

АДАПТИВНЫЙ ПРОТОКОЛ МАРШРУТИЗАЦИИ ДЛЯ МАЛОМОЩНЫХ MESH-СЕТЕЙ ИНТЕРНЕТА ВЕЩЕЙ

DOI: 10.36724/2072-8735-2026-20-5-22-28

Manuscript received 11 February 2026;

Accepted 15 April 2026

Татарникова Татьяна Михайловна,
Санкт-Петербургский государственный университет
аэрокосмического приборостроения, г. Санкт-Петербург, Россия,
tm-tatarn@yandex.ru

Янковский Никита Андреевич,
Санкт-Петербургский государственный университет
аэрокосмического приборостроения, г. Санкт-Петербург, Россия,
yannik98@yandex.ru

Ключевые слова: mesh-сети, интернет вещей,
протокол RPL, адаптивная маршрутизация, проактивное
управление

Снижение энергопотребления конечными устройствами Интернета вещей, а также увеличение надежности передачи данных являются важнейшими задачами для современных самоорганизующихся сетей. При этом традиционные подходы к маршрутизации в таких сетях, например RPL, имеют недостаточную адаптивность к резким изменениям качества сети и состоянию узлов, что в свою очередь приводит к избыточным повторным передачам пакетов и снижению энергоэффективности устройств. В работе предлагается протокол адаптивной маршрутизации на основе гибридной модели машинного обучения. Протокол предусматривает распределенное размещение обученных моделей случайного леса: на шлюзах сети располагается полновесная система, которая агрегирует данные, полученные с расположенных на промежуточных узлах сети легковесной модели случайного леса. Модель оценивает многомерный набор данных, включающий временные ряды параметров сигнала, энергетический статус и загрузку буферов, и преобразует результат прогноза в динамическую поправку к классической метрике ETX – ожидаемого числа переходов от источника к месту назначения в рамках целевой функции RPL. Результаты имитационного моделирования показывают, что предложенный протокол по сравнению со стандартным протоколом RPL и современными аналогами на основе машинного обучения повышает коэффициент доставки пакетов на 15% в условиях преднамеренных широкополосных помех, увеличивает время жизни сети до первого отказа узла на 20-25% при сохранении приемлемого уровня служебного трафика.

Информация об авторах:

Татарникова Татьяна Михайловна, доктор технических наук, профессор, Санкт-Петербургский государственный университет аэрокосмического приборостроения, кафедра инфокоммуникационных систем, г. Санкт-Петербург, Россия

Янковский Никита Андреевич, старший преподаватель, Санкт-Петербургский государственный университет аэрокосмического приборостроения, кафедра инфокоммуникационных систем, г. Санкт-Петербург, Россия

Для цитирования:

Татарникова Т.М., Янковский Н.А. Адаптивный протокол маршрутизации для маломощных mesh-сетей интернета вещей // Т-Comm: Телекоммуникации и транспорт. 2026. Том 20. №5. С. 22-28.

For citation:

T.M. Tatarnikova, N.A. Yankovsky, "Adaptive routing protocol for low-power mesh IoT networks", T-Comm, 2026, vol. 20, no.5, pp. 22-28. (in Russian)

Введение

Технологии интернета вещей (Internet of Things, IoT) изменили подходы к мониторингу и управлению в промышленности, городской инфраструктуре, сельском хозяйстве и здравоохранении. Технологической базой интернета вещей являются беспроводные сенсорные сети (БСС), часто реализуемые в виде самоорганизующихся топологий для обеспечения расширенного покрытия, отказоустойчивости и масштабируемости. Узлами таких сетей, как правило, являются автономные устройства с жесткими ограничениями по энергопотреблению, вычислительной мощности и объему памяти [1].

Доминирующим стандартом маршрутизации в самоорганизующихся БСС является протокол RPL (IPv6 Routing Protocol for Low-Power and Lossy Networks), утвержденный организацией по разработке интернет-стандартов – Internet Engineering Task Force (IETF). Согласно протоколу RPL строится направленный ациклический граф DODAG (Destination Oriented Directed Acyclic Graph) относительно корневого узла (рис. 1). Каждый родительский узел является шлюзом или роутером для дочернего узла. Таким образом, если узел не имеет записи в своей таблице маршрутизации для отправки пакета, то он просто пересылает его своему предпочтительному родителю и так далее, пока он не достигнет пункта назначения или общего родительского узла, который пересылает его вниз по дереву к месту назначения. Узлы в сети RPL имеют маршруты для всех узлов вниз по дереву. Это означает, что узлы, расположенные ближе к корневому узлу, имеют большие таблицы маршрутизации.




Рис. 1. Ациклический граф DODAG

Выбор предпочтительного родительского узла – следующей хопа определяется целевой функцией, минимизирующей метрику *ETX* (Expected Transmission Count) – ожидаемое число переходов от источника к месту назначения.

