УДК 004.021:004.7 DOI 10.18372/2073-4751.87.21685

Кулаков Ю.О., д.т.н.,
orcid.org/0000-0002-8981-5649,
e-mail: ya.kulakov@gmail.com,
Онищук М.О.,
orcid.org/0009-0004-5094-3901,
e-mail: mykolaon1@gmail.com

АНАЛІЗ МЕТОДІВ ДИНАМІЧНОЇ КЛАСТЕРИЗАЦІЇ В МОБІЛЬНИХ КОМП'ЮТЕРНИХ МЕРЕЖАХ

Національний технічний університет України "Київський політехнічний інститут імені Ігоря Сікорського"

Вступ

У зв'язку зі зростанням кількості, типів, а також щільності мобільних пристроїв, потреба у підвищенні ефективності функціонування мобільних комп'ютерних мереж є як ніколи актуальною. Найбільш очевидним фактором, що впливає на ефективність, є маршрутизація, проте і вона залежить від багатьох чинників. Таким вагомим чинником є розбиття мережі на кластери, що дозволяє уникнути перевантаження службовим трафіком та покращує масштабованість. Кластеризація має сприяти мінімізації кількості реконфігурацій, зовнішньокластерних маршрутизацій, та максимізації кількість внутрішньокластерних маршрутизацій. Особливо важливою є проблема кластеризації мобільних програмно-конфігурованих мереж, які виділяються своєю структурою. Кластеризація мобільних комп'ютерних мереж дозволяє організувати їх ефективну реконфігурацію. Відповідно, якість управління трафіком зводиться безпосередньо до оптимізації топології – ефективного розбиття вузлів на кластери та розподілу ролей всередині них.

Мета дослідження

Метою даної роботи є аналіз та групування методів формування кластерів в мобільних комп'ютерних мережах. Фокус дослідження падає на виявлення переваг та недоліків, обмежень кожного з методів кластеризації та їх типів за різних умов використання. Особлива увага надається дослідженню методів кластеризації мобільних програмно-конфігурованих мереж, а також типам їх впровадження.

Основна частина

Кожен метод кластеризації складається з двох етапів: власне формування кластерів та реконфігурація. Перший етап при цьому поділяється на вибір голів кластерів та розподіл вузлів по кластерах, що може відбуватись у будь-якому порядку в залежності від методу. Наразі існують різні методи кластеризації мобільних комп'ютерних мереж, що використовують різні підходи: від найпростіших детермінованих методів до метаевристик та застосування штучного інтелекту. Реконфігурація ж може бути реактивною, проактивною, прогнозуючою, адаптивною, періодичною та гібридною.

Існуючі методи кластеризації мобільних мереж можна поділити на наступні категорії (рис. 1).

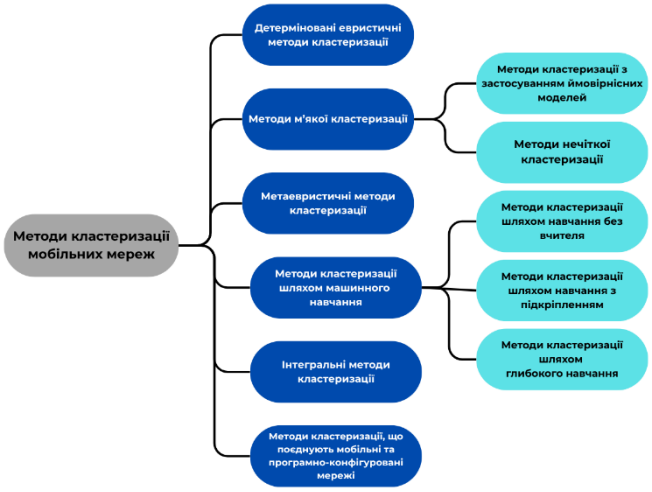


Рис. 1. Категорії методів кластеризації мобільних мереж

Детерміновані евристичні методи кластеризації

Найпростішими та базовими методами кластеризації, які використовувалися у мережах MANET з моменту їх появи, є детерміновані евристичні методи. Вони не містять жодних стохастичних елементів чи навчання, а отже, завжди продукують однаковий результат, отримавши ідентичні вхідні дані. Значними недоліками детермінованих евристичних методів кластеризації є схильність до локальних оптимумів, спрощення та неврахування складних взаємодій між вузлами, непристосованість до динаміки мережі, а також низький рівень масштабованості. Проте завдяки низькій обчислювальній складності їх доцільно використовувати для малопотужних пристроїв.

В роботі [1] пропонується евристичний алгоритм, який після розбиття мережі на кластери ітеративно шукає найкращого кандидата на роль голови у кожному з них за набором з п'яти метрик. Основним недоліком даного методу є відсутність вагових коефіцієнтів чи обмежень за використаними критеріями, та намагання знайти вузол, що буде найкращим за ними всіма.

Одним з суттєвих обмежень багатьох методів є використання жорсткої кластеризації, що значно ускладнює можливість здійснення плавного переходу вузла між кластерами, його прогнозування та планування, а також може спричиняти хаотичне перекидання вузла між двома кластерами у випадку, якщо він рухається біля межі між ними.

