

**Беляков Р.О.**

<https://orcid.org/0000-0001-9882-3088>

Військовий інститут телекомунікацій та інформатизації імені Героїв Крут

**Чурілов І.О.**

<https://orcid.org/0009-0003-9627-3221>

Військовий інститут телекомунікацій та інформатизації імені Героїв Крут

## МОДЕЛЬ ІНТЕЛЕКТУАЛЬНОГО УПРАВЛІННЯ МАРШРУТИЗАЦІЄЮ НАЗЕМНО-ПОВІТРЯНИХ КОМУНІКАЦІЙНИХ МЕРЕЖ КЛАСУ MANET

*Стаття присвячена аналітичному опису моделі інтелектуального управління маршрутизацією в наземно-повітряній комунікаційній мережі класу MANET. Управління мережами MANET є складним завданням через високу мобільність вузлів, обмежені ресурси: енергію батареї, технічні характеристики комунікаційних засобів, протоколи різних рівнів моделі OSI з урахуванням особливостей побудови комунікаційних мереж повітряного та наземного рівня за умови мінімізації централізованого управління в них. Наукова новизна розробленої математичної моделі полягає в удосконаленні процесу формування управляючих рішень на мережевому, каналному та фізичному рівнях моделі OSI за рахунок одно-крокових нейромережевих алгоритмів на виконання користувальницьких вимог із забезпечення якості інформаційного обміну.*

*Досягнення поставленої мети передбачає формалізацію задачі управління у вигляді марковського процесу прийняття рішень з крос-рівневим описом стану мережі, синтез функції нагороди, що відображає компроміс між якістю обслуговування, енергоефективністю та обсягами службового трафіка, а також розробку децентралізованого алгоритму вибору маршрутів передачі та потужності радіовипромінювання на основі оцінки функції цінності стан-дія з урахуванням довірчих інтервалів стохастичних параметрів вузлів мережі.*

*Використання такого підходу може забезпечити ефективне управління мережею, адаптуючись до змін у середовищі та враховуючи різні цільові функції в режимі часу близького до реального.*

*Прогнозується, що застосування одно-крокових RL – алгоритмів із нейромережевою апроксимацією функції цінності в задачах управління маршрутизацією MANET-FANET є більш адекватним до нестационарних умов функціонування мережі, ніж багатокрокові або офлайн-орієнтовані підходи, оскільки дозволяє оперативно реагувати на локальні зміни топології, якості каналів та залишкової енергії вузлів.*

**Ключові слова:** маршрутизація, комунікаційна мережа, MANET, БпЛА, система інтелектуального управління, нейромережі, екстремальне машинне навчання, прогнозування, оцінка параметрів, вагові коефіцієнти, потужність радіовипромінювання.

**Постановка проблеми.** Управління наземно-повітряними комунікаційними мережами класу MANET-FANET є складним завданням через їхню динамічну природу, високу мобільність вузлів, обмежені ресурси (наприклад, енергію батареї, технічні характеристики комунікаційних засобів, протоколи різних рівнів моделі OSI, тощо), що в поєднанні із вимогою щодо зменшення рівня централізованого контролю вимагає розробки моделей, методів, методик, алгоритмів для підви-

щення продуктивності мобільних комунікаційних мереж спеціального призначення [1].

Зміна топології мереж такого класу відбувається дуже швидко, тому у авторів виникла ідея перейти від алгоритму AOS-ELM (як “швидкого регресора/класифікатора”), що в основі дослідження [1] до one-step нейромережевих алгоритмів (у сенсі одно-крокового бутстрепінгу в RL: TD(0), SARSA(0), Q-learning), адже у MANET-FANET топологія й стан каналів змінюються



швидше, ніж процес “накопичення” навчальних даних для прийняття оптимальних рішень.