RPL использует три типа управляющих сообщений для создания и поддержки топологии RPL и таблицы маршрутизации:

- информационный объект DODAG (DIO), используемый RPL для формирования, поддержки и обнаружения DODAG;
- запрос информации DODAG (DIS);
- объект объявления пункта назначения DODAG (DAO).

Несмотря на широкое распространение, протокол RPL и большинство его модификаций характеризуются реактивностью: ухудшение канала или отказ узла обнаруживается только после серии неудачных попыток передачи, что приводит к каскадным эффектам, таким как влияние всплеска служебного трафика на перестроение графа, потерю критичных данных, увеличения задержки и, что наиболее важно, нераци-

ональный расход энергии на повторные передачи в деградировавшем канале. В условиях высокой динамики среды, вызванной подвижностью объектов, интерференцией или изменяющимися условиями распространения радиоволн, эти недостатки становятся критическими.

Возникает необходимость перехода от реактивных к проактивным (прогностическим) механизмам маршрутизации, способным на основе анализа текущего и исторического состояния сети предсказать вероятную деградацию маршрута и инициировать его плановую замену до момента потери связности. Машинное обучение (МО), и, в частности, методы обучения на временных рядах и контекстных данных, представляют собой мощный инструмент для построения таких прогностических моделей. Однако их прямое внедрение в маломощные IoT-устройства наталкивается на непреодолимые барьеры: вычислительная сложность методов МО, объем памяти для хранения модели МО и данных для обучения, энергетическая стоимость инференса.

Основной вклад данной работы заключается в разработке гибридной распределенной архитектуры применения машинного обучения в БСС с топологией mesh, разделяющей вычислительную нагрузку между пограничным шлюзом, где функционирует глобальная сложная модель, и роутерными узлами, выполняющими локальные легковесные модели на основе случайного леса (Random Forest, RF). Интеграция метода RF в протокол RPL обусловлена интерпретируемостью и устойчивостью метода к переобучению и возможностью эффективного сжатия модели RF путем квантизации и прунинга без катастрофической потери точности. В работе предложен полный жизненный цикл применения модели МО в БСС, охватывающий сбор признаков на узлах, локальное прогнозирование, агрегацию данных на шлюзе, глобальное обучение и распространение обновленных легковесных моделей обратно на узлы по схеме, напоминающей федеративное обучение.

Обзор существующих решений

Исследования по интеллектуализации маршрутизации в IoT можно классифицировать по нескольким направлениям:

- место размещения интеллекта: центр и/или периферия;
- используемая методология МО: обучение с учителем, обучение с подкреплением, ансамблевые модели;
- уровень интеграции с сетевым стеком.

К первому направлению относятся исследования, связанные с размещением моделей машинного обучения, что породило варианты архитектурных решений IoT: граничные и туманные (облачные) вычисления.

В работах [2-4] сбор телеметрии осуществляется в центральном контроллере или облаке, где запускаются ресурсоемкие модели, результатом работы которых являются рассчитанные оптимальные маршруты или политики маршрутизации, которые затем загружаются на узлы [5]. Такой подход используется и в полностью централизованных беспроводных системах, например для работы промышленных RFID систем [6] или сотовых сетей IoT [7]. Преимущество такого подхода – это возможность использования сложнейших моделей для глобальной оптимизации. Недостатки являются типичными для многих IoT-сценариев: высокая задержка реакции на локальные события, катастрофический рост служебного

трафика для сбора телеметрии, полная зависимость от работоспособности канала до центра и уязвимость с точки зрения конфиденциальности данных.

Второе направление исследований по интеллектуализации маршрутизации в IoT связано с применением распределенных подходов на основе обучения с подкреплением. Данное направление наиболее активно развивается [8-12]. Каждый узел рассматривается как агент, который взаимодействует со средой – сетью, выбирая действия – следующий хоп, и получает вознаграждение – комбинацию из успешной доставки и затрат энергии. Используются алгоритмы Q-Learning, в которых агент выбирает действия на основе данных из Q-таблицы, где строки обозначают возможные состояния среды, а столбцы – возможные действия агента в этих состояниях или их глубокие версии (Deep Q-Network, DQN), в которых сочетаются принципы Q-обучения с возможностями глубокого обучения. Главные достоинства от применения обучения с подкреплением – полная распределенность и адаптивность. Однако проблемы применительно к IoT заключаются в чрезвычайно медленной сходимости в больших состояниях, необходимости исследования среды, что ведет к периодическому выбору заведомо неоптимальных маршрутов и, как следствие, к потерям пакетов и энергии на этапе обучения. Кроме того, хранение и обновление Q-таблиц или нейросетевых весов потребляет значительную память и вычислительные ресурсы.