Методи м'якої кластеризації

Ця проблема вирішується за допомогою м'якої кластеризації, де вузол може одночасно належати до кількох кластерів, маючи різні ступені належності до кожного з них, сума яких зазвичай дорівнює одиниці. Окрім цього, м'яка кластеризація дозволяє мати резервні кластери, що підвищує стабільність мережі. Такий підхід містить чимало варіантів реалізації, популярними серед яких є *застосування ймовірнісної моделі* та *нечітка кластеризація*.

Методи кластеризації з застосуванням ймовірнісних моделей

До найпопулярніших ймовірнісних моделей можна віднести моделі суміші Стьюдента (SMM), байєсівські непараметричні моделі, приховані марковські моделі (HMM) та моделі суміші Гаусса (GMM). Застосування ймовірнісних моделей передбачає знаходження статистичних розподілів у структурі мережі. Таким чином розраховуються ймовірності того, що характеристики вузла відповідають

певному кластеру. Після закінчення формування кластерів такі ймовірності можуть бути використані надалі [2]. До переваг такого застосування м'якої кластеризації належать висока точність оцінювання міри невизначеності за різних умов, хороша сумісність з ШІ та забезпечення бази для багатошляхової маршрутизації. Проте основним недоліком є висока обчислювальна складність, що може бути критичним для децентралізованої мобільної мережі, де все обчислюється безпосередньо у вузлах. Також статистична модель потребує збору значної кількості даних для коректної роботи, що спричиняє перевантаження службовим трафіком, а через тривалий час обчислень результату топологія високодинамічної мережі ще до отримання результату.

Методи нечіткої кластеризації

Хоча *методи нечіткої кластеризації* також містять ресурсоємні обчислення, вони оптимальніші, ніж *ймовірнісні моделі,* для використання у мобільних мережах, до яких часто входять малопотужні вузли з досить обмеженою ємністю акумулятору. Всі методи нечіткої кластеризації базуються на теорії нечітких чисел. Те, що відношення вузлів до кластера описується через ступінь належності, а не ймовірність, дозволяє здійснювати багатошляхову маршрутизацію, причому вона та плавний перехід між кластерами реалізуються шляхом розподілу трафіку відповідно до ступеня належності вузла до кожного з кластерів, а не через ймовірнісне прогнозування стабільності маршруту.

У роботі [3] представлено метод кластеризації Density Peak Fuzzy C-Means (DP-FCM). Формування кластерів здійснюється з урахуванням відстані та щільності, а вибір їх голів – з урахуванням стабільності та захищеності від атак. Реконфігурація полягає у використанні граничного значенння для блокування вузлів з низьким рівнем довіри та є реактивною. Застосована активна ізоляція сприяє захищеності, хоча потребує вдосконалення. До недоліків представленого методу відносяться обчислення нечіткої логіки без застосування під час кластеризації, перевантаження службовим трафіком та відсутність механізму запобігання повному виснаженню голови кластера. У роботі [4] було модифіковано цей метод кластеризації шляхом видалення етапу Density Peak для спрощення процедури кластеризації згідно з особливостями нового способу маршрутизації. Однак відсутність механізму попередньої оцінки центрів кластерів негативно впливає на перевантаження та енергоефективність вузлів. Цю проблему було вирішено у роботі методі Improved Fuzzy C-Means (IFCM) [5], де подібно до методу [3] здійснюється обрахунок індексу щільності відстані на етапі ініціалізації. Під час кластеризації враховуються відстань, залишкова енергія та час життя вузла. Однак, метод не передбачає механізму реконфігурації, та як і попередні методи, не враховує вектор руху вузлів та примусово включає кожен з вузлів до якогось з кластерів, розтягуючи їх межі поза основну зону концентрації, а також йому притаманна затримка при встановленні домовленості перед передачею пакетів.

Метаевристичні методи кластеризації

Метаевристичні методи кластеризації [6] базуються на метаевристичних алгоритмах. Вони не гарантують найкращий можливий результат, проте часто знаходять якісне рішення, витрачаючи менше обчислювальних потужностей, ніж конкуренти. Метаевристичні методи кластеризації варто застосовувати, коли важливо забезпечити гарну якість обслуговування (QoS) чи балансування навантаження. Однак, їх обмеженням для високодинамічних мереж є повільна збіжність, через яку знайдене рішення може втратити актуальність, а їх вибір для

великих мереж є недоцільним через складність повноцінної реконфігурації та суттєві затримки.

Робота [7] пропонує метод Seagull-assisted May Fly Optimization Algorithm (SG-MFOA), що працює з популяціями рішень та є міжрівневим, враховуючи під час вибору голови кластера залишкову енергія, фактор балансування навантаження та очікуваний час передачі. Реконфігурація є реактивною, проте покладається на багатошляхову маршрутизацію та балансування навантаження, а не реорганізацію кластерів. Метод SG-MFOA впроваджує пріоритетність трафіку, що позитивнно впливає на QoS, а також враховує фактор балансування навантаження, що запобігає утворенню вузького місця у голові кластера. Проте реконфігурація є обмеженою, а міжрівневість загострює проблему перевантаження службовим трафіком. Іншим підходом є алгоритм кластеризації Imperialist Competitive Algorithm (ICA) [8], що використовує підходи генетичних алгоритмів для пошуку найкращого ріщення. При виборі голови кластера враховуються залишкова енергія, радіус дії, ступінь вузла та швидкість. Частина обчислень здійснюються базовою станцією. Реконфігурація кластерів є реактивною та спрацьовує при перевищенні встановленого порогу кількості несанкціонованих змін. Це сприяє уникненню зайвих перебудов кластерів, а наявність перекриття та достатньої кількості шлюзів забезпечує альтернативні шляхи. Недоліком, окрім характерних для метаевристичних методів, є чутливість до правильного налаштування коефіцієнтів, що зумовлює необхідність їх адаптації у разі застосуванні у високодинамічних мережах.