**Аналіз останніх досліджень і публікацій.** Моделювання Ad-Hoc мереж є предметом досліджень низки науковців, що підтверджується працями у сфері MANET, VANET та FANET, а також методів інтелектуального керування мережевими параметрами та маршрутизацією [1–21]. У попередніх підходах науковці здійснювали оптимізацію функціонування мережі за одним або декількома показниками якості, з урахуванням енергетичної ефективності, стабільності зв'язності, швидкодії, надійності маршрутів і динаміки топології [10–13, 20–21]. У роботі [10] запропоновано багатокритеріальну стратегію оптимізації мережеских параметрів із орієнтацією на енергоефективність Ad-Hoc мереж, у [11] розглянуто модифікацію AODV із використанням реалістичної моделі мобільності, що дозволяє точніше враховувати поведінку вузлів у просторі, а в [12] представлено підхід багатокритеріального керування топологією бездротової мережі, що підвищує стійкість і керованість мережевої структури. У дослідженні [13] оптимізацію планування та передавання мультимедійних пакетів виконано з використанням гібридизованого генетичного алгоритму. Дослідження мобільності як одного з визначальних чинників ефективності MANET розглядається в роботах [2, 4, 14], де запропоновано відповідні моделі, механізми прогнозування або інтеграції наземних та повітряних компонентів мережі. Зокрема, в [14] обґрунтовано проблематику інтеграції FANET у мобільну комунікаційну мережу спеціального призначення, що є важливим для реалізації наземно-повітряних комунікаційних мереж.

На практиці помітну частку досліджень складають евристичні протоколи маршрутизації, які спираються на географічні критерії, прогнозування мобільності або біоінспіровані метаевристики. Так, географічний евристичний протокол для VANET запропоновано в [15], підхід прогнозування мобільності для UAV-мережі розглянуто в [19], алгоритмічні рішення на основі мурашиних колоній наведено в [16], а на основі бджолиних колоній – у [17].

Разом із тим, у ряді праць підкреслюється, що аналітично обґрунтовані алгоритми та глобальні оптимізаційні стратегії часто мають обмеження щодо застосування в реальних умовах високодинамічних мереж через обчислювальну складність, обмежені ресурси вузлів та неповноту інформації про стан мережі [10–13, 16–17].

З метою подолання зазначених обмежень останніми роками активно розвиваються протоколи маршрутизації та механізми керування мережевими параметрами на основі машинного навчання, що орієнтовані на роботу зі стрімінговими даними та адаптацію до зміни середовища [5, 7, 9].

Також широко застосовуються методи навчання з підкріпленням (RL, Reinforcement Learning), що дозволяють інтелектуальному агенту (вузлу комунікаційної мережі) формувати оптимальну стратегію дій на основі локальних спостережень та системи винагород [20–21]. Зокрема, в [20] представлено протокол маршрутизації FANET на основі Q-learning із врахуванням топологічних факторів, а в [21] запропоновано мультикритеріальну оптимізацію процесу маршрутизації повітряної комунікаційної мережі із використанням Q-learning.

Водночас слід зазначити, що хоча протоколи маршрутизації побудовані із використанням машинного навчання забезпечують переваги над класичними протоколами з точки зору адаптивності та здатності враховувати складні нелінійні закономірності мережеских процесів [3, 20–21], однак, на ряду із перевагами відносно традиційних протоколів маршрутизації, машинне навчання вимагає великих обсягів вихідних даних, що може викликати суттєві ресурсні витрати і для наземно-повітряних мереж вони розроблені фрагментарно.

Таким чином, оптимізація процесів інформаційного обміну в наземно-повітряних комунікаційних мережах шляхом удосконалення існуючих моделей інтелектуальних систем управління є перспективним напрямком наукових досліджень.

**Постановка завдання.** Метою роботи є удосконалення математичної моделі інтелектуального крос-рівневого управління маршрутизацією та радіоресурсами наземно-повітряної комунікаційної мережі класу MANET-FANET шляхом застосування одно-крокових нейромережеских алгоритмів підкріплювального навчання (one-step RL із нейромережевою апроксимацією функції цінності), які забезпечують оперативне формування децентралізованих управлінських рішень в умовах динамічної топології, обмежених енергетичних ресурсів вузлів та змінних характеристик радіоканалів.

Удосконалено математичну модель інтелектуального управління маршрутизацією в наземно-повітряних комунікаційних мережах класу MANET-FANET, у якій задача вибору маршруту передачі та потужності радіовипромінювання

формалізується як децентралізований Марківський процес прийняття рішень з крос-рівневим простором станів, що одночасно враховує параметри фізичного та мережевого рівнів моделі OSI.

