

## **ОБНАРУЖЕНИЕ И КЛАССИФИКАЦИЯ НЕИСПРАВНОСТЕЙ СОТ СОТОВОЙ СВЯЗИ СТАНДАРТА LTE НА ОСНОВЕ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ БЕЗ УЧИТЕЛЯ**

*Дэльф Н.Р.А., аспирант,  
Альхамилли В.А.Н., соискатель*

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

*Карпук А.А. – профессор кафедры ПО сетей телекоммуникаций, канд. техн. наук*

Аннотация. Приведен обзор основных алгоритмов машинного обучения без учителя, используемых для решения задач обнаружения и классификации неисправностей сот в сетях сотовой связи стандарта LTE. Определены источники входных данных для алгоритмов машинного обучения без учителя. Выявлены нерешенные задачи и открытые вопросы, которые требуется решить при внедрении в самоорганизующиеся сети сотовой связи стандарта LTE интеллектуальных средств обнаружения и классификации неисправностей сот на основе алгоритмов машинного обучения без учителя.

Самоорганизующиеся сети Self-Organizing Network (SON) способны не только самостоятельно решать, когда и как будут запускаться определенные действия, основываясь на их постоянном взаимодействии с окружающей средой, но также способны обучаться и улучшать свою производительность на основе предыдущих действий, предпринятых системой. Понятие SON в мобильных сетях можно разделить на три основные категории. Этими категориями являются: самоконфигурация сети (Self-Configuration), самооптимизация сети (Self-Optimisation) и самовосстановление сети (Self-Healing).

В работе [1] предложена эталонная модель самовосстановления соты, в которой обнаружение неисправностей отвечает за выявление проблемных сот, которые необходимо исправить, включая соты с отключением обслуживания (обнаружение сбоя в работе соты) и соты с ухудшением обслуживания (обнаружение деградации соты). Возможный простой метод обнаружения неисправности соты состоит в установке пороговых значений для некоторых ключевых показателей эффективности (KPI). Однако постепенное ухудшение невозможно обнаружить просто по пороговому значению, особенно если проводится упреждающее обнаружение. Поэтому необходимо разработать алгоритмы, которые учитывают выбранные KPI и используют соответствующую логику принятия решений, чтобы определить, произошел сбой или ухудшение качества.

Значения требуемых KPI можно получить из информационной модели соты стандарта LTE. В статье [2] показано, что базовая станция (BS) стандарта LTE для каждой соты может сообщать значения тридцати трех KPI, включая количество пользователей, попытки подключения, скорость передачи пакетов данных/сигнализации, занятость ресурсов и качество радиоканала. Каждая BS для каждой своей соты генерирует значения этих тридцати трех KPI каждый час, данные каждой BS для каждой соты за сутки содержат 792 значения KPI. Таким образом, при использовании любого алгоритма машинного обучения для решения задач самовосстановления сети сотовой связи стандарта LTE требуется выбрать, значения каких KPI будут использоваться в алгоритме. Кроме того, как показано в работе [3], для решения задач самовосстановления некоторой соты могут использоваться ретроспективные и текущие значения выбранных KPI самой соты и соседних сот.

Для решения задач обнаружения и классификации неисправностей сот в сетях стандарта LTE могут использоваться следующие основные алгоритмы машинного обучения без учителя: алгоритм кластеризации  $k$ -средних ( $k$ -Means) [4]; нечеткий алгоритм кластеризации  $c$ -средних ( $c$ -Means) [5]; алгоритм самоорганизующейся нейронной сети Кохонена (SOM) [6]; алгоритм уровня локального выброса (LOF) [7]; алгоритм вероятности локального выброса (LoOP) [8].

Целью алгоритмов кластеризации является разбиение набора значений KPI на подмножества или кластеры, где точки значений KPI внутри одного кластера больше похожи друг на друга, чем на точки значений KPI в других кластерах. Алгоритм кластеризации  $k$ -средних стремится минимизировать среднеквадратичное отклонение на точках каждого кластера. На каждой итерации перевычисляется центр масс для каждого кластера, полученного на предыдущем шаге, затем значения KPI разбиваются на кластеры вновь в соответствии с тем, какой из новых центров оказался ближе по выбранной метрике. Алгоритм завершается, когда на какой-то итерации не происходит изменения кластеров. Нечеткий алгоритм кластеризации  $c$ -средних вместо однозначного ответа на вопрос, к какому кластеру относится набор значений KPI, определяет вероятность того, что заданный набор значений KPI принадлежит к тому или иному кластеру.

Алгоритмы кластеризации можно использовать для решения задачи обнаружения неисправных и деградирующих сот и решения задачи классификации деградирующих сот. При решении первой задачи множество значений выбранных KPI разбивается на три кластера: в первый кластер попадают наборы значений KPI для нормально работающей соты, во второй кластер – для деградирующей соты,

в третий кластер – для неисправной соты. При решении второй задачи множество значений KPI для деградирующей соты разбивается на некоторое количество кластеров, каждый из которых соответствует одной из причин деградации соты. В качестве причин деградации соты могут выступать изменение излучаемой мощности, изменение угла наклона антенны, перегрузка соты из-за недостаточности ресурсных блоков, появление помеховых или шумовых излучений в ближней или дальней зоне. В настоящее время открытыми являются вопросы выбора KPI для алгоритмов кластеризации, выбора метрики для оценки близости наборов значений KPI и выбора классов для решения задачи классификации деградирующих сот.