Методи кластеризації шляхом машинного навчання

Оскільки у сучасному світі мережі часто є високодинамічними, з'являється все більша кількість умов та непередбачуваних ситуацій, які мають бути врахованими для ефективності методу, все більш поширеним наразі є використання штучного інтелекту, а саме, машинного навчання, для кластеризації мережі, що робить її більш гнучкою та адаптивною.

Методи кластеризації шляхом навчання без вчителя

Одним із популярних підходів є навчання без вчителя. При його застосуванні немає потреби в наданні розмічених даних з бажаними результатами для попереднього навчання моделі. Таким чином, модель має здатність виявляти приховані структури, шаблони та закономірності [9]. Суттєвою перевагою цього підходу для кластеризації мобільних мереж є саме відсутність попередньої фази навчання, що знижує обчислювальне навантаження та нівелює потребу в датасетах. Проте досить висока обчислювальна складність та потреба у налаштуванні гіперпараметрів є суттєвими недоліками для високодинамічних мереж, зокрема транспортних.

У роботі [10] розглядається метод Dynamic Networking Method of Vehicles in VANET (DNOV), що здійснює кластеризацію мережі авто з урахуванням придорожньої інфраструктури (RSU). Для формування кластерів використовується метод навчання без вчителя DBSCAN, причому вузли на перетині кластерів стають шлюзами. Для вибору голови кластера застосовується модель оцінювання транспортних засобів (VSM), що враховує напрямок, різниці швидкостей, прискорень та відносна відстань до RSU. Метод є динамічним. Реконфігурація є реактивною з проактивним моніторингом, та ініціюється при різкому зниженні рейтингу голови, її виходу з кластера або втраті оптимальної позиції. Представлений метод забезпечує значне вивільнення радіоефіру та базу для енергоефективного керування електромобілями. До недоліків методу,

окрім загальних, належать ігнорування зустрічного потоку та значних груп авто з малою щільністю, необхідність ручного керування та зростання обсягу повідомлень у заторах, а також кількості реконфігурації у заторах та при високій динамічності. Метод [11] використовує модифіковану версію DBSCAN, де враховується широта, довгота, швидкість та траєкторія руху. Головою кластера стає вузол з найбільшим ступенем в межах визначеного радіусу, а для комунікації двох кластерів використовуються шлюзи. Спільними з роботою [10] перевагами є стійкість до включення поодиноких вузлів та ефективна робота DBSCAN з географічними даними. Окрім того, метод забезпечує стабільність та якість зв'язку завдяки обмеженню радіуса кластера. Проте суттєвими недоліками є відсутність механізму реконфігурації, квадратична складність та високі накладні витрати при великій кількості вузлів. Метод [12] на базі K-means визначає кількість кластерів шляхом розбиття на зони і відсіювання тих, де щільність менша 10%, задля балансування навантаження та енергоспоживання. Під час вибору голови кластера враховуються залишкова енергія, відстань до центроїда та швидкість вузла. Реконфігурації кластерів є гібридною, що поєднує реактивну і проактивну, та ініціюється у разі зменшення залишкової енергії голови кластера понад встановлений поріг та залишку у кластері лише одного вузла. Цей метод вирішує проблему статичності K-means та вирізняється низькими затримками. Проте методу також характерні відсутність вагових коефіцієнтів, необхідність глобального бачення для початкового зонування та розбиття, а також уніфікації пристроїв, та збільшення службового трафіку під час реконфігурацій.

Методи кластеризації шляхом навчання з підкріпленням та глибокого навчання

Сильною стороною навчання з підкріпленням є висока ефективність у динамічних та складних середовищах, проте воно потребує значних ресурсів на тренування, а складність обчислень та вимог до пам'яті значно зростає зі збільшенням кількості вимірів. Окрім цього, такий тип навчання чутливий до правильного налаштування винагороди, інакше є можливість виникнення субоптимальних рішень [9].

Глибоке навчання використовує багатошарову нейронну мережу [13], що здатна прогнозувати поведінку вузлів, знаходити приховані залежності, моментально перетворювати вхідні дані на рішення. Проте воно потребують ґрунтовного навчання, попередньо підготовлених датасетів, а також належних обчислювальних потужностей.

