

Распределение пользователей в сетях пятого и последующих поколений

Т. З. Чан¹, Нгуен Дык Ту², А. Е. Кучерявый³

Санкт-Петербургский государственный университет телекоммуникаций
им. проф. М.А. Бонч-Бруевича

¹chan.tz@sut.ru, ²nguyentuhd99@gmail.com, ³akouch@sut.ru

Аннотация. Сверхплотные сети (UDN) и интегрированные сети «космос-воздух-земля» (SAGIN) являются ключевыми технологиями для улучшения покрытия, емкости и эффективности в сетях 5G и далее (B5G). Однако оптимальное распределение пользователей остается сложной задачей из-за серьезных помех и ограничений ресурсов. Для оценки производительности сети используются различные метрики, такие как вероятность отключения/покрытия, спектральная эффективность, энергоэффективность и качество обслуживания (QoS). Традиционные методы оптимизации сталкиваются с проблемой масштабируемости, что делает теоретико-игровые методы и глубокое обучение с подкреплением (DRL) перспективными подходами. В то время как теория игр моделирует взаимодействие между пользовательским оборудованием и базовыми станциями, DRL динамически оптимизирует распределение ресурсов и адаптируется к изменяющимся условиям сети. Интеграция этих подходов позволит сетям последующих поколений повысить производительность и обеспечить надежную связь.

Ключевые слова: Сверхплотная сеть, SAGIN, QoS, теория игр, DRL, 5G, распределение пользователей

Сверхплотная сеть (UDN) считается перспективной технологией для удовлетворения потребностей в быстрорастущем трафике данных и малой задержке в системах мобильной связи пятого поколения (5G) и последующих поколений (B5G) [1]. Развертывание малых ячеек высокой плотности, таких как пикосоты и фемтосоты, способствует разделению ячеек и увеличению плотности сети, тем самым повышая пропускную способность и снижая нагрузку на макросоты [2]. Однако столь плотное развертывание сети приводит к значительным помехам, поскольку пользовательское оборудование (User Equipment, UE) может принимать сигналы от множества различных базовых станций (Base Station, BS).

Кроме того, в сетях 6G рассматриваются многослойные архитектуры, одной из ключевых концепций которых являются интегрированные Космос-Воздух-Земля сети (Space Air Ground Integrated Network, SAGIN). SAGIN предоставляет возможности для глобального покрытия, повышения надежности и более эффективного использования сетевых ресурсов за счет взаимодействия различных уровней сети.

Несмотря на различия в архитектуре, и SAGIN, и UDN сталкиваются с общей проблемой – оптимальной распределения пользователей UE с BS. Поиск оптимального распределения пользователей в этих сетях является задачей комбинаторной оптимизации.

С увеличением масштаба сети сложность этой задачи возрастает экспоненциально, что делает её практически нерешаемой с использованием традиционных методов. [3]. Максимизация общей полезности, с учетом ограничений по ресурсам и/или мощности, приводит к взаимосвязанной зависимости между распределением пользователей и планированием ресурсов, что является NP-трудной задачей и становится вычислительно неразрешимой даже для сетей среднего размера.

Для распределения пользователей в сетях 5G и последующих поколениях были приняты различные метрики для определения того, какая конкретная BS должна обслуживать того или иного UE. В данном контексте, как правило, применяются четыре ключевые метрики: вероятность отключения/покрытия, эффективность использования спектра, энергоэффективность и качество обслуживания (Quality of Service, QoS). В научных исследованиях для оценки характеристик сети может рассматриваться как одна из этих метрик, так и их комбинация.

Вероятность отключения и покрытия являются важнейшими показателями при проектировании и анализе беспроводных сетей. Они зависят от влияния помех, возникающих в радиоканале. В частности, вероятность того, что отношение сигнал/помеха плюс шум опустится ниже заданного порогового значения, называется вероятностью отключения. Соответственно, вероятность того, что этот показатель превышает порог, определяется как вероятность покрытия. Эти метрики критически важны при сравнительном анализе средней пропускной способности произвольно выбранного пользователя в сети. Они также служат основой для оценки общей эффективности работы беспроводной системы и используются при её оптимизации.

Эффективное использование спектра характеризует, сколько информации может быть передано по каналу связи при фиксированной ширине частотного диапазона. В условиях роста объема передаваемых данных и дефицита частотных ресурсов повышение спектральной эффективности становится одной из приоритетных задач при построении 5G сетей.

Энергоэффективность: В ответ на растущие экологические проблемы концепция «зеленой связи» привлекла значительное внимание как в промышленности, так и в научных кругах. В научной литературе используются различные метрики для проведения количественного анализа потенциала энергосбережения, достигаемого с помощью конкретных алгоритмов. Существует два основных типа метрик энергоэффективности:

- Показатель энергоэффективности, выражаемый как отношение суммарной скорости передачи данных всех пользовательских устройств (UE) к общему потреблению энергии (бит/Джоуль). Он отражает, насколько рационально используется энергия при передаче информации.
- Оценка экономии энергии или мощности, обеспечиваемой применением конкретного алгоритма. В данном случае анализируется разница в уровне энергопотребления до и после внедрения алгоритма, а также может рассчитываться процентное снижение энергозатрат.

QoS: важный показатель производительности, который напрямую влияет на взаимодействие UE с сетью. Это главная проблема для сетевых операторов, которые должны обеспечить высокое качество услуг, сохраняя при этом прибыльность. QoS можно оценить с помощью таких факторов, как задержка передачи, пропускная способность пользователя и отношение сигнал/шум. Обеспечение QoS не только отвечает разнообразным потребностям мультимедийных развлекательных приложений, но и поддерживает разработку современных мобильных устройств с высокими требованиями к пропускной способности. В контексте сетей последующего поколения методы оптимизации сетевых ресурсов, гибкое управление спектром и использование искусственного интеллекта становятся все более важными для улучшения QoS и улучшения пользовательского опыта.

