этом на FUE не достигается максимальная скорость передачи, что также вызвано высоким уровнем помех.

Набор состояний χ_2 предоставляет MUE знание о QoS для подчиненных FBS. Однако, как мы видим на рисунке 3а, результаты $(IL + \chi_2)$ лучше, чем при $(IL + \chi_1)$. Это утверждение справедливо и для CL . Также мы можем наблюдать эту взаимосвязь на графике, представляющем суммарную скорость передачи для FUE (рисунок 3б).

Из результатов симуляции можно сделать вывод, что IL и CL имеют отличительные особенности, а именно: при IL достигается более высокая скорость передачи данных для FBS и более низкая скорость передачи данных для MUE, в то время как CL может поддерживать более высокую скорость передачи для MUE за счет низкой общей скорости для FBS.

Для максимизации суммарной скорости передачи данных для FUE воспользуемся комбинацией независимого обучения и набора состояний χ_1 в качестве конфигурации для последующего обучения. На рисунке 4 представлены результаты расчета скорости передачи данных для MUE, суммарная скорость передачи для всех FUE, а также общая мощность излучения для FBS.

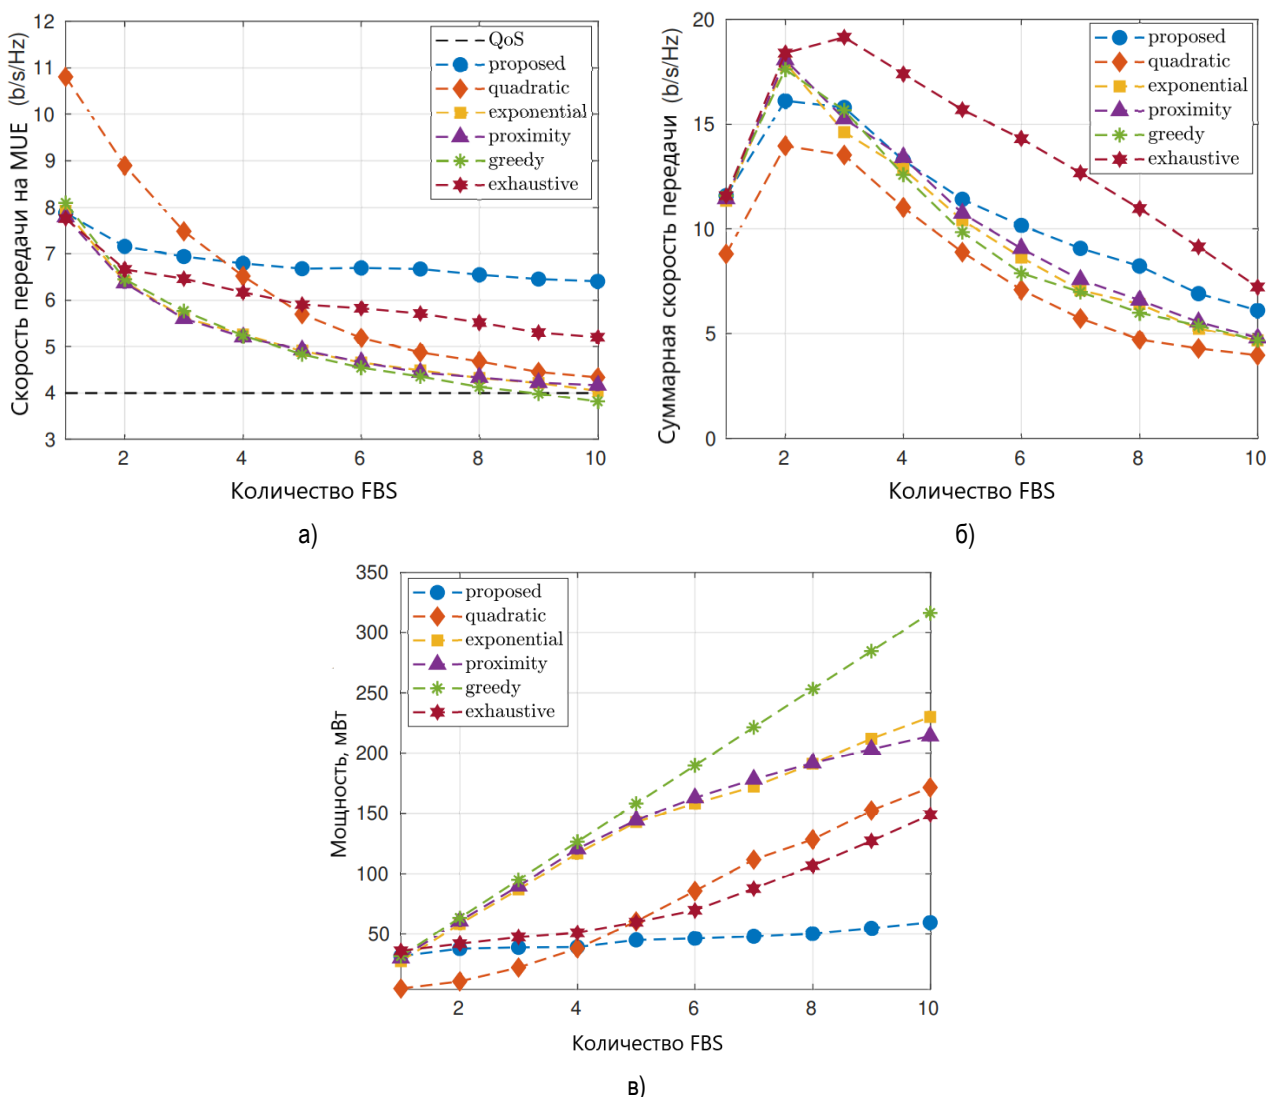


Рис. 4. Результаты симуляции для различных типов алгоритмов: а) скорость передачи данных на MUE; б) суммарная скорость передачи данных для FUE; в) суммарная скорость передачи данных для FBS

Также результаты моделирования сравниваются с жадным алгоритмом и полным перебором значений. Реализация алгоритма с полным перебором значений предлагает нам максимально возмож-

ную скорость передачи данных для всех узлов в сети. Графики для моделирования квадратичной, экспоненциальной и приближенной функций вознаграждения имеют быстро снижающийся характер для скорости передачи данных для MUE. В то же время конечные графики функции вознаграждения для предлагаемой