У роботі [14] запропоновано метод кластеризації для літальних спеціальних мобільних мереж (FANET), що керується RL-агентом на базі наземної станції, глобальне бачення якого вирішує проблему мультиагентної координації та знижує обчислювальне навантаження на дрони. У методі Hybrid Multi-Criteria Decision Making (HMCDM) вибір голови кластера здійснюється за енергією, центральністю, подібністю векторів швидкості, часом утримання зв'язку, заповненістю буфера та просторовою різноманітністю, а ваги параметрів підбираються RL-агентом. У якості RL-агента використовуються та порівнюються Q-learning, Deep Q-Network (DQN) та Deep Deterministic Policy Gradient (DDPG). Реконфігурація є гібридною, що поєднує реактивну та періодичну, ініціюється періодично RL-агентами та полягає у перерахунку ваг та зміні структури кластера. До переваг також відносяться зниження завантаженості повідомленнями, підтримка багаторівневої маршрутизації, а при використанні Q-learning та DDPG забезпечується високий рівень енергоефективності та стабільності кластерів та зниження затримок через адаптацію агента до функції винагороди.

Проте ця адаптація також спричиняє низький PDR, а Q-learning та DQN викликає зростання обчислювальної складності. Іншим прикладом застосування є робота [15], де представлено метод кластеризації Cross-layer Federated Learning-based Clustering (CFLC), що використовує глибоке навчання у комбінації з *федеративним навчанням* [13], де замість чутливих тренувальних даних передаючи лише оновлені ваги моделей задля безпеки та приватності. Локальні моделі класифікують вузли на звичайні та голови кластерів за показниками швидкості, енергії, рангами, оптимальними та середніми значеннями. При формуванні кластерів вузлом оцінюється схожість мобільності, якість зв'язку, залишкова енергія та пропускна здатність. Проактивна реконфігурація полягає у безперервності процесу навчання та кластеризації. Метод CFCL забепечує приватність, розвантаження слабких вузлів, зменшене число реконфігурацій та обсяг службового трафіку відповідно. Проте виникає необхідність попереднього навчання та високе навантаження на точки доступу. Також ефективність знижується при хаотичному русі вузлів, а представлений метод є залежним від GPS та припускає ідеальну роботу канального рівня.

Інтегральні методи кластеризації

Оскільки кожен з типів методів кластеризації має власні недоліки та обмеження, та жоден з них не є ідеальним, доцільною є комбінація кількох з них для використання найсильніших сторін обох. Це обумовлює появу інтегральних методів кластеризації.

Метод [16] поєднує глибоку нейронну мережу CBPNN для кластеризації та метаевристику, а саме алгоритм оптимізації рою частинок (PSO), для оптимізації вагових коефіцієнтів та значень зміщення. Під час вибору голів кластерів враховуються мобільність вузла, контент, що він передає, температура та вологість. Реконфігурація є адаптивною, спрацьовує при перевищенні порогу змін топології чи мобільності вузлів. Переваги представленого методу включають уникнення локальних мінімумів завдяки PSO, а також зниження рівня втрат пакетів на більш ніж 70%, затримок та підвищення пропускної здатності завдяки CBPNN. Проте методу притаманна висока обчислювальна складність, що також знижує енергоефективність, повільна збіжність PSO та перевантаженість службовим трафіком під час передачі даних для навчання нейромережі. Метод Hybrid Adaptive Clustering Algorithm for Dynamics MANETs (HACADM) [17] поєднує алгоритм зваженої кластеризації (WCA), метаевристичний гравітаційний алгоритм пошуку (GSA), а також покращений метод Enhanced-DBSCAN. Під час вибору голів кластерів WCA враховує відхилення ступеню від ідеального, суму відстаней до сусідів, середню швидкість переміщення та залишкову енергію, а GSA динамічно оптимізує їхні ваги. Enhanced-DBSCAN розподіляє вузли по кластерах при чому вузли на перетині стають шлюзами, а поодинокі вузли залишаються за межами кластерів. Завдяки адаптивному радіусу покриття зникає проблема ручного налаштування. Метод до останнього відкладає реконфігурацію, ініціюючи її, коли звичайний вузол отримує оптимальнішу вагу, ніж голова його кластера, або втрачає зв'язок з головою свого кластера, що зменшує обсяг службового трафіку та витрати енергії. Окрім того, блокування розширення кластерів дозволяє підвищити стабільність, а у щільних мережах досягається висока стабільність, PDR та пропускна здатність. Натомість, недоліки включають порівняно великі затримки у мережах з низькою щільністю та обчислювальна складність, що зростає до $O(n^2)$ з підвищенням щільності. У роботі [2] представлено метод, що поєднує м'яку кластеризацію на базі Гаусової суміші