Популярный подход для решения этой задачи – использование функции полезности, где функция полезности отражает уровень удовлетворенности UE или системы конкретной стратегией подключения. В зависимости от критерия оптимизации, функция полезности может отражать эффективность спектра, эффективность использования энергии или QoS. В сочетании с проектированием на основе функции полезности, теория игр и глубокое обучение с подкреплением применяются (Deep Reinforcement Learning, DRL) для решения задачи распределения пользователей.

Теория игр: это инструмент математического моделирования, который имеет явные преимущества при исследовании взаимодействия нескольких игроков. Она моделирует процесс принятия решений сущностями в системе, помогая анализировать поведение UE и BS в форме игры, где каждая сторона стремится оптимизировать свои собственные выгоды. В модели некооперативной игры игроки пытаются максимизировать свою собственную полезность и соревнуются друг с другом, используя различные стратегии, такие как регулировка их мощности передачи. Комбинация стратегий, включающих лучшую стратегию для каждого игрока, известна как равновесие Нэша (Nash Equilibrium) [4]. В частности, решение игры достигает равновесия Нэша, если ни один из игроков не может увеличить свою полезность, изменив свою стратегию, не ухудшив при этом полезность других игроков. В отличие от этого, кооперативная теория игр моделирует переговорную игру, где игроки договариваются друг с другом с целью достижения взаимных преимуществ. Следует подчеркнуть, что теория игр предполагает, что

все игроки действуют рационально, стремясь максимально удовлетворить свои интересы. Однако в реальных ситуациях это не всегда так. Например, в игре с участием BS и UE могут возникнуть противоречия: одна из BS может ориентироваться на минимизацию своей задержки, в то время как другая — на максимизацию покрытия. Такое поведение может казаться иррациональным с точки зрения другой стороны, которая имеет разные цели.

DRL: Это метод глубокого обучения, улучшенный по сравнению с традиционным методом обучения с подкреплением (Reinforcement Learning, RL). В традиционном RL агенты, такие как UE или BS, взаимодействуют с окружающей средой для максимизации вознаграждения. Это вознаграждение может быть, например, QoS, балансировкой нагрузки или пропускной способностью. На основе обратной связи от окружающей среды агенты действуют согласно оптимальной политике. Однако с увеличением количества UE и BS, а также сложностью многослойных сетевых моделей [5], метод RL сталкивается с трудностями из-за расширяющегося пространства состояний.

DRL решает ограничения традиционного RL, используя глубокие нейронные сети для аппроксимации значений действий, вместо хранения таблицы Q-значений. Использование глубоких нейронных сетей позволяет DRL эффективно обрабатывать очень большие пространства состояний и задачи с множеством неопределенных факторов. Вместо хранения значений состояний для каждого действия, DRL может учиться на основе опыта и корректировать политику действий на протяжении нескольких этапов, не ограничиваясь размером таблицы Q-значений. Это особенно важно в беспроводных сетях с большим количеством UE и BS, где постоянно изменяются условия каналов и требования к ресурсам. DRL может научиться оптимизировать распределение ресурсов, регулировать мощность передачи, оптимизировать расположение BS и распределять UE так, чтобы обеспечивалось оптимальное QoS в любых условиях. Более того, DRL обладает способностью автоматически адаптироваться и учиться на основе постоянно меняющейся среды, что позволяет системе поддерживать оптимальную производительность в сложных и непредсказуемых сетевых ситуациях. С такой возможностью DRL стал мощным инструментом для решения задач оптимизации в новых поколениях беспроводных сетей, многослойных сетях или сетях с высокими требованиями по скорости передачи и низкой задержке.

Сверхплотные сети и многослойные архитектуры, такие как SAGIN, играют важную роль в сетях 5G и B5G, обеспечивая глобальное покрытие и эффективное использование ресурсов. Задачи оптимизации распределения пользователей и планирования ресурсов требуют применения таких метрик, как эффективность спектра, энергоэффективность и QoS. Теория игр помогает моделировать взаимодействие между UE и BS, но ограничена предположением о рациональности участников. DRL позволяет эффективно решать задачи оптимизации, обучаясь на основе опыта и адаптируясь к изменяющимся условиям сети, что делает его перспективным инструментом для сетей последующего поколения.

СПИСОК ЛИТЕРАТУРЫ

- [1] Кучерявый А. Е., Бородин А. С., Киричек Р. В. Сети связи 2030 // Электросвязь. 2018. № 11. С. 52–56.
- [2] Ye Q., Rong B., Chen Y., Al-Shalash M., Caramanis C., Andrews J. G. User association for load balancing in heterogeneous cellular networks // IEEE Transactions on Wireless Communications. 2013. Vol. 12, no. 6. P. 2706–2716.
- [3] Zhang Y., Xiong L., Yu J. Deep learning based user association in heterogeneous wireless networks // IEEE Access. 2020. Vol. 8. P. 197439–197447.
- [4] Wang L., Kuo G. S. G. Mathematical modeling for network selection in heterogeneous wireless networks: A tutorial // IEEE Communications Surveys & Tutorials. 2012. Vol. 15, no. 1. P. 271–292.
- [5] Кучерявый А.Е., Парамонов А.И., Маколкина М.А., Мутханна А.С.А., Выборнова А.И., Дунайцев Р.А., Марочкина А.В. Трехмерные многослойные гетерогенные сверхплотные сети // Информационные технологии и телекоммуникации. 2022. Т. 10, № 3. С. 1–12.