Третье направление исследований по интеллектуализации маршрутизации в IoT связано с применением распределенных подходов на основе предобученных легковесных моделей. В работах [13-15] подробно представлены результаты такого исследования: на узлы заранее загружаются простые модели такие как линейные регрессоры, неглубокие деревья решений, наивные байесовские классификаторы, обученные на синтетических или исторических данных. Узлы используют эти модели для оценки качества каналов на основе локальных измерений. Основное преимущество от применения предобученных легковесных моделей – минимальные накладные расходы во время работы. Ключевой недостаток – статичность модели, то есть она не адаптируется к изменениям в сети после развертывания, например, к появлению нового источника помех или изменению паттернов трафика, что со временем ведет к снижению эффективности.

Четвертое направление исследований по интеллектуализации маршрутизации в IoT связано с применением гибридных и иерархических подходов. В недавних исследованиях [16-18], авторы пытаются комбинировать преимущества централизованного и распределенного подходов. Например, на узлах работают легковесные модели, которые периодически отправляют сырые данные или градиенты на шлюз для уточнения глобальной модели. Эти идеи близки к предлагаемому в данной работе подходу, однако часто не учитывают специфику RPL как базового протокола и не предлагают законченных решений для эффективного распространения обновлений моделей в масштабе всей сети.

Предлагаемый в данной статье гибридный подход стремится найти оптимальный баланс между адаптивностью, эффективностью и практической реализуемостью. RF-MeshRPL не требует постоянной связи с центром для принятия решений, но при этом постоянно улучшает свои локальные модели за счет глобального опыта, собранного на шлюзе.

Архитектура и методология протокола RF-MeshRPL

Предполагается развертывание масштабируемой гетерогенной сети, состоящей из сотен узлов, которые можно разделить на три функциональных класса, отражающих их роль и ресурсы:

- Класс 1 (Сенсорные узлы, Leaf Nodes): ресурсо-крайне-ограниченные устройства. Их единственная функция – периодический сбор данных с датчиков и их передача своему непосредственному родителю (узлу Класса 2). Они не участвуют в маршрутизации чужого трафика и не поддерживают модель МО.

- Класс 2 (Роутерные узлы, Router Nodes): узлы с расширенными ресурсами. Они способны ретранслировать трафик, формировать и поддерживать таблицы маршрутизации, а также хранить и исполнять легковесную модель L-RF (Lightweight Random Forest). Эти узлы образуют маршрутизирующий остов сети. Они могут иметь улучшенные источники питания.

- Класс 3 (Пограничный шлюз, Edge Gateway): мощное устройство с постоянным сетевым питанием, значительными вычислительными ресурсами и постоянным подключением к backbone-сети или облаку. Выполняет роль корня DODAG в RPL, агрегирует все данные от сети, а также содержит и периодически переобучает глобальную модель G-RF (Global Random Forest).

Связь между узлами осуществляется по беспроводному каналу стандарта IEEE 802.15.4 (или аналогичного), работающему в диапазоне 2.4 ГГц.

Качество решений модели машинного обучения напрямую зависит от релевантности входных признаков. Каждый роутерный узел (Класс 2) для каждого своего соседа j хранит циклический буфер измерений за временное окно T_w . Каждые T_c секунд (период сбора) узел вычисляет вектор признаков $X_j(t)$.

Выделим четыре категории признаков:

Признаки качества канала:

- $RSSI_{Avg}$ – среднее значение мощности принимаемого сигнала (Received Signal Strength Indicator) за окно T_w ;

- LQI_{Avg} – среднее значение индикатора качества связи (Link Quality Indicator), отражающего соотношение сигнал/шум;

- ETX – текущее расчетное значение ожидаемого числа передач, обновляемое протоколом на основе подсчета успешных/неуспешных передач контрольных пакетов;

- σ_{RSSI} – стандартное отклонение мощности принимаемого сигнала за период времени T_w ;

- PRR – отношение успешно принятых пакетов к отправленным.

Признаки, связанные с энергоэффективностью:

- Класс энергетической стабильности узла (NEC) – дискретный показатель, вычисляемый на основе остаточной емкости батареи согласно следующей шкале:

- 0 (<10%);
- 1 (10-30%);
- 2 (30-60%);
- 3 (60-90%);
- 4 (от сети);

- тренд изменения энергии (убывает/стабилен/растет), вычисляемый как наклон линейной регрессии по последним N измерениям.

Признаки нагрузки узла:

- процент заполненности буфера исходящих пакетов (0-100%). Высокая загрузка указывает на потенциальное узкое место и рост задержек;

- количество дочерних узлов в поддереве. Прокси-метрика потенциальной нагрузки транзитного трафика.

Топологические и временные признаки:

- текущее расстояние от соседа до корневого шлюза;
- время, прошедшее с установления связи с данным соседом. Долгоживущие связи, как правило, более стабильны.