**Виклад основного матеріалу. Вихідні умови функціонування мережі.** Розглядається наземна комунікаційна мобільна радіомережа класу MANET розмірністю до сотні мобільних вузлів, зони переміщення яких попередньо задані відповідно до визначених рангів [1]. Мобільні вузли поділяються на дві основні підмережі: наземна підмережа мобільних користувачів (переносні радіозасоби, радіозасоби на транспортних засобах) та повітряна підмережа (повітряна комунікаційна аероплатформа). Наземна комунікаційна мережа не має прив'язки до будь-якої телекомунікаційної інфраструктури загального користування. Кожен мобільний комунікаційний вузол оснащений системою позиціонування, комунікаційним обладнанням, антенними пристроями, системою живлення та відповідною системою управління. Кожен мобільний комунікаційний вузол може бути представлений як об'єкт із системою управління представленою сукупністю агентів навчання із специфічними для кожної підмережі цільовими функціями [3].

Для забезпечення швидкодії та точності формування множини управляючих рішень  $Y(t)$  інтелектуальної системи управління радіозв'язністю замість алгоритмів нечіткої логіки, алгоритмів екстремального машинного навчання [11], пропонується використовувати одно-крокові нейромережеві алгоритми навчання з підкріпленням.

Нехай наземно-повітряна комунікаційна мережа описується графом:

$$G^\psi(t) = (V^\psi, E^\psi), \psi \in \{1, 2, 3\},$$

де множина ребер  $E^\psi(t)$  визначається поточними умовами радіодоступності між вузлами, тобто радіозв'язністю між вузлами  $ij$  на  $\psi$  – му рівні  $Z_{ij}^\psi(t)$ .

Стан  $i$  – го вузла (локальний) формується на основі підмножини параметрів  $X^\psi(t)$ , отриманих з фізичного, каналного та мережевого рівнів моделі OSI. має вигляд:

$$s_i(t) = [e_i(t), p_i(t-1), \Delta BER_{ij}^\psi(t), \mathcal{N}_i(t), \Pi_{ij}^\psi, q_i(t), \widehat{d}_i^{(b)}(t)], \quad (1)$$

де  $e_i(t)$  – заряд батареї;

$\Delta BER_{ij}^\psi(t) = BER_{ij}^\psi(t) - BER_{ij}^\psi(t-1)$ ;  $\mathcal{N}_i(t) = \{j : Z_{ij}^\psi(t) = 1\}$  – вузли-сусіди;  $\Pi_{ij}^\psi$  – пріоритет трафіка;  $q_i(t)$  – локальна черга/навантаження (важливо для QoS);

$\widehat{d}_i^{(b)}(t) d^i(b)$  – оцінка “наближення” до адресата  $b$  (за GPS/ETX/географією), тобто, в дослідженні

припускається, що сигнали глобальної навігаційної супутникової системи наявні.

**Методологія дослідження.** В дослідженні було зроблено припущення, що використання одно-крокових нейромережевих алгоритмів навчання з підкріпленням (one-step RL із нейромережевою апроксимацією функції цінності) для прийняття управлінських рішень дозволить забезпечити суттєво більшу швидкість та точність управління процесами маршрутизації із урахуванням ресурсних обмежень.

Дії за Марківським процесом прийняття рішення.

Одна крос-рівнева дія вузла  $i$  :

$$a_i(t) = \text{big}(j^*(t), p_i^*(t)), \quad (2)$$

де  $j^* \in N_i(t)$  – вибір вузла наступного переходу, а  $p_i^*(t) \in [p_{min}, p_{max}]$  – потужність передачі.

В даному дослідженні, замість жорстких обмежень щодо вибору рішення із області допустимих рішень, для використання концепції одно-крокової оптимізації використовуються “м'які” обмеження через штрафи, що дозволяє забезпечити компроміс між QoS та ресурсними витратами в умовах динамічної топології MANET–FANET.

Таким чином, удосконалена нагорода  $L_i(t)$  через штрафи з урахуванням обмежень одно-крокової оптимізації в нагороду  $r_i(t)$  матиме вигляд:

$$L_i(t) = r_i(t) - \mu_1 [BER_{ij}^\psi(t) - BER_{дон}^\psi]_+ - \mu_2 [e_{min} - e_i(t)]_+, \quad (3)$$

де  $[x]_+ = \max(0, x)$  – функція позитивної частини, що забезпечує властивість зростання штрафу пропорційно величині порушення  $\mu_1, \mu_2 > 0$ ,  $\mu_1$  – коефіцієнт штрафу за порушення обмеження якості зв'язку (QoS),  $\mu_2$  – коефіцієнт штрафу за порушення енергетичного обмеження вузла.