в данной работе модели имеют более плавный характер — с увеличением количества FBS в сети скорость передачи данных снижается минимум в 1,5 раза медленнее, чем при остальных функциях вознаграждения, это видно на рисунке 4а. Там же показано, что скорость передачи данных для предлагаемой модели в 1,2 раза выше, чем у ближайшей по значению скорости передачи модели. Рисунок 4в показывает, что предлагаемая функция вознаграждения уменьшает суммарную мощность на FBS, что, в свою очередь, может привести к снижению уровня помех на FUE. В сравнении с функцией вознаграждения, полученной методом перебора, выигрыш предлагаемой функции очевиден. По рисунку 4в видно, что введенная функция вознаграждения предлагает снижение мощности на 50 мВт для восьми FBS, работающих в сети. Однако из рисунков 4а и 4б видно, что при последующем увеличении мощности возможно снижение скорости передачи данных на MUE без преодоления минимального требуемого значения.

Выводы

В работе представлен метод управления мощностью для двухуровневой гетерогенной сети. Предложенный метод использует алгоритмы машинного обучения, что выделяет его на фоне операций по планированию беспроводных сетей мобильной связи. В частности, используется обучение с подкреплением, что позволяет добиться увеличения скорости передачи на базовой станции по сравнению с другими функциями. Также видно, что при увеличении числа базовых станций в сети скорость передачи данных между станциями и пользовательскими устройствами остается выше, чем при применении алгоритмов оптимизации, основанных только на планировании беспроводной сети.

В дальнейшем планируется развитие представленного метода в направлении учета не только отношения SINR и CQI сети связи, но и других параметров, учет которых позволил бы снизить уровень интерференции на уровне MBS.