Таким образом, $X_j(t) \in R^d$, где d – общее количество признаков.

Глобальная модель случайного леса (Global Random Forest, G-RF) размещается на пограничном шлюзе. Это классический ансамбль из N_g решающих деревьев, обученный на агрегированном датасете со всей сети, при этом каждое дерево имеет глубину D_g . G-RF решает задачу многоклассовой классификации с четырьмя классами $C = \{0, 1, 2, 3\}$, соответствующими прогнозируемой пригодности канала к соседу j на интервале T_p ($T_p > T_c$):

- Класс 0: высокая вероятность потери связи или неприемлемого роста ETX в ближайшие T_p ;

- Класс 1: связь сохранится, но с повышенными потерями или задержкой. Не является предпочтительным маршрутом;

- Класс 2: надежный канал с хорошими показателями. Основной кандидат для маршрутизации;

- Класс 3: канал с отличным качеством, высокой энергией узла и низкой нагрузкой. Редкий класс, указывающий на оптимальный путь.

Легковесная модель случайного леса в свою очередь размещается на каждом роутерном узле Класса 2. Это существенно упрощенная и оптимизированная версия G-RF. Легковесная модель получается из глобальной модели путем прунинга и квантования весов, а также с помощью кодирования полученных деревьев.

Механизм адаптивной маршрутизации в RPL

Предлагаемый протокол маршрутизации использует стандартный RPL в качестве транспортной основы, но модифицирует его целевую функцию.

Протокол RPL поддерживает две целевые функции для нахождения оптимального пути:

- объективную функцию OF0, которая определяет минимальное число узлов между отправителем и корневым узлом;

- целевую функцию с гистерезисом MRHOF (Minimum Rank Objective Function with Hysteresis), минимизирующую метрику ETX , при этом используя механизм гистерезиса для снижения частоты смены путей в ответ на небольшие изменения метрики. Гистерезис работает так: при обнаружении нового пути с минимальной стоимостью переход на него происходит только в том случае, если он лучше текущего пути по крайней мере на заданный порог.

Введем композитную метрику $M_{ij}(t)$ для оценки соседа j :

$$M_{ij}(t) = \alpha ETX_{ij}(t) + \beta H_{ij} + \gamma P(C_{ij}(t)), \quad (1)$$

где $ETX_{ij}(t)$ – текущее значение ETX ;

H_{ij} – количество хопов от соседа j до корня (учитывается для минимизации длины пути);

$P(C_{ij}(t))$ – штрафная/премиальная функция, вычисляемая на основе предсказанного моделью класса $C_{ij}(t)$;

α, β, γ – весовые коэффициенты, настраиваемые эмпирически ($\alpha + \beta + \gamma = 1$).

Штрафная функция $P(\cdot)$ определяется следующим образом

$$P(C) = \begin{cases} +\infty, & \text{если } C=0, \\ +3, & \text{если } C=1, \\ 0, & \text{если } C=2, \\ -2, & \text{если } C=3. \end{cases} \quad (2)$$

Процесс выбора родителя на узле i происходит следующим образом:

1. При получении DIO от соседа j узел i извлекает из него актуальные признаки (NEC , число «прыжков» на пути до шлюза, заполненность буфера сообщений).

2. Узел i дополняет эти признаки своими локальными измерениями ($RSSI$, LQI , σ_{RSSI}) для формирования полного вектора X_j .

3. Запускается алгоритм инференса L-RF для X_j , получается $C_{ij}(t)$.

4. Рассчитывается метрика M_{ij} .

5. Из всех соседей выбирается тот, чья метрика M_{ij} минимальна. Он становится новым кандидатом в родители.

6. Собственный ранг узла i пересчитывается как

$$Rank_i = Rank_{Parent} + M_{i,Parent}. \quad (3)$$

Новый ранг анонсируется в исходящих DIO.

Таким образом, прогноз модели напрямую влияет на формирование топологии DODAG, опережая фактические изменения качества каналов.

Ключевым для долгосрочной эффективности системы является механизм обучения. Предлагается цикл, состоящий из следующих этапов:

1. Локальный сбор и разметка данных: каждый роутерный узел не только использует L-RF для предсказаний, но и ведет журнал. Для каждого предсказания $C_{ij}(t)$ он через время T_p записывает фактический исход $C_{ij}(t+T_p)$. Фактический класс определяется по наблюдаемым за период T_p значениям ETX и факту поддержания связи. Формируется локальный датасет $D_i = \{(X_j, C_{True})_k\}$.

2. Периодическая отправка логов на шлюз: раз в длительный интервал T_{upload} (например, 6-24 часа) или при накоплении достаточного объема данных, узел отправляет сжатый и агрегированный датасет D_i на шлюз, используя текущую mesh-топологию.

