

УДК 654.078

ПРОГНОЗИРОВАНИЕ ПОКРЫТИЯ И ПРОПУСКНОЙ СПОСОБНОСТИ В СЕТЯХ СОТОВОЙ СВЯЗИ ПРИ РЕШЕНИИ ЗАДАЧ САМООПТИМИЗАЦИИ

Гридасова А.А., аспирант

Дэльф Н.Р., аспирант

*Белорусская государственная академия связи,
г. Минск, Республика Беларусь*

Научный руководитель: Карпук А.А. – к.т.н., доцент

Аннотация. Рассмотрены функции самооптимизации при решении задач самоорганизации сетей сотовой связи. Приведен обзор методов машинного обучения для прогнозирования покрытия и пропускной способности в сетях сотовой связи. Определены источники входных данных для алгоритмов машинного обучения. Выявлены открытые вопросы, которые требуется решить при внедрении в самоорганизующиеся сети сотовой связи интеллектуальных средств прогнозирования покрытия и пропускной способности.

Ключевые слова. саморганизуемые сети, самооптимизация, прогнозирование покрытия и пропускной способности, машинное обучение.

Введение. С ростом числа мобильных пользователей обеспечение высококачественного покрытия сети стало первостепенной задачей. Автоматическая оптимизация покрытия сети может быть затруднена из-за факторов окружающей среды и взаимозависимости регулируемых параметров. Из-за присущей неопределенности и непредсказуемой природы крупномасштабных беспроводных сетей традиционные методы, такие как эвристика и метаэвристика, не обладают необходимой адаптивностью и масштабируемостью для работы в их динамической среде. Самоорганизующиеся сети обещают операторам значительную экономию расходов при развертывании современной инфраструктуры сотовой сети, такой как системы Long-Term Evolution (LTE) и LTE-Advanced. Экономия капитальных затрат (CAPEX) и эксплуатационных расходов (OPEX) может быть достигнута как на этапе развертывания сети, так и на этапе эксплуатации сети. В частности, самоорганизующаяся оптимизация покрытия сети и пропускной способности сети является ключевой задачей для того, чтобы справиться с ростом трафика мобильных данных и извлечь выгоду из растущего рынка.

Самооптимизация в самоорганизующихся сетях. Самоорганизующуюся сеть Self-Organizing Network (SON) можно определить как адаптивную и автономную сеть, которая является масштабируемой, стабильной и достаточно гибкой для достижения желаемых целей. Понятие SON в мобильных сетях можно разделить на три основные категории: самоконфигурация (Self-Configuration), самооптимизация (Self-Optimisation) и самовосстановление (Self-Healing) [1].

Требования к SON в части самооптимизации сетей сотовой связи сформулированы в Релизе 9 технических спецификаций 3GPP [2]. Функции самооптимизации должны отслеживать входные данные, такие как показатели производительности, сигналы тревоги об ошибках, уведомления и т. д. После анализа входных данных должны приниматься решения по оптимизации в соответствии с алгоритмами оптимизации. В случае необходимости, на определенных сетевых узлах автоматически или вручную должны запускаться корректирующие действия. Если после выполнения корректирующих действий состояние сети остается неудовлетворительным, может потребоваться возврат конфигурации сети к предыдущему состоянию, которое было до выполнения корректирующих действий. Если после выполнения корректирующих действий состояние сети стало удовлетворительным, однократная процедура самооптимизации завершается.

В Релизе 9 были сформулированы следующие функции самооптимизации в SON стандарта LTE: оптимизация балансировки нагрузки между базовыми станциями (Load Balancing Optimization, LBO); оптимизация параметров хэндовера (Handover Optimization, HO); координация межсотовых помех (Inter Cell Interference Coordination, ICIC); оптимизация покрытия и пропускной способности (Coverage and Capacity Optimization, CCO). В Релизе 10 технических спецификаций 3GPP [3] была несколько расширена функция оптимизации покрытия и пропускной способности CCO. В Релизе 11 технических спецификаций 3GPP [4] была добавлена процедура координации функций SON (SON Coordination).