Нагорода  $r_i(t)$  за «правильний» вибір (побудову, підтримку діючого) маршруту на виконання обмежень по потужності радіовипромінювання  $\{P(t), M(t)\}$ :

$$r_i(t) = \alpha_1 \cdot \underbrace{1}_{\text{зв'язність}} \{Z_{ij}^\psi(t) = 1\} - \alpha_2 \cdot \underbrace{E_{ij}(t)}_{\text{енерговитрати}} - \alpha_3 \cdot \underbrace{D_{ij}(t)}_{\text{затримка/черги}} - \alpha_4 \cdot \underbrace{O_i(t)}_{\text{службовий оверхед}} + \alpha_5 \cdot \underbrace{\Pi_{ij}^\psi}_{\text{пріоритет}},$$

де  $E_{ij}(t)$  можна представити як  $E_{ij}(t) \approx p_i(t) \cdot \Delta t + E_{\text{прос}}(t)$ , а  $O_i(t)$  – частка/обсяг контрольного трафіка (HELLO, RREQ/RREP тощо).

На жаль, у наукових публікаціях часто недостатньо деталізується вплив зростання обсягів службового трафіку на процес інформа-

ційного обміну, обмежуючись узагальненими поясненнями та посиланнями на технологічні компроміси функціонування мереж. Водночас підкреслюється, що штраф за оверхед – недооцінений важіль, так як в комунікаційних мережах MANET-FANET часто “оптимальний маршрут” математично існує, але в реальному часі руйнується саме сильним приростом службового трафіку в умовах високої мобільності (динамічної топології).

Для побудови децентралізованої політики керування маршрутизацією використовується one-step навчання з підкріпленням RL (RL – Reinforcement Learning). Функція  $Q_0(s, a)$  апроксимує очікувану сумарну дисконтовану нагороду при виконанні дії  $a$  у стані  $s$ . На кожному кроці формується one-step TD-ціль (TD – temporal difference: різниця між “новою ціллю” і “старою оцінкою”).

One-step TD-ціль (бутстрепінг на 1 крок).

Для оцінки  $Q_i(s, a)$ :

$$y_i(t) = r_i(t) + \gamma \max_a Q_i(s_i(t+1), a'), \quad (4)$$

та мінімізації втрат (квадратичної помилки):

$$\min (y_i(t) - Q_0(s_i(t), a_i(t)))^2. \quad (5)$$

У разі використання SARSA(0) замість оператора максимум  $\max_a Q_i$  підставляється фактично вибрана наступна дія  $a_i(t+1)$ , що відповідає навчанню за поточною політикою (on-policy).

У зв'язку із тим, що в умовах високої динаміки зміни топології MANET-FANET інтенсивність службового трафіка є двоспрямованим фактором: зростання службової інформації підвищує актуальність знань про стан мережі та покращує якість управлінських рішень, однак одночасно зменшує частку корисної пропускну здатності. Таким чином, *задача інтелектуального управління полягає у знаходженні компромісного значення  $O^*$ , що максимізує інтегральний показник ефективності мережі.*

Перевага запропонованого one-step RL із нейромережевою апроксимацією функції цінності підходу полягає в тому, що за використання one-step RL із нейромережевою апроксимацією функції цінності можливо адаптивно підбирати рівень “керування/оверхеду” не на пряму, бо: якщо часті перебудови маршрутів “корисні”, то RL це підсилить, і навпаки: якщо перебудови «з’їдають» канал, то RL отримає негативну нагороду і призупинить ці дії, утримуючи автоматичний баланс:

Тобто one-step RL із нейромережевою апроксимацією функції цінності забезпечує автоматичний баланс:

$$\max_{\pi} E \left[ \sum_t \gamma^t \left( \underbrace{C_{\text{data}}(t)}_{\text{корисний ефект}} - \alpha \underbrace{O(t)}_{\text{вартість керування}} \right) \right]. \quad (6)$$

Результати моделювання (рис. 1) процесу комунікаційного обміну за допомогою мови програмування Python із вихідними даними перерахованими вище для алгоритмів – AOS ELM, FOS ELM [7], Fuzzy (алгоритм нечіткої логіки) в порівнянні із запропонованим one-step RL підходом. Результат моделювання підтверджує гіпотезу про суттєве скорочення часу прийняття оптимальних рішень із управління маршрутизацією комунікаційних вузлів наземно-повітряної мережі.