3. Агрегация и глобальное обучение на шлюзе: шлюз собирает датасеты D_i со всех роутерных узлов, формируя глобальный тренировочный набор D_{Global} . На этом наборе проводится дообучение глобальной модели G-RF.

4. Создание новой L-RF и верификация: обученная G-RF подвергается процедурам прунинга и квантизации, в результате чего создается новая версия легковесной модели.

Процедура прунинга подразумевает сжатие модели нейронной сети за счет удаления избыточных или менее важных параметров – нейронов, связей, весов без существенного влияния на точность инференса.

В реализации предлагаемого протокола применяется прунинг по градиенту (Gradient-based pruning) – оценивается важность каждого веса по его вкладу в изменение функции потерь на валидационных данных.

Процедура квантизации подразумевает преобразование весов и активаций из формата с высокой точностью в форматы с меньшей разрядностью, что позволяет уменьшить объём памяти для хранения модели, ускорить вычисления за счет использования целочисленных операций, что особенно важно при инференсе и соответственно, сократить потребление энергии за счет передачи меньшего объема данных через память и выполнение более простых арифметических операций. В реализации предлагаемого протокола применяется пост-тренировочная квантизация (Post-Training Quantization, PTQ) – модель обучается в формате 32-битных чисел с плавающей запятой, после чего веса преобразуются в целочисленные значения.

5. Распространение обновлений модели по сети.

Данный цикл обеспечивает постоянную адаптацию сети к изменяющимся условиям, превращая ее в самообучающуюся систему.

Результаты моделирования

Для проверки эффективности предложенного протокола RF-MeshRPL было произведено моделирование в среде имитационного моделирования NS-3, в котором задействованы все три класса устройств (сенсоры, роутеры, шлюз). Все узлы используют полный стек 6LoWPAN/RPL. Радиоканал моделируется с учётом затухания, многолучевости и теневого эффекта:

- потери распространения с коэффициентом затухания 3, что характерно для городской застройки;
- замирания сигнала с коэффициентом замирания $m = 1,5$ в зоне прямой видимости, $m = 0,75$ при наличии препятствий;
- фоновая помеха: добавлен шум – 105 dBm, а также периодические широкополосные источники помех, имитирующие работу соседних сетей Wi-Fi/ZigBee.
- подвижные препятствия: перемещающиеся объекты, которые временно затеняют связь моделируются через изменение затухания.

Энергопотребление каждого узла детально моделируется на основе реальных профилей:

Сенсор:

- Сон: 5 мкА
- Прослушивание канала (RX): 18 мА
- Передача (TX, 0 dBm): 25 мА
- Смена состояния: 0.5 мс / 10 мкДж

Роутер:

- Сон: 10 мкА (с сохранением RAM)
- Прослушивание: 20 мА
- Передача: 30 мА (0 dBm)
- Инференс L-RF: 5 мс / 15 мкДж

Моделирование производилось по трем сценариям:

• Сценарий 1 – Базовый: 100 узлов (20 роутеров, 80 сенсоров) равномерно распределены на площади в квадрате 300×300 м. Шлюз в центре. Нет внешних помех, только внутренняя интерференция.

• Сценарий 2 – Динамические помехи: добавлены два источника широкополосных помех, перемещающихся случайным образом и создающих интерференцию на частоте 2.4 ГГц. Периоды помех – по 15 минут через каждые 30 минут.

• Сценарий 3 – Отказоустойчивость: через 2 часа симуляции 20% роутерных узлов выходят из строя (имитация разряда

батареи или аппаратного сбоя). Оценивается время восстановления связности и падение вероятности доставки пакета PDR.

Для оценки преимуществ предложенного протокола RF-MeshRPL выбраны следующие протоколы:

RPL (ETX): стандартный вариант протокола RPL с целевой функцией MRHOF, ориентированной на минимизацию ожидаемого числа передач ETX. Каждый узел самостоятельно выбирает узел для отправки исходя из локально измеренной метрики ETX до каждого соседа. Маршруты строятся в виде направленного ациклического графа DODAG, при этом ранг узла рассчитывается как суммарное ETX по пути до шлюза.

RPL (RSSI): протокол RPL с метрикой на основе усреднённого RSSI. От стандартного варианта RPL (ETX) отличается тем, что выбор родительского узла для передачи осуществляется исходя из максимизации RSSI, а не минимизации числа передач до шлюза.

MA-RPL: подход, объединяющий две метрики ETX и RSSI. Каждый узел рассчитывает скользящее среднее для временных рядов этих двух метрик, а также для их стандартного отклонения. Итоговая метрика получается, как их средневзвешенное значение.