(GMM) та рекурентну нейронну мережу (RNN). Пошук голів та розподіл інших вузлів виконуються GMM, враховуючи відстань та споживання енергії. Гібридна реконфігурація поєднує предиктивну та адаптивну. Завдяки зворотному поширенню помилки в часі нейромережа помічає тенденції руху вузлів. Іншими перевагами даної роботи є зниження енергоспоживання вузлів на 50%, а також передачі даних та затримок. Проте при різких змінах у мережі метод потребує певного часу для реакції, є схильним до локальних оптимумів, а матричні обчислення спричиняють низьку масштабованість через зростання обсягу трафіку та витрат енергії зі збільшенням кількості вузлів. Метод Hybrid Dual Optimized Machine Learning Model (HDOMLM) [18] використовує PSO для розбиття мережі на кластери за швидкістю та позицією вузлів, та оптимізовану модель машинного навчання (O-MLM) для вибору голів кластерів з урахуванням дельта-різниці ступенів, середньої відстані до сусідів, відносних енергії, мобільності та максимальної затримки передачі та їх реконфігурації. Реконфігурація є гібридною та поєднує адаптивну, періодичну та прогнозуючу, полягаючи у визначенні оптимальних голів. Переваги включають ефективне балансування навантаження мінімальну витрату часу на вибір голів, підвищення пропускної здатності на 41% та збільшення часу життя мережі на 40-58%. Проте відсутність механізму зміни топології при русі вузлів, потреба у датасетах для навчання, зростання службового трафіку через регулярний обмін п'ятьма метриками та штучність метрики мобільності є суттєвими недоліками. Метод [19] поєднує навчання без учителя K-means для поділу на кластери за відстанню до їх центроїдів та метаевристичний метод вихрового пошуку (VSA) для пошуку їх голів за енергоспоживанням та відстанню до базової станції. Окрім цього, він прагне мінімізувати реконфігурації, тому повноцінної реконфігурації тут не передбачено, лише повторний запуск кластеризації, що ініціюється з певною періодичністю в залежності від споживання енергії. Отже, реконфігурація є гібридною, що поєднує періодичну та адаптивну. До інших переваг належать уникнення локальних оптимумів, точність та високий рівень енергоефективності завдяки аналізу батареї та відстані від базової станції. Серед недоліків вирізняються перевантаження службовим трафіком, відсутність механізму заміни голови кластера та використання фіксованої кількості кластерів без механізму визначення їх числа.

Методи кластеризації, що поєднують мобільні та програмно-конфігуровані мережі

У зв'язку з викликами, перед якими постають мережі MANET, інтеграція їх з програмно-конфігурованими мережами дозволяє досягти ефективнішого керування трафіком. Адже централізація та відокремлення рівня управління дозволяють гнучко керувати мережею, масштабувати її за необхідності, забезпечити ефективне виділення ресурсів та безпеку завдяки глобальному баченню мережі [20]. Іншими перевагами є мінімізація затримки під час внутрішньокластерного прийняття рішень у разі наявності локальних контролерів, розвантаження звичайних та шлюзових вузлів, програмованість, а також покращення QoS. Проте голова кластера, приймаючи на себе більшість навантаження, може швидко розрядитися, перехід вузла до іншого кластера може викликати затримки, а залежність від центрального контролера спричиняє проблему єдиної точки відмови.

Метод [21] для мобільних SDN-мереж запускає на головах географічних кластерів тут SDN-агенти, що грають роль локальних SDN-контролерів, якими керує центральний контролер. Головою кластера може стати лише вузол, що підтримує і Wi-Fi, і LTE, якщо ж такого не існує –

керівництво переходить до голови сусіднього кластера. Вибір відбувається за найкращим балансом максимальної залишкової енергії та мінімальної швидкості. Для синхронізації даних застосовується надсилання повного дампу при утворенні кластера та інкрементальний метод при оновленнях, що зменшує перевантаження та підвищує енергоефективність. Гібридна реконфігурація кластерів, що поєднує реактивну та адаптивну, може бути спричинена падінням заряду акумулятора чи зміною місця розташування голови кластера. Глобальна видимість дозволяє розвантажити шлюзові та звичайні вузли при пошуку маршруту, підвищити ефективність реконфігурації кластерів, а локальні контролери – мінімізувати затримки при внутрішньокластерному управлінні. Проте ціною за це є високе навантаження на голову кластера та апаратні обмеження. Метод [22] використовує ідентичне формування кластерів, але пропонує й інші два підходи до комунікації локального контролера з центральним, які застосовуються для багатоадресної маршрутизації, в залежності від обраного методу маршрутизації. У разі використання реактивної стратегії (RMCMS) повідомлення центральному контролеру надсилаються локальними контролерами лише за його запитом. Це допомагає економити енергію та зменшити службовий трафік, проте провокує появу затримок. За проактивною стратегією (PMCMS) для мінімізації затримок кожна голова кластера передає інформацію про кластер з встановленою періодичністю, проте з'являються підвищені споживання енергії та обсяг службового трафіку. Для об'єднання переваг обох методів було створено іншу модифіковану стратегію (M-PMCMS), механізм якої є ідентичним до описаного у роботі [21].

В результаті проведеного аналізу було визначено наступні переваги та недоліки виділених типів методів кластеризації (табл. 1).