Литература

1. Ye H., Li G. Y., Juang B.-H. Power of Deep Learning for Channel Estimation and Signal Detection in OFDM Systems // *IEEE Wireless Communication Letters*. 2018. Vol. 7. Iss. 1. PP. 114–117.
2. Sun H., Chen X., Shi Q., Hog M., Fu X., et al. Learning to Optimize: Training Deep Neural Networks for Wireless Resource Management // *Proceedings of the IEEE 18th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC)*. 2017. PP. 1–6. DOI: 10.1109/SPAWC.2017.8227766
3. Matthiesen B., Zappone A., Besser K.-L., Jorswieck E. A., Debbah M. A Globally Optimal Energy-Efficient Power Control Framework and its Efficient Implementation in Wireless Interference Networks // *IEEE Transactions on Signal Processing*. 2018. Vol. 68. DOI: 10.1109/TSP.2020.3000328
4. Watkins C. J. C. H., Dayan P. Q-Learning // *Machine Learning*. 1992. Vol. 8. Iss. 3. PP. 279–292.
5. Galindo-Serrano A., Giupponi L. Distributed Q-Learning for Aggregated Interference Control in Cognitive Radio Networks // *IEEE Transactions on Vehicular Technology*. 2010. Vol. 59. Iss. 4. PP. 1823–1834. DOI: 10.1109/TVT.2010.2043124
6. Saad H., Mohamed A., ElBatt T. Distributed Cooperative Q-Learning for Power Allocation in Cognitive Femtocell Networks // *Proceedings of IEEE Vehicular Technology Conference*. 2012. PP. 1–5. DOI: 10.1109/VTCFall.2012.6399230
7. Guestrin C., Lagoudakis M. G., Parr R. Coordinated Reinforcement Learning // *Proceedings of The Nineteenth International Conference on Machine Learning*. 2002. PP. 227–234.
8. Busoniu L., Babuska R., Schutter B. D. A Comprehensive Survey of Multiagent Reinforcement Learning // *IEEE Transactions on Systems, Man, and Cybernetics. Part C (Applications and Reviews)*. 2008. Vol. 38. Iss. 2. PP. 156–172. DOI: 10.1109/TSMCC.2007.913919

9. Tefft J. R., Kirsch N. J. A Proximity-Based Q-Learning Reward Function for Femtocell Networks // Proceedings of the 78th Vehicular Technology Conference. 2013. PP. 1–5. DOI: 10.1109/VTCFall.2013.6692057
10. Kim J., Lee D., Sung W. Interference Coordination of Heterogeneous LTE Systems Using Remote Radio Heads // EURASIP Journal on Advances in Signal Processing. 2013. Vol. 90. DOI: 10.1186/1687-6180-2013-90
11. Zarakovitis C. C., Ni Q., Skordoulis D. E., Hadjinicolaou M. G. Power-Efficient Cross-Layer Design for OFDMA Systems with Heterogeneous QoS, Imperfect CSI, and Outage Considerations // IEEE Transactions on Vehicular Technology. 2012. Vol. 61. Iss. 2. PP. 781–798. DOI: 10.1109/TVT.2011.2179817

Статья поступила 5 декабря 2023 г.
Одобрена после рецензирования 18 декабря 2023 г.
Принята к публикации 19 декабря 2023 г.

Информация об авторе

Багаев Егор Сергеевич — аспирант кафедры радиосвязи и вещания Санкт-Петербургского государственного университета телекоммуникаций им. проф. М. А. Бонч-Бруевича.
E-mail: bagaev13@yandex.ru

Power Management Method in a Wireless Two-Level Heterogeneous Network

E. Bagaev

The Bonch-Bruевич Saint Petersburg State University of Telecommunications,
St. Petersburg, 193232, Russian Federation

Purpose. *The increase in the structural complexity of wireless communication networks actualizes the issues of ensuring their resistance to the effects of destabilizing factors. One of these factors is interference from devices working next to each other. The aim of the work is to develop a method of power management in a wireless communication system. It is proposed to apply power management methods for a two-level heterogeneous network with a goal.* **Methods.** *The solution of the power management problem is based on the use of artificial intelligence algorithms, in particular, reinforcement learning. As a parameter, thanks to which it is possible to determine the further action of the agent, it is proposed to use the signal-to-noise ratio.* **Novelty.** *The novelty elements of the presented solution are the use of Q-Learning algorithms and consideration of destabilizing factors in the form of interference from neighboring base stations and user devices. Result. Using the presented solution for the power management method in a two-level heterogeneous network allows you to reduce the power of the emitted signal, while increasing the data transfer rate from the base station to user devices. At the same time, it is shown that with the proposed power management method, with an increase in the number of base stations, the transmission rate decreases more slowly than with exponential, quadratic and greedy algorithms.*

Key words: *communication network, artificial intelligence, machine learning, base stations, power management*

Information about Author

Bagaev Egor – is a postgraduate student of the Department of Radio Communications and Broadcasting (The Bonch-Bruевич Saint Petersburg State University of Telecommunications).
E-mail: bagaev13@yandex.ru