Q-RPL: адаптивный протокол на основе Q-Learning [9]. Реализует распределённое обучение с подкреплением: каждый узел хранит Q-значение для каждого соседа, отражающее ожидаемую полезность выбора этого соседа в качестве родителя. Вознаграждение комбинирует успешность доставки, затраты энергии и задержку. Родительский узел выбирается максимизацией значения Q, при этом оно обновляется при каждой отправке сообщения.

Главная метрика – процент успешно доставленных пакетов от сенсоров до шлюза.

Таблица 1

Средний PDR для разных сценариев, (%)

Протокол	Сценарий 1	Сценарий 2	Сценарий 3
RPL (ETX)	92.3	76.1	70.4
RPL (RSSI)	93.0	79.8	72.1
MA-RPL	94.1	84.2	78.5
Q-RPL	95.7	87.0	81.2
RF-MeshRPL	97.2	93.5	89.8

В базовом сценарии RF-MeshRPL незначительно опережает другие протоколы, но в условиях помех и отказов преимущество становится значительным – до 17 процентных пунктов выше, чем у RPL(ETX) в сценарии 3.

Чтобы оценить энергоэффективность предлагаемого метода маршрутизации для сценария 2 был произведен расчёт средней энергии, затрачиваемой на передачу одного пакета данных, а также время до первого отказа сети из-за разряда батареи. В табл. 2 приведены полученные результаты для всех рассматриваемых протоколов.

Таблица 2

Результаты моделирования

Протокол	Энергия на пакет, мДж	Время до отказа, час.
RPL (ETX)	6.45	148
RPL (RSSI)	5.87	154
MA-RPL	5.49	168
Q-RPL	5.21	176
RF-MeshRPL	4.51	189

Как видно из табл. 2, предлагаемый метод маршрутизации потребляет на 1.94 мДж (30%) меньше энергии на доставленный пакет по сравнению с базовым RPL, что также увеличивает время жизни сети с 148 до 189 часов.

Для сценария 2 также была рассчитана средняя сквозная задержка для пакетов сенсорных устройств: RPL (ETX): 312 мс, RF-MeshRPL: 198 мс. При этом джиттер задержки также уменьшился благодаря более стабильным маршрутам с 82 до 40 мс.

Заключение

Представленный в статье протокол маршрутизации, получивший название RF-MeshRPL, представляет собой значительный шаг вперед в адаптивности и интеллектуальности решений по маршрутизации самоорганизующихся сетей Интернета вещей. Сохраняя основные функции RPL и дополняя их подходом к выбору родительского узла на основе машинного обучения, мы обеспечиваем как сохранение надежности традиционных методов, так и преимущества адаптивного обучения. Предлагаемая иерархическая архитектура, разделенная на глобальную и облегченную модели, делает использование машинного обучения удобным для устройств с ограниченными ресурсами, а федеративный цикл обучения обеспечивает постоянную адаптацию сети к изменяющимся условиям.

Результаты моделирования показывают, что предлагаемый метод позволяет повысить вероятность доставки пакета PDR на 15-18% по сравнению с базовым протоколом RPL для различных сценариев. Также моделирование показало выигрыш в энергоэффективности до 30% по сравнению с протоколом RPL. Так на передачу одного с использованием протокола RF-MeshRPL в среднем тратится всего 4.51 мДж энергии вместо 6.45 при использовании протокола RPL(ETX). Наконец, использование предлагаемого протокола позволило снизить сквозную задержку передачи пакета от сенсорного узла с 312 мс до 198 мс.

Результаты, полученные в данном исследовании, подтверждают перспективность интеграции обучения с подкреплением в протоколы маршрутизации связи, что приводит к повышению производительности mesh-сетей. Дальнейшая работа будет сосредоточена на усовершенствовании RF-MeshRPL с учетом требований качества обслуживания QoS и изучении других моделей обучения с подкреплением для дальнейшего сравнения.

Литература

1. Татаринова Т.М., Богданов П.Ю., Краева Е.В. Предложения по обеспечению безопасности системы умного дома, основанные на оценке потребляемых ресурсов // Проблемы информационной безопасности. Компьютерные системы. 2020. № 4. С. 88-94.
2. Wang Y., Zhang Z., Zhang P., Ma Z., Liu G. A new cloud-based network framework for 5G massive Internet of Things connections //

2017 IEEE 17th International Conference on Communication Technology (ICCT), Chengdu, China, 2017, pp. 412-416.

3. Aldas S., Babakian A. Cloud-Native Service Mesh Readiness for 5G and Beyond // IEEE Access, vol. 11, pp. 132286-132295, 2023

4. Dab B., Fajjari I., Rohon M., Auboin C., Diquélou A. Cloud-native Service Function Chaining for 5G based on Network Service Mesh // ICC 2020 - 2020 IEEE International Conference on Communications (ICC), Dublin, Ireland, 2020, pp. 1-7.