Таблиця 1. Переваги та недоліки типів кластеризації

Тип методу	**Підтип методу**	**Переваги**	**Недоліки**
Детерміновані евристичні методи кластеризації [1]	–	Простота впровадження; мінімальне використання енергії та обчислювальних ресурсів.	Схильність до локальних мінімумів; погана масштабованість; слабка адаптивність; ефект "пінг-понгу"; спрощення та неврахування складних взаємодій між вузлами.
Методи м'якої кластеризації	Методи кластеризації з застосуванням ймовірнісних моделей [2]	Високий ступінь точності визначення ймовірності входження за різних умов; гарна сумісність з ШІ; запобігання ефекту "пінг-понгу"; можливість багатошляхової маршрутизації; висока стабільність.	Завелике використання обчислювальних ресурсів; перевантаження службовим трафіком; повільна збіжність.
	Методи нечіткої	Можливість плавного переходу; запобігання ефекту "пінг-понгу"; можливість	Необхідність попереднього знаходження центрів кластерів; затримки при домовленості перед

Тип методу	**Підтип методу**	**Переваги**	**Недоліки**
	кластеризації [5]	багатошляхової маршрутизації; менша обчислювальна складність у порівнянні з ймовірнісними моделями.	передачею пакетів у разі використання Fuzzy C-Means; обчислювальна складність.
Метаевристичні методи [8]	–	Ефективне балансування навантаження; уникнення локальних оптимумів; знаходження рішень, близьких до оптимальних, з порівняно невеликим використанням ресурсів; висока QoS.	Повільна збіжність; висока чутливість до налаштувань параметрів; перевантаження службовим трафіком; складність повноцінної реконфігурації; збільшення затримки у великих мережах.
Методи машинного навчання	Методи кластеризації шляхом навчання без вчителя [10]	Відсутність необхідності датасетів та попереднього навчання; точність кластеризації; стабільність результату.	Неможливість прогнозування динаміки мережі; висока обчислювальна складність; перевантаження службовим трафіком; налаштування гіперпараметрів.
	Методи кластеризації шляхом навчання з підкріпленням та глибокого навчання [14]	Проактивність завдяки можливості прогнозування; можливість виявлення прихованих закономірностей; зниження затримок; зменшення службового трафіку; стабільність структури кластерів, гнучке налаштування пріоритетних метриків та параметрів у випадку RL; швидке прийняття рішень.	Необхідність навчання та у випадку з DL – датасетів; вразливості, пов'язані з навчанням; висока обчислювальна складність; відсутність математичного пояснення рішень у DL.
Інтегральні методи [16]	–	Об'єднання переваг інших методів; оптимізація якості обслуговування; стабільність.	Висока обчислювальна складність та, як наслідок, виснаження батареї; складність локальної реконфігурації кластерів.
Методи, що поєднують мобільні та програмно-конфігуровані мережі [21]	–	Глобальне бачення; швидке прийняття рішень; розвантаження звичайних та шлюзових вузлів, програмованість; а також покращення якості обслуговування та масштабованості.	Єдина точка відмови.

Висновки

Внаслідок того, що розміри мереж та їх щільність з часом лише збільшуються, а обсяги передавання трафіку та запит на якість та ефективність зростають, звичайні методи кластеризації та реконфігурації вичерпують свій ресурс ефективності. Також, згідно з аналізом, деякі методи, такі як традиційні евристики потребують мало ресурсів, але є суто реактивними, а впровадження глибокого навчання та навчання з підкріпленням забезпечують проактивний підхід, проте створюють значне навантаження на вузли мобільних мереж. Незважаючи на те, що наразі не існує ідеального типу методів кластеризації, поєднання використання кількох з них нівелює певні недоліки та об'єднує переваги, як наприклад, використання метаевристичних методів для налаштування гіперпараметрів навчання без вчителя. Тому релевантним є використання інтегральних методів. Окрім цього, актуальним та доцільним є впровадження методів кластеризації, що поєднують мобільні та програмно-конфігуровані мережі. Завдяки глобальному баченню та програмованості стає можливим формування кластерів таким чином, щоб максимізувати внутрішньокластерну маршрутизацію та мінімізувати зовнішньокластерну. Це своєю чергою дозволяє розвантажити звичайні та шлюзові вузли, мінімізувати затримки під час внутрішньокластерного прийняття рішень, покращити QoS та масштабованість. Більше того, це сприяє побудові стабільних кластерів, що зводить до мінімуму кількість реконфігурацій, частково нівелюючи таким чином негативний вплив одного з недоліків застосування програмно-конфігурованих мереж разом з MANET.

Література

1. *Hemalatha S., Shalini S., Sathiya U., Kumaravel P., Krishna S. V., Kulkarni P. H.* AI based cluster head based mobile adhoc network for performance improvement. Journal of Theoretical and Applied Information Technology. 2024. Vol. 102, no. 23. P. 8818–8826. URL: https://www.jatit.org/volumes/Vol102No23/30Vol102No23.pdf.

2. *Gatea A. N., Hashim H. Sh., Al-Asadi H. A. A., Tureli D. K., Abduljabbar Z. A., Nyangaresi V. O.* Towards the Development of Gaussian Clustering Algorithm Technology to Extend the Lifetime of MANETs. Engineering, Technology & Applied Science Research. 2025. Vol. 15, no. 2. P. 20984–20989. DOI: 10.48084/etasr.9375. URL: https://etasr.com/index.php/ETASR/article/view/9375.

3. *Srilakshmi U., Veeraiah N., Alotaibi Y., Alghamdi S. A., Khalaf O. I., Subbayamma B. V.* An Improved Hybrid Secure Multipath Routing Protocol for MANET. IEEE Access. 2021. Vol. 9. P. 163043–163053. URL: https://ieeexplore.ieee.org/document/9643001.