В предлагаемых сегодня на рынке программных продуктах для решения задач SON реализованы простейшие алгоритмы, основанные на сравнении некоторых параметров работы соты с заданными пороговыми значениями. Существующим сегодня методам решения задач SON не хватает адаптируемости и гибкости, необходимых для того, чтобы стать эффективными решениями для сетей стандартов LTE и 5G. Для того, чтобы использовать всю информацию, собираемую операторами, и получать на ее основе адаптируемые и гибкие решения, необходимо задействовать больше интеллектуальных ресурсов. Учитывая это, для решения задач SON в последние годы стали широко

применяться методы машинного обучения Machine Learning (ML). Рассмотрим возможности применения алгоритмов машинного обучения для реализации функций оптимизации покрытия и пропускной способности сетей сотовой связи.

Оптимизация покрытия и пропускной способности. Прогнозирование покрытия – это способность предсказывать, насколько хорошо сеть будет покрывать определенную географическую область и насколько хорошо она будет предоставлять надежные услуги в этой области. Непокрытые области (дыры) в покрытии сети сотовой связи могут появиться при неудачном планировании сети или при ошибочных настройках параметров сети. Их наличие может привести к прерыванию вызовов. Дыра в покрытии – это область, в которой уровень пилотного сигнала от базовой станции ниже порогового значения, необходимого мобильному устройству для доступа к сети, или SINR (Signal to Interference + Noise Ratio) – отношение мощности полезного сигнала к сумме мощностей шума и помех в обслуживаемой и соседних сотах ниже уровня, необходимого для поддержания базового обслуживания. Дыры в покрытии обычно вызваны физическими препятствиями, такими как новые здания, холмы, или неподходящими параметрами антенны, или просто ошибочным планированием сети. Типичными проявлениями дыры в покрытии являются частые сбои хэндовера, которые не удается устранить оптимизацией параметров хэндовера, или частые сбросы вызова, которые не может быть восстановлены повторным установлением радиосоединения. Функция ССО должна автоматически обнаруживать и устранять подобные проблемы в сети LTE.

Кроме дыр в покрытии, на пропускную способность соты могут влиять слабое покрытие, пилотное загрязнение, превышение покрытия и несоответствие нисходящего и восходящего покрытий [5]. Слабое покрытие имеет место, когда уровень пилотного сигнала или SINR для обслуживаемой соты ниже уровня, необходимого для поддержания запланированных требований к производительности (например, скорости передачи данных на границе соты). Пилотное загрязнение имеет место в областях, где покрытие разных сот сильно перекрывается, уровни мощности от обеих базовых станций eNB (eNodeB) достаточно высокие, а производительность сот может быть низкой. Обычно в этой ситуации абонентское оборудование UE (User Equipment) может иметь высокое отношение сигнал/шум для более чем одной соты, и высокие уровни помех. Превышение покрытия происходит, когда покрытие соты выходит далеко за пределы запланированного. Это может выглядеть как «остров» покрытия внутри другой соты, которая может не быть непосредственным соседом. Причинами могут быть отражения радиосигнала в зданиях или через открытую воду, озера и т. д. UE в этой области могут страдать от обрывов вызовов или сильных помех. Несоответствие нисходящего и восходящего покрытий имеет место, когда покрытие нисходящего канала больше, чем покрытие восходящего канала. В результате UE будет испытывать проблемы с передачей сообщений к eNB, когда попадет в зону несоответствия.

Обеспечение требуемой зоны покрытия является первоочередной задачей как во время развертывания сети, так и в процессе ее эксплуатации. Так же важной является возможность повысить пропускную способность сети во время ее эксплуатации. Функция ССО SON должна быть настроена на удовлетворение требований оператора к покрытию и пропускной способности, а также расстановке приоритетов между ними. В Релизе 10 [3] указаны следующие сценарии, которые должны учитываться при оптимизации покрытия и пропускной способности: наличие дыр покрытия LTE с покрытием сетей 2G/3G; наличие дыр покрытия LTE без какого-либо другого покрытия; наличие дыр покрытия LTE с изолированным покрытием островных сот; наличие сот стандарта LTE со слишком большим покрытием.

Целью оптимизации покрытия и пропускной способности является обеспечение оптимальности покрытия и пропускной способности для радиосети с учетом компромисса между ними. Для достижения цели оптимизации покрытия и пропускной способности можно оптимизировать мощность передатчика eNB по нисходящей линии связи, угол наклона антенны в вертикальной плоскости, угол направления антенны (азимут) в горизонтальной плоскости [5]. В известных алгоритмах ССО используются неконтролируемые алгоритмы ML, алгоритмы ML с байесовской оптимизацией, алгоритмы ML с подкреплением QL (Q-learning) и алгоритмы глубокого обучения DL (Deep Learning).