5. Yankovskii N.A., Tatarnikova T.M. Impact of correlated arrival and service flows for radio resource management in centralized wireless networks // T-Comm: Телекоммуникации и транспорт. 2024. Т. 18. № 5. С. 42-48.

6. Цыганкова А.А., Янковский Н.А. Использование методов машинного обучения для предсказания числа меток в RFID системах // Актуальные проблемы и перспективы развития радиотехнических и инфокоммуникационных систем ("Радиоинфоком-2024") : Сборник научных статей по материалам VIII Международной научно-практической конференции, Москва, 18-22 ноября 2024 г. С. 239-243.

7. Янковский Н.А., Татаринова Т.М. Оценка эффективности алгоритмов ассоциации и планирования для передачи чувствительного к задержке трафика по нисходящему каналу беспроводных сетей // Успехи современной радиоэлектроники. 2024. Т. 78, № 8. С. 33-38.

8. Mahajan Smita, Srideviponmalar P., Ramachandran Harikrishnan, Kotecha Ketan. Reinforcement Learning Based Congestion Control Technique for Wireless Mesh Networks // International Journal of Networked and Distributed Computing. 2025.

9. Boushaba Mustapha, Senhaji Hafid Abdelhakim, Belbekkouche Abdelouab, Gendreau Michel. Reinforcement learning based routing in wireless mesh networks // Wireless Networks. 2013.

10. Hu Zhifeng, Han,Chong, Wang Xudong. Deep Reinforcement Learning Based Cross-Layer Design in Terahertz Mesh Backhaul Networks // IEEE/ACM Transactions on Networking. 2023.

11. Dueñas Santos Carlos, Mohamad-Mezher Ahmad, Astudillo Juan, Cárdenas-Barrera Julián, Guerra Eduardo, Meng Julian. Q-RPL: Q-Learning-Based Routing Protocol for Advanced Metering Infrastructure in Smart Grids // Sensors. 2024. 24. 4818. 10.3390/s24154818.

12. Ahmed A.J. et al. Congestion Aware Q-Learning (CAQL) in RPL Protocol – WSN based IoT Networks // 2022 5th International Conference on Engineering Technology and its Applications (ICETA), Al-Najaf, Iraq, 2022, pp. 429-435.

13. Takale D.D. Machine learning techniques for Routing in Wireless sensor network // International Journal of Research and Analytical Reviews. 2023.

14. Rui Kunkun, Pan Hongzhi, Shu Sheng. Secure routing in the Internet of Things (IoT) with intrusion detection capability based on software-defined networking (SDN) and Machine Learning techniques // Scientific Reports. 2023.

15. Murry L. Review on Machine Learning for Intelligent Routing, Key Requirement and Challenges Towards 6G // Computer Networks and Communications. Universal Wiser Publisher Pte. Ltd.

16. Salama A., Stergioulis A., Zaidi S.A.R., McLernon D. Decentralized Federated Learning on the Edge Over Wireless Mesh Networks // IEEE Access, vol. 11, pp. 124709-124724, 2023.

17. Wang Y., Wen Z., Li Y., Cao B. Learn to Collaborate in MEC: An Adaptive Decentralized Federated Learning Framework // IEEE Transactions on Mobile Computing, vol. 23, no. 12, pp. 14071-14084, Dec. 2024.

18. Sloop J. et al. Federated Learning for MCS Selection in 5G Side-link MANETs // MILCOM 2025 – 2025 IEEE Military Communications Conference (MILCOM), Los Angeles, CA, USA, 2025, pp. 612-617.

ADAPTIVE ROUTING PROTOCOL FOR LOW-POWER MESH IOT NETWORKS

Tatyana M. Tatarnikova, SUAI, St. Petersburg, Russia, tm-tatarn@yandex.ruNikita A. Yankovsky, SUAI, St. Petersburg, Russia, yannik98@yandex.ru**Abstract**

Reducing power consumption by IoT endpoints and increasing data reliability are critical for today's self-organizing networks. At the same time, traditional approaches to routing in such networks, for example RPL, have insufficient adaptability to sudden changes in network quality and node status, which in turn leads to excessive packet retransmissions and a decrease in the energy efficiency of devices. The paper proposes an adaptive routing protocol based on a hybrid machine learning model. The protocol provides for the distributed placement of trained random forest models: a full-fledged system is located on the network gateways, which aggregates data received from the lightweight random forest model located on intermediate network nodes. The model estimates a multivariate data set including time series of signal parameters, energy status and buffer loading, and converts the forecast result into a dynamic correction to the classical ETX metric – the expected number of transitions from source to destination within the RPL objective function. The simulation results show that the proposed protocol, in comparison with the standard RPL protocol and modern machine learning-based counterparts, increases the packet delivery rate by 15% in conditions of deliberate broadband interference, increases the network lifetime to the first node failure by 20-25% while maintaining an acceptable level of service traffic.