Із графіку (рис. 1) легко помітити, що застосування one-step RL із нейромережевою апроксимацією функції цінності підходу забезпечує приріст точності прогнозування параметрів вузлів на 5,3% при порівняно меншому періоді навчання – на 10 с, ніж при застосуванні AOS ELM алгоритму, застосованого у вихідній моделі при однакових умовах. Під “accuracy” на графіку (рис. 1) у даній роботі розуміється інтегральний показник ефективності функціонування мережі  $J$ , який комплексно враховує коефіцієнт доставки пакетів, середню затримку, службовий трафік та енерговитрати вузлів мережі.

Таким чином, для мереж класу MANET-FANET, які характеризуються високою динамічністю топології, обмеженими енергетичними ресурсами та значною не стаціонарністю параметрів радіоканалів, доцільним є застосування підходів навчання із підкріпленням (Reinforcement Learning, RL). Це обґрунтовано тим, що поточний вибір вузла ретрансляції (next-hop) визначає не лише миттєву якість передачі, але й подальший прогнозований стан мережі, зокрема рівень енергоспоживання вузлів, стійкість радіозв'язності та інтенсивність службового трафіка, що формує довгострокову ефективність маршрутизації. У цьому контексті RL-формалізація задачі управління є більш природною порівняно з використанням лише регресійних моделей прогнозування, оскільки дозволяє оптимізувати послідовність керуючих дій із урахуванням їхніх майбутніх наслідків.

Разом з тим нейромережевий алгоритм Adaptive Online Sequential Extreme Learning Machine (AOS-ELM) доцільно розглядати ефективним компонентом інтелектуального агента комунікаційного вузла, що забезпечує швидке онлайн-навчання та адаптивне формування ознак стану мережі для подальшого прийняття

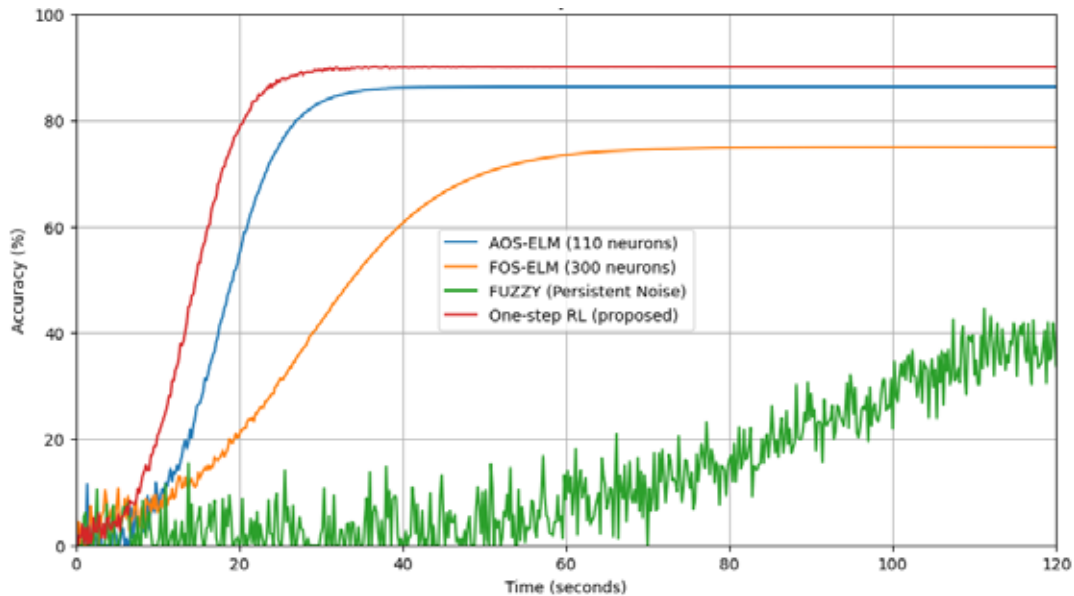


Рис. 1. Графіки точності та часу процесу формування управляючих рішень із управління маршрутизацією

рішень. Крім того, AOS-ELM може використовуватися як базовий алгоритм порівняння при оцінці результативності запропонованого підходу, що забезпечує коктність експериментальної верифікації та підвищує обґрунтованість отриманих висновків.