Самоорганизующаяся нейронная сеть Кохонена представляет собой множество нейронов, расположенных на плоскости. Каждый нейрон имеет координаты и вектор веса, размерность которого равна количеству KPI, выбранных для решения задачи обнаружения неисправных и деградирующих сот или решения задачи классификации деградирующих сот. Количество нейронов в сети определяется аналогично определению количества кластеров в алгоритмах кластеризации. Обучение сети SON состоит из трех этапов. На первом этапе производится инициализация начальных весов нейронов. Начальные значения KPI для каждого нейрона могут задаваться случайными значениями, выбираться из конкретных реальных значений KPI или определяться по специальному алгоритму, учитывающему весь набор входных данных. На втором этапе производится грубое обучение нейронов. Для каждого входного набора значений KPI вычисляется значение функции близости к вектору веса каждого нейрона и определяется нейрон наилучшего соответствия (best matching unit, BMU). Пересчитывается вектор веса нейрона BMU, определяются соседние нейроны из достаточно широкой окрестности и пересчитываются их векторы веса. Для сети с небольшим количеством нейронов, как в случае сети для обнаружения неисправных и деградирующих сот, состоящей из трех нейронов, этап грубого обучения нейронов можно опустить. На третьем этапе производится тонкое обучение нейронов. Процесс носит итерационный характер и останавливается, когда на очередной итерации все вектора веса нейронов остались без изменения. При этом на каждой итерации количество рассматриваемых соседних нейронов для нейрона BMU уменьшается. На обученной сети для каждого анализируемого набора значений KPI определяется нейрон BMU, который дает решение задачи обнаружения неисправных и деградирующих сот или задачи классификации деградирующих сот. В настоящее время недостаточно исследованы вопросы выбора KPI для построения векторов весов нейронов, выбора нейронов для решения задачи классификации деградирующих сот, выбора метода инициализации начальных весов нейронов, выбора функции близости набора значений KPI к вектору веса нейрона, выбора метода пересчета векторов веса нейронов, выбора параметров алгоритма тонкого обучения нейронов.

Алгоритмы LOF и LoOP могут использоваться при самообучении алгоритмов машинного обучения без учителя для нивелирования влияния локальных выбросов в наборах значений KPI, используемых для самообучения. Алгоритм LOF вычисляет плотности точек кластера до добавления в кластер анализируемого набора значений KPI и после добавления в кластер этого набора значений KPI, а затем оценивает отношение полученных плотностей. Если коэффициент превышения второй плотности над первой больше заданного порога, то анализируемый набор значений KPI считается локальным выбросом и не учитывается при формировании кластеров. Алгоритм LoOP является усовершенствованием алгоритма LOF и дает лучшие результаты. В этом алгоритме оценивается не отношение плотностей точек кластера, а вероятность того, что анализируемый набор значений KPI является локальным выбросом по отношению к заданному кластеру. При использовании алгоритмов LOF и LoOP открытыми остаются вопросы выбора метода вычисления плотности точек кластера, выбора метода вычисления вероятности получения локального выброса, выбора порогового значения отношения плотностей точек кластера и порогового значения вероятности получения локального выброса для отнесения анализируемого набора значений KPI к локальному выбросу.

**Список использованных источников:**

1. Barco, R. A Unified Framework for Self-healing in Wireless Networks / R. Barco, P. Lazaro, P. Munoz // *IEEE Communications Magazine*. – 2012. – Vol. 50, no 12. – P. 134–142.
2. Aoki, S. Few-Shot Learning and Self-Training for eNodeB Log Analysis for Service-Level Assurance in LTE Networks / S. Aoki, K. Shiimoto, C.L. Eng // *IEEE Transactions on Network and Service Management*. – 2020. – Vol. 17, issue 4. – P. 2077–2089.
3. Asghar, M. Z. Cell Degradation Detection based on an Inter-Cell Approach / M. Z. Asghar [et. al.] // *International Journal of Digital Content Technology and Its Applications*. – 2017. – Vol. 11, no 1. – P. 25–33.
4. Bascasov, A. Using Data Mining for Mobile Communication Clustering and Characterization / A. Bascasov, C. Cernazanu, M. Marcu // *Applied Computational Intelligence and Informatics (SACI)*, 2013 IEEE 8th International Symposium. – May 2013. – P. 41–46.
5. Velmurugan, T. Performance Based Analysis Between k-Means and Fuzzy c-Means Clustering Algorithms for Connection Oriented Telecom- Munication Data / T. Velmurugan // *Applied Soft Computing*. – 2014. – Vol. 19. – P. 134–146.
6. Hashmi, U. S. Enabling Proactive Self-healing by Data Mining Network Failure Logs / U. S. Hashmi, A. Darbandi, A. Imran // *2017 International Conference on Computing, Networking and Communications (ICNC)*. – Jan. 2017. – P. 511–517.
7. LOF: Identifying Density-based Local Outliers / M. Breuning [et al.] // *SIGMOD Record*. – Vol. 29, no 2. – 2000 – P. 93–104.
8. LoOP: Local Outlier Probabilities / H. P. Kriegel [et al.] // *18th ACM Conference on Information and Knowledge Management, ser. CIKM '09*. New York, NY, USA. – 2009 – P. 1649–1652.