Keywords: mesh networks, IoT, RPL, adaptive routing, proactive management

References

- [1] T.M. Tatarnikova, P.Yu. Bogdanov, E.V. Kraeva, "Smart Home Security Suggestions Based on Resource Assessment," *Information Security Issues. Computer systems*. 2020. No. 4, pp. 88-94.
- [2] Y. Wang, Z. Zhang, P. Zhang, Z. Ma and G. Liu, "A new cloud-based network framework for 5G massive Internet of Things connections," *2017 IEEE 17th International Conference on Communication Technology (ICCT)*, Chengdu, China, 2017, pp. 412-416
- [3] S. Aldas and A. Babakian, "Cloud-Native Service Mesh Readiness for 5G and Beyond," in *IEEE Access*, vol. 11, pp. 132286-132295, 2023
- [4] B. Dab, I. Fajjari, M. Rohon, C. Auboin and A. Diquelou, "Cloud-native Service Function Chaining for 5G based on Network Service Mesh," *ICC 2020 – 2020 IEEE International Conference on Communications (ICC)*, Dublin, Ireland, 2020, pp. 1-7.
- [5] N.A., Yankovskii, T.M. Tatarnikova, "Impact of correlated arrival and service flows for radio resource management in centralized wireless networks," *T-Comm*. 2024. Vol. 18. No. 5, pp. 42-48.
- [6] A. Tsygankova, N.A. Yankovsky, "Using machine learning methods to predict the number of tags in RFID systems," *Actual problems and prospects for the development of radio engineering and infocommunication systems ("Radio Infocom-2024"): Collection of scientific articles based on materials from the VIII International Scientific and Practical Conference*, Moscow, November 18-22, 2024, pp. 239-243.
- [7] N.A. Yankovsky, T.M. Tatarnikova, "Evaluation of the efficiency of association and scheduling algorithms for the transmission of delay-sensitive traffic over the downlink of wireless networks," *Successes of modern radio electronics*. 2024. Vol. 78, no. 8, pp. 33-38.
- [8] Mahajan Smita, Sridevionmalar P., Ramachandran Hari Krishnan, Kotecha Ketan, "Reinforcement Learning Based Congestion Control Technique for Wireless Mesh Networks," *International Journal of Networked and Distributed Computing*. 2025.
- [9] Boushaba Mustapha, Senhaji Hafid Abdelhakim, Belbekkouche Abdelouab, Gendreau Michel, "Reinforcement learning based routing in wireless mesh networks," *Wireless Networks*. 2013.
- [10] Hu Zhifeng, Han Chong, Wang Xudong, "Deep Reinforcement Learning Based Cross-Layer Design in Terahertz Mesh Backhaul Networks," *IEEE/ACM Transactions on Networking*. 2023.
- [11] Duenas Santos Carlos, Mohamad-Mezher Ahmad, Astudillo Juan, Cardenas-Barrera Julian, Guerra Eduardo, Meng Julian, "Q-RPL: Q-Learning-Based Routing Protocol for Advanced Metering Infrastructure in Smart Grids. Sensors," 2024. 24. 4818. 10.3390/s24154818.
- [12] A. J. Ahmed et al., "Congestion Aware Q-Learning (CAQL) in RPL Protocol – WSN based IoT Networks," *2022 5th International Conference on Engineering Technology and its Applications (IICETA)*, Al-Najaf, Iraq, 2022, pp. 429-435.
- [13] D.D. Takale, "Machine learning techniques for Routing in Wireless sensor network," *International Journal of Research and Analytical Reviews*. 2023.
- [14] Rui Kunkun, Pan Hongzhi, Shu Sheng, "Secure routing in the Internet of Things (IoT) with intrusion detection capability based on software-defined networking (SDN) and Machine Learning techniques," *Scientific Reports*. 2023.
- [15] L. Murry, "Review on Machine Learning for Intelligent Routing, Key Requirement and Challenges Towards 6G," *Computer Networks and Communications*. Universal Wiser Publisher Pte. Ltd.
- [16] A. Salama, A. Stergioulis, S. A. R. Zaidi and D. McLernon, "Decentralized Federated Learning on the Edge Over Wireless Mesh Networks," in *IEEE Access*, vol. 11, pp. 124709-124724, 2023
- [17] Y. Wang, Z. Wen, Y. Li and B. Cao, "Learn to Collaborate in MEC: An Adaptive Decentralized Federated Learning Framework," in *IEEE Transactions on Mobile Computing*, vol. 23, no. 12, pp. 14071-14084, Dec. 2024
- [18] J. Sloop et al., "Federated Learning for MCS Selection in 5G Sidelink MANETs," *MILCOM 2025 – 2025 IEEE Military Communications Conference (MILCOM)*, Los Angeles, CA, USA, 2025, pp. 612-617.