**Висновки.** В статті представлено удосконалену математичну модель інтелектуального управління маршрутизацією наземно-повітряної комунікаційної мережі класу MANET, проведено формалізований опис запропонованої моделі.

Наукова новизна полягає в переході до one-step RL як ядра децентралізованого крос-рівневого управління маршрутизацією та потужністю у MANET–FANET, із штрафним врахуванням

QoS/енергії та додатковим врахуванням інтенсивності службового трафіку.

Теоретична цінність розробленого наукового результату полягає у формалізації управління як Марківського процесу із крос-рівневим станом і інтегральною функцією корисності, що створює чіткий математичний фундамент для подальшого розвитку інтелектуальних систем управління для даного класу комунікаційних мереж.

Запропонована модель може бути використана для проєктування мереж спецпризначення з високою мобільністю та ресурсними обмеженнями. Напрямок подальших досліджень полягає у розробці методу маршрутизації на основі розробленої моделі та особливостей воєнного середовища функціонування.

#### Список літератури:

1. Беляков Р. О., Фесенко О. Д. Удосконалена модель інтелектуального управління вузловими ресурсами комунікаційної мережі класу MANET. *Scientific Notes of Taurida National V. Vernadsky University. Series: Technical Sciences*. 2023. № 5. С. 93–98. DOI: <https://doi.org/10.32782/2663-5941/2023.5/16>.
2. Беляков Р. О., Фесенко О. Д. Модель мобільності наземної комунікаційної мережі спеціального призначення. *Computer-Integrated Technologies: Education, Science, Production*. 2023. № 51. С. 130–138. DOI: <https://doi.org/10.36910/6775-2524-0560-2023-51-17>.
3. Phull N., et al. Enhancing vehicular ad hoc networks' dynamic behavior by integrating game theory and machine learning techniques for reliable and stable routing. *Security and Communication Networks*. 2022. Vol. 2022. P. 1–11. DOI: <https://doi.org/10.1155/2022/4108231>.
4. Hosek J., et al. Implementation of mobility management methods for MANET. *International Journal of Advances in Telecommunications, Electrotechnics, Signals and Systems*. 2012. Vol. 1, № 2–3. DOI: <https://doi.org/10.11601/ijates.v1i2-3.39>.
5. Cao W., et al. Fuzziness-based online sequential extreme learning machine for classification problems. *Soft Computing*. 2018. Vol. 22, № 11. P. 3487–3494. DOI: <https://doi.org/10.1007/s00500-018-3021-4> (дата звернення: 13.09.2023).