4. *Srilakshmi U., Alghamdi S. A., Vuyyuru V. A., Veeraiah N., Alotaibi Y.* A Secure Optimization Routing Algorithm for Mobile Ad Hoc Networks. IEEE Access. 2022. Vol. 10. P. 14260–14269. DOI: 10.1109/ACCESS.2022.3144679. URL: https://ieeexplore.ieee.org/abstract/document/9686745.

5. *Edwin Singh C., Sharon Priya S., Muthu Kumar B., Saravanan K., Neelima A., Gireesha B.* Trust aware fuzzy clustering based reliable routing in Manet. Measurement: Sensors. 2024. Vol. 33. Art. 101142. URL: https://www.sciencedirect.com/science/article/pii/S2665917424001181.

6. *Almufti S. M., Shaban A. A., Ali R. I., Dela Fuente J. A.* Overview of Metaheuristic Algorithms. Polaris Global Journal of Scholarly Research and Trends. 2023. Vol. 2, no. 2. P. 10–32. DOI: 10.58429/pgjsrt.v2n2a144. URL: https://www.researchgate.net/publication/370422753_Overview_of_Metaheuristic_Algorithms.

7. *Jaishankar B., Gururaj B., Muruganandham A., Nagarajan G.* Hybrid Clustering Approach (SG-MFOA) using Multipath Cross-Layer Design in MANET Network. IETE Journal of Research. 2024. Vol. 70, no. 9. P. 7495–7503. DOI: 10.1080/03772063.2024.2352646. URL: https://www.tandfonline.com/doi/full/10.1080/03772063.2024.2352646.

8. *Sharifi S. A., Babamir S. M.* The clustering algorithm for efficient energy management in mobile ad-hoc networks. Computer Networks. 2020. Vol. 166. Art. 106983. DOI: 10.1016/j.comnet.2019.106983. URL: https://www.sciencedirect.com/science/article/abs/pii/S1389128619302865.

9. *Khoei T. T., Kaabouch N.* Machine Learning: Models, Challenges, and Research Directions. Future Internet. 2023. Vol. 15, no. 10. Art. 332. DOI: 10.3390/fi15100332. URL: https://www.mdpi.com/1999-5903/15/10/332.

10. *Chen Q., Wu Q.* Dynamic Networking Method of Vehicles in VANET. Computers, Materials & Continua. 2024. Vol. 81, no. 1. P. 1301–1318. DOI: 10.32604/cmc.2024.054799. URL: https://www.sciencedirect.com/org/science/article/pii/S1546221824006908.

11. *Shahbazi M., Simsek M., Kantarci B.* AI-enabled cluster head selection through modified density based clustering in Aeronautical Ad Hoc Networks. Ad Hoc Networks. 2023. Vol. 148. Art. 103209. DOI: 10.1016/j.adhoc.2023.103209. URL: https://www.sciencedirect.com/science/article/abs/pii/S1570870523001294.

12. *Hussein A. A., Abdulrazzak H. N., Ali A. S.* MANET highly efficient clustering technique based on coverage k-means algorithm. Egyptian Informatics Journal. 2025. Vol. 30. Art. 100672. DOI: 10.1016/j.eij.2025.100672. URL: https://www.sciencedirect.com/science/article/pii/S1110866525000659.

13. *Sah S.* Machine Learning: A Review of Learning Types. Preprint. 2020. DOI: 10.20944/preprints202007.0230.v1. URL: https://www.researchgate.net/publication/342890321_Machine_Learning_A_Review_of_Learning_Types.

14. *Abdulhae O. T., Mandeep J. S., Islam M. T., Islam M. S.* Reinforcement-Based Clustering in Flying Ad-Hoc Networks for Serving Vertical and Horizontal Routing. IEEE Access. 2023. Vol. 11. P. 143881–143895. DOI: 10.1109/ACCESS.2023.3339533. URL: https://ieeexplore.ieee.org/abstract/document/10343150/.

15. *Amalia A., Pramitarini Y., Perdana R. H. Y., Shim K., An B.* A Cross-Layer FL-Based Clustering Protocol to Support Multicast Routing in IoT-Enabled MANETs With CF-mMIMO. IEEE Access. 2025. Vol. 13. P. 3881–3899. DOI: 10.1109/ACCESS.2025.3525636. URL: https://ieeexplore.ieee.org/abstract/document/10824772.

16. *Ali A. A., Hussein M. K., Subhi M. A.* A Classifier-Driven Deep Learning Clustering Approach to Enhance Data Collection in MANETs. Mesopotamian Journal of Cybersecurity. 2024. Vol. 4, no. 3. P. 36–45. DOI: 10.58496/MJCS/2024/014. URL: https://www.researchgate.net/publication/384368943_A_Classifier-Driven_Deep_Learning_Clustering_Approach_to_Enhance_Data_Collection_in_MANETs.

17. *Yilmaz K., Kara R., Katircioglu F.* Energy-Efficient Hybrid Adaptive Clustering for Dynamic MANETs. IEEE Access. 2025. Vol. 13. P. 51319–51331. DOI: 10.1109/ACCESS.2025.3552232. URL: https://ieeexplore.ieee.org/document/10930501.

18. *Nirmala Bai K. S., Subramanyam M. V.* HDOMLM: Hybrid Dual Optimized Machine Learning Model for Cluster Head Selection in MANET. International Research Journal of Multidisciplinary Technovation. 2025. Vol.