В работе [6] по оптимизации покрытия и пропускной способности для выделения кластера оптимизируемых сот и оптимизации параметров антенн eNB используется алгоритм SON. В работе [7] предложен метод одновременной максимизации покрытия и минимизации помех для желаемого уровня пересечения покрытия на основе контроллера с обратной связью. Эту оптимизацию можно выполнить для отдельной базовой станции eNB, кластера eNB или всей сети.

В работе [8] рассматривается прогнозирование затухания сигнала с помощью нейронных сетей на основе MLP (Multilayer Perceptron) которое можно использовать для планирования и оптимизации сетей в системах связи 5G. Модель на основе MLP может объединять данные измерений и характеристики окружающей среды. В работе [9] для прогнозирования покрытия сетей 5G в условиях плотной городской застройки используется алгоритм Extremely Randomized Trees Regressor (ERTR) основой которой стал алгоритм Random Forest. Рассмотрено несколько моделей потерь на пути, которые зависят от многих условий, таких как подходящий выбор местности для каждой модели, высота приемника и передатчика над землей и расстояние между ними, а также наличие препятствий.

В статье [10] разработан алгоритм, который настраивает мощность передатчика и угол наклона антенны eNB, чтобы оптимизировать компромисс между покрытием и пропускной способностью с помощью контроллера с обратной связью. В работе [11] для прогнозирования покрытия опробованы различные модели машинного обучения, включая обобщенные линейные модели (GLM), нейронные сети (NN) и k-nearest neighbors (K-NN) для планирования мощности радиосигнала в определенных районах на основе размещения передатчиков.

В исследовании [12] предлагается автокодировщик на основе сверточной нейронной сети CNN-AE (Convolutional Neural Network-based Auto Encoder) для прогнозирования пропускной способности сети в зависимости от местоположения базовой станции и вероятности покрытия в сотовых сетях. Исследование, представленное в [13], описывает возможность применения искусственных нейронных сетей для прогнозирования потерь при распространении электромагнитных волн, вероятности покрытия площади и отклонения уровня сигнала. Особенностью нейронных сетей является способность устанавливать функциональные связи в условиях неточности проводимых измерений.

В работе [14] предложен алгоритм ССО, в котором участок сети с несколькими eNB оптимизируется с точки зрения покрытия и пропускной способности с использованием одного контроллера. Мощности передатчиков и углы наклона антенн всех eNB в интересующей области совместно оптимизируются с использованием алгоритмов Q-обучения Deep Deterministic Policy Gradient (DDPG) и байесовской оптимизации. В работе [15] для оптимизации покрытия и пропускной способности используется алгоритм глубокого Q-обучения, в котором изменяются азимуты направления и углы наклона антенн.

Закключение. Алгоритмы машинного обучения могут анализировать большие объемы данных и выявлять сложные закономерности и зависимости, влияющие на зону покрытия и пропускную способность сети сотовой связи. Модель прогнозирования покрытия и пропускной способности помогает операторам сетей сотовой связи находить пробелы в покрытии, оценивать качество обслуживания, планировать расположение базовых станций, распределять радиочастотные ресурсы для совместного использования спектра и управления помехами. Из различных исследований следует, что результаты прогнозирования покрытия, полученные с помощью алгоритмов машинного обучения, дают более точные результаты прогнозирования по сравнению с результатами прогнозирования с использованием традиционных методов. Однако исследованы далеко не все возможности алгоритмов машинного обучения для прогнозирования зоны покрытия сотовых сетей связи. Поэтому до сих пор продолжаются исследования различных алгоритмов машинного обучения с различными примерами и вариациями параметров, чтобы получить алгоритмы с наилучшими результатами прогнозирования и метриками оценки эффективности.

Список использованных источников:

- 1 A Survey of Self Organisation in Future Cellular Networks / O.G. Aliu [et al.] // *IEEE Communications Surveys Tutorials*. – Vol. 15. – 2013. – Pp. 336-361.
- 2 3GPP TS 32.521 version 9.0.0 Release 9 [Электронный ресурс]. – 2010. – URL: https://www.etsi.org/deliver/etsi_ts/132500_132599/132521/09.00.00_60/ts_132521v090000p.pdf (дата обращения: 15.01.2025).
- 3 3GPP TS 32.521 version 10.2.0 Release 10 [Электронный ресурс]. – 2013. – URL: https://www.etsi.org/deliver/etsi_ts/132500_132599/132521/10.02.00_60/ts_132521v100200p.pdf (дата обращения: 15.01.2025).
- 4 3GPP TS 32.521 version 11.2.0 Release 11 [Электронный ресурс]. – 2013. – URL: https://www.etsi.org/deliver/etsi_ts/132500_132599/132521/11.01.00_60/ts_132521v110100p.pdf (дата обращения: 15.01.2025).
- 5 3GPP TS 32.522 version 11.7.0 Release 11 [Электронный ресурс]. – 2013. – URL: https://www.etsi.org/deliver/etsi_ts/132500_132599/132522/11.07.00_60/ts_132522v110700p.pdf (дата обращения: 15.01.2025).
- 6 Debono C.J., Buhagiar J.K. Cellular Network Coverage Optimization through the Application of Self-Organizing Neural Networks // 2005 IEEE 62nd Vehicular Technology Conference. – Vol. 4. – 2005. – Pp. 2158–2162.
- 7 Fagen D, Vicharelli P.A., Weitzen J. Automated Wireless Coverage Optimization with Controlled Overlap // *IEEE Transactions on Vehicular Technology*. – Vol. 57, no 4. – 2008. – Pp. 2395–2403.
- 8 Wu L., He D., Ai B., Wang J., Guan K., and Zhong Z., "Path loss prediction based on multi-layer perceptron artificial neural network," *Dianbo Kexue Xuebao/ Chinese J. Radio Sci.* – Vol. 36, no. 3. – 2021. – Pp. 396–404.
- 9 García C. E. and Koo I., "Extremely Randomized Trees Regressor Scheme for Mobile Network Coverage Prediction and REM Construction" in *IEEE Access* / – Vol. 11, no. July. – 2023. – Pp. 65170-65180.
- 10 Autonomous Self-Optimization of Coverage and Capacity in LTE Cellular Networks / Engels A. [et al.] // *IEEE Transactions on Vehicular Technology*. – Vol. 62, no 1. – 2013. – Pp. 1989–2004.
- 11 Mohammadjafari S., Roginsky S., Kavurmacioglu V., Cevik M., Ethier J., and Bener A.B., "Machine Learning-Based Radio Coverage Prediction in Urban Environments," *IEEE Trans. Netw. Serv. Manag.* – vol. 17, no. 4.–2020. – Pp. 2117–2130.
- 12 Mondal W. U., Mankar P.D., Das G., Aggarwal V., Ukkusuri S. V., "Deep Learning-Based Coverage and Rate Manifold Estimation in Cellular Networks," *IEEE Trans. Cogn. Commun. Netw.* – vol. 8, no. 4.– 2022. – Pp. 1706–1715.
- 13 Молчанов С. В., Захаров А. И., Применение искусственных нейронных сетей с целью прогнозирования характеристик распространения радиосигнала, *Вестник Балтийского федерального университета им. И. Канта*. 2014. Вып. 4. С. 100—105.
- 14 Machine Learning for Cognitive Network Management / Ayoubi S. [et al.] // *IEEE Communications Magazine*. – Vol. 56, no 1. – 2018. – Pp. 158–165.
- 15 An Efficient Stochastic Gradient Descent Algorithm to Maximize the Coverage of Cellular Networks / Liu Y. [et al.] // *IEEE Transactions on Wireless Communications*. – Vol. 18, no 7. – 2019. – Pp. 3424–3436. Thermal behavior of the YAG precursor prepared by sol-gel combustion process / F. Qiu [et al.] // *Ceramics International*, 2005. – Pp. 663-665.

UDC 654.078

PREDICTING COVERAGE AND CAPACITY IN CELLULAR NETWORKS WHEN SOLVING SELF-OPTIMIZATION PROBLEMS

Gridasova A.A., Postgraduate Student

Dalef N.R., Postgraduate Student

Belarusian State Academy of Communications, Minsk, Republic of Belarus

Karpuk A.A. – PhD of Technical Sciences, Associate Professor

Annotation. Self-optimization functions in solving the problems of self-organization of cellular networks are considered. The review of machine learning methods for coverage and capacity prediction in cellular networks is given. Sources of input data for machine learning algorithms are identified. Open issues that need to be solved when implementing intelligent coverage and capacity prediction tools in self-organizing cellular networks are identified.

Keywords. self-organizing networks, self-optimization, coverage and capacity prediction, machine learning.