6. Romaniuk V. A., Bieliakov R. O. Objective control functions of FANET communication nodes of land-air network. *Computer-Integrated Technologies: Education, Science, Production*. 2023. № 50. P. 125–130. DOI: <https://doi.org/10.36910/6775-2524-0560-2023-50-19>.
7. Yang R., Xu S., Feng L. An ensemble extreme learning machine for data stream classification. *Algorithms*. 2018. Vol. 11, № 7. P. 107. DOI: <https://doi.org/10.3390/a11070107> (дата звернення: 13.09.2023).
8. Zhebka V. V. Research of machine learning methods and their application for forecasting use outflow by telecommunications services. *Connectivity*. 2020. Vol. 146, № 4. DOI: <https://doi.org/10.31673/2412-9070.2020.042231>.
9. Zhang J., Li Y., Xiao W. Adaptive online sequential extreme learning machine for dynamic modeling. *Soft Computing*. 2020. DOI: <https://doi.org/10.1007/s00500-020-05289-6> (дата звернення: 13.09.2023).
10. Olascuaga-Cabrera J. G., Lopez-Mellado E., Mendez-Vazquez A. A multi-objective PSO strategy for energy-efficient ad-hoc networking. *IEEE Cybernetics Systems: Man (SMC) Conference : proceedings*. 2011.
11. Babaei H., Romoozi M. Multi objective AODV based on a realistic mobility model. *IJCSI International Journal of Computer Science Issues*. 2010. Vol. 7, Issue 3, № 3. May.
12. Banner R., Orda A. Multi-objective topology control in wireless networks. *IEEE INFOCOM : proceedings*. 2008.
13. Selvi R., Rajaram R. Multiple-objective optimization of multimedia packet scheduling for ad hoc networks through hybridized genetic algorithm. *International Journal of Multimedia & Its Applications (IJMA)*. 2011. Vol. 3, № 3. August.
14. Беляков Р. Проблема інтеграції повітряної мережі класу FANET в мобільну комунікаційну мережу спеціального призначення. *Computer-Integrated Technologies: Education, Science, Production*. 2023. № 53. С. 263–276. DOI: <https://doi.org/10.36910/6775-2524-0560-2023-53-40>.
15. Urquiza-Aguilar L., Tripp-Barba C., Igartua M. A. A geographical heuristic routing protocol for VANETs. *Sensors*. 2016. Vol. 16. P. 1567.
16. Yu Y., Ru L., Chi W., Liu Y., Yu Q., Fang K. Ant colony optimization based polymorphism-aware routing algorithm for ad hoc UAV network. *Multimedia Tools and Applications*. 2016. Vol. 75. P. 14451–14476.
17. Zhao B., Ding Q. Route discovery in flying ad-hoc network based on bee colony algorithm. *2019 IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA), 29–31 March : proceedings*. Dalian, China, 2019. P. 364–368.
18. Patel J., El-Ocla H. Energy efficient routing protocol in sensor networks using genetic algorithm. *Sensors*. 2021. P. 7060.
19. Lin L., Sun Q., Wang S., Yang F. A geographic mobility prediction routing protocol for ad hoc UAV network. *2012 IEEE Globecom Workshops : proceedings*. Anaheim, CA, USA, 3–7 December 2012. P. 1597–1602.
20. Arafat M. Y., Moh S. A Q-learning-based topology-aware routing protocol for flying ad hoc networks. *IEEE Internet of Things Journal*. 2022. Vol. 9. P. 1985–2000.
21. Liu J., Wang Q., He C., Jaffrès-Runser K., Xu Y., Li Z., Xu Y. QMR: Q-learning based multi-objective optimization routing protocol for flying ad hoc networks. *Computer Communications*. 2020. Vol. 150. P. 304–316.

## **Bieliakov R.O., Churilov I.O. INTELLIGENT ROUTING CONTROL MODEL FOR GROUND–AIR MANET-CLASS COMMUNICATION NETWORKS**

*The paper is devoted to an analytical description of an intelligent routing control model for a ground–air communication network of the MANET class. Managing MANETs is a challenging task due to the high mobility of nodes and limited resources, including battery energy, technical characteristics of communication equipment, and protocol constraints across multiple layers of the OSI model. These challenges are further intensified by the architectural specifics of integrating airborne and terrestrial network segments under the requirement of minimizing centralized control. The scientific novelty of the proposed mathematical model lies in improving the process of generating control decisions at the network, data link, and physical layers of the OSI model by employing one-step neural network–based algorithms to meet user requirements for information exchange quality.*

*Achieving the stated objective involves formalizing the control problem as a Markov decision process with a cross-layer state representation of the network, designing a reward function that captures the trade-off between Quality of Service, energy efficiency, and control traffic overhead, as well as developing a decentralized algorithm for selecting the next-hop relay and transmission power based on the state–action value function estimation while accounting for confidence intervals of stochastic node parameters.*

*The proposed approach can provide effective network control by adapting to environmental changes and simultaneously considering multiple objective functions in near real-time. It is expected that applying one-step reinforcement learning algorithms with neural network approximation of the value function to MANET–*

*FANET routing control tasks is more suitable for non-stationary network operation conditions than multi-step or offline-oriented approaches, since it enables rapid response to local variations in topology, channel quality, and residual node energy.*

**Keywords:** *routing, communication network, MANET, UAV, intelligent control system, neural networks, extreme learning machine, forecasting, parameter estimation, weighting coefficients, radio transmission power.*

Дата першого надходження статті до видання: 24.01.2026

Дата прийняття статті до друку після рецензування: 20.02.2026

Дата публікації (оприлюднення) статті: 08.04.2026