7, no. 3. P. 165–186. DOI: 10.54392/irjmt25314. URL: https://asianrepo.org/index.php/irjmt/article/view/150.

19. *Venkatasubramanian S.* Optimal Cluster Head Selection Using Vortex Search Algorithm with Deep Learning–Based Multipath Routing in MANET. IoT Based Control Networks and Intelligent Systems. 2022. Vol. 528. P. 81–98. DOI: 10.1007/978-981-19-5845-8_7. URL: https://link.springer.com/chapter/10.1007/978-981-19-5845-8_7.

20. *Fonti R., Piroddi A.* Enhancing Mobile Ad Hoc Networks (MANETs) with Software-Defined Networking (SDN): A Balanced Approach. Journal of Advances in Computer Networks. 2025. Vol. 13, No. 1. P. 7–14. DOI: 10.18178/jacn.2025.13.1.293.

21. *Kadhim A. J., Seno S. A. H., Shihab R. A.* Routing Protocol for SDN-Cluster Based MANET. Journal of Theoretical and Applied Information Technology. 2018. Vol. 96, no. 16. P. 5398–5412. URL: https://www.researchgate.net/publication/327685580_Routing_protocol_for_SDN-cluster_based_manet.

22. *Naser J. I., Kadhim A. J.* Multicast routing strategy for SDN-cluster based MANET. International Journal of Electrical and Computer Engineering. 2020. Vol. 10, no. 5. P. 4447–4457. DOI: 10.11591/ijece.v10i5.pp4447-4457. URL: https://www.researchgate.net/publication/341614598_Multicast_routing_strategy_for_SDN-cluster_based_MANET.

Кулаков Ю.О., Онищук М. О.

АНАЛІЗ МЕТОДІВ ДИНАМІЧНОЇ КЛАСТЕРИЗАЦІЇ В МОБІЛЬНИХ КОМП'ЮТЕРНИХ МЕРЕЖАХ

Оскільки з розвитком мобільних комп'ютерних мереж та збільшенням популярності та кількості пристроїв, що їх використовують, важливим є підвищення ефективності застосування мобільних комп'ютерних мереж, дана робота пропонує огляд існуючих динамічних методів реконфігурації.

Метою роботи є аналіз та групування методів формування кластерів, при цьому об'єктом є процес маршрутизації у мобільних комп'ютерних мережах, а предметом – методи кластеризації та реконфігурації у мобільних комп'ютерних мережах.

Методи, представлені у відібраних роботах було проаналізовано, систематизовано та знайдено їх сильні та слабкі сторони. Виділені категорії включають у себе детерміновані евристичні методи кластеризації, методи м'якої кластеризації (з застосуванням ймовірнісних моделей та нечіткої логіки), метаевристичні методи кластеризації, методи кластеризації з застосуванням машинного навчання (навчання без вчителя та навчання з підкріпленням, глибоке навчання), інтегральні методи кластеризації та методи кластеризації, що поєднують мобільні та SDN мережі.

На основі проведеного дослідження було зроблено висновок, що оскільки наразі не існує самостійних методів, що повністю задовольняли б сучасні вимоги, а також простежується можливість подолання викликів певних методів у разі їх комбінації з іншими типами, доцільним є застосування інтегральних методів кластеризації, що поєднують переваги різних типів. Також актуальним є використання методів кластеризації, що поєднують мобільні та програмно-конфігуровані мережі для підвищення гнучкості, стабільності та ефективності мобільних комп'ютерних мереж.

Ключові слова: *кластеризація, реконфігурація, голова кластера, контролер, MANET, SDN.*

Kulakov Y., Onyshchuk M.

ANALYSIS OF DYNAMIC CLUSTERING METHODS IN MOBILE COMPUTER NETWORKS

Since the development of mobile computer networks and the growing popularity and number of devices utilizing them make it crucial to improve the efficiency of mobile computer networks, this paper offers a review of existing dynamic reconfiguration methods.

The aim of this work is to analyze and group cluster formation methods, where the object of the study is the routing process in mobile computer networks, and the subject is the clustering and reconfiguration methods in mobile computer networks.

The methods presented in the selected papers were analyzed and systematized, and their strengths and weaknesses were identified. The defined categories include deterministic heuristic clustering methods, soft clustering methods (using probabilistic models and fuzzy logic), metaheuristic clustering methods, machine learning-based clustering methods (unsupervised learning, reinforcement learning, and deep learning), integral clustering methods, and clustering methods that combine mobile and SDN networks.

Based on the conducted research, it was concluded that since there are currently no standalone methods that fully satisfy modern requirements, and there is an opportunity to overcome the limitations of certain methods by combining them with other types, it is advisable to use integral clustering methods that combine the advantages of different types. It is also highly relevant to use clustering methods that integrate mobile and software-defined networks to enhance the flexibility, stability, and efficiency of mobile computer networks.

Keywords: *clustering, reconfiguration, cluster head, controller, MANET, SDN.*

Стаття подана до редакції: 27/09/2026
Стаття прийнята до опублікування:05/10/2026
Стаття опублікована: 10/11/2026

Стаття поширюється на умовах ліцензії CC BY 4.0